

Um Modelo Inteligente para Auxílio a Pessoas com Uso Problemático de Smartphones

Gustavo Lazarotto Schroeder¹, Rosemary Francisco¹, Jorge Luis Victória Barbosa¹

¹Universidade do Vale do Rio dos Sinos (Unisinos)
Av. Unisinos, 950 - Cristo Rei, São Leopoldo - RS, 93022-750 - Brasil

gschroeder@edu.unisinos.br, {rosemaryf, jbarbosa}@unisinos.br

Abstract. *Problematic Smartphone Use (PSU) is characterized by compulsive usage patterns that can negatively impact routines and well-being. This paper introduces the Kratos model, which leverages context awareness, context histories, machine learning, and ontological inferences to detect PSU and recommend personalized interventions. The model was evaluated using simulated data from 49 users over 30 days, demonstrating the model's effectiveness in identifying and mitigating problematic use. Kratos enables the detection of risk patterns and the recommendation of tailored interventions, complementing traditional methods that rely on questionnaires and manual interventions.*

Resumo. *O Uso Problemático de Smartphones (UPS) é caracterizado por padrões de uso compulsivos que podem gerar impactos negativos na rotina e no bem-estar. Este artigo apresenta o modelo Kratos, que integra consciência de contextos, análise de Históricos de Contextos, aprendizado de máquina e inferência ontológica para detectar UPS e gerar intervenções personalizadas. O modelo foi avaliado por meio de dados simulados de 49 usuários ao longo de 30 dias, demonstrando eficácia na identificação e na redução do uso problemático. O Kratos permite a detecção de padrões de risco e a recomendação de intervenções personalizadas, complementando métodos tradicionais baseados em questionários e intervenções manuais.*

1. Introdução

O uso de smartphones tem apresentado crescimento em escala global [Lu et al., 2024]. Projeções indicam que esse crescimento irá continuar, especialmente em países populosos, onde a taxa de penetração desses dispositivos ainda é inferior a 70% [Turner, 2021]. Esse fenômeno está intrinsecamente ligado ao aprimoramento contínuo das funcionalidades dos smartphones e à convergência com tecnologias emergentes, como avanços da Internet, que transformaram os smartphones em plataformas multifuncionais. Atualmente, seu uso transcende a comunicação básica, abrangendo atividades como jogos, navegação web e até apostas *online* [Busch and McCarthy, 2021], reflexo de uma sociedade cada vez mais dependente de soluções digitais integradas.

O Uso Problemático de Smartphones (UPS) é definido como um padrão de utilização excessiva e compulsiva que compromete o funcionamento diário do indivíduo, prejudicando produtividade, relações sociais, saúde física e bem-estar emocional [Horwood and Anglim, 2018]. Adicionalmente, o UPS impacta a saúde mental [Elhai et al., 2021], podendo exacerbar sintomas de ansiedade e depressão [Busch and

McCarthy, 2021]. Para mitigar esses efeitos, são necessárias soluções tecnológicas para reduzir o uso excessivo e intervenções psicoterapêuticas que fortaleçam o suporte social percebido, promovendo uma abordagem integrada para o manejo do transtorno [Elhai et al., 2017]. Embora a maioria dos estudos reconheça a necessidade de identificar e auxiliar indivíduos com UPS, poucos implementam métodos assistivos ou avaliaram sistematicamente a eficácia dessas estratégias [Bouazza et al., 2023].

Diante desse cenário, este artigo propõe Kratos, um modelo computacional inteligente projetado para auxiliar na identificação, prevenção e suporte a indivíduos com UPS. O modelo integra a detecção automatizada de padrões de uso perigosos com intervenções direcionadas ao uso excessivo de smartphones, criando um mecanismo para auxiliar pessoas com UPS. O Kratos integra dados de diversas fontes, como questionários, Avaliação Momentânea Ecológica (EMA), variáveis ambientais e de uso do smartphone, organizando-os em séries temporais multidimensionais, chamadas de Históricos de Contextos, que capturam interações comportamentais [Rentz et al., 2023]. Essa estrutura permite explorar padrões e similaridades entre os históricos, classificando contextos de risco por meio de técnicas de aprendizado de máquina [Filippetto et al., 2021]]. Adicionalmente, o EMA reduz vieses inerentes a questionários psicológicos tradicionais e viabiliza a gestão dinâmica de dados via sensores smartphones [Gratch et al., 2021], facilitando sua integração a modelos computacionais. Nesse contexto, o Kratos destaca-se ao combinar dados de sensores, questionários, informações demográficas e EMA para identificar comportamentos de UPS em rotinas diárias. A principal contribuição científica do modelo é sua capacidade de identificar e prever comportamentos problemáticos, bem como recomendar intervenções personalizadas, com base em aprendizado de máquina e inferências ontológicas.

Este artigo está organizado da seguinte forma. A Seção 2 descreve os trabalhos relacionados ao Kratos. Em seguida, a Seção 3 detalha a visão geral e a arquitetura do modelo. A Seção 4 discute os experimentos com algoritmos de aprendizado de máquina e a avaliação. Por fim, a Seção 5 resume as conclusões, limitações e direcionamentos futuros.

2. Trabalhos Relacionados

Esta pesquisa explorou uma revisão sistemática da literatura para buscar trabalhos relacionados [Schroeder et al., 2022]. Esta revisão investigou o uso problemático de smartphones, buscando estabelecer um panorama teórico sobre o fenômeno e a influência do UPS na saúde mental.

Após análise da lista final de estudos selecionados a partir da revisão sistemática da literatura, este estudo selecionou nove artigos que implementaram estratégias para identificar o UPS e apoiar indivíduos por meio de intervenções. A principal contribuição científica deste estudo consiste na proposta de intervenções direcionadas a indivíduos com UPS, fundamentadas na detecção e inferência de comportamentos de risco a partir de informações contextuais. Essa abordagem combina análise preditiva e ações adaptativas, proporcionando um modelo abrangente para a mitigação proativa e reativa do UPS.

A Tabela 1 apresenta uma análise comparativa que destaca as contribuições e os pontos comuns entre o Kratos e os nove trabalhos relacionados. Dentre os aspectos comuns, destaca-se a utilização de escalas para a identificação do UPS e de problemas de

saúde mental associados. A análise de dados de utilização de smartphones permite a correlação dessas informações com escalas, permitindo aos pesquisadores investigar a relação entre as informações obtidas por meio de sensores e dados autorrelatados sobre o uso de smartphones. Adicionalmente, a previsão de condições futuras com base nos registros de uso exige a aplicação de algoritmos de aprendizado de máquina capazes de processar grandes volumes de dados. Por fim, destaca-se que nenhum dos estudos utilizou ontologias para estruturar o modelo conceitual ou realizar inferências sobre os resultados.

Além disso, nenhum estudo usou Históricos de Contextos para organizar os dados coletados em uma série de ações executadas pelos usuários ou para analisar as informações coletadas em séries temporais. Embora estudos tenham realizado intervenções para o UPS [Lee et al., 2014; Kent et al., 2021; Yasudomi et al., 2021; Olson et al., 2022], poucos trabalhos conduziram intervenções combinando as informações coletadas do uso de smartphones, EMA e questionários, baseando-se apenas nos questionários para detectar o nível de UPS antes de testar as intervenções ou aplicá-las manualmente.

Tabela 1. Comparação entre o Modelo Kratos e Trabalhos Relacionados

Referência	Objetivo	Escalas	Sensores	Context Aware	Machine Learning	Ontologia	Intervenção	Intervenção Inteligente
Lee et al. [2014]	Auxiliar profissionais de saúde a avaliar e intervir continuamente no UPS utilizando o sistema SAMS.	Sim	Sim	Sim	Sim	Não	Sim	Não
Choi et al. [2017]	Classificar a dependência de smartphones usando um algoritmo de aprendizado de máquina.	Sim	Sim	Sim	Não	Não	Não	Não
Lee et al. [2018]	Analisar o UPS considerando as diferenças entre padrões de uso e cognição.	Sim	Sim	Sim	Não	Não	Não	Não
Kent et al. [2021]	Avaliar a eficácia e aceitabilidade de uma intervenção e-saúde para reduzir o UPS em estudantes.	Sim	Não	Não	Sim	Não	Sim	Não
Lee and Kim [2021]	Prever o nível de dependência de smartphones com dados de uso de smartphones.	Sim	Sim	Não	Não	Não	Não	Não
Yasudomi et al. [2021]	Analisar a eficácia de um aplicativo que restringe aplicativos nos smartphones dos usuários.	Sim	Sim	Sim	Sim	Não	Sim	Não
Marciano and Camerini [2022]	Investigar a correlação entre rastreamento de smartphones e dados autorrelatados de uso.	Sim	Sim	Sim	Não	Não	Não	Não
Olson et al. [2022]	Testar dez estratégias de intervenção que incentivam os usuários a reduzir o uso de smartphones.	Sim	Não	Não	Sim	Não	Sim	Não
Rahman et al. [2022]	Identificar padrões relacionados ao comportamento de <i>phubbing</i> .	Sim	Não	Não	Não	Não	Não	Não
Modelo Kratos	Reconhecer traços e preditores de UPS e auxiliar pessoas com UPS por meio de intervenções	Sim	Sim	Sim	Sim	Sim	Sim	Sim

3. Modelo Kratos

O Kratos tem como objetivo auxiliar usuários com UPS por meio da classificação dos comportamentos de uso e da recomendação de intervenções a partir da identificação de padrões de risco. Além disso, a capacidade de predição de comportamentos problemáticos viabiliza a adoção de estratégias preventivas, permitindo a mitigação proativa do UPS. O modelo integra dados de diversas fontes, como sensores do smartphone, questionários e EMA, para classificar e inferir o estado atual de uso do dispositivo. Utilizando aprendizado de máquina, o modelo analisa essas informações e classifica o comportamento de uso do smartphone com base em históricos de comportamentos saudáveis e de UPS. Além disso, emprega uma ontologia computacional para inferir e gerar intervenções adaptativas, como *nudges* [Grüning et al., 2023] para interrupção de ciclos de uso excessivo ou alertas para suporte psicossocial.

3.1. Visão geral do modelo

A Figura 1 ilustra a visão geral do Kratos. Inicialmente, os dados comportamentais do usuário, incluindo padrões de uso de aplicativos, interações com o dispositivo e contexto temporal, são coletados em tempo real (1). Esses dados são armazenados em um banco de dados (2), organizando os dados em Históricos de Contextos (3) seguindo a estrutura da Ontologia OntoKratos (4). Na fase analítica, o modelo combina inferências semânticas da ontologia (4) com algoritmos de aprendizado de máquina (5). O modelo utiliza os dados obtidos para identificar indivíduos com padrões de utilização de smartphones em conformidade com a UPS. Quando padrões de UPS são detectados, intervenções proativas ou reativas são acionadas (6), adaptando-se ao contexto identificado. Após a intervenção, o ciclo se reinicia, com novos dados sendo coletados para avaliar a eficácia das estratégias, permitindo ajustes contínuos nas previsões e nas respostas do modelo.




Figura 1. Descrição geral do Modelo Kratos

3.2. Organização Multi Agente

A Figura 2 ilustra o Sistema Multiagente, elaborado utilizando a ferramenta Prometheus [Padgham and Winikoff, 2003]. O Kratos é composto por três agentes autônomos especializados: o *Smartphone Use Monitor*, que coleta e analisa métricas comportamentais em tempo real (tempo de uso, notificações, exposição à luz); o *Context Builder*, responsável por sintetizar um perfil contextual dinâmico, integrando dados de atividades do usuário, respostas a EMA e variáveis de ambiente (luminosidade). O agente *Data Preprocessor* recebe um conjunto de informações de Históricos de Contextos e pré-processa os dados para os modelos de aprendizado de máquina.

O *Dangerous Use Pattern Identifier* analisa dados pré-processados, categorizando o comportamento do usuário em clusters normais e associados ao UPS, direcionando intervenções personalizadas. Utilizando dados de sensores do *Smartphone Use Monitor*, o Kratos utiliza Históricos de Contextos para identificar comportamentos de UPS com base em dados históricos. Paralelamente, o *Dangerous Use Pattern Analyst* utiliza inferências ontológicas para gerenciar perfis, monitorando o uso de smartphones e recomendando intervenções adaptadas ao estado atual do usuário. Por fim, o *Intervention Engine*

Agent executa estratégias preventivas e reativas, visando mitigar a progressão do UPS e reduzir impactos psicossociais decorrentes do uso compulsivo.




Figura 2. Organização do sistema multiagente

3.3. Ontologia OntoKratos

A Figura 3 apresenta a OntoKratos, organizando o conhecimento do domínio através das classes principais denominadas *Assistance Methods*, *Context*, *Person*, *Scale* e *User*. Ontologias, enquanto artefatos de representação semântica, estabelecem relações taxonômicas e axiomáticas entre entidades, formalizando conceitos-chave e interdependências em um domínio específico. Estudos recentes empregaram ontologias para auxiliar pessoas no domínio da saúde [Bavaresco et al., 2024]. A ontologia proposta padroniza os termos e a estrutura de dados empregados nesta pesquisa, facilitando a organização das informações analisadas.

A classe *Context* representa o contexto de uma pessoa, incluindo informações sobre sua rotina, hábitos de uso do smartphone, dados ambientais e EMA. Esta classe abrange informações dinâmicas relacionadas ao tempo, como o contexto do dispositivo (nível de bateria, aplicativos utilizados, status da tela, etc.), EMA (níveis de ansiedade, humor e qualidade do sono) e o contexto geral (luminosidade do ambiente, turno do dia e localização). Os *Assistance Methods* referem-se a estratégias voltadas para a intervenção e prevenção do uso problemático de smartphones. Esses métodos são divididos em métodos reativos e métodos preventivos. A *Scale* refere-se aos questionários utilizados para identificar condições de saúde mental, bem como o uso problemático de smartphones, nomofobia e outros transtornos relacionados. A classe é subdividida em escalas de saúde mental e escalas para avaliação do PSU. A classe *Person* representa informações demográficas, dados sobre o humor dos indivíduos e fatores de risco demográficos e emocionais. Por fim, a classe *User* representa o usuário do smartphone.

A OntoKratos integra-se ao Kratos, permitindo não apenas a padronização da representação de dados dinâmicos e estáticos do domínio, mas também a realização de inferências a partir de informações. Sua estrutura ontológica estabelece relações




Figura 3. Visão geral da ontologia OntoKratos

axiomáticas que subsidiam análises preditivas e a recomendação de intervenções personalizadas. Além disso, a arquitetura da OntoKratos reflete a complexidade multidimensional do UPS, acomodando variáveis ambientais para proporcionar um viabilizar estratégias adaptativas e eficazes.

4. Avaliação

Esta pesquisa se concentra em identificar o comportamento do UPS e propor intervenções para o uso do smartphone. Nesse sentido, foi desenvolvido um simulador de dados sintéticos denominado Kratos Dataset Simulator (KDS). O KDS permitiu simular o processo de coleta de dados durante 30 dias de uso do smartphone por 49 usuários. Com base nesse conjunto de dados sintéticos, foram conduzidos experimentos de aprendizado de máquina para reconhecer comportamentos normais e problemáticos.

4.1. Kratos Dataset Simulator

O KDS foi projetado para replicar ecossistemas de uso de smartphones, integrando a captura de dados de sensores, como luminosidade ambiente, tempo de tela ativo, status da bateria, histórico de notificações e aplicativos em primeiro plano. O KDS realiza a fusão de informações utilizando seis conjuntos de dados públicos. A Figura 4 apresenta a arquitetura do KDS. O código foi organizado em três partes: a classe principal, a análise e persistência da informação e o gerador de contexto.

A classe principal gerencia o fluxo de dados e a simulação, iniciando com a análise e persistência de dados. Durante a leitura, cada participante presente nos *datasets* é associado a um indivíduo simulado no KDS. O número de participantes é definido com base no *Student Life Dataset*, enquanto dados demográficos (gênero, idade, escolaridade) são extraídos do DASS-21. As respostas dos questionários SAS [Kwon et al., 2013], No-




Figura 4. Arquitetura KDS

mophobia [Yildirim and Correia, 2015] e DASS-21 [Lovibond and Lovibond, 1995] são pontuadas conforme protocolos estabelecidos.

4.2. Pré-processamento dos Dados

O agente *Data Preprocessing* inicia o pré-processamento de dados selecionando as características a serem utilizadas no cálculo da distância de Manhattan. A distância de Manhattan foi escolhida dada a necessidade de classificação de dados de alta dimensão [Wang et al., 2014]. A seleção de características é uma etapa importante ao utilizar a distância de Manhattan como métrica de similaridade [Yu et al., 2008]. Devido à natureza da distância de Manhattan, que mede as diferenças absolutas entre características selecionadas, calculando a soma dessas diferenças [Aggarwal et al., 2001], o número de características pode ser computacionalmente oneroso e pode levar a problemas de sobreajuste ou subajuste.

Posteriormente, os dados foram submetidos a um processo de normalização, visando escalonar as variáveis para uma mesma faixa de valores e evitar que diferenças de escala distorcessem a influência relativa dos atributos nos modelos. Esse processo teve o objetivo de escalonar as características para que tivessem a mesma importância, evitando que nenhuma característica exercesse uma influência indevida nos resultados [Norris, 2001]. A normalização dos dados ajuda a melhorar o desempenho e a estabilidade dos modelos de aprendizado de máquina [Patel and Mehta, 2011]. A combinação entre seleção rigorosa de atributos e normalização criteriosa permitiu a construção de um pipeline de pré-processamento otimizado para a detecção de padrões UPS.

4.3. Modelo Baseado em Distância para Identificação de UPS

O conjunto de dados gerado pelo KDS permitiu criar grupos de comportamento possibilitando que o agente *Dangerous Use Pattern Identifier* identificasse comportamentos normais e problemáticos do uso do smartphone. O processo de identificação do comportamento inicia com a recuperação dos contextos gerados pelo KDS no banco de dados. O algoritmo simula o recebimento de informações de hora em hora, o que permite a comparação entre as informações sincronizadas e o padrão de uso do smartphone de usuários normais e de UPS. O processo de identificação do comportamento consiste em

analisar uma sequência de Históricos de Contextos baseados em horas e o comportamento de uso do smartphone com base em dados históricos. Essa abordagem permite o uso da distância de Manhattan para categorizar os comportamentos de uso do smartphone.

A Figura 5 ilustra a abordagem utilizada para estruturar os dados de entradas do modelo de aprendizado de máquina. A Referência 1 indica o processo de simulação dos Históricos de Contextos. A Referência 2 apresenta a criação de clusters de uso de smartphones. As caixas azuis representam os identificadores de grupos, enquanto a caixa laranja representa as características calculadas dos clusters. O algoritmo inicia verificando a existência de grupos de usuários de smartphones. A geração de perfis ocorre de forma dinâmica, aumentando o conhecimento e recalculando os perfis de uso de smartphones uma vez ao dia. A simulação gera dados de forma horária, enquanto os contextos convergem em agrupamentos diários. No primeiro dia de sincronização de dados, o algoritmo não realiza o processo de categorização, pois a geração de perfis se baseia em informações históricas.




Figura 5. Estrutura do modelo de aprendizado de máquina

A Referência 3 mostra a simulação de um novo Histórico de Contextos para um indivíduo. Por fim, a Referência 4 apresenta o cálculo da distância entre as informações de contexto recebidas e o comportamento de um indivíduo normal e um indivíduo que apresenta UPS. As informações demográficas (gênero, tipo de dia e faixa etária) determinam a seleção do perfil comportamental. Em seguida, o algoritmo normaliza as informações sincronizadas, mantendo apenas as características selecionadas (Tabela 2).

O algoritmo calcula a distância Manhattan entre as informações de contexto recebidas (comportamento de uso de smartphone) e os perfis de comportamento normal e UPS do usuário. A soma das distâncias é calculada e armazenada em um dicionário. Posteriormente, o algoritmo itera sobre as entradas do dicionário. Para cada entrada, o algoritmo verifica se as informações sincronizadas correspondem a um comportamento normal ou indicam UPS. Finalmente, as distâncias são transformadas em percentuais, representando o nível de confiança de que o comportamento de uso de smartphone do usuário pertence ao grupo com a menor distância.

Com base nas informações classificadas, o Kratos sugere intervenções para auxi-

Tabela 2. Características selecionadas após a técnica de *information gain ratio*.

Informação	Tipo	Information Gain Ratio	Seleção de Característica
Resultado Total SAS	Questionário	0,37725	Information Gain Ratio (Alvo)
Resultado Total Nomofobia	Questionário	0,31057	Information Gain Ratio
Pontuação de Depressão	Questionário	0,03247	Information Gain Ratio
Pontuação de Estresse	Questionário	0,03002	Information Gain Ratio
Tempo de Uso do Aplicativo Mais Usado	Sensor	0,02849	Information Gain Ratio
Minutos Bloqueado	Sensor	0,02811	Information Gain Ratio
Tempo de Uso do Aplicativo	Sensor	0,02716	Information Gain Ratio
Minutos Bloqueado	Sensor	0,02524	Information Gain Ratio
Categoria de Notificações (Quantidade)	Sensor	0,01166	Information Gain Ratio
Quantidade de Notificações	Sensor	0,01120	Information Gain Ratio
Pontuação de Ansiedade	Questionário	0,00192	Information Gain Ratio
Humor	EMA	0,00115	Information Gain Ratio
Nível da Bateria	Sensor	0,00089	Information Gain Ratio
Horas de Sono	EMA	0,00083	Information Gain Ratio
Gênero	Informação Pessoal	-	Literatura
Categoria Etária	Informação Pessoal	-	Literatura
Tipo de Dia	Informação Pessoal	-	Literatura

liar no UPS. O algoritmo verifica o horário, o turno do dia, o tipo de dia e as informações de uso do smartphone para propor intervenções. Por exemplo, no caso de um indivíduo que usa um smartphone à noite em um dia de semana, o agente *Intervention Engine* sugere a prática de exercícios físicos como uma intervenção para equilibrar o tempo sedentário gasto com o telefone e quebrar o ciclo de PSU.

4.4. Desempenho da Classificação por Análise de Silhueta

A Tabela 3 apresenta os escores de silhueta para os segmentos. A primeira coluna (Gênero) exibe o gênero dos indivíduos. A segunda coluna (Tipo de Dia) indica se o registro do comportamento ocorreu em dias úteis ou finais de semana. A terceira coluna (Faixa Etária) informa a faixa de idade dos indivíduos. A quarta coluna (Comportamento Normal) apresenta os escores de silhueta para o grupo de comportamento normal. A quinta (Comportamento UPS) exibe os escores de silhueta para o grupo de comportamento UPS. Finalmente, a coluna número de registros normais mostra a contagem de comportamentos identificados como normais, e a coluna número de registros UPS retrata a quantidade de comportamentos identificados como UPS. Um escore de silhueta próximo de 1 indica que os indivíduos estão bem ajustados ao seu cluster e mal ajustados ao cluster vizinho.

Tabela 3. Escores de silhueta para cada um dos segmentos.

Gênero	Tipo de Dia	Faixa Etária	Comportamento Normal	Comportamento UPS	Num. Registros Normais	Num. Registros UPS
Feminino	Dia útil	Adulto	0,358	0,004	6.525	3.075
Feminino	Dia útil	Adolescente	0,354	0,042	6.524	2.115
Feminino	Final de semana	Adulto	0,331	0,146	3.111	1.210
Feminino	Final de semana	Adolescente	0,196	0,103	2.790	1.098
Masculino	Dia útil	Adulto	0,324	-0,138	2.258	622
Masculino	Dia útil	Adolescente	0,304	0,244	1.533	388
Masculino	Final de semana	Adulto	0,199	0,116	1.029	267
Masculino	Final de semana	Adolescente	0,427	0,172	652	213

Os resultados indicam que os registros classificados como comportamento normal apresentam escores de silhueta positivos em todos os segmentos, sugerindo uma boa coesão dentro dos clusters e uma clara separação em relação a outros grupos. Destaca-se o segmento de adolescentes do gênero masculino durante finais de semana, que obteve o maior escore (0,427), reforçando a efetividade da classificação nesse contexto.

Para os registros classificados como comportamento problemático, os escores são mais variados, com alguns valores próximos de zero ou negativos. Em particular, os

adultos do gênero masculino em dias úteis apresentaram um escore de -0,138, sugerindo uma sobreposição maior com outros clusters. Esse comportamento pode estar relacionado à maior diversidade de padrões dentro desse grupo específico.

Os resultados demonstram que a abordagem utilizada conseguiu segmentar os registros de forma eficiente, especialmente para os comportamentos normais. Para os comportamentos problemáticos, os escores sugerem a necessidade de refinamentos na categorização, o que pode ser abordado em iterações futuras do modelo. Ainda assim, o desempenho geral do algoritmo reforça sua capacidade de diferenciar padrões comportamentais relacionados ao uso de smartphones, sendo uma ferramenta promissora para a identificação do UPS.

5. Conclusão

Este estudo apresentou o Kratos, um modelo computacional desenvolvido para identificar padrões de UPS e recomendar intervenções cientes de contexto. O Kratos combina técnicas de aprendizado de máquina, modelagem ontológica e fusão de dados, com o objetivo de estabelecer um modelo robusto para o monitoramento comportamental do uso de smartphones. O modelo proposto visa aprimorar a detecção precoce de riscos psicossociais associados à hiperconectividade, além de oferecer estratégias de mitigação adaptáveis a perfis de usuários e contextos ambientais.

As contribuições deste trabalho se destacam em três dimensões principais. Primeiramente, o desenvolvimento do Kratos Dataset Simulator, uma ferramenta baseada em *datasets* públicos para a geração de dados sintéticos, que simula a coleta de informações contextuais a partir de sensores móveis, EMA e questionários. Em segundo lugar, propôs-se uma metodologia integrada para a fusão de múltiplas fontes de dados, viabilizando a aplicação de técnicas avançadas de aprendizado de máquina para a detecção de padrões de uso problemático. Por fim, a estruturação de um modelo capaz de inferir comportamentos de risco e sugerir intervenções personalizadas abrindo novas possibilidades para a aplicação da tecnologia no suporte ao bem-estar digital.

Entretanto, o estudo apresenta limitações. A avaliação baseada exclusivamente em dados sintéticos limita a generalização dos resultados à falta de diversidade individual, exigindo validação futura em ambientes reais. A estratégia de agrupamento baseada na Distância Manhattan com dois clusters por participante pode constituir uma simplificação excessiva, potencialmente negligenciando nuances comportamentais em contextos multimodais. Estas limitações orientam direções futuras: (1) ampliar a coleta de dados empíricos multissensoriais para treinamento de modelos preditivos; (2) explorar técnicas de agrupamento mais sofisticadas para capturar padrões complexos de uso; (3) investigar estratégias de intervenção adaptativas baseadas em modelos de recomendação contextual. Estes avanços poderão auxiliar políticas de saúde digital para promoção de hábitos de uso da tecnologia sustentáveis.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001, e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento deste trabalho.

Referências

- Aggarwal, C. C., Hinneburg, A., and Keim, D. A. (2001). On the surprising behavior of distance metrics in high dimensional space. In *Database Theory — ICDT 2001*, pages 420–434. Springer Berlin Heidelberg.
- Bavaresco, R., Ren, Y., Barbosa, J., and Li, G. (2024). An ontology-based framework for worker’s health reasoning enabled by machine learning. *Computers Industrial Engineering*, 193:110310.
- Bouazza, S., Abbouyi, S., El Kinany, S., El Rhazi, K., and Zarrouq, B. (2023). Association between problematic use of smartphones and mental health in the middle east and north africa (mena) region: A systematic review. *International Journal of Environmental Research and Public Health*, 20(4):2891.
- Busch, P. A. and McCarthy, S. (2021). Antecedents and consequences of problematic smartphone use: A systematic literature review of an emerging research area. *Computers in Human Behavior*, 114:106414.
- Choi, J., Rho, M. J., Kim, Y., Yook, I. H., Yu, H., Kim, D.-J., and Choi, I. Y. (2017). Smartphone dependence classification using tensor factorization. *PLOS ONE*, 12(6):1–12.
- Elhai, J. D., Dvorak, R. D., Levine, J. C., and Hall, B. J. (2017). Problematic smartphone use: A conceptual overview and systematic review of relations with anxiety and depression psychopathology. *Journal of Affective Disorders*, 207:251–259.
- Elhai, J. D., Rozgonjuk, D., Alghraibeh, A. M., and Yang, H. (2021). Disrupted Daily Activities From Interruptive Smartphone Notifications: Relations With Depression and Anxiety Severity and the Mediating Role of Boredom Proneness. *Social Science Computer Review*, 39(1):20–37.
- Filippetto, A. S., Lima, R., and Barbosa, J. L. V. (2021). A risk prediction model for software project management based on similarity analysis of context histories. *Information and Software Technology*, 131:106497.
- Gratch, I., Choo, T.-H., Galfalvy, H., Keilp, J. G., Itzhaky, L., Mann, J. J., Oquendo, M. A., and Stanley, B. (2021). Detecting suicidal thoughts: The power of ecological momentary assessment. *Depression and anxiety*, 38(1):8–16.
- Grüning, D. J., Riedel, F., and Lorenz-Spreen, P. (2023). Directing smartphone use through the self-nudge app one sec. *Proceedings of the National Academy of Sciences*, 120(8).
- Horwood, S. and Anglim, J. (2018). Personality and problematic smartphone use: A facet-level analysis using the five factor model and HEXACO frameworks. *Computers in Human Behavior*, 85:349–359.
- Kent, S., Masterson, C., Ali, R., Parsons, C. E., and Bewick, B. M. (2021). Digital intervention for problematic smartphone use. *International Journal of Environmental Research and Public Health*, 18(24):13165.
- Kwon, M., Kim, D.-J., Cho, H., and Yang, S. (2013). The smartphone addiction scale: Development and validation of a short version for adolescents. *PLoS ONE*, 8(12):e83558.
- Lee, H., Ahn, H., Choi, S., and Choi, W. (2014). The sams: Smartphone addiction management system and verification. *Journal of medical systems*, 38(1):1–10.
- Lee, J. and Kim, W. (2021). Prediction of problematic smartphone use: A machine learning approach. *International Journal of Environmental Research and Public Health*, 18(12).

- Lee, M., Han, M., and Pak, J. (2018). Analysis of behavioral characteristics of smartphone addiction using data mining. *Applied Sciences*, 8(7).
- Lovibond, P. F. and Lovibond, S. H. (1995). The structure of negative emotional states: Comparison of the Depression Anxiety Stress Scales (DASS) with the Beck Depression and Anxiety Inventories. *Behaviour Research and Therapy*, 33(3):335–343.
- Lu, X., An, X., and Chen, S. (2024). Trends and influencing factors in problematic smartphone use prevalence (2012–2022): A systematic review and meta-analysis. *Cyberpsychology, Behavior, and Social Networking*, 27(9):616–634.
- Marciano, L. and Camerini, A.-L. (2022). Duration, frequency, and time distortion: Which is the best predictor of problematic smartphone use in adolescents? a trace data study. *PLOS ONE*, 17(2):1–19.
- Norris, G. A. (2001). The requirement for congruence in normalization. *The International Journal of Life Cycle Assessment*, 6(2).
- Olson, J. A., Sandra, D. A., Chmoulevitch, D., Raz, A., and Veissière, S. P. (2022). A nudge-based intervention to reduce problematic smartphone use: Randomised controlled trial. *International Journal of Mental Health and Addiction*, pages 1–23.
- Padgham, L. and Winikoff, M. (2003). Prometheus: A methodology for developing intelligent agents. In Giunchiglia, F., Odell, J., and Weiß, G., editors, *Agent-Oriented Software Engineering III*, pages 174–185, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Patel, V. R. and Mehta, R. G. (2011). Impact of outlier removal and normalization approach in modified k-means clustering algorithm. *International Journal of Computer Science Issues (IJCSI)*, 8(5):331.
- Rahman, M. A., Duradoni, M., and Guazzini, A. (2022). Identification and prediction of phubbing behavior: a data-driven approach. *Neural Computing and Applications*, 34(5):3885–3894.
- Rentz, D. M., Heckler, W. F., and Barbosa, J. L. V. (2023). A computational model for assisting individuals with suicidal ideation based on context histories. *Universal Access in the Information Society*, 23(3):1447–1466.
- Schroeder, G. L., Heckler, W., Francisco, R., and Barbosa, J. L. V. (2022). Problematic smartphone use on mental health: a systematic mapping study and taxonomy. *Behaviour & Information Technology*, 42(16):2808–2831.
- Turner, A. (2021). How many smartphones are in the world? <https://www.bankmycell.com/blog/how-many-phones-are-in-the-world>. Accessed: 2025-01-11.
- Wang, R., Chen, F., Chen, Z., Li, T., Harari, G., Tignor, S., Zhou, X., Ben-Zeev, D., and Campbell, A. T. (2014). StudentLife. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*. ACM.
- Yasudomi, K., Hamamura, T., Honjo, M., Yoneyama, A., and Uchida, M. (2021). Usage prediction and effectiveness verification of app restriction function for smartphone addiction. *2020 IEEE International Conference on E-Health Networking, Application and Services, HEALTHCOM 2020*.
- Yildirim, C. and Correia, A.-P. (2015). Exploring the dimensions of nomophobia: Development and validation of a self-reported questionnaire. *Computers in Human Behavior*, 49:130–137.
- Yu, J., Amores, J., Sebe, N., Radeva, P., and Tian, Q. (2008). Distance learning for similarity estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(3):451–462.