

INSPIRAÇÃO EM BRANCO: O PROBLEMA DA REPRESENTAÇÃO EM IA MUSICAL ENTRE A PLATAFORMIZAÇÃO, O EXTRATIVISMO E O TRABALHO FANTASMA

Henrique Maia Lins Vaz ¹

Resumo: Este artigo investiga a produção algorítmica de música sob a regra industrial da plataformização corporativa — o que o mercado comercializa como inovação democrática, mas que opera como fortaleza algorítmica (AlaaS, IA extrativista) —, a partir de uma perspectiva crítica que articula três quadros teóricos. Primeiro, a análise musicológica de Christopher W. White demonstra como a lógica probabilística da tokenização e o viés do proximal inviabilizam a geração de música como ato de intencionalidade corporificada, onde a escuta se faz gesto e a forma se faz evento — aquilo que a escuta humana reconhece como Gestalt vivida, irreduzível à correlação estatística. Segundo, os Estudos Críticos do Código de Mark C. Marino permitem investigar arquiteturas de geração trancadas sob regimes de opacidade proprietária, através de uma "arqueologia do indisponível". Por fim, articula-se a ontologia da técnica de Giorgio Agamben para demonstrar que o problema fulcral não reside apenas na economia da extração de dados, mas na transformação ontológica da música de *uso* (*uti*, prática encarnada de um vivente) em *função* (*fungi*, operação autônoma de um dispositivo). Contra essa lógica industrial, o texto contrapõe o modelo de autoria distribuída — praticado em contextos experimentais fora da lógica corporativa, onde o compositor atua como arquiteto de possibilidades — à "desativação da desativação": a restituição da técnica algorítmica à sua dimensão de *ethos* e forma de vida, recusando a função em favor do uso.

Palavras-Chave: IA e música; Representação musical; Extrativismo de dados; Trabalho fantasma; Plataformização.

¹ Henrique Vaz é pesquisador-criador, professor permanente do Programa de Pós-Graduação em Artes, Cultura e Linguagens da UFJF, onde coordena as pesquisas: "Programação Criativa como Chave Pedagógica", "Gambioluteria: da Programação Orientada à Gambiarra ao Entalhe da Luteria Pós-Digital" e "Escrever com o Espaço Latente: Arquiteturas Neurais e Estratégias de Invenção Composicional". Com formação em composição, ciências da computação e música com ênfase pedagógica, sua prática se desenvolve entre ensaios, oficinas e experimentações algorítmicas que investigam os impactos sociotécnicos da informação digital, as políticas de acesso e direito cibernético, e os limites do sujeito de direito sob os regimes de virtualização e colonização algorítmica. Atua na intersecção entre modelagem computacional e composicional, síntese sonora e visual, e explora notações e sintaxes emergentes no campo das práticas criativas. E-mail: henrique.maia.vaz@gmail.com ORCID: <https://orcid.org/0009-0005-4918-9689>. Currículo Lattes: <http://lattes.cnpq.br/2157611772722802>

BLANK INSPIRATION: THE PROBLEM OF REPRESENTATION IN AI MUSIC BETWEEN PLATFORMIZATION, EXTRACTIVISM, AND GHOST WORK

Abstract: This article investigates AI-generated music from a critical perspective that articulates Christopher W. White's musicological analysis with Mark C. Marino's Critical Code Studies. Starting from White's five obstacles to musical creation by AI – motivation, examples, representation, structure, and interpretation – the text deepens the last three, demonstrating how the absence of experiential knowledge makes it impossible to produce structurally coherent and semantically meaningful music. Inspired by Marino, a reading of code as a cultural artifact was added to this analysis, proposing an archaeology of the unavailable to investigate proprietary systems whose code remains inaccessible. The examination of the political economy of musical AI reveals three interconnected dimensions: data extractivism, which treats human experience as free raw material; ghost work, a precarious workforce that sustains the illusion of automation; and platformization, a regime in which generated music is optimized for algorithmic engagement, producing pastiche and semantic flattening. It can be concluded that the problem of musical AI is not primarily technical but structural and political, demanding transparency, strengthening of community alternatives, and critical education.

Keywords: AI and music; Musical representation; Data extractivism; Ghost work; Platformization.

Depois de fundir-se o espaço e amanhecer um novo tempo, eu hei de fazer que circule a palavra-alma novamente pelos ossos de quem se põe de pé [...] Quando isso acontecer Tupã renascerá no coração do estrangeiro.

Profecia da nação Guarani do clã Jeguakava, narrada por Pablo Werá no início do século XX (Jecupé, 2001).

1. Onde a máquina não toca: assombro, técnica e a pergunta que antecede a resposta

Muito antes de a imaginação europeia do século XIX perguntar se uma máquina poderia compor música, tradições não europeias já haviam elaborado, de modo sistemático, problemas de automatismo e engenho mecânico. Entre os séculos VIII e XIV, a engenharia no mundo islâmico articulou investigação científica e solução prática, produzindo autômatos e sistemas hidráulicos complexos. Os Banū Mūsā, com o *Kitab al-Hiyal*, forneceram um dos textos fundacionais para o estudo sistemático de dispositivos automáticos, enquanto Al-Jazarī elevou esses desenhos a um novo patamar técnico, cujos princípios de automação ecoam na história da engenharia (Hakimov, 2024; Jeoung-Myoung, 2023).

Essa genealogia não concorre para substituir um cânone por outro, mas para desprovincializar a própria pergunta sobre técnica e inteligência. A questão deixa de ser quem veio primeiro e passa a ser quais histórias foram universalizadas como origem legítima da máquina e quais foram convertidas em nota de rodapé pelo que a literatura chama de "império cognitivo" — a invasão e subordinação de outras formas de saber pela racionalidade ocidental (Ndlovu-Gatsheni, 2020).

Sob essa luz, quando a questão ressurgiu na Europa industrial com Ada Lovelace em 1843, ela ganhou uma roupagem epistemológica específica. Diante da máquina analítica de Babbage (1837/1961), Lovelace celebrou o cálculo, mas negou a originação: a máquina não tem pretensão alguma de originar qualquer coisa. O que faltava ao mecanismo, aos olhos da matemática, era a centelha romântica que distingue a recombinação mecânica da "criação humana" (White, 2025). O problema é que, ao fazer dessa dúvida europeia o mito de origem da IA, a moderna indústria de algoritmos naturaliza sua história.

Hoje, plataformas corporativas de criação generativa por inteligência artificial (modelos estatísticos de alta dimensionalidade baseados em aprendizado profundo) prometem ao usuário comum o poder de "criar" música a partir de *prompts* de texto. Contudo, a IA contemporânea aparece menos como o súbito advento dessa máquina criativa romântica e mais como a atualização de uma longa infraestrutura de poder. A literatura recente descreve a AlaaS (Inteligência Artificial como Serviço) como inscrita numa *colonial matrix of power*, sustentada por regimes de exploração laboral global, extração de conhecimento e marginalização de alternativas não ocidentais (Muldoon, 2023; Hung, 2024). Em vez de autonomia maquínica, o que se vê é uma cadeia colonial de suprimento em que trabalhadores do Sul Global, ecologias periféricas e epistemologias subalternizadas sustentam a ilusão de neutralidade vendida pelas plataformas.

Nesse sentido, a música gerada por IA (AlaaS e IAs extrativistas) não deve ser analisada apenas como um problema estético, mas como o produto de uma extração em três frentes. A extração laboral, evidenciada pela divisão internacional do trabalho digital que terceiriza a classificação de dados sonoros para trabalhadores precarizados (Le Ludec et al., 2023); a extração ecológica, ancorada na mineração e no consumo desmedido de *data centers*; e a extração epistêmica, que universaliza padrões musicais do Norte Global enquanto trata tradições orais ou não ocidentais como "ruído" ou dados descartáveis.

É contra esse pano de fundo que este artigo situa seu objeto. Embora artistas demonstrem usos criticamente situados da tecnologia, o foco aqui é a regra industrial: a produção algorítmica de música como *commodity* plataformizada. A tese que orienta este artigo é a de que a música gerada por IA corporativa constitui a expressão mais acabada de uma economia política da extração. Para demonstrá-la, articulo dois quadros teóricos complementares. O primeiro vem de Christopher W. White (2025), cuja análise musicológica expõe os obstáculos estruturais que inviabilizam que as máquinas produzam "música conectada à experiência humana". O segundo provém dos Estudos Críticos do Código de Mark C. Marino (2020), que propõe ler o software como artefato ideológico.

A articulação entre White e Marino nos força a enfrentar um problema: o código das grandes IAs (as de fluxo criativo opaco) é inacessível, trancado atrás de muros

corporativos. Essa opacidade é uma estratégia de poder (Pasquinelli, 2023). Diante dela, propomos uma "arqueologia do indisponível", uma leitura sintomática que opera por rastros — os efeitos materiais, o trabalho invisível e as "falhas estruturais" da música gerada — para interpretar o que o código proprietário esconde.

Retomando a pergunta de Lovelace à luz dessa infraestrutura colonial, o que está em jogo não é se a máquina pode originar música no sentido romântico, mas compreender a quais custos materiais, políticos e epistêmicos certos sistemas são autorizados a aparecer como "criativos" (Hung, 2024). A questão urgente é como regimes proprietários de computação extraem da vida social suas formas e sensibilidades musicais, para devolvê-las como conteúdo sonoro otimizado para o engajamento.

2. Três lentes para o que não se escuta

2.1 O corpo que a máquina não tem: cinco obstáculos, cinco ausências

Enquanto boa parte da literatura dedicada à intersecção entre inteligência artificial e música tem se concentrado em experimentos localizados ou em investigações de caráter fenomenológico, a contribuição de Christopher W. White em *The AI Music Problem* (2025) distingue-se por seu escopo analítico sistêmico. Autores como Bob Sturm (2015) exploram a aplicação de redes neurais na *folk music*; Oliver Bown (2015) investiga a criatividade computacional sob a ótica da agência; e Aaron Einbond (2021) foca nas fronteiras da análise sonora e da composição. Diferentemente dessas abordagens, White propõe uma radiografia estrutural dos limites inerentes à lógica de aprendizado de máquina quando aplicada ao domínio musical, explicitando por que a música resiste à reprodução algorítmica de maneiras que o texto ou a imagem não o fazem. Mais do que uma especulação teórica, o diagnóstico de White tem sido corroborado por achados recentes na área de Recuperação de Informação Musical (MIR) e em engenharia de modelos generativos (Christodoulou et al., 2024; Evans et al., 2024).

O argumento central de White é o de que a música apresenta desafios específicos que tornam sua reprodução por IA particularmente problemática. Ele organiza sua investigação em cinco forças que se encadeiam de forma cumulativa.

O primeiro é a Motivação (*Motivation*). A pesquisa em IA aplicada à música recebe uma fração ínfima dos investimentos globais. A explicação reside na aplicabilidade *cross-industrial*: um modelo de linguagem serve para contratos, código e atendimento, mas um modelo musical serve quase exclusivamente ao domínio do áudio, oferecendo um retorno sobre o investimento (ROI) e uma escalabilidade significativamente menores (White, 2025, p. 47-51).

O segundo obstáculo são os Exemplos (*Examples*). A música apresenta um paradoxo informacional. Há uma barreira de entrada para a criação, e a música é feita para repetição. Contudo, a literatura de MIR mostra que "mais horas de áudio" não equivale automaticamente a melhor aprendizagem estatística. A construção de *datasets* exige limpeza de dados, refinamento de rótulos, unificação estrutural e protocolos rigorosos, revelando que a matéria-prima da IA é altamente dependente de curadoria humana invisível (Zhou et al., 2025). Ademais, a diversidade musical é fragmentada e ontologicamente heterogênea. *Datasets* massivos, como o Lakh MIDI, sofrem de problemas concretos de duplicação e vazamento de dados, exigindo filtragens conservadoras (Choi et al., 2025), enquanto a tentativa de universalizar modelos treinados em repertórios estreitos marginaliza tradições não ocidentais (Huang et al., 2023) — um problema que ecoa diretamente a extração epistêmica discutida na abertura deste artigo. A isso se soma a dificuldade técnica de extrair informação confiável de áudio. A transcrição polifônica automática continua sendo uma das tarefas mais difíceis do MIR, exigindo estratégias complexas de rastreamento de múltiplos *F0* (frequências fundamentais) e tratamento de parciais sobrepostas (Argenti et al., 2011; Benetos et al., 2011). O sinal bruto de áudio não oferece transparência estrutural imediata à máquina, chegando ao modelo já degradado por ambiguidades físico-acústicas.

O terceiro problema é a Representação (*Representation*). Para processar música, a IA deve traduzi-la em *tokens*. A literatura técnica recente mostra que isso não é uma falha contingente, mas uma tensão estrutural: sistemas serializam eventos usando *piano rolls*, notação simbólica ou *tokens* compostos, mas cada escolha privilegia

certos aspectos da música e comprime outros (Cui et al., 2025). Modelos de transcrição precisam escolher entre descrições prescritivas ou descritivas (Hsu; Su, 2021), e o bom desempenho em uma tarefa não transfere automaticamente para outra (Christodoulou et al., 2024). Representações gerais (como graus da escala) são estatisticamente fáceis de aprender, mas não geram música concreta; representações específicas geram uma explosão combinatória que inviabiliza o aprendizado de padrões amplos. A tokenização, portanto, nunca é neutra: ela define antecipadamente os limites do que o modelo poderá perceber como padrão.

O quarto obstáculo é a Estrutura (*Structure*). White demonstra que redes neurais são exímias em identificar "proximidades determinadas aninhadas", mas a "música humana" opera frequentemente via relações não determinísticas, não aninhadas e separadas no tempo. A convergência entre a musicologia de White e a engenharia de IA generativa nesse ponto é notável. Revisões sistemáticas recentes confirmam que os modelos atuais ainda "falham" em desenvolvimento narrativo e coerência de longo prazo, validando empiricamente a taxonomia de White (Ji et al., 2025). O *Music Transformer* consegue continuar motivos de forma coerente localmente, mas não resolve o arco macro. Modelos de *Latent Diffusion* melhoram a estrutura quando o contexto é expandido para até 4 minutos, mas exigem escala computacional proibitiva e ainda falham na arquitetura de longo prazo (Evans et al., 2024). Há um *trade-off* arquitetural comprovado: modelos LSTM preservam a microcoerência local, enquanto Transformers melhoram a globalidade, mas produzem fraseados irregulares (Ghoshal et al., 2026). O "estágio Adulto" de White — aquele em que a música articula variação e repetição em múltiplos níveis orgânicos — permanece inalcançado. A forma longa, quando obtida, precisa ser imposta ou guiada externamente, não emergindo da compreensão estrutural da máquina (Atassi et al., 2024).

O quinto e último problema é a Interpretação (*Interpretation*). Em linguagem técnica, isso se traduz como uma lacuna intransponível entre correlação estatística e compreensão musical integrada. Sistemas computacionais podem superar humanos em rastreamento de *pitch* e *timing*, mas permanecem fragmentados entre tarefas isoladas, distantes da integração holística que caracteriza a "escuta humana" (Christodoulou et al., 2024). A percepção musical humana organiza melodias, acordes e seções como *Gestalten* — entidades percebidas como mais do que a soma de notas individuais

(Ostermann et al., 2023). White distingue conhecimento associacional (saber que acordes menores seguem determinados padrões) de conhecimento experiencial (saber o que é sentir o aperto no peito da perda). A IA corporativa pode gerar estatísticas perfeitas, mas falha em injetar a intencionalidade corporificada que fundamenta a escuta. A "alma vazia" da música de IA não é um *bug* a ser corrigido no próximo semestre de desenvolvimento, mas a expressão lógica de um sistema estruturalmente limitado por seus próprios fundamentos probabilísticos e epistemológicos.

2.2 O comentário no código: hermenêutica da suspeita e o ajuste que não se nomeia

Se White nos oferece uma radiografia musicológica do problema da IA, é nos Estudos Críticos do Código (*Critical Code Studies*), conforme formulados por Mark C. Marino (2020), que encontramos o instrumental para interrogar suas causas materiais. Marino parte de uma premissa de consequências profundas: código não é instrução neutra; código é texto cultural. Como qualquer outro artefato semiótico, ele carrega marcas de sua história, de seus autores e das disputas de poder que o constituíram (Marino, 2020). Trabalhos posteriores no campo reiteram que essa leitura crítica se torna ainda mais urgente na era da IA generativa, pois a mediação automatizada não elimina a espessura cultural do código, mas frequentemente a obfusca (Douglass, 2026).

Essa perspectiva do código como cultura encontra um eco e uma expansão metodológica vital na etnografia dos sistemas algorítmicos proposta por Nick Seaver (2017). Enquanto Marino aplica a hermenêutica de perto ao texto do código, Seaver nos alerta para o risco de buscarmos nos algoritmos uma definição puramente abstrata — como se fossem fórmulas matemáticas isoladas. Ao contrário, Seaver argumenta que devemos entender os algoritmos não como objetos que estão na cultura, mas como cultura: sistemas sociotécnicos heterogêneos, instáveis, que são performados por uma miríade de práticas humanas. No chão de fábrica do desenvolvimento de software, o "algoritmo" raramente é um procedimento formal e sim um produto coletivo, difuso, envolvendo decisões corporativas, ajustes empíricos e a interação constante com os usuários.

O gesto metodológico central de Marino ganha nova camada de complexidade quando lido através da lente de Seaver. A aplicação da "hermenêutica da suspeita" —

categoria tomada de empréstimo de Paul Ricoeur e resumida por Hans-Georg Gadamer (1984) como a crítica que desconfia das aparências imediatas e questiona as pretensões de validade de ideologias — ao domínio do software não se restringe a investigar a sintaxe do código. Trata-se de suspeitar tanto do texto quanto do sistema sóciotécnico que o envolve: as ideologias que encarna, os trabalhos que esconde e as assimetrias de conhecimento que o constituem (Shukla, 2025). Como aponta a literatura sobre ciência e tecnologia, dados não são "brutos"; cada ponto já resulta de abstração e escolha humana (Díaz Perojo; Van de Ven; Chateau, 2024).

Um caso analisado por Marino é particularmente esclarecedor para a nossa discussão sobre IA: o escândalo do Climategate em 2009. Quando e-mails e códigos da Unidade de Pesquisa Climática foram hackeados, detratores encontraram um comentário do programador: "APPLIES A VERY ARTIFICIAL CORRECTION FOR DECLINE". Para o público, era a prova de fraude: um *fudge factor* manipulando dados. No entanto, investigações técnicas e científicas posteriores revelaram que não havia fraude, mas sim fragilidades de documentação e comunicação pública do software. O episódio reforçou a importância de transparência, dados abertos e *Quality Assurance* (QA) na ciência computacional (Hocquet et al., 2024), mostrando que software científico envolve práticas, governança, infraestrutura e conhecimento tácito que vão muito além do código-fonte.

A lição do Climategate para a crítica da IA musical é dupla. Primeiro, o código adquire significados que escapam ao controle de seus autores quando circula fora de seu contexto. Segundo, o conceito de *fudge factor* — um ajuste estatístico para forçar dados conflitantes a se encaixarem em um modelo — revela algo fundamental sobre a materialidade da programação contemporânea.

Como Seaver (2017) observa em sua etnografia, a construção de sistemas complexos depende de um *sensemaking* pragmático e impreciso. O *fudge factor* não é uma anomalia, mas a lógica de funcionamento de sistemas que lidam com a realidade. Na verdade, a literatura de aprendizado de máquina (ML) mostra que esse ajuste não é um acidente isolado, mas a própria estrutura dos *pipelines* modelísticos contemporâneos. Em ML, correções e manipulações não são exceções; são a rotina do pré-processamento (Yang et al., 2024). Modelos de regressão, por exemplo, produzem naturalmente um viés sistemático de tendência central (superestimando valores baixos

e subestimando altos), exigindo métodos específicos de correção (Lee, 2025). Em modelos baseados em árvores, esse mesmo padrão exige técnicas de *distribution matching* para alinhar as saídas à realidade (Chen, 2021). Além disso, o desempenho e o resultado de um modelo dependem fortemente das transformações e do balanceamento impostos aos dados antes do treinamento — um processo onde a correção de viés para a classe majoritária é uma necessidade constante para dados desbalanceados (Uddin et al., 2024).

O *fudge factor*, portanto, nomeia uma lógica técnica mais ampla: sistemas frequentemente não processam a realidade em sua integridade, mas a achatam através de correções, aproximações e *bricolage* técnica para forçar os dados a se comportarem dentro de modelos matemáticos rígidos. A IA musical não opera como um oráculo desinteressado, mas inteiramente sob essa lógica do ajuste contínuo — um sistema onde a matemática é constantemente amansada pela improvisação humana e por camadas ocultas de pré-processamento.

2.3 Ler o que não se pode ver: arqueologia do indisponível

A articulação entre White e Marino não é imediata, pois enfrenta um obstáculo epistemológico central: o código das IAs musicais comerciais não está disponível para leitura. Trata-se de software proprietário, trancado atrás do que podemos chamar de "IA de Fortaleza", um modelo de desenvolvimento que utiliza a opacidade não como um acidente, mas como estratégia de poder para impedir contestação e concentrar lucros (Pasquinelli, 2023). Como bem notam pesquisadores que investigam algoritmos de *streaming*, tentar compreender a arquitetura de *big data* por meio de análises qualitativas de universo reduzido é uma tarefa estruturalmente dificultada pela própria natureza do objeto.

É exatamente diante dessa barreira intransponível que nossa proposta analítica se assenta. Diante da indisponibilidade do código-fonte, este ensaio não propõe uma "arqueologia do indisponível" como um método empírico de escavação de dados primários — o que exigiria acesso a patentes, auditoria de código ou engenharia reversa, fugindo ao escopo desta análise teórica. Propomos, antes, a arqueologia do indisponível como uma lente hermenêutica de leitura sintomática.

Sob essa lente, inspirada na hermenêutica da suspeita de Marino, não precisamos "ver" o algoritmo para interpretá-lo; nós o lemos através dos rastros materiais que ele deixa. Se o código é um texto que performa na interface entre humanos e máquinas, seus efeitos no mundo são a própria materialização de sua arquitetura oculta. Nossa análise opera, portanto, sobre cinco camadas de sintomas: (1) a economia política de sua infraestrutura (quem paga e quem trabalha para que ele exista); (2) a materialidade de seus insumos (quais dados foram extraídos e como); (3) as "falhas estruturais" de seus outputs (a música gerada que, como White demonstra, falha em atingir coerência de longo prazo); (4) a lógica tradutória de sua representação (como a experiência é achatada em *tokens*); e (5) os discursos corporativos que tentam vender uma imagem de magia e autonomia.

Essa postura epistemológica nos permite formular perguntas que a análise técnica pura ou a condenação moral superficial não alcançam: que trabalho humano é extraído para sustentar a ilusão da automação? Que visões de mundo estão inscritas nos *datasets* que definem o que conta como "música"? Que relações de poder se consolidam quando a "falha estrutural" da máquina é maquiada por intervenção humana invisível?

O percurso analítico que segue é uma tentativa de responder a essas perguntas. No próximo movimento, mapearemos a infraestrutura material dessa máquina – o extrativismo de dados e o trabalho fantasma –, para, em seguida, mergulharmos na lógica interna do *fudge factor* algorítmico: a tokenização, a estrutura e o pastiche plataformaizado.

3. O que a máquina come: economia política da extração

Se a seção anterior estabeleceu a lente hermenêutica para interrogar a IA musical, este movimento analítico a coloca em ação para investigar a infraestrutura material que sustenta o fenômeno. Sob a aparente imaterialidade do código e a "etereidade da música", opera uma máquina de extração que combina a mineração de comportamentos, a exploração de trabalho precarizado e a dissipação de recursos planetários.

3.1 Extrativismo de dados, fontes ocultas e o cerco ao *commons* sonoro

Os modelos gerativos atuais não "aprendem" música no sentido "humano"; eles operam por aquilo que White (2025) chama de conhecimento associacional: a capacidade de identificar padrões estatísticos em conjuntos massivos de exemplos e recombina-los. Para que essa operação ocorra, é necessário alimentar os algoritmos com volumes colossais de música já existente. Esse processo de alimentação é o núcleo do extrativismo de dados (*data extractivism*), um regime no qual a experiência humana acumulada – neste caso, séculos de criação e performance musical – é tratada como matéria-prima gratuita a ser minerada e transformada em ativo comercial (Mezzadra; Neilson, 2019).

Essa tradução da experiência sonora para o associacionismo estatístico exige um violento processo de parametrização. Ao examinarmos a arquitetura técnica de modelos multimodais de ponta, como o LLARK – um sistema de compreensão musical desenvolvido por pesquisadores do Spotify e da Universidade de Washington –, a mecânica desse extrativismo torna-se explícita (Gardner et al., 2024). Para que o modelo "entenda" uma faixa de áudio bruto, ele não a escuta; ele a submete a uma etapa que os engenheiros chamam de "aumento de metadados" (*metadata augmentation*). Nesse processo, a complexidade de uma performance musical é seletivamente extraída e condensada em apenas quatro vetores numéricos: andamento (BPM), tonalidade global, acordes e uma grade de compassos (*beat grid*). O que sobra da obra musical – suas microdinâmicas, texturas, desvios rítmicos e intenções expressivas – é descartado como ruído residual para que o modelo de linguagem possa processar o áudio como se fosse uma planilha.

A primeira pergunta que nossa leitura sintomática deve fazer é: de onde vem a matéria-prima original para essa parametrização? As corporações de IA raramente divulgam a composição exata de seus *datasets* de treinamento, o que constitui em si um dado revelador de sua economia política. Quando essas fontes são expostas por vazamentos ou processos judiciais, revela-se um retrato de apropriação em larga escala. Os bancos de dados que alimentam ferramentas corporativas de licenciamento fechado não provêm de um acervo mágico e livre na nuvem; eles são construídos a partir da raspagem sistemática da internet, que inclui desde repositórios de domínio público até

acervos de plataformas de *streaming* e, crucialmente, vastas bibliotecas de música sob direitos autorais cujo uso não foi autorizado pelos artistas. O recente escrutínio legal sobre essas empresas – exemplificado por ações judiciais de grandes gravadoras acusando plataformas de IA de "pirataria em escala industrial" para treinar seus modelos – expõe a falsidade do discurso de inovação democrática, revelando um colonialismo de dados (Couldry; Mejias, 2019) que despossui os criadores de seu trabalho para alimentar os servidores corporativos.

Nesse contexto, o extrativismo musical revela sua face epistêmica mais perversa. A curadoria desses *datasets* opera uma violência classificatória que não é acidental, mas estrutural aos próprios modelos computacionais. Curiosamente, os próprios desenvolvedores de IA reconhecem essa limitação em seus relatórios técnicos: o *Impact Statement* do modelo LLARK admite abertamente a existência de um "viés em direção à música ocidental nos *datasets* musicais e nas características usadas para representá-los (isto é, acordes na escala de 12 tons, instrumentos em formatos MIDI)" (Gardner et al., 2024). Essa confissão técnica corrobora nossa tese: a extração de dados exige a padronização prévia do objeto. Músicas de tradições orais, microtonalidades, experimentações de vanguarda, gêneros periféricos ou manifestações que não se deixam capturar por uma "grade de compassos" ocidental (tempos fortes e fracos numerados em fórmulas como 4/4) ou pela harmonia funcional são, por definição arquitetônica do sistema, sub-representadas ou tratadas como dados falhos. O que a IA recebe como insumo é majoritariamente a música hegemônica dos centros da indústria cultural, já destilada em suas coordenadas cartesianas.

É aqui que se estabelece uma tendência de retroalimentação, embora devamos evitar determinismos prematuros sobre seu impacto presente. A IA corporativa, treinada nos padrões extraídos do consumo passado, tende a gerar música que replica esses mesmos padrões. Contudo, não é apenas a dieta de dados que direciona essa produção, mas a própria limitação física da máquina. A arquitetura de modelos como o LLARK é restrita a "janelas de contexto" de áudio de meros 25 segundos – um recorte determinado pelos limites computacionais dos codificadores de áudio atuais (Gardner et al., 2024).

Essa limitação técnica é o que explica a afinidade eletiva entre a IA gerativa e o "long tail" da internet. Hoje, essa produção já está sendo infiltrada de forma massiva

nesses exatos 25 segundos funcionais: trilhas sonoras para vídeos do YouTube, *background music* para *streamings* ao vivo na Twitch, bibliotecas de áudio para conteúdo de TikTok e Instagram. A máquina não foi projetada para gerar sinfonias ou narrativas de longa duração; sua ontologia computacional a aprisiona no formato de "loop" utilitário. Embora seja precipitado afirmar que a música de IA já substituiu o consumo de "músicas humanas", ela está ocupando rapidamente os espaços da música utilitária e do conteúdo de baixo custo. O "círculo" que se desenha é o da homogeneização do ambiente sonoro funcional: à medida que essas plataformas passam a indexar e recomendar seu próprio conteúdo gerativo (em blocos de 25 segundos otimizados por métricas ocidentais de BPM e tonalidade) para reduzir custos de licenciamento, molda-se, gradualmente, um padrão algorítmico de "música de fundo" que atrofia a diversidade nesses ecossistemas.

3.2 Trabalho fantasma: a escuta traduzida em dados e a falsa automação

Se o extrativismo de dados é o *front* visível, o trabalho fantasma (*ghost work*) opera nas sombras (Gray; Suri, 2019). A expressão designa a multidão invisível de trabalhadores precarizados que realizam as tarefas de curadoria e rotulagem sem as quais os modelos de IA simplesmente não funcionariam. Na indústria de IA em geral, são esses trabalhadores que identificam se uma imagem contém um semáforo ou se um texto contém discurso de ódio. Mas como se configura esse trabalho no domínio específico da música?

A especificidade do trabalho fantasma musical reside na tradução da escuta para o código. Antes que um modelo possa prever uma melodia, milhares de horas de áudio precisam ser segmentadas, etiquetadas e classificadas por humanos. Plataformas como o Amazon Mechanical Turk (AMT) operam como mercados de trabalho digital nos quais empresas e pesquisadores terceirizam pequenas tarefas humanas, remuneradas por item concluído, para uma multidão distribuída de trabalhadores (Strickland; Stoops, 2019; Schmidt; Jettinghoff, 2016). Esse modelo de microtrabalho decompõe projetos em atividades breves e repetitivas, executadas em segundos ou minutos, como classificação, correção e anotação de dados (Lellis, 2020; Ipeirotis; Provost; Wang, 2010). No campo musical, esse arranjo já foi usado para coletar anotações de conteúdo

musical, julgamentos de similaridade, marcações de emoção ou humor e detecção de erros em transcrições e partituras, inclusive com trabalhadores sem formação musical formal (Samiotis et al., 2022; Lee, 2010; Çano; Morisio, 2017). Em *audio annotation* mais amplamente, tarefas complexas costumam ser quebradas em unidades menores ou em passes binários sucessivos, justamente porque a dimensão temporal do som dificulta anotações mais ricas em uma única etapa (Cartwright et al., 2019).

A precarização não reside apenas no baixo valor pago pela tarefa concluída, mas na arquitetura estrutural da plataforma, que obriga o trabalhador a realizar trabalho não remunerado apenas para ter acesso ao trabalho remunerado. Um estudo quantitativo rigoroso, que instalou rastreadores de navegação nas máquinas de 100 trabalhadores do AMT, revelou que esses indivíduos gastam em média 33% do seu tempo diário realizando "trabalho invisível" — atividades não pagas exigidas pela própria plataforma, como vigiar obsessivamente o perfil de solicitantes à espera de novas tarefas (hipervigilância) ou gerenciar pagamentos e lidar com tarefas que expiraram (*time out*) após horas de trabalho, resultando em zero remuneração pelo esforço (Toxtli; Suri; Savage, 2021). Se contabilizado apenas o tempo de tarefas formalmente pagas, o salário mediano era de US\$ 3,76/hora; mas, ao subtrair o tempo gasto nesse trabalho invisível não remunerado, a renda real despenca para US\$ 2,83/hora. Outros trabalhos também caracterizam o pagamento em plataformas de *crowdsourcing* como muito baixo e observam que tarefas de anotação vêm sendo deslocadas globalmente para regiões de menor custo de vida (Kaufmann; Schulze; Veit, 2011; Kutlu et al., 2020).

Essa etapa é a materialização do que discutimos sobre a representação: é o momento em que o conhecimento experiencial e corporificado da música é esmagado e convertido em rótulos discretos (*tokens*) para alimentar a máquina associacional. A epistemologia da IA musical não flui de programadores, mas da precarização da escuta humana.

Além da rotulagem de *datasets*, o trabalho fantasma atua de outra forma crucial: a "limpeza" dos resultados gerados. Como vimos na análise de White, os modelos frequentemente falham em produzir estruturas coerentes de longo prazo (os estágios *Toddler* e *Child*). Eles podem gerar frases com sete compassos em vez de oito, ou introduzir um tema que nunca mais retorna. Quando uma plataforma corporativa

apresenta ao usuário um resultado aparentemente perfeito, frequentemente há uma cadeia de intervenções humanas invisíveis ocorrendo em tempo real ou em pós-processamento: algoritmos de regra (*heuristic*) que forçam um corte no compasso correto, ou até mesmo trabalhadores humanos editando e "consertando" as falhas mais gritantes antes da publicação.

Essa descoberta tem implicações profundas para a crítica da IA musical. Ela revela que a automação é, em larga medida, uma fachada – um artefato discursivo que oculta o trabalho humano necessário para fazer a máquina parecer autônoma. O que a IA musical corporativa automatiza, em última instância, não é a criação, mas a extração de valor a partir do trabalho precário sob a aparência de magia tecnológica.

Mais do que ocultar o trabalho humano, essa arquitetura revela o estatuto jurídico-econômico da própria máquina no modo de produção plataformação. Como sugere Jamie Kelly (2026) em sua análise marxista da automação, o desenvolvimento da IA não aponta para uma revolução liberadora, mas para um regime de "feudalismo artificial". A IA generativa atua, de fato, como uma forma de trabalho artificial – ela produz o conteúdo sonoro, executa a "tarefa" –, mas ela é estruturalmente desprovida da "dupla liberdade" marxiana. Ela não possui controle legal sobre os meios de produção (os servidores e o código pertencem à plataforma) nem sobre o produto de seu trabalho (os direitos autorais da música gerada são imediatamente apropriados pelo capital). A música gerada por IA não é o produto de um agente autônomo no mercado, mas o trabalho subserviente de um servo algorítmico enclausurado nos domínios corporativos. Essa dinâmica explicita uma assimetria fundamental do nosso tempo: enquanto os trabalhadores humanos tremem diante da ameaça de substituição automática, os detentores do capital não temem a IA, pois utilizam seu poder sobre os arranjos legais e sociais para garantir que a máquina permaneça, irrevogavelmente, sua propriedade.

Esses dois custos – o extrativismo de dados e o trabalho fantasma – articulam-se a um terceiro, crescentemente incontornável: o custo socioambiental. Os *data centers* que processam o treinamento de modelos de áudio consomem água e energia em escalas colossais. Projeções recentes publicadas na *Nature Sustainability* estimam que, apenas nos Estados Unidos, a expansão dos servidores de IA entre 2024 e 2030 gerará uma pegada hídrica anual entre 731 milhões e 1,1 bilhão de metros cúbicos, somada a emissões de carbono de 24 a 44 megatoneladas — um impacto ambiental tão

severo que o estudo conclui ser "improvável que a indústria atinja suas metas de zero líquido [net-zero] até 2030 sem depender massivamente de mecanismos altamente incertos de compensação de carbono e restauração hídrica" (Xiao et al., 2025). A "IA generativa" é, também, uma IA sedimentar no seu sentido mais literal: suas camadas de abstração repousam sobre uma base material de recursos hídricos esgotados e energia fóssil queimada, cujo custo é sistematicamente externalizado. É contra esse pano de fundo de extração em múltiplas camadas que devemos agora examinar a lógica interna do código e o regime estético que ele produz.

4. A lógica do *fudge factor*: estrutura, tokenização e pastiche

Se a seção anterior expôs a infraestrutura de extração que sustenta a IA musical corporativa, este movimento adentra a maquinaria interna de sua operação. O fio condutor aqui é a categoria que tomamos de empréstimo de Marino (2020): o *fudge factor*. Como vimos, o *fudge factor* é um fator de ajuste, uma correção estatística aplicada para fazer dados conflitantes se encaixarem em um modelo. Na IA musical, esse conceito deixa de ser um comentário passageiro de código para se tornar o princípio estruturante de todo o sistema: a lógica mesma de um aparato que só pode operar convertendo a experiência em aproximações estatísticas.

4.1 A estrutura sob suspeita: o viés do proximal

Para compreender por que a IA musical corporativa opera inteiramente por *fudge factors*, precisamos retomar a análise de White (2025) sobre as diferenças entre a estrutura musical e aquilo que os modelos probabilísticos são arquitetados para aprender. Redes neurais e grandes modelos de linguagem (LLMs) são otimizados para identificar o que White chama de proximidades determinadas aninhadas: padrões que são estatisticamente frequentes, adjacentes no tempo ou no espaço, e derivados de regras rígidas. Essa própria arquitetura impõe o que a literatura de computação musical recente vem diagnosticando como um *trade-off* estrutural insolúvel nas redes neurais

atuais: uma tensão inerente entre a capacidade de modelar a continuidade melódica imediata e a necessidade de manter a coerência estrutural global (Ghoshal et al., 2026).

A "música humana", contudo, frequentemente opera na contramão dessa lógica. É evidente que o *Big Data* pode vir a mapear estruturas musicais complexas no futuro, e já existem abordagens híbridas sendo testadas. No entanto, a arquitetura predominante nos modelos comerciais atuais (baseados na previsão do próximo *token*) apresenta um viés estrutural claro: ela aprende exímia e eficientemente o que está próximo – a relação entre uma nota e a seguinte, ou um acorde e o próximo –, mas sua eficiência decai exponencialmente quando precisa relacionar eventos separados por dezenas de compassos.

A anatomia exata desse viés do proximal torna-se visível quando comparamos sistematicamente as duas principais famílias de modelos gerativos. Estudos controlados mostram que as redes de memória recorrente (LSTM), dependentes de um processamento sequencial passo a passo, demonstram uma superioridade inequívoca na captura de padrões locais e na continuidade em passagens curtas; contudo, elas entram em colapso na preservação de dependências de longo prazo, perdendo a coerência estrutural à medida que a sequência se expande. Por outro lado, os modelos baseados em atenção (*Transformers*) — que deveriam ser a solução para esse problema — revelam uma falha paradoxal: embora seu mecanismo de autoatenção consiga mapear a estrutura global de uma peça, eles "tendem a produzir fraseados irregulares" (*irregular phrasing*), falhando na precisão rítmica de baixo nível e na articulação sintática local (Ghoshal et al., 2026).

Esse viés do proximal explica a taxonomia proposta por White para os resultados gerativos. Os modelos *Toddler* repetem padrões locais *ad nauseam* (como o sistema MidiGPT preso na célula rítmica inicial de *Für Elise*). Os modelos *Child* organizam blocos reconhecíveis, mas sem direcionalidade ou acúmulo de tensão. Os modelos *Adolescent* (como Suno e Udio) geram frases com sofisticação local e timbres convincentes, mas falham em costurar esses fragmentos numa totalidade orgânica, gerando extensões de compassos estranhas ou temas que surgem e desaparecem sem desenvolvimento (White, 2025, p. 129-138). A descoberta da computação musical de que os *Transformers* falham especificamente na regularidade das frases fornece a prova de laboratório da categoria "*Adolescent*".

O que essa taxonomia revela não é uma limitação tecnológica absoluta e imutável, mas o sintoma de uma escolha de design corporativo: diante da dificuldade de computar relações de longo prazo, a indústria opta por otimizar a coerência local imediata. O resultado é aplicável o suficiente para o consumo rápido nas plataformas, mas estruturalmente falho do ponto de vista da composição.

4.2 Tokenização: o *fudge factor* permanente

Esse viés estrutural repousa sobre um problema mais fundamental: a representação. Para que o modelo probabilístico funcione, a continuidade da experiência musical deve ser fatiada em *tokens* – unidades discretas. A decisão sobre o que conta como um *token* (se a nota individual, o acorde, o grau escalar, a posição métrica) é, em si mesma, o primeiro *fudge factor* do sistema. É uma correção forçada: cortar a música em pedaços que o algoritmo consiga digerir, sabendo-se que algo fundamental será perdido no processo.

O dilema da representação de White atua aqui com toda a força. Representações gerais (como "acorde de tônica") são estatisticamente fáceis de aprender, mas pobres em informação específica; representações ricas em especificidade geram uma explosão combinatória que inviabiliza o aprendizado de padrões amplos. A gravidade empírica desse achatamento torna-se audível quando comparamos modelos que adotam diferentes estratégias de fatiamento. Um estudo perceptual controlado com ouvintes demonstrou que modelos que utilizam *tokens* isolados simples (como sequências discretas de eventos MIDI) geram um resultado perceptivamente mais "pobre" e menos melódico. Percebendo essa perda, a engenharia de IA tenta criar contrapesos: por exemplo, o modelo *Compound Word Transformer* agrupa múltiplas dimensões musicais em um único "*token* composto" para forçar o algoritmo a aprender a relação de coocorrência entre elas. O resultado é que ouvintes humanos avaliam imediatamente a música gerada por esses *tokens* compostos como significativamente mais "melódica" e "rica" do que a gerada por *tokens* simples (CHU et al., 2022). No entanto, essa solução não resolve o impasse epistemológico; ela é apenas um *fudge factor* de segunda ordem: um remendo técnico para tentar costurar a

complexidade que a primeira fatia destruiu. Esse dilema escapa às soluções puramente estatísticas.

Enquanto isso, a tokenização atua como um achatamento semântico permanente (*semantic squeeze*). O que ocorre aqui não é apenas a perda de dados, mas um abismo epistêmico de descrição, na esteira do que René Thom (1988) chamou de transposição entre ilhas linguísticas e ilhas matemáticas: a IA mapeia estruturas de altíssima complexidade combinatória em seu domínio matemático – onde são perfeitamente determinadas –, mas ao traduzi-las de volta para o áudio, geram uma morfologia que a cognição musical humana, dependente de relações de longo prazo e intencionalidade, lê como ruído estrutural ou pastiche. A música que chega aos nossos ouvidos não é o produto de uma compreensão musical, mas o resultado de uma operação de tradução estatística forçada.

4.3 Pastiche e a otimização do gosto funcional

O resultado em nível macro desse processo é o que podemos chamar, com Ted Chiang (2024), de automação do gosto. A expressão designa o uso de IA não para "criar arte", mas para produzir conteúdo que seja "bom o suficiente" para manter o usuário engajado.

No entanto, a própria expressão "automação do gosto" carrega uma contradição intrínseca que a filosofia nos ajuda a desvendar. Em sua investigação arqueológica sobre o conceito, Giorgio Agamben (2017) demonstra que a tradição ocidental constituiu o gosto justamente como um "conhecimento outro" — um conhecimento que não sabe que sabe, mas que goza; um prazer que julga sem recorrer a conceitos. Desde Platão até Kant, o gosto foi o espaço do enigma: a faculdade de julgar o belo não como uma ciência exata, mas como uma "universalidade sem conceito" e um "prazer sem interesse". O gosto habita o registro do "eu não sei o quê", operando como um significante flutuante e excessivo que escapa à apreensão racional e à adequação estrita entre significado e significante. O que a IA corporativa tenta fazer, sob o rótulo de "automação do gosto", não é, portanto, aprimorar o "juízo estético", mas aniquilar esse excesso: trata-se de capturar o significante indeterminado do belo e aprisioná-lo na lógica determinista da métrica computacional.

É fundamental, contudo, imprimir aqui uma dose de nuance crítica. A subordinação da criação a métricas de engajamento não é uma patologia exclusiva da IA. A indústria fonográfica já produz, há décadas, larga escala de música altamente funcional e desprovida de intenção expressiva individual: trilhas para publicidade, música para ambientes comerciais, ou mesmo segmentos de gêneros massificados onde o objetivo declarado do artista ou produtor é, explicitamente, alcançar o topo das paradas de *streaming* aderindo estritamente a fórmulas estéticas pré-estabelecidas (Manovich; Arielli, 2024). Nesses casos, os critérios estéticos já foram historicamente colonizados pelas métricas de engajamento.

A diferença estrutural que a IA corporativa introduz não é a invenção do pastiche, mas a sua automação radical e o deslocamento do custo do trabalho. Quando a produção de música pasteurizada é transferida de estúdios (onde ainda há custos de trabalho, horas de estúdio, músicos de sessão) para servidores de inferência (onde o custo marginal de gerar mais uma faixa funcional tende a zero), instaura-se um regime de "pastiche plaformizado".

A pergunta que passa a orientar essa produção não é "isto é belo?" ou "isto expressa algo?" — perguntas que remeteriam ao domínio enigmático do gosto —, mas "isto performa algoritmicamente?". Na lógica das plataformas de *streaming*, "performar algoritmicamente" significa, em última instância, atuar como uma variável de entrada para sistemas de *analytics* preditivos projetados para mitigar o *churn* (a taxa de cancelamento de assinaturas). A resposta é dada não pela escuta humana profunda, mas por métricas de retenção e cliques. Como revelam os estudos sobre a automação plataformação, a música gerada por IA é avaliada por sua capacidade de sinalizar engajamento contínuo; quando os algoritmos de análise preditiva detectam padrões de declínio no usuário — como redução no tempo de escuta ou "*skips*" frequentes —, a injeção de conteúdo gerativo hiperfamiliar é acionada como uma contramedida matemática para manter o consumidor preso ao ecossistema (Mokoena; Obagbuwa, 2025). É por isso que fenômenos de IA gerativa que viram modismo passageiro na internet — como certas faixas virais que surgem e somem em semanas — não se sustentam como música a ser ouvida atentamente: elas são otimizadas para o impacto imediato da curiosidade, não para a escuta sustentada. Seu ciclo de vida efêmero é, na verdade, funcional para o modelo de negócios, que integra o gerativo à lógica das redes

sociais (como o TikTok) não para preservar obras, mas para gerar picos de engajamento que sirvam à conversão de usuários da camada gratuita para a camada paga de assinaturas (Mokoena; Obagbuwa, 2025).

É evidente, como aponta a literatura recente (Floridi, 2023), que a IA pode atuar como parceira criativa quando apropriada por artistas humanos conscientes de seus limites e potencialidades, e que o mercado já busca caminhos de licenciamento e remuneração. Porém, o foco deste ensaio permanece na regra industrial: a música gerada em escala como *commodity* de baixo custo. Nesse estrato da produção, o que a IA corporativa entrega é estatística musicalizada: um *fudge factor* estético que soa "quase humano" precisamente porque se alimenta da média do que os humanos já consumiram, esvaziando, no processo, a singularidade que fundamenta a experiência estética.

4.4 Do uso à função: a música como dispositivo

A crítica ao "pastiche plataformizado", no entanto, exige uma fundação mais profunda do que a mera denúncia da economia de atenção. Para compreender por que a música gerada por IA corporativa é estruturalmente incapaz de constituir uma prática artística no sentido pleno, é preciso interrogar a natureza mesma da técnica que a produz. Longe de ser um acidente da engenharia contemporânea, a lógica do *fudge factor* expressa uma mutação ontológica mais antiga: a passagem do *uso* à *função* como modo de relação do humano com o mundo.

Desde a antropogênese, o humano se distingue como o vivente que externaliza suas capacidades em dispositivos técnicos, criando um patrimônio exossomático que se coloca ao lado das habilidades endossomáticas do corpo. Cada invenção técnica, nesse movimento, desativa uma função corporal para confiá-la a um instrumento artificial — um princípio de desativação que, ao longo da história, gerou uma separação crescente entre o humano e seus próprios produtos. O que se observa na modernidade é o auge desse desnível: o humano como indivíduo endossomático torna-se progressivamente incapaz de estar à altura da esfera exossomática que criou, e a consciência, longe de dominar essa esfera, transforma-se em mais um órgão do sistema tecnológico que pretendia governar.

A consequência decisiva para a nossa questão reside na transformação do *uso* em *função*. Enquanto o uso de um instrumento — *uti*, no sentido etimológico — implica integralmente o indivíduo em sua corporeidade, exigindo um *ethos* e uma forma de vida, a execução da função de um dispositivo parece operar sem qualquer consequência para o sujeito que dela participa. A caneta, instrumento da mão que escreve, torna-se o suporte de uma função-escrevibilidade autonomizada; o martelo, prolongamento do braço, converte-se em uma função-batedora que se desvincula do gesto corporal. Nessa passagem, o que se perde não é apenas a mediação física, mas a relação de sentido: o *fungi*, o puro exercício da função, opera *opere operato*, independentemente das qualidades do sujeito que o aciona.

A música gerada por IA corporativa é a realização máxima dessa lógica. Onde a performance musical humana é um *uso* — uma prática encarnada que implica o corpo do intérprete, sua história, sua forma de vida, sua vulnerabilidade diante do limite do dizível —, a geração algorítmica é uma *função* pura: o *prompt* é o botão que aciona o dispositivo, e o output é o resultado de uma operação estatística desprovida de *ethos*. O *fudge factor* não é, portanto, uma imperfeição contingente do código, mas a marca estrutural de um sistema que não pode operar de outro modo, porque foi arquitetado para executar funções, não para cultivar usos. A tokenização, o viés do proximal, o pastiche — todos esses sintomas que identificamos são, em última instância, manifestações de uma mesma transformação: a música, antes prática de um vivente em sua corporeidade, tornou-se função de um dispositivo que a processa sem relação com o sujeito.

O que está em jogo, nessa perspectiva, não é apenas a "qualidade estética" do *output*, mas o estatuto ontológico da própria experiência musical. Se a antropogênese coincide com a tecnogênese, então a desativação progressiva das capacidades musicais endossomáticas — a escuta atenta, a memória corporificada do ritmo, a percepção gestáltica da forma — não é um processo neutro. Cada faixa gerada em segundos por um modelo de difusão latente corresponde, do lado humano, a uma capacidade de *uso* musical que se atrofia. A indústria não vende apenas música funcional; ela vende a ilusão de que a função pode substituir o uso sem perda, de que o dispositivo pode gerar o equivalente de uma prática encarnada. Mas o equivalente, aqui, é precisamente o que falta: o *ethos*, a forma de vida, o corpo que resiste e que, na resistência, faz sentido.

Diante dessa constatação, a pergunta que se impõe é se existe uma saída para o "desnível prometeico". A resposta não pode vir da consciência, que já foi assimilada pelo sistema técnico, mas de uma operação inversa: não a invenção de mais dispositivos, mas a *desativação da desativação* — a recuperação do uso das capacidades que a técnica sepultou. No domínio da música, isso significa restituir à impotência sua potência, transformar o "não poder usar" em um "poder não usar": a recusa em delegar a escuta à função algorítmica, a reivindicação do corpo como lugar irredutível da experiência sonora, a prática de uma técnica que não se confunde com o dispositivo. É nesse sentido que a reforma da escuta, invocada ao final deste ensaio, não é apenas uma exigência política, mas uma operação ontológica: a reabertura de um espaço entre o endossomático e o exossomático, onde a música possa voltar a ser *ars* — não no sentido estreito da modernidade estética, mas no sentido original de *techne*, de prática encarnada de um vivente que faz uso de si (Agamben, 2017).

5. Considerações Finais: o custo do espelhamento estatístico

Ao longo deste ensaio, percorremos um arco que partiu da cena inaugural de Ada Lovelace diante da máquina analítica — "pode ela originar algo?" — e chegou a uma constatação menos romântica, porém mais politicamente urgente. Formulada nos termos de Lovelace, a pergunta pela capacidade criativa da máquina pode até se tornar obsoleta com o avanço dos modelos probabilísticos; afinal, a engenharia de *prompt* já permite combinações inéditas de padrões sonoros. A pergunta que permanece — e que o nosso percurso analítico buscou iluminar — é outra: a que custo ecológico, social e epistêmico a indústria da IA musical extrai, processa e nos devolve uma versão empobrecida de nossa própria experiência musical?

A resposta a essa indagação exigiu uma mudança de foco. Diante da "IA de Fortaleza" e de seus códigos inacessíveis, não tentamos realizar uma engenharia reversa da caixa-preta, mas operar uma leitura sintomática de seus efeitos. O que emerge dessa leitura cruzada entre White e Marino é uma imagem da IA musical corporativa muito distinta da narrativa de democratização criativa veiculada pelo marketing. Longe de ser um parceiro criativo autônomo, o modelo generativo comercial revela-se como um

aparato de otimização de custos. Ele não nos devolve música sob a forma de "composições humanas" – como ocorre nas *playlists* algorítmicas de recomendação do *streaming*, que organizam acervos pré-existentes –, mas sob a forma de conteúdo sonoro gerativo funcional, fabricado em tempo real para preencher o silêncio dos ambientes digitais com o mínimo de envolvimento humano e o máximo de extração de dados passados.

O que este ensaio propôs, portanto, não foi um novo método empírico de auditoria de algoritmos, mas um arcabouço teórico-crítico para interpretar a IA musical em sua materialidade. Articulando a musicologia estrutural de White – que expôs o viés do proximal, o dilema da representação e a ausência de conhecimento experiencial – com a hermenêutica da suspeita de Marino – que nos forneceu a categoria de *fudge factor* para pensar a violência da tokenização –, construímos uma lente capaz de enxergar através da opacidade corporativa. Essa lente nos permitiu nomear os mecanismos do "pastiche plataformizado": o extrativismo de acervos sob o manto do colonialismo de dados; o trabalho fantasma da tradução da escuta em rótulos; e o achatamento semântico que transforma a complexidade da experiência humana em vetores de engajamento.

É certo que a tecnologia em si não determina seu próprio destino. Na esfera da experimentação artística, compositores e compositoras têm se apropriado desses sistemas operando o que poderíamos chamar, numa chave filosófica, de uma delegação de decisões: o agente intencional humano mantém o controle morfológico da obra, delegando à máquina a geração de material em ambientes de imprecisão controlada. Nesses casos, a intencionalidade humana permanece como centro de extração de sentido, e a própria indústria já busca freios regulatórios e modelos de remuneração, como os acordos recentes envolvendo grandes gravadoras e plataformas de geração.

Contudo, enquanto o *default* (o padrão estrutural) da indústria permanecer focado na maximização do engajamento via extração predatória, o que ocorre não é uma delegação artística, mas uma abdicação estrutural. A regra industrial da IA musical – a produção algorítmica de commodities sonoras em escala – opera como um gigantesco espelhamento estatístico. Ela não cria significados, mas calcula a probabilidade de que certos arranjos sonoros simulem significados que já tivemos. O perigo dessa lógica não reside na máquina em si, mas na domesticação de nossa escuta:

quanto mais nos habituamos a "paisagens sonoras" geradas por *fudge factors* estatísticos, mais corremos o risco de atrofiar nossa capacidade de exigir e reconhecer a dimensão corporificada, histórica e estrutural da música.

É nesse ponto que a crítica da IA musical encontra a ontologia política. Como sugere Giorgio Agamben (2020), a nossa sociedade é onde a música penetra freneticamente em todo lugar, mas que é, paradoxalmente, a primeira comunidade humana "não musaicamente (ou amusaicamente) acordada". A perda do nexos musaico com a linguagem – a perda da experiência de que o canto lida com os limites do dizível – produz hoje o que Agamben chama de uma "inspiração em branco", que roda no vazio. A música gerada por IA corporativa é a materialização tecnológica dessa inspiração em branco: é uma tagarelice sonora algorítmica que preenche todos os silêncios sem jamais chocar-se com o próprio limite, sem dor, sem luto, sem a impossibilidade que constitui a verdadeira palavra.

Se a tarefa política do nosso tempo é constitutivamente uma tarefa poética, e se o pensamento coincide com a capacidade de interromper o fluxo insensato dos sons para restituí-los ao seu lugar, então desafiar a IA plataformação exige uma reforma da escuta. Exige, no nível prático, fortalecer alternativas comunitárias e modelos abertos que rompam com a lógica do colonialismo de dados. Exige, no nível educacional, um letramento crítico que ensine a ouvir as camadas de extração que sustentam o "fundo de tela" sonoro do nosso dia a dia. Acima de tudo, exige que continuemos perguntando, a cada nova faixa gerada em segundos: quem lucra com a ilusão de que a música não custa nada – e que parte das formas de vida estamos trocando por essa abundância espelhada?

5.1 Delegação e abdicação: o espectro da autoria híbrida

Se a seção anterior fundou a crítica na ontologia da técnica, é preciso agora evitar que essa crítica desemboque em uma condenação indiferenciada da inteligência artificial na música. O risco de uma leitura puramente negativa é o de reproduzir, sob outras roupagens, a mesma lógica binária que a indústria explora: a oposição entre "humano" e "máquina", entre "autenticidade" e "artificialidade", oposição que, como vimos, o marketing de IA já sabe instrumentalizar a seu favor. Para escapar desse beco,

é necessário distinguir dois regimes radicalmente diferentes de relação entre compositor(a) e algoritmo — regimes que, embora partilhem a mesma infraestrutura técnica, divergem em sua lógica de agência, em sua economia de sentido e em seu horizonte político.

Do lado da experimentação artística, observa-se um modo de apropriação que não coincide com a lógica do pastiche nem com a da abdicação estrutural. Nesse regime, o compositor(a) não se coloca como mero usuário(a) de um dispositivo que gera *outputs*, mas como arquiteto de um sistema de possibilidades: ele(a) define *constraints*, cura *datasets*, projeta interfaces, estabelece regras de interação e, crucialmente, mantém o controle morfológico da obra em todas as etapas do processo. A máquina, aqui, não substitui a intencionalidade, mas opera como interlocutora em um diálogo onde a imprecisão é deliberadamente cultivada como espaço de emergência. O compositor(a) delega ao algoritmo a geração de material bruto — melodias, texturas, estruturas —, mas delega *de dentro de um campo de forças* que ele mesmo desenhou: a condução e o ato de criação permanecem como centro gravitacional do sistema, e a interação entre proposta algorítmica e seleção constitui o motor do processo.

Essa dinâmica, que poderíamos chamar de delegação artística, difere da mera utilização de ferramentas porque transforma o próprio ato de composição: o autor(a) deixa de ser o detentor exclusivo de todas as decisões para tornar-se curador(a) de processos, mediador(a) entre agências distribuídas, orquestrador(a) de uma ecologia criativa onde "humanos" e "não-humanos" negociam sentido. A autoria, nesse modelo, não se dissolve, mas se desloca: ela reside menos na superfície sonora final do que na arquitetura do sistema, nas escolhas de design que antecedem e condicionam a geração. O código, longe de ser um operador neutro, torna-se texto cultural carregado de decisões estéticas e éticas; o *dataset*, longe de ser matéria-prima inerte, é um ato de curadoria que inscreve valores no corpo da máquina.

A diferença estrutural entre esse regime e a produção industrial de commodities sonoras não pode ser exagerada. Na lógica corporativa, o que se observa não é uma delegação, mas uma *abdicação*: a remoção do *steering* humano do circuito produtivo, sua substituição por métricas de engajamento que operam como funções autonomizadas, e a concentração da agência criativa nas mãos de engenheiros que projetam modelos para maximizar retenção, não para cultivar experiência. Onde o

compositor(a)-artista define *constraints* morfológicas que preservam a intencionalidade, a plataforma corporativa define *constraints* comerciais que a anulam. Onde o primeiro itera em diálogo com o *output*, a segunda itera em diálogo com o *churn*. Onde o primeiro cura dados para abrir possibilidades, a segunda raspa dados para fechar o círculo do consumo.

O que está em jogo, nessa distinção, é a própria definição de autoria na era algorítmica. A autoria distribuída, quando praticada conscientemente, não elimina o sujeito criador, mas o reposiciona: o compositor(a) torna-se não menos, mas diferentemente autor(a) — autor(a) do sistema, das regras, da ecologia de sentido que torna a emergência algorítmica significativa. Já a autoria extrativista da indústria não redistribui a agência, mas a concentra: ela apropria o trabalho de milhões para treinar modelos que, em seguida, dispensam qualquer sujeito criador, humano ou não. A "autoria" do *output* gerado é, nesse regime, um efeito de marketing: a plataforma vende a ilusão de que o usuário "criou" algo, quando, de fato, ele apenas acionou uma função previamente programada para produzir um resultado estatisticamente provável.

A tarefa crítica, portanto, não é abolir a hibridização entre "humano" e "máquina", mas politizá-la. Isso exige, em primeiro lugar, transparência: que os sistemas deixem de operar como caixas-pretas e tornem visíveis suas arquiteturas de decisão, seus *datasets*, seus *fudge factors*. Exige, em segundo lugar, uma ética do design que reconheça o software como artefato cultural, carregado de escolhas que têm consequências estéticas e políticas concretas. Exige, finalmente, que a comunidade musical recupere o *uso* das ferramentas contra a *função* que a indústria lhes impõe — que o compositor(a), para usar uma formulação já invocada, aprenda a "desativar a desativação", reconectando a técnica algorítmica à corporeidade da escuta e à forma de vida que a sustenta.

Somente nessa condição a inteligência artificial deixa de ser um aparato de extração para tornar-se, de fato, um parceiro de criação — não porque a máquina tenha adquirido agência autônoma, mas porque o "humano" (sob todas as carnações) recusou abdicar da sua.

Referências

- AGAMBEN, Giorgio. **A música suprema**. Música e política. Zero à Esquerda, 14 set. 2020. Disponível em: <https://tradutoresproletarios.wordpress.com/2020/09/14/giorgio-agamben-a-musica-suprema-musica-e-politica/>. Acesso em: 6 jul. 2026.
- AGAMBEN, Giorgio. **O uso dos corpos**. Tradução de Selvino José Assmann. São Paulo: Boitempo, 2017.
- AGAMBEN, Giorgio. **Gosto**. Tradução de Cláudio Oliveira. 1. ed. Belo Horizonte: Autêntica, 2017.
- ARGENTI, F.; NESI, P.; PANTALEO, G. **Automatic transcription of polyphonic music based on the constant-Q bispectral analysis**. IEEE Transactions on Audio, Speech, and Language Processing, v. 19, n. 6, p. 1610–1630, 2011.
- ATASSI, L. **Toward guided musical form: structuring generative music with LLMs**. Computer Music Journal, Cambridge, v. 48, n. 4, p. 28–41, 2024.
- BABBAGE, Charles. **On the Analytical Engine**. In: MORRISON, Philip; MORRISON, Emily (Ed.). Charles Babbage and his Calculating Engines: Selected Writings by Charles Babbage and Others. New York: Dover Publications, 1961. p. 73-115.
- BENETOS, Emmanouil; DIXON, S. **Joint multi-pitch detection using harmonic envelope estimation for polyphonic music transcription**. IEEE Journal of Selected Topics in Signal Processing, v. 5, n. 6, p. 1111–1123, 2011.
- BOWN, O. **Attributing Creative Agency: Are we doing it right?** In: Proceedings of the Sixth International Conference on Computational Creativity. Park City, Utah, 2015.
- ÇANO, Erion; MORISIO, Maurizio. **Crowdsourcing emotions in music domain**. International Journal of Artificial Intelligence and Applications, v. 8, n. 4, p. 25-40, 2017.
- CARTWRIGHT, Mark; DOVE, Graham; MÉNDEZ MÉNDEZ, Ana Elisa; BELLO, Juan P.; NOV, Oded. **Crowdsourcing multi-label audio annotation tasks with citizen scientists**. In: PROCEEDINGS OF THE 2019 CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS (CHI '19). Glasgow, Scotland, UK: ACM, 2019.
- CHEN, Liqun. **Learning deep models via optimal transport distance**. 2021. Tese (Doutorado em Engenharia Elétrica e de Computação) – Duke University, Durham, NC, EUA, 2021. Total de páginas: 112.
- UDDIN, Shahadat; LU, Haohui; RAHMAN, Ashfaqur; GAO, Junbin. **A novel approach for assessing fairness in deployed machine learning algorithms**. Scientific Reports, v. 14, artigo 17753, 2024.
- CHOI, Eunjin; KIM, Hyeri; RYU, Jiwoo; NAM, Juhan; JEONG, Dasaem. **On the deduplication of the Lakh MIDI dataset**. arXiv, 2025. Disponível em: <https://arxiv.org/abs/2509.16662v1>. Acesso em: 6 jul. 2026.
- CHRISTODOULOU, E. et al. **A review of multimodal music information retrieval**. Information Processing & Management, Oxford, v. 61, n. 4, 2024.
- CHU, Hyeslin; KIM, Joohee; KIM, Seongouk; LIM, Hongkyu; LEE, Hyunwook; JIN, Seungmin; LEE, Jongeun; KIM, Taehwan; KO, Sungahn. **An empirical study on how people perceive AI-generated music**. In: PROCEEDINGS OF THE 31ST ACM

INTERNATIONAL CONFERENCE ON INFORMATION & KNOWLEDGE MANAGEMENT (CIKM '22). Atlanta, GA, USA: ACM, 2022.

COULDRY, Nick; MEJIAS, Ulises A. **The costs of connection: how data is colonizing human life and appropriating it for capitalism**. Stanford: Stanford University Press, 2019.

CUI, X. H.; HU, P.; HUANG, Z. **Music sequence generation and arrangement based on transformer model**. Journal of Computational Methods in Sciences and Engineering, v. 25, n. 5, p. 3986–3999, 2025.

HSU, J.-Y.; SU, L. **VOCANO: a note transcription framework for singing voice in polyphonic music**. In: PROCEEDINGS OF THE 22ND INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR). Online, 2021. p. 293–300.

DE LELLIS, Lorenzo. **How gamification affects crowdsourcing: the case of Amazon Mechanical Turk**. Eludamos: Journal for Computer Game Culture, v. 10, n. 1, p. 27-37, 2020.

DÍAZ PEROJO, R. L.; VAN DE VEN, I.; CHATEAU, L. **Digital culture and the hermeneutic tradition: suspicion, trust, and dialogue**. 2024. Disponível em: <https://ssrn.com/abstract=6484178>. Acesso em: 6 jul. 2026.

DOUGLASS, Jeremy; MARINO, Mark C. **Introduction: reading code in the age of AI**. Digital Humanities Quarterly, v. 20, n. 4, 2026.

EINBOND, A.; BRESSON, J.; SCHWARZ, D.; CARPENTIER, T. **Instrumental Radiation Patterns as Models for Corpus-Based Spatial Sound Synthesis: Cosmologies for piano and 3D electronics**. In: Proceedings of the International Computer Music Conference (ICMC). Santiago, 2021.

EVANS, Zach; PARKER, Julian; CARR, CJ; ZUKOWSKI, Zack; TAYLOR, Josiah; PONS, Jordi. **Long-form music generation with latent diffusion**. arXiv, 2024. Disponível em: <https://arxiv.org/html/2404.10301v2>. Acesso em: 6 jul. 2026.

FLORIDI, Luciano. **The ethics of artificial intelligence: principles, challenges, and opportunities**. Oxford: Oxford University Press, 2023.

GADAMER, H.-G. **Verdade e Método II: Complementos e índice**. Tradução de Enio Paulo Giachini. Petrópolis: Vozes, 1984.

GARDNER, J.; DURAND, S.; STOLLER, D.; BITTNER, R. LLARK: **A Multimodal Instruction-Following Language Model for Music**. In: Proceedings of the 41st International Conference on Machine Learning (ICML), Vienna, Austria, 2024. Proceedings... Vienna: PMLR, v. 235, 2024.

GHOSHAL, Soudeep; CHAKRABORTY, Sandipan; CHOWDHURY, Pradipto; BUCKCHASH, Himanshu. **Fusing memory and attention: a study on LSTM, Transformer and hybrid architectures for symbolic music generation**. Expert Systems with Applications, [s. l.], v. [no prelo], 2026. Disponível em: <https://arxiv.org/abs/2603.21282v1>. Acesso em: 6 jul. 2026.

GRAY, Mary L.; SURI, Siddharth. **Ghost work: how to stop Silicon Valley from building a new global underclass**. Boston: Houghton Mifflin Harcourt, 2019.

HAKIMOV, Nazar; KARIMOV, Nodir; RESHETNIKOV, Ivan. **Mechanical Marvels: Innovations in Engineering During the Islamic Golden Age**. Archives for Technical Sciences, 2024.

HOCQUET, Alexandre; WIEBER, Frédéric; GRAMELSBERGER, Gabriele; HINSEN, Konrad; DIEMANN, Markus; PASQUINI SANTOS, Roberto; LANDSTRÖM, Catharina; PETERS, Jörg; KASPROWICZ, David; BORRELLI, Arianna; ROTH, Phillip; LEE, Francis; OLTEANU, Alin; BÖSCHEN, Stefan. **Software in science is ubiquitous yet overlooked**. Nature Computational Science, v. 4, p. 465, 2024.

HUANG, Rujing Stacy et al. **Beyond diverse datasets: responsible MIR, interdisciplinarity, and the fractured worlds of music**. Transactions of the International Society for Music Information Retrieval, v. 6, n. 1, p. 43-59, 2023.

HUNG, Kai-Hsin. **Artificial intelligence as planetary assemblages of coloniality: The new power architecture driving a tiered global data economy**. *Big Data & Society*, 2024.

IPEIROTIS, Panagiotis G.; PROVOST, Foster; WANG, Jing. **Quality management on Amazon Mechanical Turk**. In: Proceedings of the ACM SIGKDD Workshop on Human Computation (HCOMP '10). Washington, DC: ACM, 2010. p. 64-67.

JECUPÉ, Kaka Werá. **Tupã Tenondé: a criação do Universo, da Terra e do Homem segundo a tradição oral Guarani**. São Paulo: Peirópolis, 2001.

JEOUNG-MYOUNG, Kim. **Automata Technology in the Medieval Islamic World and Its Influence on Korea**. Journal of Oriental Studies, 2023.

Ji, Shulei; WU, Songruoyao; WANG, Zihao; LI, Shuyu; ZHANG, Kejun. **A comprehensive survey on generative AI for video-to-music generation**. arXiv, 2025. Disponível em: <https://arxiv.org/abs/2502.12489>. Acesso em: 6 jul. 2026.

KAUFMANN, Nicolas; SCHULZE, Thimo; VEIT, Daniel. **More than fun and money: worker motivation in crowdsourcing: a study on Mechanical Turk**. In: PROCEEDINGS OF THE 17TH AMERICAS CONFERENCE ON INFORMATION SYSTEMS (AMCIS 2011). Detroit, Michigan: Association for Information Systems, 2011.

KELLY, Jamie Terence. **Free robot labour: Marx, automation, and the future of AI**. Cham: Palgrave Macmillan, 2026.

KUTLU, Mucahid; MCDONNELL, Tyler; ELSAYED, Tamer; LEASE, Matthew. **Annotator rationales for labeling tasks in crowdsourcing**. Journal of Artificial Intelligence Research, v. 69, p. 143-189, 2020.

LE LUDEC, Clément; CORNET, Maxime; CASILLI, Antonio A. **The problem with annotation**. Human labour and outsourcing between France and Madagascar. *Big Data & Society*, London, v. 10, n. 2, p. 1-13, July/Dec. 2023.

LEE, Hwiyoung; CHEN, Shuo. **Systematic bias of machine learning regression models and correction**. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 47, n. 6, p. 4974-4983, 2025.

LEE, Jin Ha. **Crowdsourcing music similarity judgments using Mechanical Turk**. In: PROCEEDINGS OF THE 11TH INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR 2010). Utrecht: ISMIR, 2010.

MANOVICH, Lev; ARIELLI, Emanuele. **Artificial aesthetics**: generative AI, art and visual media. [S. l.], 2024. Disponível em: <https://manovich.net/index.php/projects/artificial-aesthetics>. Acesso em: 6 jul. 2026.

MARINO, Mark C. **Critical code studies**. Cambridge, MA: MIT Press, 2020.

MEZZADRA, Sandro; NEILSON, Brett. **The politics of operations**: excavating contemporary capitalism. Durham: Duke University Press, 2019.

MOKOENA, Nontokozo; OBAGBUWA, Ibidun Christiana. **An analysis of artificial intelligence automation in digital music streaming platforms for improving consumer subscription responses**: a review. *Frontiers in Artificial Intelligence*, v. 7, artigo 1515716, 2025.

MULDOON, James; WU, Boxi A. **Artificial Intelligence in the Colonial Matrix of Power**. *Philosophy & Technology*, 2023.

NDLOVU-GATSHENI, Sabelo J. **The cognitive empire, politics of knowledge and African intellectual productions**: reflections on struggles for epistemic freedom and resurgence of decolonisation in the twenty-first century. *Third World Quarterly*, 2020.

OSTERMANN, F.; VATOLKIN, I.; EBELING, M. **AAM**: a dataset of artificial audio multitracks for diverse music information retrieval tasks. *EURASIP Journal on Audio, Speech, and Music Processing*, v. 2023, n. 1, p. 1–26, 2023.

PASQUINELLI, Matteo. **The eye of the master**: a social history of artificial intelligence. London: Verso, 2023.

SAMIOTIS, Ioannis Petros; QIU, Sihang; LOFI, Christoph; YANG, Jie; GADIRAJU, Ujwal; BOZZON, Alessandro. **An analysis of music perception skills on crowdsourcing platforms**. *Frontiers in Artificial Intelligence*, v. 5, artigo 828733, 2022.

SCHMIDT, Gordon B.; JETTINGHOFF, William M. **Using Amazon Mechanical Turk and other compensated crowdsourcing sites**. *Business Horizons*, v. 59, n. 4, p. 391-400, 2016.

SEAYER, Nick. **Algorithms as culture**: some tactics for the ethnography of algorithmic systems. *Big Data & Society*, v. 4, n. 2, p. 1-12, 2017.

SHUKLA, Nishanshi. **Investigating AI systems**: examining data and algorithmic bias through hermeneutic reverse engineering. *Frontiers in Communication*, v. 10, artigo 1380252, 2025.

STRICKLAND, Justin C.; STOOPS, William W. **The use of crowdsourcing in addiction science research**: Amazon Mechanical Turk. *Experimental and Clinical Psychopharmacology*, v. 27, n. 5, p. 501-512, 2019.

STURM, B. L. T.; SANTOS, J. F.; KORSHUNOVA, I. Folk music style modelling by recurrent neural networks with long short term memory units. In: **16th International Society for Music Information Retrieval Conference, Late-Breaking Demo Session**. Malaga, Spain, 2015. p. 2. Disponível em: <http://hdl.handle.net/1854/LU-7053070>. Acesso em: 6 jul. 2026.

THOM, R. **Esquisse d'une sémiophysique**: physique aristotélicienne et théorie des catastrophes. Paris: InterÉditions, 1988.

TOXTLI, Carlos; SURI, Siddharth; SAVAGE, Saiph. **Quantifying the invisible labor in crowd work**. Proceedings of the ACM on Human-Computer Interaction, v. 5, n. CSCW2, p. 1-26, 2021.

WHITE, Christopher W. **The AI music problem: why machine learning conflicts with musical creativity**. New York: Routledge, 2025.

XIAO, Tianqi; FUSO NERINI, Francesco; MATTHEWS, H. Damon; TAVONI, Massimo; YOU, Fengqi. **Environmental impact and net-zero pathways for sustainable artificial intelligence servers in the USA**. Nature Sustainability, v. 8, p. 1541-1553, 2025.

YANG, Yifan; MAVROGIORGIS, Konstantinos; QIN, Yiming; LI, Hongmin; XU, Weiping; ZHANG, Y. **A survey of recent methods for addressing AI fairness and bias in biomedicine**. Journal of Biomedical Informatics, v. 154, p. 104646, 2024.

ZHOU, M.; XU, S.; LIU, Z.; WANG, Z.; YU, F.; LI, W.; HAN, B. **CCMusic: An Open and Diverse Database for Chinese Music Information Retrieval Research**. Transactions of the International Society for Music Information Retrieval, v. 8, n. 1, p. 22-38, 2025.

Recebido em 22/02/2026

Aceito em 07/07/2026