

Mapeamento Sistemático da Literatura sobre Detecção de Pessoas Negras em Obras Audiovisuais com Visão Computacional

Anne G. M. Ávila¹, Gabriel M. O. Machado², Maria de Jesus do Nascimento¹,
Raquel Silveira¹, Carina Teixeira de Oliveira¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

²Universidade Federal do Ceará (UFC)

anne.avila10@aluno.ifce.edu.br, gabrielmarinho@alu.ufc.br,
{jesus.nascimento, raquel.silveira, carina.oliveira}@ifce.edu.br

Abstract. *This study presents a Systematic Literature Mapping (SLM) on the use of Computer Vision for analyzing the representation of Black people in audio-visual productions. The objective is to identify the predominant methodologies used for detecting Black individuals and the persistent gaps in the field. The research followed the PRISMA methodology, resulting in 23 selected studies published between 2020 and 2025. The findings indicate that although models such as YOLO, ResNet, and VGG achieve high overall accuracy, there are racial disparities in model performance. Furthermore, there is limited ethical concern regarding data curation, and approaches that consider phenotypic and cultural diversity remain scarce.*

Resumo. *Este trabalho apresenta um Mapeamento Sistemático da Literatura sobre o uso de Visão Computacional na análise da representatividade de pessoas negras em produções audiovisuais. O objetivo é identificar quais metodologias predominam na detecção de pessoas negras e as lacunas persistentes na área. A pesquisa seguiu a metodologia PRISMA, resultando em 23 estudos selecionados no período de 2020 a 2025. Os resultados indicam que, embora modelos como YOLO, ResNet e VGG apresentem alta acurácia no geral, há desigualdades raciais nos desempenhos dos modelos. Além disso, há uma baixa preocupação ética com a curadoria de dados e ainda são escassas as abordagens que consideram a diversidade fenotípica e cultural.*

1. Introdução

A exclusão sistemática de pessoas negras da centralidade das narrativas audiovisuais constitui um reflexo direto das estruturas de poder que sustentam a sociedade moderna desde o período colonial. Fruto da consolidação do sistema escravocrata e da exploração de corpos racializados como força de trabalho, a racialização não é uma condição natural, mas uma construção histórica que acompanha o projeto de modernidade ocidental [Quijano 2005].

A presença negra continua sendo marcada pela marginalização social, pela desigualdade econômica e pela invisibilidade midiática. Como aponta [Hooks 2023], o cinema dominante, ainda que por vezes se apresente como progressista, está profundamente enraizado nas estruturas do “patriarcado supremacista branco capitalista”, reproduzindo e

naturalizando hierarquias de raça, gênero e classe. Assim, os meios de comunicação não apenas refletem a desigualdade estrutural, mas participam ativamente de sua produção simbólica e de seu processo de legitimação.

Relatórios recentes, como o *Annenberg Inclusion Initiative* da *University of Southern California* da [Neff et al. 2025], confirmam a persistência dessa exclusão em escala global: entre 1.800 filmes populares analisados, apenas 25% tiveram protagonistas de grupos racialmente sub-representados. A sub-representação de pessoas negras nas telas, portanto, evidencia um descompasso entre a diversidade real das sociedades contemporâneas e sua expressão simbólica nos meios de comunicação.

Contudo, estudos apontam que esses sistemas frequentemente reproduzem os mesmos vieses estruturais presentes nas representações tradicionais [Luccioni et al. 2023]. Ferramentas de reconhecimento facial, por exemplo, tendem a apresentar maiores taxas de erro na identificação de pessoas negras, especialmente mulheres, o que reflete desigualdades na composição dos conjuntos de dados e na curadoria de imagens [Buolamwini and Gebru 2018]. Esses vieses técnicos expressam uma dimensão política e epistêmica mais profunda: os algoritmos operam dentro de estruturas sociais que definem quem é visto, quem é reconhecido e sob quais parâmetros [Bento 2017].

Diante desse contexto, este trabalho apresenta um Mapeamento Sistemático da Literatura (do inglês, *Systematic Literature Mapping* – SLM) sobre o uso de visão computacional e aprendizado de máquina na análise da representatividade de pessoas negras em produções audiovisuais. O estudo foi desenvolvido em conformidade com as diretrizes *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) [Page et al. 2021], proporcionando transparência e reprodutibilidade nas etapas. O objetivo deste estudo é caracterizar o estado da arte da área, identificar padrões metodológicos, avaliar métricas de desempenho e destacar lacunas que ainda persistem na interface entre tecnologia e justiça racial. Ao integrar discussões sobre desempenho técnico, diversidade de dados e ética algorítmica, o mapeamento busca oferecer uma visão abrangente do campo, sendo um subsídio inicial para a construção de práticas computacionais mais responsáveis e socialmente conscientes.

Este trabalho está organizado da seguinte forma: na Seção 2 são detalhados os trabalhos relacionados. A metodologia de desenvolvimento do SLM é apresentada na Seção 3. Os resultados são discutidos na Seção 4 e, por fim, as considerações finais são apresentadas na Seção 5.

2. Trabalhos Relacionados

Nesta seção, são apresentados trabalhos voltados ao uso de visão computacional e aprendizado de máquina na análise da representatividade racial em produções audiovisuais, de modo a verificar a existência de estudos desenvolvidos nessa temática e compreender os aspectos avaliados e as lacunas metodológicas existentes em cada pesquisa.

Os autores [Malik et al. 2022] utilizaram Redes Neurais Convolucionais (CNN), R-CNNs (CNNs baseadas em regiões) e YOLO para analisar a representatividade racial em filmes de Hollywood. Aplicado a 89 produções, o método identifica vieses visuais e estruturais, oferecendo uma forma escalável e automatizada de avaliar a representatividade de minorias raciais em filmes populares. O trabalho mostra que personagens brancos

recebem mais tempo de tela e ocupam posições centrais nas narrativas, enquanto personagens negros e de outras minorias apresentam menor relevância e menos conexões. Esse estudo evidencia o potencial de métodos computacionais para avaliar de forma escalável vieses raciais em produções audiovisuais.

De forma similar, [Mikaeel et al. 2024] utilizaram *datasets* diversos para a criação de um *dataset* final composto da mistura de imagens de rostos aleatórios de pessoas asiáticas, caucasianas, indianas e africanas para o treinamento de modelos de CNNs para o reconhecimento facial de raças e gêneros. O estudo mostra que ResNet50 teve melhor acurácia em raça, seguido por RGCNN e IncV3, enquanto VGG19 apresentou pior desempenho. O RGCNN destacou-se por ser leve, com menor número de parâmetros.

Os autores [Khan and Fu 2021] realizaram um estudo empírico para analisar a generalização das categorias raciais (como preto, branco, asiático e sul-asiático) em quatro *datasets* (FairFace, BFW, RFW, LAOFIW). Os autores utilizaram um *ensemble* de classificadores (ResNet50) para aprender o "sistema racial" codificado em cada *dataset*. O estudo identifica que cada *dataset* codifica um sistema racial substancialmente único, sendo as categorias preto e asiático menos representadas nos datasets, um sinal de que os classificadores aprendem estereótipos mais frequentes nos dados. Isso, no entanto, leva a uma falha central: a exclusão sistemática de etnias que não se encaixam no estereótipo. Assim, o estudo evidencia que o uso de categorias raciais amplas pode mascarar disparidades e gerar novos vieses ao falhar em representar a diversidade étnica.

O trabalho de [Xu 2023] identifica que a maioria dos bancos de dados de rostos em grande escala utilizados atualmente, como CK+, JAFFE, e AffectNet, são coletados de mídias *online*, resultando em uma representação desproporcional de figuras públicas e, crucialmente, de indivíduos de "pele mais clara" (em torno de 80%), em comparação com rostos de "pele mais escura", como a população negra. Essa desproporção racial e demográfica leva à propagação de vieses: classificadores de gênero apresentaram disparidades de precisão de até 34.4% na detecção de rostos femininos de pele escura em relação a rostos masculinos de pele clara.

Embora esses trabalhos avancem na aplicação de CNNs e *Deep Learning* para reconhecimento facial e análise de representatividade racial, muitas abordagens se baseiam apenas em características fenotípicas, desconsiderando a autodeclaração e o contexto sociocultural, o que pode reforçar estereótipos e vieses algorítmicos. O presente estudo contribui ao propor um SLM nessa temática, destacando metodologias, lacunas e limitações éticas, oferecendo subsídios para o desenvolvimento de abordagens mais inclusivas e conscientes, capazes de analisar a representatividade racial de forma mais ampla e contextualizada. Destaca-se que, até o momento, não foram identificados SLMs com esse enfoque, o que reforça a originalidade e a relevância do presente estudo.

3. Metodologia

Este estudo apresenta um SLM sobre o uso de visão computacional e aprendizado de máquina na detecção e análise da representatividade de pessoas negras em produções audiovisuais. A pesquisa busca caracterizar o estado da arte da área, mapear tendências metodológicas, destacar boas práticas e apontar lacunas que possam orientar futuras investigações, contribuindo para o avanço da aplicação de técnicas de IA de forma ética e socialmente responsável no estudo da representatividade racial.

Para a condução do SLM utilizou-se a metodologia PRISMA [Page et al. 2021], de modo a fornecer uma abordagem sistemática para a coleta do estado da arte.

3.1. Definição das Questões de Pesquisa (QPs)

Nesta etapa, as QPs foram elaboradas para atender aos objetivos do mapeamento sistemático, abrangendo aspectos centrais da aplicação de visão computacional e técnicas de aprendizagem de máquina na análise da presença e representatividade de pessoas negras em produções audiovisuais. Assim, as QPs definidas para guiar este estudo foram:

- QP1: Quais trabalhos utilizaram visão computacional para detectar a presença e representatividade de pessoas negras em filmes e séries?
- QP2: Quais arquiteturas de redes neurais convolucionais (CNNs) ou outros algoritmos de detecção de rostos foram empregados?
- QP3: Quais resultados de desempenho foram obtidos nesses estudos?
- QP4: Como os conjuntos de dados foram construídos, qual a proporção de pessoas negras e como isso influencia a análise de representatividade?
- QP5: Que limitações algorítmicas foram discutidas, incluindo vieses, falhas de detecção ou impactos sociais dessas limitações?

3.2. Definição da Estratégia de Busca

Na segunda etapa, foi estruturada a *string* de busca com termos-chave das áreas de visão computacional, IA e representatividade racial em produções audiovisuais. Assim, estruturou-se a seguinte *string* de busca: ((*“Computer Vision” OR “Deep Learning” OR “Convolutional Neural Network” OR CNN OR YOLO*) AND (*“Facial Recognition” OR “Face Detection” OR “Object Detection”*)) AND (*“Racial Representation” OR “Racial Diversity” OR “Representation in Media” OR “Black Representation” OR “Racial Bias” OR “Algorithmic Justice” OR “Fairness in AI”*) AND (*“Audiovisual” OR “Cinema” OR “Film” OR “Media Studies”*)).

As buscas contemplaram repositórios científicos de relevância nacional e internacional, tais como IEEE Xplore, *Association for Computing Machinery (ACM) Digital Library*, *Nature*, *Amsterdam University Press (AUP)*, *arXiv Proceedings of the National Academy of Sciences (PNAS)*, dada sua representatividade em publicações sobre tecnologia e aplicações sociais da computação. Esses repositórios foram selecionados por sua abrangência nas áreas de ciência da computação, IA e estudos críticos de mídia, incluindo fontes que integram discussões sobre justiça algorítmica e diversidade racial.

As buscas foram realizadas em setembro de 2025, resultando, inicialmente, em um total de 324 trabalhos. Contudo, após a aplicação inicial de um filtro de data (período de 2020 a 2025), 40 trabalhos foram excluídos, resultando em 284 trabalhos na etapa de identificação.

3.3. Seleção e Identificação dos Estudos

Com o objetivo de selecionar os trabalhos mais adequados para responder às QPs, foram definidos critérios de inclusão e exclusão. Os critérios de inclusão exigiam que os estudos fossem nacionais ou internacionais, publicados entre 2020 e 2025, e abordassem de forma direta o tema proposto. Embora a *string* de busca inicial tenha retornado um número expressivo de resultados, muitos trabalhos não apresentavam relação efetiva com o objeto de

estudo, sendo, portanto, excluídos. Também foram desconsiderados artigos não escritos em português ou inglês, duplicados, em andamento ou fora do escopo da pesquisa. Após a aplicação desses critérios, permaneceram 18 trabalhos para a análise final.

Adicionalmente, foram incluídos 5 (cinco) trabalhos pontuais considerados de relevância para a temática, extraídos dos repositórios: Revista da Associação Brasileira de Pesquisadores(as) Negros(as) (ABPN), DergiPark, *ResearchGate* e Repositório de Teses e Dissertações da PUC-SP, totalizando 23 trabalhos para leitura completa e análise final, com o objetivo de responder às questões de pesquisa. A Figura 1 apresenta o fluxograma do processo metodológico de coleta dos trabalhos, conforme metodologia PRISMA.




Figura 1. Fluxograma do processo de identificação, triagem e inclusão dos estudos no SLM (conforme metodologia PRISMA [Page et al. 2021]).

4. Resultados e Discussões

Com base nos estudos selecionados, foram identificadas evidências que permitem responder às questões de pesquisa, oferecendo um panorama sobre o uso de visão computacional na análise da representatividade de pessoas negras em produções audiovisuais. Após a triagem e a aplicação dos critérios de inclusão e exclusão, 23 estudos foram selecionados. A Tabela 1 apresenta esses trabalhos.

4.1. QP1: Quais trabalhos utilizaram visão computacional para detectar a presença e representatividade de pessoas negras em filmes e séries?

Dos 23 estudos analisados, apenas 11 (E2, E4, E6, E8, E11, E12, E13, E14, E16, E18, E21) aplicaram técnicas de visão computacional para detectar rostos de pessoas negras ou avaliar diversidade em produções audiovisuais, indicando que seu uso para mensurar representatividade racial ainda é incipiente. Os 12 restantes focam em aplicações técnicas ou experimentais, sem vínculo com a análise de mídia. Desses, quatro estudos discutem a representação racial apenas de forma conceitual, tratando qualitativamente a representação racial, o racismo algorítmico e a hegemonia da branquitude nas tecnologias de imagem. Assim, a aplicação da visão computacional à análise racial em conteúdos audiovisuais permanece marginal no estado da arte.

Tabela 1. Trabalhos selecionados na revisão

ID	Referência	ID	Referência
E1	[Hoque et al. 2020]	E13	[Kancharlapalli and Dwivedi 2023]
E2	[Irawan et al. 2020]	E14	[Wang 2023]
E3	[Silva 2020]	E15	[Xu 2023]
E4	[Bouraya and Belangour 2021]	E16	[Yucer et al. 2023]
E5	[Khan and Fu 2021]	E17	[Bamman et al. 2024]
E6	[Scheuerman et al. 2021]	E18	[Kumar et al. 2024]
E7	[Steed and Caliskan 2021]	E19	[Mikaeel et al. 2024]
E8	[Aggarwal et al. 2022]	E20	[Silva and Silva 2024]
E9	[Hirota et al. 2022]	E21	[Bhattacharjee and Ribes 2025]
E10	[Kagan et al. 2022]	E22	[Mohammed and Atay 2025]
E11	[Krishnan et al. 2022]	E23	[Rodrigues 2025]
E12	[Malik et al. 2022]		

4.2. QP2: Quais arquiteturas de redes neurais convolucionais (CNNs) ou outros algoritmos de detecção de rostos foram empregados?

A categorização dos algoritmos de aprendizagem de máquina utilizados nos estudos não é exclusiva, pois vários combinam diferentes arquiteturas em um mesmo *pipeline*, como detectores faciais baseados em CNN (RetinaFace, MTCNN, YuNet) e modelos de reconhecimento (ArcFace, FaceNet, InclusiveFaceNet). Ao todo, 19 trabalhos usam algum modelo de aprendizagem de máquina. 14 estudos (60,9%) empregam CNNs em alguma etapa. Sendo que 7 estudos utilizam CNN tradicionais para a classificação e extração de características (ResNet, VGG, Inception, EfficientNet, DenseNet, MobileNet); 11 estudos usam detectores faciais baseados em CNN (RetinaFace, MTCNN, YuNet, Cascade-CNN); 7 estudos usam modelos especializados de reconhecimento facial, voltados à correspondência de identidade ou análise de *embeddings* (ArcFace, FaceNet, InclusiveFaceNet, FSANet, FaceQNet); enquanto que 4 estudos usam detectores generalistas de objetos aplicados a rostos (YOLO, SSD, Faster R-CNN, RetinaNet). Além desses estudos, três estudos usam métodos não *deep-learning* (Haar Cascades, HoG+SVM, ASM, AAM). Enquanto três estudos utilizam modelos não baseados em CNN, como arquiteturas auto-supervisionadas e inspiradas em *transformers* (iGPT, SimCLRv2). Destaca-se que um estudo pode utilizar mais de uma arquitetura. Portanto, o total excede 19 trabalhos quando analisado separadamente, sendo reflexo da sobreposição e da diversidade técnica das abordagens adotadas.

4.3. QP3: Quais resultados de desempenho foram obtidos nesses estudos?

Tem-se que 12 estudos (E1, E2, E4, E6, E7, E8, E12, E13, E14, E18, E20 e E21) apresentaram métricas quantitativas na avaliação de desempenho dos modelos, destacando arquiteturas CNN como ResNet50, DenseNet e LightCNN, com acurácias entre 87% e 100% em bases como LFW, UTKFace, CelebA e FairFace, além de métricas complementares como MAE de 6,5 e ROC-AUC de 0,999. Três trabalhos combinaram detectores

faciais (MTCNN, Dlib) a *embeddings* profundos (ArcFace, FairFace, RetinaFace), aumentando a consistência da detecção e do reconhecimento. Contudo, essas performances não se traduziram em equidade preditiva, com lacunas de até 34,4% entre pele clara e escura e diferenças de 1 a 2 vezes em favor de indivíduos brancos. Essa diferença de desempenho evidencia a persistência de vieses algorítmicos estruturais, frequentemente associados à sub-representação de rostos negros nos conjuntos de dados de treinamento. Os demais estudos abordaram análises qualitativas, evidenciando como conjuntos de dados e modelos reproduzem hierarquias raciais e marginalizam a presença negra. Assim, embora as CNNs alcancem excelência técnica, sua performance permanece concentrada em indivíduos de pele clara, refletindo bases enviesadas e limitações sociais.

4.4. QP4: Como os conjuntos de dados foram construídos, qual a proporção de pessoas negras e como isso influencia a análise de representatividade?

Dos 23 estudos selecionados, 18 detalharam os *datasets* usados, mas apenas dois (E6 e E21) equilibraram a representação racial, mantendo proporções semelhantes entre pessoas negras e outros grupos raciais, com 49,2% e 25% de pessoas negras no *dataset*. A maioria utilizou bases públicas como LFW, UTKFace, CelebA, FairFace e CASIA-Face-Africa sem informar a proporção de negros, refletindo sub-representação histórica. Esse desequilíbrio afeta, naturalmente, o desempenho: modelos treinados majoritariamente com rostos brancos tiveram precisão até 34,4% menor para rostos negros.

Quanto à rotulagem racial, observou-se a ausência de práticas que incorporassem a autodeclaração racial ou o vínculo com a comunidade negra na construção e anotação dos *datasets*. Estudos qualitativos [Rodrigues 2025] [Silva 2020] apontam que a curadoria de dados em visão computacional reproduz hierarquias sociais, revelando que a representatividade racial influencia não apenas a acurácia técnica, mas também a visibilidade simbólica da população negra.

4.5. QP5: Que limitações algorítmicas foram discutidas, incluindo vieses, falhas de detecção ou impactos sociais dessas limitações?

Cerca de 74% dos estudos (17 trabalhos) discutem limitações algorítmicas, sobretudo em desempenho técnico frente a variações de iluminação, pose e resolução, enquanto que, dentre esses, 43% dos estudos (10 trabalhos) abordam vieses raciais, de gênero e impactos sociais, como sub-representação de rostos negros, associações estereotipadas e falhas de detecção em mulheres negras e pessoas trans. Alguns trabalhos situam o viés no contexto sociopolítico, vinculando-o ao colonialismo digital e à hegemonia branca nas tecnologias de reconhecimento facial. Apesar de avanços recentes, apenas uma pequena parcela (3 trabalhos, o que corresponde a 13%) propõe medidas de *fairness* (minimização de vieses discriminatórios), *accountability* (responsabilização de impactos das decisões algorítmicas) e transparência, evidenciando que a precisão técnica ainda predomina sobre a equidade e a responsabilidade social.

5. Considerações Finais

A visão computacional constitui hoje um campo central no desenvolvimento tecnológico e científico, com impactos diretos sobre a forma como o mundo social é percebido, classificado e administrado. Entretanto, os resultados deste mapeamento sistemático evidenciam

que, ao ser aplicada à análise da representatividade racial, essa tecnologia ainda reproduz desigualdades históricas e epistemológicas enraizadas nas estruturas sociais.

Entre os 23 estudos analisados, observou-se uma ausência de práticas que incorporassem a autodeclaração racial ou o vínculo com a comunidade negra na construção e anotação dos conjuntos de dados. Cerca de 90% (n=20) dos trabalhos não fazem menção a esses aspectos, revelando uma perspectiva tecnocêntrica de coleta e classificação, em que as identidades raciais são tratadas como atributos neutros e descontextualizados.

Embora modelos como YOLO, ResNet e VGG apresentem acurácias elevadas em métricas gerais, essas performances não se traduzem em equidade. Os resultados mostraram discrepâncias significativas de desempenho entre tons de pele, bem como sub-representação de pessoas negras nas bases de treinamento, evidências de que os avanços técnicos permanecem subordinados a epistemologias excludentes.

O mapeamento aqui apresentado contribui, assim, para visibilizar lacunas, riscos e potencialidades de um campo que, ao mesmo tempo em que reflete as desigualdades estruturais, também as reproduz, e, portanto, deve ser continuamente tensionado por uma perspectiva de justiça racial e responsabilidade social na ciência de dados. Dessa forma, torna-se necessário utilizar o papel da visão computacional como instrumento de análise e intervenção social, ampliando seu escopo para além da eficiência técnica. A produção de bases de dados diversas deve integrar a autodeclaração racial e a paridade representativa, enfrentando disparidades de desempenho de até 34,4%. A inclusão de pesquisadores negros e o diálogo interdisciplinar são cruciais para priorizar a equidade preditiva sobre a acurácia geral, construindo práticas éticas e socialmente responsáveis.

Como desdobramento futuro, propõe-se a realização de uma pesquisa empírica que utilize técnicas de visão computacional para detectar e quantificar a presença de pessoas negras em produções audiovisuais, integrando informações de autodeclaração racial e contextos socioculturais na construção dos conjuntos de dados. Essa abordagem buscará avaliar de que modo a inclusão dessas dimensões subjetivas e coletivas pode contribuir para reduzir disparidades de desempenho e promover uma compreensão mais justa e complexa da representatividade negra na mídia e na inteligência artificial.

Referências

- Aggarwal, A., Pandya, Y., Ravindranathan, L. A., Ahire, L. S., Sethu, M., and Nandy, K. (2022). Robust actor recognition in entertainment multimedia at scale. In *Proceedings of the 30th ACM International Conference on Multimedia*, MM '22, page 2079–2087, New York, NY, USA. Association for Computing Machinery.
- Bamman, D., Samberg, R., So, R. J., and Zhou, N. (2024). Measuring diversity in hollywood through the large-scale computational analysis of film. *Proceedings of the National Academy of Sciences*, 121(46):e2409770121.
- Bento, M. A. S. (2017). Branqueamento e branquitude no brasil. In Carone, I. and Bento, M. A. S., editors, *Psicologia social do racismo: estudos sobre branquitude e branqueamento no Brasil*, page 645. Editora Vozes, Petrópolis, RJ, Brasil.
- Bhattacharjee, S. and Ribes, D. (2025). Technical responses to critique: The case of skin tone. In *Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems*, CHI '25, New York, NY, USA. Association for Computing Machinery.

- Bouraya, S. and Belangour, A. (2021). Approaches to video real time multi-object tracking and object detection: A survey. In *2021 12th International Symposium on Image and Signal Processing and Analysis (ISPA)*, pages 145–151.
- Buolamwini, J. and Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. In Friedler, S. A. and Wilson, C., editors, *Proceedings of the 1st Conference on Fairness, Accountability and Transparency*, volume 81 of *Proceedings of Machine Learning Research*, pages 77–91. PMLR.
- Hirota, Y., Nakashima, Y., and Garcia, N. (2022). Gender and racial bias in visual question answering datasets. In *ACM Conference on Fairness, Accountability, and Transparency*, New York, NY, USA. Association for Computing Machinery.
- Hooks, B. (2023). *Cinema vivido: raça, classe e gênero no cinema*. Editora Elefante, São Paulo, Brasil, 1 edition. Tradução de Stephanie Borges. Obra original: *Reel to Real: Race, Sex, and Class at the Movies*, 1996.
- Hoque, M. N., Saquib, N., Billah, S. M., and Mueller, K. (2020). Toward interactively balancing the screen time of actors based on observable phenotypic traits in live telecast. *Proc. ACM Hum.-Comput. Interact.*, 4(CSCW2).
- Irawan, E., Mantoro, T., Ayu, M. A., and Asian, J. (2020). Multi-faces recognition in crowd using support vector machine on histogram of gradient. In *2020 6th International Conference on Computing Engineering and Design (ICCED)*, pages 1–4.
- Kagan, D., Levy, M., Fire, M., and Alpert, G. F. (2022). Ethnic representation analysis of commercial movie posters.
- Kancharlapalli, T. P. and Dwivedi, P. (2023). A novel approach for age and gender detection using deep convolution neural network. In *2023 10th International Conference on Computing for Sustainable Global Development (INDIACom)*, pages 873–878.
- Khan, Z. and Fu, Y. (2021). One label, one billion faces: Usage and consistency of racial categories in computer vision. In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, FAccT '21, page 587–597. ACM.
- Krishnan, A., Neas, B., and Rattani, A. (2022). Is facial recognition biased at near-infrared spectrum as well? In *2022 IEEE International Symposium on Technologies for Homeland Security (HST)*, pages 1–7.
- Kumar, D., Kumar, R. K., Garain, J., Kisku, D. R., Sing, J. K., and Gupta, P. (2024). Dem-ufr: Deep ensemble method for enhanced unconstrained face recognition system. In *2024 OITS International Conference on Information Technology (OCIT)*.
- Luccioni, A. S., Akiki, C., Mitchell, M., and Jernite, Y. (2023). Stable bias: Analyzing societal representations in diffusion models.
- Malik, M., Hopp, F., and Weber, R. (2022). Representations of racial minorities in popular movies: A content-analytic synergy of computer vision and network science. *Computational Communication Research*, 4(1):208–253. Publisher Copyright: © Musa Malik, Frederic R. Hopp & René Weber.
- Mikaeel, V., Turan, B., and Abdulrazaq, M. (2024). Facial race and gender recognition based on convolutional neural network models. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 13(3):1–18.

- Mohammed, A.-Q. and Atay, M. (2025). Evaluating the impact of gender on facial expression recognition. In *SoutheastCon 2025*, pages 906–911.
- Neff, K. L., Smith, S. L., and Pierper, K. (2025). Inequality in 1,800 popular films: Examining portrayals of gender, race/ethnicity, lgbtq+ characters with disabilities from 2007 to 2024. In *Annenberg Inclusion Initiative*.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., McGuinness, L. A., Stewart, L. A., Thomas, J., Tricco, A. C., Welch, V. A., Whiting, P., and Moher, D. (2021). The prisma 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, page n71.
- Quijano, A. (2005). Colonialidade do poder, eurocentrismo e américa latina. In *A colonialidade do saber: eurocentrismo e ciências sociais. Perspectivas latino-americanas*. CLACSO – Consejo Latinoamericano de Ciencias Sociales, Buenos Aires, Argentina.
- Rodrigues, A. M. d. S. (2025). É uma questão de dados? o ponto de vista do negro em relação a discriminação algorítmica. Dissertação de mestrado, Pontifícia Universidade Católica de São Paulo (PUC SP), São Paulo, Brasil.
- Scheuerman, M. K., Hanna, A., and Denton, R. (2021). Do datasets have politics? disciplinary values in computer vision dataset development. *Proc. ACM Hum.-Comput. Interact.*, 5(CSCW2).
- Silva, F. and Silva, T. (2024). *Teoria Crítica da Raça na Regulação de Inteligência Artificial*.
- Silva, T. (2020). Visão computacional e vieses racializados: Branquitude como padrão no aprendizado de máquina. *Revista da ABPN*, 12(31):428–448. Licenciado sob uma Licença Creative Commons.
- Steed, R. and Caliskan, A. (2021). Image representations learned with unsupervised pre-training contain human-like biases. In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, FAccT '21*, page 701–713. ACM.
- Wang, S. (2023). Design of real-time object recognition algorithm based on deep convolution neural network. In *2023 International Conference on Internet of Things, Robotics and Distributed Computing (ICIRDC)*, pages 533–538.
- Xu, C. (2023). Harmonyvisage: Ethical facial emotion dataset using advanced generative ai. In *2023 IEEE 14th Annual Ubiquitous Computing, Electronics Mobile Communication Conference (UEMCON)*, pages 0558–0563.
- Yucer, S., Tektas, F., Moubayed, N. A., and Breckon, T. P. (2023). Racial bias within face recognition: A survey.