

Os Potenciais Impactos Ético Legais da Aplicação de Modelos Generativos de Áudio na Música

João Pedro de Matos D' Assumpção¹, Gilberto Martins de Almeida², Mariza Ferro¹

¹Instituto de Computação – Universidade Federal Fluminense (UFF)
Av. Gal. Milton Tavares de Souza, S/Nº, São Domingos – Niterói – RJ – Brasil.

²Departamento de Direito - Pontifícia Universidade Católica do Rio de Janeiro (PUC-RJ)
Rua Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ - Brasil.

{jod, mariza_ferro}@id.uff.br

gilberto@mda.com.br

Abstract. *With recent advances in generative algorithms, the use of models for audio generation has become increasingly common, bringing with it several implications, in particular, in the field of music. However, little researches discuss such impacts figuring out in a gap in the literature of works discussing this issue. This article discusses the main ethical consequences of the increasing use of generative audio models in the music industry. The focus is on possible negative impacts, such as the danger of erasure of marginal musical genres, the depletion of creativity, and the impacts of generative models on the environment, in addition to potential ethical-legal implications. Recommendations are made to avoid, or at least mitigate, the potential risks and harms discussed.*

Resumo. *Com os recentes avanços em algoritmos generativos, o uso de modelos para geração de áudio se torna cada vez mais comum trazendo consigo diversas implicações, em particular, no campo da música. No entanto, poucas pesquisas discutem tais impactos, de forma que a literatura carece de estudos que discorram sobre essa questão. Este artigo discute as principais consequências éticas do crescente uso de modelos generativos de áudio na indústria musical. O foco está nos possíveis impactos negativos, como o perigo de apagamento de gêneros musicais marginais, o esgotamento de criatividade, e os impactos de modelos generativos no meio ambiente, além de potenciais implicações ético-legais. Recomendações são feitas para evitar, ou ao menos mitigar, os potenciais riscos e danos discutidos.*

1. Introdução

A utilização da Inteligência Artificial (IA) para a criação musical é um tópico que passou a ser frequentemente debatido atualmente. Devido aos recentes avanços nos estudos de algoritmos generativos, em particular com o uso de Transformer [Vaswani et al. 2017] e sua variante para música [Huang et al. 2018], há um renovado interesse em pesquisas que envolvam a geração de músicas através de modelos computacionais. Algumas dessas aplicações já afetam a sociedade, como a polêmica envolvendo o *rapper* canadense Drake em abril de 2023 pela criação da música (*Heart On My Sleeve*) usando sua voz sem o seu consentimento. Eventos como este geram discussões sobre o papel da computação nos

processos criativos, e o interesse de corporações e pesquisadores neste tema é cada vez maior.

Toda aplicação de IA traz consigo uma gama de possíveis implicações éticas a se considerar, e apesar de haver diversos impactos possíveis destes modelos para a sociedade, poucos estudos da área consideram essas potenciais implicações na música [Barnett 2023]. Tendo em mente a crescente relevância e popularidade da aplicação de IA à arte, bem como a ausência de um debate mais ostensivo acerca das consequências dessa aplicação na sociedade, este trabalho tem como objetivo discutir os potenciais impactos éticos negativos que o desenvolvimento e implementação de modelos generativos musicais podem ter, além dos aspectos legais correlatos.

Na Seção 2 é feita uma breve apresentação sobre o tema música e computação. Na Seção 3 são apresentados os principais desafios da aplicação de algoritmos de IA generativa às composições musicais. Cada subseção corresponde a uma etapa de desenvolvimento, explicando sucintamente o processo e esclarecendo as possíveis implicações éticas de cada passo. Na Seção 4 são retomadas todas as questões éticas comentadas, discutindo inclusive alguns aspectos legais correlatos, e as consequências potenciais discutidas nas seções anteriores.

2. Computação e Música

O interesse na união entre algoritmos e música não é recente: Mozart praticava sua técnica de composição jogando dados para escolher aleatoriamente elementos musicais. A conexão entre Inteligência Artificial e música também não é nova: Ada Lovelace discutiu essa possibilidade nas notas de tradução de *Sketch of The Analytical Engine* [Menabrea and Lovelace 1842]. No final dos anos 1950, já havia composições feitas por computadores, como a *Illiad Suite*, que utilizava cadeias de Markov para criar uma composição algorítmica [Civit et al. 2022]. Porém, foi o desenvolvimento de arquiteturas complexas, como as redes neurais recorrentes e convolucionais, e o aumento do poder computacional disponível para pesquisadores que permitiram a significativa popularização da área.

Atualmente, as arquiteturas mais comuns em pesquisas de modelos generativos musicais são variações de redes neurais profundas (*Deep Learning* - DL), em especial arquiteturas convolucionais e recorrentes [Civit et al. 2022]. Um grande motivador para o uso de técnicas de DL foi o desenvolvimento do Transformer musical [Huang et al. 2018], que adaptou o poderoso mecanismo de atenção do Transformer para o contexto de geração de música. Assim, redes neurais e arquiteturas híbridas como o *Variational Autoencoder* (VAE) dominam as pesquisas da área [Briot 2020]. A maior parte dos estudos que não adotam esses dois tipos de arquitetura optam por algoritmos genéticos [Wen and Ting 2020], tentando utilizar o elemento de aleatoriedade das populações para simular a originalidade artística.

Em geral, há dois principais objetivos para o desenvolvimento de modelos generativos para música. O primeiro deles é o desenvolvimento de modelos que possam automatizar o processo criativo por completo, substituindo o trabalho de artistas. Esse tipo de modelo tem como público-alvo pessoas com pouco conhecimento de teoria musical e frequentemente utiliza como *input* do usuário palavras-chave, imagens, ou até vídeos. [Frid et al. 2020] apresenta um modelo desse tipo, que cria uma composição a

partir de um arquivo de vídeo fornecido e uma música que exemplifique o *output* desejado. Apesar de haver interesse em modelos com esse objetivo, a maior parte da literatura foca em ferramentas de IA que auxiliem o processo de composição de um artista. Um exemplo deste tipo de modelo, chamado de modelo de co-criação ou modular, é o Coconet [Huang et al. 2019], que recebe uma melodia como *input* e retorna uma melodia criada com base na técnica musical de contraponto. Há uma grande variedade de modelos desse tipo, desde os que geram harmonia para uma dada melodia, até os que geram seções inteiras de música [Huang et al. 2020]. O que modelos desse tipo têm em comum é a suposição que o usuário possui conhecimento musical significativo, e a expectativa que a saída gerada não será a música final, e sim uma etapa na composição.

Modelos de co-criação também são variados em seus objetivos mais específicos. Apesar de todos terem como foco geral a integração humano-máquina, os seus possíveis posicionamentos no processo de composição são diversos. [Huang et al. 2020] reportam como o uso de IA durante a criação artística conjunta teve efeitos diferentes no contexto de uma competição de composição. Enquanto alguns modelos buscavam estabelecer uma comunicação humano-máquina, com um processo interativo em que cada elemento era conjuntamente composto, outros funcionavam como ferramenta auxiliar para a composição conjunta entre duas ou mais pessoas. O ponto de partida comum oferecido por estes tipos de modelos foram fundamentais para uma colaboração efetiva e dinâmica em diversos grupos de compositores [Huang et al. 2020]. É interessante notar que a função de “cola social” oferecida por modelos do segundo tipo parece ser preferido por compositores, principalmente por ferramentas desse tipo serem responsáveis por pouca parte do processo criativo.

3. Pipeline de Desenvolvimento e Implicações Relacionadas

O foco desta seção é analisar etapas do *pipeline* de desenvolvimento de um modelo generativo de música e seus possíveis impactos éticos, pois cada passo traz consigo implicações potenciais que devem ser mencionadas. Primeiramente, é elaborado como é feita a representação de música para o modelo. Em seguida, será discutido o passo de delineamento dos objetivos de aprendizado. Por fim, será discutido o método de avaliação do *output* e o custo envolvido com o treinamento.

3.1. Representação

Um dos maiores desafios no treinamento de modelos para aplicação em música é a representação das composições sendo analisadas. A escolha do formato que um algoritmo receberá como entrada é componente fundamental do planejamento do modelo. A representação simbólica tenta se aproximar da representação por partitura, comum na teoria musical ocidental. Nela, são representadas tanto as notas sendo tocadas, quanto a sua duração. Uma dificuldade de traduzir partituras para uma estrutura computacional está na possibilidade de várias notas, de durações diferentes, serem tocadas ao mesmo tempo. Isso motivou muitos estudos a focarem somente na geração de melodias (chamada de geração monofônica) [Briot 2020]. Para a geração polifônica, que permite a ocorrência de mais de uma nota em um instante, é comum uma estrutura similar ao *piano roll*, usando um vetor em que cada elemento é uma variável indicadora informando a presença ou não de uma nota em um determinado instante de tempo. Outra forma comum de representação é através do MIDI (*Musical Instrument Digital Interface*), que difere do *piano roll* por

possuir atuadores ligados a sons dos instrumentos. Ainda há a representação de áudio, que utiliza um arquivo de áudio como *input*.

Apesar de alguns modelos serem arquitetados para utilizar representação de áudio, a maioria dos estudos mais citados da área usam representação simbólica [Civit et al. 2022]. Esse fato se deve ao treinamento por representação simbólica ser menos intensivo computacionalmente, já que discretiza o tempo da música, enquanto a representação por áudio considera o tempo contínuo [Briot 2020]. O grande desafio da representação simbólica, no entanto, é o trabalho manual de transcrever cada música da base de treinamento para o formato desejado. É natural, portanto, que a maioria dos modelos treinados com representação simbólica não utilizem bases originais, optando por bases disponíveis publicamente. As bases de dados mais comumente utilizadas são a *Lakh*, a *Nottingham*, e a *piano-midi dataset* [Civit et al. 2022]. A dificuldade de produzir uma base simbólica, juntamente com a necessidade de grande volume de dados para treinamento, fazem com que haja um forte viés da produção de modelos de IA generativos musicais em favor dessas bases mais comuns, que são compostas majoritariamente de músicas produzidas em países ocidentais e desenvolvidos.

Algoritmos genéticos não utilizam bases de treino, e optam por limitações baseadas em regras de teoria musical, escolhidas com base no objetivo do modelo. [Wen and Ting 2020], por exemplo, busca gerar melodias de Bossa Nova e, para isso, usa uma função *fitness* que penaliza certas propriedades melódicas, como repetição da mesma nota por dois períodos de tempo ou distâncias grandes entre duas notas. Apesar dessas regras serem geradas com base no objetivo do estudo, pode ser difícil estabelecer limitações quando as ferramentas de análise da teoria musical ocidental não são adequadas.

Outra questão importante sobre a escolha de representação é que o uso de símbolos, por ser uma forma de modelar o áudio, deve escolher quais características informar e quais omitir. Ou seja, a representação simbólica é menos fiel que a em áudio. Assim, certos elementos devem ser ignorados com esse modelo de representação. Um exemplo é o timbre, que diz respeito à qualidade do som. Tocar a mesma nota em dois instrumentos diferentes, ou até mesmo no mesmo instrumento mas utilizando técnicas diferentes, pode gerar sons muito distintos, fato que é explicado por uma análise de timbre. No entanto, tanto a representação piano-roll quanto a MIDI não incluem nenhum elemento de qualidade sonora. Apesar de ser possível relevar esse fato para a música ocidental, outras regiões, como a Índia, possuem músicas regionais fortemente ditadas pelo timbre e pela presença de dinâmicas (isto é, o quão forte ou fraca uma nota é tocada). Similarmente, certos gêneros têm um enfoque no ritmo, relegando melodia e harmonia para o segundo plano. A falta de modelos de representação simbólica que permitam expressividade de timbre e ritmo tem como implicação potencial a exclusão de gêneros regionais dos estudos de geração de música, com o potencial de marginalizar culturalmente comunidades com músicas típicas de difícil modelagem. De fato, [Huang et al. 2020] aponta que poucos modelos existentes têm um foco na produção de ritmos.

3.2. Objetivos do aprendizado

Uma questão muito relevante no estudo de algoritmos generativos aplicados à arte num geral, e música em específico, é o delineamento do objetivo do aprendizado.

Em outras palavras, que função que deve ser maximizada ou minimizada durante o processo de treinamento. Muitos estudos utilizam alguma métrica baseada em reconstrução, estimulando o modelo a gerar resultados parecidos com os exemplos de treino. Apesar da ideia por trás ser do *output* ter qualidade similar ao conjunto de treino, o resultado prático é tornar tipicidade, e não inovação, o objetivo do treinamento [Chemla-Romeu-Santos and Esling 2022]. A difusão dessa forma de traçar objetivos, juntamente com o uso supracitado do mesmo punhado de bases de treino, pode levar à uma situação de sufocamento criativo, na qual diversos modelos treinados independentemente possuem resultados muito parecidos, e pouco inovadores. Esse prospecto é particularmente preocupante quando consideramos a possibilidade de ferramentas de IA para criação de música terem grande presença na indústria musical em um futuro próximo. Algoritmos genéticos não estão a salvo dessa possibilidade: o uso excessivo de restrições teóricas na formulação da função *fitness* pode ter como resultado a punição de gerações inovadoras, além de reforçar um viés ocidental.

3.3. Avaliação e custo dos modelos

Um desafio comum em toda a área de algoritmos generativos é a dificuldade de avaliar o produto dos modelos treinados. Nas aplicações à música, há três métodos comumente utilizados: a avaliação humana, a avaliação por regras, e a avaliação por aprendizado [Wen and Ting 2020]. A primeira realiza um teste às cegas e pede para pessoas classificarem se uma música é gerada por IA ou não, similar a um teste de Turing. A avaliação por regras utiliza um conjunto de características, consideradas pelos pesquisadores como desejáveis, para determinar a qualidade do produto. Por fim, a avaliação por aprendizado usa um modelo pré-treinado para julgar o *output* do algoritmo generativo.

Os três métodos possuem implicações éticas em potencial. Para a avaliação humana, uma falta de cuidado na escolha dos avaliadores pode levar a um modelo que favoreça o viés de uma determinada cultura. Um grupo multicultural de avaliadores alivia esse impacto. A avaliação por regras pode desincentivar o estudo de gêneros musicais que não são bem explicados pela teoria musical ocidental. Já a avaliação por aprendizado introduz a dificuldade de conter o viés tanto do modelo de avaliação quanto do modelo generativo, além de aumentar o custo de treino necessário para a pesquisa. Para este último caso, seria fundamental escolher bem a base de treinamento do modelo avaliador.

Uma característica de modelos treinados com redes neurais é o seu alto custo de treino e inferência. [Douwes et al. 2021] apontam que, apesar do consumo energético de modelos generativos baseados em redes neurais não ser risível (podendo chegar a equivaler ao consumo diário médio de sete pessoas nos Estados Unidos) [Strubell et al. 2019, Verdecchia et al. 2023], poucos estudos sequer discutem esse impacto. Com uma ênfase cada vez maior de organizações internacionais na importância de diminuir os impactos ambientais, e considerando a prevalência de modelos de Deep Learning na área, é imperativo que estudos em algoritmos generativos num geral, e na aplicação à música em específico, passem a não só medir e reportar métricas de consumo energético, como também considerá-las na avaliação do modelo, ao invés de focar somente no desempenho preditivo.

O alto custo de treino desses modelos também causa uma alta barreira de entrada para o estudo de algoritmos generativos de música. O treinamento e a inferência através

dessas ferramentas requerem significativo investimento em *hardware*, o que elitiza a pesquisa na área. Assim, culturas marginais podem facilmente ser excluídas do desenvolvimento teórico e prático desse tipo de modelo, dependendo do interesse corporativo para serem representadas. Nesse sentido, é imperativo o desenvolvimento de algoritmos mais eficientes que permitam uma maior democratização de algoritmos generativos no geral.

4. Discussão

Um dos maiores riscos existentes com a adoção de ferramentas de IA na indústria musical é o apagamento de culturas marginais. Como discutido na seção anterior, alguns fatores apontam para essa possível realidade: os modelos representativos utilizados pela maior parte dos pesquisadores não levam em conta elementos fundamentais da música de culturas não hegemônicas; as bases de dados mais populares para treinamento são compostas majoritariamente de músicas da cultura dominante; o treinamento e inferência muitas vezes dependem em algum grau de regras de teoria musical ocidental, que frequentemente reforçam um viés ocidental; a alta barreira de entrada para a pesquisa na área dificulta a representatividade de culturas de países em desenvolvimento ou culturas minoritárias em países desenvolvidos. Assim, um futuro no qual ferramentas de geração de música adotadas pela indústria não contemplam comunidades minoritárias se torna cada vez mais possível. Esse processo impacta também a cultura *mainstream*, uma vez que uma das características da música contemporânea é a mistura de gêneros. O foco na reprodução de padrões ocidentais e hegemônicos pode ter como consequência um esgotamento de criatividade, com ferramentas de IA “regurgitando” as mesmas ideias.

Cabe aqui uma breve discussão acerca de teoria musical. É importante frisar que não há uma teoria musical unificada. Similarmente como ocorre na matemática, diferentes fenômenos requerem diferentes teorias e *frameworks*, e a teoria musical busca modelar o entendimento musical e explicar certas tendências. Dessa forma, regiões diferentes possuem teorias diferentes com ferramentas distintas. Como mencionado na seção anterior, a teoria musical ocidental, baseada nas práticas de orquestras e concertos da Europa Ocidental, possui poucos conceitos que expliquem a possível complexidade de timbre em composições. Isso é resultado da música fortemente baseada em movimento harmônico e melódico que dominou aquela região, e que deixou traços na música popular contemporânea. Por outro lado, a música indiana dá muita importância ao movimento de timbre. Não é incomum uma composição possuir pouquíssimo movimento harmônico durante toda a sua duração, focando na manipulação da qualidade da nota. Assim, a teoria musical indiana foi desenvolvida buscando explicar esse tipo de variação, e abrindo mão de explicar propriamente a complexidade harmônica da música europeia. Assim como a teoria musical ocidental não possui estrutura para explicar a música indiana, a teoria musical indiana não foi feita para explicar a música europeia. Com isso, espera-se que fique claro o perigo da predominância da teoria musical ocidental como medidor de qualidade em estudos de algoritmos generativos.

Outro tópico pertinente é o impacto ambiental do treinamento e da inferência desses modelos. Como discutido, o custo energético do processo de desenvolvimento é altíssimo, mas a maioria dos estudos o ignora e foca apenas na qualidade do resultado. Com a crescente necessidade de uma IA sustentável, é importantíssimo que esse impacto seja considerado não só pela sua inclusão nos estudos, mas também como parte da avaliação do modelo.

Há ainda a serem mencionados aspectos legais indissolavelmente ligados a questões éticas. Um deles é de que no campo do Direito de Autor, as obras ensejam dois tipos de direitos: os patrimoniais, que são livremente negociáveis, e os morais, que são inegociáveis. Ou seja, estes últimos são tão eticamente ligados à personalidade do autor, que a ele pertencerão perpetuamente, sendo intransferíveis a terceiros – por exemplo, a editoras e gravadoras.

E quais são esses direitos morais? De interesse para o tema deste artigo, seguem alguns exemplos: “IV - o de assegurar a integridade da obra, opondo-se a quaisquer modificações ou à prática de atos que, de qualquer forma, possam prejudicá-la ou atingi-lo, como autor, em sua reputação ou honra;”, “V - o de modificar a obra, antes ou depois de utilizada;” e “VI - o de retirar de circulação a obra ou de suspender qualquer forma de utilização já autorizada, quando a circulação ou utilização implicarem afronta à sua reputação e imagem;”. Resumindo: se o uso de modelos generativos prejudicar a reputação, honra ou imagem do autor ou da obra, esse uso pode ser impugnado.

Outro aspecto legal e ético é o relacionado à voz. Ela é considerada como um dado pessoal biométrico. Então, não pode – exceto se consentido pelo autor-intérprete - ser livremente “transferida” para uma composição ou execução distinta da original em que foi gravada. Isto porque como dado pessoal, ela identifica o intérprete e depende do consentimento dele como dado pessoal, e como atributo associado à interpretação, ela depende do consentimento do intérprete para uma nova forma de exploração.

Diferente pode ser a situação em relação ao uso de um instrumento musical, como a guitarra. Em tese, ela não é tão pessoal quanto a voz. Portanto, será preciso verificar o quanto o uso de determinada guitarra era relevante para caracterizar a originalidade de certa música. Se muito relevante, a modificação deverá passar um escrutínio, e vice-versa.

Por último, mas não menos importantes, os aspectos da independência e da originalidade, que são os dois requisitos caracterizadores do Direito de Autor. Se um sistema de IA for alimentado com uma ou poucas composições ou execuções musicais, delas será mais dependente, e isso vai contra o requisito de criação independente. E se ao fim do processamento pelo sistema resultar uma obra ainda similar à que tenha sido alimentada no sistema, isto ferirá o requisito da originalidade. Portanto, nesses pontos, a lei parece convergir com a ética no sentido de que contraria o senso comum e a boa fé “pegar carona”, demasiadamente, em obras preexistentes, de compositores ou intérpretes.

Embora tais questões ético-legais ainda não se encontrem suficientemente amadurecidas (a exemplo de recente ação judicial nos EUA movida pelo *New York Times* contra OpenAI e Microsoft acusando-as de uso massivo - ou seja, aspecto quantitativo, além do qualitativo - de materiais jornalísticos), é importante que se chame a atenção, na literatura, para o cruzamento ético-legal presente nesses aspectos.

5. Considerações Finais

Este trabalho traz uma contribuição sobre as implicações que a computação pode trazer para a nossa sociedade, em especial, foram discutidos os principais impactos éticos potenciais do crescente uso de algoritmos generativos aplicados à música. Foi discutido como, em cada etapa do processo de desenvolvimento desses modelos, há o risco de criar impactos na sociedade, com culturas marginalizadas correndo maior risco de sofrer com essas

possíveis implicações. Após o exposto, fica clara a necessidade de tomar medidas para garantir o desenvolvimento e uso éticos de algoritmos generativos na arte como um todo, e na música em específico - inclusive em função de alguns aspectos legais nitidamente ligados a preocupações éticas. Como em outras áreas da computação, a acessibilidade dos métodos computacionais e o foco em grupos plurais de pesquisadores é fundamental para garantir a representatividade de culturas marginais. Além disso, uma maior atenção com o consumo energético dos modelos generativos é essencial em uma realidade de crescente preocupação com impactos ambientais, não só na geração de músicas, mas para todo desenvolvimento com grandes modelos de IA.

Em trabalhos futuros será feita uma revisão sistemática da literatura, procurando aprofundar como a sociedade está se posicionando diante deste tema e aprofundar o debate de como o direito do autor vêm se relacionando com as implicações éticas.

Agradecimentos

Este trabalho recebeu apoio da FAPERJ - Auxílio Básico à Pesquisa - APQ1 E_13/2023 (Proc.N:210.723/20240).

Referências

- Barnett, J. (2023). The ethical implications of generative audio models: A systematic literature review. *AIES '23: Proceedings of the 2023 AAAI/ACM Conference on AI, Ethics, and Society*.
- Briot, J.-P. (2020). From artificial neural networks to deep learning for music generation: history, concepts and trends. *Neural Comput & Applic*, 33:39–65.
- Chemla-Romeu-Santos, A. and Esling, P. (2022). Challenges in creative generative models for music: a divergence maximization perspective.
- Civit, M., Civit-Masot, J., Cuadrado, F., and Escalona, M. J. (2022). A systematic review of artificial intelligence-based music generation: Scope, applications, and future trends. *Expert Systems with Applications*, 209:118–190.
- Douwes, C., Esling, P., and Briot, J. (2021). A multi-objective approach for sustainable generative audio models. *CoRR*, abs/2107.02621.
- Frid, E., Gomes, C., and Jin, Z. (2020). Music creation by example. In *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, CHI '20, page 1–13, New York, NY, USA. Association for Computing Machinery.
- Huang, C. A., Cooijmans, T., Roberts, A., Courville, A. C., and Eck, D. (2019). Counterpoint by convolution. *CoRR*, abs/1903.07227.
- Huang, C. A., Koops, H. V., Newton-Rex, E., Dinculescu, M., and Cai, C. J. (2020). AI song contest: Human-AI co-creation in songwriting. *CoRR*, abs/2010.05388.
- Huang, C. A., Vaswani, A., Uszkoreit, J., Shazeer, N., Hawthorne, C., Dai, A. M., Hoffman, M. D., and Eck, D. (2018). An improved relative self-attention mechanism for transformer with application to music generation. *CoRR*, abs/1809.04281.
- Menabrea, L. F. and Lovelace, A. (1842). Sketch of the analytical engine invented by Charles Babbage.

- Strubell, E., Ganesh, A., and McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *CoRR*, abs/1906.02243.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is all you need. *CoRR*, abs/1706.03762.
- Verdecchia, R., Sallou, J., and Cruz, L. (2023). A systematic review of green ai. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13.
- Wen, Y.-W. and Ting, C.-K. (2020). Composing bossa nova by evolutionary computation. In *2020 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.