

**ANA CLARA SAISSE DA SILVA SANTOS**

**O DIABO VESTE DADO: REVISÃO DA LITERATURA SOBRE A IDENTIFICAÇÃO DE  
TENDÊNCIAS DE MODA NAS REDES SOCIAIS.**

**SÃO PAULO**

**2024**

**ANA CLARA SAISSE DA SILVA SANTOS**

**O DIABO VESTE DADO: REVISÃO DA LITERATURA SOBRE A IDENTIFICAÇÃO DE  
TENDÊNCIAS DE MODA NAS REDES SOCIAIS.**

**Monografia apresentada ao Programa de Educação  
Continuada da Escola Politécnica da Universidade de São  
Paulo, para obtenção do título de Especialista, pelo Pro-  
grama de Pós-Graduação em Engenharia de Dados e Big  
Data.**

**Área de concentração: Tecnologia da Informação –  
Engenharia/ Tecnologia/ Gestão**

**Orientadora: Prof. Dra. Lucia Vilela Leite Filgueiras.**

**SÃO PAULO**

**2024**

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catalogação-na-publicação

Saisse da S. Santos, Ana Clara

O DIABO VESTE DADO: REVISÃO DA LITERATURA SOBRE A IDENTIFICAÇÃO DE TENDÊNCIAS DE MODA NAS REDES SOCIAIS. / A. C. Saisse da S. Santos -- São Paulo, 2024.

60 p.

Monografia (Especialização em Engenharia de Dados e Big Data) - Escola Politécnica da Universidade de São Paulo. PECE – Programa de Educação Continuada em Engenharia.

1.Big Data 2.Engenharia de dados I.Universidade de São Paulo. Escola Politécnica. PECE – Programa de Educação Continuada em Engenharia II.t.

## **AGRADECIMENTOS**

Agradeço aos meus pais e à minha família, que sempre estiveram ao meu lado, apoiando meus sonhos e acreditando no meu potencial. Aos meus amigos, Vitória e Caio, pela amizade, pelo apoio e por me ouvirem em todos os momentos em que precisei. Ao corpo docente, por todo o conhecimento compartilhado ao longo desses dois anos de curso, com destaque especial à professora Lúcia, cuja paciência e dedicação foram fundamentais para minha orientação e crescimento nos últimos meses.

Também expresso minha gratidão à GFT, que contribuiu financeiramente para a realização deste curso, demonstrando confiança no meu desenvolvimento e investindo no meu crescimento profissional.

## **CURSO ENGENHARIA DE DADOS E BIG DATA**

Coord.: Prof. Solange N. Alves de Souza

Vice-Coord.: Prof. Pedro Luiz Pizzigatti Corrêa

### **Perspectivas profissionais alcançadas com o curso:**

*Como resultado direto da pós-graduação, consegui uma mudança significativa em minha carreira, passando da área de desenvolvimento para engenharia de Cloud dentro da empresa onde trabalho. Essa transição foi impulsionada pelo conhecimento adquirido durante o curso, a pós me permitiu explorar novas tecnologias e metodologias que ampliaram minha visão estratégica, e despertaram meu interesse em continuar estudando áreas como computação na nuvem e data visualization.*

## **RESUMO**

Com o crescimento das redes sociais na última década, a indústria têxtil é um dos setores que mais se beneficia do uso do Big Data para prever tendências. Os cinco Vs do Big Data — volume, variedade, velocidade, veracidade e valor — destacam o potencial dessas plataformas, que produzem dados massivos, diversificados e em alta velocidade, fundamentais para análises estratégicas.

Este trabalho realiza uma revisão da literatura sobre o uso de dados de redes sociais para a previsão de tendências de moda de vestuário, considerando o impacto crescente de plataformas como Instagram e Twitter. Foram revisados 19 artigos científicos publicados entre 2015 e 2024, avaliando metodologias, tecnologias e resultados.

Os resultados destacam o papel de tecnologias como aprendizado de máquina e inteligência artificial na análise de dados de redes sociais.

**Palavras-chave:** Redes sociais, previsão de tendências, moda, Big Data.

## ABSTRACT

With the growth of social media over the past decade, the textile industry is one of the sectors that benefits the most from using Big Data to predict trends. The five Vs of Big Data — volume, variety, velocity, veracity, and value — highlight the potential of these platforms, which generate massive, diverse, and high-speed data essential for strategic analysis.

This study conducts a literature review on the use of social media data for predicting fashion trends in apparel, considering the growing impact of platforms like Instagram and Twitter. 19 scientific articles published between 2015 and 2024 were reviewed, evaluating methodologies, technologies, and results.

The findings highlight the role of technologies such as machine learning and artificial intelligence in analyzing social media data.

**Keywords:** Social media, trend forecasting, fashion, Big Data.

## **LISTA DE FIGURAS**

Figura 1: Exemplo de cluster de cores ..... 29

## **LISTA DE TABELAS**

Tabela 1 - Resumo dos artigos analisados na revisão de literatura .....	25
---	----

## **LISTA DE ABREVIACÕES**

**API** – Application Programming Interface

**CNN** – Convolutional Neural Network

**GDPR** – General Data Protection Regulation

**IBGE** – Instituto Brasileiro de Geografia e Estatística

**LSTM** – Long Short-Term Memory

**ML** – Machine Learning

**NLP** – Natural Language Processing.

## SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	Objetivo .....	13
1.2	Justificativa.....	14
1.3	Metodologia.....	14
1.3.1	Formulação de Perguntas de Pesquisa.....	14
1.3.2	Critérios de Seleção .....	16
1.3.3	Análise dos Artigos .....	16
2	CONCEITOS FUNDAMENTAIS .....	17
2.1	Redes Sociais .....	17
2.2	Tendência .....	18
2.3	Previsão de tendências na indústria da moda.....	19
2.4	Marketing Digital e Moda.....	20
3	REVISÃO DE LITERATURA: PREVISÃO DE TENDÊNCIAS NA MODA.....	23
3.1	Organização do Capítulo.....	22
3.2	Metodologia de Revisão.....	23
3.3	Apresentação dos Resultados.....	24
3.3.1	Algoritmos e tecnologias utilizados .....	28
3.3.2	Definição de "tendência" nos artigos .....	31
3.3.3	Relevância de modelos de análise de texto .....	32
3.3.4	Tempo necessário para o treinamento dos modelos .....	34
3.3.5	Métodos de extração de dados utilizados.....	35
3.3.6	Confiabilidade das previsões baseadas em redes sociais .....	35
3.3.7	De acordo com os artigos, a previsão (baseada em redes sociais) traduz-se em vendas?.....	36
3.3.8	Consideração da localização nos estudos?.....	36
3.3.9	Objetos de moda analisados em cada estudo.....	37
4	DISCUSSÃO .....	39
4.1	Desafios e Limitações no Uso de Dados de Redes Sociais.....	39
4.2	Análise geográfica dos dados .....	40

4.3	Ética e Responsabilidade no Uso de Dados .....	42
5	CONCLUSÃO .....	45
5.1	TRABALHOS FUTUROS .....	45
	BIBLIOGRAFIA.....	47
	APÊNDICE A - RESUMOS DOS ARTIGOS ANALISADOS.....	54

## 1 INTRODUÇÃO

Segundo dados divulgados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), em novembro de 2023, 87,9% da população brasileira com dez anos ou mais têm acesso à internet, o que corresponde a mais de 160 milhões de pessoas. Desses, 83,2% afirmaram utilizar redes sociais como principal atividade na internet (IBGE, 2024).

Com a popularização das redes sociais na última década no Brasil, as empresas encontraram uma oportunidade única de explorar a vasta quantidade de dados gerados pelos usuários. Esses dados permitem desenvolver estratégias de marketing e de desenvolvimento de produtos alinhadas às demandas do consumidor. É possível extrair informações específicas sobre comportamentos, preferências e tendências, oferecendo uma base sólida para a tomada de decisões estratégicas.

Ao mesmo tempo, o varejo online cresceu e se consolidou como um dos principais canais de vendas no mercado brasileiro. De acordo com o Instituto Brasileiro de Economia da Fundação Getúlio Vargas (FGV IBRE, 2024), 16% do volume total de vendas do comércio no Brasil foram realizadas por plataformas de e-commerce no primeiro trimestre de 2024. Este foi o quarto trimestre consecutivo de crescimento, superando os índices de janeiro de 2020, quando as vendas digitais representavam apenas 9,2% do mercado nacional (Folha de São Paulo, 2024).

A análise de dados gerados por redes sociais é hoje essencial para empresas que desejam compreender melhor seus consumidores e mercados. Segundo Singhal (2019, tradução nossa), “a análise de redes sociais é representada como a capacidade de rastrear e dar forma ao significado nos dados coletados para apoiar decisões empresariais.”

O conceito dos cinco V's do Big Data ajuda a entender o potencial dessas informações:

1. **Volume** – A grande quantidade de dados gerados continuamente pelas redes sociais; fotos, vídeos, curtidas, hashtags, comentários e outros metadados. Esses dados são uma fonte rica para identificar padrões de comportamento e tendências emergentes.

2. **Velocidade** – A rapidez com que os dados são criados diariamente..
3. **Variedade** – A diversidade de formatos de dados, como texto, imagens, vídeos e metadados geográficos.
4. **Veracidade** – A importância de garantir a confiabilidade e a qualidade dos dados, eliminando ruídos e inconsistências.
5. **Valor** – A capacidade de transformar esses dados em insights estratégicos, apoioando tomadas de decisão baseadas em dados para otimizar processos e direcionar estratégias.

Segundo Singhal (2019, tradução nossa):

“A análise de dados das redes sociais compreendem as experiências de uso, comportamentos esperados, sentimentos, possibilidades de referência e insights de inovação, ao mesmo tempo em que cria uma base suficiente para as organizações utilizarem essas informações”. (SINGHAL, 2019).

Um exemplo de sucesso na aplicação de ciência de dados na indústria da moda é a *Heuritech*, uma empresa francesa que combina inteligência artificial com Big Data para fazer tendências com precisão. Utilizando redes sociais como fonte de dados primária, a *Heuritech* processa imagens e textos compartilhados por usuários de redes sociais, identificando padrões emergentes, como cores, estilos e diferentes materiais. Segundo a empresa, essa análise de dados permite não apenas prever tendências sazonais, mas também oferecer insights específicos por região ou público-alvo. Grandes marcas, como o grupo *Louis Vuitton* e *Dior*, já utilizam os serviços da *Heuritech* para adaptar suas coleções às preferências do consumidor.

Entretanto, a riqueza de dados disponíveis nas redes sociais ainda encontra alguns desafios como a necessidade de transformar dados não estruturados em *insights* açãoáveis importante. Por exemplo, seria mais eficiente focar em curtidas e reações? Hashtags? Ou priorizar a análise dos comentários dos usuários? Essas são algumas questões para empresas que desejam extrair valor estratégico dos dados sociais e aplicá-los à indústria da moda

A capacidade de visualizar dados de forma clara e compreensível representa um dos maiores desafios, mas também uma oportunidade de diferenciação no mercado. Representações visuais bem elaboradas, com dashboards interativos, possibilitam a interpretação rápida e precisa dos dados, fornecendo informações valiosas para estratégias de marketing.

Esse estudo inicial visa entender as metodologias existentes, ferramentas disponíveis e as lacunas no uso de Big Data e redes sociais na previsão de tendências para a indústria têxtil.

### **1.1 Objetivo**

Este trabalho tem como objetivo revisar a literatura científica que explora o uso de dados de redes sociais na análise e previsão de tendências de moda, com base em um conjunto de 19 artigos selecionados. Buscando-se compreender como as redes sociais, enquanto repositórios massivos de informações dinâmicas e em tempo real, têm sido exploradas como fonte de dados para identificar padrões de comportamento e antecipar tendências no setor da moda.

Pretende-se analisar as abordagens metodológicas utilizadas nos estudos, com foco em como as tecnologias, ferramentas e algoritmos empregados permitem a coleta, o processamento e a análise de grandes volumes de dados, incluindo técnicas baseadas em aprendizado de máquina, mineração de dados e inteligência artificial. Adicionalmente, este estudo visa identificar os principais resultados alcançados, os desafios enfrentados na utilização dessas metodologias, bem como as lacunas existentes na aplicação de tecnologias emergentes para a previsão de tendências de moda.

Outro objetivo é discutir as implicações práticas e teóricas dos resultados obtidos, considerando seu impacto no marketing de moda e no desenvolvimento de estratégias inovadoras para atender às demandas de um mercado em constante transformação. Ao integrar diferentes perspectivas acadêmicas e práticas, este trabalho busca contribuir para o avanço do conhecimento na interseção entre moda, tecnologia e ciência de dados, fornecendo subsídios para novas investigações e aplicações no campo

## 1.2 Justificativa

De acordo com a Associação Brasileira da Indústria Têxtil e de Confecção (ABIT) no Brasil, a indústria têxtil, é o segundo maior empregador na indústria de transformação, com US\$ 1,06 bilhão em exportações em 2021. Globalmente, segundo o *State of Fashion 2017 report* da consultoria McKinsey & Company, a indústria da moda é classificada como uma das mais importantes para a economia mundial, representando a sétima maior economia, caso fosse comparada ao PIB de países individuais.

Assim a previsão de tendências de moda é uma ferramenta estratégica essencial para diversos setores, incluindo o desenvolvimento de produtos, publicidade e relacionamento com o cliente. Além disso “um sistema de previsão é vital para prevenir problemas como excesso de estoque e escassez de inventário assim como a perda de receita e perda de clientes.” (S. Anitha; R. Neelakandan, 2024, tradução nossa).

Com a crescente disponibilidade de dados de redes sociais, é possível acessar informações em tempo real sobre comportamentos de consumo e tendências emergentes. Entretanto, para aproveitar plenamente essas oportunidades, é necessário dispor de boas práticas de coleta, armazenamento e análise de dados Serrano-Malebrán, Vidal-Silva e Veas-González (2023).

Esta monografia se justifica pela necessidade de consolidar o conhecimento atual sobre o uso de dados de redes sociais na previsão de tendências de moda, abordando métodos, métricas e resultados.

## 1.3 Metodologia

A presente monografia segue a abordagem de revisão da literatura. O processo foi conduzido com base nos seguintes passos:

### 1.3.1 Dimensões de Análise:

1. Definição de "tendência" nos artigos.
2. Algoritmos utilizados nos estudos.
3. Relevância de modelos de análise de texto.

4. Tempo necessário para o treinamento dos modelos.
5. Métodos de extração de dados utilizados.
6. Confiabilidade das previsões baseadas em redes sociais.
7. De acordo com os artigos, a previsão (baseada em redes sociais) traduz-se em vendas?
8. Consideração da localização nos estudos.
9. Objetos de moda analisados em cada estudo.

### **1.3.2 Critérios de Seleção:**

Foram incluídos estudos publicados entre 2015 e 2024 que focassem na previsão e análise de moda de vestuário. O principal objetivo foi selecionar artigos que utilizassem dados de redes sociais Instagram e Twitter<sup>1</sup> como base para prever tendências, devido à relevância dessas plataformas no mercado atual. No entanto, com o objetivo de proporcionar uma visão mais abrangente do mercado e das tecnologias empregadas nesse contexto também foram considerados artigos que utilizaram outras fontes de dados como a rede de compartilhamento de fotos Flicker, bases de dados com fotos dos principais eventos de moda mundial, postagens de blogs sobre uma ou mais peças de roupas.

As bases de dados consultadas incluíram Elsevier, IEEE, ACM Digital Library e SAGE Journals. As bases de dados selecionadas são reconhecidas pela qualidade e credibilidade das informações que oferecem. Elsevier e IEEE são referências nas áreas de tecnologia, com acesso a artigos revisados por pares e pesquisas atualizadas. ACM Digital Library se destaca na computação e inovação, essenciais para a análise de dados de redes sociais. Já a SAGE Journals fornece periódicos relevantes nas áreas de ciências sociais e gestão, importantes para entender a influência das redes sociais na moda.

### **1.3.3 Análise dos Artigos:**

Cada artigo foi analisado de acordo com um conjunto de questões previamente formuladas, buscando ferramentas utilizadas, resultados alcançados e desafios enfrentados. As respostas foram sintetizadas em uma tabela que organiza as informações de maneira estruturada, destacando as lacunas existentes nos estudos revisados e apontando oportunidades para futuras pesquisas no campo da previsão de tendências de moda. Essa abordagem visa proporcionar uma visão clara e comparativa dos métodos e contribuições de cada trabalho, além de orientar futuras investigações acadêmicas e aplicações práticas.

---

<sup>1</sup> Em outubro de 2023, a plataforma anteriormente conhecida como Twitter foi renomeada para X após sua aquisição pelo empresário Elon Musk. Contudo, para manter a consistência com os artigos analisados nesta revisão, que utilizam o nome "Twitter" em suas metodologias e análises, este trabalho também empregará o termo "Twitter" para se referir à plataforma, independentemente de sua nomenclatura atual.

## 2 CONCEITOS FUNDAMENTAIS

### 2.1 Redes Sociais

As redes sociais são plataformas digitais que conectam pessoas facilitando a troca de ideias. As redes sociais promovem o compartilhamento de informações e a interação com diferentes tipos de conteúdo, como textos, imagens, vídeos e áudios. Essas plataformas funcionam como espaços virtuais para a troca de opiniões, informações e interesses. Além disso, as redes sociais têm se consolidado como um espaço de geração de dados massivos, refletindo comportamentos, preferências e interações sociais dos usuários (Otre, Jorge e Ferreira, 2019).

Essas informações ajudam a entender, em tempo real, como as dinâmicas sociais e as mudanças culturais acontecem, oferecendo informações relevantes para áreas como marketing, moda e desenvolvimento de produtos. A velocidade e o volume de dados tornam as redes sociais ferramentas indispensáveis para empresas que desejam se manter competitivas hoje em dia (Otre, Jorge e Ferreira, 2019).

Ao integrar análises provenientes de diferentes redes sociais e explorar os algoritmos utilizados em cada uma delas, é possível construir uma visão mais abrangente sobre como tendências emergem, evoluem e são adaptadas em diferentes contextos culturais e temporais. Essa abordagem destaca o papel central das redes sociais e dos métodos computacionais como ferramentas para a análise de tendências no mercado da moda (Sudhakar et al. 2021).

Além disso, a capacidade de segmentar públicos e personalizar a experiência do usuário torna as redes sociais ainda mais valiosas para a previsão de comportamentos de consumo (Mehta, Reena & Udita, Kulkarni, 2020). A análise de dados extraídos dessas plataformas revelam padrões que são essenciais para a identificação precoce de tendências, permitindo que as empresas ajustem suas estratégias de marketing e posicionamento de produtos de maneira proativa.

## 2.2 Tendência

De acordo com o *Dicionário Michaelis* (s.d.), "tendência", pode ser definida como:

1. Disposição natural que leva alguém a agir de determinada maneira ou a seguir certo caminho; inclinação, predisposição. Disposição natural que leva alguém a agir de determinada maneira ou a seguir certo caminho; inclinação, predisposição.
2. Inclinação natural para certas atividades; vocação.
3. Orientação comum em determinada categoria ou grupo de pessoas; movimento.

Uma tendência, de acordo com Kotler (2000), pode ser definida como uma direção ou sequência de eventos que apresenta determinado impulso e orientação, sendo possível observá-la e analisá-la ao longo do tempo (Kotler, 2000). Embora frequentemente associadas a algo passageiro, as tendências refletem comportamentos sociais mais amplos. Elas permitem analisar como as pessoas respondem a mudanças sociais e como o ambiente cultural se adapta para incorporá-las.

A moda de vestuário é uma expressão cultural que traduz os valores, aspirações e transformações sociais de uma época. Por meio de roupas, acessórios e estilos, a moda vai além da funcionalidade, tornando-se uma forma de comunicação visual que reflete identidade, status e pertencimento cultural (Lipovetsky, 2009).

Na indústria da moda de vestuário, as tendências funcionam como um reflexo do espírito do tempo (*zeitgeist*), capturando os valores, aspirações e desafios sociais de um determinado período (Raymond, 2010). Ao mesmo tempo, atuam como um indicador das mudanças culturais e das preferências coletivas, sendo amplamente influenciadas por fatores como tecnologia, política, economia e, cada vez mais, as redes sociais.

De acordo com Otre, Jorge e Ferreira (2019), os produtos da moda seguem um ciclo que pode ser dividido em cinco fases distintas: introdução, aumento da popularidade, pico de popularidade, queda da popularidade e, por fim, rejeição. Frings (2012) complementa esse conceito, explicando que o ciclo de uma tendência frequentemente começa com marcas e designers renomados, que lançam produtos

de alto custo direcionados à classe alta e celebridades. Com o tempo, essas peças são copiadas por empresas menores, que as oferecem a preços mais acessíveis, resultando em um aumento significativo na popularidade. No entanto, à medida que o público começa a se desinteressar, a tendência perde força, sinalizando o fim de sua ascensão e o início de um novo ciclo de modas.

No entanto, com o avanço das redes sociais, o ciclo de tendências sofreu uma aceleração sem precedentes. O que antes demandava anos para ganhar força e se consolidar, agora pode surgir, alcançar o pico e desaparecer em questão de semanas. Isso deu origem a fenômenos como os "trends" e "micro-trends", impulsionados por plataformas digitais como Twitter, Instagram e TikTok (El País, 2023). Essas tendências rápidas são moldadas por algoritmos de recomendação e a constante interação entre usuários. Embora representem oportunidades para a moda acompanhar os desejos dos consumidores em tempo real, também levantam desafios, como a dificuldade de previsão de tendências e o impacto no consumo sustentável.

### **2.3 Previsão de tendências na indústria da moda.**

A capacidade de prever tendências é essencial para a indústria da moda, pois permite que marcas e designers antecipem as demandas do mercado e planejem suas coleções de maneira estratégica.

Até a década de 1990, era comum que as marcas lançassem poucas coleções principais por ano, alinhadas às estações primavera/verão e outono/inverno, essa prática teve origem na França no século XIX (João Braga, 2013). Charles Frederick Worth, frequentemente reconhecido como o pai da alta-costura, foi pioneiro em criar desfiles de moda quatro vezes ao ano para apresentar suas criações, contribuindo para a padronização de um calendário sazonal de moda (João Braga, 2013). Essas apresentações, realizadas regularmente, ajudaram a estabelecer um ciclo previsível, permitindo que tendências fossem introduzidas de forma organizada e com tempo suficiente para planejamento e produção (Victoria and Albert Museum, s.d.).

Esse modelo tradicional seguia um ritmo que permitia às empresas planejar e produzir suas peças com meses e até anos de antecedência. No entanto, a introdução do modelo de negócios da Zara revolucionou a indústria ao adotar o conceito de fast

*fashion* (IESE Business School, 2015). A empresa passou a produzir coleções menores e lançá-las continuamente ao longo do ano, verificando continuamente as demandas dos consumidores e reduzindo drasticamente o tempo entre a criação e a chegada dos produtos às lojas. Esse modelo não só aumentou a frequência das coleções, mas também tornou a indústria mais acessível e reativa às demandas dos consumidores (Ghemawat; Nueno, 2003).

Hoje, com a popularização das redes sociais e a disseminação de microtendências, o ciclo de vida das tendências tornou-se ainda mais curto. Plataformas como Instagram e TikTok popularizam estilos em questão de dias, muitas vezes criando um movimento que atinge o ápice e desaparece em semanas. Ou seja, a previsão de tendências deixou de ser apenas uma vantagem estratégica e passou a ser uma necessidade para as marcas que desejam se manter competitivas e relevantes (Associate Press, 2024).

Ferramentas tecnológicas desempenham um papel vital nesse processo. Empresas, como a já citada *Heuritech*, fundada por dois PhDs em Machine Learning, utilizam inteligência artificial para analisar mais de três milhões de imagens em redes sociais diariamente e combina essas análises com modelos preditivos para antecipar quais tendências ganharão popularidade (*Heuritech*, s.d.). Eles já colaboraram com marcas de luxo como Louis Vuitton e Dior para prever demandas específicas de produtos e ajustar suas coleções com base em dados visuais (*Heuritech*, s.d.).

De acordo com Otre, Jorge e Ferreira (2019), “o Big Data pode auxiliar os processos de inovação de produtos, reduzindo o tempo de resposta para o mercado”. Assim o conhecimento adquirido possibilita às organizações maior agilidade e assertividade nas tomadas de decisões, atendendo às demandas do mercado e contribuindo para práticas de negócios mais eficientes e sustentáveis.

## **2.4 Marketing Digital e Moda.**

O marketing digital é definido como o uso de tecnologias digitais, especialmente a internet, para promover produtos e serviços, engajando consumidores por meio de canais online como websites, e-mails, redes sociais e publicidade digital. Essa abordagem permite uma comunicação mais direta e

personalizada com o público-alvo, além de possibilitar a mensuração precisa dos resultados das campanhas (Kotler, Armstrong, 2018).

O marketing digital modificou a maneira como as marcas de moda se comunicam com seus consumidores. Antes limitado a vitrines físicas e campanhas publicitárias tradicionais, o setor passou a explorar plataformas digitais para alcançar um público global e diversificado. Redes sociais como Instagram, TikTok e YouTube desempenham um papel central nessa mudança de paradigma, permitindo que as marcas apresentem suas coleções de forma visualmente atraente e criando conexões principalmente com o público jovem (Forbes Brasil, 2022). O Instagram, por exemplo, é amplamente utilizado para exibir campanhas e conteúdos exclusivos, enquanto o TikTok tornou-se um espaço para viralizar tendências por meio de desafios, hashtags e colaborações com usuários (Forbes Brasil, 2022).

Outro avanço significativo no marketing digital da moda é o uso de Big Data para personalizar estratégias (Otre, Jorge e Ferreira, 2019). Dados extraídos de interações em redes sociais, históricos de compras e comportamentos de navegação online são amplamente utilizados para segmentar consumidores e adaptar mensagens às suas preferências individuais. Essa prática permite que marcas personalizem suas campanhas, aumentando sua relevância e impacto. Estudos, como o de Serrano-Malebrán, Vidal-Silva e Veas-González (2023), destacam que variáveis como a qualidade da informação, interatividade e recomendações boca a boca desempenham papéis fundamentais na aceitação de anúncios digitais direcionados. Isso é evidente em anúncios programáticos, que utilizam esses dados para segmentar públicos específicos de forma eficiente. Além disso, a personalização é potencializada por algoritmos capazes de sugerir produtos com base no comportamento individual de cada usuário (Serrano-Malebrán, Vidal-Silva e Veas-González (2023)).

O storytelling também ocupa uma posição de destaque no marketing digital de moda (Otre, Jorge e Ferreira, 2019). Marcas utilizam narrativas visuais para criar uma conexão emocional com os consumidores, apresentando histórias que refletem seus valores e identidades. Por meio de vídeos curtos e conteúdos interativos, as marcas conseguem capturar a atenção do público e transmitir mensagens impactantes (Forbes Brasil, 2022).

Além disso, o marketing digital na moda é sustentado pela mensuração precisa de resultados (Otre, Jorge e Ferreira, 2019). Ferramentas como Google Analytics e as métricas integradas das redes sociais, como numero de interações, oferecem dados em tempo real sobre o desempenho das campanhas, permitindo ajustes rápidos e melhorias contínuas. Métricas de engajamento social são essenciais para avaliar o sucesso das estratégias adotadas.

Como exemplo de inovação no marketing digital, destaca-se o uso de plataformas sociais que integram descoberta de produtos e experiências de compra. Redes como o Instagram permitem que os consumidores explorem e adquiram itens de forma prática, simplificando o processo de decisão e eliminando barreiras entre inspiração e aquisição. Essa funcionalidade reflete como a integração de tecnologias digitais pode aprimorar a jornada do consumidor, alinhando-se ao uso estratégico de Big Data para personalizar ofertas e atender às demandas específicas do mercado (Otre, Jorge e Ferreira, 2019).

### 3 REVISÃO DE LITERATURA: PREVISÃO DE TENDÊNCIAS NA MODA

#### 3.1 Organização do Capítulo

Neste capítulo, os resultados da revisão serão apresentados em duas seções principais:

Ferramentas e Métodos Utilizados na Previsão de Tendências – Uma análise das ferramentas analíticas, técnicas de mineração de dados e modelos preditivos descritos nos estudos revisados.

Principais Contribuições e Lacunas Identificadas – Um resumo das principais descobertas dos estudos, incluindo o impacto das redes sociais na previsão de tendências e os desafios enfrentados pelos pesquisadores.

#### 3.2 Metodologia de Revisão

A metodologia de revisão iniciou-se com a formulação das palavras-chave de busca e dos critérios de inclusão e exclusão.

Para realizar a revisão de literatura, inicialmente, foi utilizada a plataforma Google Scholar, devido à sua ampla abrangência e acessibilidade, como ferramenta principal para a busca inicial de artigos. As pesquisas foram conduzidas utilizando strings de busca como "fashion forecasting in social media", "fashion trend forecasting", "social media fashion trends", "social media fashion forecasting", "predicting fashion trends from social media", "social media analytics fashion forecasting", "fashion trend prediction using social media data", "impact of social media on fashion trends", "fashion forecasting machine learning social media", "fashion data analysis social media platforms".

Os critérios de inclusão e exclusão foram:

- Critérios de Inclusão: Estudos publicados entre 2015 e 2024, que abordassem a análise de tendências utilizando dados de redes sociais, com foco específico no setor de moda de vestuário.
- Critérios de Exclusão: Utilizavam dados de redes sociais sem foco na indústria de moda e artigos que abordassem aspectos de previsão de

tendências e revisões de literatura que não fazem parte do escopo deste trabalho.

Após a identificação inicial de artigos relevantes, cada estudo foi analisado quanto à sua base de origem para garantir a qualidade e a confiabilidade das publicações. Como resultado, os artigos foram extraídos de diversas bases de dados acadêmicas reconhecidas, incluindo ScienceDirect, SpringerLink, ACM Digital Library, IEEE Xplore, SAGE Journals, Semantic Scholar, ArXiv, Atlantis Press e MDPI.

**Processo de Seleção:** Após uma triagem inicial de 19 estudos, os 16 artigos finais foram escolhidos por atenderem aos critérios estabelecidos e apresentarem relevância para o tema.

### **3.3 Apresentação dos Resultados**

Artigos	Tecnologia ou Algoritmo utilizado	Como a extração dos dados é feita?	A predição das redes sociais é confiável?	A predição das redes sociais se traduz em vendas?	Análisa as tendências geográficamente?
Leveraging Multiple Relations For Fashion Trend Forecasting Based On Social Media - Sudhakar et al. (2024)	LSTM (Long Short-Term Memory) e Redes Neurais Convolucionais (CNN)	Data Scraping	sim (com ressalvas)	Não menciona.	A análise geográfica não é mencionada no artigo.
Big Data Analysis in Social Networks for Managing Risks Clothing Industry - Blekanov et al. (2019)	Bitemr topic model (modelo de text analysis)	Data Scraping	sim (com ressalvas)	Não menciona.*	A análise geográfica não é mencionada no artigo.
Googling Fashion: Forecasting Fashion Consumer Behaviour Using Google Trends - Silva et al. (2019)	Analise de Séries Temporais	Data Scraping	Sim	Sim	O artigo menciona a análise de termos de busca por regiões específicas.
Style in the Age of Instagram: Predicting Success within the Fashion Industry using Social Media - Park et al. (2016)	Árvore de Decisão e Random Forest	Data Scraping	Sim	Não menciona.*	A análise geográfica não é mencionada no artigo.
How to Extract Fashion Trends From Social Media? A Robust Object Detector With Support For Unsupervised Learning - Gabale et al. (2018)	CDSSD (É baseado no SSD - Single Shot MultiBox Detector) Esse artigo também menciona (mas não explica) o YOLO e SSD	Data Scraping	Não menciona	Não menciona.	A análise geográfica não é mencionada no artigo.
Twitter and Fashion Forecasting: An Exploration of Tweets regarding Trend Identification for Fashion Forecasting - Beheshti-Kashi (2015)	Mineração de texto e Análise exploratória de tweets	Data Scraping	A predição pode ser confiável (o artigo ressalta que depende da qualidade de dados)	Não menciona.	A análise geográfica não é abordada. (mas reconhece que é importante)
Social Image Mining for Fashion Analysis and Forecasting - Wazarkar e Keshavamurthy (2020)	Árvores de Decisão e Random Forest (para análise de imagens, Decision Tree, k-Nearest Neighbor, Random Forest para previsão.)	Data Scraping	A predição pode ser confiável (o artigo ressalta que depende da qualidade de dados)	Não menciona.	A análise geográfica não é mencionada no artigo.

<b>Social4Fashion: An Intelligent Expert System for Forecasting Fashion Trends from Social Media Contents</b> - Balloni et al. (2024)	Redes Neurais Convolucionais (CNN)	Data Scraping	Sim	Não menciona.	Sim, pelo metadados dos posts.
<b>The Rise of Fashion Informatics: A Case of Data-Mining-Based Social Network Analysis in Fashion</b> - Zhao e Min (2019)	Text Mining	Data Scraping (usando a antiga API do twitter)	Sim	Não menciona.	A análise geográfica não é mencionada no artigo.
<b>Who, Where, and What to Wear? Extracting Fashion Knowledge from Social Media</b> - Ma et al. (2019)	Bi-LSTM (Bidirectional Long Short-Term Memory), ResNet (um tipo de Rede Neural Convolucional)	Data Scraping	Sim	Não menciona.*	Sim, pelo metadados dos posts.
<b>Neo-Fashion: A Data-Driven Fashion Trend Forecasting System Using Catwalk Analysis</b> - Zhao et al. (2024)	Mask RCNN (um tipo de Rede Neural Convolucional)	Coleta fotos de desfiles de moda (fashion weeks) e também extraí figuras de uma base de dados chamada WGSN.	Não mencionado (pois não trouxe de redes sociais).	Não menciona.	A análise geográfica não é mencionada no artigo.
<b>Fashion Forward: Forecasting Visual Style in Fashion</b> - Al-Halah et al. (2017)	Redes Neurais Convolucionais (CNN)	Dataset já estava pronto (80K fashion products from amazon).	Não foca em rede social	Não menciona.	A análise geográfica não é mencionada no artigo.
<b>Color Trend Analysis Using Machine Learning with Fashion Collection Images</b> - Han et al. (2022)	MMAN (Macro-Micro Adversarial Network), K-means Clustering	Data Scraping (Usando as fotos das coleções postadas no site da vogue)	Não foca em rede social	Não menciona.	A análise geográfica não é mencionada no artigo.
<b>GeoStyle: Discovering Fashion Trends and Events</b> - Mall et al. (2019)	Redes Neurais Convolucionais (CNN)	Data Scraping	Sim	Não menciona.	O framework categoriza imagens em 44 principais cidades do mundo e analisa as tendências por local.
<b>Approaching Fashion Design Trend Applications Using Text Mining and Semantic Network Analysis</b> - An e Park (2020)	Mineração de texto e análise de sentimentos	Uso de uma plataforma chamada Textom	Sim	Não menciona.	A análise geográfica não é mencionada no artigo.

<b>Exploitation of Social Network Data for Forecasting Garment Sales - Giri et al. (2019)</b>	Text mining e modelos de Regressão Linear, Análise de Séries Temporais	Data Scraping	Sim	Sim.	A análise geográfica não é abordada, (mas reconhece que é importante)

Tabela 1: Consolidação da análise dos artigos na revisão de literatura.

### 3.3.1 Algoritmos utilizados nos estudos.

#### Aprendizado Profundo e Redes Neurais

As Redes Neurais Convolucionais que chamaremos aqui por CNNs (Convolutional Neural Networks) são utilizadas nos artigos para classificar imagens. Modelos avançados, como *LSTM* e *Mask RCNN*, destacam-se na análise sequencial e segmentação de imagens. Esses métodos são úteis para identificar características de roupas.

As CNNs foram utilizadas para identificar padrões complexos em dados visuais, como texturas, cores e formas, sendo fundamentais na previsão de tendências e análise de atributos visuais.

Primeiramente as imagens são convertidas em matrizes numéricas, depois filtros são aplicados para identificar características visuais, como texturas ou formas. No artigo "GeoStyle: Discovering Fashion Trends and Events", de Mall et al. (2019), essa etapa detectou padrões como estilos de jaquetas em diferentes partes do mundo.

Durante o treinamento, o modelo ajusta seus parâmetros para melhorar a precisão. No artigo "Who, Where, and What to Wear? Extracting Fashion Knowledge from Social Media", de , isso ajudou a recomendar trajes adequados para eventos com base em imagens analisadas.

Após treinada, a CNN fornece saídas como categorias de roupas ou previsões de tendências.

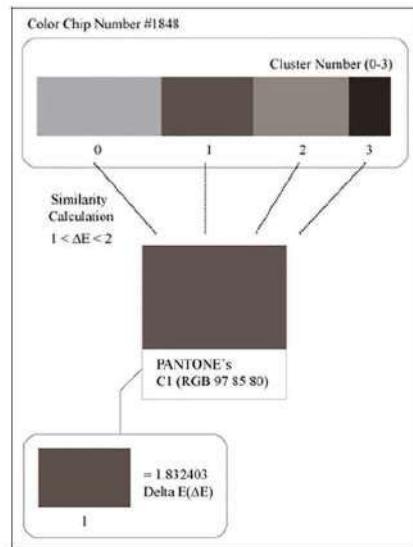
#### K-means Clustering

É uma técnica de aprendizado não supervisionado amplamente utilizada para identificar padrões em grandes volumes de dados visuais. Segundo Jain (2010), o K-means funciona agrupando itens com características semelhantes em diferentes categorias, chamadas de clusters.

Assim o algoritmo recebe dados visuais, como características extraídas de imagens (ex.: cores, texturas ou formas). Esses dados são transformados em representações numéricas para processamento. Cada ponto de dado é associado ao cluster mais próximo com base na distância. Por exemplo, no artigo "Color Trend

"Analysis Using Machine Learning with Fashion Collection Images", de Han et al. (2022), os pixels das imagens foram agrupados para formar clusters que representavam paletas de cores mais utilizadas em coleções reais, exemplificado na figura 1.

Figura 1 – exemplo de cluster de cores.



Fonte: HAN et al., 2022

Os clusters formados são analisados para extrair insights significativos. No caso dos artigos, isso inclui identificar cores ou padrões dominantes e determinar como eles variam entre categorias de produtos. No artigo de Han et al. (2022) que foi usado de exemplo, os clusters mostraram discrepâncias entre as paletas propostas pela empresa Pantone e as cores efetivamente usadas nas coleções, o que ajudou os designers a ajustarem suas coleções futuras.

### Técnicas de mineração de texto (*Text Mining*)

A mineração de texto é uma técnica utilizada para analisar grandes volumes de dados textuais, como comentários de fotos e tweets, com o objetivo de identificar tópicos, sentimentos e padrões relevantes. De acordo com Feldman e Sanger (2007), essa abordagem combina algoritmos de Processamento de Linguagem Natural (NLP) e métodos estatísticos para extrair informações úteis de textos não estruturados. Nos artigos revisados, a técnica é frequentemente empregada para explorar as interações

entre marcas e consumidores, compreender preferências e prever tendências. O primeiro passo na mineração de texto é coletar dados textuais relevantes, como comentários de redes sociais, postagens de blogs ou outras fontes. Os textos coletados passam por um processo de limpeza e padronização, como remoção de *stopwords* (palavras irrelevantes), pontuações e normalização dos termos. Isso garante que apenas informações relevantes sejam analisadas.

No artigo "Big Data Analysis in Social Networks for Managing Risks Clothing Industry", de Blekanov et al. (2019), o Bitemr Topic Model (um algoritmo utilizado para agrupar palavras em temas recorrentes) foi aplicado para entender quais tópicos relacionados à moda foram mais mencionados em tweets coletados..

## **Modelos de Regressão e Séries Temporais**

Modelos de regressão e séries temporais são ferramentas para prever padrões futuros com base em dados históricos. Eles ajudam a identificar tendências, sazonalidades e relações entre variáveis. Essas técnicas são particularmente úteis para prever vendas, analisar interesses de consumidores e compreender como os eventos passados influenciam os padrões de consumo futuros.

### **1. Regressão Linear**

A regressão linear estabelece uma relação entre uma variável dependente (como vendas de um produto) e uma ou mais variáveis independentes (como preço, campanhas de marketing ou estações do ano). Ela é amplamente usada para avaliar a influência de fatores específicos no comportamento de mercado.

### **2. Análise de Séries Temporais**

Modelos de séries temporais, como ARIMA, ETS, TBATS e NNAR, analisam dados históricos para prever padrões futuros, considerando sazonalidades e ciclos repetitivos. No Artigo de Silva et al. (2019), os modelos analisaram dados do Google Trends para prever o interesse em moda, com foco em picos de busca. O artigo utilizou essas informações para identificar padrões e tendências de consumo, como o aumento de buscas por "vestidos de verão" durante certas épocas do ano. A ideia era explorar como os dados de pesquisas online podem indicar a popularidade e o comportamento do consumidor na indústria da moda.

A integração dessas duas abordagens permitiu prever vendas e tendências de forma mais precisa, combinando padrões históricos com variáveis contextuais. Por exemplo, no artigo "Exploitation of Social Network Data for Forecasting Garment Sales", de Giri et al. (2019), os modelos previram vendas de produtos de moda ao correlacionar dados históricos de vendas com sentimentos e tendências extraídos de redes sociais.

### **Árvores de Decisão**

As árvores de decisão são modelos preditivos utilizados categorizar dados e identificar padrões com base em critérios hierárquicos. Cada nó ou “folha” da árvore representa uma decisão baseada em um atributo específico, e os ramos conduzem a resultados possíveis. Essa abordagem é eficaz para analisar dados visuais e comportamentais, fornecendo insights detalhados e açãoáveis.

As árvores de decisão são modelos preditivos que utilizam dados organizados em atributos e variáveis para categorizar informações e identificar padrões. Por exemplo, no artigo "Social Image Mining for Fashion Analysis and Forecasting", de Wazarkar e Keshavamurthy (2020), foram analisadas imagens de moda para prever atributos visuais, como tecidos, utilizando algoritmos de mineração de imagem. A construção da árvore de decisão envolveu definir critérios de decisão em cada nó, como "o tecido é preto?" ou "o tecido é vermelho?", orientando a classificação de itens ou padrões.

#### **3.3.2 Definição de "tendência" nos artigos**

Segundo os artigos tendências na moda podem ser compreendidas como padrões que refletem as mudanças no comportamento do consumidor, preferências e demandas ao longo do tempo. Esses padrões surgem de diferentes fontes, como dados visuais, sociais e históricos, sendo moldados por influências sociais, culturais e até políticas, como aponta o artigo "Leveraging Multiple Relations For Fashion Trend Forecasting Based On Social Media", de Sudhakar et al. (2021).

Já no mundo digital, tendências são frequentemente refletidas em redes sociais, como Instagram, Twitter e blogs, onde o engajamento, sentimentos e

interações dos usuários ajudam a identificar cores, estilos, tecidos e combinações predominantes.

Além disso, tendências podem ser específicas de eventos, como analisado no artigo "The Rise of Fashion Informatics: A Case of Data-Mining-Based Social Network Analysis in Fashion", de Zhao e Min (2019), e no artigo "GeoStyle: Discovering Fashion Trends and Events", de Mall et al. (2019), como aqueles capturados em imagens de desfiles de moda ou em fotografias de rua, que destacam estilos regionais. Elas também estão relacionadas à demanda do consumidor, mapeando a correlação entre sentimentos expressos em redes sociais e dados de vendas, permitindo prever flutuações no mercado, como apontado no artigo "Exploitation of Social Network Data for Forecasting Garment Sales", de Giri et al. (2019).

### **3.3.3 Relevância de modelos de análise de texto**

A análise e a mineração de texto são relevantes, como indicam diversos artigos, como o de Blekanov et al. (2019), de Beheshti-Kashi (2015), de Zhao e Min (2019) e o artigo de Giri et al. (2019), sobre redes sociais baseadas em texto, especialmente o Twitter.

Há uma vasta literatura acadêmica sobre a utilização de tweets para análise de sentimentos dos usuários em tempo real. Contudo, a análise de dados do Twitter na área da moda enfrenta alguns desafios específicos. Uma abordagem comum para a análise de tweets é o estudo de hashtags (#) utilizadas pelos usuários, o que se mostra eficaz em eventos ao vivo, mas limita-se pelo fato de que nem todos utilizam hashtags para expressar opiniões sobre determinados temas.

Por exemplo, o artigo de Zhao e Min (2019), analisou tweets durante as semanas de moda da Paris Fashion Week 2017 e agrupou-os em clusters de nós, permitindo identificar a marca de maior influência, o interesse por vestidos de noiva e até a celebridade presente mais comentada. No entanto, focar apenas nas hashtags impediu a análise de sentimentos dos usuários em relação às coleções apresentadas.

Outro estudo, descrito no artigo de Blekanov et al. (2019), analisou cerca de 250 mil tweets sobre "sneakers" coletados em setembro de 2018. Os autores separaram as interações (curtidas e comentários) em positivas e negativas,

observando um pico de tweets negativos no início do mês devido à frustração dos usuários com o adiamento de um modelo de tênis da Nike. Contudo, a hashtag mais usada teve apenas 1.987 menções, um número baixo dentro do volume total de 250 mil tweets, exemplificando a limitação de depender exclusivamente de hashtags para capturar o panorama completo.

O artigo de Giri et al. (2019), ilustra isso bem: os autores coletaram dados do Twitter e registros de vendas de uma marca italiana de roupas ao longo de seis meses (de abril a setembro de 2018), totalizando 838 tweets, dos quais 313 foram mantidos após a limpeza de dados. Eles realizaram uma análise aprofundada aplicando o algoritmo Naïve Bayes (NB) para classificar os tweets, além de usar parâmetros complexos como Texto, Favoritado, Data de Criação, Localização, Retweetado, Longitude e Latitude, entre outros. Esse nível de detalhe permitiu uma avaliação mais completa dos dados.

O artigo "Approaching Fashion Design Trend Applications Using Text Mining and Semantic Network Analysis", de An e Park (2020), foca na mineração de texto em blogs de moda entre 2009 e 2019, analisando quase 30 mil postagens sobre jaquetas. Os autores conseguiram extrair informações sobre design, como estilo, cor, tecido e padrão ao longo do tempo, e realizaram uma análise de agrupamento em séries temporais para identificar quatro tipos de tendências: crescentes, decrescentes, atemporais (sempre populares) e sazonais. A conclusão foi que essas categorias de tendências permitem uma análise detalhada, auxiliando designers e comerciantes a identificar tendências com maior precisão e aplicabilidade, ainda que o estudo não tenha alcançado previsões futuras.

Outros artigos, que têm seu foco principal na análise visual dos dados, ainda utilizam a análise de texto. Esses artigos se dividem entre os que consideram a análise textual relevante, mas com ressalvas, como o "Social4Fashion: An Intelligent Expert System for Forecasting Fashion Trends from Social Media Contents", de Balloni et al. (2024), que destaca a importância da análise de texto para dados de mídias sociais (hashtags e descrições de postagens), mas alerta para a confiabilidade de dados textuais devido à possível inconsistência entre o conteúdo visual e os metadados textuais.

### 3.3.4 Tempo necessário para o treinamento dos modelos.

Os artigos revisados não fornecem informações claras sobre o tempo necessário para o treinamento dos modelos. Independentemente do tipo de modelo utilizado — seja mineração de texto, árvores de decisão ou CNNs — o tempo de treinamento depende diretamente da capacidade computacional disponível. Modelos executados em sistemas com maior número de GPUs e memória tendem a ser mais rápidos e eficientes.

Entre os artigos estudados, aqueles com períodos de coleta de dados mais longos apresentaram, em geral, resultados mais robustos. No artigo de Giri et al. (2019), por exemplo, os autores coletaram dados ao longo de seis meses, entre o início de abril e o final de setembro de 2018, e compararam esses dados com as vendas da empresa no mesmo período. Embora tenham trabalhado com um conjunto de dados relativamente pequeno — 838 tweets, dos quais apenas 318 foram usados após a limpeza — o estudo demonstrou que a temporalidade e a qualidade dos dados são mais impactantes para a previsão de vendas do que a mera quantidade de dados disponíveis.

O artigo de Balloni et al. (2024), coletou dados do Instagram de janeiro de 2022 até janeiro de 2023, visando estudar as tendências ao longo de um ano completo. De forma semelhante "Neo-Fashion: A Data-Driven Fashion Trend Forecasting System Using Catwalk Analysis", de Zhao et al. (2024), os dados analisados consistiram em imagens dos desfiles das semanas de moda ao longo de 2019, resultando em previsões satisfatórias sobre cores e peças de roupas para as diferentes estações do ano seguinte.

Por outro lado, os artigos que dedicaram menos tempo à coleta de dados apresentaram resultados menos satisfatórios. O artigo de Blekanov et al. (2019), por exemplo, realizou a coleta em apenas um mês. Embora tenha analisado as informações disponíveis, a conclusão não foi robusta o suficiente para gerar resultados significativos.

### **3.3.5 Métodos de extração de dados utilizados.**

A maioria dos artigos realiza data scraping — uma técnica que coleta dados automaticamente de sites e plataformas digitais. Essa prática permite extrair grandes volumes de informações de redes sociais, sites e outras fontes online. No contexto dos artigos, o data scraping é utilizado para capturar dados sobre moda e tendências em redes sociais e plataformas de moda, com exceção dos Silva et al. (2019), Zhao et al. (2024), Al-Halah et al. (2017), Han et al. (2022), An e Park (2020) todos utilizaram data scraping para minerar os dados dos estudos.

Os estudos que focaram no Twitter utilizaram a API disponível na época. Já os que se concentraram no Instagram adotaram métodos variados de *scraping*.

O artigo de Zhao et al. (2024) utilizou fotos das principais semanas de moda do mundo e também coletou dados de uma plataforma de análise de dados de moda, a *WGSN*. O artigo de Rostamzadeh et al. (2018), por sua vez, fez scraping das coleções de moda publicadas no site da *Vogue*, uma renomada referência em comunicação de moda.

### **3.3.6 Confiabilidade das previsões baseadas em redes sociais.**

De acordo com os artigos a confiabilidade das análises baseadas em redes sociais é reconhecida, mas condicionada a certos fatores. Os estudos destacam que métodos avançados, como CNNs, técnicas de mineração de texto e análise de sentimentos, desempenham um papel fundamental na obtenção de previsões alinhadas à realidade. Mas, a qualidade dos dados, as técnicas de limpeza e o contexto específico de cada análise desempenham um papel crucial.

De forma geral, os artigos sugerem que as redes sociais são fontes relevantes e úteis para prever tendências e comportamentos no setor da moda, especialmente devido ao volume de dados gerados por usuários. No entanto, limitações como ruído, dados não estruturados e vieses podem comprometer os resultados se não forem devidamente tratados. Modelos que integram dados históricos e sociais, como o artigo de Zhao et al. (2024) demonstraram ser confiáveis, superando abordagens tradicionais.

A confiabilidade é considerada possível e, em muitos casos, demonstrada nos estudos, ela depende fortemente de uma fundamentação técnica sólida, da qualidade do conjunto de dados e da escolha correta das metodologias para extrair insights válidos e aplicáveis.

### **3.3.7 De acordo com os artigos, a predição (baseada em redes sociais) traduz-se em vendas?**

A relação entre as previsões baseadas em redes sociais e as vendas é explorada de forma limitada nos artigos analisados. Embora a maioria não trate desse impacto de forma direta, alguns artigos destacam como a análise eficaz de dados sociais pode influenciar o mercado e potencialmente alavancar vendas.

O artigo de Giri et al. (2019), é o que mais diretamente aborda essa relação. Ele combina dados históricos de vendas com sentimentos extraídos de tweets para prever vendas futuras. O estudo demonstra uma correlação significativa entre o engajamento social e os números de vendas.

Já no artigo "Style in the Age of Instagram: Predicting Success within the Fashion Industry using Social Media", de Park et al. (2016), a mineração de texto e análise de tweets identificam picos de menções a temas de moda, como cores e estilos diferentes, que coincidem com momentos de maior atenção do público. Embora não explore diretamente as vendas, os autores sugerem que tendências qualitativas detectadas em redes sociais podem influenciar as escolhas dos consumidores.

Por outro lado, alguns artigos, como de Wazarkar e Keshavamurthy (2020), concentram-se em prever tendências sazonais e atributos de moda, mas não exploram diretamente a conexão dessas previsões com o aumento ou diminuição de vendas.

### **3.3.8 Consideração da localização nos estudos.**

A análise de tendências geográficas é mencionada de forma limitada nos artigos, com muitos não abordando diretamente esse aspecto ou indicando que ele não foi considerado, embora sua importância seja reconhecida na maioria dos artigos.

Os artigos "Who, Where, and What to Wear? Extracting Fashion Knowledge from Social Media", de Ma et al. (2019), e "GeoStyle: Discovering Fashion Trends and Events", de Mall et al. (2019), são os que exploram a análise geográfica de maneira mais detalhada. Ambos utilizam os metadados dos posts, como localização e timestamp (data/hora), para fundamentar suas análises. No entanto, há diferenças importantes entre eles: o artigo Ma et al. (2019) incorpora também dados textuais, como comentários dos usuários e hashtags, para contextualizar as tendências e associá-las a eventos ou ocasiões específicas. Por outro lado, o artigo de Mall et al. (2019) foca em dados visuais, analisando atributos como cores, tecidos e designs para mapear variações regionais e geográficas, sem considerar outros elementos textuais.

### 3.3.9 Objetos de moda analisados em cada estudo

Os artigos analisaram uma grande variedade de objetos de moda, tanto peças específicas como categorias mais amplas como cores e diferentes tecidos. Alguns estudos focaram em itens específicos, como jaquetas, bolsas, sapatos (botas e modelos de sapatos de salto alto).

Modelos de moda também foram analisados em artigos que exploraram suas características físicas e engajamento em redes sociais, como no caso da análise de tweets durante a Paris Fashion Week de 2017. Além disso, temas como cores, tecidos e combinações de estilos foram amplamente investigados em diferentes contextos e eventos. O artigo "Color Trend Analysis Using Machine Learning with Fashion Collection Images", de Han et al. (2022), estuda as paletas de cores e analisa se elas condizem com a paleta Pantone divulgada naquele ano, concluindo que há diferenças significativas entre o que a indústria têxtil efetivamente fabrica e as paletas que a Pantone publica anualmente.

O Artigo "Fashion-Gen: The Generative Fashion Dataset and Challenge", de Rostamzadeh et al. (2018), analisa imagens sociais, identificando cores, tecidos e designs para prever tendências emergentes. Já o Artigo de Wazarkar e Keshavamurthy (2020), utiliza técnicas de clustering para agrupar imagens com base em atributos como cor e tecido, classificando as tendências em padrões temporais. O Artigo de Al-Halah et al. (2017), se concentra na análise de combinações de cores e

estilos em postagens do Instagram, aplicando aprendizado profundo para prever popularidade futura.

O Artigo "GeoStyle: Discovering Fashion Trends and Events", de Mall et al. (2019), destaca a relação entre roupas, cores e eventos específicos, vinculando esses atributos a contextos regionais e sociais. Já o Artigo de Al-Halah et al. (2017), identifica estilos visuais latentes, como silhuetas e combinações de cores, com base em dados históricos. O artigo de Han et al. (2022) realiza uma análise detalhada de tendências de cores, comparando paletas previstas por instituições como Pantone com aquelas efetivamente utilizadas em coleções de moda.

## 4 DISCUSSÃO

### 4.1 Desafios e Limitações no Uso de Dados de Redes Sociais

Entre os principais obstáculos na coleta de dados de redes sociais estão a qualidade dos dados coletados e os vieses introduzidos pelos algoritmos das plataformas, que podem distorcer os resultados das análises e influenciar decisões estratégicas. Os dados disponíveis em redes sociais, como fotos, vídeos, curtidas, hashtags e comentários, são amplamente não estruturados, heterogêneos e inconsistentes.

Um dos desafios mais evidentes é a presença de ruído nos dados, como informações irrelevantes, duplicadas ou fora de contexto, que podem comprometer a precisão dos modelos preditivos. Por exemplo, hashtags populares como #ootd (*outfit of the day*), #fashion ou #parisfashionweek são usadas em posts que mostram desde imagens relacionadas à moda até paisagens ou conteúdos promocionais irrelevantes. Além disso, há casos em que a localização das postagens é registrada de forma imprecisa ou intencionalmente alterada, como quando um usuário em Roma, na Itália, marca sua foto como sendo em Nova Iorque, nos Estados Unidos. Esses fatores podem dificultar a extração de padrões confiáveis e comprometer a análise de tendências.

Os algoritmos das redes sociais também apresentam um impacto significativo, pois tendem a priorizar conteúdos com base em métricas de engajamento determinadas pelas próprias plataformas. Isso pode levar à amplificação de determinados tipos de conteúdo enquanto outros são negligenciados, resultando em uma visão distorcida das preferências do público. Por exemplo, tendências visualmente impactantes, como peças minimalistas ou de cores vibrantes, podem receber atenção desproporcional em detrimento de estilos mais menos populares ou regionais.

Apesar dessas dificuldades, existem soluções para refinar os dados e melhorar sua análise. Ferramentas avançadas de filtragem e segmentação são essenciais para lidar com os desafios mencionados. O Artigo de Balloni et al. (2024), por exemplo, utiliza CNNs como a VGG-16 para classificar imagens e identificar elementos de moda, como roupas e acessórios, eliminando componentes irrelevantes, como fotos que não contêm peças de roupa ou acessórios, fundos ou objetos fora do contexto *fashion*. Já o artigo de Gabale et al. (2018) destaca o uso do modelo CDSSD

(Convolution-Deconvolution Single Shot Detector), que lida com variáveis como iluminação inconsistente e elementos visuais distrativos, garantindo que apenas os objetos relevantes sejam analisados.

Na análise de texto, algoritmos de mineração desempenham um papel crucial ao remover ruídos como *stopwords*, emojis, caracteres especiais e informações irrelevantes. Esses métodos estruturam os dados textuais, permitindo análises mais precisas e úteis, que capturam nuances semânticas importantes para entender o comportamento do consumidor.

Além disso, a integração de dados provenientes de diferentes fontes, como redes sociais variadas, dados de vendas online e a expertise de designers de moda, é essencial para criar uma visão equilibrada e representativa do mercado.

#### 4.2 Análise geográfica dos dados

O impacto cultural é um dos elementos mais significativos na definição e adoção de tendências, variando amplamente entre regiões devido a fatores como tradições locais, preferências estéticas, clima e valores sociais. Na Tailândia, por exemplo, o Dia dos Pais, celebrado no aniversário do rei, possui um forte simbolismo cultural que influencia diretamente a moda. Durante essa data, é comum o uso de roupas amarelas, simbolizando respeito e devoção ao monarca. Essa tradição reflete-se no aumento da demanda por peças nessa cor, como observado por Zhao et al. (2024), onde uma plataforma desenvolvida pelos autores identificou, com base em dados de redes sociais, um pico no uso da cor amarela, no período de celebração do Dia dos Pais no país.

Diferenças culturais e climáticas também influenciam a forma como tendências globais são adaptadas regionalmente, e o Brasil oferece um exemplo claro dessa diversidade. Enquanto estados do Sul e Sudeste costumam incorporar tendências de inverno como casacos, botas e tecidos mais quentes durante os meses frios, no Nordeste, onde o clima é predominantemente quente durante todo o ano, peças leves e cores vibrantes continuam predominantes, mesmo no inverno. Essa variação regional reflete não apenas as diferenças climáticas, mas também as preferências culturais e as necessidades práticas das populações locais.

Para marcas globais, a coleta e análise de dados geográficos em redes sociais oferecem um desafio. Esses dados, extraídos de metadados associados a postagens, como localizações marcadas, hashtags regionais, o idioma predominante nos comentários e *timestamp*, permitem identificar preferências e tendências específicas de diferentes regiões. Além de plataformas como o Instagram, Zhao et al. (2024) destaca o uso de imagens geolocalizadas de outra rede social, o Flickr, que, combinadas com atributos visuais extraídos das imagens, ajudam a mapear variações regionais e sazonais de estilos. Esses dados visuais e geográficos permitem identificar padrões de moda relacionados a cores, tecidos e estilos predominantes em diferentes localidades. Isso ajuda as empresas a criar campanhas e coleções que ressoem com públicos locais.

A coleta desses dados apresenta dificuldades significativas; o principal desafio está na precisão das localizações marcadas pelos usuários. Por exemplo, uma pessoa pode marcar uma postagem no Rio de Janeiro, mas residir na Bahia, o que pode distorcer a análise geográfica. Além disso, muitos usuários deixam a opção de geolocalização desativada ou utilizam marcadores genéricos, como "Brasil", tornando difícil identificar padrões regionais específicos. O uso de hashtags, embora útil, também pode ser ambíguo, já que elas não garantem uma correspondência exata com a localização real do público-alvo.

Ferramentas avançadas de inteligência artificial, como o GoogLeNet, mencionado no artigo "GeoStyle: Discovering Fashion Trends and Events" de Mall et al. (2019), podem extrair atributos visuais, como cores e tecidos, de imagens geolocalizadas, enquanto a ResNet, utilizada no artigo "Who, Where, and What to Wear? Extracting Fashion Knowledge from Social Media" de Ma et al. (2019), auxilia na classificação de estilos e no mapeamento de padrões regionais. Além disso, algoritmos de mineração de texto, como o Naïve Bayes, são eficazes na análise de hashtags e comentários, complementando as informações geográficas e corrigindo inconsistências.

Outra abordagem eficaz é a segmentação baseada em clusters geográficos e demográficos. Métodos como o K-Means agrupam usuários com comportamentos e interesses semelhantes em regiões específicas, mesmo quando os dados de localização não são precisos. Por exemplo, engajamentos em postagens relacionadas a

eventos locais, como festivais ou celebrações regionais, oferecem insights adicionais que ajudam a preencher lacunas nas informações geográficas. Esse tipo de análise é exemplificado no artigo de Mall et al. (2019), que utiliza dados do Instagram e do Flickr para identificar padrões regionais de estilo vinculados a eventos locais.

Além disso, estratégias que integram padrões de engajamento com dados culturais e temporais enriquecem a coleta de dados geográficos. Essa abordagem permite que as plataformas ajustem suas análises a contextos regionais específicos, refinando os resultados e corrigindo informações de localização incompletas. A combinação dessas práticas reforça a capacidade de entender como tendências globais são adaptadas localmente, possibilitando análises mais alinhadas às dinâmicas culturais, sociais e mercadológicas de cada região.

Ferramentas como o Mask RCNN, mencionada no artigo “Neo-Fashion: A Data-Driven Fashion Trend Forecasting System Using Catwalk Analysis” de Zhao et al. (2024), também podem ser utilizadas para identificar itens de moda específicos em imagens, contribuindo para um mapeamento visual mais detalhado.

Essas estratégias, ao unir dados visuais, textuais e geográficos, oferecem soluções robustas para superar as limitações das redes sociais e explorar todo o potencial das análises geográficas na moda. Isso permite às marcas globais criar campanhas e coleções mais alinhadas às características culturais e sociais de seus públicos-alvo em diferentes regiões.

#### **4.3 Ética e Responsabilidade no Uso de Dados**

Nas redes sociais, onde os dados são utilizados para identificar tendências, prever comportamentos e planejar coleções, a coleta ética de dados é indispensável. Regulamentações como o GDPR (Regulamento Geral de Proteção de Dados) na União Europeia e a LGPD (Lei Geral de Proteção de Dados) no Brasil estabelecem padrões rigorosos para a coleta, processamento e armazenamento de dados pessoais. Essas leis garantem aos usuários direitos como o consentimento explícito, o acesso às informações coletadas e a possibilidade de solicitar a exclusão de seus dados. As empresas que não respeitam essas normas estão sujeitas a multas severas.

Nos artigos estudados, com apenas duas exceções, todos utilizaram o *data scraping*, que envolve a extração automatizada de informações de sites e plataformas sociais. No entanto, nenhum dos estudos analisados especifica se as práticas adotadas são inteiramente legais ou se foram realizadas em conformidade com as regulamentações, evidenciando que o uso do data scraping é um território cinzento. Embora seja uma ferramenta indispensável para reunir grandes volumes de dados e possibilitar análises detalhadas, seu uso muitas vezes se dá em um contexto que não é claramente definido pelas leis ou pelos termos de uso das plataformas.

Sob a perspectiva do GDPR, o *data scraping* é permitido somente quando respeita o consentimento do usuário e os termos de uso das plataformas. Porém, as condições de uso dessas ferramentas variam amplamente e mudam de acordo com cada rede social. Apesar das incertezas legais, o *data scraping* continua sendo uma prática para viabilizar estudos acadêmicos e análises estratégicas.

Para mitigar as preocupações éticas e legais associadas ao *data scraping*, é fundamental adotar práticas que minimizem os riscos e protejam a privacidade dos indivíduos. A anonimização dos dados se destaca como uma estratégia essencial para tornar a coleta mais responsável. Isso pode ser alcançado por meio de:

- Remoção de identificadores pessoais, como nomes, IDs de contas, localizações detalhadas e timestamps precisos.
- Pseudonimização, substituindo identificadores únicos por códigos aleatórios que não possam ser rastreados.
- Agregação de dados, agrupando informações em categorias amplas para reduzir a granularidade.
- Filtragem automatizada, que exclua informações irrelevantes ou sensíveis no momento da coleta.
- Além disso, os estudos demonstraram o uso de ferramentas que permitem uma análise mais focada em padrões coletivos do que em informações pessoais. Por exemplo, o Mask RCNN no Artigo Zhao et al. (2024), e o GoogLeNet no

artigo de Mall et al. (2019) foram usados para identificar atributos visuais, como cores e estilos, sem envolver diretamente dados pessoais. Essas abordagens são uma alternativa ética que permite a análise de dados sem comprometer a privacidade.

Embora o *data scraping* permaneça em uma área cinzenta do ponto de vista legal, sua aplicação pode ser justificada quando realizada de maneira responsável, com práticas que priorizem a ética e a proteção dos usuários. Nesse contexto, é essencial equilibrar a necessidade de inovação com o respeito às normas de privacidade, utilizando ferramentas que viabilizem estudos e análises sem ultrapassar os limites éticos.

## 5 CONCLUSÃO

A presente revisão da literatura evidenciou o potencial significativo do uso de dados de redes sociais para a previsão de tendências de moda na indústria têxtil, destacando o papel central de tecnologias como aprendizado de máquina e inteligência artificial no processamento e análise de grandes volumes de informações. Plataformas como Instagram e Twitter têm desempenhado um papel crucial na formação e disseminação de tendências, oferecendo insights valiosos para marcas e profissionais da indústria.

Apesar dos avanços, foram identificados desafios relacionados à qualidade e veracidade dos dados, ressaltando a necessidade de metodologias robustas que minimizem ruídos e vieses. A integração de dados geográficos e sociais também foi apontada como um aspecto essencial para entender como tendências globais se manifestam em diferentes contextos regionais, mas ainda carece de maior exploração.

Por fim, o estudo reafirma o papel transformador da análise de Big Data no setor da moda e a importância de aprimorar ferramentas e abordagens que possibilitem previsões mais confiáveis e contextualizadas, considerando as particularidades culturais e as nuances locais já discutidas ao longo do trabalho.

### 5.1 TRABALHOS FUTUROS

Embora o presente estudo tenha abordado principalmente redes sociais como Instagram e Twitter, trabalhos futuros podem expandir o escopo para incluir plataformas emergentes, como o TikTok, que têm ganhado relevância no cenário global devido à sua forte influência cultural e potencial para impulsionar tendências virais. Além disso, redes sociais regionais, como o WeChat, amplamente utilizada na China, oferecem oportunidades únicas para investigar comportamentos locais e explorar mercados de alta complexidade cultural.

Essas plataformas emergentes e regionais apresentam características e dinâmicas distintas que podem enriquecer a compreensão de tendências de moda, permitindo análises mais diversificadas e adaptadas a diferentes públicos e contextos. Explorar como essas redes sociais contribuem para a formação de tendências também

pode abrir novos caminhos para a integração de dados culturais, sociais e comportamentais em sistemas de previsão de tendências.

Outro desenvolvimento possível deste estudo seria a elaboração de um dashboard interativo, utilizando as tecnologias discutidas neste estudo. Esse dashboard poderia integrar dados de redes sociais, como imagens, hashtags, engajamento e localização, para fornecer análises em tempo real sobre tendências de moda. A ferramenta também poderia permitir a personalização dos parâmetros de análise, oferecendo suporte a marcas e profissionais do setor da indústria têxtil e profissionais de marketing na identificação de padrões e insights estratégicos.

A criação desse tipo de plataforma contribuiria para uma maior aplicabilidade prática dos conceitos discutidos, ao transformar grandes volumes de dados em informações acessíveis e acionáveis. Essa abordagem reforça a conexão entre pesquisa acadêmica e inovação tecnológica, facilitando a tomada de decisão baseada em dados.

## BIBLIOGRAFIA

Androniki Sapountzi, Kostas E. Psannis, Social networking data analysis tools & challenges, Future Generation Computer Systems. Volume 86, 2018, Pages 893-913, ISSN 0167-739X, <https://doi.org/10.1016/j.future.2016.10.019>.

ANITHA, S.; NEELAKANDAN, R. *Demand Forecasting New Fashion Products: A Review Paper*. *Forecasting*, 2024. Disponível em: <https://onlinelibrary.wiley.com/doi/epdf/10.1002/for.3192>.

ASSOCIATED PRESS. TikTok Influencers: Trends in Food and Fashion. AP News, 2024. Disponível em: <https://apnews.com/projects/tik-tok-influencers-trends-food-fashion/>.

BRAGA, João. Um século de moda: de 1901 a 2000. São Paulo: Disal Editora, 2014.

FELDMAN, R.; SANGER, J. *The Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. Cambridge University Press, 2007.

FOLHA DE S.PAULO. Online representa 16% das vendas do comércio no Brasil; percentual sobe há 4 trimestres. Folha de S.Paulo, 10 abr. 2024. Disponível em: <https://www1.folha.uol.com.br/mercado/2024/04/online-representa-16-das-vendas-do-comercio-no-brasil-percentual-sobe-ha-4-trimestres.shtml>.

FORBES BRASIL. *Instagram e TikTok polarizam disputa pela atenção de marcas e creators*. 2022. Disponível em: <https://forbes.com.br/forbes-tech/2022/09/instagram-e-tiktok-polarizam-disputa-pela-atencao-de-marcas-e-creators/>.

FRINGS, G. S. Moda: do conceito ao consumidor. Trad. Mariana Belloli. Porto Alegre: Bookman, 2012

Gémar G., Jiménez-Quintero J. A. (2015) Text mining social media for competitive analysis. *Tourism & Management Studies*. 105, 11(1) 84-90.

GHEMAWAT, Pankaj; NUENO, José Luis. ZARA: Fast Fashion. Harvard Business School, 2006. Disponível em: <https://www.hbs.edu/faculty/Pages/item.aspx?num=29832>.

HEURITECH. Heuritech: AI-powered fashion trend forecasting. Disponível em: <https://heuritech.com>.

IBGE. Em 2023, 87,2% das pessoas com 10 anos ou mais utilizaram internet, segundo o módulo Tecnologia da Informação e Comunicação (TIC) da Pesquisa Nacional por Amostra de Domicílios (PNAD). Agência de Notícias IBGE, 27 out. 2023. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/41026-em-2023-87-2-das-pessoas-com-10-anos-ou-mais-utilizaram-internet>.

IESE BUSINESS SCHOOL. The Fast Fashion Business Model: How Zara Stays Ahead of the Curve. 2015. Disponível em: <https://www.iese.edu/insight/articles/fast-fashion-business-model-zara/>.

IESE INSIGHT. *The nuts and bolts of fast fashion*. IESE Business School, 2023. Disponível em: <https://www.iese.edu/insight/articles/fast-fashion-business-model-zara/>.

Ignoatto, Maicon & Webber, Carine. (2019). Inteligência Competitiva nas Mídias Sociais: Um Estudo de Caso na Moda. *Scientia cum Industria*. 7. 156-164. DOI: 10.18226/23185279.v7iss2p156.

Jain, Anil. (2010). Data Clustering: 50 Years Beyond K-Means. *Pattern Recognition Letters*. 31. 651-666. 10.1016/j.patrec.2009.09.011.

KOTLER, Philip. Administração de Marketing: A Edição do Novo Milênio. São Paulo: Prentice Hall, 2000.

KOTLER, Philip; ARMSTRONG, Gary. Princípios de Marketing. 17. ed. São Paulo: Pearson, 2018.

LIPOVETSKY, Gilles. O império do efêmero: A moda e seu destino nas sociedades modernas. São Paulo: Companhia das Letras, 2009.

Maria Teresa Romão, Sérgio Moro, Paulo Rita, Pedro Ramos. Leveraging a luxury fashion brand through social media, European Research on Management and Business Economics. Volume 25, Issue 1, 2019, Pages 15-22, ISSN 2444-8834,<https://doi.org/10.1016/j.iedeen.2018.10.002>.

Mehta, Reena & Udita, Kulkarni. (2020). Impact of Personalized Social Media Advertisements on Consumer Purchase Intention. *Annals of Dunarea de Jos University of Galati. Fascicle I. Economics and Applied Informatics*. 26. 15-24. 10.35219/eai15840409101.

OTRE, Maria Alice Campagnoli; JORGE, Carlos Francisco Bitencourt; FERREIRA, Tamires Guedes. Informação e Moda na Era do Big Data: Como a Informação Digital

Inovou a Moda e Tornou-a Mais Competitiva. Revista Ibero-Americana de Ciências da Informação, v. 14, n. 2, p. 164-181, 2021. Disponível em: [https://iberoamericanic.org/rev/article/view/335/pdf\\_194](https://iberoamericanic.org/rev/article/view/335/pdf_194).

Raymond, M. (2010). The trend forecaster's handbook. London: Laurence King.  
 Serrano-Malebran, Jorge & Vidal, Cristian & Veas-González, Iván. (2023). Social Media Marketing as a Segmentation Tool. *Sustainability*. 15. 1151. 10.3390/su15021151.

Singhal, T. K. (2019). Social media analytics and new product development. *International Journal of Innovative Technology and Exploring Engineering*, 8(11), 3682–3686. <https://doi.org/10.35940/ijitee.K1991.0981119>

STEAL THE LOOK. A geração Z e a nostalgia: como funciona o ciclo de tendências de 20 anos? Steal The Look, 22 fev. 2023. Disponível em: <https://stealthe-look.com.br/a-geracao-z-e-a-nostalgia-e-como-funciona-o-ciclo-de-tendencias-de-20-anos/>.

TENDÊNCIA. In: MICHAELIS, *Dicionário Michaelis online*. Disponível em: <https://michaelis.uol.com.br/moderno-portugues/busca/portugues-brasileiro/tend%C3%A3ncia/>, acesso em: 16 out. 2024

Vice. How the 20-Year Trend Cycle Collapsed. Vice, 7 jun. 2022. Disponível em: <https://www.vice.com/en/article/how-the-20-year-trend-cycle-collapsed/>. Acesso em: 18 nov. 2024.

VICTORIA AND ALBERT MUSEUM. The fashion show: A history of haute couture. Disponível em: <https://www.vam.ac.uk/articles/the-fashion-show>.

Y. Liu and T. Zhang, Research on Digital Marketing Strategies of Fast Fashion Clothing Brands Based on Big Data, 2019 34rd Youth Academic Annual Conference of Chinese Association of Automation (YAC), Jinzhou, China, 2019, pp. 552-556, doi: 10.1109/YAC.2019.8787647

YOO, Jungmin. Can consumer engagement on social media affect brand extension success? The case of luxury fashion brands and restaurants. *Journal of Retailing and Consumer Services*, v. 79, p. 103885, 2024. Disponível em: <https://doi.org/10.1016/j.jretconser.2024.103885>.

Zhebin Xue, Qing Li, Xianyi Zeng, Social media user behavior analysis applied to the fashion and apparel industry in the big data era. *Journal of Retailing and Consumer*

Services, Volume 72, 2023, 103299, ISSN 0969-6989, <https://doi.org/10.1016/j.jretconser.2023.103299>

### **Artigos analisados**

1- SUDHAKAR, M.; PANAKANTI, Rishika; REDDY, Kukudala Naveen; SRINIJA, Ramani; KUMAR, Kadamanchi Shiva. **Leveraging Multiple Relations For Fashion Trend Forecasting Based On Social Media.** Disponível em: <https://sifisheressciences.com/index.php/journal/article/view/1228>. Acesso em: 20 julho 2024.

2-BLEKANOV, Ivan; KRYLATOV, Alexander; IVANOV, Dmitri; BUBNOVA, Yulia. **Big Data Analysis in Social Networks for Managing Risks Clothing Industry.** Disponível em: <https://www.sciencedirect.com>. DOI: 10.1016/j.ifacol.2019.11.447. Acesso em: 10 set. 2024.

3- SILVA, Emmanuel Sirimal; HASSANI, Hossein; MADSEN, Dag Øivind; GEE, Liz. **Googling Fashion: Forecasting Fashion Consumer Behaviour Using Google Trends.** *Social Sciences*, v. 8, n. 4, p. 111, 2019. Disponível em: <https://doi.org/10.3390/socsci8040111>. Acesso em: 17 nov. 2024.

4 - PARK, Jaehyuk; CIAMPAGLIA, Giovanni; FERRARA, Emilio. **Style in the Age of Instagram: Predicting Success within the Fashion Industry using Social Media.** In: CONFERENCE ON COMPUTER-SUPPORTED COOPERATIVE WORK & SOCIAL COMPUTING, 19., 2016, San Francisco. New York: ACM, 2016. p. 64–73. DOI: 10.1145/2818048.2820065.

5- GABALE, Vijay; SUBRAMANIAN, Anand Prabhu. **How to Extract Fashion Trends From Social Media?: A Robust Object Detector With Support For Unsupervised Learning.** In: ACM CONFERENCE (KDD'18), 2018, London. Anais [...]. London: ACM, 2018. 6 p. Disponível em: <https://doi.org/10.48550/arXiv.1806.10787>.

6 - BEHESHTI-KASHI, Samaneh. **Twitter and Fashion Forecasting: An Exploration of Tweets regarding Trend Identification for Fashion Forecasting.** 2015.

Disponível em: <https://api.semanticscholar.org/CorpusID:42082694>. Acesso em: 17 nov. 2024.

7- WAZARKAR, Seema; KESHAVAMURTHY, Bettahally N. **Social image mining for fashion analysis and forecasting**. *Applied Soft Computing*, v. 95, p. 106517, 2020. ISSN 1568-4946. Disponível em: <https://doi.org/10.1016/j.asoc.2020.106517>.

8 - BALLONI, Emanuele; PIETRINI, Rocco; FABIANI, Matteo; FRONTONI, Emanuele; MANCINI, Adriano; PAOLANTI, Marina. **Social4Fashion: An intelligent expert system for forecasting fashion trends from social media contents**. *Expert Systems with Applications*, v. 252, parte A, 2024, p. 124018. ISSN 0957-4174. Disponível em: <https://doi.org/10.1016/j.eswa.2024.124018>. Acesso em: 17 nov. 2024.

9- ZHAO, L.; MIN, C. **The Rise of Fashion Informatics: A Case of Data-Mining-Based Social Network Analysis in Fashion**. *Clothing and Textiles Research Journal*, v. 37, n. 2, p. 87–102, 2019. DOI: 10.1177/0887302X18821187. Disponível em: <https://doi.org/10.1177/0887302X18821187>.

10 - MA, Yunshan; YANG, Xun; LIAO, Lizi; CAO, Yixin; CHUA, Tat-Seng. **Who, Where, and What to Wear? Extracting Fashion Knowledge from Social Media**. In: 27th ACM INTERNATIONAL CONFERENCE ON MULTIMEDIA, 27., 2019, Nice. New York: Association for Computing Machinery, 2019. p. 257–265. DOI: 10.1145/3343031.3350889. Disponível em: <https://doi.org/10.1145/3343031.3350889>.

11- ZHAO, L.; LI, M.; SUN, P. **Neo-Fashion: A Data-Driven Fashion Trend Forecasting System Using Catwalk Analysis**. *Clothing and Textiles Research Journal*, v. 42, n. 1, p. 19–34, 2024. DOI: 10.1177/0887302X211004299. Disponível em: <https://doi.org/10.1177/0887302X211004299>.

12- WANG, Zhendi; LIU, Xiaogang. **Statistical Analysis and Big Data Based Intelligent Fashion Prediction Model**. In: IEEE CONFERENCE ON

TELECOMMUNICATIONS, OPTICS AND COMPUTER SCIENCE (TOCS), 2021, Shanghai. Anais [...]. New York: IEEE, 2021. DOI: 10.1109/TOCS53301.2021.9688919. Disponível em: <https://doi.org/10.1109/TOCS53301.2021.9688919>.

13- AL-HALAH, Ziad; STIEFELHAGEN, Rainer; GRAUMAN, Kristen. **Fashion Forward: Forecasting Visual Style in Fashion.** In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2017, Venice. Anais [...]. New York: IEEE, 2017. p. 388–397. DOI: 10.48550/arXiv.1705.06394. Disponível em: <https://doi.org/10.48550/arXiv.1705.06394>.

14 - 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. DOI: 10.1177/0887302X21995948. Disponível em: <https://doi.org/10.1177/0887302X21995948>.

15 - ROSTAMZADEH, Negar; HOSSEINI, Seyedarian; BOQUET, Thomas; STOKOWIEC, Wojciech; ZHANG, Ying; JAUVIN, Christian; PAL, Chris. **Fashion-Gen: The Generative Fashion Dataset and Challenge.** *arXiv*, 2018. Disponível em: <https://doi.org/10.48550/arXiv.1806.08317>.

16 - MALL, Utkarsh; MATZEN, Kevin; HARIHARAN, Bharath; SNAVELY, Noah; BALA, Kavita. **GeoStyle: Discovering Fashion Trends and Events.** In: INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2019. *arXiv*, 2019. Disponível em: <https://doi.org/10.48550/arXiv.1908.11412>.

17 - BHOIR, Smita V.; PATIL, Sunita R. **The FASHION Visual Search using Deep Learning Approach.** *Library Philosophy and Practice (e-journal)*, n. 7569, 2023. Disponível em: <https://digitalcommons.unl.edu/libphilprac/7569>.

18 - AN, H.; PARK, M. **Approaching fashion design trend applications using text mining and semantic network analysis.** *Fashion and Textiles*, v. 7, n. 34, 2020.

DOI: 10.1186/s40691-020-00221-w. Disponível em: <https://doi.org/10.1186/s40691-020-00221-w>.

19 - GIRI, Chandadevi; THOMASSEY, Sebastien; ZENG, Xianyi. **Exploitation of Social Network Data for Forecasting Garment Sales.** *International Journal of Computational Intelligence Systems*, v. 12, n. 2, p. 1423–1435, 2019. DOI: 10.2991/ijcis.d.191109.001. ISSN: 1875-6891. Disponível em: <https://www.atlantis-press.com/journals/ijcis/>.

## APÊNDICE A - Artigos Selecionados

Nesta seção, são apresentados os artigos selecionados, com a indicação de seus respectivos títulos, autores e resumos. Além disso, são feitas considerações sobre a relevância de cada estudo para o desenvolvimento do trabalho, destacando suas contribuições específicas e como eles se relacionam com os objetivos da pesquisa.

**Artigo 1:** Sudhakar et al. (2021) – *Leveraging Multiple Relations For Fashion Trend Forecasting Based On Social Media*

Este artigo explora o processo de mudança das tendências de moda, destacando o uso da tecnologia LSTM (Long Short-Term Memory), uma arquitetura de rede neural recorrente, para analisar séries temporais de dados de moda. O LSTM captura padrões complexos ao longo do tempo, ajudando a prever como tendências passadas influenciam futuras. A conclusão enfatiza que a moda é sensível ao contexto social e que a aplicação de redes neurais, como o LSTM, pode aprimorar a compreensão dessas mudanças dinâmicas.

**Artigo 2:** Blekanov et al. (2019) – *Big Data Analysis in Social Networks for Managing Risks Clothing Industry*

Este estudo analisa 248.728 tweets relacionados a tênis coletados durante setembro de 2018, usando "sneakers" como palavra-chave. Os dados foram processados com ferramentas de big data, como a série de Bayes, para identificar tópicos e sentimentos predominantes. A análise revelou que o volume de tweets negativos aumentou significativamente no início do mês, coincidindo com a decepção dos consumidores devido a expectativas frustradas sobre lançamentos de novos produtos. Esses insights destacam a relevância do monitoramento de redes sociais como parte da gestão de riscos na cadeia de suprimentos, sugerindo que estratégias proativas, como comunicação transparente sobre lançamentos, podem mitigar os impactos de feedbacks negativos.

**Artigo 3:** Silva et al. (2019) – *Googling Fashion: Forecasting Fashion Consumer Behaviour Using Google Trends*

Este estudo explora o uso do Google Trends como ferramenta analítica para prever o comportamento do consumidor de moda, utilizando como exemplo a marca de luxo Burberry. Diferentes modelos de séries temporais foram comparados, com foco na previsão de tendências de busca sazonais. Para melhorar a precisão, foi proposto o modelo híbrido Denoised Neural Network Autoregression (DNNAR), que combina redes neurais e análise de espectro singular (SSA) para reduzir ruídos nos dados. Os resultados demonstraram que o modelo DNNAR superou as abordagens tradicionais em todos os horizontes de previsão, destacando sua eficácia para analisar variações sazonais e tendências comportamentais. Este estudo enfatiza a relevância do Google Trends na identificação de padrões de consumo e na formulação de estratégias de marketing mais assertivas para marcas de moda.

**Artigo 4:** Park et al. (2016) – *Style in the Age of Instagram: Predicting Success within the Fashion Industry using Social Media*

Este artigo explora como o Instagram influencia o sucesso de modelos na indústria da moda, utilizando aprendizado de máquina para avaliar a relevância de métricas de engajamento digital em comparação com fatores tradicionais, como a associação a agências renomadas. Através da aplicação do algoritmo Random Forest, os autores analisaram dados de atributos físicos, experiência profissional e atividade no Instagram de um grupo de modelos estreantes da temporada Primavera/Verão de 2015. A pesquisa conclui que uma presença forte no Instagram pode ser mais importante para o sucesso do que a associação a agências renomadas como revistas especializadas no assunto, destacando a popularidade digital como um novo indicador de potencial na carreira da moda.

**Artigo 5:** Gabale et al. (2018) – *How to Extract Fashion Trends From Social Media? A Robust Object Detector With Support For Unsupervised Learning*

Este artigo apresenta um detector de objetos baseado em aprendizado não supervisionado, projetado para identificar tendências de moda em imagens de redes sociais. Utilizando a arquitetura CDSSD (Convolution-Deconvolution Single Shot Detector), o modelo foi pré-treinado com 60 mil imagens não rotuladas coletadas de plataformas sociais e refinado com 8.200 imagens rotuladas do dataset Open Images

V4. O desempenho do modelo superou outros detectores de ponta, como SSD e YOLO, particularmente na identificação de objetos pequenos, como acessórios (por exemplo, brincos e bolsas). Com uma média de precisão (mAP) de 72,7% em um conjunto de teste de 2.400 imagens, a pesquisa demonstra a eficácia da abordagem para processar grandes volumes de dados visuais e identificar tendências emergentes na moda, como cores predominantes e estilos populares, de maneira automatizada.

**Artigo 6:** Beheshti-Kashi (2015) – *Twitter and Fashion Forecasting: An Exploration of Tweets regarding Trend Identification for Fashion Forecasting*

Este artigo explora o uso do Twitter para prever tendências de moda, analisando 535.682 tweets sobre marcas, produtos e eventos. Técnicas de mineração de texto e regras de associação foram utilizadas para identificar padrões relacionados a cores, estilos e atributos de moda. Apesar dos desafios para análises quantitativas, o Twitter mostrou-se eficaz para captar preferências em tempo real. Os autores sugerem o uso de conjuntos de dados maiores (inclusive de outras redes sociais) e técnicas mais avançadas para melhorar os insights e identificar tendências emergentes.

**Artigo 7:** Wazarkar e Keshavamurthy (2020) – *Social Image Mining for Fashion Analysis and Forecasting*

Este artigo apresenta um sistema para previsão de moda com base em imagens de redes sociais, utilizando o método Rough Mean Shift Clustering para agrupar imagens por atributos como cor, tecido e design. Após o agrupamento, análises de correlação e temporais identificam relações entre os atributos, enquanto modelos preditivos de classificação e regressão são usados para prever tendências futuras. O sistema mostrou eficácia ao lidar com grandes volumes de dados não rotulados e heterogêneos.

**Artigo 8:** Balloni et al. (2024) – *Social4Fashion: An Intelligent Expert System for Forecasting Fashion Trends from Social Media Contents*

Este artigo apresenta o Social4Fashion, um sistema especialista baseado em inteligência artificial para prever tendências de moda a partir de fotos do Instagram. O

sistema utiliza técnicas de aprendizado, como classificação de imagens utilizando algoritmos como VGG-16 para classificação de imagens. O sistema proposto analisa itens de moda variados e suas cores dominantes. Os autores exibiram os dados em dashboards que permitem a análise por localização e período. Com 97% de precisão, o Social4Fashion se apresenta como uma ferramenta promissora para designers e marcas alinharem suas coleções às preferências dos consumidores. Além de acelerar a análise de tendências, o sistema também contribui com um novo dataset para pesquisas futuras.

**Artigo 9:** Zhao e Min (2019) – *The Rise of Fashion Informatics: A Case of Data-Mining-Based Social Network Analysis in Fashion*

Este artigo explora o campo emergente da "Fashion Informatics" usando uma abordagem de análise de redes sociais baseada em mineração de texto para analisar as interações na Semana de Moda de Paris 2017. Utilizando Python e Gephi, o estudo analisa hashtags como nós em redes, identificando influenciadores e comunidades que discutem temas de moda. A conclusão sugere que a análise de redes sociais permite identificar interações complexas e influências durante eventos de moda, fornecendo insights valiosos para estratégias de engajamento em redes sociais.

**Artigo 10:** Ma et al. (2019) – *Who, Where, and What to Wear? Extracting Fashion Knowledge from Social Media*

Este artigo propõe um método para extrair conhecimento de moda centrado no usuário a partir de redes sociais, focando em eventos, pessoas e vestuário. Utilizando uma rede neural Bi-LSTM, o modelo identifica atributos de moda e prevê ocasiões, criando uma base de conhecimento contextualizada para recomendações personalizadas. Combinando dados visuais e textuais, a abordagem demonstrou eficácia na extração de conceitos de moda e na construção de padrões úteis, sugerindo o que vestir em diferentes ocasiões com base em dados do Instagram.

**Artigo 11:** Zhao et al. (2024) – *Neo-Fashion: A Data-Driven Fashion Trend Forecasting System Using Catwalk Analysis*

Este artigo apresenta o Neo-Fashion, um sistema baseado em inteligência artificial para previsão de tendências de moda utilizando imagens de desfiles. Com a aplicação do modelo Mask RCNN, o sistema realiza segmentação e classificação de itens de moda, enquanto o K-means clustering identifica padrões em cores, estilos e combinações de roupas. O Neo-Fashion analisa 32.702 imagens de desfiles para prever tendências sazonais, oferecendo insights valiosos para decisões estratégicas. A abordagem destaca o potencial de métodos computacionais para auxiliar marcas a se adaptarem às mudanças nas preferências dos consumidores de forma eficiente e precisa.

**Artigo 12:** Wang e Liu (2021) – *Statistical Analysis and Big Data Based Intelligent Fashion Prediction Model*

Este artigo não foi utilizado, pois, embora explore o uso de big data e inteligência artificial para prever tendências de moda, seu foco principal está no desenvolvimento de modelos para aprimorar previsões de demanda e otimizar cadeias de suprimentos. Essa abordagem, voltada para gestão operacional, não está alinhada com o objetivo desta revisão de literatura, que é compreender a identificação de tendências de moda em redes sociais.

**Artigo 13:** Al-Halah et al. (2017) – *Fashion Forward: Forecasting Visual Style in Fashion*

Este artigo apresenta uma abordagem para prever estilos de moda combinando aprendizado profundo e análise não supervisionada. Utilizando uma rede neural convolucional treinada com mais de 200 mil imagens, o modelo identifica atributos visuais de roupas e projeta a popularidade futura desses estilos com base em dados da Amazon e suavização exponencial. Os resultados indicam que a análise visual supera métodos baseados em metadados textuais ou tags, demonstrando maior precisão na identificação de padrões destacando seu potencial para orientar decisões estratégicas na indústria da moda.

**Artigo 14:** Han et al. (2022) – *Color Trend Analysis Using Machine Learning with Fashion Collection Images*

Este artigo aplica aprendizado de máquina para analisar tendências de cores na moda, comparando as paletas previstas pela renomada empresa Pantone com as cores efetivamente usadas em coleções. Utilizando o algoritmo K-means para agrupar e identificar cores representativas, os resultados revelaram diferenças significativas entre as paletas Pantone e as coleções reais. A pesquisa destaca o potencial do aprendizado de máquina para análises quantitativas de tendências, oferecendo insights valiosos para designers e marcas ajustarem suas estratégias.

**Artigo 15:** Rostamzadeh et al. (2018) – *Fashion-Gen: The Generative Fashion Dataset and Challenge*

Este artigo não foi utilizado, pois trata-se de uma revisão sistemática de estudos relacionados à previsão de tendências na moda com o uso de tecnologia, sem apresentar uma aplicação prática ou resultados originais.

**Artigo 16:** Mall et al. (2019) – *GeoStyle: Discovering Fashion Trends and Events*

Este artigo apresenta o GeoStyle, uma metodologia para prever e identificar tendências de moda globais com base em imagens de redes sociais como Instagram e Flickr. Utilizando a rede neural convolucional GoogLeNet para reconhecimento de atributos e combinando modelos temporais com análise de clusters, o sistema identifica estilos, eventos e prevê tendências sazonais com 20% mais precisão em comparação a métodos anteriores. A pesquisa demonstra como a análise espaço-temporal de dados visuais pode revelar padrões regionais de estilo, eventos sociais e ciclos de popularidade de tendências.

**Artigo 17:** Bhoir e Patil (2023) – *The FASHION Visual Search using Deep Learning Approach*

Este artigo não foi utilizado, pois, embora aborde o uso de aprendizado de máquina para análise de imagens, seu foco está no desenvolvimento de um sistema de busca visual para o setor da moda, utilizando aprendizado profundo para aprimorar a experiência de compra online. Esse objetivo não está alinhado com o propósito desta revisão de literatura.

**Artigo 18:** An e Park (2020) – *Approaching Fashion Design Trend Applications Using Text Mining and Semantic Network Analysis*

Este artigo aplica mineração de texto e análise de redes semânticas para identificar tendências de design de moda a partir de dados de blogs. Analisando mais de 29.000 postagens sobre "jaquetas" e "coleções de moda" ao longo de uma década, as tendências foram classificadas em crescentes, decrescentes, perenes e sazonais. Utilizando ferramentas como UCINET e NetDraw, o estudo examinou atributos como cor e tecido, visualizando conexões entre design e preferências dos consumidores. A abordagem demonstrou eficiência ao reduzir o tempo de análise e fornecer diretrizes práticas para o design de moda baseado em dados.

**Artigo 19:** Giri et al. (2019) – *Exploitation of Social Network Data for Forecasting Garment Sales*

Este artigo apresenta o Social Media Based Forecasting (SMBF), um modelo híbrido que combina dados históricos de vendas e sentimentos extraídos de tweets para prever vendas. Utilizando séries temporais fuzzy e o algoritmo Naïve Bayes, o SMBF foi aplicado a dados de uma marca italiana de moda ao longo de seis meses. O modelo demonstrou correlação significativa entre tweets e vendas, superando métodos tradicionais como o Exponential Forecasting (EF). A pesquisa destaca que o uso de mídias sociais aumenta a precisão das previsões e oferece insights valiosos para estratégias no setor de moda.