

Mineração de componentes de interface e metadados em aplicativos móveis

Jonathan Cesar Kuspil¹, Gislaine Camila L. Leal¹, Renato Balancieri¹

¹Programa de Pós-Graduação em Ciência da Computação
Universidade Estadual de Maringá (UEM)
Maringá – PR – Brasil

jonathankuspil@gmail.com, {gclleal, rbalancieri}@uem.br

Abstract. Introduction: High-quality interfaces are essential for the success of mobile applications. **Objective:** This study proposes the integration of metadata and interface characteristics through the creation of two complementary datasets, the Automated Insights Dataset (AID) and the User Interface Depth Dataset (UID). **Methodology:** The AID compiled metadata from 6,400 of the most downloaded free Google Play applications across 32 categories. The UID, derived from the AID, manually mapped 7,540 interface components and 1,948 screenshots from 400 applications. Data analysis and machine learning techniques were applied to identify patterns and predict the presence of components based on textual descriptions. **Results:** The AID revealed market trends and recurring technical requirements. The UID identified relevant patterns in component usage, correlations and variations according to applications categories, color schemes, and design practices. The predictive model achieved an accuracy above 80%. The findings demonstrate the potential of these datasets to contribute to the advancement of intelligent, data-driven mobile interface design and to support Human-Computer Interaction research. **Keywords** Dataset, Mobile Application, User Interface, Machine Learning, Natural Language Processing.

Resumo. Introdução: Interfaces de qualidade são essenciais para o sucesso de aplicativos móveis. **Objetivo:** Este trabalho propõe a integração entre metadados e características de interface por meio da criação de dois datasets complementares: Automated Insights Dataset (AID) e User Interface Depth Dataset (UID). **Metodologia:** O AID reuniu metadados de 6.400 aplicativos gratuitos mais baixados da Google Play. O UID, derivado do AID, mapeou manualmente, 7.540 componentes de interface e 1.948 capturas de tela de 400 aplicativos. Técnicas de análise de dados, aprendizado de máquina foram aplicadas para identificar padrões e prever a presença de componentes a partir de descrições textuais. **Resultados:** O AID revelou tendências de mercado e requisitos técnicos recorrentes. O UID identificou padrões relevantes de uso e correlação de componentes e variações conforme categorias, cores e práticas de design. O modelo alcançou acurácia superior a 80%. As descobertas demonstram o potencial dos datasets para apoiar pesquisas em Interação Humano-Computador e contribuir para o avanço do design inteligente e orientado a dados de interfaces móveis.

Palavras-Chave Conjunto de Dados, Aplicativos Móveis, Interface do Usuário, Aprendizado de Máquina, Processamento de Linguagem Natural.

1. Problema de pesquisa

Os dispositivos móveis consolidaram-se como o principal meio de acesso à tecnologia no mundo, contando com mais de 7,4 bilhões de usuários em 2023 [Sahami Shirazi et al. 2013, STATISTA 2024]. Esse cenário impulsiona um mercado bilionário de desenvolvimento de aplicativos, especialmente voltado ao sistema operacional Android, presente em cerca de 70% dos dispositivos globais [STATISTA 2024]. A Google Play Store (GPlay), sua principal loja de aplicativos, reúne mais de 1,6 milhão de apps (junho de 2024) [STATISTA 2024]. Nesse contexto altamente competitivo, destacar-se é desafiador. Custos elevados, limitações tecnológicas e a complexidade de criar interfaces funcionais e atrativas em telas reduzidas figuram entre os principais entraves enfrentados [Kuspil et al. 2024].

A usabilidade destaca-se como fator decisivo para o sucesso de aplicativos. Embora múltiplos aspectos influenciem a experiência de uso, a Interface Gráfica do Usuário (GUI) ocupa papel central [Nielsen e Budiu 2015, Pratama e Cahyadi 2020]. Muitos desenvolvedores, especialmente iniciantes ou com recursos limitados, não têm acesso a especialistas em *design*, tampouco a conhecimento consolidado sobre boas práticas e padrões de interface. Linguagens e *frameworks* de *design*, como o Google Material Design¹ (GMD), oferecem diretrizes úteis, mas sua aplicação descontextualizada pode resultar em experiências frustrantes [Clifton 2015]. Nesse cenário, ganham força abordagens orientadas a dados que apoiem decisões fundamentadas de *design*.

A análise de exemplos, amplamente utilizada em diversas áreas, é uma estratégia eficaz para compreender como diferentes conceitos se materializam em um produto final. Ao investigar aplicativos de uma mesma categoria, é possível identificar padrões funcionais, estilos visuais e perfis de público, contribuindo para a redução de custos e riscos nas fases iniciais de projeto. Contudo, esse processo é custoso e exige discernimento para selecionar referências relevantes, um desafio intensificado em ambientes de desenvolvimento ágil, onde decisões rápidas são essenciais [Deka et al. 2017, Bunian et al. 2021, Kuspil et al. 2024].

Uma análise eficaz de aplicativos semelhantes requer, como ponto de partida, o acesso a um conjunto abrangente e representativo de informações. A literatura apresenta diversos *datasets* voltados a finalidades específicas [Deka et al. 2017, Liu et al. 2018, Prakash e Koshy 2021]. Alguns concentram-se na extração de metadados a partir de lojas como a GPlay; outros analisam características por meio de interceptação de chamadas de APIs; e há ainda iniciativas que produzem *datasets* hierárquicos baseados em *screenshots*. As aplicações desses dados são múltiplas e extrapolam o apoio ao desenvolvimento. Incluem, por exemplo: a extração de características com base em descrições textuais; a recomendação de novas funcionalidades com base nas APIs já presentes [Yu et al. 2016]; a detecção de *malwares* a partir de permissões atípicas [Gorla et al. 2014]; a criação de modelos de busca por GUIs similares [Liu et al. 2018, Bowers et al. 2022]; e a geração de descrições acessíveis para leitores de tela [Wang et al. 2021].

A mineração de metadados tem sido explorada por múltiplas perspectivas. Por exemplo, Gorla et al. [2014] utilizam metadados e APIs para verificar a consistência entre o comportamento anunciado e o real dos aplicativos, focando na detecção de anomalias

¹<https://m3.material.io/components>

e potenciais *malwares*. Yu et al [2016] propõem uma abordagem híbrida, combinando descrições textuais e APIs para recomendar funcionalidades, reconhecendo que fontes isoladas são insuficientes para caracterização completa. Outros estudos, como os de Kabir e Arefin [2019] e Prakash e Koshy [2021], analisam grandes volumes de metadados para identificar tendências de mercado, correlações com avaliações e preços, ou para realizar análises de sentimento. Apesar da relevância, esses trabalhos pouco exploram a conexão entre metadados e os elementos visuais e interativos da interface, centrais para a experiência do usuário [Nielsen e Budiu 2015].

Em paralelo, a análise de interfaces também tem avançado. Destacam-se iniciativas como o *dataset* Rico, de Deka et al. [2017], base de diversos estudos subsequentes. Liu et al. [2018] e Cruz Alves et al. [2022] utilizaram aprendizado de máquina para classificar componentes de interface do usuário (UI) a partir de capturas de tela, enquanto Moran et al. [2018] e Chen et al. [2019] abordaram a geração automática de código ou recomendações funcionais com base na estrutura de *layout*. Há ainda esforços voltados à busca visual de interfaces [Bunian et al. 2021], geração de descrições textuais [Wang et al. 2021] e avaliação estética de UIs [de Souza Lima et al. 2022]. No entanto, mesmo esses estudos frequentemente tratam as interfaces de forma isolada, ignorando o contexto do aplicativo ou reduzindo os componentes a meros elementos visuais ou textuais, sem conectar tais dados aos metadados estruturados e contextuais disponíveis nas lojas [Kuspil et al. 2024].

Apesar dos avanços, persiste uma lacuna crítica: a falta de integração entre metadados atualizados e uma análise rica e semântica dos componentes de interface. Uma das poucas tentativas, como a de Li et al. [2014], relaciona descrições e textos extraídos de *screenshots*, mas trata os componentes como simples fragmentos textuais, sem considerar funcionalidade ou complexidade visual [Kuspil 2024]. Não se observa, até o momento, um estudo que combine metadados estruturados com uma análise detalhada dos componentes realmente empregados em aplicativos reais, considerando aspectos visuais, funcionais e sua aderência a sistemas como o GMD. Tal ausência compromete o desenvolvimento de métodos e ferramentas capazes de apoiar efetivamente designers e desenvolvedores nas etapas iniciais do projeto de interfaces.

A Tabela 1 sintetiza a comparação entre este trabalho (apresentado nas linhas em negrito) e estudos anteriores (discutidos nesta seção) quanto à abrangência dos *datasets* de metadados e componentes de interface. O símbolo “?” indica ausência de informação clara no estudo, enquanto “–” representa elementos não aplicáveis.

O presente artigo constitui uma síntese de uma dissertação de mestrado, seu objetivo, portanto, é apresentar, de forma condensada e crítica, os principais resultados e contribuições de uma investigação mais ampla, focada na integração entre metadados estruturados e componentes de interface de aplicativos móveis. Ao consolidar a metodologia, as análises e os artefatos gerados, esta versão busca destacar o potencial de abordagens orientadas a dados para apoiar o design de interfaces, respondendo diretamente à lacuna identificada.

Diante desse cenário, a pergunta que orienta esta pesquisa é: **como integrar metadados estruturados e componentes de interface extraídos de aplicativos móveis de forma a apoiar o *design* orientado a dados?** Esta investigação busca responder a essa

Tabela 1. Comparação da abrangência dos *datasets* de metadados e componentes de interface em diferentes estudos.

	Autores	Ano publicação	Número de...						Coleta de dados	Identificação de componentes	Utilizou <i>layout</i>
			Metadados	Categorias de aplicativos	Tipo de comp.	Componentes identificados	<i>Screenshots</i> ou <i>layouts</i>	Aplicativos			
Mineração de metadados	Gorla et al.	2014	4	30	-	-	-	22,5 mil	Auto.	-	-
	Yu et al.	2016	1	4	-	-	-	441	Auto.	-	-
	Kabir et al.	2019	5	?	-	-	-	10 mil	Auto.	-	-
	Prakash et al.	2021	10	32	-	-	-	2 milhões	Auto.	-	-
	Kuspil et al.	2024	48	32	-	-	-	6,4 mil	Auto.	-	-
Mineração de características de interface	Li et al.	2014	5	?	10	61 mil	21 mil	8,4mil	Auto.	Híbrida	✓
	Deka et al.	2017	8	27	-	-	72 mil	9,7 mil	Híbrida	-	
	Liu et al.	2018	8	24	25	73 mil	720	?	Manual	Auto.	✓
	Moran et al.	2018	-	32	?	190 mil	19 mil	8,8 mil	Auto.	Auto.	
	Chen et al.	2019	?	?	-	-	61 mil	10,4 mil	Auto.	Auto.	✓
	Bunian et al.	2020	1	?	11	?	4,5 mil	?	Manual	Manual	
	Wang et al.	2021	?	?	-	-	22 mil	?	Manual	-	
	Cruz Alves et al.	2022	1	?	9	644	365	?	Manual	Manual	
	de Souza Lima et al.	2022	-	?	1	481	481	?	Manual	Manual	
	Kuspil et al.	2024	48	32	50	7,4 mil	1,9 mil	400	Manual	Manual	

questão por meio da construção de um conjunto de dados inédito e da exploração de seu potencial para subsidiar o desenvolvimento de interfaces mais fundamentadas e eficazes.

2. Solução produzida

Esta seção apresenta a solução proposta neste trabalho, voltada à integração entre metadados de aplicativos móveis e seus componentes de interface. A seguir, são descritos os fundamentos da proposta, os conjuntos de dados gerados e uma aplicação prática que demonstra seu potencial.

2.1. Proposta geral

Diante da lacuna observada na literatura — relacionada à escassez de recursos que integrem de maneira sólida os metadados de aplicativos móveis com uma análise detalhada de seus componentes de interface — este trabalho definiu como solução principal a criação e desenvolvimento de uma base de dados original e bem estruturada. O foco central dessa iniciativa foi o desenvolvimento de um artefato de pesquisa na forma de um *dataset* que integra metadados e características de interface, com o objetivo de apoiar futuras investigações científicas e o desenvolvimento de ferramentas para *designers* e desenvolvedores de software móvel.

A proposta parte do entendimento de que a combinação entre essas duas dimensões, metadados e componentes de interface, tradicionalmente exploradas de forma isolada, possui elevado potencial. Espera-se que essa base de dados contribua para decisões mais fundamentadas e eficazes, especialmente nas etapas iniciais do desenvolvimento de interfaces gráficas do usuário, como em sistemas de recomendação ou predição de componentes.

2.2. Descrição dos *datasets* gerados

Foram construídos dois *datasets* distintos, porém complementares: o *Automated Insights Dataset* (AID) e o *User Interface Depth Dataset* (UID). Esses conjuntos de dados foram projetados para capturar diferentes níveis de informação sobre os aplicativos móveis analisados.

O AID consiste em uma ampla tabela que reúne dados de 6.400 aplicativos, obtidos principalmente a partir da GPlay. Tais dados, foram minerados automaticamente em novembro de 2023 através do uso de um *Web Crawler* na plataforma AppBrain², que compila os dados da GPlay e de análises próprias sobre aplicativos. Para tal amostra, foram considerados os 200 aplicativos gratuitos mais baixados em cada uma das 32 categorias da loja no período da coleta. Além dos metadados básicos, o *dataset* inclui outros metadados relevantes como bibliotecas e tecnologias utilizadas, histórico de versões, marcos de *downloads* (*milestones*) e mudanças de categoria ao longo do tempo, proporcionando uma visão abrangente do mercado. A Tabela 2 apresenta os principais metadados coletados.

Tabela 2. Tipos de metadados obtidos de aplicativos.

Categoria de dados	Metadado coletado
Metadados GPlay	<i>GPlay Link, Name, Package, Developer, Category, Current Global Rank, Total Downloads, Description, Purchase Cost, Cost of In-App Purchases, Current App Version, APK size, Minimal Android Version, Maturity, Suitable for, User Rating e Number of Ratings.</i>
Metadados AppBrain	<i>AppBrain App Link, Most Downloaded Position in Category, 10 Ranks by Country, Recent Downloads, Short Description, Description Language, Library Count, Positive and Negative Reviews Examples, Development Tools and Libraries, Contains Ad Content, Ad Network Libraries, Social Libraries, 12 Categories of Permissions, Release day, Installations milestones, Updates, Unpublished day, Category change e Price over the time.</i>

O UID é derivado do AID e representa uma amostra mais focada e aprofundada, composta por 400 aplicativos. Esses aplicativos mantêm os mesmos metadados presentes no AID, mas com a adição de uma camada de análise detalhada da interface. Foi realizada a identificação e catalogação manual dos componentes de software utilizados nas principais telas de cada aplicativo, abrangendo um total de 50 tipos diferentes de componentes, incluindo 49 identificadores visuais e funcionais, além da cor predominante.

A definição de "telas principais" foi um critério metodológico focado nas interfaces que materializam as funcionalidades centrais de cada aplicativo. Foram deliberadamente excluídos da análise componentes presentes em telas de login, configurações, tutoriais, elementos externos e anúncios. Essa delimitação visou garantir a viabilidade da coleta

²<https://www.appbrain.com/>

manual e concentrar o esforço nos elementos que representam a proposta de valor de cada software. A identificação de tais telas foi guiada por uma abordagem empírica, na qual os pesquisadores se basearam na descrição, na categoria e na própria experiência de uso com aplicativos do mesmo domínio para discernir as funcionalidades essenciais.

A definição dos componentes baseou-se principalmente nas diretrizes do GMD, que propõe 35 componentes reutilizáveis para construção de interfaces. Esses elementos foram complementados por componentes mais complexos oriundos do Android Studio, como visualizadores de mapas e vídeos. Além disso, foi feita uma curadoria para incluir funcionalidades recorrentes (*features*) observadas com frequência durante a análise empírica, consideradas relevantes para caracterização funcional e estética dos aplicativos. De forma complementar, decidiu-se por capturar: as *screenshots* dos aplicativos, pois, conforme identificado em observações, as *screenshots* disponíveis na GPlay não seriam adequadas para uma padrão caracterização dos diversos aplicativos dado seu caráter heterogêneo e comercial; a cor característica dos aplicativos, sendo essa uma cor que normalmente caracteriza a identidade estética do aplicativo, presente ícone e cor de botões. A Tabela 3 apresenta os componentes mapeados.

Tabela 3. Tipos de componentes mapeado nos aplicativos.

Categoria de dados	Componente identificado
Componentes do GMD	<i>Snackbar, Tool tip, Badge, Circular progress indicator, Linear progress indicator, Dialog, Full-screen dialog, Date picker, Dial time picker, Digital time picker, Side sheet, Bottom sheet, Radio button, Switch, Checkbox, Slider, Menu, Navigation rail, Navigation drawer, Navigation bar, Primary tabs, Secondary tabs, Segmented buttons, Chips, Top app bar, Extended FAB, Floating action button, Bottom app bar, Search, Carousel, List, Divider, Common button, Text field e Icon button.</i>
Componentes complementares	<i>Pre-loading indicator, Sound effects, Background music, Web component, Map view, Videos, Account required, Social interaction, Default night mode, Landscape mode, Text view, Card list, Grid layout, Images, Characteristic color, Colected date e Screenshots.</i>

2.3. Aplicação da solução

Com o objetivo de verificar a aplicabilidade do *dataset* UID e demonstrar seu potencial analítico, especialmente no que diz respeito à relação entre metadados de aplicativos e a presença de componentes específicos de interface, foi conduzida uma etapa de avaliação prática da proposta. Essa avaliação consistiu no desenvolvimento e teste de um modelo preditivo baseado em técnicas de aprendizado de máquina (*Machine Learning*) e processamento de linguagem natural (*Natural Language Processing* – NLP).

O modelo foi construído para prever a presença ou ausência de um subconjunto de 13 componentes de interface previamente identificados no UID, utilizando como entrada as descrições textuais completas dos aplicativos (um dos metadados disponíveis). A escolha desse subconjunto buscou verificar a viabilidade de construção de um modelo

funcional e generalizável. Os resultados obtidos indicaram uma precisão superior a 80% nas predições, o que corrobora a hipótese de que o UID possui valor significativo para apoiar investigações orientadas a dados e o desenvolvimento de ferramentas voltadas ao *design* de interfaces móveis.

Em consonância com os princípios da ciência aberta, os *datasets* AID e UID, bem como as ferramentas utilizadas para sua construção, encontram-se disponíveis em repositório público³. Os *scripts* de análise e o modelo preditivo inicial também estão acessíveis em repositório complementar⁴.

3. Método de Pesquisa

O estudo foi conduzido com base na *Design Science Research Methodology* (DSRM) [Peppers et al. 2007], considerada adequada ao desenvolvimento e avaliação de artefatos tecnológicos. A seguir, apresentam-se as etapas metodológicas adotadas, organizadas conforme a estrutura proposta pelo modelo da DSRM.

3.1. Design Science Research Methodology

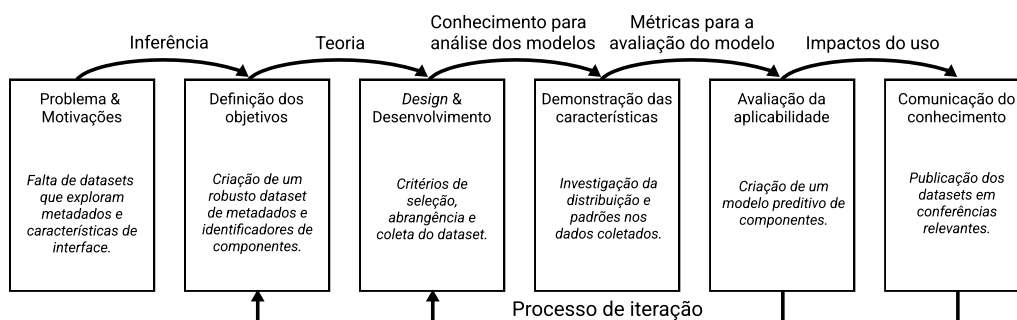


Figura 1. Modelo do processo da DSRM. Fonte: Adaptado de Peppers et al. [2007]

A Figura 1 apresenta o modelo do processo da DSRM adotado neste trabalho, composto por seis etapas: (i) identificação do problema e motivação, (ii) definição dos objetivos, (iii) *design* e desenvolvimento do artefato, (iv) demonstração, (v) avaliação e (vi) comunicação dos resultados. Essas etapas forneceram um guia estruturado para a construção e validação dos *datasets* propostos.

A adoção desta abordagem foi fundamental para garantir um caminho claro e rigoroso, assegurando que o desenvolvimento dos *datasets* fosse orientado por objetivos bem definidos e que sua relevância fosse sistematicamente avaliada, culminando em artefatos com potencial de contribuição para a área.

3.2. Coleta de dados

A construção dos conjuntos de dados que fundamentam esta pesquisa, o AID e o UID, constituiu uma etapa metodológica central. Essa fase teve como objetivo prover uma base empírica robusta para investigar relações entre metadados de aplicativos móveis e suas características de interface. O processo de coleta foi conduzido em múltiplas fases, com atenção ao rigor metodológico, à replicabilidade e à auditabilidade dos dados, seguindo diretrizes presentes em estudos anteriores na área [Liu et al. 2018, de Souza Lima et al. 2022].

³<https://doi.org/10.5281/zenodo.10676845>

⁴<https://doi.org/10.5281/zenodo.14812156>

3.2.1. Critérios de seleção e panorama da amostra

Dada a impossibilidade de analisar a totalidade dos milhões de aplicativos disponíveis, tornou-se necessário definir uma amostra representativa para permitir um estudo aprofundado. Optou-se por delimitar o universo da pesquisa ao sistema Android, com dados provenientes da GPlay, em razão de sua ampla presença no mercado global, da reconhecida qualidade das interfaces de seus aplicativos populares, da disponibilidade de ferramentas de emulação robustas e da relativa facilidade de acesso ao código-fonte, se necessário [Kortum e Sorber 2015, Yu et al. 2016, STATISTA 2023].

Para dimensionar a amostra de aplicativos que passaria pela análise manual de interface (UID), aplicou-se a fórmula para populações finitas [Fonseca e Martins 2016], tomando como base os 2,6 milhões de aplicativos disponíveis na GPlay em novembro de 2023 [STATISTA 2023]. Com um nível de confiança de 95% e margem de erro de 5,4%, obteve-se uma amostra estatisticamente representativa de 400 aplicativos, número coerente com estudos semelhantes que também envolvem análise manual.

A identificação dos aplicativos e a extração inicial de metadados foram realizadas por meio da plataforma AppBrain, que oferece um repositório dinâmico e abrangente de dados da GPlay, superando limitações comuns da coleta direta [Harty e Müller 2019, Hecht e Bergel 2021]. Foram coletados os 200 aplicativos gratuitos mais baixados em cada uma das 32 categorias da GPlay, totalizando 6.400 entradas, que compuseram o AID. A opção por aplicativos gratuitos visou facilitar o acesso e a replicação da análise, prática comum em investigações anteriores [Deka et al. 2017].

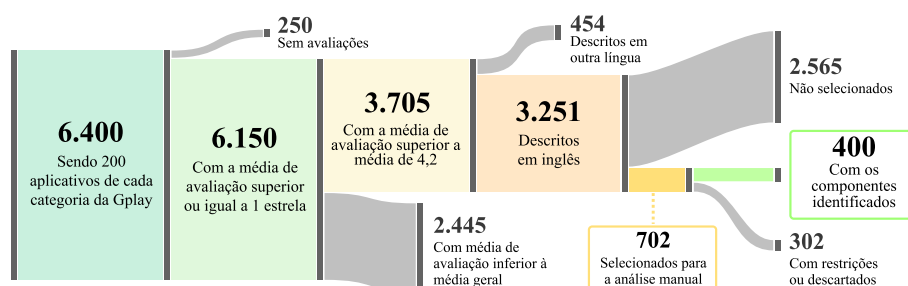


Figura 2. Etapas do processo de seleção dos aplicativos que compõem o UID, a partir do conjunto inicial do AID.

A partir do AID, foi conduzido um processo iterativo de refinamento para selecionar os 400 aplicativos que integrariam o UID, conforme ilustrado na Figura 2. Inicialmente, foram removidos os aplicativos sem avaliações. Em seguida, com base na média de avaliação dos 6.150 restantes (4,14 estrelas), eliminaram-se aqueles com nota igual ou inferior a 4,1, utilizando a avaliação do usuário como indicador de qualidade percebida [Kuspil 2024]. Adicionalmente, utilizou-se a API *Language Service* do Google⁵ para identificar o idioma das descrições, e excluíram-se os aplicativos cuja descrição principal não estava em inglês.

Após esses filtros, restaram 3.251 aplicativos. Aplicou-se então uma distribuição proporcional por categoria para garantir representatividade na amostra final. Durante a análise manual, critérios de exclusão adicionais foram adotados: foram descartados

⁵<https://developers.google.com/apps-script/reference/language>

aplicativos em modo exclusivamente paisagem, que impediam capturas de tela, exigiam número de telefone, eram jogos incorretamente categorizados, tinham acesso restrito (por geolocalização, credenciais ou *paywalls*), eram incompatíveis com o emulador ou se tratavam de *frameworks*, APIs, *launchers* ou teclados virtuais — categorias sem foco em interface para o usuário final [Kuspil et al. 2024].

Ao final, 702 aplicativos foram analisados manualmente, resultando na seleção final de 400, distribuídos proporcionalmente nas 32 categorias, que compõem o UID.

3.2.2. Coleta de metadados

Para a coleta dos metadados que compõem o AID um *Web Crawler* foi desenvolvido em *Python*, utilizando a biblioteca *Selenium*⁶ para a extração de dados do AppBrain [Kuspil 2024]. O processo foi dividido em duas etapas: uma coleta inicial dos dados básicos (em 3 de novembro de 2023) e uma extração complementar realizada 23 dias depois, resultando na estruturação final do AID.

Devido à natureza dinâmica da GPlay e à atualização constante dos dados refletidos no AppBrain, observou-se a ocorrência de alterações em diversos metadados entre as duas coletas. Tais mudanças foram incorporadas ao AID, com exceção de dois casos considerados de menor impacto: (i) a posição no *ranking* por categoria, frequentemente alterada, e (ii) a mudança de categoria em dois aplicativos. Ambos os casos foram mantidos conforme a coleta inicial, pois não comprometeram a organização nem a integridade geral do *dataset*.

3.2.3. Coleta de característica de interface

A coleta de dados para o UID iniciou-se com a definição rigorosa dos parâmetros de coleta (Etapa U1). O processo foi conduzido por dois pesquisadores (o autor principal e um aluno de iniciação científica), ambos testados previamente para daltonismo, a fim de garantir consistência na identificação das características visuais dos aplicativos. Utilizou-se o emulador Android BlueStacks⁷, configurado para simular um dispositivo Samsung Galaxy S22 Ultra com Android 11, resolução Full HD (1080x1920 *pixels*, 240 DPI) e arquiteturas x86/ARM de 32 e 64 bits. As capturas de tela foram feitas em modo retrato, com a ferramenta nativa do Android. Para padronizar o uso da linguagem e o acesso aos aplicativos, definiram-se dados fictícios para preenchimento de formulários e a localização geográfica do emulador foi fixada em Nova Iorque, EUA. O pesquisador menos experiente passou por treinamento específico sobre os componentes de interface, incluindo estudo de materiais de referência, discussões e testes práticos.

Antes da coleta definitiva, realizou-se um teste piloto (Etapa U2) com 33 aplicativos de diferentes categorias. O piloto foi essencial para avaliar a viabilidade da metodologia e resultou em importantes ajustes: adotou-se a captura de telas completas (ao invés de registrar componentes isolados), expandiu-se a paleta de cores para incluir o preto, e novos componentes e *features* recorrentes foram incorporados. Além disso,

⁶<https://www.selenium.dev/>

⁷<https://www.bluestacks.com/>

decidiu-se manter os metadados previamente coletados do AID, devido à instabilidade da coleta em tempo real. A principal mudança metodológica foi o desenvolvimento de uma ferramenta de apoio para marcação dos componentes, substituindo o uso de planilhas manuais.

Para otimizar a catalogação (Etapa U3), desenvolveu-se uma ferramenta com interface baseada em *checkboxes* e representações gráficas dos componentes (inspiradas no Material Design). Componentes recorrentes, como botões e campos de texto, vinham pré-selecionados para acelerar o preenchimento. A ferramenta armazenava os dados temporariamente e organizava automaticamente as *screenshots* em pastas nomeadas conforme o identificador do aplicativo. Testes indicaram que seu uso reduziu em cerca de 40% o tempo médio de coleta por aplicativo.

A coleta efetiva (Etapa U4) ocorreu entre 12 de novembro de 2023 e 5 de fevereiro de 2024, seguindo um roteiro padronizado. Utilizou-se a ferramenta desenvolvida e uma planilha online compartilhada para registro dos componentes. Os 400 aplicativos selecionados foram instalados manualmente a partir de seus *links* na GPlay. O tempo médio de análise por aplicativo foi de 15 minutos, variando conforme complexidade, necessidade de cadastro ou presença de tutoriais. O processo de marcação dos componentes foi baseado nas principais telas de cada aplicativo, conforme ilustrado na Figura 3. Em tal figura, as esferas na tabela a direita representam a interseção entre os aplicativos (eixo horizontal) e os componentes (eixo vertical), já o caractere apresentado ao centro de cada esfera indica o uso (T para *True*, em português, verdadeiro) ou não (F para falso) de determinado componente nas principais telas do aplicativo, já as reticências representam componentes não abrangidos nesta amostra. Na parte inferior da tabela apresentada na figura, é descrito a cor característica dos aplicativos, sendo o *Red*, em português, vermelho, a cor característica do primeiro aplicativo da cor e o *Yellow*, em português amarelo, cor característica dos demais aplicativos.

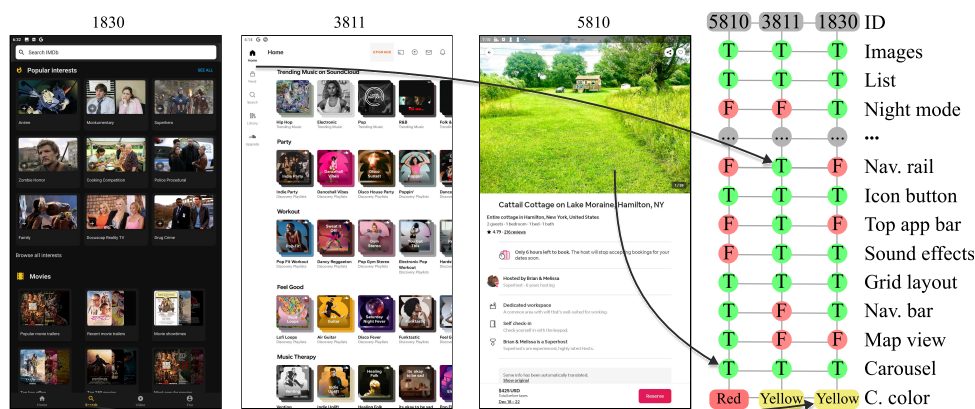


Figura 3. Amostragem do UID para os aplicativos: IMDB (1830), Soundcloud (3811) e Airbnb (5810).

Durante a coleta, enfrentaram-se desafios como a presença de publicidade intrusiva e restrições de captura de tela. Aplicativos que exigiam acesso restrito, operavam exclusivamente em modo paisagem ou apresentavam outras limitações foram descartados e substituídos por outros da mesma categoria.

Categorias como "Finanças" apresentaram altas taxas de descarte, enquanto outras,

como “Livros e Referência” e “Saúde e Fitness”, não apresentaram problemas relevantes. Para manter a proporcionalidade da amostra, a seleção foi iterativamente ajustada até atingir a cota por categoria. As sessões de coleta foram limitadas a no máximo duas horas diárias por pesquisador, com média de sete aplicativos por sessão, para mitigar erros por fadiga [Deka et al. 2017]. Ao final de cada sessão, os dados e capturas eram validados e armazenados em um repositório online.

Na etapa final (Etapa U5), procedeu-se à consolidação e verificação dos dados. Aplicativos do teste piloto e casos com inconsistências foram reavaliados. Para verificar a consistência da coleta, uma amostra aleatória de 10% dos aplicativos foi revisitada. Confirmou-se a coerência na identificação dos componentes, considerando a média de cinco *screenshots* por aplicativo. A organização prévia e o uso da ferramenta facilitaram significativamente a curadoria e o gerenciamento final do UID.

3.3. Procedimentos de análise dos dados

Os *datasets* desenvolvidos, AID e UID, foram submetidos a análises quantitativas com o objetivo de caracterizar seus conteúdos e extrair informações relevantes. No caso do AID, a análise concentrou-se na distribuição de seus 48 metadados entre os 6.400 aplicativos, por meio de estatísticas descritivas e visualizações gráficas, com foco na representação geral dos aplicativos populares da GPlay. Para o UID, além de uma caracterização semelhante em relação à frequência dos 50 tipos de componentes de interface e às 1.948 *screenshots* coletadas dos 400 aplicativos, foi conduzida uma investigação mais aprofundada sobre as inter-relações entre os dados, com ênfase na identificação de padrões de correlação — conforme descrito a seguir.

A análise específica do UID buscou identificar e quantificar relações entre os diversos componentes de interface catalogados, bem como entre esses componentes e outros atributos dos aplicativos, como categoria de mercado e cor predominante da interface. Para isso, utilizou-se a linguagem *Python*, com suporte extensivo da biblioteca *pandas* para manipulação e estruturação dos dados (convertidos de planilhas para o formato *.CSV*). A geração das visualizações, incluindo mapas de calor para interpretar matrizes de correlação, foi realizada com as bibliotecas *seaborn* e *matplotlib* [Bowers et al. 2022].

As associações entre os indicadores binários de presença dos componentes foram examinadas por dois métodos estatísticos principais: (i) o teste do qui-quadrado, empregado para avaliar a independência entre variáveis categóricas por meio de tabelas de contingência (*chi2_contingency*, da *scipy.stats*) [Verma 2012, McHugh 2013]; e (ii) o coeficiente de correlação de Pearson, utilizado para aferir a força e direção das relações lineares entre pares de componentes (*pearsonr*, também do *scipy.stats*) [Adler e Parmryd 2010, Sousa 2019]. Esses procedimentos permitiram uma exploração sistemática das dependências e interconexões presentes nos dados do UID.

3.4. Estudo de viabilidade com aprendizado supervisionado

Como forma de avaliar a aplicabilidade do UID e demonstrar seu potencial para investigações orientadas a dados, foram treinados modelos de aprendizado de máquina (*Machine Learning*) supervisionado. O objetivo central dessa etapa foi verificar a viabilidade de prever a presença de determinados componentes de interface com

base exclusivamente nas descrições textuais dos aplicativos [Kuspil 2024]. Para isso, experimentou-se com diferentes algoritmos de classificação clássicos, incluindo *Naive Bayes* (em sua variante Multinomial), *Decision Tree*, *Random Forest* e *Support Vector Classification* (SVC). A vetorização das descrições, etapa essencial para o processamento textual, foi realizada por meio das abordagens *Bag of Words* e *Term Frequency-Inverse Document Frequency* (TF-IDF).

A performance dos modelos e das configurações de hiperparâmetros foi sistematicamente avaliada por meio de validação cruzada (*k-fold cross-validation*), garantindo que todas as instâncias do UID fossem utilizadas tanto para treino quanto para teste em diferentes iterações [Kuspil 2024]. Como métrica de avaliação, adotou-se o *micro-F1 score*, por sua adequação a contextos com classes desbalanceadas.

Importa destacar que o desenvolvimento desses modelos preditivos não visou a criação de uma ferramenta pronta para uso imediato, mas funcionou como uma validação empírica da proposta do *dataset*, evidenciando sua utilidade e potencial para investigações futuras no contexto de IHC e desenvolvimento de software.

4. Resultados e discussão

Em consonância com o propósito deste artigo e dadas as restrições de espaço do formato, esta seção concentra-se na apresentação e discussão textual dos achados mais relevantes. O conjunto completo de visualizações gráficas, incluindo os mapas de calor gerados na análise de correlação, exemplos visuais dos componentes de interface e as capturas de tela dos aplicativos analisados, está disponível para consulta detalhada no repositório público da pesquisa⁸ e na dissertação que originou este trabalho.

Os resultados obtidos com a aplicação do método proposto são apresentados a seguir, organizados em três eixos principais: (i) a caracterização dos metadados presentes no *dataset* AID; (ii) a análise dos componentes de interface do *dataset* UID e suas correlações; e (iii) a avaliação empírica da aplicabilidade do UID por meio da predição automatizada de componentes com base em descrições textuais dos aplicativos.

4.1. Análise dos metadados

A análise do AID, que contempla 6.400 aplicativos populares da GPlay, permitiu identificar padrões relevantes sobre o ecossistema de software móvel. Observou-se, por exemplo, que a categoria “*Tools*” (Ferramentas) apresenta o maior número de *downloads*, resultado possivelmente influenciado pela presença de *frameworks* e bibliotecas essenciais pré-instaladas no sistema Android.

Em relação aos requisitos técnicos, verificou-se que as permissões de acesso à rede são amplamente predominantes: 95% dos aplicativos analisados requerem “acesso total à rede” (*full network access*), evidenciando a dependência crítica da conectividade para o funcionamento da maioria das aplicações.

Outro achado relevante é que, embora muitos dos aplicativos mais populares apresentem avaliações elevadas, um número expressivo deles não possui qualquer avaliação registrada. Ainda assim, a distribuição geral das notas no AID mostrou-se semelhante à de amostras mais amplas da loja, segundo os dados do AppBrain.

⁸Disponível em: <https://doi.org/10.5281/zenodo.10676845>

Quanto ao idioma, o inglês predomina como língua principal nas descrições dos aplicativos (presente em 84% dos casos). O português aparece como o segundo idioma mais frequente, especialmente em aplicativos direcionados ao mercado brasileiro, sugerindo estratégias de localização adotadas por seus desenvolvedores.

Além disso, identificou-se uma tendência à manutenção da compatibilidade com versões mais antigas do sistema Android, como as versões 4 e 5, o que indica uma preocupação em atender à base de dispositivos legados ainda em uso. Esses achados quantitativos do AID oferecem um panorama das características técnicas, mercadológicas e de apresentação dos aplicativos de maior alcance, fornecendo subsídios para a compreensão de tendências e requisitos recorrentes no desenvolvimento móvel.

4.2. Análise dos dados de interface

A análise do UID, que compreende uma investigação detalhada de 400 aplicativos selecionados do AID, envolveu o mapeamento de 7.540 instâncias de componentes, distribuídas em 50 tipos distintos, além da captura de 1.948 *screenshots*. Essa análise foi conduzida de forma unidimensional, observando a distribuição individual dos componentes, e bidimensional, por meio de mapas de calor utilizados para explorar correlações entre componentes e entre componentes e metadados.

4.2.1. Análise unidimensional

Os resultados quantitativos revelam a predominância de componentes estruturais básicos: o *Text view* foi identificado em 99,8% dos aplicativos do UID, seguido por *Icon button* (98,5%), *Common button* (97,8%) e *Images* (89,5%), reforçando a essencialidade desses elementos para a construção de interfaces minimamente funcionais. Componentes voltados à navegação, como a *Navigation bar* (presente em 62,8% dos aplicativos), e à entrada de dados, como o *Text field* (64,3%), também demonstraram ampla adoção.

Em contrapartida, elementos de interface mais específicos ou contextuais, como o *Dial time picker* (1,3%) e o *Badge* (1,8%), apresentaram baixa frequência — possivelmente em decorrência do foco da análise nas telas e funcionalidades principais de cada aplicativo.

No que diz respeito ao uso de sistemas de *design*, os dados do UID sugerem uma adesão apenas parcial às diretrizes estéticas do GMD. Embora muitos aplicativos adotem visualmente os componentes propostos, observam-se desvios no uso funcional recomendado: por exemplo, *Chips* e *Segmented buttons*, concebidos para filtragem de conteúdo, são frequentemente empregados como mecanismos de navegação entre telas.

Também se constatou que o componente *Pre-loading indicator* muitas vezes exibiu um conteúdo visual distinto do efetivamente carregado, o que pode comprometer a continuidade da experiência do usuário, que por exemplo, pode estar esperando um *layout* em grade (indicado pelo componente de pre-carregamento) mas quando o conteúdo é carregado o mesmo se apresenta como um *Card List*. Em relação às cores predominantes, o azul destacou-se como a mais comum (presente em 39% dos aplicativos), seguido pelo preto (18,5%), enquanto amarelo e magenta foram significativamente menos utilizados. Esses achados oferecem *insights* relevantes sobre as práticas de *design* de interface,

evidenciando tanto elementos consolidados quanto adaptações que podem sinalizar tendências emergentes ou lacunas normativas.

4.2.2. Análise bidimensional

A análise das inter-relações entre os 49 componentes de interface identificados no UID, conduzida com base no coeficiente de correlação de Pearson, revelou diversas associações lineares significativas. Destacam-se, por exemplo, correlações positivas entre o componente *Primary tab* e barras de navegação inferiores como *Bottom App Bar* (0,26) e *Navigation Bar* (0,26), sugerindo práticas de *design* que combinam navegação por abas superiores com comandos na base da tela.

De maneira semelhante, componentes como *Images* e *Carousel* (0,28) demonstraram tendência à coocorrência, refletindo seu uso conjunto na exibição de coleções visuais. Por outro lado, foram identificadas correlações negativas relevantes, por exemplo, entre *Navigation Bar* e *Navigation Rail* (-0,33), bem como entre *Navigation Bar* e *Navigation Drawer* (-0,27), indicando escolhas mutuamente exclusivas na estruturação da navegação primária dos aplicativos.

A estatística do qui-quadrado complementou essas descobertas ao identificar associações relevantes não necessariamente lineares. Entre os exemplos, destaca-se a associação entre *List* e *Divider* (55%), *Menu* e *Landscape mode* (46%) e *Social interaction* com *Text Field* (39%). Essa abordagem permitiu uma visão mais ampla das dependências entre os componentes, baseada na frequência de ocorrência conjunta.

A relação entre os componentes e as 32 categorias de aplicativos do UID foi investigada por meio de mapas de calor, revelando padrões de adoção específicos por domínio. O componente *Map Views* foi amplamente utilizado em “*Maps & Navigation*”(83%) e também em “*Food & Drink*”(80%), sugerindo seu uso para localização ou rastreamento de entregas. Já o componente *Videos* apareceu com frequência em “*Video Players & Editors*”(81%) e “*Social*”(83%), mas esteve ausente nas categorias “*Auto & Vehicles*” e “*Finance*”. Curiosamente, o componente *Search*, embora comum em muitas categorias, não foi identificado em nenhum aplicativo da categoria “*Dating*”. Esses padrões reforçam o papel das funcionalidades e expectativas do usuário na definição dos elementos de interface adotados por categoria.

A análise também considerou a relação entre os componentes e as oito cores predominantes nas interfaces do UID. Embora os componentes mais comuns apareçam associados a diversas cores, algumas combinações mostraram-se mais marcantes. Por exemplo, aplicativos com cor característica laranja apresentaram maior presença de *Slider* (52%) e *Videos* (59%), enquanto os com cor magenta, menos frequentes, destacaram-se pelo uso de *Date Picker* (44%) e *Radio Button* (31%).

Finalmente, a distribuição das cores por categoria revelou padrões estéticos alinhados ao domínio das aplicações: azul, a cor mais popular, apareceu em 91% dos aplicativos da categoria “*Tools*” e em 81% dos de “*Weather*”; preto foi predominante em “*Social*”(46%) e “*Sports*”(42%); vermelho prevaleceu em “*Food & Drink*” e em “*News & Magazines*”(56%). Tais achados sugerem que a escolha das cores principais está ligada a convenções do setor, identidade visual e expectativas de usuários por categoria.

4.3. Modelo preditivo de componentes

Para validar empiricamente a utilidade do UID e explorar a relação entre metadados textuais e a composição da interface, foi desenvolvido um conjunto de modelos preditivos utilizando as descrições completas dos aplicativos como dados de entrada. O objetivo foi treinar algoritmos de aprendizado de máquina supervisionado para prever a presença ou ausência de 14 componentes de interface distintos [Kuspil 2024].

O processo envolveu a experimentação com diversos classificadores, incluindo *Naive Bayes* (Multinomial), *Decision Tree*, *Random Forest* e *Support Vector Classification* (SVC), combinados com técnicas de vetorização textual como *Bag of Words* e *Term Frequency-Inverse Document Frequency* (TF-IDF), além de seleção de atributos com *SelectKBest*.

A avaliação, realizada por meio de validação cruzada e abrangendo 378 combinações de algoritmos, técnicas de vetorização e seleção de atributos, demonstrou que os modelos específicos para cada um dos 14 componentes superaram consistentemente a linha de base do erro majoritário. Notavelmente, 11 desses modelos atingiram acurácia superior a 90% sobre os dados do UID, enquanto os três restantes apresentaram acurácia acima de 82%, com os respectivos *micro-F1 scores* acompanhando de perto esses valores. A configuração mais frequentemente associada aos melhores desempenhos foi o classificador *Multinomial Naive Bayes* com vetorização via *Bag of Words*.

A capacidade de generalização desses modelos foi posteriormente testada em um conjunto de seis aplicativos populares não presentes no UID. Nessa avaliação com dados inéditos, o conjunto de preditores alcançou uma taxa de acerto global de 73% na identificação da presença ou ausência dos componentes [Kuspil 2024].

Embora essa performance tenha sido inferior à obtida sobre os dados de treinamento, ela ainda superou abordagens mais simples, como a atribuição da classe majoritária, indicando que os modelos foram capazes de aprender padrões relevantes a partir das descrições textuais. A variação no desempenho pode ser atribuída a fatores como: (i) as particularidades do UID, que, por seus critérios de seleção, pode não representar perfeitamente todos os tipos de aplicativos; (ii) o possível sobreajuste (*overfitting*) dos modelos, decorrente do grande volume de termos em comparação ao número de instâncias; e (iii) limitações das próprias técnicas de NLP e ML utilizadas, que foram escolhidas por sua simplicidade e interpretabilidade inicial.

Esses resultados indicam que descrições textuais de aplicativos podem, em certa medida, fornecer indícios sobre sua composição de interface, abrindo caminho para aplicações automatizadas em avaliação de *design* e usabilidade. Tal possibilidade reforça o potencial do UID como base empírica para estudos futuros em IHC, engenharia de software e ciência dos dados.

5. Contribuições para a área de IHC

A principal contribuição deste trabalho para a área de Interação Humano-Computador (IHC) reside na proposição e desenvolvimento de artefatos e análises que promovem o avanço de ferramentas orientadas a dados, voltadas ao apoio ao complexo processo de concepção e desenvolvimento de aplicativos móveis — com ênfase na construção

de interfaces gráficas baseadas em componentes amplamente utilizados. Os *datasets* gerados, AID e, especialmente, o UID, configuram-se como uma infraestrutura valiosa para a comunidade de IHC. Eles oferecem não apenas uma base rica para estudos sobre usabilidade e padrões de *design* em larga escala, mas também funcionam como *benchmarks* metodológicos e exemplos práticos de coleta e integração de metadados e características de interface, com potencial para subsidiar o treinamento de novas ferramentas inteligentes de apoio ao *design* [Kuspil 2024].

Alinhado aos princípios da ciência aberta, este trabalho destaca-se pela disponibilização pública de seus principais artefatos. Entre as contribuições centrais estão os *datasets* AID e UID⁹, os *scripts* de análise e um modelo preditivo baseado em aprendizado de máquina¹⁰, todos acessíveis em repositórios públicos com o objetivo de promover replicabilidade, transparência e continuidade de investigações na área. A metodologia usada e a relevância dos achados foram validadas em publicações revisadas por pares, incluindo um artigo apresentado no WIDE/IHC 2023¹¹ e outro na conferência internacional ICEIS 2024¹².

As descobertas obtidas a partir da análise dos dados representam um avanço na compreensão das práticas contemporâneas de *design* de interfaces móveis. As associações identificadas entre componentes, bem como entre componentes e metadados, fornecem evidências empíricas que reforçam conceitos consolidados de usabilidade e princípios de *design* de interação amplamente reconhecidos na literatura de IHC. Destaca-se também o potencial dos *datasets* para revelar padrões e relações ainda não documentadas ou suficientemente compreendidas, abrindo novas possibilidades de investigação científica e contribuindo para a evolução do conhecimento em IHC aplicada ao contexto móvel. Esses achados podem, por exemplo, subsidiar a derivação de heurísticas específicas ou guias contextuais de *design* com base em evidências.

A exploração inicial da predição de componentes de interface com base em descrições textuais, validada por meio de modelos de aprendizado de máquina [Kuspil 2024], contribui para a IHC ao demonstrar a viabilidade de métodos orientados a dados no suporte ao processo de *design*. Essa abordagem estabelece uma ponte entre áreas distintas do conhecimento e exemplifica um processo de *design* que se beneficia diretamente de evidências empíricas, representando um passo em direção a ferramentas inteligentes que podem apoiar *designers* e desenvolvedores, reduzindo a carga cognitiva, promovendo o acesso a boas práticas e oferecendo suporte às decisões de projeto [Abbas et al. 2022].

Em uma perspectiva mais ampla, esta pesquisa oferece subsídios para refletir sobre como o conhecimento extraído de grandes volumes de dados pode ser traduzido em apoio prático, seja para estimular a criatividade de *designers* por meio da apresentação de padrões consolidados, seja para desafiar convenções, ao revelar tendências de uso possivelmente subótimas. Embora os *datasets* tenham sido construídos com base em aplicativos descritos em inglês, a metodologia de coleta e análise, bem como a concepção de ferramentas de apoio, são adaptáveis e podem, futuramente, ser aplicadas a

⁹Disponível em: <https://doi.org/10.5281/zenodo.10676845>

¹⁰Disponível em: <https://doi.org/10.5281/zenodo.14812156>

¹¹Disponível em: <https://doi.org/10.5753/wide.2023.236109>

¹²Disponível em: <https://doi.org/10.5220/0012740600003690>

contextos específicos, atendendo à necessidade de desenvolver soluções digitais sensíveis a particularidades regionais e culturais, um desafio central e contemporâneo da área de IHC.

Em síntese, esta pesquisa oferece uma contribuição abrangente e multifacetada à área de IHC, ao integrar rigor metodológico, inovação técnica e compromisso com a ciência aberta. Seus resultados reforçam o papel da IHC como campo estratégico na mediação entre tecnologia, *design* e responsabilidade social, particularmente no contexto da crescente complexidade dos sistemas móveis.

6. Cuidados éticos

A condução desta pesquisa pautou-se por princípios éticos, assegurando a integridade do processo e o respeito aos envolvidos, mesmo na ausência de interação direta com participantes humanos — como em estudos de campo ou experimentos controlados — o que dispensou a submissão formal a um Comitê de Ética em Pesquisa. Durante a coleta de dados para o UID, adotaram-se medidas para proteger a privacidade dos pesquisadores, incluindo o uso de contas de e-mail dedicadas e dados fictícios no preenchimento de formulários, além da exclusão de aplicativos que exigissem número de telefone pessoal para acesso [Kuspil 2024]. O bem-estar da equipe também foi considerado, com a realização de testes preliminares e a limitação da duração das sessões de coleta, a fim de evitar fadiga e erros associados [Deka et al. 2017].

Na captura de telas dos aplicativos, buscou-se registrar os componentes de interface por meio de *screenshots* estratégicas que evitassem, sempre que possível, a exposição de dados ou imagens de usuários finais [Kuspil 2024]. Reconhece-se, contudo, que especialmente em aplicativos de natureza social, algumas das imagens capturadas continham rostos e dados que podem identificar pessoas. A preocupação com a privacidade e o direito de imagem foi uma consideração central durante a coleta, e o planejamento original da pesquisa previa uma etapa de anonimização, na qual tais informações seriam devidamente censuradas. No entanto, devido ao cronograma do projeto, não houve tempo hábil para a conclusão dessa tarefa antes da disponibilização inicial do *dataset*. Considera-se este um passo crítico e necessário, que será tratado como trabalho futuro prioritário para garantir a plena adequação do artefato aos princípios éticos de pesquisa e atualização dos dados já disponibilizados.

Os metadados que compõem o AID foram extraídos automaticamente do portal AppBrain. Embora essa prática possa entrar em conflito com o modelo de negócio da plataforma, não foram identificadas proibições explícitas quanto à extração de dados públicos. Um pilar central deste trabalho é o compromisso com a ciência aberta, evidenciado pela disponibilização pública dos *datasets* AID e UID, das ferramentas de coleta desenvolvidas e do modelo preditivo inicial em repositórios como o Zenodo [Kuspil 2024]. Tal prática visa fomentar a replicabilidade, permitir a validação pela comunidade científica e encorajar o reuso dos dados em novas investigações na área de IHC. A transparência sobre as limitações do estudo e as ameaças à validade dos dados é discutida ao longo do texto, reforçando o compromisso ético assumido nesta pesquisa.

7. Conclusão

Este trabalho apresentou uma proposta de integração entre metadados e características de interface de aplicativos móveis, concretizada por meio da criação de dois *datasets* complementares — AID e UID. A proposta não se restringiu à coleta ou organização de dados, mas buscou estabelecer uma base sólida e estruturada para análises que pudessem beneficiar tanto o campo científico da Interação Humano-Computador quanto o desenvolvimento prático de interfaces. A construção dos conjuntos de dados e as análises subsequentes permitiram não apenas identificar padrões e relações relevantes, mas também ilustrar possibilidades concretas de uso, como a predição automatizada de componentes a partir das descrições textuais dos aplicativos.

Além de oferecer recursos inéditos à comunidade de IHC, o trabalho buscou fomentar uma abordagem empírica e orientada a dados para apoiar decisões no *design* de interfaces. Ao documentar e compartilhar os procedimentos metodológicos, ferramentas e conjuntos de dados utilizados, reforça-se o compromisso com a ciência aberta e a transparência, ampliando o potencial de reaproveitamento dos artefatos desenvolvidos.

Apesar da robustez metodológica e da riqueza dos dados gerados, o estudo apresenta algumas limitações relevantes. A amostra de aplicativos do UID, embora representativa, foi restrita a apps populares, gratuitos e com descrições em inglês, o que pode limitar a generalização dos achados para outros contextos. A catalogação manual, por mais criteriosa que tenha sido, dependeu da percepção dos pesquisadores e pode ter introduzido viés na identificação dos componentes. Além disso, o modelo preditivo desenvolvido teve caráter experimental e não utilizou algoritmos de aprendizado profundo, o que restringe sua capacidade de generalização.

Como caminhos futuros, destaca-se a necessidade de expandir o UID, principal produto dessa pesquisa, para contemplar maior diversidade de idiomas, regiões e perfis de aplicativos. Também se aponta a oportunidade de formalizar um protocolo de identificação de componentes, promovendo maior reprodutibilidade e consistência em estudos subsequentes. Em relação ao modelo preditivo, investigações futuras poderão empregar técnicas mais avançadas de NLP e *deep learning*, bem como testar outras fontes de dados — como avaliações de usuários, fluxos de navegação e registros de uso em tempo real — para enriquecer a acurácia e relevância das previsões. Por fim, acredita-se que a integração dos *datasets* com ferramentas visuais de apoio ao *design* possa viabilizar aplicações práticas voltadas a diferentes perfis de desenvolvedores, contribuindo para democratizar o acesso a boas práticas e elevar a qualidade das interfaces móveis no ecossistema Android.

Reconhece-se, ainda, que os *datasets* gerados, apesar dos critérios rigorosos de seleção, podem conter vieses inerentes, como o foco em aplicativos populares, gratuitos e com descrições em inglês. Esses vieses podem afetar a generalização dos achados e, por consequência, influenciar o comportamento de ferramentas ou modelos preditivos derivados, que podem herdar não apenas as limitações da amostra, mas também influências dos próprios *designers* e desenvolvedores dos aplicativos analisados, ou dos pesquisadores durante o processo de mapeamento [Kuspil 2024]. Nesse contexto, discute-se a implicação ética de que o uso disseminado de ferramentas baseadas nesses dados poderia, inadvertidamente, promover uma padronização excessiva no *design* de aplicativos ou desencorajar soluções inovadoras que se afastem dos padrões mais

frequentes. A conscientização sobre esses potenciais impactos é fundamental, e trabalhos futuros que utilizem ou expandam tais artefatos deverão considerar ativamente essas questões éticas em suas propostas e aplicações.

Em suma, ao apresentar *datasets* ricos e uma análise multifacetada, este trabalho contribui para o avanço do *design* orientado a dados, oferecendo recursos concretos e validados que permitem uma melhor compreensão do ecossistema de aplicativos móveis. Demonstrou-se, assim, que a integração entre metadados e componentes de interface não apenas é viável, mas representa um caminho promissor para a criação de soluções mais eficazes e inteligentes no campo da Interação Humano-Computador.

Referências

- Abbas, A. M., Ghauth, K. I., e Ting, C.-Y. (2022). User experience design using machine learning: a systematic review. *IEEE Access*, 10:51501–51514.
- Adler, J. e Parmryd, I. (2010). Quantifying colocalization by correlation: the pearson correlation coefficient is superior to the mander's overlap coefficient. *Cytometry Part A*, 77(8):733–742.
- Bowers, A. J., Zhao, Y., e Ho, E. (2022). Towards hierarchical cluster analysis heatmaps as visual data analysis of entire student cohort longitudinal trajectories and outcomes from grade 9 through college. *The High School Journal*, 106(1):5–36.
- Bunian, S., Li, K., Jemmali, C., Harteveld, C., Fu, Y., e Seif El-Nasr, M. S. (2021). Vins: Visual search for mobile user interface design. In *Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems*, pages 1–14.
- Chen, X., Zou, Q., Fan, B., Zheng, Z., e Luo, X. (2019). Recommending software features for mobile applications based on user interface comparison. *Requirements Engineering*, 24(4):545–559.
- Clifton, I. G. (2015). *Android user interface design: Implementing material design for developers*. Addison-Wesley Professional.
- da Cruz Alves, N., Kreuch, L., e von Wangenheim, C. G. (2022). Analyzing structural similarity of user interface layouts of android apps using deep learning. In *Anais do XXI Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais*, Porto Alegre, RS, Brasil. SBC.
- de Souza Lima, A. L., Martins, O. P. H. R., von Wangenheim, C. G., von Wangenheim, A., Borgatto, A. F., e Hauck, J. C. R. (2022). Automated assessment of visual aesthetics of android user interfaces with deep learning. In *Proceedings of the 21st Brazilian Symposium on Human Factors in Computing Systems, IHC '22*, New York, NY, USA. Association for Computing Machinery.
- Deka, B., Huang, Z., Franzen, C., Hibschan, J., Afegan, D., Li, Y., Nichols, J., e Kumar, R. (2017). Rico: A mobile app dataset for building data-driven design applications. In *Proceedings of the 30th Annual ACM Symposium on User Interface Software and Technology*, UIST '17. ACM.
- Fonseca, J. S. d. e Martins, G. d. A. (2016). *Curso de estatística*. Atlas, São Paulo, SP, 6ª edição.

- Gorla, A., Tavecchia, I., Gross, F., e Zeller, A. (2014). Checking app behavior against app descriptions. In *Proceedings of the 36th international conference on software engineering*, pages 1025–1035.
- Harty, J. e Müller, M. (2019). Better android apps using android vitals. In *Proceedings of the 3rd ACM SIGSOFT International Workshop on App Market Analytics*, WAMA 2019, page 26–32, New York, NY, USA. Association for Computing Machinery.
- Hecht, G. e Bergel, A. (2021). Quantifying the adoption of kotlin on android stores: Insight from the bytecode. In *2021 IEEE/ACM 8th International Conference on Mobile Software Engineering and Systems (MobileSoft)*, pages 94–98.
- Kabir, M. S. e Arefin, M. S. (2019). Google play store data mining and analysis. *International Journal of Applied Information Systems*, 12(26):1–5.
- Kortum, P. e Sorber, M. (2015). Measuring the usability of mobile applications for phones and tablets. *International Journal of Human-Computer Interaction*, 31(8):518–529.
- Kuspil, J., Ribeiro, J., Leal, G., Guerino, G., e Balancieri, R. (2024). Datasets on mobile app metadata and interface components to support data-driven app design. In *Proceedings of the 26th International Conference on Enterprise Information Systems - Volume 1: ICEIS*, pages 425–432. INSTICC, SciTePress.
- Kuspil, J. C. (2024). Mineração de componentes de interface e metadados em aplicativos móveis. Dissertação de mestrado, Universidade Estadual de Maringá (UEM), Maringá, PR. Programa de Pós-Graduação em Ciência da Computação (PCC–UEM). Orientador: Prof. Dr. Renato Balancieri. Coorientadora: Profa. Dra. Gislaíne Camila Lapasini Leal.
- Li, K., Xu, Z., e Chen, X. (2014). A platform for searching ui component of android application. In *2014 5th International Conference on Digital Home*, pages 205–210. IEEE.
- Liu, T. F., Craft, M., Situ, J., Yumer, E., Mech, R., e Kumar, R. (2018). Learning design semantics for mobile apps. In *Proceedings of the 31st Annual ACM Symposium on User Interface Software and Technology*, pages 569–579.
- McHugh, M. L. (2013). The chi-square test of independence. *Biochemia medica*, 23(2):143–149.
- Moran, K., Bernal-Cárdenas, C., Curcio, M., Bonett, R., e Poshyvanyk, D. (2018). Machine learning-based prototyping of graphical user interfaces for mobile apps. *IEEE Transactions on Software Engineering*, 46(2):196–221.
- Nielsen, J. e Budiu, R. (2015). *User Experience for Mobile Applications and Websites*. Nielsen Norman Group, Fremont, CA, 3rd edition. Design Guidelines for Improving the Usability of Mobile Sites and Apps; Copyright © Nielsen Norman Group, All Rights Reserved.
- Peppers, K., Tuunanen, T., Rothenberger, M. A., e Chatterjee, S. (2007). A design science research methodology for information systems research. *Journal of management information systems*, 24(3):45–77.

- Prakash, G. e Koshy, J. (2021). Google play store apps. <https://www.kaggle.com/datasets/gauthamp10/google-playstore-apps>. Kaggle. [Acessado 26-Jul-2025].
- Pratama, M. e Cahyadi, A. (2020). Effect of user interface and user experience on application sales. In *IOP Conference Series: Materials Science and Engineering*, volume 879, page 012133. IOP Publishing.
- Sahami Shirazi, A., Henze, N., Schmidt, A., Goldberg, R., Schmidt, B., e Schmauder, H. (2013). Insights into layout patterns of mobile user interfaces by an automatic analysis of android apps. In *Proceedings of the 5th ACM SIGCHI Symposium on Engineering Interactive Computing Systems*, EICS '13, page 275–284, New York, NY, USA. Association for Computing Machinery.
- Sousa, Á. (2019). Coeficiente de correlação de pearson e coeficiente de correlação de spearman: o que medem e em que situações devem ser utilizados? *Correio dos Açores: Matemática*, page 19. Disponível em <https://repositorio.uac.pt/entities/publication/48103d09-4406-4176-b520-41bce0b65345>. [Acessado 27-Jul-2025].
- STATISTA (2023). Statista - technology & telecommunications. <https://www.statista.com/markets/418/technology-telecommunications/>. [Acessado 04-Ago-2024].
- STATISTA (2024). Statista - number of available applications in the google play store from march 2017 to june 2024. <https://www.statista.com/statistics/266210/number-of-available-applications-in-the-google-play-store/>. [Acessado 11-Jun-2025].
- Verma, J. P. (2012). *Data analysis in management with SPSS software*. Springer Science & Business Media.
- Wang, B., Li, G., Zhou, X., Chen, Z., Grossman, T., e Li, Y. (2021). Screen2words: Automatic mobile ui summarization with multimodal learning. In *The 34th Annual ACM Symposium on User Interface Software and Technology*, UIST '21, page 498–510, New York, NY, USA. Association for Computing Machinery.
- Yu, H., Lian, Y., Yang, S., Tian, L., e Zhao, X. (2016). Recommending features of mobile applications for developer. In *International Conference on Advanced Data Mining and Applications*, pages 361–373. Springer.