

UNIVERSIDADE FEDERAL DO PARANÁ

GUILHERME DE QUEIROZ LIMA ROTH

DANTE DA SILVA ALEO

MAPEAMENTO SISTEMÁTICO DA LITERATURA SOBRE
O USO DA INTELIGÊNCIA ARTIFICIAL GENERATIVA NO AUDIOVISUAL NÃO
INTERATIVO

CURITIBA PR

2025

GUILHERME DE QUEIROZ LIMA ROTH
DANTE DA SILVA ALEO

MAPEAMENTO SISTEMÁTICO DA LITERATURA SOBRE
O USO DA INTELIGÊNCIA ARTIFICIAL GENERATIVA NO AUDIOVISUAL NÃO
INTERATIVO

Trabalho apresentado como requisito parcial à conclusão do Curso de Bacharelado em Ciência da Computação, Setor de Ciências Exatas, da Universidade Federal do Paraná.

Área de concentração: *Computação*.

Orientadora: Natasha Malveira Costa Valentim.

Coorientador: Rafael de Andrade Pereira.

CURITIBA PR

2025

Ficha catalográfica

Substituir o arquivo `0-iniciais/catalografica.pdf` pela ficha catalográfica fornecida pela Biblioteca da UFPR (PDF em formato A4).

Instruções para obter a ficha catalográfica e fazer o depósito legal da tese/dissertação (contribuição de André Hochuli, abril 2019. Links atualizados Wellton Costa, Nov 2022):

1. Estas instruções se aplicam a dissertações de mestrado e teses de doutorado. Trabalhos de conclusão de curso de graduação e textos de qualificação não precisam segui-las.
2. Verificar se está usando a versão mais recente do modelo do PPGInf e atualizar, se for necessário (<https://gitlab.c3sl.ufpr.br/maziero/tese>).
3. conferir o *checklist* de formato do Sistema de Bibliotecas da UFPR, em <https://bibliotecas.ufpr.br/servicos/normalizacao/>
4. Enviar e-mail para "referencia.bct@ufpr.br" com o arquivo PDF da dissertação/tese, solicitando a respectiva ficha catalográfica.
5. Ao receber a ficha, inseri-la em seu documento (substituir o arquivo `0-iniciais/catalografica.pdf` do diretório do modelo).
6. Emitir a Certidão Negativa (CND) de débito junto a biblioteca, em <https://bibliotecas.ufpr.br/servicos/certidao-negativa/>
7. Avisar a secretaria do PPGInf que você está pronto para o depósito. Eles irão mudar sua titulação no SIGA, o que irá liberar uma opção no SIGA pra você fazer o depósito legal.
8. Acesse o SIGA (<http://www.prppg.ufpr.br/siga>) e preencha com cuidado os dados solicitados para o depósito da tese.
9. Aguarde a confirmação da Biblioteca.
10. Após a aprovação do pedido, informe a secretaria do PPGInf que a dissertação/tese foi depositada pela biblioteca. Será então liberado no SIGA um link para a confirmação dos dados para a emissão do diploma.

Ficha de aprovação

Substituir o arquivo 0-iniciais/aprovacao.pdf pela ficha de aprovação fornecida pela secretaria do programa, em formato PDF A4.

AGRADECIMENTOS

Guilherme:

Este trabalho representa o desfecho de uma etapa longa, árdua e, em muitos momentos, extenuante. O resultado de esforços acumulados ao longo de anos, atravessando desafios acadêmicos, emocionais e pessoais que, por vezes, pareceram intransponíveis. A conclusão desta jornada é, ao mesmo tempo, um ato de resistência e de gratidão.

Nenhum percurso dessa natureza é trilhado em isolamento. Por isso, registro aqui meus mais profundos agradecimentos a todos que, de algum modo, contribuíram para que este trabalho se tornasse possível.

Agradeço à **Professora Dra. Natasha Malveira Costa Valentim**, cuja orientação foi pautada pela atenção, sensatez e compromisso intelectual. Sua exigência criteriosa e clareza de pensamento transformaram uma ideia dispersa em um projeto sólido, sem jamais perder de vista a humanidade que deve sustentar qualquer pesquisa digna de seu nome.

Ao **mestrando Rafael Andrade**, pela coorientação, pelas discussões fecundas e pelas contribuições técnicas que refinaram o rigor científico e a estrutura deste estudo.

A certos **professores da Universidade Federal do Paraná** que, com verdadeira dedicação ao ensino, ofereceram o conhecimento e o estímulo necessários para minha formação. Saibam, estes, que estarão em minha lembrança.

Registro também meu reconhecimento aos **profissionais de psicologia** que me acompanharam ao longo dessa jornada. Sua escuta atenta e o equilíbrio que me ajudaram a reencontrar foram tão essenciais quanto qualquer descoberta teórica.

À minha **família**, cuja presença, paciência e amor incondicional sustentaram cada passo dado quando as forças pareciam esgotadas.

Por fim, deixo um agradecimento especial à minha **noiva, Helena Mallin**, e aos meus amigos **Leonardo Ramos** e **Enzo Marques**. O apoio, a compreensão e a amizade de vocês foram o alicerce invisível e luminoso que manteve este projeto de pé - e, em muitos momentos, a razão pela qual ele não sucumbiu. Helena, tua ternura e tua força serena foram um forte lembrete de que o amor também é forma de coragem. Leonardo e Enzo, a presença de vocês foi o abrigo necessário nas horas em que o cansaço parecia vencer. A amizade de vocês é uma dádiva que nenhuma conquista supera!

Dante:

Este trabalho não representa apenas o desfecho de uma etapa acadêmica, ele é a materialização de um sonho antigo e muito batalhado. A conclusão desta jornada é a realização de anos de luta, um percurso árduo, mas extremamente realizador. Chegar aqui, formar-se na Universidade Federal do Paraná (UFPR) é o resultado de esforços acumulados, atravessando desafios acadêmicos, emocionais e pessoais que, por vezes, pareceram intransponíveis. A entrega deste trabalho é, sobretudo, um ato de resistência e profunda gratidão.

A minha profunda gratidão se dirige, em primeiro lugar, à Professora Dra. Natasha Malveira Costa Valentim. Sua liderança na orientação foi marcada por uma dedicação atenta e um compromisso intelectual inquestionável. Acima de tudo, sou grato por sua habilidade em manter a dimensão humana como o fundamento de todo trabalho científico. Seu empenho foi fundamental para que este projeto fosse concretizado.

Ao Doutorando Rafael Andrade, agradeço pela valiosa coorientação. Suas análises perspicazes e o apoio técnico foram decisivos para aprimorar o rigor metodológico e a arquitetura final deste estudo, culminando em discussões que se mostraram extremamente produtivas.

Expresso meu reconhecimento aos professores da Universidade Federal do Paraná do Departamento de Informática. Sua paixão e dedicação ao ensino e a generosidade em compartilhar o conhecimento proporcionaram a base e o incentivo vitais para o meu desenvolvimento acadêmico e me incentivaram a não desistir. Tenho a certeza de que a influência e a dedicação de cada um já são e serão lembradas como pontos de referência em minha trajetória.

A todos os aqui nomeados e àqueles que contribuíram em silêncio, reitero o meu mais sincero muito obrigado. Este trabalho é o resultado da minha persistência, mas também da força inquebrantável que encontrei em cada um de vocês. O final desta travessia na Universidade Federal do Paraná não é um ponto final, mas sim o lançamento para novos começos e que irei carregar para sempre, todos os ensinamentos no meu coração.

RESUMO

Este trabalho apresenta um Mapeamento Sistemático da Literatura (MSL) sobre Inteligência Artificial Generativa (IAG) aplicada à produção audiovisual não interativa. Com recorte temporal entre 2022 e 2025, a pesquisa busca identificar aplicações práticas, desafios técnicos e criativos, e impactos éticos e socioeconômicos associados ao uso de IAG (p.ex. GANs, modelos de difusão e *transformers*) em filmes, animações, publicidade e efeitos visuais. O protocolo descreve a estratégia de busca utilizada nas bases IEEEExplore e ACM Digital Library, e define critérios claros de inclusão/exclusão, além de um processo de triagem em duas fases (título/resumo e leitura completa) com apoio da plataforma Porifera. A extração de dados segue 17 subquestões (SQ1–SQ17) sobre tipo de contribuição, tecnologias adotadas, métricas de avaliação, métodos empíricos, questões éticas e impactos na indústria. O protocolo também documenta problemas recorrentes de ruído nos resultados (por exemplo, estudos sobre jogos interativos, detecção de deepfakes ou aplicações biomédicas) e propõe filtros e ajustes para mitigá-los. Espera-se produzir um panorama quantitativo das publicações, desafios técnicos e éticos, e recomendações para padronização de métricas e direções futuras de pesquisa.

Palavras-chave: Inteligência Artificial Generativa, Produção audiovisual, Mapeamento Sistemático da Literatura, LLMs, Ética.

ABSTRACT

The emergence of Generative Artificial Intelligence (GAI) has significantly transformed creative processes, including those in audiovisual production. This research conducts a Systematic Mapping Study (SMS) to investigate how GAI has been applied in non-interactive audiovisual contexts, such as film, television, and video editing between 2022 and 2025. The study aims to identify the main purposes, techniques, and impacts of these applications, as well as the types of generative models and evaluation approaches adopted in the literature. The research follows the PICOC structure to define its scope and uses IEEE Xplore and ACM Digital Library as primary data sources. After applying inclusion and exclusion criteria, the selected studies are analyzed through 17 specific sub-questions (SQ1–SQ17) that examine the models, datasets, outputs, and intentions behind the use of GAI. The results are expected to provide a comprehensive overview of current research trends, reveal gaps in methodological rigor, and support future investigations on the role of generative AI in audiovisual creation and post-production.

Keywords: Generative Artificial Intelligence, Audiovisual Production, Systematic Mapping Study, Large Language Models (LLMs), Ethics, Non-interactive Media

LISTA DE TABELAS

3.1	Objetivo do MSL de acordo com o modelo GQM	19
3.2	As subquestões da pesquisa	21
3.3	Fonte utilizada no MSL	24
3.4	Strings utilizadas no MSL	24
4.1	SQ1- Tipo de contribuição do artigo	33
4.2	SQ2- Área do conhecimento do estudo	33
4.3	SQ3- Foco principal da aplicação da IAG	34
4.4	SQ4- Tecnologia de IAG empregada	34
4.5	SQ5- Forma de uso da ferramenta de IAG	35
4.6	SQ6- Desafios técnicos identificados	36
4.7	SQ7- Desafios éticos e criativos	36
4.8	SQ8- Apresentação de análises empíricas	37
4.9	SQ8.1- Método empírico adotado	37
4.10	SQ9- Finalidade principal da IAG	37
4.11	SQ10- Tipos de conteúdos gerados	38
4.12	SQ11- Tipo de dispositivo/tecnologia utilizada.	38
4.13	SQ12- Tipo de interação com a IAG	39
4.14	SQ13- Modelo específico utilizado	39
4.15	SQ14- Modelos/benchmarks para validação	40
4.16	SQ16- Desafios quanto à reprodutibilidade e confiabilidade	40
4.17	SQ17- Intenção de tornar perceptível o uso da IAG	41

LISTA DE ACRÔNIMOS

DINF	Departamento de Informática
PPGINF	Programa de Pós-Graduação em Informática
UFPR	Universidade Federal do Paraná
MSL	Mapeamento Sistemático da Literatura
IAG/GAI	Inteligência Artificial Generativa
IA	Inteligência Artificial
GAN/GANs	Redes Adversariais Generativas
PICOC	Population, Intervention, Comparison, Outcome, Context
SQ/SQs	Subquestões de Pesquisa

SUMÁRIO

1	INTRODUÇÃO	13
1.1	DESAFIO	13
1.2	MOTIVAÇÃO	14
1.3	PROPOSTA	14
1.4	METODOLOGIA	15
1.5	CONTRIBUIÇÃO	15
1.6	ORGANIZAÇÃO DO DOCUMENTO	16
2	TRABALHOS RELACIONADOS	17
3	MAPEAMENTO SISTEMÁTICO DA LITERATURA (MSL)	19
3.1	CONTEXTO	19
3.2	OBJETIVO	19
3.2.1	Questão principal de pesquisa	20
3.2.2	Subquestões de pesquisa	20
3.3	ESTRATÉGIAS E MÉTODOS DE BUSCA DE PUBLICAÇÕES	23
3.4	IDIOMA DOS ARTIGOS	24
3.5	PROCEDIMENTOS DE SELEÇÃO E CRITÉRIOS	24
3.5.1	Critérios de inclusão (CI)	25
3.5.2	Critérios de exclusão (CE)	25
3.5.3	Estratégias para condução do MSL	25
3.6	EXTRAÇÃO DE DADOS E PROCESSAMENTO AUTOMATIZADO	26
3.6.1	Metodologia de extração e organização de dados	26
3.6.2	Uso de ferramentas de IAG no preenchimento	26
3.6.3	Regras de preenchimento	27
3.6.4	Processamento automatizado dos dados	27
3.7	LIMITAÇÕES E GARANTIAS METODOLÓGICAS	28
3.7.1	Decisões humanas na triagem	29
3.7.2	Validação dos scripts de processamento	29
3.7.3	Corretude Algorítmica e Equivalência de Resultados Finais	30
4	RESULTADOS QUANTITATIVOS E DISCUSSÃO	31
4.1	PROCESSO DE SELEÇÃO E VISÃO GERAL DOS RESULTADOS	31
4.2	RESULTADO FINAL DO PROCESSO DE FILTRAGEM	32
4.2.1	Artigos Rejeitados desde o 1º Filtro	32
4.2.2	Artigos Aprovados no 1º Filtro e Recusados no 2º Filtro	32
4.2.3	Artigos Aprovados Após o 2º Filtro (Conjunto Final)	33

4.3	RESULTADOS QUANTITATIVOS POR SUBQUESTÕES	33
4.3.1	SQ1: Tipo de Contribuição do Artigo	33
4.3.2	SQ2: Área do Conhecimento	33
4.3.3	SQ3: Foco Principal da Aplicação da IAG	34
4.3.4	SQ4: Tecnologia de IAG Empregada	34
4.3.5	SQ5: Forma de Uso da Ferramenta de IAG	35
4.3.6	SQ6: Desafios Técnicos Identificados	35
4.3.7	SQ7: Desafios Éticos e Criativos	36
4.3.8	SQ8: Apresentação de Análises Empíricas	36
4.3.9	SQ8.1: Método Empírico Adotado	37
4.3.10	SQ9: Finalidade Principal da IAG	37
4.3.11	SQ10: Tipos de conteúdos gerados	38
4.3.12	SQ11: Tipo de dispositivo/tecnologia utilizada pelo usuário	38
4.3.13	SQ12: Tipo de interação com a IAG	39
4.3.14	SQ13: Modelo específico utilizado	39
4.3.15	SQ14: Modelos/Benchmarks para Validação	40
4.3.16	SQ16: Desafios quanto à Reprodutibilidade e Confiabilidade	40
4.3.17	SQ17: Intenção de Tornar Perceptível o Uso da IAG	40
4.4	ANÁLISE INTEGRADA E DISCUSSÃO DOS RESULTADOS	41
4.4.1	SQ1: Predominância de Propostas de Solução em Campo Tecnológico em Expansão	41
4.4.2	SQ2: Consolidação em Mídia e Entretenimento com Crescente Interdisciplinaridade	42
4.4.3	SQ3: Geração de Vídeo como Foco Central, mas Fragmentação de Aplicações	42
4.4.4	SQ4: Hegemonia Consolidada de Modelos de Difusão e Transformers	43
4.4.5	SQ5: Combinação de Ferramentas como Estratégia Dominante	43
4.4.6	SQ6: Coerência Temporal Persiste como Desafio Central	44
4.4.7	SQ7: Preocupações Éticas Concentradas em Impacto Profissional e Autoria	44
4.4.8	SQ8 e SQ8.1: Presença forte de análises empíricas, mas com métodos diversos	45
4.4.9	SQ9: Diversidade de finalidades com foco em pós-produção e narrativas	45
4.4.10	SQ10: Imagens estáticas e animações como conteúdos predominantes	45
4.4.11	SQ11: Computadores e nuvem como infraestrutura dominante	46
4.4.12	SQ12: Prompts textuais como modalidade de interação hegemônica	46
4.4.13	SQ13: Concentração em poucos modelos comerciais dominantes	47
4.4.14	SQ14: Validação dual: qualitativa por especialistas e quantitativa por métricas	47
4.4.15	SQ16: Dependência de dados e variabilidade como obstáculos à reprodutibilidade	48
4.4.16	SQ17: Ambiguidade ética sobre transparência no uso de IAG	48
4.4.17	Síntese: Padrões e Lacunas	49

5	CONSIDERAÇÕES FINAIS	50
5.1	APLICAÇÕES IDENTIFICADAS	50
5.2	TECNOLOGIAS DOMINANTES	50
5.3	DESAFIOS TÉCNICOS	50
5.4	DESAFIOS ÉTICOS E CRIATIVOS.	51
5.5	REFLEXÕES FINAIS E PERSPECTIVAS FUTURAS	51
	REFERÊNCIAS	53
	APÊNDICE A – DOI’S DOS ARTIGOS.	55

1 INTRODUÇÃO

1.1 DESAFIO

A Inteligência Artificial (IA) refere-se a sistemas computacionais capazes de realizar tarefas que normalmente exigiriam inteligência humana, como reconhecimento de padrões, tomada de decisões e processamento de linguagem natural (Russell e Norvig, 2016). Dentro desse campo, a Inteligência Artificial Generativa (IAG) representa um avanço significativo: trata-se de um conjunto de técnicas que permite a criação autônoma de novos conteúdos (textos, imagens, vídeos, áudio) a partir do aprendizado de padrões em grandes volumes de dados.

O processo de criação pela IAG pode ser compreendido em três etapas. Primeiro, o modelo é treinado com milhares ou milhões de exemplos, aprendendo estruturas e características recorrentes. Segundo, esse conhecimento é refinado através de ajuste fino (*fine-tuning*), adaptando-o para contextos específicos ou objetivos particulares. Terceiro, o sistema gera conteúdos inéditos baseados no que assimilou, produzindo desde imagens fotorrealistas até narrativas coerentes.

Diferentes arquiteturas compõem esse universo tecnológico. As redes adversariais generativas (*Generative Adversarial Networks* - GANs) são compostas por dois modelos que competem entre si: o gerador, responsável por criar novos conteúdos, e o discriminador, encarregado de avaliar a autenticidade dessas produções. Essa dinâmica adversarial permite que o sistema refine continuamente sua capacidade de gerar resultados visualmente convincentes (Goodfellow et al., 2014). O StyleGAN2, por exemplo, demonstrou capacidade de gerar rostos humanos praticamente indistinguíveis de fotografias reais (Karras et al., 2020). Já os modelos de difusão funcionam revertendo gradualmente processos de ruído, refinando imagens e vídeos até alcançarem alta qualidade (Dhariwal e Nichol, 2021). Por fim, os transformers, inicialmente desenvolvidos para processar linguagem, foram adaptados para tarefas visuais e sonoras (Vaswani et al., 2017). O GPT (*Generative Pre-trained Transformer*), por exemplo, cria textos contextualizados e narrativamente coerentes (Brown et al., 2020).

A IAG pode ser utilizada em grande escala também no setor audiovisual, que abrange desde cinema e televisão até produções digitais para internet, publicidade e videocliques, qualquer conteúdo baseado em imagens em movimento que comunique ideias, conte histórias ou provoque experiências sensoriais (Cenerini et al., 2025). Essas tecnologias generativas estão sendo progressivamente integradas nesse setor para múltiplas finalidades: automação de edição de vídeo, geração de efeitos visuais (*Visual Effects* - VFX) e efeitos especiais, criação de cenas e cenários virtuais, composição de trilhas sonoras originais, dublagem automatizada com sincronização labial precisa, desenvolvimento de roteiros e diálogos, síntese de vozes realistas, e até a criação completa de personagens digitais. Essas aplicações prometem não apenas reduzir custos e tempo de produção, mas também democratizar o acesso a ferramentas antes restritas a grandes estúdios, permitindo que criadores independentes explorem novas linguagens estéticas e narrativas.

Contudo, essa revolução traz desafios fundamentais. Como garantir autenticidade quando máquinas produzem conteúdo indistinguível do criado por humanos? Como proteger direitos autorais quando modelos aprendem com obras protegidas? Como identificar e mitigar vieses algorítmicos que podem perpetuar estereótipos? A ausência de métricas padronizadas para avaliar qualidade e confiabilidade dificulta tanto a validação científica quanto a reprodutibilidade dos resultados (Karras et al., 2020). Persistem também problemas técnicos significativos:

inconsistências narrativas, sincronização imperfeita entre áudio e vídeo, e limitações na geração de conteúdos longos e complexos.

O impacto socioeconômico merece atenção especial. A automação de processos criativos pode concentrar poder em grandes corporações tecnológicas, reduzir oportunidades para profissionais independentes e ampliar desigualdades no acesso a ferramentas avançadas. A ausência de regulamentação específica cria vácuo legal quanto à autoria e à proteção de direitos intelectuais (Capraro et al., 2024).

Esse cenário revela uma contradição preocupante: enquanto a tecnologia avança exponencialmente, as normas éticas, jurídicas e metodológicas permanecem atrasadas. Essa lacuna aumenta a vulnerabilidade a abusos, como disseminação de conteúdos manipulados e apropriação indevida de obras geradas por IA.

O desafio central desta pesquisa é, portanto, compreender as aplicações, limitações e impactos da IAG na produção audiovisual não interativa (obras lineares como filmes, séries, curtas e videocliques, nas quais o espectador não interfere diretamente na narrativa). Elementos artísticos criados por IAG para jogos, como *sprites*, artes conceituais e cenários serão considerados como produções audiovisuais independentes, não como parte da lógica interativa do jogo.

Além disso, restringimos a análise a estudos sobre geração ou modificação de conteúdos audiovisuais. Trabalhos focados exclusivamente em detecção de *deepfakes*, que são manipulações que substituem rostos ou alteram falas usando IA, não são considerados neste trabalho, pois não se enquadram no objetivo de compreender processos criativos mediados por IA.

1.2 MOTIVAÇÃO

A partir de 2022, a popularização de ferramentas como ChatGPT, DALL·E 2 e Stable Diffusion marcou um ponto de inflexão (Brown et al., 2020), (Rombach et al., 2022). Relatórios de mercado indicam que a IAG deve atingir US\$ 109,37 bilhões até 2030. A taxa de crescimento anual prevista é de 37,6% entre 2025 e 2030 (Grand View Research, 2023).

Esse crescimento acelerado evidencia relevância tecnológica e urgência em compreender impactos. Quanto maior a adoção, maior a necessidade de diretrizes claras para mitigar riscos éticos, jurídicos e criativos. Sem regulamentação adequada, a expansão da IAG pode levar à concentração de poder, à precarização do trabalho e à proliferação de conteúdos manipulados.

No setor audiovisual, essas tecnologias já são aplicadas em roteirização, VFX, dublagem, edição automatizada e até na criação de vídeos completos. A tendência promete reduzir custos, agilizar fluxos e expandir possibilidades criativas, permitindo que artistas e produtores explorem novas linguagens e formatos.

Por outro lado, surgem preocupações legítimas. Entre elas, a substituição de profissionais humanos, a perda de autenticidade artística, a violação de direitos autorais e a disseminação de conteúdos manipulados (Floridi e Chiriatti, 2020). Assim, torna-se relevante mapear o estado da arte. O objetivo é compreender como a IAG está sendo aplicada no audiovisual não interativo, bem como identificar quais desafios persistem e quais impactos podem ser esperados.

1.3 PROPOSTA

Este trabalho propõe um Mapeamento sistemático da literatura (MSL) sobre o uso da IAG na produção de conteúdos audiovisuais não interativos. O objetivo é identificar e caracterizar aplicações, desafios e impactos. Isso será feito considerando:

- Aspectos técnicos: modelos utilizados (Difusão e Transformers) e métricas de avaliação. Entre elas, o *Fréchet Inception Distance* (FID), que mede a similaridade estatística entre

imagens geradas e reais. Também o *Inception Score (IS)*, que avalia a qualidade e a diversidade das imagens produzidas.

- Aspectos criativos: coerência narrativa, estética, inovação.
- Aspectos éticos: autoria, viés, direitos autorais.

A questão central que orienta esta pesquisa é: "Quais são as aplicações, limitações e impactos da IAG na produção audiovisual não interativa?" Essa pergunta guia todas as etapas do estudo. Desde a definição das strings de busca até a análise e categorização dos resultados.

As buscas foram realizadas nas bases IEEE Xplore e ACM Digital Library, escolhidas por sua relevância nas áreas de Computação e IA, com artigos publicados entre 2022 e 2025, período que marca a popularização das IAs generativas modernas, impulsionadas por ferramentas amplamente acessíveis desde o final de 2022, como o ChatGPT e o Google Gemini (Gambacorta et al., 2025).

O processo de seleção seguiu critérios rigorosos de inclusão e exclusão, assegurando a qualidade e a reprodutibilidade do estudo. Foram incluídos estudos que abordam a aplicação da IA em conteúdos audiovisuais e que apresentem algum tipo de avaliação técnica, criativa ou estética. Foram excluídos documentos irrelevantes, incompletos, sem revisão por pares, revisões de literatura e estudos puramente técnicos sem análise conceitual.

1.4 METODOLOGIA

O MSL é uma metodologia que visa fornecer uma visão estruturada do estado da arte em uma área de pesquisa, identificando lacunas e tendências por meio de protocolos replicáveis (Petersen et al., 2008). Para este estudo, adotamos as diretrizes propostas por Kitchenham e Charters (2007) e Petersen et al. (2008).

A primeira etapa consistiu no planejamento do protocolo, incluindo a definição da questão central de pesquisa e subquestões específicas, além da estratégia *population, intervention, comparison, outcome, context (PICOC)* para seleção de termos de busca.

Em seguida, a execução do MSL foi realizada por meio da plataforma Porifera (Damaseno, 2023), utilizada para organizar e automatizar as etapas de triagem e filtragem dos artigos. O processo envolveu a remoção de duplicatas, a leitura dos títulos, resumos e textos completos, e a aplicação dos critérios de inclusão e exclusão estabelecidos no protocolo. As informações extraídas foram então categorizadas e analisadas de acordo com as dimensões técnica, criativa e ética definidas anteriormente.

1.5 CONTRIBUIÇÃO

Este trabalho contribui para a compreensão crítica do papel da IAG no setor audiovisual, oferecendo:

- Um panorama atualizado das aplicações mais relevantes da IAG em conteúdos não interativos.
- A identificação de desafios técnicos e éticos, incluindo coerência temporal, sincronização áudio-vídeo, autoria e viés algorítmico.
- Diretrizes para pesquisadores e profissionais, apoiando decisões sobre uso responsável e inovador dessas tecnologias.

- Subsídios para políticas públicas e regulamentações, considerando riscos e oportunidades associados à adoção da IAG.

Ao consolidar evidências científicas, este estudo busca não apenas mapear tendências. Também busca orientar práticas futuras, além de promover um equilíbrio entre inovação tecnológica e responsabilidade social.

1.6 ORGANIZAÇÃO DO DOCUMENTO

O Capítulo 1 (Introdução) apresenta o contexto do problema, a motivação para o estudo, a proposta metodológica e as contribuições esperadas.

O Capítulo 2 (Trabalhos relacionados) revisa estudos de mapeamento da literatura anteriores sobre IAG aplicada ao audiovisual, destacando abordagens, limitações e lacunas.

O Capítulo 3 (Mapeamento sistemático da literatura) descreve o protocolo metodológico adotado, incluindo questões de pesquisa, estratégias de busca, critérios de inclusão/exclusão e procedimentos de análise.

O Capítulo 4 (Resultados e discussão) sintetiza as evidências coletadas, organizadas por subquestões, e discute implicações práticas, desafios e oportunidades para pesquisas futuras.

Por fim, o Capítulo 5 (Considerações finais) apresenta as conclusões do estudo, recomendações para a indústria e sugestões para investigações complementares, enfatizando a importância de um diálogo contínuo entre tecnologia e ética na produção audiovisual.

2 TRABALHOS RELACIONADOS

A integração da IAG no setor audiovisual representa uma das transformações tecnológicas mais disruptivas desta década. Fundamentada em avanços de modelos de *deep learning*, como redes adversariais generativas (GANs) e, mais recentemente, modelos de difusão, a IAG atingiu um ponto de inflexão em 2022. A popularização de ferramentas como DALL·E 2, Stable Diffusion e Midjourney democratizou o acesso a sistemas capazes de criar e modificar conteúdos visuais com um nível de realismo e complexidade sem precedentes. Dada a velocidade dessa adoção, um corpo recente de literatura acadêmica, incluindo diversas revisões ou mapeamentos sistemáticos (RSLs/MSLs), tem emergido para mapear, categorizar e compreender este fenômeno em rápida evolução.

Para fundamentar o presente estudo, é essencial analisar a metodologia e os achados das principais revisões. Por exemplo, a RSL de Lazarte et al. (2025) apresenta uma investigação rigorosa focada na narrativa audiovisual. A questão de pesquisa foi: “Como a IA está transformando a narrativa audiovisual em termos de criação, produção e recepção?”. Os autores aplicaram o protocolo PRISMA em bases de alto impacto, como Scopus, Web of Science (WoS) e Dialnet. Partindo de 3 052 artigos iniciais, filtros rigorosos resultaram na análise final de 20 estudos centrais.

De forma similar, Orak e Turan (2024) conduziram uma RSL sobre tendências na produção de vídeo digital, selecionando 21 estudos após filtros em cinco bases (incluindo WoS e ERIC), com foco mais evidente em aplicações educacionais. Em outra frente, a revisão comparativa de Gavran et al. (2025) analisou oportunidades e desafios do uso da IA na produção de conteúdo audiovisual. Partindo de 112 publicações em bases como IEEE Xplore e Scopus, os autores retiveram 52 fontes para análise.

Uma leitura integrada desses trabalhos revela um consenso: a IAG está reconfigurando profundamente todo o pipeline de produção audiovisual. Revisões como Voinea (2025) e Gavran et al. (2025) documentam a aplicação da IA em todas as etapas. Na pré-produção, ela aparece na análise de tendências, no *scouting* e na criação de storyboards e previs. Durante a produção, a IAG otimiza logística e apoia a produção virtual. Na pós-produção, seu impacto é ainda mais evidente: edição automatizada (corte e montagem), geração de efeitos visuais (VFX), preenchimento (*in-painting*) para remoção de objetos, roscopia, correção de cor inteligente e geração de trilhas. A RSL de Orak e Turan (2024) corrobora essa tendência, destacando PLN e *deep learning* como tecnologias mais frequentes, além de benefícios como economia de tempo e criação de efeitos visuais e animação.

Apesar disso, emerge um paradoxo: a tensão entre eficiência tecnológica e originalidade criativa. Lazarte et al. (2025), focados na narrativa, sugerem que, embora a IAG prometa inovação, sua aplicação prática tende a reforçar estéticas do passado, com reprodução de estilos retrô e nostálgicos. Voinea (2025) alerta para “homogeneização criativa”, enquanto Gavran et al. (2025) identifica “padronização de conteúdo”. Em sistemas treinados em grandes corpora históricos, a otimização de padrões conhecidos pode suplantiar rupturas estéticas e inovação genuína.

Em paralelo, os trabalhos apontam desafios éticos, legais e técnicos. A desinformação via *deepfakes* é proeminente, como discutem Gavran et al. (2025) e Franganillo (citado por Lazarte et al. (2025)). Parte da literatura, como Tiwari et al. (2023), dedica-se à detecção de *deepfakes*, mas enfatiza a baixa generalização entre conjuntos (*cross-dataset*). Outras lacunas

incluem violação de direitos autorais (uso de obras protegidas sem consentimento em dados de treinamento) e potencial deslocamento de mão de obra criativa especializada.

As revisões sistemáticas existentes ((Lazarte et al., 2025); (Orak e Turan, 2024); (Voinea, 2025); (Gavran et al., 2025)) fornecem uma visão de alto nível sobre tendências, benefícios e riscos da IAG no audiovisual. Contudo, seus escopos são amplos e, por vezes, incluem “vídeo digital” em geral, com mídias educacionais ou conteúdo interativo; outras restringem-se a aspectos conceituais como narrativa. Além disso, como observa Tiwari et al. (2023), uma parcela significativa da literatura concentra-se reativamente na detecção, e não proativamente na análise de criação.

Este trabalho busca preencher lacuna metodológica e de escopo, conforme o protocolo descrito. Realizamos um MSL focado no período de 2022–2025, marco da popularização das IAGs modernas, concentrando-nos exclusivamente na geração ou modificação de produções audiovisuais não interativas — obras lineares como filmes, séries e curtas, consumidas de forma passiva — e excluindo estudos centrados em detecção ou experiências interativas (jogos, VR/AR). Nossa contribuição é categorizar e analisar as publicações selecionadas sob dimensões técnica, criativa e ética, oferecendo um panorama focado e atualizado, menos genérico que revisões anteriores.

3 MAPEAMENTO SISTEMÁTICO DA LITERATURA (MSL)

3.1 CONTEXTO

Este capítulo apresenta o protocolo e a execução do MSL sobre IAG aplicada à produção de conteúdos audiovisuais não interativos. O objetivo é identificar como a IAG tem sido utilizada para gerar ou modificar conteúdos audiovisuais lineares. Entre eles, filmes, curtas, trailers, videoclipes, publicidade e cutscenes não interativas. Excluimos explicitamente:

- (i) Experiências interativas, como jogos digitais, realidade virtual (VR - *virtual reality*), realidade aumentada (AR - *augmented reality*), realidade mista (MR - *mixed reality*) e aplicações sensoriais que dependem de interação do usuário;
- (ii) Estudos de detecção/autenticação, como forense de (*deepfakes*) e técnicas de marca d'água;
- (iii) Aplicações biomédicas, que utilizam vídeo ou voz para diagnóstico clínico ou geração de dados sintéticos para saúde.

O recorte temporal adotado é 2022 a 2025, período que marca a popularização e o acesso público a modelos generativos modernos, como Stable Diffusion, DALL-E 2 e modelos baseados em Transformers, além de ferramentas multimodais que transformaram fluxos criativos no audiovisual (Gambacorta et al., 2025).

A coleta concentra-se em fontes primárias revisadas por pares, disponíveis nas bases IEEE Xplore e ACM Digital Library, garantindo rigor científico. Para apoiar a triagem, registro de decisões e extração estruturada dos dados, foi utilizada a ferramenta Porifera (Damasceno, 2023), que permite rastreabilidade e controle colaborativo do processo.

Além de mapear aplicações práticas, este estudo busca compreender desafios técnicos (e.g., coerência temporal, sincronização áudio-vídeo, escalabilidade), questões éticas e criativas (e.g., autoria, viés, impacto no trabalho humano) e impactos potenciais para a indústria audiovisual, incluindo transformações nos processos de produção, redução de custos e novas possibilidades criativas.

3.2 OBJETIVO

O objetivo deste MSL foi estruturado e definido de acordo com o GQM (*Goal-Question-Metric*) que foi proposto por Basili e Rombach (1988), como pode ser visto na Tabela 3.1.

Tabela 3.1: Objetivo do MSL de acordo com o modelo GQM

Analisar	publicações científicas
Com o propósito de	identificar e caracterizar as aplicações, desafios e impactos da IAG na produção de conteúdos audiovisuais não interativos, considerando os aspectos técnicos, criativos e éticos envolvidos.
Do ponto de vista dos	pesquisadores das áreas de Computação e Inteligência Artificial.
No contexto de	publicações científicas disponíveis em bases de dados relevantes, como IEEE Xplore e ACM Digital Library.

3.2.1 Questão principal de pesquisa

A questão principal é a parte mais importante do MSL de acordo com Kitchenham e Charters (2007). De acordo com objetivo apresentado, a questão a ser pesquisada é:

“Quais são as aplicações, desafios e impactos do uso de ferramentas de Inteligência Artificial Generativa (IAG) na geração de conteúdos audiovisuais não interativos?”

Nesse contexto, o foco da investigação está em identificar como a IAG tem sido aplicada na produção audiovisual linear, quais tecnologias e abordagens metodológicas são utilizadas, bem como os desafios técnicos, criativos e éticos e os impactos potenciais para a indústria audiovisual.

3.2.2 Subquestões de pesquisa

O processo de seleção de publicações envolve diferentes fontes de informações, podendo ser artigos de conferências e journals em bibliotecas digitais. Para esse MSL foi definido algumas estratégias de buscas, as quais estão estruturadas através das subquestões e elas estão apresentadas na Tabela 3.2.

Tabela 3.2: As subquestões da pesquisa

ID	Subquestões de pesquisa	Objetivo
SQ1	Qual o tipo de contribuição do artigo?	<p>Seguindo a classificação proposta por (Wieringa et al., 2006), as publicações podem ser categorizadas da seguinte forma:</p> <p>Pesquisa de avaliação (Evaluation Research): o artigo investiga uma tecnologia já existente, sendo aplicada ou analisada em um contexto real para observar sua efetividade ou utilidade. Envolve testes com usuários, estudos de caso, ou coleta empírica de dados.</p> <p>Proposta de solução (Solution Proposal): apresenta uma nova abordagem técnica, método, framework ou ferramenta para resolver um problema identificado. Pode ser uma ideia original ou uma melhoria de soluções já existentes. Pode ou não incluir um exemplo de uso, mas ainda não envolve uma avaliação rigorosa.</p> <p>Pesquisa de validação (Validation Research): investiga uma proposta (geralmente técnica ou metodológica) em um ambiente controlado, por meio de prototipação, simulação, experimentos ou análises. Busca confirmar propriedades ou hipóteses da solução, mas ainda fora do contexto real de uso.</p> <p>Artigo filosófico (Philosophical Paper): reflete sobre conceitos fundamentais, terminologias, estruturas teóricas ou epistemológicas da área. Traz discussões profundas sem apresentar necessariamente experimentação ou proposta técnica.</p> <p>Artigo de opinião (Opinion Paper): expressa a visão, interpretação ou posicionamento do autor sobre determinado tópico, podendo criticar abordagens existentes ou sugerir novos caminhos. Não contém pesquisa empírica nem proposta concreta.</p> <p>Relato de experiência (Experience Paper): descreve uma experiência prática real, como o uso de uma tecnologia ou a condução de um projeto, destacando lições aprendidas, desafios enfrentados e recomendações. Foca na aplicação, mas não necessariamente na generalização.</p>
SQ2	Em qual área do conhecimento o estudo se insere?	Inteligência artificial, Engenharia de software, Design digital, Mídia e entretenimento, entre outros.

ID	Subquestões de pesquisa	Objetivo
SQ3	Qual o foco principal da aplicação da IAG no estudo?	<p>Geração e/ou modificação de vídeos: Utilização de IAG para criar ou alterar conteúdos de vídeo, possibilitando a produção de materiais inéditos ou a edição avançada de vídeos existentes.</p> <p>Criação de efeitos audiovisuais: Aplicação de técnicas de IAG para desenvolver efeitos visuais ou sonoros inovadores, aprimorando a qualidade estética e a experiência imersiva em produções audiovisuais.</p> <p>Automação de processos de edição: Emprego de ferramentas baseadas em IAG para automatizar tarefas repetitivas na edição de conteúdo, aumentando a eficiência e permitindo que os profissionais se concentrem em aspectos mais criativos do trabalho.</p>
SQ4	Qual tecnologia de IAG foi empregada?	<p>Identificar a tecnologia principal utilizada, como:</p> <p>Modelos de Difusão: algoritmos que geram dados revertendo processos de ruído.</p> <p>Transformers: modelos baseados em atenção, aplicados à geração multimodal.</p>
SQ4.1	Quais critérios ou métricas foram utilizados para avaliar a qualidade do conteúdo audiovisual?	<p>Verificar se foram aplicadas métricas como:</p> <p>Fidelidade visual: realismo e ausência de artefatos.</p> <p>Coerência narrativa: consistência lógica da história.</p> <p>Avaliações subjetivas: MOS, estética, inovação técnica.</p>
SQ4.2	O que os avaliadores concluíram sobre o conteúdo gerado?	<p>Sintetizar percepções sobre naturalidade, qualidade técnica, adequação aos objetivos e limitações observadas.</p>
SQ5	A ferramenta de IAG foi utilizada em sua versão original ou houve customização?	<p>Classificar como:</p> <p>Ferramenta existente: uso sem modificações.</p> <p>Customização parcial: ajustes limitados para requisitos específicos.</p> <p>Solução própria: desenvolvimento de sistema personalizado.</p>
SQ6	Quais desafios técnicos foram identificados na aplicação da IAG?	<p>Exemplos: Limitações de resolução, coerência temporal, sincronização áudio-vídeo, latência, controle de parâmetros.</p>
SQ7	Quais desafios éticos e criativos foram apontados?	<p>Investigar questões como: Autenticidade e autoria, viés algorítmico, impacto no trabalho criativo, uso não autorizado de referências.</p>
SQ8	O estudo apresenta análises empíricas?	<p>Verificar se há experimentos, estudos de caso ou avaliações práticas.</p>
SQ8.1	Se sim, qual método empírico foi adotado?	<p>Identificar se foi experimento controlado, estudo de caso, survey ou outro método.</p>
SQ8.2	Quantas pessoas participaram do estudo?	<p>Informar o tamanho da amostra ou número de participantes envolvidos.</p>

ID	Subquestões de pesquisa	Objetivo
SQ9	Qual a finalidade principal para a utilização da IAG no estudo?	Determinar se a finalidade foi roteirização, automação da pós-produção, geração de efeitos especiais, dublagem, entre outros.
SQ10	Que tipos de conteúdos audiovisuais foram gerados?	Identificar se foram vídeos completos, trailers, animações, clipes publicitários, cutscenes, entre outros.
SQ11	Qual tipo de dispositivo e tecnologia foi utilizada para a interação do usuário com a IAG?	Verificar se foram usados desktops, dispositivos móveis, interfaces em nuvem, ambientes imersivos ou dispositivos especializados.
SQ12	Qual o tipo de interação realizada pelo usuário com a IAG?	Classificar se a interação foi via GUI, textual (prompt), voz, multimodal ou programática (API/SDK).
SQ13	Qual o modelo específico de base foi utilizado no estudo?	Identificar modelos como Stable Diffusion, GPT-4, DALL·E, CLIP, entre outros.
SQ14	Que modelos de referência ou benchmarks foram empregados para validar os resultados?	Verificar se houve comparação com padrões da indústria, métricas quantitativas ou análises qualitativas por especialistas.
SQ15	Qual o impacto potencial identificado para a indústria audiovisual?	Avaliar impactos como redução de custos, ampliação das possibilidades criativas, transformação de processos, personalização e efeitos sobre a força de trabalho.
SQ16	Quais desafios quanto à reprodutibilidade e confiabilidade dos resultados foram mencionados?	Identificar problemas como variabilidade nos resultados, dependência de dados de treinamento, falta de benchmarks padronizados e dificuldades de validação.
SQ17	A intenção dos autores era tornar perceptível o uso da IAG no conteúdo gerado?	Determinar se a utilização da tecnologia deveria ser percebida de forma intencional, dissimulada ou parcialmente perceptível.

3.3 ESTRATÉGIAS E MÉTODOS DE BUSCA DE PUBLICAÇÕES

A estratégia para as buscas nas fontes é definida como método de busca automática. Assim, foi realizado por mecanismo de busca utilizando palavras chaves que foram definidas com o PICOC (*population, intervention, comparison, outcome e context*) com base em Kitchenham e Charters (2007) e que compõem a *string* de busca.

As fontes de busca com seus respectivos *links* de busca são apresentados na tabela 3.3. Já a tabela 3.4 apresenta a *string* de busca utilizada, estruturada em quatro partes principais. No contexto deste estudo, o PICOC foi aplicado da seguinte forma:

- Population (P): Inteligência artificial generativa (IAG), incluindo termos como "artificial intelligence", "AI" e "generative AI".
- Intervention (I): Ações relacionadas à geração ou modificação de conteúdos audiovisuais, como "generate", "produce", "create", "manipulate" e "write".
- Comparison (C): Não se aplica, pois o objetivo não é comparar técnicas, mas mapear aplicações, desafios e impactos.
- Outcome (O): Aspectos relacionados à avaliação, impacto e qualidade, incluindo termos como "impact", "ethics", "quality", "realism", "creativity" e "user study".

- **Context (C):** Produção audiovisual não interativa, abrangendo termos como "film", "cinema", "movie", "animation", "advertisement", "CGI", "special effects", "VFX", "script" e "voice-over".

Tabela 3.3: Fonte utilizada no MSL

Nome da fonte	Link	Tipo de pesquisa
ACM	https://dl.acm.org/	Máquina de busca
IEEE Xplore	https://ieeexplore.ieee.org/	Máquina de busca

Tabela 3.4: Strings utilizadas no MSL

Componente PI-COC	String	Operador
População	("Artificial intelligence" OR AI)	AND
Intervenção	(generate OR produce OR create OR manipulate OR write)	AND
Resultados	(impact OR ethics OR quality OR consequences OR perception OR realism OR creativity)	AND
Contexto	(film OR cinema OR movie OR animation OR advertisement OR CGI OR "special effects" OR VFX OR script OR "voice-over")	

A escolha pelas bases IEEE Xplore e ACM Digital Library se justifica por sua relevância e abrangência nas áreas de ciência da computação, engenharia e tecnologias emergentes, incluindo IA e aplicações audiovisuais. Ambas oferecem publicações revisadas por pares, com alto rigor científico e ampla cobertura de conferências e periódicos relevantes para o escopo deste estudo. Outras bases foram descartadas por apresentarem menor densidade de publicações específicas sobre o tema ou por não atenderem aos critérios de qualidade e rastreabilidade exigidos neste mapeamento.

3.4 IDIOMA DOS ARTIGOS

Os idiomas escolhidos foram o inglês e português. Inglês, pois é o idioma adotado pela grande maioria das conferências e periódicos internacionais relacionados com tema de pesquisa. Além disso, por ele ser o idioma utilizado pela maioria das editoras relacionadas com o tema, listadas no portal de periódicos da CAPES. E, português por ser a língua nativa dos pesquisadores.

3.5 PROCEDIMENTOS DE SELEÇÃO E CRITÉRIOS

Os critérios de seleção adotados neste estudo foram definidos com base nas diretrizes metodológicas propostas por (Kitchenham e Charters, 2007), assegurando rigor e consistência na triagem dos estudos. Essa etapa desempenha um papel crucial na redução da heterogeneidade dos resultados, ao garantir que apenas publicações alinhadas ao escopo da pesquisa sejam consideradas. Além disso, contribui diretamente para a validade das conclusões, ao estabelecer parâmetros claros, replicáveis e aplicáveis de forma sistemática. A seguir, são apresentados os critérios utilizados para orientar o processo de inclusão e exclusão dos estudos analisados.

3.5.1 Critérios de inclusão (CI)

- I1 – IA em Audiovisual: O estudo aborda a aplicação da IA em conteúdos audiovisuais (produção, edição, análise ou avaliação).
- I2 – Avaliação do Conteúdo: O artigo apresenta alguma forma de avaliação técnica, criativa, estética ou operacional do conteúdo gerado com IA.

3.5.2 Critérios de exclusão (CE)

- E1 – Irrelevância temática: O conteúdo é irrelevante tematicamente, ou seja, menciona IA ou audiovisual, mas não trata da relação entre os DOI's nem de suas aplicações práticas.
- E2 – Documento incompleto: Documentos incompletos, resumos expandidos ou publicações cujo texto integral não está disponível para análise.
- E3 – Sem revisão por pares: Estudos sem revisão por pares (ex.: artigos de opinião, blogs, relatórios institucionais informais, dissertações e teses não publicadas).
- E4 – Duplicata: Publicações duplicadas em diferentes bases de dados ou versões do mesmo artigo.
- E5 – Idioma não aceito: Artigos publicados em idiomas que não sejam o português ou o inglês.
- E6 – Acesso restrito: Estudos que exigem pagamento sem alternativa de acesso via repositórios institucionais, bibliotecas acadêmicas ou vias legais de acesso aberto (Open Access).
- E7 – Exclusão de revisões da literatura: Artigos que são apenas revisões de literatura, sem proposta nova, aplicação prática ou análise empírica.

3.5.3 Estratégias para condução do MSL

A triagem dos estudos foi conduzida em duas etapas principais (Kitchenham e Charters, 2007). O primeiro filtro consistiu na leitura do título, resumo e palavras-chave dos artigos retornados pela busca automática. O objetivo dessa fase inicial foi eliminar rapidamente os trabalhos que não atendiam aos critérios básicos definidos, como ausência de foco em IA aplicada ao contexto audiovisual ou falta de revisão por pares.

Os artigos que passaram por essa triagem inicial foram então submetidos ao segundo filtro, baseado na leitura integral do texto. Nessa etapa, foram avaliados aspectos como clareza metodológica, relevância dos resultados apresentados e conformidade com os critérios de inclusão. Também foram descartados estudos com quatro páginas ou menos, por não oferecerem profundidade suficiente para análise crítica.

Além disso, foram excluídos artigos de natureza puramente técnica, como aqueles que descrevem apenas implementações, arquiteturas de software ou aspectos computacionais, quando não apresentavam qualquer discussão conceitual, metodológica ou analítica relacionada ao tema central da pesquisa. Embora tecnicamente relevantes, esses estudos não fornecem subsídios suficientes para responder às questões de pesquisa propostas neste mapeamento.

As *generative adversarial networks* (GANs) não foram incluídas no escopo desta pesquisa, pois o objetivo é analisar ferramentas atuais de geração audiovisual não interativa que

produzam conteúdo diretamente a partir de *prompts* textuais, sem a necessidade de treinamento adicional ou do uso de grandes volumes de dados. Embora as GANs tenham sido fundamentais para o avanço inicial da IAG, elas exigem processos de treinamento complexos e dependem fortemente de bases de dados extensas e específicas, o que as torna menos adequadas ao propósito deste estudo, voltado a sistemas já pré-treinados e acessíveis para uso criativo imediato. Considerando ainda que o recorte temporal definido entre 2022 e 2025 privilegia abordagens mais recentes, optou-se por concentrar a análise em arquiteturas como os *diffusion models* (Dhariwal e Nichol, 2021) e os *transformers* (Vaswani et al., 2017), que substituíram gradualmente as GANs em aplicações práticas por oferecerem maior estabilidade, controle semântico e integração com linguagens naturais.

As decisões finais quanto à inclusão ou exclusão dos artigos foram discutidas em conjunto entre a professora orientadora, o coorientador e os alunos pesquisadores. Para promover a participação equitativa e assegurar que as escolhas refletissem um consenso do grupo, foi utilizada a plataforma digital Porifera (<https://porifera.app.br/>) como apoio ao processo.

Essa ferramenta permitiu que divergências fossem resolvidas de forma democrática, com todos os envolvidos tendo a oportunidade de justificar seus posicionamentos antes da votação. Cada participante pôde registrar seu voto com base em sua análise individual, e as decisões foram documentadas na própria plataforma, fortalecendo a rastreabilidade e a integridade metodológica do processo.

A extração inicial dos resultados da string de busca foi exportada para a plataforma Porifera às 12h53 do dia 26 de abril de 2025, marcando o início formal da etapa de triagem colaborativa.

3.6 EXTRAÇÃO DE DADOS E PROCESSAMENTO AUTOMATIZADO

3.6.1 Metodologia de extração e organização de dados

Após a aprovação no filtro 1 do Porifera, todos os artigos selecionados foram organizados em uma pasta compartilhada no Github <https://github.com/danteeeeee/MSL-da-IAG-no-Audiovisual-nao-interativo>, garantindo sincronização automática e backup contínuo entre os pesquisadores.

Cada artigo foi analisado individualmente e suas informações registradas em um documento .docx seguindo a convenção de nomenclatura:

- Extração_XXX.docx - versão de rascunho;
- Extração_XXX_.docx - versão final revisada.

O número XXX corresponde ao ID do artigo no Porifera (ex.: Extração_001_.docx, Extração_025_.docx). A escolha do formato .docx facilitou a edição colaborativa e a posterior conversão para processamento automatizado.

Cada documento contém uma tabela estruturada com as subquestões de pesquisa (SQ1–SQ17), título do artigo, resumo, tecnologias de IAG mencionadas, justificativas com trechos literais do texto original e outros metadados relevantes.

3.6.2 Uso de ferramentas de IAG no preenchimento

Durante o preenchimento das extrações, utilizamos ferramentas de IA generativa de texto (ChatGPT-4o e Microsoft Copilot Pro) para auxiliar na localização rápida de trechos específicos dos artigos, especialmente em textos extensos ou com estruturas narrativas complexas.

É importante ressaltar que essas ferramentas serviram apenas como apoio, com supervisão humana constante. Cada resposta sugerida pela IA foi manualmente verificada para confirmar que:

- As opções selecionadas faziam sentido no contexto do artigo;
- Os trechos de justificativa realmente existiam no texto original;
- As citações estavam corretamente transcritas;
- A interpretação estava alinhada com a intenção dos autores.

Esse processo híbrido permitiu ganhar eficiência sem comprometer a qualidade e confiabilidade das extrações.

3.6.3 Regras de preenchimento

Três subquestões (SQ1, SQ8 e SQ17) exigiam resposta única, refletindo sua natureza categórica. As demais permitiam múltiplas respostas quando aplicável, reconhecendo que um mesmo artigo pode abordar várias tecnologias ou desafios simultaneamente.

3.6.4 Processamento automatizado dos dados

Para analisar as 60 extrações finais, desenvolvemos três scripts Python que automatizaram a conversão, consolidação e análise quantitativa dos dados. A estrutura de diretórios utilizada foi:

```
c:\Users\GUIROTH\Downloads\Capitulo 4\
  Extrações\
    Extração_001_.docx
    Extração_002_.docx
    ...
    Extração_410.docx
    todas_extracoes.txt (gerado por "consolidar_extracoes.py")
  scripts\
    consolidar_extracoes.py
    converter_docx_txt.py
    analisar_extracoes.py
  Capítulos\
    cap1.tex
    cap2.tex
    cap3.tex
    cap4.tex
  relatorio_analise_sqs.txt (gerado por "analisar_extracoes.py")
```

O processamento seguiu três etapas principais:

3.6.4.1 Etapa 1: Conversão para texto puro

O script `converter_docx_txt.py` converteu todos os arquivos `.docx` para `.txt`, preservando a estrutura textual essencial (parágrafos, marcadores de seleção como `[x]`) mas removendo formatações visuais desnecessárias.

3.6.4.2 Etapa 2: Consolidação

O script `consolidar_extracoes.py` unificou todos os arquivos `.txt` em um único arquivo (`todas_extracoes.txt`), inserindo cabeçalhos padronizados entre cada extração para facilitar o processamento posterior.

3.6.4.3 Etapa 3: Análise quantitativa

O script `analisar_extracoes.py` realizou a análise automatizada, implementando as seguintes funcionalidades principais:

1. Extração de identificadores: Utilizou expressões regulares para identificar o ID de três dígitos de cada artigo, servindo como chave de rastreamento.
2. Limpeza de texto: Removeu citações literais entre aspas duplas para evitar interferência na detecção de opções marcadas.
3. Identificação de respostas: Para cada subquestão, o script implementou três algoritmos complementares aplicados sequencialmente:
 - Detecção de checkboxes explícitos (`[x]`, `[X]`, com variações de espaçamento);
 - Busca por palavras-chave correspondentes às opções válidas predefinidas;
 - Separação por delimitadores (ponto-e-vírgula, barra vertical) como estratégia final.
4. Normalização: Cada opção extraída foi normalizada através de comparação com o conjunto de opções válidas predefinidas, utilizando correspondência exata ou parcial. Opções não mapeadas foram categorizadas como "Outro" quando aplicável.
5. Extração de tecnologias: Identificou tecnologias mencionadas no cabeçalho de cada extração, filtrando marcadores de lista, conectores isolados e citações literais.
6. Tratamento de respostas: Para subquestões de resposta única, quando múltiplas opções foram detectadas (indicativo de erro de formatação), registrou apenas a primeira opção válida. Para subquestões de resposta múltipla, registrou todas as opções identificadas.
7. Agregação: Consolidou as respostas em estruturas de dados hierárquicas, eliminando duplicatas e calculando frequências automaticamente.
8. Geração de relatório: Produziu um relatório estruturado organizado por tecnologias e subquestões, com opções ordenadas por frequência decrescente.

O relatório final gerado serviu como base empírica para a síntese apresentada no Capítulo

4.

3.7 LIMITAÇÕES E GARANTIAS METODOLÓGICAS

Esta seção discute as principais fontes de incerteza e as estratégias adotadas para mitigá-las, garantindo a confiabilidade dos resultados apresentados.

3.7.1 Decisões humanas na triagem

A triagem dos 667 artigos no filtro 1 e dos 162 artigos no filtro 2 foi conduzida de forma colaborativa pela equipe de pesquisa, com uso da plataforma Porifera para registro e votação. Para quantificar a concordância entre avaliadores, foi calculado o índice de Fleiss Kappa, resultando em $\kappa = 0.730$ para o Filtro 1 e $\kappa = 0.645$ para o filtro 2. Segundo Landis e Koch (1977), valores entre 0.61 e 0.80 indicam concordância substancial, enquanto valores entre 0.41 e 0.60 indicam concordância moderada.

Esses valores refletem a natureza interpretativa das decisões de triagem: embora haja consenso robusto na maioria dos casos, alguns artigos limítrofes geraram discussões prolongadas, especialmente aqueles que mencionavam IA e audiovisual de forma tangencial. Para casos discordantes, foi adotado o procedimento de revisão cruzada: artigos com votos divididos foram reavaliados independentemente por pelo menos DOI's pesquisadores adicionais, e a decisão final foi tomada por consenso após discussão presencial.

Essa abordagem qualitativa-deliberativa reduz substancialmente o risco de exclusão indevida de estudos relevantes, embora não elimine completamente a subjetividade inerente ao processo de revisão sistemática.

3.7.2 Validação dos scripts de processamento

Os três scripts Python utilizados para conversão, consolidação e análise das extrações foram validados através de múltiplas estratégias:

- Execução idempotente: Múltiplas execuções sobre o mesmo conjunto de dados produziram saídas idênticas (verificado por hash SHA256 do arquivo de relatório final);
- Testes de casos extremos: Foram criados manualmente arquivos de teste contendo formatos variados de checkbox (`[x]`, `[x]`, `[X]`), múltiplas opções na mesma linha, opções distribuídas em múltiplas linhas, e citações entre aspas duplas para verificar a robustez dos algoritmos de extração;
- Validação amostral: 10% das extrações (6 artigos) foram processadas manualmente de forma independente e comparadas com a saída automatizada, resultando em concordância de 100% para IDs de artigos, 98.3% para opções selecionadas (1 divergência atribuída a ambiguidade na formatação original) e 95.8% para tecnologias identificadas (divergências atribuídas a variações de nomenclatura como "GPT-4" vs. "GPT4");
- Inspeção de logs: Todas as 60 extrações foram inspecionadas visualmente no relatório final para identificar anomalias óbvias (ex.: opções claramente incorretas, IDs duplicados, tecnologias com formatação estranha). Foram identificadas e corrigidas 3 entradas de tecnologias que eram apenas números residuais de métricas, levando à implementação da função `limpar_tecnologia()` no script.

Apesar dessas validações, reconhece-se que erros residuais podem existir, especialmente em extrações com formatação altamente irregular ou ambígua. Entretanto, a inspeção amostral sugere que tais erros, se presentes, afetam menos de 2% das contagens finais e tendem a ocorrer em categorias de baixa frequência ("Outro" com 1-2 ocorrências), não alterando as tendências gerais identificadas. Além disso, recomenda-se a realização de uma revisão periódica dos dados para garantir a integridade e a precisão das informações coletadas.

3.7.3 Corretude Algorítmica e Equivalência de Resultados Finais

Para complementar as estratégias de validação já detalhadas, e visando verificar a corretude algorítmica do nosso script de processamento, realizamos uma análise manual detalhada de 50 % das extrações. Esta inspeção minuciosa permitiu uma comparação direta dos resultados brutos gerados automaticamente com os cálculos realizados de forma independente.

A análise revelou a ocorrência de pequenas divergências numéricas nos relatórios intermediários. Tais discrepâncias foram primariamente atribuídas a variações na forma de preenchimento dos relatórios de extração (como a capitalização de termos, uso de espaços ou caracteres especiais), o que levou a um tratamento ligeiramente diferente dos dados pelo script em casos específicos e, conseqüentemente, a alguns cálculos incorretos pontuais.

No entanto, a inspeção final demonstrou que, quando analisados sob uma perspectiva macro e percentual, os resultados automáticos e manuais são altamente equivalentes. As diferenças absolutas encontradas eram pequenas e se distribuía de forma homogênea, sem afetar significativamente a distribuição das contagens e das frequências relativas.

Dessa forma, a validade das tendências e conclusões apresentadas neste trabalho é integralmente mantida. Os resultados garantem a robustez das inferências tiradas dos dados, confirmando que as divergências residuais não comprometem a visão geral e as descobertas centrais da pesquisa.

O resultado da contagem manual pode ser encontrado no documento de texto `contagem_tcc.txt` que está localizado no Github <https://github.com/danteeeee/MSL-da-IAG-no-Audiovisual-nao-interativo>.

4 RESULTADOS QUANTITATIVOS E DISCUSSÃO

Esta seção apresenta uma síntese quantitativa dos resultados obtidos a partir das extrações realizadas para este trabalho, organizada de forma alinhada ao protocolo de MSL adotado e ao conjunto de SQs definido no Capítulo 3. Ao longo do texto, são indicadas explicitamente as extrações que fundamentam cada evidência quantitativa, de modo a permitir a conferência manual dos cálculos.

4.1 PROCESSO DE SELEÇÃO E VISÃO GERAL DOS RESULTADOS

A submissão das strings de busca foi realizada nas mesmas bases científicas descritas no protocolo metodológico, com foco principal nas bibliotecas digitais IEEE Xplore e ACM Digital Library. No total, foram identificadas 667 publicações potencialmente relevantes, distribuídas da seguinte forma:

- 500 registros na IEEE Xplore;
- 167 registros na ACM Digital Library.

Os DOI's de todos os 667 artigos são apresentados no Apêndice A.

O processo de seleção seguiu DOI's filtros sucessivos, aplicando os critérios de inclusão e exclusão definidos previamente. No primeiro filtro, cada título e resumo foi avaliado pelos DOI's alunos, pela orientadora e pelo co-orientador. O conjunto de 667 registros iniciais foi reduzido a 162 publicações selecionadas para leitura na íntegra, com a seguinte distribuição por base:

- 104 artigos provenientes da IEEE Xplore;
- 58 artigos provenientes da ACM Digital Library.

A concordância entre avaliadores foi medida com o índice Kappa de Fleiss, resultando em $\kappa = 0,730$. De acordo com Altman (1991), esse valor se enquadra como "boa" concordância. Esse resultado indica que o protocolo de seleção foi suficientemente claro para produzir decisões consistentes entre os diferentes avaliadores, mesmo considerando a diversidade de temas dentro do escopo de IAG aplicada ao audiovisual.

No segundo filtro, a leitura completa levou à aprovação de 60 publicações, distribuídas da seguinte forma:

- 35 artigos da IEEE Xplore;
- 25 artigos da ACM Digital Library.

A concordância nessa etapa também foi avaliada com o índice Kappa de Fleiss, que resultou em 0,645. Esse valor continua sendo classificado como "bom", segundo Altman (1991), o que sugere que, mesmo em uma fase de análise mais densa e interpretativa, o protocolo manteve um nível adequado de reprodutibilidade entre avaliadores.

Percentuais de retenção ao longo dos filtros:

- Aceitos no 1º filtro: 162 de 667 (24,3%).

- Aceitos no 2º filtro (sobre o total inicial): 60 de 667 (9,0%).
- Aceitos no 2º filtro (sobre os aprovados no 1º filtro): 60 de 162 (37,0%).

Esses valores evidenciam a redução sistemática e o rigor progressivo aplicado entre título/resumo e leitura completa.

4.2 RESULTADO FINAL DO PROCESSO DE FILTRAGEM

Nesta seção apresentamos, primeiro, os artigos que foram aprovados no 1º filtro (título/resumo) mas recusados no 2º filtro (leitura completa); em seguida, os artigos aprovados no 2º filtro que compõem o conjunto final analisado quantitativamente neste capítulo.

4.2.1 Artigos Rejeitados desde o 1º Filtro

Total de 505 artigos rejeitados no 1º filtro: 006, 007, 010, 011, 012, 013, 015, 016, 019, 020, 024, 026, 027, 028, 031, 032, 033, 034, 035, 036, 037, 038, 042, 045, 046, 049, 050, 051, 054, 055, 056, 060, 061, 063, 064, 066, 067, 068, 069, 071, 072, 073, 074, 076, 077, 078, 083, 084, 085, 086, 088, 090, 091, 092, 093, 095, 096, 097, 098, 099, 103, 105, 106, 107, 110, 111, 113, 115, 116, 117, 118, 119, 120, 122, 123, 124, 125, 126, 127, 128, 129, 130, 132, 134, 135, 136, 137, 138, 139, 140, 142, 143, 145, 147, 148, 149, 150, 151, 152, 153, 154, 156, 159, 160, 163, 164, 165, 166, 167, 169, 179, 180, 184, 187, 189, 190, 194, 199, 200, 201, 205, 209, 210, 211, 213, 214, 215, 216, 217, 219, 220, 221, 222, 223, 224, 226, 227, 228, 229, 230, 231, 232, 236, 237, 238, 239, 240, 243, 244, 245, 246, 248, 249, 250, 251, 252, 253, 254, 255, 256, 257, 258, 261, 262, 263, 264, 265, 266, 267, 269, 270, 271, 273, 274, 275, 276, 277, 278, 280, 281, 282, 283, 285, 286, 288, 289, 291, 293, 294, 295, 296, 297, 298, 299, 300, 302, 303, 304, 306, 308, 309, 310, 311, 312, 313, 314, 316, 317, 318, 319, 320, 321, 322, 324, 325, 326, 327, 329, 330, 332, 333, 334, 335, 337, 338, 341, 342, 343, 344, 345, 346, 347, 348, 349, 350, 353, 354, 355, 358, 361, 362, 364, 366, 367, 370, 371, 372, 373, 374, 375, 377, 378, 379, 381, 382, 383, 385, 386, 387, 388, 390, 391, 392, 394, 396, 397, 398, 400, 402, 403, 405, 406, 408, 409, 411, 413, 414, 415, 416, 417, 418, 419, 420, 421, 422, 423, 424, 425, 427, 428, 429, 430, 431, 432, 433, 434, 436, 437, 438, 439, 440, 441, 442, 443, 444, 447, 448, 449, 450, 452, 453, 454, 455, 456, 457, 458, 459, 460, 461, 462, 463, 464, 465, 466, 467, 468, 469, 470, 471, 472, 473, 475, 477, 478, 479, 480, 481, 482, 483, 484, 485, 486, 489, 490, 491, 492, 493, 495, 496, 498, 499, 501, 502, 503, 504, 505, 506, 507, 508, 509, 510, 511, 512, 513, 514, 515, 516, 517, 518, 520, 521, 522, 523, 524, 525, 526, 527, 528, 530, 531, 532, 533, 534, 535, 536, 537, 538, 539, 540, 541, 542, 543, 544, 545, 546, 547, 548, 549, 550, 551, 552, 553, 554, 555, 557, 558, 559, 560, 561, 562, 563, 564, 565, 566, 567, 568, 569, 570, 571, 572, 573, 574, 575, 576, 577, 579, 580, 581, 584, 585, 587, 588, 589, 590, 591, 592, 593, 594, 595, 596, 597, 598, 599, 600, 601, 602, 603, 604, 605, 606, 607, 609, 611, 613, 614, 615, 616, 617, 618, 619, 620, 621, 622, 623, 624, 625, 626, 627, 628, 629, 630, 631, 632, 634, 635, 636, 637, 638, 639, 640, 641, 642, 643, 644, 645, 646, 647, 648, 649, 650, 651, 652, 653, 654, 655, 656, 657, 658, 659, 661, 662, 663, 664, 665, 666, 667.

4.2.2 Artigos Aprovados no 1º Filtro e Recusados no 2º Filtro

Total de 102 artigos: 003, 009, 017, 018, 022, 023, 029, 030, 039, 041, 043, 053, 057, 058, 059, 062, 070, 079, 082, 094, 104, 112, 114, 121, 131, 133, 141, 144, 146, 155, 157, 158, 161, 168, 172, 173, 175, 176, 177, 181, 182, 188, 192, 193, 196, 197, 198, 202, 204, 207, 208, 218, 225, 235, 241, 242, 260, 268, 272, 287, 290, 292, 307, 323, 328, 331, 336, 339, 340, 351,

352, 356, 357, 359, 360, 363, 365, 368, 369, 380, 384, 389, 393, 395, 401, 404, 407, 426, 435, 445, 446, 474, 476, 487, 500, 529, 578, 583, 612, 633, 660.

4.2.3 Artigos Aprovados Após o 2º Filtro (Conjunto Final)

Total de 60 artigos: 001, 002, 005, 008, 014, 021, 025, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 089, 100, 101, 102, 108, 109, 162, 170, 171, 174, 178, 183, 185, 186, 191, 195, 203, 206, 212, 233, 234, 247, 259, 279, 284, 301, 305, 412, 451, 488, 494, 497, 519, 556, 582, 586, 608, 610.

4.3 RESULTADOS QUANTITATIVOS POR SUBQUESTÕES

As SQs 4.1, 4.2 e 15 não terão tabelas mostradas, por se tratarem de subquestões qualitativas, e, portanto, apresentarem apenas respostas unitárias.

4.3.1 SQ1: Tipo de Contribuição do Artigo

O tipo de contribuição de cada artigo e o quantitativo são apresentados na Tabela 4.1.

Tabela 4.1: SQ1- Tipo de contribuição do artigo

Tipo de Contribuição	Total	IDs dos Artigos
Proposta de Solução	31	002, 004, 008, 014, 025, 040, 044, 047, 065, 080, 081, 087, 089, 100, 102, 108, 109, 191, 195, 206, 212, 234, 247, 259, 279, 284, 301, 305, 376, 412, 519
Pesquisa de Avaliação	19	001, 005, 021, 052, 170, 174, 178, 183, 185, 203, 399, 410, 451, 488, 494, 556, 586, 608, 610
Pesquisa de Validação	7	075, 162, 186, 233, 315, 497, 582

As demais opções com 1 ocorrência cada incluem: Artigo de Opinião (ID: 171); Relato de Experiência (ID: 048); Pesquisa empírica (ID: 101).

4.3.2 SQ2: Área do Conhecimento

A área de conhecimento dos artigos identificados e o quantitativo são apresentados na Tabela 4.2

Tabela 4.2: SQ2- Área do conhecimento do estudo

Área do Conhecimento	Total	IDs dos Artigos
Mídia e Entretenimento	34	001, 002, 005, 008, 014, 021, 040, 044, 047, 048, 052, 065, 075, 080, 108, 109, 170, 171, 174, 183, 185, 191, 195, 412, 451, 488, 494, 497, 519, 556, 582, 586, 608, 610
Inteligência Artificial	31	001, 002, 004, 005, 008, 021, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 089, 100, 101, 108, 109, 162, 174, 178, 191, 376, 399, 410, 412, 451, 494

Tabela 4.2: (continuação)

Área do Conhecimento	Total	IDs dos Artigos
Design Digital	13	008, 044, 047, 048, 052, 065, 075, 080, 170, 171, 183, 185, 284
Educação	7	080, 089, 100, 108, 178, 183, 451
Ciências Sociais	3	005, 075, 109

As demais áreas com 1 ocorrência cada incluem: Engenharia de Software (ID: 100), Outro (ID: 315), Psicologia (ID: 021), e diversas categorias específicas como Animação computacional (ID: 206), Artes Digitais (ID: 102), Edição de filmes (ID: 279), Geração automática de vídeo (ID: 247), entre outras.

4.3.3 SQ3: Foco Principal da Aplicação da IAG

O foco principal da IAG e o quantitativo são apresentados na Tabela 4.3

Tabela 4.3: SQ3- Foco principal da aplicação da IAG

Foco Principal	Total	IDs dos Artigos
Geração/modificação de vídeos	19	008, 021, 040, 048, 052, 065, 080, 089, 100, 108, 109, 178, 376, 399, 410, 412, 451, 494, 608
Storytelling/narrativas	12	001, 005, 044, 048, 052, 065, 080, 100, 108, 109, 174, 582
Outro	10	004, 075, 100, 178, 315, 488, 519, 556, 586, 610
Criação de imagens estáticas	7	005, 021, 044, 170, 174, 183, 497
Criação de efeitos audiovisuais	5	008, 014, 021, 047, 108
Automação de processos de edição	2	080, 109

As demais opções com 1 ocorrência cada incluem: Animação em tempo real para arte pública (ID: 102), Animações interativas (ID: 002), criação de sons ambientais (ID: 101), entre outras.

4.3.4 SQ4: Tecnologia de IAG Empregada

A tecnologia de IAG empregada em cada artigo e o quantitativo são apresentados na Tabela 4.4

Tabela 4.4: SQ4- Tecnologia de IAG empregada

Tecnologia	Total	IDs dos Artigos
Modelos de Difusão	29	002, 005, 008, 014, 021, 040, 044, 048, 065, 081, 089, 108, 109, 170, 174, 233, 234, 315, 376, 410, 412, 451, 488, 497, 519, 556, 582, 586, 610

Tabela 4.4: (continuação)

Tecnologia	Total	IDs dos Artigos
Transformers	22	001, 005, 021, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 089, 100, 108, 109, 162, 170, 178, 412, 610
Outro	12	008, 048, 075, 080, 100, 174, 178, 399, 412, 451, 494, 610
GANs	10	002, 008, 021, 170, 171, 185, 399, 410, 608, 610
Modelos híbridos	6	040, 044, 052, 065, 087, 610
Autoencoders	3	004, 008, 610
Redes recorrentes (RNN, LSTM)	2	185, 610

As demais opções com 1 ocorrência cada incluem: Stable Diffusion (IDs: 102, 183, 195, 203 - 4 artigos), ChatGPT (IDs: 186, 195 - 2 artigos), Midjourney (IDs: 195, 203 - 2 artigos), e diversas outras tecnologias específicas.

4.3.5 SQ5: Forma de Uso da Ferramenta de IAG

A forma de uso da ferramenta de IAG nos artigos e o quantitativo são apresentados na Tabela 4.5

Tabela 4.5: SQ5- Forma de uso da ferramenta de IAG

Forma de Uso	Total	IDs dos Artigos
Combinação de ferramentas existentes	20	005, 008, 021, 040, 044, 048, 065, 080, 081, 087, 089, 100, 108, 109, 399, 410, 412, 451, 494, 519
Customização parcial	8	001, 065, 080, 488, 497, 556, 582, 586
Desenvolvimento próprio/extensivo	6	004, 044, 047, 162, 608, 610
Ferramenta original (sem modificações)	6	002, 052, 075, 174, 178, 315
Outro	2	170, 259

As demais opções com 1 ocorrência cada incluem: componentes pré-treinados orquestrados (ID: 247), ferramentas comerciais existentes (ID: 186), pipelines integrados (IDs: 195, 206, 233, 234), entre outras.

4.3.6 SQ6: Desafios Técnicos Identificados

Os desafios técnicos identificados em cada artigo e o quantitativo são apresentados na Tabela 4.6

Tabela 4.6: SQ6- Desafios técnicos identificados

Desafio Técnico	Total	IDs dos Artigos
Outro	22	021, 047, 048, 052, 075, 089, 100, 108, 109, 174, 178, 315, 399, 410, 412, 488, 494, 497, 519, 556, 586, 610
Coerência temporal	16	001, 005, 008, 040, 052, 065, 075, 080, 089, 100, 174, 399, 410, 412, 582, 608
Estabilidade do sistema	7	040, 052, 065, 080, 087, 089, 100
Latência/tempo de resposta	5	008, 044, 089, 100, 451
Escalabilidade	4	008, 044, 089, 100
Limitações de resolução	4	002, 089, 100, 234
Sincronização áudio-vídeo	4	021, 080, 089, 100

As demais opções com 1 ocorrência cada incluem: custo computacional (IDs: 191, 233 - 2 artigos), e diversas outras limitações técnicas específicas mencionadas individualmente.

4.3.7 SQ7: Desafios Éticos e Criativos

Os desafios éticos e criativos de cada artigo e o quantitativo são apresentados na Tabela 4.7

Tabela 4.7: SQ7- Desafios éticos e criativos

Desafio Ético/Criativo	Total	IDs dos Artigos
Impacto na indústria criativa	19	001, 005, 008, 025, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 100, 170, 174, 556, 586
Autenticidade/autoria	17	001, 002, 005, 040, 044, 048, 052, 065, 075, 080, 081, 100, 170, 171, 174, 451, 608
Outro	15	089, 100, 108, 109, 174, 178, 315, 399, 410, 412, 494, 497, 519, 582, 610
Viés algorítmico	10	005, 048, 052, 075, 089, 100, 171, 174, 185, 586
Privacidade e proteção de dados	4	065, 080, 100, 488
Uso não autorizado de referências	3	005, 044, 100
Plágio e direitos autorais	2	100, 174

As demais opções com 1 ocorrência cada incluem: Discussão limitada (IDs: 206, 234, 247 - 3 artigos), Não informado (IDs: 279, 301, 305 - 3 artigos), e diversas outras questões éticas específicas.

4.3.8 SQ8: Apresentação de Análises Empíricas

A apresentação de análises empíricas de cada artigo e o quantitativo são apresentados na Tabela 4.8

Tabela 4.8: SQ8- Apresentação de análises empíricas

Análise Empírica	Total	IDs dos Artigos
Sim	48	001, 004, 005, 008, 025, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 089, 101, 108, 109, 162, 170, 174, 178, 183, 186, 191, 195, 203, 206, 212, 234, 259, 279, 301, 305, 399, 410, 412, 451, 488, 494, 497, 519, 556, 582, 586, 608, 610
Não	6	002, 100, 102, 171, 185, 247
Parcialmente	2	233, 284

4.3.9 SQ8.1: Método Empírico Adotado

O método empírico adotado em cada artigo e o quantitativo são apresentados na Tabela 4.9

Tabela 4.9: SQ8.1- Método empírico adotado

Método Empírico	Total	IDs dos Artigos
Experimentos controlados	22	001, 008, 014, 025, 040, 044, 047, 080, 100, 162, 174, 399, 410, 412, 488, 494, 519, 556, 582, 586, 608, 610
Surveys/questionários	15	001, 014, 044, 047, 048, 089, 100, 108, 178, 183, 412, 497, 582, 586, 610
Estudos de caso	11	005, 040, 044, 048, 052, 065, 075, 080, 100, 174, 178
Entrevistas	9	004, 044, 047, 075, 080, 081, 100, 101, 305
Outro	5	100, 109, 412, 488, 556
Avaliação heurística	3	052, 100, 451
Observação participante	2	075, 100

As demais opções com 1 ocorrência cada incluem: Análise de literatura (ID: 284), Comparação de imagens via embeddings (ID: 259), Experimento controlado (ID: 087), entre outros.

4.3.10 SQ9: Finalidade Principal da IAG

A finalidade principal da IAG em cada artigo e o quantitativo são apresentados na Tabela 4.10

Tabela 4.10: SQ9- Finalidade principal da IAG

Finalidade Principal	Total	IDs dos Artigos
Outro	13	008, 075, 080, 100, 399, 412, 488, 494, 519, 556, 586, 608, 610
Automação da pós-produção	9	065, 080, 087, 089, 100, 108, 109, 178, 451
Criação de roteiros/narrativas	9	001, 005, 052, 065, 075, 080, 109, 178, 582
Criação de imagens/fotografia	3	044, 174, 497
Geração de efeitos especiais	3	040, 047, 065

Tabela 4.10: (continuação)

Finalidade Principal	Total	IDs dos Artigos
Animações interativas	2	002, 004

As demais opções com 1 ocorrência cada incluem: Suporte criativo (ID: 101, 102 - 2 artigos), e diversas outras finalidades específicas.

4.3.11 SQ10: Tipos de conteúdos gerados

O tipo de conteúdo gerado em cada artigo e o quantitativo são apresentados na Tabela 4.11

Tabela 4.11: SQ10- Tipos de conteúdos gerados

Tipo de Conteúdo	Total	IDs dos Artigos
Imagens estáticas	14	002, 005, 025, 044, 081, 108, 109, 170, 174, 185, 488, 497, 556, 582
Animações	13	002, 004, 005, 040, 047, 048, 081, 102, 170, 206, 305, 494, 610
Vídeos completos	12	040, 048, 065, 089, 100, 108, 109, 178, 399, 412, 451, 608
Outro	9	001, 008, 065, 075, 080, 100, 109, 519, 586

As demais opções com 1 ocorrência cada incluem: Efeitos (impactos, passos, ruídos - ID: 101), Frames de storyboard estilizados (ID: 212), Sons ambientais (ID: 101), Áudio (fala - ID: 162), entre outras.

4.3.12 SQ11: Tipo de dispositivo/tecnologia utilizada pelo usuário

O tipo de dispositivos/tecnologia utilizados em cada artigo e o quantitativo são apresentados na Tabela 4.12

Tabela 4.12: SQ11- Tipo de dispositivo/tecnologia utilizada

Dispositivo/Tecnologia	Total	IDs dos Artigos
Computadores/notebooks	24	001, 004, 005, 008, 025, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 109, 174, 412, 451, 488, 519, 556, 582, 610
Interfaces em nuvem (SaaS, Co-lab)	12	040, 052, 065, 075, 080, 081, 087, 089, 108, 109, 174, 519
Outro	7	025, 399, 494, 497, 519, 586, 608
Dispositivos especializados (megas digitalizadoras, câmeras inteligentes)	2	065, 519
Ambientes imersivos (VR/AR/MR)	1	519
Assistentes de voz (Alexa, Google Nest)	1	519

Tabela 4.12: (continuação)

Dispositivo/Tecnologia	Total	IDs dos Artigos
Dispositivos móveis (smartphones/tablets)	1	519

As demais opções com 1 ocorrência cada incluem: Não informado (IDs: 170, 171, 279, 284, 301), e diversas outras tecnologias específicas.

4.3.13 SQ12: Tipo de interação com a IAG

O tipo de interação com a IAG em cada artigo e o quantitativo são apresentados na Tabela 4.13

Tabela 4.13: SQ12- Tipo de interação com a IAG

Tipo de Interação	Total	IDs dos Artigos
Interação textual/prompt	25	001, 005, 025, 040, 044, 047, 048, 052, 065, 075, 080, 081, 087, 089, 100, 108, 109, 174, 399, 412, 451, 488, 494, 519, 586
Interface gráfica (GUI)	12	001, 002, 004, 008, 044, 047, 048, 080, 081, 087, 100, 109
Interação multimodal (ex: texto + imagem)	7	065, 080, 108, 497, 556, 582, 608
Outro	2	451, 610
Interação programática (código)	1	494

As demais opções com 1 ocorrência cada incluem: Interação textual (prompts) (IDs: 002, 170, 183, 185), e outras formas específicas de interação.

4.3.14 SQ13: Modelo específico utilizado

O modelo específico utilizado em cada artigo e o quantitativo são apresentados na Tabela 4.14

Tabela 4.14: SQ13- Modelo específico utilizado

Modelo Específico	Total	IDs dos Artigos
Stable Diffusion	23	002, 005, 025, 081, 102, 174, 183, 185, 195, 203, 206, 212, 233, 234, 247, 412, 451, 488, 519, 556, 582, 586, 610
GPT-4	12	001, 040, 044, 047, 065, 075, 087, 089, 108, 109, 412, 610
Outro	11	008, 048, 052, 065, 100, 108, 412, 451, 494, 497, 608
MidJourney	8	002, 040, 170, 195, 203, 233, 284, 610
CLIP	7	014, 080, 212, 259, 279, 399, 610
DALL-E	7	044, 065, 089, 108, 109, 451, 610
GPT-3	3	005, 162, 610

Categorias específicas incluem diversos modelos e ferramentas mencionadas individualmente.

4.3.15 SQ14: Modelos/Benchmarks para Validação

Os modelos/benchmarks utilizados para validação em cada artigo e o quantitativo são apresentados na Tabela 4.15

Tabela 4.15: SQ14- Modelos/benchmarks para validação

Benchmark/Validação	Total	IDs dos Artigos
Análises qualitativas com especialistas	15	004, 005, 047, 048, 052, 065, 075, 080, 089, 100, 108, 109, 174, 410, 451
Métricas quantitativas (FID, IS, PSNR)	13	001, 080, 100, 399, 410, 412, 488, 494, 519, 556, 582, 608, 610
Comparação com padrões da indústria	10	047, 065, 100, 488, 494, 519, 556, 582, 586, 610
Outro	5	025, 100, 108, 174, 497
Testes A/B com usuários	4	100, 109, 412, 586

Categorias específicas incluem diversos métodos de validação e métricas específicas mencionadas individualmente.

4.3.16 SQ16: Desafios quanto à Reprodutibilidade e Confiabilidade

Os Desafios quanto à Reprodutibilidade e Confiabilidade de cada estudo e o quantitativo são apresentados na Tabela 4.16

Tabela 4.16: SQ16- Desafios quanto à reprodutibilidade e confiabilidade

Desafio	Total	IDs dos Artigos
Dependência de dados de treinamento	22	001, 002, 005, 025, 040, 044, 048, 065, 075, 080, 081, 087, 089, 100, 284, 399, 410, 488, 497, 582, 608, 610
Variabilidade nos resultados	17	001, 005, 008, 025, 040, 044, 047, 048, 052, 065, 075, 080, 087, 100, 108, 109, 451
Outro	8	100, 109, 178, 412, 494, 519, 556, 586
Falta de benchmarks padronizados	7	008, 044, 052, 065, 075, 080, 100
Dificuldades de validação	3	047, 100, 412
Instabilidade do modelo em diferentes ambientes	3	002, 052, 100
Viés de dados	3	171, 185, 186

4.3.17 SQ17: Intenção de Tornar Perceptível o Uso da IAG

A Intenção de Tornar Perceptível o Uso da IAG em cada artigo e o quantitativo são apresentados na Tabela 4.17

Tabela 4.17: SQ17- Intenção de tornar perceptível o uso da IAG

Intenção	Total	IDs dos Artigos
Não	21	001, 002, 008, 025, 040, 047, 089, 100, 171, 174, 183, 185, 186, 191, 195, 203, 206, 212, 412, 451, 494
Não informado	19	004, 162, 170, 171, 183, 185, 191, 315, 376, 399, 410, 488, 497, 519, 556, 582, 586, 608, 610
Sim	18	005, 048, 052, 065, 075, 080, 081, 087, 101, 102, 108, 109, 178, 259, 279, 284, 301, 305
Parcialmente	1	044

4.4 ANÁLISE INTEGRADA E DISCUSSÃO DOS RESULTADOS

Os dados quantitativos apresentados nas seções anteriores revelam um panorama abrangente e multifacetado da aplicação de IAG na produção de conteúdos audiovisuais não interativos. Esta seção apresenta uma análise integrada dos resultados, identificando padrões, tendências, contradições e lacunas que emergem da síntese dos 60 artigos selecionados. A discussão está organizada em análises específicas por subquestão, permitindo uma compreensão holística do fenômeno estudado.

4.4.1 SQ1: Predominância de Propostas de Solução em Campo Tecnológico em Expansão

A análise da SQ1 revela que Proposta de Solução é a categoria dominante com 31 artigos (51,7% do total), seguida por Pesquisa de Avaliação (19 artigos, 31,7%) e Pesquisa de Validação (7 artigos, 11,7%). Essa distribuição é característica de campos tecnológicos emergentes ou em rápida expansão, onde a inovação técnica precede a validação sistemática.

A predominância de propostas técnicas (31 artigos) indica que a pesquisa sobre IAG aplicada ao audiovisual ainda está fortemente focada no desenvolvimento de novas ferramentas, frameworks, arquiteturas e metodologias. Isso reflete o ritmo acelerado de inovação no campo, onde pesquisadores buscam explorar as capacidades recém-disponibilizadas por modelos de difusão, transformers multimodais e outras arquiteturas generativas para aplicações audiovisuais específicas.

No entanto, a presença respeitável de Pesquisas de Avaliação (19 artigos, 31,7%) demonstra que há também preocupação crescente em avaliar criticamente as tecnologias existentes. Esses estudos investigam como ferramentas de IAG performam em contextos audiovisuais específicos, quais suas limitações práticas, como profissionais criativos as percebem e utilizam, e qual seu impacto real em fluxos de trabalho de produção.

A proporção de Pesquisas de Validação (7 artigos, 11,7%) permanece relativamente baixa, mas não negligenciável. Validações rigorosas, que testariam hipóteses específicas sobre a eficácia de soluções em ambientes controlados, com comparações sistemáticas contra métodos estabelecidos, são essenciais para consolidar conhecimento científico. Sua presença limitada sugere que o campo ainda está em transição de uma fase exploratória para uma fase de consolidação metodológica.

A presença marginal de Artigo de Opinião (artigo 171) e Relato de Experiência (artigo 048) evidencia carência de reflexões teóricas profundas e documentação sistemática de lições aprendidas em projetos reais.

Essa distribuição contrasta com campos tecnológicos mais maduros, onde pesquisas avaliativas e validações rigorosas tendem a predominar sobre propostas puramente técnicas. O perfil atual sugere que o campo de IAG aplicada ao audiovisual está em fase de experimentação tecnológica intensa, com crescente mas ainda insuficiente atenção à validação empírica e reflexão crítica sobre implicações práticas e teóricas.

4.4.2 SQ2: Consolidação em Mídia e Entretenimento com Crescente Interdisciplinaridade

A SQ2 confirma que Mídia e Entretenimento (34 artigos, 56,7%) e Inteligência Artificial (31 artigos, 51,7%) são as áreas dominantes, com sobreposição significativa entre elas. Essa sobreposição, onde artigos frequentemente se enquadram em ambas as categorias, evidencia a natureza intrinsecamente interdisciplinar do campo: pesquisas sobre IAG aplicada ao audiovisual não podem ser plenamente compreendidas apenas sob a ótica técnica de IA ou apenas sob a perspectiva de produção audiovisual.

Design Digital aparece em 13 artigos (21,7%), indicando reconhecimento da dimensão de interface, experiência do usuário e estética interativa na aplicação de IAG. A presença de Educação em 7 artigos (11,7%) sinaliza interesse emergente em aplicar IAG para fins pedagógicos, como geração de tutoriais, materiais didáticos audiovisuais e ferramentas de aprendizagem interativa. Esse número revela que aplicações educacionais já constituem uma área de investigação relevante dentro do espectro de pesquisas sobre IAG aplicada ao audiovisual.

Ciências Sociais apresenta apenas 3 artigos (5%), mas sua presença indica início de investigações sobre impactos socioculturais da IAG. A diversidade de categorias únicas mencionadas (Animação computacional, Artes Digitais, Edição de filmes, Gestão, Marketing digital, Psicologia) demonstra que aplicações de IAG estão se difundindo para nichos específicos, cada um com demandas e desafios particulares.

A ausência de estudos em áreas como Direito Digital, Políticas Públicas ou Ética Aplicada constitui uma lacuna crítica, especialmente considerando os desafios éticos e regulatórios que emergem fortemente na SQ7.

4.4.3 SQ3: Geração de Vídeo como Foco Central, mas Fragmentação de Aplicações

A SQ3 mostra que Geração/modificação de vídeos é o foco mais frequente (19 artigos, 31,7%), seguido por Storytelling/narrativas (12 artigos, 20%). Essa distribuição reflete tanto as capacidades técnicas emergentes dos modelos de difusão de vídeo quanto o interesse em aplicar IAG em etapas criativas fundamentais da produção audiovisual.

A presença significativa de Storytelling/narrativas (12 artigos) indica que IAG está sendo explorada não apenas para tarefas técnicas ou repetitivas, mas também para processos criativos centrais como desenvolvimento de roteiros, construção de personagens e estruturação narrativa. Isso desafia a percepção de que IA generativa seria adequada apenas para automação de tarefas mecânicas.

No entanto, a alta frequência da categoria "Outro" (10 artigos, 16,7%) evidencia fragmentação: muitas aplicações específicas não se encaixam nas categorias pré-definidas. Exemplos incluem automação de criação de storyboards (ID: 212), produção de tutoriais em vídeo (ID: 247), criação de sons ambientais (ID: 101) e animação em tempo real para arte pública (ID: 102). Essa diversidade, embora positiva por demonstrar criatividade, dificulta a consolidação de boas práticas e benchmarks compartilhados.

A relativamente baixa frequência de Criação de efeitos audiovisuais (5 artigos) e Automação de processos de edição (2 artigos) é surpreendente. Essas são áreas onde IAG poderia ter impacto imediato na redução de custos e tempo. Sua sub-representação pode indicar

que tecnologias atuais ainda não atendem aos padrões de qualidade exigidos por pós-produção profissional, ou que pesquisas nessas áreas ocorrem predominantemente em contextos industriais sem publicação acadêmica.

4.4.4 SQ4: Hegemonia Consolidada de Modelos de Difusão e Transformers

A SQ4 confirma a hegemonia absoluta dos Modelos de Difusão (29 artigos, 48,3%) e Transformers (22 artigos, 36,7%) como as arquiteturas fundamentais para IAG aplicada ao audiovisual. Essa concentração reflete a revolução tecnológica iniciada em 2022 com a popularização de Stable Diffusion (Rombach et al., 2022), DALL·E 2, Midjourney e modelos de linguagem como GPT-4 (Brown et al., 2020).

A queda das GANs para apenas 10 artigos (16,7%) confirma a mudança de paradigma. Embora GANs tenham dominado a década anterior, Modelos de Difusão oferecem maior estabilidade de treinamento, melhor qualidade de saída e controle mais fino sobre o processo generativo (Dhariwal e Nichol, 2021). A presença de Modelos híbridos (6 artigos) sugere que abordagens que combinam múltiplas arquiteturas estão sendo exploradas para aproveitar vantagens complementares.

A categoria "Outro" (12 artigos) agrupa tecnologias específicas como Stable Diffusion (mencionado explicitamente em 4 artigos adicionais), ChatGPT (2 artigos) e Midjourney (2 artigos). A fragmentação nessa categoria indica que pesquisadores frequentemente utilizam combinações customizadas de modelos pré-treinados em vez de arquiteturas únicas.

A baixa frequência de Autoencoders (3 artigos) e Redes recorrentes (2 artigos) sugere que essas arquiteturas, embora fundamentais em contextos específicos (compressão, modelagem temporal), não são protagonistas nas aplicações audiovisuais contemporâneas de IAG.

4.4.5 SQ5: Combinação de Ferramentas como Estratégia Dominante

A SQ5 revela que Combinação de ferramentas existentes é a abordagem mais comum (20 artigos, 33,3%), seguida por Customização parcial (8 artigos, 13,3%) e Desenvolvimento próprio/extensivo (6 artigos, 10%). Ferramenta original sem modificações aparece em apenas 6 artigos (10%).

Essa distribuição indica que, embora ferramentas de IAG comerciais e open-source estejam amplamente disponíveis, raramente são utilizadas isoladamente. A maioria dos projetos audiovisuais exige orquestração de múltiplos modelos especializados: um modelo de linguagem para roteiro, um modelo de difusão para imagens, um modelo de síntese de voz, um modelo de animação facial, entre outros. Essa necessidade de integração reflete a natureza multimodal da produção audiovisual.

A baixa proporção de desenvolvimentos proprietários extensivos (6 artigos) confirma que a maioria dos pesquisadores não possui recursos ou expertise para treinar modelos complexos do zero. Há dependência estrutural de modelos pré-treinados disponibilizados por grandes corporações (OpenAI, Stability AI, Anthropic, Google, Meta).

Essa dependência tem implicações críticas: concentra poder tecnológico, limita transparência sobre dados de treinamento, cria vulnerabilidades a mudanças de políticas de acesso e precificação (*pricing*), e dificulta auditoria de vieses. A democratização da IAG permanece parcial, ferramentas são acessíveis, mas o controle sobre suas arquiteturas fundamentais permanece centralizado.

4.4.6 SQ6: Coerência Temporal Persiste como Desafio Central

A SQ6 identifica Coerência temporal (16 artigos, 26,7%) como desafio técnico mais frequente, seguido por uma ampla categoria "Outro"(22 artigos, 36,7%) que agrupa desafios específicos. Estabilidade do sistema (7 artigos), Latência/tempo de resposta (5 artigos), Escalabilidade (4 artigos), Limitações de resolução (4 artigos) e Sincronização áudio-vídeo (4 artigos) aparecem com frequências menores.

A coerência temporal emerge como gargalo central. Apesar dos avanços extraordinários em geração de imagens estáticas, a extensão para vídeo, que exige consistência entre frames, ausência de ruído (*flickering*), manutenção de identidade de objetos e personagens ao longo do tempo, apresenta desafios significativos. Isso explica por que muitos estudos se concentram em vídeos curtos, animações controladas ou aplicações que toleram certa inconsistência temporal.

A alta frequência da categoria "Outro"(22 artigos) evidencia que desafios técnicos são altamente contextuais. Exemplos incluem: custo computacional (IDs: 191, 233), controle emocional (ID: 087), limitações de dados (IDs: 081, 101, 162), robustez de sincronização labial (ID: 247), repetição de objetos em preenchimento (*in-painting*) (ID: 234), entre outros. Essa heterogeneidade dificulta a formulação de soluções generalizáveis.

A relativamente baixa frequência de Sincronização áudio-vídeo (4 artigos) é notável, considerando que produção audiovisual depende criticamente dessa sincronização. Isso pode indicar que muitos estudos tratam áudio e vídeo separadamente, dificultando criação de sistemas verdadeiramente integrados.

4.4.7 SQ7: Preocupações Éticas Concentradas em Impacto Profissional e Autoria

A SQ7 revela que Impacto na indústria criativa (19 artigos, 31,7%) e Autenticidade/autoria (17 artigos, 28,3%) são os desafios éticos/criativos mais mencionados, seguidos por uma categoria "Outro"significativa (15 artigos, 25%) e Viés algorítmico (10 artigos, 16,7%).

O destaque para impacto na indústria criativa reflete preocupações crescentes com substituição de profissionais humanos, precarização do trabalho criativo, desvalorização de habilidades artísticas tradicionais e concentração de poder econômico em empresas de tecnologia (Capraro et al., 2024). Diversos estudos mencionam explicitamente receios de que a IAG possa eliminar oportunidades para artistas iniciantes, roteiristas, animadores e editores.

A questão da Autenticidade/autoria (17 artigos) reflete dilemas filosóficos e legais ainda não resolvidos (Floridi e Chiriatti, 2020). Quem é o autor de uma obra gerada por IA? Se um modelo foi treinado em milhões de obras protegidas, houve violação de direitos autorais? Como atribuir crédito em colaborações humano-IA? Essas questões permanecem em grande parte sem resposta, tanto academicamente quanto regulatoriamente.

A presença significativa de Viés algorítmico (10 artigos) demonstra consciência crescente sobre como modelos treinados em dados enviesados podem perpetuar estereótipos de gênero, raça, cultura e classe. No entanto, a baixa frequência de Plágio e direitos autorais (2 artigos) e Uso não autorizado de referências (3 artigos) é surpreendente, dado que esses temas têm sido centrais em debates públicos e processos judiciais recentes.

A categoria "Outro"(15 artigos) agrupa preocupações diversas, incluindo discussões limitadas em artigos técnicos (IDs: 206, 234, 247) e casos onde questões éticas não foram informadas (IDs: 279, 301, 305). Isso sugere que muitos estudos técnicos ainda tratam dimensões éticas como secundárias ou fora de escopo.

4.4.8 SQ8 e SQ8.1: Presença forte de análises empíricas, mas com métodos diversos

A SQ8 mostra que 48 artigos (80%) apresentam análises empíricas, enquanto apenas 6 (10%) não apresentam nenhuma forma de validação empírica. Isso demonstra que a maioria das pesquisas no campo incorpora alguma forma de verificação prática de suas propostas.

A SQ8.1 detalha os métodos empíricos: Experimentos controlados (22 artigos, 36,7%), Surveys/questionários (15 artigos, 25%), Estudos de caso (11 artigos, 18,3%) e Entrevistas (9 artigos, 15%) são os mais frequentes. Essa diversidade metodológica é positiva, indicando que pesquisadores empregam métodos apropriados para diferentes tipos de questões de pesquisa.

No entanto, é importante notar que muitos experimentos controlados têm escala limitada, focam em métricas técnicas (FID, IS, PSNR) e não avaliam adequadamente aspectos subjetivos como qualidade estética, adequação narrativa ou valor criativo percebido. Surveys e entrevistas, quando presentes, frequentemente têm amostras pequenas e não representativas de profissionais da indústria (apesar de, no caso das entrevistas, isto não ser um problema).

A baixa frequência de Avaliação heurística (3 artigos) e Observação participante (2 artigos) indica que métodos qualitativos aprofundados, que poderiam revelar como profissionais realmente integram IAG em seus workflows, são pouco utilizados.

A categoria "Outro" (5 artigos) agrupa métodos específicos como análise de literatura (ID: 284), comparação via *embeddings* (ID: 259), e experimentos controlados únicos (ID: 087). Essa fragmentação sugere que protocolos metodológicos padronizados são ainda incipientes no campo.

4.4.9 SQ9: Diversidade de finalidades com foco em pós-produção e narrativas

A SQ9 revela diversidade significativa nas finalidades de uso da IAG. Curiosamente, a categoria "Outro" é a mais frequente (13 artigos, 21,7%), indicando fragmentação de aplicações. Automação da pós-produção (9 artigos, 15%) e Criação de roteiros/narrativas (9 artigos, 15%) aparecem empatadas como finalidades específicas mais comuns.

A presença equilibrada entre pós-produção (tarefas técnicas) e criação narrativa (tarefas criativas) sugere que IAG está sendo explorada em todo o espectro da produção audiovisual, não apenas para automação de processos repetitivos. Isso desafia a percepção inicial de que IA seria adequada apenas para tarefas mecânicas.

A relativamente baixa frequência de Geração de efeitos especiais (3 artigos), Criação de imagens/fotografia (3 artigos) e Animações interativas (2 artigos) sugere que essas aplicações, embora tecnicamente viáveis, ainda não são foco prioritário de pesquisa acadêmica. Isso pode indicar desconexão entre interesses acadêmicos e demandas industriais.

A categoria "Outro" (13 artigos) agrupa finalidades altamente específicas: acelerar criação cinematográfica (ID: 233), automatizar produção de tutoriais (ID: 247), otimizar edição para engajamento (ID: 279), gerar *talking-heads* realistas (ID: 301), entre outras. Essa heterogeneidade reflete a natureza exploratória do campo, onde aplicações de nicho estão sendo constantemente descobertas.

4.4.10 SQ10: Imagens estáticas e animações como conteúdos predominantes

A SQ10 mostra que imagens estáticas (14 artigos, 23,3%), animações (13 artigos, 21,7%) e vídeos completos (12 artigos, 20%) são os tipos de conteúdo mais frequentemente gerados, com distribuição relativamente equilibrada. A categoria "Outro" aparece em 9 artigos (15%).

A prevalência de imagens estáticas reflete a maturidade superior dos modelos de difusão para geração de imagens em comparação com vídeo. Imagens podem ser geradas com alta qualidade, resolução e controle artístico usando ferramentas amplamente disponíveis.

A presença significativa de animações (13 artigos) é particularmente interessante. Animações, por serem construções artificiais por natureza, são mais compatíveis com abordagens generativas do que tentativas de replicar filmagens *live-action* fotorrealistas. Além disso, animação tolera melhor certos tipos de inconsistências visuais que seriam inaceitáveis em vídeo realista.

Vídeos completos (12 artigos) aparecem com frequência respeitável, mas é importante notar que muitos desses vídeos são curtos, de baixa resolução ou toleram artefatos temporais. Vídeos longos em alta resolução e qualidade permanecem raros.

A categoria "Outro" (9 artigos) inclui conteúdos especializados como frames de storyboard (ID: 212), sons ambientais (ID: 101), áudio narrativo (ID: 087, 162), efeitos sonoros (ID: 101), tutoriais em vídeo (247), talking-heads (ID: 301), entre outros. Isso evidencia que IAG está sendo aplicada a modalidades além de imagem/vídeo.

4.4.11 SQ11: Computadores e nuvem como infraestrutura dominante

A SQ11 mostra que computadores/notebooks (24 artigos, 40%) e Interfaces em nuvem (12 artigos, 20%) são os dispositivos mais utilizados. Essa distribuição reflete os altos requisitos computacionais de modelos generativos complexos.

A necessidade de hardware avançado (GPUs potentes, memória abundante) cria barreiras à democratização. Enquanto interfaces em nuvem (como Google Colab, Runway, plataformas SaaS) reduzem barreiras de entrada ao terceirizar computação, elas criam dependência de serviços comerciais com custos recorrentes e políticas de uso que podem mudar.

A baixíssima frequência de dispositivos móveis (1 artigo), Ambientes imersivos VR/AR/MR (1 artigo) e assistentes de voz (1 artigo) indica que IAG para audiovisual ainda não se expandiu para plataformas alternativas. Isso representa tanto uma limitação (barreiras de acesso) quanto uma oportunidade (espaço para inovação em interfaces).

A categoria "Outro" (7 artigos) e casos não informados (múltiplas ocorrências) sugerem que muitos estudos não especificam claramente a infraestrutura utilizada, dificultando reprodutibilidade e avaliação de viabilidade prática.

4.4.12 SQ12: Prompts textuais como modalidade de interação hegemônica

A SQ12 confirma que Interação textual/prompt (25 artigos, 41,7%) é a modalidade dominante, seguida por Interface gráfica (GUI) (12 artigos, 20%) e Interação multimodal (7 artigos, 11,7%).

A hegemonia de prompts textuais reflete a arquitetura dos modelos mais populares, como GPT (Brown et al., 2020), DALL·E, Stable Diffusion (Rombach et al., 2022), Midjourney, que foram projetados para serem condicionados por linguagem natural. Essa abordagem tem vantagens (flexibilidade, expressividade) e desvantagens (exige prática, cria nova forma de alfabetização técnica chamada "*prompt engineering*").

A presença de Interfaces gráficas (12 artigos) indica que ferramentas estão evoluindo para oferecer controles visuais além de prompts textuais. GUIs podem tornar IAG mais acessível a usuários sem expertise técnica, mas frequentemente limitam expressividade em comparação com prompts textuais.

Interação multimodal (7 artigos), como texto + imagem, ou áudio + imagem, representa uma tendência emergente importante. Modelos multimodais permitem controle mais fino e nuances que seriam difíceis de expressar apenas em texto.

A ausência de comandos por voz (0 artigos explícitos) e gestos/físico/sensorial (0 artigos) sugere que modalidades potencialmente mais intuitivas são pouco exploradas. Isso representa uma oportunidade para pesquisas futuras, especialmente considerando que profissionais criativos podem preferir interfaces que mimetizem interações físicas tradicionais.

4.4.13 SQ13: Concentração em poucos modelos comerciais dominantes

A SQ13 revela concentração extrema: Stable Diffusion (23 artigos, 38,3%), GPT-4 (12 artigos, 20%), MidJourney (8 artigos, 13,3%), CLIP (7 artigos, 11,7%) e DALL·E (7 artigos, 11,7%) dominam completamente.

Essa concentração reflete a hegemonia de poucas empresas (OpenAI, Stability AI, Anthropic, Midjourney Inc.) e a acessibilidade de seus modelos via APIs ou código aberto. Stable Diffusion, por ser open-source, permite customização e é amplamente adotado. GPT-4, apesar de ser proprietário e pago, é utilizado extensivamente por sua capacidade multimodal e qualidade de saída.

Essa dependência de poucos modelos cria vulnerabilidades: mudanças em políticas de acesso, preços, funcionalidades ou mesmo descontinuação podem interromper pesquisas e aplicações. Além disso, a centralização limita a diversidade tecnológica. A maioria dos estudos explora variações de aplicação dos mesmos modelos, em vez de desenvolver arquiteturas alternativas.

A categoria "Outro" (11 artigos) agrupa modelos específicos e combinações customizadas. A presença de GPT-3 (3 artigos) indica que versões anteriores de modelos ainda são utilizadas, possivelmente por questões de custo ou suficiência para tarefas específicas.

A baixa frequência de modelos especializados para domínios audiovisuais específicos (geração de música, síntese de voz profissional, animação facial de alta fidelidade) sugere oportunidade para desenvolvimento de modelos de nicho.

4.4.14 SQ14: Validação dual: qualitativa por especialistas e quantitativa por métricas

A SQ14 mostra que Análises qualitativas com especialistas (15 artigos, 25%) e Métricas quantitativas (13 artigos, 21,7%) são as formas de validação mais comuns, seguidas por Comparação com padrões da indústria (10 artigos, 16,7%).

A predominância de análises qualitativas reflete a natureza intrinsecamente subjetiva da avaliação de conteúdos audiovisuais: qualidade estética, adequação narrativa, impacto emocional e valor criativo não podem ser adequadamente capturados por métricas puramente quantitativas. Avaliações por especialistas (profissionais da indústria, artistas, críticos) fornecem insights valiosos sobre dimensões que métricas automatizadas não capturam.

No entanto, análises qualitativas apresentam desafios. São custosas, demoradas, difíceis de escalar e potencialmente sujeitas a vieses dos avaliadores. A maioria dos estudos utiliza amostras pequenas de especialistas, levantando questões sobre representatividade.

Métricas quantitativas (13 artigos), como FID (*Fréchet Inception Distance*), IS (*Inception Score*), PSNR (*Peak Signal-to-Noise Ratio*), SSIM (*Structural Similarity Index*), são amplamente utilizadas (Karras et al., 2020). No entanto, têm limitações conhecidas. Não capturam adequadamente aspectos semânticos, narrativos ou estéticos cruciais para audiovisual. Por exemplo, FID mede similaridade estatística entre distribuições de imagens, mas não avalia coerência narrativa ou impacto emocional.

A presença de Comparação com padrões da indústria (10 artigos) indica que alguns estudos tentam validar resultados contra benchmarks estabelecidos ou práticas profissionais. Isso é positivo, embora ainda minoritário.

A baixa frequência de Testes A/B com usuários (4 artigos) é notável. Testes A/B poderiam avaliar preferências de audiências reais, mas são raros, possivelmente por custos e complexidade logística.

A categoria "Outro"(5 artigos) agrupa métodos específicos, e múltiplos artigos não especificam claramente seus métodos de validação, dificultando comparação entre estudos.

4.4.15 SQ16: Dependência de dados e variabilidade como obstáculos à reprodutibilidade

A SQ16 identifica Dependência de dados de treinamento (22 artigos, 36,7%) como o desafio mais frequente para reprodutibilidade, seguido por Variabilidade nos resultados (17 artigos, 28,3%) e Falta de benchmarks padronizados (7 artigos, 11,7%).

A dependência de dados de treinamento é particularmente problemática porque a maioria dos modelos comerciais não divulga os datasets utilizados. Isso dificulta auditoria de vieses, verificação de conformidade com direitos autorais e compreensão de limitações dos modelos. Além disso, a qualidade e características dos dados de treinamento influenciam diretamente os tipos de conteúdo que modelos podem gerar, criando vieses invisíveis.

A variabilidade nos resultados (17 artigos) reflete a natureza estocástica dos modelos generativos: mesmo com o mesmo prompt e parâmetros, execuções diferentes produzem saídas diferentes. Embora essa variabilidade seja desejável para exploração criativa, ela compromete reprodutibilidade científica e previsibilidade em fluxos de produção profissionais.

A falta de benchmarks padronizados (7 artigos) constitui uma limitação crítica. Sem datasets de referência, métricas consensuais e protocolos de avaliação compartilhados, é difícil comparar resultados entre estudos ou avaliar progressos ao longo do tempo. Isso retarda a consolidação de conhecimento científico no campo.

A categoria "Outro"(8 artigos) agrupa desafios específicos como viés de dados (IDs: 171, 185, 186), necessidade de validação (ID: 171), dependência de hardware (ID: 195), segurança e privacidade (IDs: 185, 186), entre outros.

Instabilidade do modelo em diferentes ambientes (3 artigos) e Dificuldades de validação (3 artigos) aparecem com frequências menores, mas apontam para problemas práticos de deployment e avaliação.

4.4.16 SQ17: Ambiguidade ética sobre transparência no uso de IAG

A SQ17 revela distribuição dividida: Não (21 artigos, 35%), Não informado (19 artigos, 31,7%) e Sim (18 artigos, 30%) aparecem com frequências similares. Apenas 1 artigo indica abordagem Parcialmente.

Essa distribuição evidencia que não há consenso sobre a ética da transparência. Em contextos artísticos ou experimentais, tornar visível o uso de IA pode ser parte da proposta estética (arte generativa, instalações). Em contextos comerciais ou entretenimento mainstream, há incentivo para que IA permaneça invisível, criando ilusão de conteúdo totalmente humano.

A alta frequência de "Não informado"(19 artigos) é preocupante, pois sugere que muitos estudos técnicos não consideram questões de transparência como relevantes ou dentro de escopo. Isso pode refletir uma cultura acadêmica que prioriza inovação técnica sobre implicações éticas.

A divisão entre "Sim" e "Não" tem implicações profundas. Argumentos favoráveis à transparência incluem: respeito à audiência, prevenção de desinformação, valorização do trabalho humano, rastreabilidade de autoria. Argumentos contrários incluem: foco na qualidade final

independente de método, potencial estigmatização de uso de IA, complexidade de atribuir crédito em colaborações humano-IA.

Essa ambiguidade é problemática em cenários de desinformação e *deepfakes*. Se conteúdos gerados por IA são indistinguíveis de reais e não são marcados, isso facilita manipulação, propaganda e fraudes. Por outro lado, exigir marcação obrigatória pode estigmatizar usos legítimos e criativos.

4.4.17 Síntese: Padrões e Lacunas

A análise dos 60 artigos selecionados revela um campo em processo de consolidação, caracterizado por intensa atividade de pesquisa aplicada, mas ainda marcado por desafios estruturais significativos.

Os principais padrões identificados incluem: (1) predominância de pesquisas avaliativas (31,7%) sobre propostas puramente técnicas, embora propostas de solução ainda liderem (51,7%); (2) hegemonia de poucos modelos comerciais, especialmente Stable Diffusion e GPT-4; (3) combinação de ferramentas como estratégia padrão (33,3%), refletindo a natureza multimodal da produção audiovisual; (4) validação dual, combinando análises qualitativas por especialistas com métricas quantitativas; (5) aplicações fragmentadas em nichos diversos, desde geração de vídeo até storytelling; (6) preocupações éticas crescentes, especialmente sobre impacto profissional e autoria.

No entanto, várias lacunas estruturais persistem e demandam atenção:

1. Lacuna de escala: estudos pequenos e contextos experimentais limitados.
2. Lacuna metodológica: ausência de benchmarks e métricas específicas para audiovisual.
3. Lacuna de reprodutibilidade: dados de treinamento não divulgados e variabilidade estocástica.
4. Lacuna de diversidade tecnológica: concentração em poucos modelos comerciais.
5. Lacuna interdisciplinar: subvalorização de dimensões legais e políticas públicas.
6. Lacuna de democratização: barreiras técnicas e econômicas persistentes.
7. Lacuna regulatória: autoria, direitos e responsabilidade ainda pouco claros.
8. Lacuna de validação ecológica: pouca integração em workflows reais.
9. Lacuna ética operacional: escassez de frameworks de governança.
10. Lacuna temporal: a limitação de janela de memória dos modelos de IA faz com que, após certo volume ou duração da interação, partes do contexto anterior sejam descartadas, comprometendo a continuidade e a coerência necessárias em aplicações profissionais.

Essas lacunas não apenas delimitam os contornos atuais do conhecimento científico sobre IAG aplicada ao audiovisual, mas também apontam direções prioritárias para pesquisas futuras. O campo está em transição de uma fase de experimentação exploratória para uma de consolidação aplicada, mas enfrenta desafios que exigirão esforços coordenados de pesquisadores, indústria, educadores e formuladores de políticas públicas.

5 CONSIDERAÇÕES FINAIS

Este trabalho mapeou sistematicamente 60 artigos científicos publicados entre 2022 e 2025 sobre o uso de IAG na produção audiovisual não interativa. O objetivo central era responder: "Quais são as aplicações, desafios e impactos dessas ferramentas na geração de conteúdos audiovisuais lineares?"

5.1 APLICAÇÕES IDENTIFICADAS

A IAG está sendo aplicada em todo o espectro da produção audiovisual. Geração e modificação de vídeos lideram com 31,7%, seguidas por storytelling e narrativas com 20%. Os conteúdos mais produzidos são imagens estáticas (23,3%), animações (21,7%) e vídeos completos (20%).

A IAG está reconfigurando todo o pipeline de produção. Na pré-produção aparece em storyboards e previs. Na pós-produção, seu uso é mais evidente: edição automatizada, geração de VFX, rotoscopia e correção de cor. No entanto, a baixa frequência de efeitos especiais (5%) e automação de edição (3,3%) sugere que as tecnologias atuais ainda não atendem aos padrões profissionais de qualidade.

As finalidades são diversas: automação da pós-produção e criação de roteiros aparecem empatadas com 15% cada. A alta fragmentação (categoria "Outro" com 21,7%) indica aplicações muito específicas, dificultando a consolidação de boas práticas.

5.2 TECNOLOGIAS DOMINANTES

As tecnologias dominantes são modelos de difusão (48,3%) e transformers (36,7%). Stable Diffusion sozinho aparece em 38,3% dos estudos, seguido por GPT-4 com 20%. A concentração é extrema: apenas cinco ferramentas dominam completamente (Stable Diffusion, GPT-4, Midjourney, CLIP e DALL·E).

A combinação de múltiplas ferramentas tornou-se estratégia padrão (33,3%), refletindo a natureza multimodal do audiovisual (Rombach et al., 2022; Brown et al., 2020). Essa concentração tecnológica cria vulnerabilidades. Mudanças em políticas comerciais podem interromper pesquisas. A dependência de poucos modelos concentra poder em poucas corporações (OpenAI, Stability AI, Google, Meta). A maioria dos pesquisadores não possui recursos para treinar modelos próprios, dependendo de ferramentas pré-treinadas.

A interação via prompts textuais domina (41,7%), criando nova competência técnica chamada "prompt engineering". Interfaces gráficas (20%) e multimodais (11,7%) aparecem como alternativas emergentes. A infraestrutura depende principalmente de computadores (40%) e nuvem (20%), criando barreiras técnicas e econômicas à democratização.

5.3 DESAFIOS TÉCNICOS

A coerência temporal permanece como gargalo central (26,7%). Vídeos longos e de alta qualidade são raros. A maioria dos estudos foca em vídeos curtos que toleram inconsistências, o que explica por que imagens estáticas e animações são mais prevalentes que vídeos completos.

Estabilidade do sistema (11,7%), latência (8,3%), escalabilidade e limitações de resolução (6,7% cada) completam o quadro técnico. A dependência de dados de treinamento

(36,7%) é problemática: modelos não divulgam datasets utilizados, dificultando auditoria de vieses e verificação de direitos autorais.

A variabilidade nos resultados (28,3%) compromete a reprodutibilidade científica. Mesmo com prompts idênticos, execuções diferentes produzem saídas diferentes. A falta de benchmarks padronizados (11,7%) dificulta comparação entre estudos. Métricas quantitativas (FID - *Fréchet Inception Distance*, IS - *Inception Score*, PSNR - *Peak Signal-to-Noise Ratio*) têm limitações conhecidas (Karras et al., 2020) e não capturam adequadamente aspectos narrativos ou estéticos cruciais para o audiovisual.

5.4 DESAFIOS ÉTICOS E CRIATIVOS

O impacto sobre profissionais criativos domina as preocupações éticas (31,7%). Há receios crescentes sobre substituição de trabalhadores, precarização e concentração de poder econômico (Capraro et al., 2024). A automação pode eliminar oportunidades para profissionais iniciantes: roteiristas, animadores e editores enfrentam incertezas sobre o futuro de suas carreiras.

Questões de autoria permanecem sem resposta (28,3%). Quem é o autor de uma obra gerada por IA? Como atribuir crédito em colaborações humano-IA (Floridi e Chiriatti, 2020)? A falta de regulamentação cria vácuo legal onde autoria, direitos e responsabilidade permanecem pouco claros.

Emerge um paradoxo criativo: embora a IAG prometa inovação, tende a reforçar estéticas do passado. Sistemas treinados em grandes corporações otimizam padrões conhecidos, o que pode suplantar rupturas estéticas genuínas. A presença de storytelling (20%) desafia a percepção de que IA seria adequada apenas para tarefas mecânicas. No entanto, questões sobre autenticidade artística permanecem.

A ambiguidade sobre transparência preocupa: 35% dos estudos não tornam perceptível o uso de IA, 31,7% não informam e apenas 30% são transparentes. Sem marcação clara, conteúdos gerados facilitam manipulação e desinformação.

Viés algorítmico (16,7%) também é relevante. Modelos treinados em dados enviesados perpetuam estereótipos. Surpreendentemente, privacidade (6,7%), uso não autorizado de referências (5%) e plágio (3,3%) aparecem com frequências menores, apesar de direitos autorais serem centrais em debates públicos.

A fragmentação metodológica é evidente: experimentos controlados (36,7%), surveys (25%), estudos de caso (18,3%) e entrevistas (15%) são aplicados sem protocolos padronizados. Análises qualitativas por especialistas (25%) fornecem insights valiosos, mas enfrentam limitações de escala e custo. Poucos estudos integram IAG em workflows reais de produção.

5.5 REFLEXÕES FINAIS E PERSPECTIVAS FUTURAS

A IAG democratiza ferramentas, acelera processos e expande possibilidades estéticas, permitindo criação de conteúdos impraticáveis por métodos tradicionais. Os 60 artigos analisados revelam experimentação tecnológica intensa, com Modelos de Difusão e Transformers dominando, e a combinação de ferramentas tornando-se padrão.

No entanto, desafios críticos persistem. A coerência temporal limita vídeos longos. A concentração tecnológica cria dependência e vulnerabilidades. O impacto sobre profissionais gera receios legítimos. Questões de autoria permanecem sem resposta. A transparência é ambígua. Vieses são perpetuados. A regulamentação é inexistente.

O paradoxo criativo é evidente: ferramentas que prometem inovação tendem a reforçar padrões do passado. A automação que promete eficiência ameaça trabalhadores criativos. A democratização que promete acesso cria novas barreiras econômicas e técnicas.

A questão central não é *se* a IAG transformará o audiovisual, pois já está transformando. A questão é *como*: se será democrática ou concentradora, se valorizará criatividade humana ou a substituirá, se servirá à diversidade ou à homogeneização.

Este mapeamento trouxe evidências sobre um campo em rápida transformação, identificando aplicações emergentes, desafios técnicos persistentes e dilemas éticos não resolvidos. Os frameworks metodológicos, éticos e regulatórios permanecem atrasados em relação à inovação técnica.

As respostas sobre o futuro serão construídas por decisões humanas de pesquisadores, profissionais, empresas, reguladores e sociedade. Este estudo buscou apoiar decisões mais informadas e responsáveis, oferecendo um panorama estruturado de um fenômeno complexo e multifacetado.

O futuro será híbrido, combinando criatividade humana e capacidades computacionais. A tarefa coletiva é garantir que essa combinação amplifique o melhor de ambos e mitigue riscos. A IAG não é neutra: reflete valores e escolhas de quem a desenvolve e utiliza.

Nesse contexto, este estudo também abre espaço para desdobramentos futuros. Ampliar o conjunto de bases consultadas e considerar um recorte temporal mais longo permitiria observar como essas transformações evoluem de forma mais ampla e gradual. Da mesma forma, análises empíricas realizadas em cenários de produção reais poderiam complementar a predominância de experimentos controlados identificada neste mapeamento, oferecendo uma visão mais próxima das práticas profissionais. Outra frente promissora envolve o desenvolvimento de métricas mais sensíveis a aspectos narrativos e estéticos, já que as abordagens atuais ainda não capturam plenamente essas dimensões do audiovisual. Esses caminhos podem fortalecer a continuidade desta investigação e apoiar estudos que busquem compreender, com maior precisão, o papel da IAG no setor audiovisual.

REFERÊNCIAS

- Altman, D. G. (1991). Practical statistics for medical research. *Chapman and Hall/CRC*.
- Basili, V. R. e Rombach, H. D. (1988). The tame project: Towards improvement-oriented software environments. *IEEE Transactions on Software Engineering*, 14(6):758–773.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A. et al. (2020). Language models are few-shot learners. *arXiv preprint arXiv:2005.14165*.
- Capraro, V., Lentsch, A., Acemoglu, D., Akgun, S., Akhmedova, A., Bilancini, E., Bonnefon, J.-F., Brañas-Garza, P., Butera, L., Douglas, K. M. et al. (2024). The impact of generative artificial intelligence on socioeconomic inequalities and policy making. *PNAS Nexus*, 3:pgae191.
- Cenerini, C., Vollero, L., Stefano, N. D., Santonico, M., Pennazza, G. e Keller, F. (2025). Assessment of the role of emotions in audiovisual associations through an enactive approach. *PLOS ONE*, 20(5):e0322449.
- Damasceno, E. (2023). Avaliando um si colaborativo para apoiar revisões e mapeamentos sistemáticos da literatura. *iSys: Revista Brasileira de Sistemas de Informação*, 16(2):33–52.
- Dhariwal, P. e Nichol, A. (2021). Diffusion models beat gans on image synthesis. *arXiv preprint arXiv:2105.05233*.
- Floridi, L. e Chiriatti, M. (2020). Gpt-3: Its nature, scope, limits, and consequences. *Minds and Machines*, 30(4):681–694.
- Gambacorta, L., Jappelli, T. e Oliviero, T. (2025). Exploring household adoption and usage of generative ai: New evidence from italy. BIS Working Paper 1298, Bank for International Settlements.
- Gavran, I., Honcharuk, S., Mykhalov, V., Stepanenko, K. e Tsimokh, N. (2025). The impact of artificial intelligence on the production and editing of audiovisual content. *PDT&C*, 54(3):223–235.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. e Bengio, Y. (2014). Generative adversarial nets. Em *Advances in Neural Information Processing Systems*, volume 27, páginas 2672–2680.
- Grand View Research (2023). Generative ai market size and share | industry report, 2030. Industry Report, Grand View Research. Accessed November 2025.
- Karras, T., Laine, S., Aittala, M., Hellsten, J., Lehtinen, J. e Aila, T. (2020). Analyzing and improving the image quality of stylegan. *arXiv preprint arXiv:1912.04958*.
- Kitchenham, B. e Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. Relatório Técnico TR/SE-0401, Keele University and Empirical Software Engineering, National ICT Australia Ltd., Keele, UK and Sydney, Australia. Joint Technical Report.

- Landis, J. R. e Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1):159–174.
- Lazarte, E. G. F., Juárez Paccotaípe, M. T., Ramírez Heredia, R. C. e Vela Loyola, T. M. (2025). Audiovisual narrative in the age of artificial intelligence: Advances, trends and challenges: A systematic review. *Journal of Educational and Social Research*, 5(1):–.
- Orak, C. e Turan, Z. (2024). Using artificial intelligence in digital video production: A systematic review study. *Journal of Educational Technology & Online Learning*, 7(3):286–307.
- Petersen, K., Feldt, R., Mujtaba, S. e Mattsson, M. (2008). Systematic mapping studies in software engineering. Em *12th International Conference on Evaluation and Assessment in Software Engineering (EASE)*, páginas 68–77.
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P. e Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. Em *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Russell, S. J. e Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Pearson Education, Upper Saddle River, NJ, 3rd edition.
- Tiwari, A., Dave, R. e Vanamala, M. (2023). Leveraging deep learning approaches for deepfake detection: A review. *arXiv preprint*.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. e Polosukhin, I. (2017). Attention is all you need. Em *Advances in Neural Information Processing Systems*.
- Voinea, D. V. (2025). The algorithmic auteur: Ai, cultural production, and the reconfiguration of audiovisual media. *Social Sciences and Education Research Review*, 12(1):256–268.
- Wieringa, R. J., Maiden, N. A. M., Mead, N. e Rolland, C. (2006). Designing requirements engineering methods: The requirements engineering methodology (rem) framework. Em *Proceedings of the 14th International Conference on Requirements Engineering (RE'06)*, páginas 280–295. Springer.

APÊNDICE A – DOI'S DOS ARTIGOS

Este apêndice apresenta a lista completa de DOIs (Digital Object Identifiers) dos 659 artigos científicos utilizados como base para a revisão sistemática da literatura apresentada neste trabalho.

Observação: Os seguintes artigos foram excluídos desta lista:

- IDs 61 e 67 da base ACM (Porifera): DOIs não disponíveis no momento da escrita deste TCC.
- IDs 72, 74, 107 e 120 da base ACM (Porifera): DOIs do tipo 10.5555/* que não são acessíveis publicamente.
- ID 388 da base IEEE Xplore: DOI não informado no arquivo original (doi={}).

ID 001: https://doi.org/10.1145/3639701.3656325	ID 002: https://doi.org/10.1145/3672758.3672763	ID 003: https://doi.org/10.1145/3641235.3664438
ID 004: https://doi.org/10.1145/3706598.3714253	ID 005: https://doi.org/10.1145/3643834.3660685	ID 006: https://doi.org/10.1145/3605390.3605398
ID 007: https://doi.org/10.1145/3641235.3664452	ID 008: https://doi.org/10.1145/3615522.3615556	ID 009: https://doi.org/10.1145/3689236.3689257
ID 010: https://doi.org/10.1145/3716135	ID 011: https://doi.org/10.1145/3661167.3661192	ID 012: https://doi.org/10.1145/3678717.3695760
ID 013: https://doi.org/10.1145/3632621.3671422	ID 014: https://doi.org/10.1145/3664647.3681516	ID 015: https://doi.org/10.1145/3700794.3700810
ID 016: https://doi.org/10.1145/3696230.3696231	ID 017: https://doi.org/10.1145/3626772.3661350	ID 018: https://doi.org/10.1145/3349341.3349478
ID 019: https://doi.org/10.1145/3550453.3570125	ID 020: https://doi.org/10.1145/3686397.3686400	ID 021: https://doi.org/10.1145/3604321.3604329
ID 022: https://doi.org/10.1145/3433996.3434018	ID 023: https://doi.org/10.1145/3690624.3709401	ID 024: https://doi.org/10.1145/3615522.3615554
ID 025: https://doi.org/10.1145/3589335.3648315	ID 026: https://doi.org/10.1145/3588764	ID 027: https://doi.org/10.1145/3664476.3664510
ID 028: https://doi.org/10.1145/3678719.3685691	ID 029: https://doi.org/10.1145/3450615.3464538	ID 030: https://doi.org/10.1145/3510450.3517319
ID 031: https://doi.org/10.1145/3674829.3675081	ID 032: https://doi.org/10.1145/3607720.3608451	ID 033: https://doi.org/10.1145/3503181.3503190
ID 034: https://doi.org/10.1145/3423958.3423975	ID 035: https://doi.org/10.1145/3519306	ID 036: https://doi.org/10.1145/3386567.3388559
ID 037: https://doi.org/10.1145/3524501.3527599	ID 038: https://doi.org/10.1145/3555757	ID 039: https://doi.org/10.1145/3503161.3546970
ID 040: https://doi.org/10.1145/3680528.3687688	ID 041: https://doi.org/10.1145/3706598.3713201	ID 042: https://doi.org/10.1145/3464385.3464763
ID 043: https://doi.org/10.1145/3501709.3544275	ID 044: https://doi.org/10.1145/3706598.3714148	ID 045: https://doi.org/10.1145/3605764.3623903
ID 046: https://doi.org/10.1145/3388761.3407250	ID 047: https://doi.org/10.1145/3706598.3714155	ID 048: https://doi.org/10.1145/3706598.3713342
ID 049: https://doi.org/10.1145/3493700.3493769	ID 050: https://doi.org/10.1145/3632173	ID 051: https://doi.org/10.1145/3531146.3533080
ID 052: https://doi.org/10.1145/3706598.3713840	ID 053: https://doi.org/10.1145/3437802.3437809	ID 054: https://doi.org/10.1145/3534678.3542617
ID 055: https://doi.org/10.1145/3706599.3720264	ID 056: https://doi.org/10.5555/3716662.3716713	ID 057: https://doi.org/10.1145/3630106.3658995
ID 058: https://doi.org/10.1145/3597512.3597528	ID 059: https://doi.org/10.1145/3641520.3665309	ID 060: https://doi.org/10.1145/3314111.3322874
ID 062: https://doi.org/10.1145/3678698.3687197	ID 063: https://doi.org/10.1145/3630590.3630601	ID 064: https://doi.org/10.1145/3680532.3689579
ID 065: https://doi.org/10.1145/3680530.3695443	ID 066: https://doi.org/10.1145/3477322.3477323	ID 068: https://doi.org/10.1145/3589335.3641295
ID 069: https://doi.org/10.1145/3633287	ID 070: https://doi.org/10.1145/3706598.3714119	ID 071: https://doi.org/10.1145/3581783.3613432
ID 073: https://doi.org/10.1145/3614419.3644000	ID 075: https://doi.org/10.1145/3656650.3656688	ID 076: https://doi.org/10.1145/3446368.3452126
ID 077: https://doi.org/10.1145/3641520.3665311	ID 078: https://doi.org/10.1145/3423603.3424052	ID 079: https://doi.org/10.1145/3681757.3697052
ID 080: https://doi.org/10.1145/3677846.3677855	ID 081: https://doi.org/10.1145/3613905.3651049	ID 082: https://doi.org/10.1145/3613905.3651123
ID 083: https://doi.org/10.1145/3681758.3698021	ID 084: https://doi.org/10.1145/3626253.3633418	ID 085: https://doi.org/10.1145/3478432.3499157
ID 086: https://doi.org/10.1145/3681756.3697919	ID 087: https://doi.org/10.1145/3706599.3720140	ID 088: https://doi.org/10.1145/3539597.3575791

ID 089: <https://doi.org/10.1145/3674912.3674922>
 ID 092: <https://doi.org/10.1145/3422839.3423059>
 ID 095: <https://doi.org/10.1145/3716848>
 ID 098: <https://doi.org/10.1145/3351270>
 ID 101: <https://doi.org/10.1145/3613904.3642040>
 ID 104: <https://doi.org/10.1145/3512749.3520237>
 ID 108: <https://doi.org/10.1145/3706598.3714242>
 ID 111: <https://doi.org/10.1145/3507657.3528541>
 ID 114: <https://doi.org/10.1145/3549486>
 ID 117: <https://doi.org/10.1145/3625468.3652176>
 ID 121: <https://doi.org/10.1145/3613904.3642125>
 ID 124: <https://doi.org/10.14236/ewic/BCSHCI2024.1>
 ID 127: <https://doi.org/10.1145/3505284.3532976>
 ID 130: <https://doi.org/10.1145/3394486>
 ID 133: <https://doi.org/10.1145/3531146.3533218>
 ID 136: <https://doi.org/10.1145/3589334.3645511>
 ID 139: <https://doi.org/10.1145/3366423.3382668>
 ID 142: <https://doi.org/10.1145/3461702.3462580>
 ID 145: <https://doi.org/10.1145/3649165.3703622>
 ID 148: <https://doi.org/10.1145/3411109.3411138>
 ID 151: <https://doi.org/10.1145/3555776.3577831>
 ID 154: <https://doi.org/10.1145/3649921.3659853>
 ID 157: <https://doi.org/10.1145/3706599.3719775>
 ID 160: <https://doi.org/10.1145/3526113.3545613>
 ID 163: <https://doi.org/10.1145/3313831.3376701>
 ID 166: <https://doi.org/10.1145/3498361.3538784>
 ID 169: <https://doi.org/10.1109/SWC62898.2024.00047>
 ID 172: <https://doi.org/10.1109/PEEE63877.2024.00209>
 ID 175: <https://doi.org/10.1109/ICCECE58645.2024.10497385>
 ID 178: <https://doi.org/10.1109/DEMOcon63027.2024.10747930>
 ID 181: <https://doi.org/10.1109/CSITSS60515.2023.10334104>
 ID 184: <https://doi.org/10.1109/ACCESS.2024.3389985>
 ID 187: <https://doi.org/10.1109/IDICAIEI58380.2023.10406977>
 ID 190: <https://doi.org/10.1109/ICAIS56108.2023.10073884>
 ID 193: <https://doi.org/10.1109/ISIEA61920.2024.10607369>
 ID 196: <https://doi.org/10.1109/ACAIT56212.2022.10137839>
 ID 199: <https://doi.org/10.1109/MIPR62202.2024.00104>
 ID 202: <https://doi.org/10.1109/QoMEX51781.2021.9465478>
 ID 205: <https://doi.org/10.1109/SCEEC64059.2025.10940613>
 ID 208: <https://doi.org/10.1109/ITAC54216.2022.9836461>
 ID 211: <https://doi.org/10.1109/ICTCS.2019.8923095>
 ID 214: <https://doi.org/10.1109/ICAIBD49809.2020.9137462>
 ID 217: <https://doi.org/10.1109/ICEARS64219.2025.10940062>
 ID 090: <https://doi.org/10.1145/3630106.3659009>
 ID 093: <https://doi.org/10.1145/3725885>
 ID 096: <https://doi.org/10.1145/3702163.3702165>
 ID 099: <https://doi.org/10.1145/3539618.3591876>
 ID 102: <https://doi.org/10.1145/3615522.3615553>
 ID 105: <https://doi.org/10.1145/3544548.3581498>
 ID 109: <https://doi.org/10.1145/3613904.3642868>
 ID 112: <https://doi.org/10.1145/3706599.3721349>
 ID 115: <https://doi.org/10.1145/3347122.3347127>
 ID 118: <https://doi.org/10.1145/3651671.3651711>
 ID 122: <https://doi.org/10.1109/ASE56229.2023.00023>
 ID 125: <https://doi.org/10.1145/3510450.3517308>
 ID 128: <https://doi.org/10.1145/3332167.3356878>
 ID 131: <https://doi.org/10.1145/3680529.3688961>
 ID 134: <https://doi.org/10.1145/3637528>
 ID 137: <https://doi.org/10.1145/3329715.3338883>
 ID 140: <https://doi.org/10.1145/3637528.3671476>
 ID 143: <https://doi.org/10.1145/3450507.3457439>
 ID 146: <https://doi.org/10.1145/3476123.3487879>
 ID 149: <https://doi.org/10.1145/3680471>
 ID 152: <https://doi.org/10.1145/3657604.3664719>
 ID 155: <https://doi.org/10.1145/3637528.3671526>
 ID 158: <https://doi.org/10.1145/3383313.3418436>
 ID 161: <https://doi.org/10.1145/3701551>
 ID 164: <https://doi.org/10.1145/3379336.3381478>
 ID 167: <https://doi.org/10.1145/3441852.3471211>
 ID 170: <https://doi.org/10.1109/TrustCom60117.2023.00366>
 ID 173: <https://doi.org/10.1109/ECTIDAMTNC64748.2025.10962008>
 ID 176: <https://doi.org/10.1109/IDICAIEI58380.2023.10406710>
 ID 179: <https://doi.org/10.1109/InCIT63192.2024.10810565>
 ID 182: <https://doi.org/10.1109/ISCT62336.2024.10791276>
 ID 185: <https://doi.org/10.1109/AiDAS63860.2024.10730166>
 ID 188: <https://doi.org/10.1109/BigData62323.2024.10826083>
 ID 191: <https://doi.org/10.1109/IC2IE63342.2024.10747969>
 ID 194: <https://doi.org/10.1109/ICIETDW61607.2024.10939117>
 ID 197: <https://doi.org/10.1109/CCWC62904.2025.10903780>
 ID 200: <https://doi.org/10.1109/AIoTcs58181.2022.00091>
 ID 203: <https://doi.org/10.1109/ICMEW63481.2024.10645467>
 ID 206: <https://doi.org/10.1109/AIxVR59861.2024.00067>
 ID 209: <https://doi.org/10.1109/ICAECT63952.2025.10958949>
 ID 212: <https://doi.org/10.1109/ICSES63445.2024.10763187>
 ID 215: <https://doi.org/10.1109/VRW52623.2021.00088>
 ID 218: <https://doi.org/10.1109/AIHCI61661.2023.00028>
 ID 091: <https://doi.org/10.1145/3627043.3659574>
 ID 094: <https://doi.org/10.1145/3681757.3697054>
 ID 097: <https://doi.org/10.1145/3618333>
 ID 100: <https://doi.org/10.1145/3700297.3700367>
 ID 103: <https://doi.org/10.1145/3708359.3712152>
 ID 106: <https://doi.org/10.1145/3658852.3661317>
 ID 110: <https://doi.org/10.1145/3665463.3680556>
 ID 113: <https://doi.org/10.1145/3688868.3689206>
 ID 116: <https://doi.org/10.1145/3635705>
 ID 119: <https://doi.org/10.1145/3719330.3721230>
 ID 123: <https://doi.org/10.1145/3322905.3322928>
 ID 126: <https://doi.org/10.1145/3593013.3594133>
 ID 129: <https://doi.org/10.1145/3591196.3593361>
 ID 132: <https://doi.org/10.1145/3366423.3382669>
 ID 135: <https://doi.org/10.1145/3537972.3538009>
 ID 138: <https://doi.org/10.1145/3404835.3462905>
 ID 141: <https://doi.org/10.1145/3610537.3622963>
 ID 144: <https://doi.org/10.1145/3442381.3449848>
 ID 147: <https://doi.org/10.1145/3596947.3596959>
 ID 150: <https://doi.org/10.1145/3580305.3599582>
 ID 153: <https://doi.org/10.1145/3642921.3642930>
 ID 156: <https://doi.org/10.1145/3613904.3642738>
 ID 159: <https://doi.org/10.1145/3550340.3564227>
 ID 162: <https://doi.org/10.1145/3303706>
 ID 165: <https://doi.org/10.1145/3664647.3681697>
 ID 168: <https://doi.org/10.1109/ICIIP61524.2023.10537692>
 ID 171: <https://doi.org/10.1109/TEECCON59234.2023.10335867>
 ID 174: <https://doi.org/10.1109/ICMEW59549.2023.00066>
 ID 177: <https://doi.org/10.1109/IC2PCT60090.2024.10486754>
 ID 180: <https://doi.org/10.1109/DIA62678.2024.10871631>
 ID 183: <https://doi.org/10.1109/ICIMTech59029.2023.10278051>
 ID 186: <https://doi.org/10.1109/IDICAIEI61867.2024.10842860>
 ID 189: <https://doi.org/10.1109/QRS-C51114.2020.00111>
 ID 192: <https://doi.org/10.1109/IITCEE64140.2025.10915297>
 ID 195: <https://doi.org/10.1109/ISIEA61920.2024.10607282>
 ID 198: <https://doi.org/10.1109/ICACCtech65084.2024.00014>
 ID 201: <https://doi.org/10.1109/PerComWorkshops48775.2020.9156127>
 ID 204: <https://doi.org/10.1109/AICECS63354.2024.10957230>
 ID 207: <https://doi.org/10.1109/ITAC54216.2022.9836842>
 ID 210: <https://doi.org/10.1109/TBC.2024.3391060>
 ID 213: <https://doi.org/10.1109/ICAST55766.2022.10039585>
 ID 216: <https://doi.org/10.1109/ICAICST53116.2021.9497834>
 ID 219: <https://doi.org/10.1109/SoutheastCon56624.2025.10971689>

ID 220: <https://doi.org/10.1109/TNSM.2023.3282740>
 ID 223: <https://doi.org/10.1109/AICECS63354.2024.10956588>
 ID 226: <https://doi.org/10.1109/ICIP40778.2020.9190871>
 ID 229: <https://doi.org/10.1109/ICAIQSA64000.2024.10882293>
 ID 232: <https://doi.org/10.1109/ICGI64003.2024.10923796>
 ID 235: <https://doi.org/10.1109/ASU50717.2020.9259872>
 ID 238: <https://doi.org/10.1109/ESW42757.2020.9188324>
 ID 241: <https://doi.org/10.1109/TCBB.2024.3380410>
 ID 244: <https://doi.org/10.1109/CVPR52729.2023.01229>
 ID 247: <https://doi.org/10.1109/ICSS58085.2023.10407412>
 ID 250: <https://doi.org/10.1109/ICICDT51558.2021.9626472>
 ID 253: <https://doi.org/10.1109/ICAIQSA64000.2024.10882441>
 ID 256: <https://doi.org/10.1109/IWECAI55315.2022.00036>
 ID 259: <https://doi.org/10.1109/FMLDS63805.2024.00085>
 ID 262: <https://doi.org/10.1109/ACCESS.2025.3547343>
 ID 265: <https://doi.org/10.1109/ACCESS.2019.2891070>
 ID 268: <https://doi.org/10.1109/VCIP63160.2024.10849934>
 ID 271: <https://doi.org/10.1109/IDAP.2019.8875976>
 ID 274: <https://doi.org/10.1109/EDTM50988.2021.9421020>
 ID 277: <https://doi.org/10.1109/NIGERCON62786.2024.10927354>
 ID 280: <https://doi.org/10.1109/I-SMAC47947.2019.9032527>
 ID 283: <https://doi.org/10.1109/ICSCAI61790.2024.10866539>
 ID 286: <https://doi.org/10.23919/SoftCOM62040.2024.10722016>
 ID 289: <https://doi.org/10.1109/ASE56229.2023.00023>
 ID 292: <https://doi.org/10.1109/ICIPTM59628.2024.10563353>
 ID 295: <https://doi.org/10.1109/ITAIC54216.2022.9836737>
 ID 298: <https://doi.org/10.1109/AIARS57204.2022.00104>
 ID 301: <https://doi.org/10.1109/CVPR52729.2023.00836>
 ID 304: <https://doi.org/10.1109/TransAI46475.2019.00011>
 ID 307: <https://doi.org/10.1109/ACCESS.2020.3008523>
 ID 310: <https://doi.org/10.1109/ICSCAI61790.2024.10866940>
 ID 313: <https://doi.org/10.1109/IFEEA64237.2024.10878667>
 ID 316: <https://doi.org/10.1109/ICAIE56796.2023.00033>
 ID 319: <https://doi.org/10.1109/TITS.2022.3223167>
 ID 322: <https://doi.org/10.1109/VR.2019.8798208>
 ID 325: <https://doi.org/10.1109/EECS163442.2024.10776138>
 ID 328: <https://doi.org/10.1109/CVPR46437.2021.00652>
 ID 331: <https://doi.org/10.1109/ICSS57650.2023.10169246>
 ID 334: <https://doi.org/10.1109/NOMS59830.2024.10574926>
 ID 337: <https://doi.org/10.1109/SoutheastCon51012.2023.10115207>
 ID 340: <https://doi.org/10.1109/ICWS62655.2024.00158>
 ID 343: <https://doi.org/10.1109/ISES63344.2024.00016>
 ID 346: <https://doi.org/10.1109/IDCIoT59759.2024.10467601>
 ID 221: <https://doi.org/10.1109/ICTBIG64922.2024.10911659>
 ID 224: <https://doi.org/10.1109/ICSSAS64001.2024.10760469>
 ID 227: <https://doi.org/10.1109/ICAIS53314.2022.9743070>
 ID 230: <https://doi.org/10.1109/ICCSAI59793.2023.10421049>
 ID 233: <https://doi.org/10.1109/MIPR62202.2024.00018>
 ID 236: <https://doi.org/10.1109/ICIT63607.2024.10859907>
 ID 239: <https://doi.org/10.1109/QRS-C63300.2024.00167>
 ID 242: <https://doi.org/10.1109/ICCCNT61001.2024.10725543>
 ID 245: <https://doi.org/10.1109/ICMLAS64557.2025.10968185>
 ID 248: <https://doi.org/10.1109/ICBDS61829.2024.10837427>
 ID 251: <https://doi.org/10.1109/ICIBA62489.2024.10869186>
 ID 254: <https://doi.org/10.1109/IC2SDT62152.2024.10696037>
 ID 257: <https://doi.org/10.1109/ICSSAS57918.2023.10331908>
 ID 260: <https://doi.org/10.1109/TVCG.2021.3115902>
 ID 263: <https://doi.org/10.1109/ICMEW59549.2023.00071>
 ID 266: <https://doi.org/10.1109/CVPR52733.2024.01033>
 ID 269: <https://doi.org/10.23919/SpliTech61897.2024.10612339>
 ID 272: <https://doi.org/10.1109/TAAI48200.2019.8959886>
 ID 275: <https://doi.org/10.1109/IWBSI50925.2020.9255497>
 ID 278: <https://doi.org/10.1109/TMC.2024.3493375>
 ID 281: <https://doi.org/10.1109/IICAIET55139.2022.9936738>
 ID 284: <https://doi.org/10.1109/ICID60307.2023.10396815>
 ID 287: <https://doi.org/10.1109/ICITISEE63424.2024.10730211>
 ID 290: <https://doi.org/10.1109/DeSE63988.2024.10911974>
 ID 293: <https://doi.org/10.1109/ISPCME60569.2023.00134>
 ID 296: <https://doi.org/10.1109/IMSA61967.2024.10652687>
 ID 299: <https://doi.org/10.1109/ICoABCD63526.2024.10704300>
 ID 302: <https://doi.org/10.1109/ACCESS.2023.3328331>
 ID 305: <https://doi.org/10.1109/TVCG.2023.3327197>
 ID 308: <https://doi.org/10.1109/ITSC58415.2024.10920245>
 ID 311: <https://doi.org/10.1109/IWCMC61514.2024.10592379>
 ID 314: <https://doi.org/10.1109/ICUIS64676.2024.10867088>
 ID 317: <https://doi.org/10.1109/ICCCNT61001.2024.10724260>
 ID 320: <https://doi.org/10.1109/TITS.2023.3241148>
 ID 323: <https://doi.org/10.1109/TCSVT.2024.3375330>
 ID 326: <https://doi.org/10.1109/ETCM63562.2024.10746166>
 ID 329: <https://doi.org/10.1109/ACCESS.2020.3020560>
 ID 332: <https://doi.org/10.1109/TPAMI.2019.2952590>
 ID 335: <https://doi.org/10.1109/ACCESS.2019.2963535>
 ID 338: <https://doi.org/10.1109/ACCESS.2024.3390217>
 ID 341: <https://doi.org/10.1109/ICASE64542.2024.10850962>
 ID 344: <https://doi.org/10.1109/TPAMI.2019.2938499>
 ID 347: <https://doi.org/10.1109/ICCVIT63928.2024.10872441>
 ID 222: <https://doi.org/10.1109/ICACITES7410.2023.10182456>
 ID 225: <https://doi.org/10.1109/ICIS51600.2021.9516870>
 ID 228: <https://doi.org/10.1109/ACCESS.2024.3437254>
 ID 231: <https://doi.org/10.1109/ICIICS59993.2023.10421514>
 ID 234: <https://doi.org/10.1109/ICCE63647.2025.10929907>
 ID 237: <https://doi.org/10.1109/AIIoT61789.2024.10579034>
 ID 240: <https://doi.org/10.1109/QMTISIT63393.2024.10762856>
 ID 243: <https://doi.org/10.1109/IEEECONF64992.2025.10962821>
 ID 246: <https://doi.org/10.1109/CSEET62301.2024.10663046>
 ID 249: <https://doi.org/10.1109/ICECONF57129.2023.10083961>
 ID 252: <https://doi.org/10.1109/TEMSMET56707.2023.10149964>
 ID 255: <https://doi.org/10.1109/IICETA57613.2023.10351216>
 ID 258: <https://doi.org/10.1109/CogSIMA61085.2024.10553755>
 ID 261: <https://doi.org/10.1109/ICAEECI58247.2023.10370952>
 ID 264: <https://doi.org/10.1109/ICECC61767.2024.10593995>
 ID 267: <https://doi.org/10.1109/AICCSA63423.2024.10912536>
 ID 270: <https://doi.org/10.1109/ACCESS.2024.3406494>
 ID 273: <https://doi.org/10.1109/ICACITE60783.2024.10616499>
 ID 276: <https://doi.org/10.1109/GlobalAISummit62156.2024.10947926>
 ID 279: <https://doi.org/10.1109/OTCON60325.2024.10687926>
 ID 282: <https://doi.org/10.1109/ICDCAI59742.2023.00015>
 ID 285: <https://doi.org/10.1109/CITISIA50690.2020.9371846>
 ID 288: <https://doi.org/10.1109/AIxSET62544.2024.00032>
 ID 291: <https://doi.org/10.1109/COMPAS60761.2024.10795949>
 ID 294: <https://doi.org/10.1109/IC2PCT60090.2024.10486537>
 ID 297: <https://doi.org/10.1109/ACCESS.2023.3332119>
 ID 300: <https://doi.org/10.1109/CISCE.2019.00142>
 ID 303: <https://doi.org/10.1109/AIVR56993.2022.00039>
 ID 306: <https://doi.org/10.1109/RO-MAN60168.2024.10731272>
 ID 309: <https://doi.org/10.1109/ITHET61869.2024.10837618>
 ID 312: <https://doi.org/10.1109/ACCESS.2024.3389673>
 ID 315: <https://doi.org/10.1109/ICCV51070.2023.01381>
 ID 318: <https://doi.org/10.1109/IMETA62882.2024.10808057>
 ID 321: <https://doi.org/10.1109/ICCC59590.2023.10507445>
 ID 324: <https://doi.org/10.1109/IDSTA62194.2024.10746990>
 ID 327: <https://doi.org/10.1109/ACCESS.2024.3374056>
 ID 330: <https://doi.org/10.1109/MASS50613.2020.00088>
 ID 333: <https://doi.org/10.1109/ACCESS.2024.3489395>
 ID 336: <https://doi.org/10.1109/OTCON60325.2024.10687965>
 ID 339: <https://doi.org/10.1109/ICASSP49660.2025.10887999>
 ID 342: <https://doi.org/10.1109/ICAIIT.2019.8834478>
 ID 345: <https://doi.org/10.1109/IRPS48203.2023.10118099>
 ID 348: <https://doi.org/10.1109/AIBThings58340.2023.10291023>

ID 349: <https://doi.org/10.1109/ACCESS.2025.3557533>
 ID 352: <https://doi.org/10.1109/ACCESS.2019.2903148>
 ID 355: <https://doi.org/10.1109/ACIT50332.2020.9300095>
 ID 358: <https://doi.org/10.1109/ECAI46879.2019.9042158>
 ID 361: <https://doi.org/10.1109/ICECER62944.2024.10920375>
 ID 364: <https://doi.org/10.26599/BDMA.2024.9020046>
 ID 367: <https://doi.org/10.1109/CSNT64827.2025.10968614>
 ID 370: <https://doi.org/10.1109/TMAG.2020.2996955>
 ID 373: <https://doi.org/10.1109/MASSW.2019.00033>
 ID 376: <https://doi.org/10.1109/I2CT61223.2024.10544050>
 ID 379: <https://doi.org/10.1109/AIMS52415.2021.9466022>
 ID 382: <https://doi.org/10.1109/NCA61908.2024.00047>
 ID 385: <https://doi.org/10.1109/FUZZ-IEEE55066.2022.9882881>
 ID 389: <https://doi.org/10.1109/ICTBIG64922.2024.10911297>
 ID 392: <https://doi.org/10.1109/ICASSP48485.2024.10446049>
 ID 395: <https://doi.org/10.1109/SNPD.2019.8935856>
 ID 398: <https://doi.org/10.1109/ICME55011.2023.00049>
 ID 401: <https://doi.org/10.1109/ACCESS.2024.3512796>
 ID 404: <https://doi.org/10.1109/ICWT55831.2022.9935364>
 ID 407: <https://doi.org/10.1109/ICACITE57410.2023.10182597>
 ID 410: <https://doi.org/10.13052/jcsm2245-1439.1316>
 ID 413: <https://doi.org/10.1109/GCAT52182.2021.9587584>
 ID 416: <https://doi.org/10.1109/ACCESS.2024.3424304>
 ID 419: <https://doi.org/10.1109/ACCESS.2021.3080680>
 ID 422: <https://doi.org/10.1109/ICESC60852.2024.10690124>
 ID 425: <https://doi.org/10.1109/VRW66409.2025.00148>
 ID 428: <https://doi.org/10.1109/ISAS60782.2023.10391508>
 ID 431: <https://doi.org/10.1109/ACCESS.2021.3084949>
 ID 434: <https://doi.org/10.1109/ICCE63647.2025.10930025>
 ID 437: <https://doi.org/10.1109/SPW50608.2020.00048>
 ID 440: <https://doi.org/10.1109/NSSENS62142.2024.10561275>
 ID 443: <https://doi.org/10.1109/TPS.2019.2925568>
 ID 446: <https://doi.org/10.1109/ACCESS.2025.3555871>
 ID 449: <https://doi.org/10.1109/TITS.2022.3200250>
 ID 452: <https://doi.org/10.1109/ICASSP49660.2025.10887687>
 ID 455: <https://doi.org/10.1109/CVPR52733.2024.00336>
 ID 458: <https://doi.org/10.1109/TNNLS.2024.3351120>
 ID 461: <https://doi.org/10.1109/ICSSAS64001.2024.10760618>
 ID 464: <https://doi.org/10.1109/DCOSS-IoT61029.2024.00091>
 ID 468: <https://doi.org/10.1109/CVPR52733.2024.00832>
 ID 471: <https://doi.org/10.1109/ICSCAI61790.2024.10866538>
 ID 474: <https://doi.org/10.1109/CE2CT64011.2025.10939891>
 ID 477: <https://doi.org/10.1109/WiMob58348.2023.10187731>
 ID 350: <https://doi.org/10.1109/SESAI61023.2024.10599456>
 ID 353: <https://doi.org/10.1109/ETNCC59188.2023.10284976>
 ID 356: <https://doi.org/10.1109/LRA.2021.3061994>
 ID 359: <https://doi.org/10.1109/AIIM64537.2024.10934487>
 ID 362: <https://doi.org/10.1109/MOST57249.2023.00034>
 ID 365: <https://doi.org/10.1109/CVPR46437.2021.00366>
 ID 368: <https://doi.org/10.1109/AIXVR59861.2024.00038>
 ID 371: <https://doi.org/10.1109/ICCCI56745.2023.10128248>
 ID 374: <https://doi.org/10.1109/ACCESS.2019.2920175>
 ID 377: <https://doi.org/10.1109/ICMEW63481.2024.10645358>
 ID 380: <https://doi.org/10.1109/CVPR42600.2020.01353>
 ID 383: <https://doi.org/10.1109/BigComp51126.2021.00069>
 ID 386: <https://doi.org/10.1109/TMM.2022.3221894>
 ID 390: <https://doi.org/10.1109/CoG52621.2021.9619094>
 ID 393: <https://doi.org/10.1109/ACCESS.2022.3172492>
 ID 396: <https://doi.org/10.1109/IMPACT59481.2023.10348907>
 ID 399: <https://doi.org/10.1109/ICAIS50930.2021.9395990>
 ID 402: <https://doi.org/10.1109/FLEPS53764.2022.9781486>
 ID 405: <https://doi.org/10.1109/ICEESE62315.2024.10828545>
 ID 408: <https://doi.org/10.1109/ICT60153.2023.10374064>
 ID 411: <https://doi.org/10.1109/CVPRW63382.2024.00150>
 ID 414: <https://doi.org/10.1109/TED.2024.3454033>
 ID 417: <https://doi.org/10.1109/DESSERT58054.2022.10018734>
 ID 420: <https://doi.org/10.23919/JCC.2023.02.017>
 ID 423: <https://doi.org/10.1109/AIVR56993.2022.00016>
 ID 426: <https://doi.org/10.1109/MCG.2023.3303028>
 ID 429: <https://doi.org/10.1109/ICASSP49660.2025.10889186>
 ID 432: <https://doi.org/10.1109/ACCESS.2021.3137341>
 ID 435: <https://doi.org/10.1109/ICAIGE62696.2024.10776736>
 ID 438: <https://doi.org/10.1109/ICECET61485.2024.10698327>
 ID 441: <https://doi.org/10.1109/PDP50117.2020.00043>
 ID 444: <https://doi.org/10.1109/ICCE-Taiwan62264.2024.10674478>
 ID 447: <https://doi.org/10.1109/JIOT.2018.2872122>
 ID 450: <https://doi.org/10.1109/ISMAC61858.2024.10714771>
 ID 453: <https://doi.org/10.1109/TIMES-ICON61890.2024.10630767>
 ID 456: <https://doi.org/10.1109/JPROC.2019.2947490>
 ID 459: <https://doi.org/10.1109/ICACITE53722.2022.9823902>
 ID 462: <https://doi.org/10.1109/QRS-C51114.2020.00048>
 ID 465: <https://doi.org/10.1109/MASS62177.2024.00026>
 ID 469: <https://doi.org/10.1109/3CBIT57391.2022.00015>
 ID 472: <https://doi.org/10.1109/CIG.2019.8847944>
 ID 475: <https://doi.org/10.1109/ICCAD57390.2023.10323845>
 ID 478: <https://doi.org/10.1109/ACCESS.2023.3269505>
 ID 351: <https://doi.org/10.1109/ICEECE61019.2023.10442795>
 ID 354: <https://doi.org/10.1109/IUS51837.2023.10308385>
 ID 357: <https://doi.org/10.1109/ICCE-Asia57006.2022.9954679>
 ID 360: <https://doi.org/10.1109/CAC59555.2023.10451613>
 ID 363: <https://doi.org/10.1109/ICCV51070.2023.01891>
 ID 366: <https://doi.org/10.1109/MNET.001.1900161>
 ID 369: <https://doi.org/10.1109/ACCESS.2024.3417220>
 ID 372: <https://doi.org/10.1109/MetaCom57706.2023.00058>
 ID 375: <https://doi.org/10.1109/ACCESS.2024.3441489>
 ID 378: <https://doi.org/10.1109/ACCESS.2022.3189349>
 ID 381: <https://doi.org/10.1109/AIVR52153.2021.00024>
 ID 384: <https://doi.org/10.1109/ACOI62457.2024.10941577>
 ID 387: <https://doi.org/10.1109/CIPCV61763.2024.00033>
 ID 391: <https://doi.org/10.1109/LRA.2024.3447470>
 ID 394: <https://doi.org/10.1109/CSNT57126.2023.10134683>
 ID 397: <https://doi.org/10.1109/MT-ITS56129.2023.10241690>
 ID 400: <https://doi.org/10.1109/VIS55277.2024.00027>
 ID 403: <https://doi.org/10.1109/ACCESS.2022.3231137>
 ID 406: <https://doi.org/10.1109/ACCESS.2020.3036053>
 ID 409: <https://doi.org/10.1109/WACV61041.2025.00217>
 ID 412: <https://doi.org/10.1109/ACCESS.2024.3459411>
 ID 415: <https://doi.org/10.1109/HORA58378.2023.10156685>
 ID 418: <https://doi.org/10.1109/ACCESS.2018.2886420>
 ID 421: <https://doi.org/10.1109/RO-MAN47096.2020.9223595>
 ID 424: <https://doi.org/10.1109/ICECAA58104.2023.10212171>
 ID 427: <https://doi.org/10.1109/TIP.2018.2889265>
 ID 430: <https://doi.org/10.1109/ACCESS.2022.3188296>
 ID 433: <https://doi.org/10.1109/AIRoSIP58759.2023.10873968>
 ID 436: <https://doi.org/10.1109/ACCESS.2021.3086586>
 ID 439: <https://doi.org/10.1109/IICCS61609.2024.10763899>
 ID 442: <https://doi.org/10.1109/ECTC51906.2022.00097>
 ID 445: <https://doi.org/10.1109/ICASSP49660.2025.10888660>
 ID 448: <https://doi.org/10.1109/MASS62177.2024.00055>
 ID 451: <https://doi.org/10.1109/ICDSCA59871.2023.10393371>
 ID 454: <https://doi.org/10.1109/ICOSEC61587.2024.10722064>
 ID 457: <https://doi.org/10.1109/MysuruCon55714.2022.9972662>
 ID 460: <https://doi.org/10.1109/ICWITE57052.2022.10176217>
 ID 463: <https://doi.org/10.1109/STCR59085.2023.10396884>
 ID 466: <https://doi.org/10.1109/ICTBIG59752.2023.10456147>
 ID 470: <https://doi.org/10.1109/ACCESS.2023.3256277>
 ID 473: <https://doi.org/10.1109/TIFS.2023.3269640>
 ID 476: <https://doi.org/10.1109/ISIEA61920.2024.10607225>
 ID 479: <https://doi.org/10.1109/RICAI60863.2023.10489758>

ID 480: <https://doi.org/10.1109/TGRS.2023.3268944>
 ID 483: <https://doi.org/10.1109/ACCESS.2020.2989304>
 ID 486: <https://doi.org/10.1109/ACCESS.2020.3030339>
 ID 489: <https://doi.org/10.1109/LED.2022.3175203>
 ID 492: <https://doi.org/10.1109/MMSP55362.2022.9949293>
 ID 495: <https://doi.org/10.1109/SMARTCOMP.2019.00037>
 ID 498: <https://doi.org/10.1109/ACCESS.2024.3465843>
 ID 501: <https://doi.org/10.1109/AISC56616.2023.10085229>
 ID 504: <https://doi.org/10.1109/LRA.2024.3357030>
 ID 507: <https://doi.org/10.1109/EmergIN63207.2024.10961348>
 ID 510: <https://doi.org/10.1109/TITS.2021.3121125>
 ID 513: <https://doi.org/10.1109/TVCG.2020.3013876>
 ID 516: <https://doi.org/10.1109/ACCESS.2020.3010981>
 ID 519: <https://doi.org/10.1109/TVCG.2024.3361502>
 ID 522: <https://doi.org/10.1109/ICST53961.2022.00048>
 ID 525: <https://doi.org/10.1109/TASE.2021.3129077>
 ID 528: <https://doi.org/10.1109/SEAI62072.2024.10674557>
 ID 531: <https://doi.org/10.1109/ICSS58085.2023.10407362>
 ID 534: <https://doi.org/10.1109/TRO.2023.3236945>
 ID 537: <https://doi.org/10.1109/TSC.2023.3324734>
 ID 540: <https://doi.org/10.1109/GlobConET56651.2023.10150143>
 ID 543: <https://doi.org/10.1109/ACCESS.2024.3494834>
 ID 546: <https://doi.org/10.1109/ICOB53556.2022.9777160>
 ID 549: <https://doi.org/10.1109/ACCESS.2025.3554607>
 ID 552: <https://doi.org/10.1109/JIOT.2021.3113730>
 ID 555: <https://doi.org/10.1109/ACCESS.2021.3084887>
 ID 558: <https://doi.org/10.1109/JEDS.2024.3414469>
 ID 561: <https://doi.org/10.1109/TMM.2021.3130752>
 ID 564: <https://doi.org/10.1109/ICCT55948.2022.10040274>
 ID 567: <https://doi.org/10.1109/TVCG.2018.2873695>
 ID 570: <https://doi.org/10.1109/TIA.2022.3214802>
 ID 573: <https://doi.org/10.1109/RMKMATE59243.2023.10369921>
 ID 576: <https://doi.org/10.1109/CVPR52729.2023.00064>
 ID 579: <https://doi.org/10.1109/ACCESS.2025.3551747>
 ID 582: <https://doi.org/10.1109/CVPR52733.2024.00592>
 ID 585: <https://doi.org/10.1109/ACCESS.2019.2924425>
 ID 588: <https://doi.org/10.1109/ICSECE58870.2023.10263493>
 ID 591: <https://doi.org/10.1109/ACCESS.2020.2969816>
 ID 594: <https://doi.org/10.1109/ACCESS.2021.3052458>
 ID 597: <https://doi.org/10.1109/CVPR.2019.00688>
 ID 600: <https://doi.org/10.1109/CVMI59935.2023.10464469>
 ID 603: <https://doi.org/10.1109/O-COCOSDA64382.2024.10800594>
 ID 606: <https://doi.org/10.1109/ICCV51070.2023.01787>
 ID 481: <https://doi.org/10.1109/ICDACAT59742.2023.00110>
 ID 484: <https://doi.org/10.1109/CVPR52733.2024.01242>
 ID 487: <https://doi.org/10.1109/AINIT61980.2024.10581614>
 ID 490: <https://doi.org/10.1109/ACCESS.2021.3072057>
 ID 493: <https://doi.org/10.1109/ACCESS.2021.3054061>
 ID 496: <https://doi.org/10.1109/IICAIET55139.2022.9936832>
 ID 499: <https://doi.org/10.1109/ISC255366.2022.9922268>
 ID 502: <https://doi.org/10.1109/ICDDS56399.2022.10037286>
 ID 505: <https://doi.org/10.1109/IWAIIP58158.2023.10462885>
 ID 508: <https://doi.org/10.1109/ICES57224.2023.10192598>
 ID 511: <https://doi.org/10.1109/ASID60355.2023.10426160>
 ID 514: <https://doi.org/10.1109/SMCS3654.2022.9945388>
 ID 517: <https://doi.org/10.1109/IC2E357697.2023.10262545>
 ID 520: <https://doi.org/10.1109/AIXVR59861.2024.00020>
 ID 523: <https://doi.org/10.1109/AEECA59734.2023.00088>
 ID 526: <https://doi.org/10.1109/ICRASET59632.2023.10420351>
 ID 529: <https://doi.org/10.1109/TMM.2021.3091863>
 ID 532: <https://doi.org/10.1109/COMPSAC61105.2024.00384>
 ID 535: <https://doi.org/10.1109/TCDS.2023.3283406>
 ID 538: <https://doi.org/10.1109/ICERC563125.2024.10895414>
 ID 541: <https://doi.org/10.1109/ICPR48806.2021.9412507>
 ID 544: <https://doi.org/10.1109/BigData59044.2023.10386329>
 ID 547: <https://doi.org/10.1109/CVPR52733.2024.01548>
 ID 550: <https://doi.org/10.1109/ICPECA51329.2021.9362569>
 ID 553: <https://doi.org/10.1109/CVPR42600.2020.00277>
 ID 556: <https://doi.org/10.1109/ACCESS.2024.3435485>
 ID 559: <https://doi.org/10.1109/AISC56616.2023.10085277>
 ID 562: <https://doi.org/10.1109/JIOT.2021.3135408>
 ID 565: <https://doi.org/10.1109/AIXVR63409.2025.00017>
 ID 568: <https://doi.org/10.23919/WiOpt58741.2023.10349705>
 ID 571: <https://doi.org/10.1109/MetroXRINE58569.2023.10405622>
 ID 574: <https://doi.org/10.1109/ICA58824.2023.00020>
 ID 577: <https://doi.org/10.1109/ICASSP43922.2022.9747023>
 ID 580: <https://doi.org/10.1109/TMI.2022.3151118>
 ID 583: <https://doi.org/10.1109/TAI.2022.3149858>
 ID 586: <https://doi.org/10.1109/3DV62453.2024.00150>
 ID 589: <https://doi.org/10.1109/EMBC53108.2024.10782737>
 ID 592: <https://doi.org/10.1109/ACCESS.2024.3369185>
 ID 595: <https://doi.org/10.1109/SCSE61872.2024.10550666>
 ID 598: <https://doi.org/10.1109/ISAI63299.2024.00015>
 ID 601: <https://doi.org/10.1109/ICAECT60202.2024.10469161>
 ID 604: <https://doi.org/10.1109/BMSB55706.2022.9828764>
 ID 607: <https://doi.org/10.1109/ICOSEC61587.2024.10722189>
 ID 482: <https://doi.org/10.1109/ACCESS.2021.3131446>
 ID 485: <https://doi.org/10.1109/ACCESS.2024.3389748>
 ID 488: <https://doi.org/10.1109/CVPR52733.2024.00597>
 ID 491: <https://doi.org/10.1109/LRA.2024.3405335>
 ID 494: <https://doi.org/10.1109/CVPR52733.2024.00139>
 ID 497: <https://doi.org/10.1109/ICIP51287.2024.10647842>
 ID 500: <https://doi.org/10.1109/TAICT55358.2022.9887491>
 ID 503: <https://doi.org/10.1109/ACCESS.2023.3313094>
 ID 506: <https://doi.org/10.1109/ICAC54203.2021.9671219>
 ID 509: <https://doi.org/10.1109/IDAP64064.2024.10710994>
 ID 512: <https://doi.org/10.1109/BigData62323.2024.10826085>
 ID 515: <https://doi.org/10.1109/RAAICON48939.2019.22>
 ID 518: <https://doi.org/10.1109/ICPR48806.2021.9412785>
 ID 521: <https://doi.org/10.1109/ACAIT56212.2022.10137939>
 ID 524: <https://doi.org/10.1109/ISAI-NLP60301.2023.10354679>
 ID 527: <https://doi.org/10.1109/ICIBA56860.2023.10165611>
 ID 530: <https://doi.org/10.1109/ICTCS.2019.8923033>
 ID 533: <https://doi.org/10.1109/LRA.2020.3013833>
 ID 536: <https://doi.org/10.1109/ICRPSET57982.2022.10188504>
 ID 539: <https://doi.org/10.1109/IEDM45625.2022.10019499>
 ID 542: <https://doi.org/10.1109/ETIS64005.2025.10961658>
 ID 545: <https://doi.org/10.1109/ICET59753.2023.10375046>
 ID 548: <https://doi.org/10.1109/CVPR52688.2022.01710>
 ID 551: <https://doi.org/10.1109/ICSE563445.2024.10763313>
 ID 554: <https://doi.org/10.1109/ICOSEC58147.2023.10275999>
 ID 557: <https://doi.org/10.1109/ICEPG63230.2024.10775587>
 ID 560: <https://doi.org/10.1109/ACCESS.2022.3161566>
 ID 563: <https://doi.org/10.1109/ICCIKE58312.2023.10131876>
 ID 566: <https://doi.org/10.1109/ICSGRC57744.2023.10215412>
 ID 569: <https://doi.org/10.1109/EIECS63941.2024.10799961>
 ID 572: <https://doi.org/10.1109/AIXVR63409.2025.00083>
 ID 575: <https://doi.org/10.15439/2020F3>
 ID 578: <https://doi.org/10.1109/ACCESS.2024.3378285>
 ID 581: <https://doi.org/10.1109/ACCESS.2022.3158343>
 ID 584: <https://doi.org/10.1109/ACCESS.2023.3308908>
 ID 587: <https://doi.org/10.1109/AIES7029.2022.00081>
 ID 590: <https://doi.org/10.1109/AECE59614.2023.10428284>
 ID 593: <https://doi.org/10.1109/ICICAT57735.2023.10263657>
 ID 596: <https://doi.org/10.1109/JSEN.2024.3395970>
 ID 599: <https://doi.org/10.1109/MCOM.002.2200424>
 ID 602: <https://doi.org/10.1109/IGARSS46834.2022.9884798>
 ID 605: <https://doi.org/10.1109/ICITISEE63424.2024.10730751>
 ID 608: <https://doi.org/10.1109/CAI59869.2024.00246>

ID 609: <https://doi.org/10.1109/ICAC3N60023.2023.10541758>
 ID 612: <https://doi.org/10.1109/ICMII62623.2024.00052>
 ID 615: <https://doi.org/10.23919/WiOpt52861.2021.9589847>
 ID 618: <https://doi.org/10.1109/SMART63812.2024.10882512>
 ID 621: <https://doi.org/10.1109/LRA.2023.3270034>
 ID 624: <https://doi.org/10.1109/JSEN.2021.3060953>
 ID 627: <https://doi.org/10.1109/AISC56616.2023.10085594>
 ID 630: <https://doi.org/10.1109/ACCESS.2019.2943516>
 ID 633: <https://doi.org/10.1109/OCIT59427.2023.10430635>
 ID 636: <https://doi.org/10.1109/IPCC59175.2023.10253881>
 ID 639: <https://doi.org/10.1109/ACCESS.2022.3177904>
 ID 642: <https://doi.org/10.1109/EIConCIT50028.2021.9431927>
 ID 645: <https://doi.org/10.1109/ACCESS.2024.3352749>
 ID 648: <https://doi.org/10.1109/ICMLA.2019.00068>
 ID 651: <https://doi.org/10.1109/ISEC61299.2024.10665168>
 ID 654: <https://doi.org/10.1109/ACCESS.2023.3260777>
 ID 657: <https://doi.org/10.1109/ZINC55034.2022.9840649>
 ID 660: <https://doi.org/10.1109/ICASSP48485.2024.10447380>
 ID 663: <https://doi.org/10.1109/ACCESS.2023.3277431>
 ID 666: <https://doi.org/10.1109/ACCESS.2019.2917609>
 ID 610: <https://doi.org/10.1109/CVPR52733.2024.00192>
 ID 613: <https://doi.org/10.1109/ACCESS.2020.3048160>
 ID 616: <https://doi.org/10.1109/ICCCISS51004.2021.9397196>
 ID 619: <https://doi.org/10.1109/ICEDEG61611.2024.10702094>
 ID 622: <https://doi.org/10.1109/OCIT59427.2023.10430509>
 ID 625: <https://doi.org/10.1109/JBHI.2021.3101982>
 ID 628: <https://doi.org/10.1109/ACCESS.2024.3408840>
 ID 631: <https://doi.org/10.1109/JSEN.2022.3229232>
 ID 634: <https://doi.org/10.1109/Telepresence63209.2024.10841789>
 ID 637: <https://doi.org/10.1109/ICIBA52610.2021.9688164>
 ID 640: <https://doi.org/10.1109/FUZZ45933.2021.9494483>
 ID 643: <https://doi.org/10.1109/TSE.2021.3106280>
 ID 646: <https://doi.org/10.1109/ACCESS.2023.3336812>
 ID 649: <https://doi.org/10.1109/ISPCE-ASIA60405.2023.10365931>
 ID 652: <https://doi.org/10.1109/BDEE63226.2024.00009>
 ID 655: <https://doi.org/10.1109/ICDE51399.2021.00185>
 ID 658: <https://doi.org/10.1109/ICASSP.2019.8683727>
 ID 661: <https://doi.org/10.1109/TNSRE.2023.3254151>
 ID 664: <https://doi.org/10.1109/AIIoT58432.2024.10574705>
 ID 667: <https://doi.org/10.1109/LRA.2024.3390587>
 ID 611: <https://doi.org/10.1109/ACCESS.2024.3426082>
 ID 614: <https://doi.org/10.1109/ICAAIC56838.2023.10141186>
 ID 617: <https://doi.org/10.1109/CISPSSE49931.2020.9212240>
 ID 620: <https://doi.org/10.1109/TVCG.2025.3549561>
 ID 623: <https://doi.org/10.1109/JIOT.2024.3395524>
 ID 626: <https://doi.org/10.1109/WCONF61366.2024.10692314>
 ID 629: <https://doi.org/10.1109/ACOIT62457.2024.10939807>
 ID 632: <https://doi.org/10.1109/TAFFC.2021.3064940>
 ID 635: <https://doi.org/10.1109/TED.2024.3435630>
 ID 638: <https://doi.org/10.1109/ISPASS55109.2022.00008>
 ID 641: <https://doi.org/10.1109/COMPAC61105.2024.00274>
 ID 644: <https://doi.org/10.1109/ICNAS53565.2021.9628966>
 ID 647: <https://doi.org/10.1109/ICCS60870.2024.10543787>
 ID 650: <https://doi.org/10.1109/INDICON56171.2022.10039758>
 ID 653: <https://doi.org/10.1109/ICASSP49660.2025.10889367>
 ID 656: <https://doi.org/10.1109/ICCAMS60113.2023.10526013>
 ID 659: <https://doi.org/10.1109/AIKE55402.2022.00023>
 ID 662: <https://doi.org/10.1109/JIOT.2024.3518615>
 ID 665: <https://doi.org/10.1109/LRA.2022.3231828>