

* Ítalo José de Medeiros Dantas Doutorando em Processos e Manifestações Culturais, onde é bolsista PROSUC/CAPES. Possui Mestrado em Design (UFCG) e Graduação em Design de Moda (IFRN).

italodantasdesign@hotmail.com

ORCID 0000-0003-0710-6142

Marcelo Curth Possui doutorado em Administração pela Universidade do Vale do Rio dos Sinos (UNISINOS), mestrado em Administração e Negócios pela Universidade Católica do Rio Grande do Sul (PUC-RS), Pós-Graduado em Administração e Marketing pela Universidade Gama Filho, Pós-Graduado em Educação pela Faculdade (SE-NAC-RS) e pós-graduando em Mentoring Teacher Education (Universidade de Tampere - Finlândia) e graduação em Ciências do Desporto pela Universidade Luterana do Brasil (ULBRA). É professor do PPG em Processos e Manifestações Culturais da Universidade Feevale, atuando como pesquisador no tema Marketing: Identidade e Cultura.

marcelocurth@feevale.br

ORCID 0000-0002-9361-8373

Aline Gabriel Freire Mestre em Engenharia Têxtil pela Universidade Federal do Rio Grande do Norte. Professora de Moda e Vestuário no Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte.

alinefreire2@gmail.com

ORCID 0000-0002-0365-227X

Ítalo José de Medeiros Dantas, Marcelo Curth, Aline Gabriel Freire*

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda

Resumo O interesse crescente na aplicação da aprendizagem de máquina (AM) na moda destaca a importância do uso de dados rotulados para desenvolver modelos, facilitando a replicação de pesquisas e automatizando a análise de novos dados, como imagens de desfiles de moda disponíveis online. Apesar dessa necessidade, poucos estudos, especialmente no Brasil, exploram metodologicamente a interseção entre moda e AM. Esta pesquisa visa oferecer uma visão geral das bases de dados online para treinamento de modelos de AM. Uma revisão sistemática identificou 26 artigos que utilizam essas bases de dados, como Fashion-MNIST e DeepFashion2. A análise de conteúdo revelou que essas bases, incluindo Polyvore e Fashion Image Dataset, têm aplicações diversas, destacando o potencial transformador da AM na moda e incentivando inovações em design, produção e marketing na indústria da moda.

Palavras Chave Aprendizagem de Máquina na Moda, Inteligência Artificial, Inovação tecnológica, Base de dados, Aprendizagem supervisionada.

Exploring databases for training models in machine learning in the Fashion industry

Abstract Growing interest in applying machine learning (ML) to fashion highlights the importance of using labeled data to develop models, facilitating research replication, and automating the analysis of new data, such as fashion show images available online. Despite this need, few studies, especially in Brazil, methodologically explore the intersection between fashion and AM. This research aims to provide an overview of online databases for training ML models. A systematic review identified 26 articles that use these databases, such as Fashion-MNIST and DeepFashion2. Content analysis revealed that these databases, including Polyvore and Fashion Image Dataset, have diverse applications, highlighting the transformative potential of AM in fashion and encouraging innovations in design, production, and marketing in the fashion industry.

Keywords Machine Learning in Fashion, Artificial intelligence, Technological innovation, Data base, Supervised learning.

Exploración de bases de datos para la formación de modelos de aprendizaje automático en la industria de la moda

Resumen El creciente interés en aplicar el aprendizaje automático (ML) a la moda destaca la importancia de utilizar datos etiquetados para desarrollar modelos, facilitando la replicación de la investigación y automatizando el análisis de nuevos datos, como las imágenes de desfiles de moda disponibles en línea. A pesar de esta necesidad, pocos estudios, especialmente en Brasil, exploran metodológicamente la intersección entre moda y AM. Esta investigación tiene como objetivo proporcionar una descripción general de las bases de datos en línea para entrenar modelos de ML. Una revisión sistemática identificó 26 artículos que utilizan estas bases de datos, como Fashion-MNIST y DeepFashion2. El análisis de contenido reveló que estas bases de datos, incluidas Polyvore y Fashion Image Dataset, tienen diversas aplicaciones, destacando el potencial transformador de la fabricación aditiva en la moda y fomentando innovaciones en diseño, producción y marketing en la industria de la moda.

Palabras clave Machine Learning en Moda, Inteligencia Artificial, Innovación tecnológica, Bases de Datos, Aprendizaje supervisado.

Introdução

A Inteligência Artificial (IA) é um tópico com uma longa história, especialmente quando consideramos seu desenvolvimento científico, técnico e tecnológico até chegar nas suas aplicações contemporâneas (Haenlein; Kaplan, 2019; Muthukrishnan, 2020). Ainda que compreendamos esse cenário, podemos observar que, nos últimos anos, tal área tem despertado um crescente interesse, influenciado pelo uso e pela curiosidade geradas por artefatos digitais como ChatGPT e MidJourney. Nesse sentido, a IA tem se tornado cada vez mais uma realidade, ocorrendo graças a estudos que a empregam na resolução de diversos problemas sociais, destacando sua importância como campo de estudo e sua promessa de automação em várias indústrias e nas comunidades de maneira geral (Lu, 2019, Taherdoost; Madanchian, 2023).

Nesse contexto, a indústria da moda, como uma expressão cultural e econômica proeminente, reflete as dinâmicas sociais (Lipovetsky, 2009; Miranda, 2019) e as mudanças tecnológicas em andamento (Sun; Zhao, 2018; Lee, 2022). Nas últimas décadas, tem ocorrido um notável encontro entre os interesses da moda e o potencial da inteligência artificial (Luce, 2018; Giri et al., 2019; Gu et al., 2020; Castro et al., 2023), com foco especial nas técnicas e aplicações da Aprendizagem de Máquina (AM) (Rathore, 2017, Sulthana et al., 2021). Essa convergência de campos cria um ambiente rico em oportunidades de pesquisa e inovação (Luce, 2018), abordando desde a análise de atributos de design em imagens (Cui, 2022, Peng et al., 2022) até a identificação ágil de tendências (Chang et al., 2021, Getman et al., 2021) e o aprimoramento de sistemas de recomendação (Chakraborty et al., 2021; Yang, 2022).

A AM, como um subcampo da IA, fornece métodos e técnicas para extrair conhecimento e automatizar processos complexos a partir de grandes conjuntos de dados (Shinde; Shah, 2018). Na moda, esse subcampo se mostra particularmente relevante, permeando várias etapas da cadeia de valor da indústria e permitindo melhorias na eficiência operacional, personalização de produtos e compreensão aprofundada das tendências de mercado (Luce, 2018). Além de estender a otimização de processos de pesquisas, acadêmicas ou industriais, ao facilitar a identificação de atributos do design em desfiles de Moda a partir de imagens.

A aprendizagem supervisionada, dentro do campo da AM, é um dos paradigmas essenciais (Huyen, 2022) e uma das mais empregadas na conformação de modelos aplicados a Moda. Nesse contexto, um algoritmo é treinado com um conjunto de dados que já possui exemplos rotulados. Esses rótulos funcionam como orientações para o modelo, permitindo-lhe aprender a mapear entradas para saídas desejadas (Huyen, 2022). De tal maneira, entendemos que é como ensinar a uma IA a maneira de se realizar uma tarefa específica, fornecendo exemplos claros e etiquetados/rotulados (Huyen, 2022). Esse método é particularmente valioso em aplicações onde se deseja prever, classificar ou tomar decisões com base em dados históricos, isto é, que já um conhecimento estabelecido e que poderá servir para a

construção de um modelo (Bertolini et al., 2021), como em diagnósticos médicos, detecção de fraudes em transações financeiras ou reconhecimento de padrões em imagens – na Moda, por exemplo, pode-se utilizar na conformação de modelos de previsão de tendências com base em imagens de desfiles de estações passadas (Zhang et al., 2018; Getman et al., 2020).

Apesar do crescente interesse e das inúmeras aplicações que podem ser observadas, a literatura científica carece de uma exploração mais ampla do potencial que os trabalhos sobre aprendizagem de máquina podem fornecer para os pesquisadores da Moda, automatizando processos de análise e tornando-os mais efetivos e orientados. Portanto, este estudo tem por objetivo apresentar uma visão geral dos bases de dados disponíveis de maneira digital e que, por sua vez, podem servir para treinamento de modelos de AM.

Aprendizagem de máquina supervisionada: relevância dos bases de dados e rotulagem

O aprendizado de máquina representa uma disciplina fundamental na era da inteligência artificial (IA). Trata-se de uma abordagem computacional que visa permitir que sistemas computacionais aprendam com dados e experiências passadas, permitindo-lhes tomar decisões, fazer previsões ou executar tarefas específicas sem serem programados para cada situação (Mahesh, 2020). Este campo abrange vários conceitos e atributos essenciais que moldam sua compreensão e aplicação. (Stuart; Norvig, 2009).

Basicamente, o aprendizado de máquina é baseado em algoritmos e modelos matemáticos que permitem aos sistemas identificarem padrões e tendências nos dados. Um dos pilares fundamentais é a divisão em dois tipos principais de aprendizagem: supervisionada e não supervisionada¹. Na aprendizagem supervisionada, o modelo é treinado em dados rotulados, onde cada exemplo possui um rótulo ou saída desejada, com o objetivo de aprender como mapear entradas em saídas. Na aprendizagem não supervisionada, o modelo explora dados sem rótulos, identificando padrões, estruturas ou grupos intrínsecos sem orientação de resultados conhecidos (Stuart; Norvig, 2009; Alloghani et al., 2019; Huyen, 2022).

Como nosso foco, a aprendizagem supervisionada implica treinar um algoritmo com um conjunto de dados previamente rotulados, onde os rótulos atuam como direcionadores para o modelo, permitindo-lhe aprender a mapear entradas para saídas desejadas (Huyen, 2022). Em outras palavras, trata-se de instruir uma IA na execução de tarefas específicas, fornecendo exemplos claros e rotulados, que a levarão a entender a dinâmica que existe entre as variáveis (Huyen, 2022).

A aprendizagem supervisionada destaca-se pela sua aplicação em previsões, classificações e tomadas de decisões baseadas em dados históricos (Bertolini et al., 2021), sendo valiosa na Moda, onde a interseção entre dinâmicas sociais, tecnologia e inteligência artificial otimiza processos produtivos e criativos (Luce, 2018; Giri et al., 2019; Gu et al., 2020; Castro et al., 2023). Na construção de modelos para a moda dentro da aprendiza-

1. É relevante mencionar que há outros processos de aprendizagem de máquina, tais como os semi-supervisionadas, ou de aprendizagem reforçada (Huyen, 2022), no entanto, atemo-nos a comentar dos dois métodos principais.

gem supervisionada, a escolha cuidadosa de algoritmos e parâmetros exige intervenção humana (Haenlein; Kaplan, 2019; Muthukrishnan, 2020), destacando-se pela eficácia em campos nos quais o conhecimento humano é crucial na modelagem (Lu, 2019; Taherdoost; Madanchian, 2023).

Ao considerarmos esse contexto, ressaltamos o conceito de rotulagem dos dados, que está intimamente relacionado à aprendizagem de máquina supervisionada e a própria elaboração dos bases de dados. Como explica Huyen (2022), dado a quantidade de estudos que empregam aprendizagem supervisionada, o desempenho de um modelo de AM continua a depender consideravelmente da qualidade e quantidade dos dados rotulados nos quais é treinado, e isso pode variar consideravelmente ao se entender a natureza dos dados utilizados. Dentre as possibilidades de rotulagem, o autor supramencionado (2022) menciona a rotulagem manual e a natural, conceitos que iremos explorar a seguir.

Segundo Huyen (2022), a rotulagem manual implica o envolvimento humano direto na atribuição de rótulos aos dados, demandando a experiência de indivíduos capazes de analisar e categorizar a informação com cuidado. Alguns pesquisadores optam por usar designers de moda experientes ou estudantes da área (Guan; Qin; Long, 2019) para essa tarefa, visando mitigar enviesamentos e aproximar o banco de dados da realidade. Apesar do tempo e esforço consideráveis, essa abordagem assegura alta precisão, sendo aplicada em situações que demandam julgamento humano devido à complexidade da tarefa (Huyen, 2022). Em contrapartida, a rotulagem natural extrai rótulos de dados gerados organicamente, como interações de usuários e comportamentos online. Embora menos precisa que a rotulagem manual, esse método captura a natureza contextual e dinâmica dos dados do mundo real, proporcionando uma perspectiva mais abrangente e adaptável durante o treinamento do modelo (Huyen, 2022).

Por isso, uma das formas de conter tais adversidades, reside na adoção de bases de dados já existentes e disponíveis em repositórios digitais, tais como o GitHub, à medida que estes costumam ter um volume de dados consideravelmente amplo – muitas vezes com mais de 100.000 imagens, já rotuladas quanto a elementos de linguagem visual e atributos de vestuário (Xiao; Rasul; Vollgraf, 2017). Huyen (2022, p. 118, tradução nossa) comenta que “É uma boa prática acompanhar a origem de cada uma de suas amostras de dados, bem como seus rótulos, uma técnica conhecida como linhagem de dados. A linhagem de dados ajuda a sinalizar possíveis preconceitos em seus dados e a depurar seus modelos”. Além disso, tais bases de dados costumam ser submetidos a diversas rodadas de avaliação e revisão, por diferentes pesquisadores ao redor do mundo.

Materiais, métodos e dados

A consecução dos objetivos propostos envolveu uma análise sistemática da literatura, sob a ótica da revisão de escopo metodológico dos artigos, visando fornecer uma visão das bases de dados adotadas na litera-

tura existente sobre aprendizagem de máquina aplicada à Moda (Arksey; O'Malley, 2005; Paré et al., 2015). O processo de mapeamento e análise compreendeu seis etapas: seleção das bases de dados, escolha das palavras-chave, busca efetiva dos estudos, revisão dos títulos, resumos e palavras-chave, exclusão de estudos não alinhados às especificidades propostas e uma leitura paralela para excluir textos completos não relacionados ao tema pesquisado.

Optamos por três bases de dados amplamente utilizadas: “Scopus”, “Web of Science” (Martín-Martín et al., 2021) e “SciELO” (Packer, 2009). Dada a natureza do financiamento desta pesquisa pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), órgão brasileiro de fomento à pesquisa, acrescentamos eticamente a base de dados “Portal de Periódicos Capes”, a maior base de dados brasileira, proporcionando acesso gratuito a diversas publicações e artigos científicos em instituições nacionais de ensino superior (Cendon; Ribeiro, 2008). Nesse contexto, a liberação de acesso às bases de dados Scopus e Web of Science foi viabilizada pelo Portal de Periódicos Capes. Apesar de serem recursos valiosos para revisões sistemáticas, vale ressaltar que vários artigos não estavam disponíveis em nenhuma das bibliotecas online, resultando em sua exclusão subsequente.

Com o intuito de identificar os bases de dados presentes nos estudos sobre aprendizagem de máquina e Moda, para a busca dos artigos, adotamos termos genéricos como marcadores, mas que fossem capazes de refletir a essência da pesquisa. Portanto, criamos um marcador para localizar artigos que incluíssem o termo “machine learning” e “fashion” ou “fashion design” nos títulos, resumos ou palavras-chave dos artigos mapeados. Os termos utilizados foram:

1. “machine learning”
2. “fashion” OR “fashion design”

Combinamos os itens 1 e 2 com um operador booleano “AND” para recuperar estudos que contivessem o item 1 agregado a pelo menos um dos termos do item 2. Aplicamos esses marcadores em cada biblioteca digital separadamente e registramos os resultados em planilhas do Microsoft Excel. O mapeamento dos artigos foi concluído em setembro de 2023, englobando trabalhos produzidos até agosto do mesmo ano. A primeira busca resultou em 2500 artigos, aos quais aplicamos três filtros de exclusão: (1) remoção de artigos duplicados ou não relacionados ao tema (-2403); (2) exclusão de artigos retirados por má conduta das plataformas de publicação, indisponíveis online, fora do escopo ou não produzidos em inglês (-16); (3) trabalhos que empregam base de dados disponíveis na internet para construção dos modelos de aprendizagem de máquina (-55). Ao final, selecionamos 26 artigos para análise completa (Tabela 1).

Para a etapa de análise do escopo metodológico dos artigos, adotamos uma perspectiva qualitativa, considerando o conteúdo dos trabalhos. De tal forma, utilizaremos como estratégia a revisão narrativa e estudo de múltiplos

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda 163

casos, visando explorar exclusivamente as bases de dados empregadas nos artigos mapeados, evidenciando casos, aplicações e potencialidades, abrangendo também informações externas as apresentadas nos trabalhos mapeados.

Tabela 1 Base de dados, quantidade de artigos e filtros aplicados na revisão sistemática da literatura
Fonte Elaborado pelos autores de acordo com os dados da pesquisa, 2017

Biblioteca digital	Busca	Filtro 1	Filtro 2	Filtro 3
Scopus	1433	49	34	8
Web of Science	952	17	17	3
Portal de Periódicos Capes	115	31	30	15
Scielo	0	-	-	-
Total	2500	97	81	26

Ciência livre na moda: explorando bases de dados em acesso aberto

Nesta pesquisa propomos uma análise volta para os artigos que apresentam base de dados em acesso aberto durante a conformação dos modelos de aprendizagem que apresenta em sua estrutura. Nisso, observamos que todos os 26 artigos mapeados apresentam menção a pelo menos uma base de dados em acesso aberto, totalizando 35 bases de dados, sendo 26 destas diferentes entre si. Percebemos a pulverização de bases de dados disponíveis, abrindo margem para diferentes abordagens projetuais. Outrossim, identificamos que a base de dados mais utilizada pelos pesquisadores é a Fashion-MNIST (6), seguida pela Polyvore (4), DeepFashion2 (3) e Fashion Product Images Dataset (2) (Tabela 2), as demais, trata-se de diferentes outras bases de dados, ou variações anteriores das mencionadas.

Tabela 2 Base de dados em acesso aberto utilizadas na proposição de modelos de AM
Fonte Elaborado pelos autores de acordo com os dados da pesquisa

Base de dados	Quant.	%
Fashion-MNIST	6	17,14%
Polyvore	4	11,43%
DeepFashion2	3	8,57%
Fashion Product Images dataset	2	5,71%
Outras	20	57,14%

Clothing Co-Parsing (CCP) dataset, COCO dataset, DeepFashion-C, iMaterialist, Fashion1000, Fashion data, Clothing attribute dataset, DeepFashion-C2S, Street2Shop, DeepFashion, Farfetch dataset, Fashion dataset, CIFAR10, CIFAR100, Tiny ImageNet, SHIFT15m dataset, shopping100k, Street Fashion Style dataset, StreetStyle, TILDA database

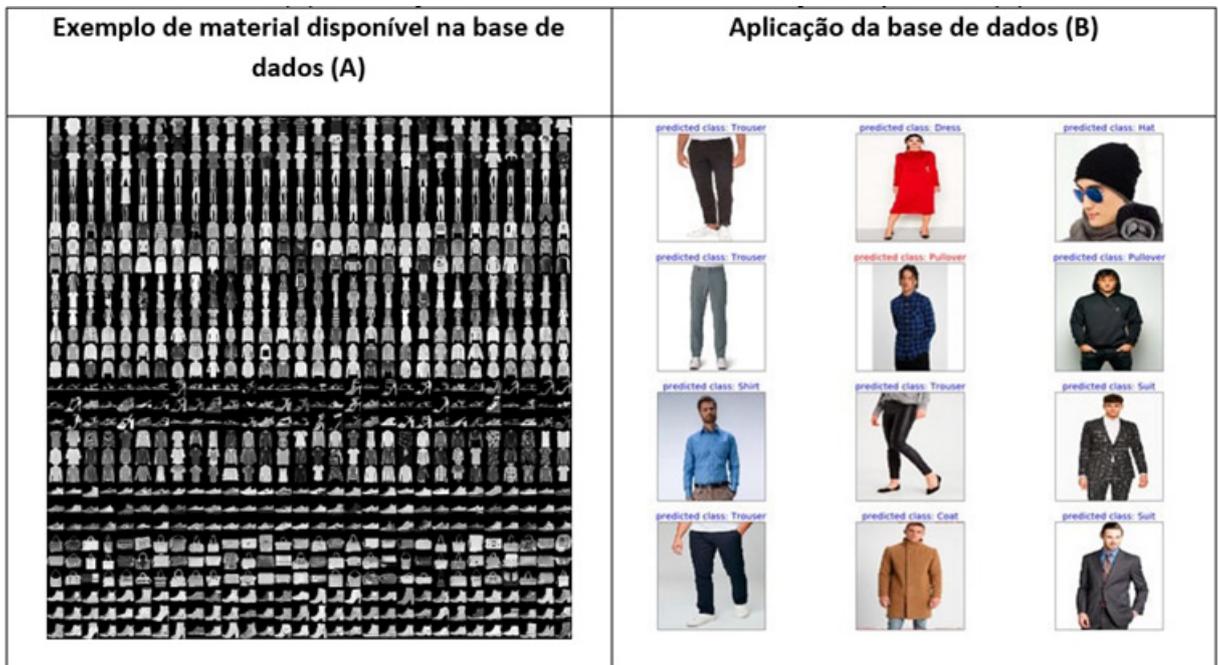
Assim sendo, a base de dados mais empregada é denominada de Fashion-MNIST, criada em 2017 a partir de imagens da varejista Zalando, empresa alemã de Moda. De acordo com seus codificadores, Xiao, Rasul e Vollgraf (2017),ⁱ a base de dados é composta por um conjunto de treinamento de 60.000 exemplos (imagens de produtos de Moda) e um conjunto de teste de 10.000 exemplos. Cada exemplo é uma imagem em tons de cinza

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda 164

28x28, associada a um rótulo de 10 classes. Os rótulos em questão se trata especificamente de t-shirt, calças, pulôver, vestido, casaco, sandália, camisa, tênis, bolsa e bota de tornozelo (Figura 1A).

Tal base de dados é comumente empregada na classificação de imagens de produtos de Moda, de tal forma que se torne possível otimizar recomendação em aplicações web ou aplicativos de compra, pautado em especial no reconhecimento do tipo de produto. Na plataforma Kaggleⁱⁱ, voltado para competição em ciência de dados, tem uma nota de usabilidade de 8.53, influenciado negativamente pela infrequência de atualização das imagens, tornando-as obsoletas/datadas. No entanto, trata-se de uma das bases de dados mais baixadas na plataforma, com cerca de 2227 códigos envolvidos e 177.000 downloads realizados.

Figura 1 Exemplo de imagens disponíveis na base de dados Fashion-MNIST para treino (A) e utilização do modelo durante classificação de produtos (B)
Fonte Xiao, Rasul e Vollgraf (2017) (A) e Rohrmanstorfer, Komarov e Mödritscher (2021) (B)



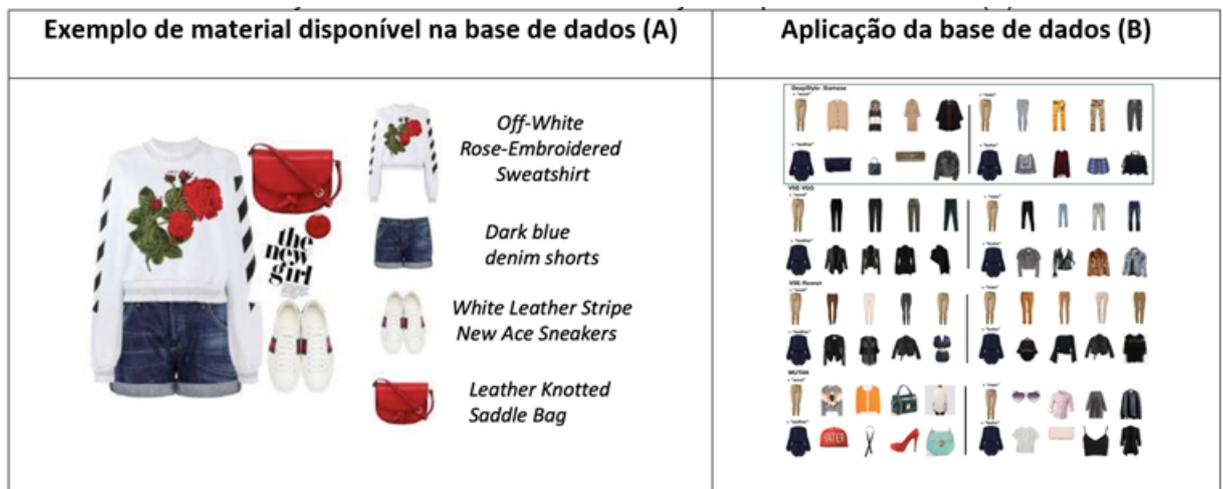
Nos estudos analisados, a base de dados é comumente utilizada para aprimorar a precisão na classificação de imagens, geralmente através da combinação de diferentes algoritmos associados ao Fashion-MNIST. Os pesquisadores buscam alcançar melhores resultados por meio de comparações entre modelos. Yian e Kyung-shik (2019) propuseram o uso de Redes Neurais Convolucionais Hierárquicas (H-CNN) na classificação de vestuário, concluindo que o H-CNN demonstra melhor desempenho nessa tarefa. Desta forma, acreditamos que a complexidade na classificação de imagens de vestuário pode ser superada ao considerar a estrutura hierárquica das redes neurais convolucionais (CNN). No mesmo contexto, Liu et al. (2020) introduziram dois algoritmos de classificação associados ao Fashion-MNIST, obtendo resultados satisfatórios, destacando-se pela capacidade de classificar produtos de maneira rápida e precisa.

No mesmo contexto, os trabalhos de Rohrmanstorfer, Komarov e Mödritscher (2021), Vijayaraj et al. (2022) e Shin, Jo e Wang (2023) emprega-

ram o Fashion-MIST na conformação de algoritmos de AM pautado em CNN, buscando classificar atributos visuais de um novo conjunto de produtos de Moda (Figura 1B), sendo eles imagens de websites de compra (Rohrmanstorfer, Komarov e Mödritscher, 2021) ou desfiles de moda (Vijayaraj et al., 2022; Shin; Jo; Wang, 2023). Dentre os achados, ressaltamos que os autores descobriram que roupas mais visualmente distintas, como calças, sapatos e chapéus, foram mais bem classificadas do que outras roupas relacionadas a parte superior do corpo (Rohrmanstorfer; Komarov; Mödritscher, 2021). Outrossim, Sipper (2022) propôs um sistema de classificação de imagem hierárquico, pautado em aprendizagem profunda, utilizando como teste o base de dados do Fashion-MNIST. O autor encontra resultados satisfatórios e aplicáveis na produção industrial.

A segunda base de dados em acesso aberto mais utilizada é denominada de Polyvoreⁱⁱⁱ, criada por volta de 2017, a partir das imagens de produtos de Moda que foram carregadas no website^{iv} de mesmo nome, pelos próprios usuários, como uma espécie de Pinterest, em que os usuários propõem combinações de produtos. De acordo com seus codificadores (Han et al., 2017), a base de dados possui 21.889 imagens de roupas do Polyvore, com, das quais 17.316 são para treinamento, 1.497 para validação e 3.076 para teste. As imagens se trata de peças individuais, coloridas, aliadas a diferentes combinações encontradas no próprio website, com uma descrição simples dos elementos e atributos dos produtos em questão (Figura 2A).

Figura 2 Exemplo de imagens disponíveis na base de dados Polyvore para treino (A) e utilização do modelo durante classificação de produtos de Moda (B)
Fonte Han et al. (2017) (A) e Tautkute et al. (2019) (B)



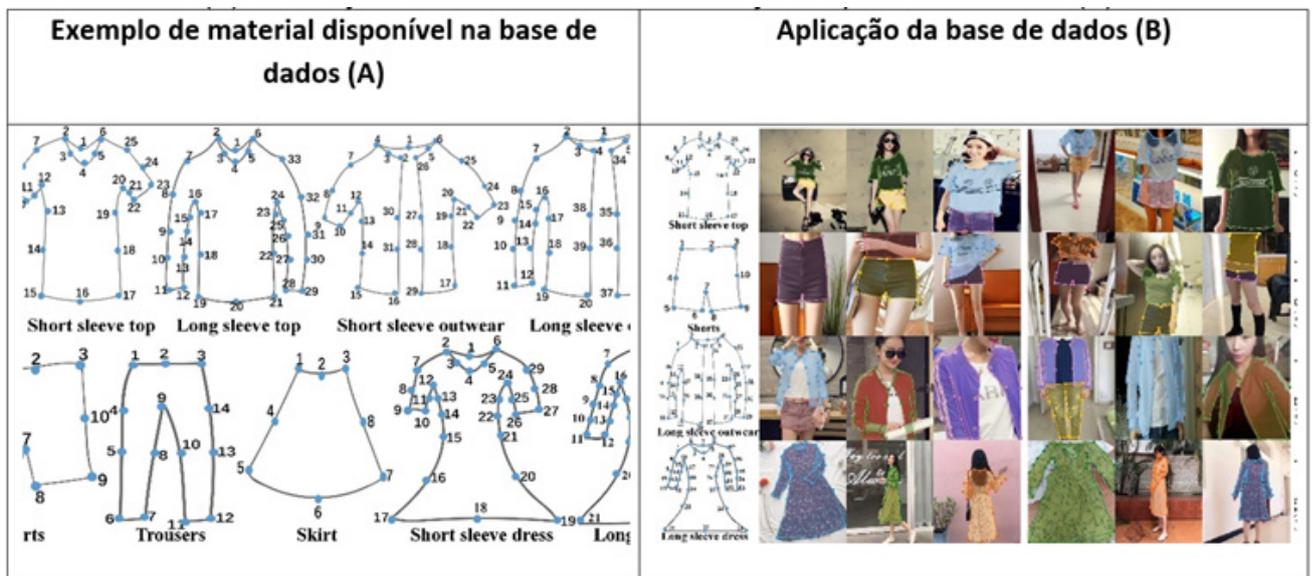
Assim como o Fashion-MNIST, este banco de dados visa ser um treinamento para a classificação de produtos de Moda, associando-os a descrições textuais para aprofundar o reconhecimento e a categorização. Tautkute et al. (2019) propõem um mecanismo multimodal que combina referências visuais e textuais da Polyvore para recuperar itens esteticamente semelhantes, contribuindo para recomendações em e-commerce e atividades de stylists (Figura 2B). Liu et al. (2019) criam a base de dados Fashion-VC+, utilizando referências visuais e textuais da Polyvore, identificando a necessidade de aprimorar a combinação de produtos por meio de pesquisa

com especialistas em Moda. Peng et al. (2022) e Cui (2022) usam a base de dados da Polyvore na criação ou teste de sistemas de recomendação, explorando algoritmos, inclusive não supervisionados, para propostas de sistemas de baixo custo e menor taxa de erros de rotulagem (Peng et al., 2022).

A terceira base de dados mais utilizada é denominado de DeepFashion2, criada em 2019 a partir de um conjunto de imagens de produtos de empresas online de Moda. De acordo com Ge et al. (2019), o grupo de codificadores, contém 491.000 imagens de diversas, curadas a partir de 13 categorias de roupas populares, tanto de lojas comerciais quanto de consumidores. Possui um total de 801 mil itens de vestuário, onde cada item em uma imagem é rotulado com escala, oclusão, zoom, ponto de vista, categoria, estilo, caixa delimitadora, pontos de referência densos e máscara por pixel. A rotulagem das imagens torna capaz do modelo reconhecer diferentes tamanhos das peças e mangas (Figura 3A e Figura 3B). Também não há métricas disponíveis no Kaggle para metrificar seu alcance.

Na abordagem de Kim et al. (2022), a utilização do DeepFashion2^v concentra-se no reconhecimento de estilos de produtos, propondo um sistema automatizado para medir tamanhos de roupas por meio de modelos de aprendizagem profunda e dados de nuvem de pontos. Eles empregaram as rotulagens de estilo disponíveis na base de dados, focando em cinco categorias: top de manga curta, top de manga longa, shorts, calças e saia (Kim et al., 2022). Chang e Zhang (2022) aplicam a base de dados em conjunto com o algoritmo YOLOv5 para uma classificação eficiente de produtos, alcançando resultados satisfatórios e rápidos com base nos dados da DeepFashion2. Por outro lado, Fontanini e Ferrari (2022) propõem um modelo de aprendizagem de transferência utilizando a base de dados para modificar estilos e elementos da linguagem visual de produtos de Moda, mantendo a forma anterior. Os resultados, com alta acurácia, indicam aplicabilidade quando o consumidor deseja realizar alterações visuais em um produto com base em uma referência pré-estabelecida por ele.

Figura 3 Exemplo de imagens disponíveis na base de dados DeepFashion2 para treino (A) e utilização do modelo durante classificação de produtos de Moda (B)
 Fonte Ge et al. (2019)



Algumas variações da DeepFashion2 incluem DeepFashion-C, DeepFashion-C2S e DeepFashion^{vi}. As mudanças com relação a analisada se trata de versões com menos ou mais quantidade de imagens, outros tipos de imagens ou a inclusão/exclusão de rótulos classificadores.

A quarta base de dados mais utilizada é denominada de Fashion Product Images dataset^{vii}, sendo esta disponível em duas versões, uma completa, e uma reduzida, com esta última com um intuito mais didático e de teste, para quem não deseja iniciar com uma base de dados tão ampla. Ao contrário das anteriores, esta base de dados não foi proposta a partir da coleta digital de imagens, mas construída com imagens profissionais, do próprio codificado. Portanto, de acordo com o autor (Aggarwal, 2024), além de imagens de produtos de alta resolução tiradas profissionalmente (Figura 4A), a base de dados também tem vários atributos de rotulagem que descrevem o produto que foi inserido manualmente durante a catalogação. Outrossim, também se pode encontrar um texto descritivo que comenta as características do produto, auxiliando em sua detecção e classificação com base em imagem, acrescido a informações textuais (Aggarwal, 2024). A base de dados é composta por itens de diferentes categorias, passando por vestuário, acessórios, calçados, cuidado pessoal, entre outros.

Nos artigos estudados, os autores utilizam a base de dados majoritariamente para construir modelos de classificação e busca de produtos de Moda. No caso de Bhoir e Patil (2023), os autores empregam a base de dados no treinamento de um modelo que auxilia na busca visual de outros produtos semelhantes, de mesma categoria (Figura 4B). Em outro contexto, a pesquisa de Rocha et al. (2023) busca solucionar problemas relacionados aos consumidores cegos ao integrar aprendizagem profunda para identificação e categorização de manchas em roupas. Foram encontrados resultados satisfatórios, com alta acurácia.

Figura 4 Exemplo de imagens disponíveis na base de dados Fashion Image para treino (A) e utilização do modelo durante classificação de produtos de Moda (B)
 Fonte Aggarwal (2024) (A) e Bhoir e Patil (2023) (B)



Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda

Além destas bases de dados já mencionadas, há uma pulverização em outras 20, com diferentes objetivos e funcionalidades. Ressaltamos o caso das bases de dados Street Fashion Style dataset^{viii}, StreetStyle e Street2Shop, construídas utilizando como referência imagens de pessoas nas ruas, não apenas desfiles de Moda ou produtos comerciais em lojas virtuais. Algumas das características dessas bases de dados se trata de rótulos voltados para localização geográfica dos indivíduos, tornando possível propor modelo de recomendações específicas por regiões do mundo, ou reconhecimento da origem de um produto (Figura 5).

Figura 5 Exemplo de imagens e recursos disponíveis na base de dados Street Fashion Style
 Fonte Matzen, Bala e Snavely (2017)



Figura 6 Exemplo de imagens e recursos disponíveis na base de dados Street Fashion Style Dataset
 Fonte Guo et al. (2019) (A) e Alzu'bi, Younis e Madain (2023)

Outros bases de dados incluem iMaterialist (Figura 6A) e Shopping100k dataset (Figura 6B), que combinam imagens com uma série de rotulagem textuais, envolvendo desde estilo das peças, como classificação e diferentes tipos de golas e mangas, até elementos da linguagem visual (cores, especialmente), e público-alvo central do produto.

Exemplo de material disponível na base de dados iMaterialist (A)		Exemplo de material disponível na base de dados Shopping100K (B)	
<p>Pattern</p> <p>Neckline</p> <p>Style</p> <p>Category</p>	<p>Attributes Category: Shirt Color: White Fabric: Jersey Fit: Regular Gender: Female Neckline: Square Sleeve Length: 3/4</p>	<p>Attributes Category: Jacket Color: Hood Color: Olive Fastening: Zip Fit: Regular Gender: Female Pattern: Plain Sleeve Length: Long</p>	
	<p>Attributes Category: Jumper Color: Beige Fabric: Jersey Fastening: Zip Gender: Female Pattern: Plain</p>	<p>Attributes Category: T-shirt Color: White Fabric: Jersey Fit: Long Gender: Female Neckline: Square Pattern: Striped Sleeve Length: Extra Short</p>	

Os achados desta pesquisa delineiam implicações significativas tanto para a prática industrial quanto para as pesquisas na área. A diversidade de abordagens observadas reflete um campo em constante evolução, onde os modelos de aprendizagem de máquina oferecem potencial para transformar fundamentalmente a cadeia de valor da moda. Observamos uma quantidade ampla de bases de dados disponíveis e pouco exploradas em pesquisas científicas. A capacidade de construir modelos robustos de classificação, busca visual e detecção de características específicas abre caminho para a personalização de recomendações, melhorando a experiência do consumidor e potencialmente impulsionando as vendas no comércio eletrônico.

Assim, a variedade de bases de dados e métodos empregados destaca a adaptabilidade desses modelos aos desafios específicos do setor, desde a identificação de estilos nas ruas até a categorização de produtos com base em diferentes atributos. Para a indústria da Moda, essa flexibilidade oferece oportunidades para inovações em áreas como design, produção e marketing. Ao mesmo tempo, para os pesquisadores, a multiplicidade de abordagens sugere uma rica paisagem para investigações futuras, incentivando a exploração de novas fronteiras na convergência entre moda e inteligência artificial. Esses resultados fornecem uma perspectiva para ambas as partes interessadas, destacando o potencial de transformação da aprendizagem de máquina na moda e motivando avanços continuados para aprimorar a aplicação prática desses modelos inovadores.

Conclusão

Na integração crescente da tecnologia na moda, percebemos um promissor avanço na aplicação de técnicas de inteligência artificial nos processos produtivos e criativos. A aprendizagem de máquina, em particular, emerge como um impulsionador significativo de inovações na criação e recomendação de produtos, utilizando entradas imagéticas e textuais para guiar algoritmos na geração de novos itens. Dada a limitada aplicação desses métodos na pesquisa de Moda, especialmente no Brasil, conduzimos uma revisão sistemática da literatura e um estudo de múltiplos casos para destacar possíveis trajetórias de utilização de diversas bases de dados na indústria e academia. O mapeamento abrange 26 trabalhos e 35 bases de dados de acesso aberto, proporcionando uma discussão das principais descobertas.

Com isso, descobrimos que a Fashion-MNIST, Polyvore, Deep-Fashion2 e Fashion Product Images Dataset são as principais bases de dados utilizadas. Observamos que os seus empregos e funcionalidades variam de acordo com a natureza dos dados utilizados, indo desde a proposição de sistemas de recomendação, passando pelo desenvolvimento de modelos de compatibilidade de produtos até identificação geográfica dos consumidores. A diversidade de abordagens destaca a capacidade dos modelos de aprendizagem de máquina em transformar a cadeia de valor da moda, proporcionando personalização de recomendações e melhorando a experi-

ênica do consumidor no comércio eletrônico. A flexibilidade demonstrada, tanto na escolha de bases de dados quanto nos métodos utilizados, oferece oportunidades de inovação em design, produção e marketing para a indústria da Moda, enquanto motiva os pesquisadores a explorarem novas fronteiras na convergência entre moda e inteligência artificial.

Assim, buscamos evidenciar nesse trabalho a rica potencialidade do uso de métodos de aprendizagem de máquina na criação de novos produtos, processos e pesquisas acadêmicas. Assim sendo, para pesquisas e ações futuras, sugerimos a busca pela facilitação do acesso e entendimento desses métodos pelos pesquisadores, integrando-os a equipes de proposição de novas base de dados ou modelos de aprendizagem de máquina, gerando uma rede interdisciplinar que poderá apresentar avanço tecnológico significativo.

Notas de fim

- ⁱ <https://github.com/zalando-research/Fashion-MNIST?tab=readme-ov-file> (Acesso em 17 jan. 2024).
- ⁱⁱ <https://www.kaggle.com/datasets/zalando-research/fashionmnist> (Acesso em 17 jan. 2024).
- ⁱⁱⁱ <https://github.com/xthan/polyvore-dataset> (Acesso em 17 jan. 2024).
- ^{iv} Polyvore foi, posteriormente, comprada pela SSNSE: <https://www.ssense.com/en-nz> (Acesso em 17 jan. 2024).
- ^v <https://github.com/switchablenorms/DeepFashion2> (Acesso em 18 jan. 2024).
- ^{vi} <https://paperswithcode.com/dataset/deepfashion> (Acesso em 18 jan. 2023).
- ^{vii} <https://www.kaggle.com/datasets/paramaggarwal/fashion-product-images-dataset/data> (Acesso em 17 jan. 2024).
- ^{viii} <https://paperswithcode.com/dataset/streetstyle> (Acesso em 18 jan. 2024).

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda 171

Referências

AGGARWAL, P. **Fashion product images dataset**. 2024. Disponível em: <https://www.kaggle.com/datasets/paramaggarwal/fashion-product-images-dataset>. Acesso em: 18 jan. 2024.

ALLOGHANI, M. et al. **A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science**. In: BERRY, M.; MOHAMED, A.; YAP, B. (Eds.) *Supervised and Unsupervised Learning for Data Science. Unsupervised and Semi-Supervised Learning*. Springer, Cham, 2020.

ALZU'BI, A. et al. **An interactive attribute-preserving fashion recommendation with 3D image-based virtual try-on**. *International Journal of Multimedia Information Retrieval*, v. 12, n. 2, p. 24, 2023.

ARKSEY, H.; O'MALLEY, L. **Scoping studies: towards a methodological framework**. *International Journal of Social Research Methodology*, v. 8, n. 1, p. 19–32, 2005.

BERTOLINI, M.; MEZZOGORI, D.; NERONI, M.; ZAMMORI, F. **Machine Learning for industrial applications: A comprehensive literature review**. *Expert Systems with Applications*, v. 175, p. 114820, 2021.

BHOIR, S.; PATIL, S. **The FASHION Visual Search using Deep Learning Approach**. *Library Philosophy and Practice*, n. 7569, n. p., 2023.

CASTRO, E. et al. **Fill in the blank for fashion complementary outfit product retrieval: Visum summer school competition**. *Machine Vision and Applications*, v. 34, n. 1, p. 16, 2023.

CENDON, B. V.; RIBEIRO, N. A. **Análise da literatura acadêmica sobre o portal periódico capes**. *Informação & Sociedade*, v. 18, n. 2, 2008.

CHAKRABORTY, S. et al. **Fashion recommendation systems, models, and methods: A review**. *Informatics*, v. 8, p. 49, 2021.

CHANG, A. A. et al. **Fashion trend forecasting using machine learning techniques: a review**. In: *Data Science and Intelligent Systems: Proceedings of 5th Computational Methods in Systems and Software 2021*, Vol. 2, p. 34–44, 2021.

CHANG, Y.-H.; ZHANG, Y.-Y. **Deep learning for clothing style recognition using yolov5**. *Micromachines*, v. 13, n. 10, p. 1678, 2022.

CUI, X. **An adaptive recommendation algorithm of intelligent clothing design elements based on large database**. *Mobile Information Systems*, v. 2022, p. 3334047, 2022.

FONTANINI, T.; FERRARI, C. **Would Your Clothes Look Good on Me? Towards Transferring Clothing Styles with Adaptive Instance Normalization**. *Sensors*, v. 22, n. 13, p. 5002, 2022.

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda 172

GE, Y.; ZHANG, R.; WU, L.; WANG, X.; TANG, X.; LUO, P. **A Versatile Benchmark for Detection, Pose Estimation, Segmentation and Re-Identification of Clothing Images.** In: CVPR, 2019.

GETMAN, R. R. et al. **Machine learning (ML) for tracking fashion trends: Documenting the frequency of the baseball cap on social media and the runway.** Clothing and Textiles Research Journal, v. 39, n. 4, p. 281–296, 2021.

GIRI, C. et al. **A detailed review of artificial intelligence applied in the fashion and apparel industry.** IEEE Access, v. 7, p. 95376–95396, 2019.

GU, X. et al. **Fashion analysis and understanding with artificial intelligence.** Information Processing & Management, v. 57, n. 5, p. 102276, 2020.

GUAN, C.; QIN, S.; LONG, Y. **Apparel-based deep learning system design for apparel style recommendation.** International Journal of Clothing Science and Technology, v. 31, n. 3, p. 376–389, 2019.

GUO, S.; HUANG, W.; ZHANG, X.; SRIKHANTA, P.; CUI, Y.; LI, Y.; BELONGIE, S. **The Imaterialist Fashion Attribute Dataset.** In: Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops, 2019.

HAENLEIN, M.; KAPLAN, A. **A brief history of artificial intelligence: On the past, present, and future of artificial intelligence.** California Management Review, v. 61, n. 4, p. 5–14, 2019.

HAN, A.; KIM, J.; AHN, J. **Color trend analysis using machine learning with fashion collection images.** Clothing and Textiles Research Journal, v. 40, n. 4, p. 308–324, 2022.

HAN, X.; WU, Z.; JIANG, Y.-G.; DAVIS, L. S. **Learning Fashion Compatibility with Bidirectional LSTMs.** In: ACM Multimedia, 2017.

HUYEN, C. **Designing Machine Learning Systems.** O'Reilly Media, Inc., 2022.

KIM, S. et al. **Automatic Measurements of Garment Sizes Using Computer Vision Deep Learning Models and Point Cloud Data.** Applied Sciences, v. 12, n. 10, p. 5286, 2022.

LEE, Y. A. **Trends of Emerging Technologies in the Fashion Product Design and Development Process.** In: LEE, Y. A. (Ed.). Leading Edge Technologies in Fashion Innovation. Palgrave Studies in Practice: Global Fashion Brand Management. Cham: Palgrave Macmillan, 2022. p. 1–15.

LIPOVETSKY, G. **O império do efêmero: a moda e seu destino nas sociedades modernas.** São Paulo: Editora Companhia das Letras, 2009.

LIU, J.; SONG, X.; CHEN, Z.; MA, J. **Neural fashion experts: I know how to make the complementary clothing matching.** Neurocomputing, v. 359, p. 249–263, 2019.

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda 173

LU, Y. **Artificial intelligence: a survey on evolution, models, applications, and future trends.** *Journal of Management Analytics*, v. 6, n. 1, p. 1-29, 2019.

LUCE, L. **Artificial intelligence for fashion: How AI is revolutionizing the fashion industry.** Apress, 2018.

MAHESH, B. **Machine Learning Algorithms - A Review.** *International Journal of Science and Research*, v. 9, n. 1, p. 381-386, 2020.

MARTÍN-MARTÍN, A. et al. **Google scholar, microsoft academic, scopus, dimensions, web of science, and opencitations coci: a multidisciplinary comparison of coverage via citations.** *Scientometrics*, v. 126, n. 1, p. 871-906, 2021.

MATZEN, K.; BALA, K.; SNAVELY, N. **Streetstyle: Exploring world-wide clothing styles from millions of photos.** arXiv preprint arXiv:1706.01869, 2017.

MIRANDA, A. P. **Consumo de moda: a relação pessoa-objeto.** São Paulo: Editora estação das letras e cores, 2019.

MUTHUKRISHNAN, N. et al. **Brief history of artificial intelligence.** *Neuroimaging Clinics*, v. 30, n. 4, p. 393-399, 2020.

PACKER, A. L. **The scielo open access: a gold way from the south.** *Canadian Journal of Higher Education*, v. 39, n. 3, p. 111-126, 2009.

PARÉ, G. et al. **Synthesizing information systems knowledge: A typology of literature reviews.** *Information & Management*, v. 52, n. 2, p. 183-199, 2015.

PENG, D. et al. **Unsupervised multi-modal modeling of fashion styles with visual attributes.** *Applied Soft Computing*, v. 115, 108214, 2022.

RATHORE, B. **Beyond trends: Shaping the future of fashion marketing with ai, sustainability and machine learning.** *Eduzone*, v. 6, n. 2, p. 16-24, 2017.

ROCHA, D.; SOARES, F.; OLIVEIRA, E.; CARVALHO, V. **Blind people: Clothing category classification and stain detection using transfer learning.** *Applied Sciences*, v. 13, n. 3, p. 1925, 2023.

SHIN, S.-Y.; JO, G.; WANG, G. **A novel method for fashion clothing image classification based on deep learning.** *Journal of Information and Communication Technology*, v. 22, n. 1, p. 127-148, 2023.

SHINDE, P. P.; SHAH, S. **A review of machine learning and deep learning applications.** In: 2018 Fourth international conference on computing communication control and automation (ICCUBEA), p. 1-6. IEEE, 2018.

SIPPER, M. **Combining Deep Learning with Good Old-Fashioned Machine Learning.** *SN COMPUT. SCI.*, v. 4, p. 85, 2023.

Explorando bases de dados para treinamento de modelos em aprendizagem de máquina na indústria da moda 174

STUART, R.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. Upper Saddle River, NJ, USA: Prentice-Hall, 2009.

SULTHANA, R. et al. **A review on the literature of fashion recommender system using deep learning**. International Journal of Performability Engineering, v. 17, n. 8, p. 695, 2021.
SUN, L.; ZHAO, L. Technology disruptions: exploring the changing roles of designers, makers, and users in the fashion industry. International Journal of Fashion Design, Technology and Education, v. 11, n. 3, p. 362-374, 2018.

TAHERDOOST, H.; MADANCHIAN, M. **Artificial intelligence and knowledge management: Impacts, benefits, and implementation**. Computers, v. 12, n. 4, p. 72, 2023.

TAUTKUTE, I. et al. **Deepstyle: Multimodal search engine for fashion and interior design**. IEEE Access, v. 7, p. 84613–84628, 2019.

VIJAYARAJ, A. et al. **Deep learning image classification for fashion design**. Wireless Communications and Mobile Computing, 2022.

XIAO, H.; RASUL, K.; VOLLGRAF, R. **Fashion-MNIST: a Novel Image Dataset for Benchmarking Machine Learning Algorithms**. 2017. Disponível em: <https://arxiv.org/abs/cs.LG/1708.07747>. Acesso em: 18 jan. 2024.

YANG, B. **Clothing design style recommendation using decision tree algorithm combined with deep learning**. Computational Intelligence and Neuroscience, 2022.

YIAN, S.; KYUNG-SHIK, S. **Hierarchical convolutional neural networks for fashion image classification**. Expert Systems with Applications, v. 116, p. 328-339, 2019.

whaZHANG, S. et al. **Watch fashion shows to tell clothing attributes**. Neurocomputing, v. 282, p. 98–110, 2018.

Recebido: 27 de fevereiro de 2024

Aprovado: 12 de julho de 2024