



UNIVERSIDADE FEDERAL DO MARANHÃO
Programa de Pós-Graduação em Ciência da Computação

Ivan Rodrigues de Moura

Monitoramento Ubíquo da Saúde Mental: Detectando Padrões de Sociabilidade Enriquecidos por Contexto Através do Processamento de Eventos Complexos

São Luís
2020

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Ivan Rodrigues de Moura

*Monitoramento Ubíquo da Saúde Mental: Detectando Padrões de
Sociabilidade Enriquecidos por Contexto Através do
Processamento de Eventos Complexos*

São Luís
2020

Ivan Rodrigues de Moura

Monitoramento Ubíquo da Saúde Mental: Detectando Padrões de Sociabilidade Enriquecidos por Contexto Através do Processamento de Eventos Complexos

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Maranhão como requisito parcial para a obtenção do grau de MESTRE em Ciência da Computação.

Orientador: Francisco José da Silva e Silva

Doutor - UFMA

Co-orientador: Luciano Reis Coutinho

Doutor - UFMA

São Luís

2020

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Rodrigues de Moura, Ivan.

Monitoramento Ubíquo da Saúde Mental: Detectando Padrões de Sociabilidade Enriquecidos por Contexto Através do Processamento de Eventos Complexos / Ivan Rodrigues de Moura. - 2020.

107 f.

Coorientador(a): Luciano Reis Coutinho.

Orientador(a): Francisco José da Silva e Silva.

Dissertação (Mestrado) - Programa de Pós-graduação em Ciência da Computação/ccet, Universidade Federal do Maranhão, São Luís, 2020.

1. Computação Móvel. 2. Computação Ubíqua. 3. Padrões de Sociabilidade. 4. Saúde Mental. 5. Transtornos Mentais. I. da Silva e Silva, Francisco José. II. Reis Coutinho, Luciano. III. Título.

Ivan Rodrigues de Moura

Monitoramento Ubíquo da Saúde Mental: Detectando Padrões de Sociabilidade Enriquecidos por Contexto Através do Processamento de Eventos Complexos

Este exemplar corresponde à redação final da dissertação devidamente corrigida e defendida por Ivan Rodrigues de Moura e aprovada pela comissão examinadora.

Aprovada em

BANCA EXAMINADORA

Francisco José da Silva e Silva (orientador)

Doutor - UFMA

Luciano Reis Coutinho (coorientador)

Doutor - UFMA

Carlos de Salles Soares Neto

Doutor - UFMA

Raphael Yokoingawa de Camargo

Doutor - UFABC

*Aos meus pais, meus
irmãos, meus amigos e meus
professores.*

Resumo

Tradicionalmente, o monitoramento de indivíduos com transtornos mentais é realizado por meio de reuniões presenciais com profissionais especializados em saúde mental. Hoje, no entanto, os métodos computacionais podem usar dispositivos ubíquos (e.g., smartphones e tecnologias vestíveis) para monitorar comportamentos sociais relacionados à saúde mental, em vez de depender de autorrelatos. Esses dispositivos representam uma fonte valiosa de dados contextuais que permitem a identificação das atividades sociais vivenciadas pelos indivíduos em sua rotina diária. Portanto, o uso dessas tecnologias para identificar o hábito de atividades sociais permite o reconhecimento de comportamentos sociais anormais que podem ser indicativos de transtornos mentais. Por esse motivo, este estudo apresenta uma nova abordagem para monitorar a saúde mental por meio da conscientização da situação social. Este trabalho apresenta um algoritmo capaz de detectar padrões de sociabilidade, ou seja, caracteriza os períodos do dia em que o indivíduo se socializa habitualmente. O reconhecimento da rotina social é realizado sob diferentes condições de contexto (e.g., dia útil e fim de semana), o que permite diferenciar comportamentos sociais anormais das mudanças nos hábitos sociais esperadas em determinadas situações. A solução apresentada também é capaz de identificar mudanças nos padrões sociais que podem ser indicativos da presença de transtornos mentais. A implementação do algoritmo proposto utilizou a combinação da abordagem de Mineração de Padrões Frequentes com o Processamento de Eventos Complexos, o que permite a realização do processamento contínuo do fluxo de dados sociais. A avaliação realizada demonstrou que o reconhecimento baseado em contexto fornece uma melhor compreensão da rotina social, indicando também que a solução proposta é capaz de detectar padrões de sociabilidade semelhantes a um algoritmo em lote. Além disso, foi validado o desempenho do mecanismo de detecção de mudanças no comportamento social.

Palavras-chave: Saúde Mental, Transtornos Mentais, Computação Ubíqua, Computação Móvel, Padrões de Sociabilidade.

Abstract

Traditionally, the monitoring of individuals with mental disorders is conducted through face-to-face meetings with professionals specialized in mental health. Today, however, computational methods can use ubiquitous devices (e.g., smartphones and wearable technologies) to monitor social behaviors related to mental health rather than relying on self-reports. These devices represent a valuable source of contextual data that allows the identification of the social activities experienced by individuals in their daily routine. Therefore, the use of these technologies to identify social activities habit enables the recognition of abnormal social behaviors that may be mental disorders indicative. For this reason, this study presents a new approach to monitoring mental health through social situation awareness. This work introduces an algorithm capable of detecting sociability patterns, i.e., it characterizes the periods of the day when the individual socializes habitually. The recognition of social routine is performed under different context conditions (e.g., workday and weekend), which allows differentiating abnormal social behaviors from changes in social habits expected in certain situations. The solution presented is also able to identify changes in social patterns that may be indicative of mental disorders presence. The implementation of the proposed algorithm used the combination of the Frequent Patterns Mining approach with the Complex Events Processing, which allows the realization of the continuous social data stream processing. The evaluation performed demonstrated that context-based recognition provides a better understanding of the social routine, also indicating that the proposed solution is capable of detecting sociability patterns similar to a batch algorithm. Additionally, it was validated the performance of the social behavior change detection mechanism.

Keywords: Mental Health, Mental Disorders, Ubiquitous Computing, Mobile Computing, Sociability Pattern.

Agradecimentos

Este trabalho foi fruto de muito esforço depositado por meu orientador, coorientador e por mim durante a minha vida acadêmica no mestrado. Contudo, nada disso seria possível sem a contribuição direta e indireta de muitas pessoas.

Ao bom Deus em primeiro lugar, pela minha vida e por todas as maravilhas.

Ao meu orientador, o Prof. Francisco José da Silva e Silva, e coorientado, o Prof. Luciano Reis Coutinho, pela orientação, compreensão e por se fazerem presente em todas as etapas do processo de concepção deste estudo, fornecendo todo apoio que necessitei nesta trajetória.

A Ariel Teles e Davi Viana, pelo apoio e ensinamentos que foram essenciais para minha evolução como pesquisador nesta jornada acadêmica.

Aos membros da banca examinadora, por aceitarem a missão de avaliar este trabalho.

Aos meus familiares, que representam minha sustentação, pois forneceram o apoio necessário para me manter firme nesta jornada árdua. Aos meus irmãos Lucas Rodrigues e Valéria Rodrigues pela companhia, apoio, compreensão e por todos os momentos compartilhados na minha vida. Aos meus tios. Aos meus padrinhos Otacílio Moura e Francisca Pereira. Aos meus primos, em especial Ernandes Guedes, pois foi um dos primeiros a incentivar-me a fazer este mestrado. A minha mãe Marlene Rodrigues e ao meu pai Raimundo Moura, pois sem eles nada disso seria possível, uma vez que estes são responsáveis pelo que sou atualmente, pois tanto minha índole quanto capacidade profissional são frutos de seus valiosos esforços para me educar.

Aos membros do LSDi e do LAC, com os quais compartilhei alegrias, tristezas, e conhecimento. Em especial, aos meus amigos Anderson, Tércio, Leonardo, Fernando e Felipe por estarem presente nessa caminhada. Sem a ajuda deles, essa jornada teria sido muito mais difícil.

Ao meu orientador da graduação Carleandro Noletto, que foi um dos responsáveis por me incentivar, preparar e qualificar para enfrentar esta jornada acadêmica.

À UFMA e ao PPGCC pela estrutura dada a execução deste trabalho.

Agradeço também a todos os meus amigos de Floriano-PI e São Luís-MA, que direta ou indiretamente foram responsáveis por me motivar em todo o período deste mestrado.

"Você aprende melhor e mais rápido quando alcança determinado lugar bem além do limite da sua capacidade atual."

Daniel Coyle

Lista de Figuras

2.1	Detecção de situações sociais através dos dispositivos ubíquos.	25
2.2	Detecção de co-localização e conversação entre indivíduos.	26
2.3	Visão geral de um mecanismo CEP.	31
2.4	Tipos de <i>concept drift</i> [78].	36
2.5	Conjunto fuzzy para avaliar a velocidade de um veículo.	38
2.6	Arquitetura de um sistema fuzzy.	40
3.1	Diagrama do processo de revisão da literatura.	45
4.1	Fluxo de processamento.	58
4.2	Estratégia de detecção de comportamentos sociais anormais.	65
4.3	Estratégia de detecção de mudança de rotina social.	65
4.4	Conjunto <i>fuzzy</i> para avaliar a sensibilidade de mudança.	67
4.5	Conjunto <i>fuzzy</i> para avaliar a similaridade.	68
4.6	Conjunto <i>fuzzy</i> para avaliar a mudança.	69
5.1	Formato das amostras de conversação.	74
5.2	Padrões de sociabilidade identificados por ambos algoritmos.	77
5.3	Padrões de sociabilidade utilizando CAs.	78
5.4	Configuração da avaliação da predição do padrão de sociabilidade. . . .	80
5.5	Médias das predições dos padrões de sociabilidade.	81
5.6	Configuração da avaliação da estabilidade de rotina social.	81
5.7	Estabilidade da rotina social dos indivíduos monitorados.	82
5.8	Visualização da correlação entre perda e rotina de sociabilidade. . . .	83

5.9	Correlação entre perda e rotina de sociabilidade para cada condição de contexto.	83
5.10	Média do nível de correlação para cada condição de contexto.	84
5.11	Junção da rotina social dos usuários u27 e u04.	85
A.1	Distribuição dos estudos por ano.	105
A.2	Estados de saúde mental explorados pelos estudos selecionados.	106

Lista de Tabelas

3.1	Palavras-chave e seus sinônimos.	43
3.2	Itens usados no processo de extração de dados.	44
3.3	Usos da conscientização da situação social.	46
5.1	Processamento da detecção de mudança de comportamento social.	86
A.1	Resumo dos estudos revisados - Parte I.	101
A.2	Resumo dos estudos revisados - Parte II.	103

Lista de Siglas

C_s	<i>Matriz de Contadores.</i>
S_{th}	<i>Slot Theshold.</i>
ADWIN	<i>Adaptive Windowing.</i>
API	<i>Application Programming Interface.</i>
CAs	<i>Atributos de Contexto.</i>
CEP	<i>Processamento de Eventos Complexos.</i>
DDM	<i>Drift Detection Method.</i>
ECA	<i>Evento-Condição-Ação.</i>
EDDM	<i>Early Drift Detection Method.</i>
EMA	<i>Avaliação Momentânea Ecológica.</i>
EMI	<i>Intervenção Momentânea Ecológica.</i>
EPL	<i>Linguagem de Processamento de Eventos .</i>
FCL	<i>Fuzzy Control Language.</i>
FIS	<i>Sistemas de Inferência Fuzzy.</i>
FPM	<i>Mineração de Padrões Frequentes.</i>
GMM	<i>Gaussian Mixing Models.</i>
IoT	<i>Internet das Coisas.</i>
JSON	<i>JavaScript Object Notation.</i>

NFC *Near Field Communication.*

OMS *Organização Mundial da Saúde.*

RSL *Revisão Sistemática da Literatura.*

RSSI *WiFi Received Signal Strength Indicator.*

SQL *Structured Query Language.*

Sumário

Lista de Figuras	vii
Lista de Tabelas	ix
Lista de Siglas	x
1 Introdução	16
1.1 Objetivos	18
1.2 Metodologia	18
1.3 Estrutura da Dissertação	19
2 Fundamentação Teórica	21
2.1 Avaliação e Intervenção Momentânea Ecológica	21
2.2 Fenotipagem digital	23
2.3 Computação Positiva	24
2.4 Relações Sociais	25
2.4.1 Encontros Face a Face	26
2.4.2 Comunicação Mediada por Dispositivo	28
2.5 Processamento de Eventos Complexos	30
2.5.1 Agentes de Processamento de Eventos e Rede de Processamento de Eventos	31
2.5.2 Contexto e Partições de Contexto	32
2.5.3 Janela de Tempo	33
2.5.4 Tabela Nomeada	34
2.6 Mineração de Padrões Frequentes	34
2.7 Concept Drift	35

2.8	Lógica Fuzzy	37
2.8.1	Sistemas de Inferência Fuzzy	39
2.9	Discussões	40
3	Trabalhos Relacionados	41
3.1	Metodologia de Pesquisa	41
3.1.1	Objetivo e Questões de Pesquisa	42
3.1.2	Estratégia de pesquisa	42
3.1.3	Critérios de Seleção	43
3.1.4	Extração de Dados	44
3.2	Condução da RSL	45
3.3	Resultados da RSL	46
3.3.1	Detectar e Quantificar a Sociabilidade	46
3.3.2	Associação entre Estado Mental e Características Sociais	47
3.3.3	Classificação e Predição do Estado Mental	49
3.4	Oportunidades de Pesquisas Identificadas Através da RSL	50
3.5	Discussões	51
4	Solução Proposta	53
4.1	Cenário de Aplicação	53
4.2	Aprendendo Padrões de Sociabilidade Enriquecidos pelo Contexto	54
4.2.1	Identificação de Padrões de Sociabilidade	54
4.2.2	Variações de Comportamentos Sociais Devido ao Contexto	56
4.3	Implementações Utilizando CEP	57
4.3.1	Enriching Social Events	58
4.3.2	<i>Context Partition EPA</i>	59
4.3.3	<i>Candidate Slot EPA</i>	61
4.3.4	Extração do Padrão de Sociabilidade	61

4.4	Detecção de Mudança de Rotina Social e Comportamentos Sociais Anormais	62
4.4.1	Estratégia de Detecção de Mudança Comportamental	63
4.4.2	Modelagem do Conhecimento do Especialista	65
4.5	API de Programação	70
4.6	Discussões	71
5	Avaliação	73
5.1	Descrição dos Dados	73
5.2	Design experimental	75
5.3	Precisão dos Intervalos Identificados	76
5.4	Análise dos Padrões de Sociabilidade Enriquecidos Por Contexto	78
5.5	Capacidade de Modelagem da Rotina Social	79
5.6	Validação da Detecção de Mudança de Comportamento Social	84
5.7	Discussões	87
6	Conclusões e Trabalhos Futuros	89
6.1	Contribuições	90
6.2	Trabalhos Futuros	90
6.3	Publicações	91
	Referências Bibliográficas	93
A	Apêndice A - Visão Geral dos Trabalhos Seleccionados na RSL	101
A.1	Resumo dos Estudos Seleccionados	101
A.2	Data de Publicação dos Trabalhos Incluídos	104
A.3	Estados de saúde mental	105
A.4	Duração e Participantes do Estudo	106
A.5	Dados Contextuais	107

1 Introdução

De acordo com a *Organização Mundial da Saúde* (OMS) [75], *Saúde Mental* é conceituada como um estado de bem-estar no qual os indivíduos são capazes de usar suas habilidades, recuperar-se do estresse diário da rotina, ser produtivos e contribuir com a sua comunidade. O termo transtorno mental é normalmente utilizado para designar problemas relacionados a saúde mental, como os transtornos de humor (e.g., depressão), ansiedade e estresse excessivos, transtornos de personalidade (e.g., bipolar) e transtornos delirantes. As consequências destas condições resultam em um conjunto de mudanças comportamentais, as quais podem fornecer indicadores relevantes da presença, início, ou desenvolvimento de transtornos mentais [54].

Dentre os comportamentos que estão relacionados a saúde mental é possível destacar a importância da sociabilidade dos pacientes, uma vez que as relações sociais têm implicações importantes para a saúde mental [68]. O nível de sociabilidade de uma pessoa pode afetar diretamente seu estado psicológico, podendo desempenhar um papel protetor ou contribuir para as consequências de transtornos mentais. Por exemplo, o isolamento social está associado a sintomas de depressão, ansiedade e ideação suicida [11]. Também existem evidências de que níveis mais altos de apoio social podem representar uma condição protetora para a depressão e que níveis mais baixos estão associados à presença, início ou desenvolvimento da depressão [28, 32]. Assim, os sintomas dos transtornos mentais podem ser externalizados por meio de mudanças nos comportamentos sociais, caracterizando uma situação de interesse para o monitoramento da saúde mental.

Os métodos tradicionais de avaliação psicológica, que analisam o aspecto social, baseiam-se em evidências clínicas e informações autorrelatadas pelo paciente. Essas abordagens geralmente são apoiadas por relatos retrospectivos de experiências sociais vivenciada por indivíduos em sua rotina diária, nas quais o tempo de lembrança pode ser dias, semanas e até meses. Portanto, esses métodos são limitados por um conjunto de vieses cognitivos que podem contribuir para uma exposição incoerente da experiência vivida [58]. Por exemplo, os pacientes podem mudar a verdade dos autorrelatos, consciente ou inconscientemente, para alcançar um resultado socialmente

desejável [69]. Outro motivo que limita a eficácia dessa metodologia é que ela ocorre em ambientes clínicos, onde a entrevista é coordenada pelo profissional da saúde mental. Portanto, não há validade ecológica nessa técnica de avaliação, porque o ambiente clínico é significativamente diferente do contexto natural das pessoas [67]. Deste modo, é necessário conceber novos métodos capazes de fornecer medidas objetivas do comportamento social.

Os dispositivos ubíquos, como *smartphones*, *smartwatches*, bandas inteligentes e pulseiras de *fitness*, representam um meio promissor de mitigar essas limitações, porque estão amplamente difundidas na rotina diária de seus usuários, apresentando o potencial de monitorar e realizar intervenções em tempo real [33]. Os sensores incorporados nesses dispositivos coletam dados de contexto, que combinados com métodos computacionais (e.g., aprendizado de máquina e mineração de dados) podem ser usados para identificar situações de interesse, como as atividades sociais. Por exemplo, esses métodos podem usar dados de microfones para identificar conversas experimentadas por indivíduos [72]. Essa abordagem permite identificar padrões de sociabilidade (i.e., a rotina das atividades sociais) que fornecem informações valiosas sobre o bem-estar dos indivíduos. O monitoramento desses padrões possibilita reconhecer atividades anormais e mudanças comportamentais, que podem ser indicadores significativos de transtornos mentais.

Para propor uma solução que possa mitigar as limitações dos métodos tradicionais de monitoramento do comportamento social, este trabalho apresenta um algoritmo para detectar padrões de sociabilidade enriquecidos por contexto, que foi implementado combinando a abordagem de *Mineração de Padrões Frequentes* (FPM) [2] com o *Processamento de Eventos Complexos* (CEP) [26]. A solução proposta processa observações de atividades sociais derivadas de dispositivos ubíquos, vindo a realizar um aprendizado incremental do comportamento social dos indivíduos monitorados. O reconhecimento dos padrões sociais é realizado para contextos específicos (e.g., dias da semana, dias úteis, dias chuvosos), permitindo identificar a variabilidade do comportamento em diferentes condições de contexto.

1.1 Objetivos

A pesquisa à qual se refere esta dissertação de mestrado tem como objetivo geral conceber uma nova abordagem de monitoramento da saúde mental apoiada pela conscientização da situação social. Portanto, objetiva-se desenvolver uma solução capaz de reconhecer padrões de sociabilidade, comportamentos sociais anormais e mudanças significativas ocorridas na rotina social dos indivíduos monitorados.

Os objetivos específicos desta pesquisa são:

- Fornecer uma revisão abrangente do estado da arte existente sobre estudos que propõem métodos para reconhecer situações sociais por meio de dispositivos ubíquos, os quais o utilizaram para desenvolver ferramentas de assistência à saúde mental.
- Introduzir uma abordagem para realizar o aprendizado incremental de padrões de sociabilidade enriquecido por contexto através da combinação entre FPM e CEP.
- Introduzir uma abordagem que possa identificar a variação no comportamento social devido a mudanças no contexto.
- Apresentar uma abordagem para detectar comportamentos sociais anormais e mudanças na rotina social.
- Conduzir uma avaliação experimental da solução proposta usando um fluxo de dados do mundo real.

1.2 Metodologia

Para identificar, analisar e caracterizar o estado da arte da pesquisa relacionada ao monitoramento da saúde mental através da consciência da situação social foi realizada uma *Revisão Sistemática da Literatura* (RSL). Para tanto, foi conduzida uma pesquisa bibliográfica abrangente nas seguintes bibliotecas digitais: Science Direct, PubMed, Scopus, ACM Digital Library, Web of Science, e IEEE Xplorer. A partir de critérios de inclusão e exclusão, foram selecionados os estudos que apresentam

escopo adequado ao objetivo da RSL conduzida. A partir de uma análise aprofundada dos estudos selecionados, foram esclarecidas questões fundamentais para caracterizar este tópico de pesquisa. Assim, ao final, realizou-se uma análise dos resultados da RSL conduzida para reconhecer oportunidades de pesquisa.

Para o desenvolvimento dos componentes de softwares da infraestrutura proposta, foram utilizados princípios dos chamados Métodos Ágeis de Desenvolvimento de Software que preveem a construção de software de forma incremental, interativa e adaptativa. Esta escolha foi tomada devido a necessidade de utilizar um processo ágil de desenvolvimento, que seja razoavelmente documentado e fácil de ser gerenciado. Sempre que possível, o desenvolvimento incremental do software foi baseado em técnicas de refatoração.

A solução proposta foi extensivamente avaliada e validada através de experimentos para identificar sua precisão e verificar a utilidade de reconhecer padrões de sociabilidade enriquecidos em contexto. Para isto, utilizou-se fluxos de dados reais, que permitiram medir o desempenho da solução proposta em diversas configurações, assim como identificar a importância de considerar as informações de contexto na tarefa de reconhecimento de padrões de sociabilidades.

1.3 Estrutura da Dissertação

A organização desta dissertação é a seguinte:

- O Capítulo 2 apresenta a fundamentação teórica, abordando conceitos sobre a aplicação das tecnologias ubíquas no monitoramento da saúde mental, vindo a demonstrar abordagens para alcançar a consciência da situação social. É apresentado também conceitos sobre as tecnologias utilizadas para desenvolver a solução proposta, como CEP, FPM, Concept Drift e Lógica Fuzzy.
- O Capítulo 3 apresenta uma RSL sobre o monitoramento da saúde mental por meio da conscientização da situação social, com foco em soluções que usaram dados comportamentais derivados de sensores embutidos em dispositivos ubíquos.

- O Capítulo 4 apresenta a solução proposta. Essa apresentação contempla o algoritmo concebido para identificar padrões de sociabilidade enriquecidos por contexto, assim como sua implementação através de regras do CEP. Este capítulo também expõem a abordagem de detecção de comportamento sociais anormais e mudanças de rotinas sociais.
- O Capítulo 5 expõe a avaliação experimental da solução proposta usando um fluxo de dados do mundo real, no qual validamos sua precisão e verificamos a utilidade de reconhecer padrões de sociabilidade enriquecidos em contexto.
- O Capítulo 6 apresenta as conclusões obtidas a partir desta pesquisa e apresenta trabalhos futuros que podem ser desenvolvidos a partir deste esforço inicial.

2 Fundamentação Teórica

Este capítulo contém a fundamentação teórica, abordando conceitos sobre a aplicação das tecnologias ubíquas para monitorar a saúde mental e descrevendo as abordagens de detecção de situações sociais relacionados a saúde mental através dos dispositivos ubíquos. Portanto, este capítulo apresenta conceitos sobre a *Avaliação Momentânea Ecológica* (EMA) [37, 60], *Intervenção Momentânea Ecológica* (EMI) [37, 60], fenotipagem digital [65] e computação positiva [17], os quais são termos cunhados para designar a aplicação das tecnologias ubíquas ao bem-estar e a saúde mental. São apresentados também as tecnologias usadas para conceber a solução proposta, vindo a descrever os principais conceitos e características do CEP, FPM, *concept drift* e da *lógica fuzzy*. Algumas considerações são apresentadas no final do capítulo.

2.1 Avaliação e Intervenção Momentânea Ecológica

Os métodos tradicionais de avaliação psicológica são baseados em evidências clínicas e informações autorrelatadas pelo paciente. Essas abordagens são tipicamente baseadas em relatos retrospectivos de eventos experimentados na rotina dos pacientes, nos quais o tempo de lembrança pode ser dias, semanas e até meses. Portanto, esses métodos estão expostos a um conjunto de vieses cognitivos que podem ocorrer na imprecisão da memória relatada [5]. Por exemplo, os pacientes podem, consciente ou inconscientemente, mudar a verdade do autorrelato para alcançar um resultado desejável [69]. Outro motivo que limita a eficácia desse tipo de metodologia é que esta ocorre em ambientes clínicos, onde a terapia é coordenada pelo profissional de saúde mental. Portanto, não existe validade ecológica nesse método de monitorar esse comportamento de saúde mental, uma vez que o ambiente clínico é significativamente diferente do contexto natural das pessoas [67]. Portanto, é necessário criar novos métodos capazes de monitorar automaticamente comportamentos de interesse para tratamentos de saúde mental.

A partir desses requisitos, surgiram os métodos EMA e EMI. A EMA é um mecanismo usado para induzir indivíduos, em horários fixos ou aleatórios, a responder a perguntas sobre o que estão fazendo (ou fizeram) e/ou estão experimentando (ou experimentaram), repetidamente, durante um período de tempo dentro de sua rotina diária. Portanto, EMA é um conjunto de metodologias usadas para coletar informações comportamentais do paciente em sua rotina diária, em que o tempo de coleta de dados é definido com base em situações de interesse (e.g., após acordar e minutos após o término das atividades físicas). De acordo com Shiffman [60], a EMA tem como objetivo “ avaliar o fluxo de experiência e comportamento ao longo do tempo, capturando a vida como ela é vivida, momento a momento, hora a hora, dia a dia, como uma maneira de caracterizar fielmente os indivíduos e de capturar a dinâmica da experiência e do comportamento ao longo do tempo”.

Ao passo que a EMA se concentra na obtenção de informações dos pacientes, a EMI fornece uma estrutura para tratamentos caracterizados pela entrega de intervenções às pessoas durante suas vidas diárias [37]. O EMI é uma metodologia que permite aos profissionais de saúde mental fornecer intervenções aos pacientes em seu ambiente natural. Tais intervenções remotas incluem recomendações clínicas, mensagens encorajadoras e alertas baseados em diferentes informações. Ambas as metodologias (i.e., EMA/EMI), são ecológicas porque ocorrem no ambiente natural e são consideradas momentâneas porque solicitam autoavaliações próximo do tempo em que a atividade ocorreu, fornecendo suporte em tempo real na vida cotidiana do paciente.

Os dispositivos móveis têm as características apropriadas para a implementação dessas metodologias, uma vez que são tecnologias altamente difundidas no cotidiano das pessoas. Além disso, eles têm um caráter difundido e onipresente que ajuda a reduzir a intrusividade e a autopercepção do monitoramento, impedindo, assim, que o paciente mude conscientemente seu comportamento natural. Assim, os métodos EMA/EMI foram implementados em tecnologias móveis usando chamadas telefônicas, mensagens de texto e, mais recentemente, aplicativos móveis, que permitem o relato de experiências e estados mentais (e.g., humor, motivação, ansiedade, qualidade do sono) em tempo real, em ambientes do mundo real, ao longo do tempo e em diferentes contextos/situações. Os aplicativos móveis EMI foram usados para motivar os pacientes, incentivar o engajamento na prática de atividades

físicas, ajudar no desenvolvimento de novas habilidades, notificar ou distrair os indivíduos quando eles correm o risco de se envolver em comportamentos viciantes e fornecer aos indivíduos dados de resumo personalizados.

Os gatilhos EMA/EMI são feitos em horários predeterminados. Portanto, solicitações de autoavaliações e até intervenções podem não ser feitas ao usuário no momento mais apropriado (e.g., quando o usuário está dormindo ou no local de trabalho). *SituMan* [62, 63] é uma solução proposta para enfrentar essa limitação. Ele fornece conhecimento da situação para um aplicativo móvel EMA/EMI usado para solicitar autoavaliações de pacientes em tratamentos de depressão. *SituMan* possui um mecanismo de inferência difusa desenvolvido para identificar situações de rotina diária do usuário (por exemplo, “estudar”, “trabalhar”, “atividade física”) usando informações de contexto obtidas de sensores de dispositivos móveis. As situações são especificadas em conjunto pelo paciente e pelo profissional de saúde mental e representam a rotina diária do paciente. Aproveitando a conscientização da situação fornecida pelo *SituMan*, o aplicativo EMA/EMI pode solicitar autoavaliações do estado mental dos pacientes em momentos adequados.

2.2 Fenotipagem digital

A EMA depende das informações autorrelatadas pelo paciente, apresentando algumas limitações que podem influenciar a eficiência do monitoramento do estado mental. Portanto, é necessário desenvolver abordagens de monitoramento que possam coletar marcadores comportamentais passivamente, removendo as restrições apresentadas por possíveis autorrelatos tendenciosos. A onipresente adoção dos dispositivos ubíquos, incluindo *smartphones* e *tablets*, pode permitir oportunidades mais eficientes para rastrear o estado de saúde mental e os distúrbios mentais, como a fenotipagem digital, um termo definido por Torous et al. [65] que refere-se à quantificação momento a momento do fenótipo humano em nível individual in situ usando dados de *smartphones* e outros dispositivos digitais pessoais.

Embora a EMA se baseie em descrições estáticas autorrelatadas de emoções e comportamentos, o objetivo da fenotipagem digital não é apenas implementar

recursos para solicitar autoavaliações, mas coletar e analisar grandes quantidades de diferentes tipos de informações sociais e comportamentais que representam experiências dos usuários e suas interações com pessoas e lugares. A ideia por trás da fenotipagem digital já foi considerada útil, explorando novas dimensões da patologia praticamente inacessíveis alguns anos antes e permitindo descobertas de pesquisas e avanços clínicos [64]. Além disso, os resultados de um estudo experimental realizado com indivíduos esquizofrênicos que usaram uma ferramenta de fenotipagem digital baseada em *smartphone* sugeriram que os padrões de uso de aplicativos móveis podem conter informações clinicamente relevantes e potencialmente preditivas sobre futuros estados de transtornos mentais [66]

2.3 Computação Positiva

O termo Computação Positiva foi criado por Calvo e Peters [17]. É uma mudança de paradigma que defende o “design e desenvolvimento de tecnologia para apoiar o bem-estar psicológico e o potencial humano” [17]. A noção de computação positiva surgiu da necessidade de enfrentar os efeitos negativos do ônus do uso de alguns tipos de tecnologia, que incluem, por exemplo, o estresse causado por notificações excessivas e o sentimento de perda de privacidade. Portanto, soluções computacionais positivas são desenvolvidas para promover o bem-estar mental e ajudar a tornar realidade todas as potencialidades humanas, respeitando as necessidades psicológicas dos indivíduos. Além disso, eles são concebidos para melhorar a eficiência e a eficácia dos trabalhadores do conhecimento.

A computação ubíqua e as tecnologias da *Internet das Coisas* (IoT) contribuíram para promover a computação positiva inteligente [44]. Alguns benefícios de soluções que usam esse paradigma incluem a facilitação de novas maneiras de detectar mudanças no comportamento humano que podem indicar problemas de bem-estar ou o início de transtornos mentais, fornecer intervenções terapêuticas oportunas e possibilitar o rastreamento de respostas para avaliar a eficácia das intervenções [44].

2.4 Relações Sociais

As consequências dos transtornos mentais resultam em um conjunto de mudanças comportamentais, as quais podem fornecer indicadores relevantes para detectar sintomas de transtornos mentais. Os comportamentos sociais podem revelar algumas situações de interesse, como o isolamento social, frequência de interações sociais físicas e virtuais, laços sociais, dentre outros indicadores. A partir da consciência dessas situações, os profissionais da saúde mental podem realizar intervenções mais efetivas, como aconselhar o paciente a socializar logo que reconhecer situações de isolamento social ou propor atividades que incentivem o contato social

Os sensores embutidos nos dispositivos ubíquos (e.g., acelerômetro, microfone, pedômetro, e sensores de localização) fornecem dados capazes de caracterizar situações sociais, permitindo assim o desenvolvimento de sistemas capazes de automatizar o processo de monitoramento do comportamento social. Esses sistemas usam dados coletados dos sensores para identificar situações sociais, nas quais são utilizadas técnicas estatísticas, mineração de dados, aprendizado de máquina, dentre outros métodos de análise e processamento de dados. Por exemplo, os registros de uso do *smartphone* podem ser usados para inferir laços sociais (e.g., amigos, familiares, colegas de trabalho) [49], enquanto tecnologias como *Bluetooth* e *Near Field Communication* (NFC) podem indicar proximidade e co-localização [18, 48]. A Figura 2.1 apresenta uma visão geral da utilização dos sensores embutidos nos dispositivos ubíquos para inferir situações sociais (i.e., encontros face a face e comunicação mediada por dispositivos).

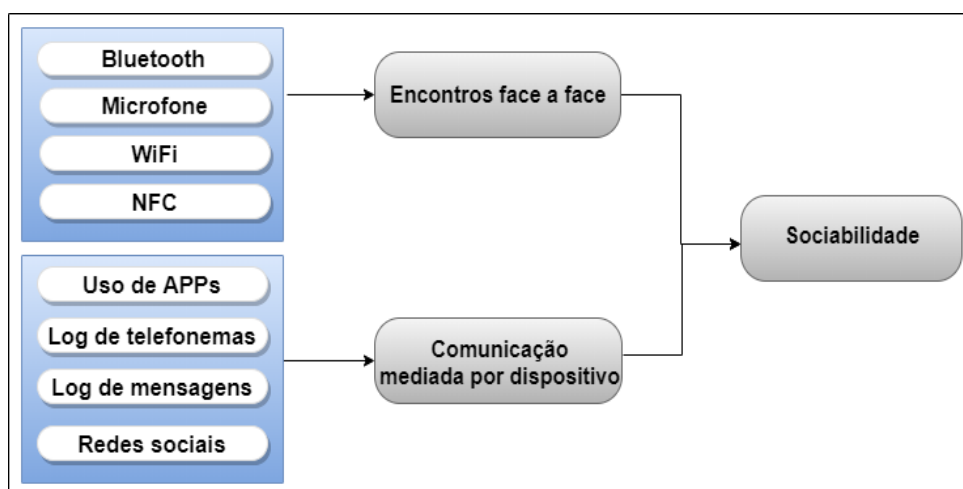


Figura 2.1: Detecção de situações sociais através dos dispositivos ubíquos.

Nas subseções a seguir, descrevemos como essas tecnologias podem ser usadas para identificar situações sociais relevantes para o monitoramento da saúde mental.

2.4.1 Encontros Face a Face

Encontros face a face denotam interações físicas, nas quais não há presença de uma tecnologia mediadora. Esses encontros são identificados quando os indivíduos envolvidos estão fisicamente no mesmo espaço (i.e., em distâncias curtas) e interagindo entre si. Os dispositivos que compõem a computação ubíqua (e.g., dispositivos móveis e vestíveis) possuem sensores capazes de caracterizar essas situações, fornecendo meios de quantificar as relações sociais. A maioria desses dispositivos possuem microfones e tecnologias de comunicação sem fio (e.g., *WiFi*, *Bluetooth* e *NFC*), que podem ser usadas para identificar proximidade e conversação [72]. A Figura 2.2 apresenta o cenário de detecção de interação face a face entre dois indivíduos, onde a descoberta de dispositivos usando tecnologias sem fio e a ativação do microfone identificam a co-localização e a ocorrência da conversa, respectivamente.




Figura 2.2: Detecção de co-localização e conversação entre indivíduos.

As interfaces de comunicação sem fio são comumente usadas para reconhecer interações físicas experimentadas por indivíduos [23,52]. Estas interfaces possuem a capacidade de identificar dispositivos próximo, vindo a funcionar como um indicador de interações sociais. Portanto, os pesquisadores utilizaram esta tecnologia para caracterizar a sociabilidade do indivíduo monitorado através do registro dos identificadores dos dispositivos encontrados (e.g., IDs de *Bluetooth*), permitindo realizar análises adicionais para identificar correlações com o estado mental e extrair características sociais apropriadas para classificar e prever estados mentais. Por exemplo, os pesquisadores correlacionaram características sociais derivadas da percepção de encontros físicos (e.g., usando o *Bluetooth* como sensor de proximidade) com distúrbios mentais como depressão [72] e níveis de estresse [76].

O uso das interfaces de comunicação sem fio como indicador de interações sociais apresenta algumas limitações que podem resultar em baixo desempenho. Por exemplo, existe o risco de um dispositivo descoberto pela interface *Bluetooth* não representar uma pessoa (e.g., pode ser uma *smart tv* ou uma impressora) ou o indivíduo pode transportar mais de um dispositivo. Outro fator limitante é o alcance de detecção dessas tecnologias, pois os rádios *Bluetooth* têm um alcance estimado de até 10 metros, enquanto os sinais *WiFi* cobrem uma área média de 32 metros em ambientes internos [55]. Portanto, a distância interpessoal pode não ser reconhecida com precisão e pode não identificar o número correto de pessoas socialmente co-presentes. Para mitigar essa limitação, Carreras et al. [18] aplicaram um algoritmo de aprendizado de máquina para estimar a distância interpessoal, na qual 20 amostras de *WiFi Received Signal Strength Indicator* (RSSI) foram usadas para treinar o modelo proposto. Este método foi capaz de detectar interação social com um erro médio de 0,5 metros, apresentando uma metodologia viável para detecção de co-localização.

Os microfones embutidos nos dispositivos ubíquos também foram explorados para reconhecer interações sociais face a face. Os pesquisadores utilizaram algoritmos de aprendizado de máquina (e.g., Modelo Oculto de Markov e Modelo de Mistura de Gaussianas) para identificar a voz humana em amostras de áudio. Normalmente, os fluxos de áudio são segmentados em quadros, os quais são usados para conceber características adequadas para desenvolver modelos de aprendizado de máquina capazes de reconhecer a fala de um indivíduo. Essa conscientização

da situação social tem sido usada para inferir o engajamento social, bem como para identificar evidências de isolamento social. [1,36,43,72]

A extração de pistas comportamentais contidas nas vozes dos usuários durante as interações sociais também foram exploradas para avaliar objetivamente a saúde mental [21], pois várias mudanças cognitivas, afetivas e fisiológicas podem refletir na fala. As soluções propostas processaram o áudio do microfone para extrair e analisar as características paralinguísticas (i.e., sinais vocais não verbais) apresentadas na voz durante as interações sociais [19, 34]. Essas características representam componentes como intensidade do som, velocidade da fala e dinâmica energética. Assim, pesquisadores associaram essas características a estados mentais, como autismo [19] e ansiedade [34].

O uso do microfone apresenta alguns fatores que podem limitar a identificação de interações sociais, solicitando cuidados específicos para preservar a eficiência dos métodos propostos. Algoritmos usados para reconhecer conversas podem ter dificuldade em distinguir a voz humana de outros sons, como conversas derivadas da televisão e do rádio. Outra preocupação que os estudos devem ter é com relação à privacidade dos indivíduos, pois métodos capazes de processar dados de microfones podem revelar o conteúdo da fala, tornando-a excessivamente invasiva. Assim, os métodos devem extrair apenas características que não permitam a reconstrução do conteúdo da fala e impossibilitar a identificação do falante, a fim de preservar a privacidade dos usuários.

2.4.2 Comunicação Mediada por Dispositivo

A comunicação mediada por dispositivo é uma interação social que ocorre por meio da tecnologia, como dispositivos móveis e vestíveis ou através das redes sociais online. Os eventos sociais que ocorrem nessas mídias permitem o registro de informações valiosas para monitorar o comportamento social. Por exemplo, registros de chamadas telefônicas e aplicativos sociais (e.g., SMS, E-mail, *WhatsApp*, *Facebook*, *Twitter*) podem identificar características como vínculos sociais, suporte social, frequência de interações sociais, entre outros aspectos [49, 74]. Assim, as abordagens computacionais podem usar essa rica fonte de dados comportamentais

para identificar características da sociabilidade dos indivíduos, representando uma ferramenta valiosa para o processo de monitoramento da saúde mental.

O alto fluxo de atividades sociais derivadas das comunicações mediadas por dispositivo apresenta um ambiente adequado para identificar comportamentos sociais significativos. Por esse motivo, soluções exploraram os registros de interações sociais vividas através dos dispositivos ubíquos para detectar a sociabilidade dos indivíduos. A maioria dos estudos desenvolveu maneiras de quantificar a sociabilidade do usuário a partir de registros de chamadas e mensagens de texto. As soluções presentes na literatura geralmente projetam características (e.g., número de chamadas, duração das chamadas, contatos exclusivos e número de mensagens enviadas) para caracterizar o comportamento social dos indivíduos. Além disso, as soluções usam essa caracterização para desenvolver modelos capazes de classificar e prever estados mentais [8,9,57,59,70], associar o comportamento social ao estado mental [16,31,59] e quantificar a sociabilidade [15,24].

As redes sociais online, como *Twitter*, *Facebook* e *Instagram*, são cada vez mais indispensáveis para alcançar a conexão social. Nessas plataformas online, as pessoas realizam diferentes tipos de atividades, como criar e compartilhar status, publicar fotos e vídeos, estabelecer novas amizades, trocar mensagens com amigos, dentre outros eventos sociais. A partir dessas ações, os usuários expressam seus sentimentos e pensamentos, além de expor informações sobre sua rotina diária. Dessa forma, a dinâmica dos usuários nas redes sociais online produz um fluxo de dados comportamentais, o que representa um perfil da prática social desse indivíduo.

Nos últimos anos, os pesquisadores reconheceram as plataformas sociais online como fontes valiosas de dados de saúde e indicadores comportamentais [74]. O caráter público e o alto fluxo de atividades sociais dessas plataformas apresentam um ambiente adequado para a identificação de comportamentos sociais significativos. Em particular, o campo dos cuidados de saúde mental pode tirar proveito dessas informações comportamentais para identificar possíveis indicadores de transtornos mentais (e.g., tipo de status compartilhado, publicações com sentimentos negativos, formação de amizades) [74]. Com base nestes indicadores, é possível usar uma ampla gama de técnicas, como mineração de dados, aprendizado de máquina e CEP para identificar problemas de saúde mental. Por exemplo, técnicas podem ser usadas para realizar a análise de sentimentos, identificar ações e padrões significativos de

atividades sociais nessas plataformas, vindo a atuar como um indicador de mudança comportamental.

2.5 Processamento de Eventos Complexos

Atualmente, os dispositivos ubíquos e redes de sensores são responsáveis por coletar continuamente um grande volume de dados, vindo a evidenciar a necessidade de analisar e reagir em tempo real a este crescente fluxo de dados. Para mitigar esse desafio, é possível utilizar o CEP [26], que fornece um conjunto de ferramentas para processar fluxos de dados de maneira eficiente, realizando tarefas como agregação de dados, derivação de informações de alto nível e reconhecimento de padrões. O CEP utiliza o paradigma de processamento orientado a evento, no qual cada evento modela uma observação em um domínio específico, que pode ser resultante da ação ou mudança de estado de objetos físicos ou virtuais. Neste cenário, o CEP processa eventos primitivos para detectar relacionamentos de temporalidade, causalidade e semânticos entre estes, derivando eventos complexos (i.e., compostos) para criar um novo fluxo ou emitir um alerta para o usuário. A arquitetura geral de um mecanismo CEP é mostrada na Figura 2.3, a qual segue as seguintes etapas básicas [26]:

1. Eventos são criados por diferentes fontes (e.g., sensores, web e aplicações clientes), que são responsáveis por gerar um fluxo de entrada para o mecanismo CEP.
2. Especialistas da área de aplicação do sistema especificam as regras e padrões que serão instanciados no mecanismo CEP. O mecanismo processa o fluxo de eventos, emitindo eventos derivados sempre que as regras e padrões forem satisfeitos.
3. Consumidores recebem os eventos derivados, vindo a engatilhar alertas e executar ações de maneira automática.

Tendo em vista as características do CEP, o mecanismo proposto por este estudo o explora para implementar uma abordagem de detecção de padrões de sociabilidade, comportamentos sociais anormais e mudanças de rotinas sociais. Para tanto, foi utilizado o *Esper* [25], pois este é um motor CEP que atende as necessidade de processamento online e incremental requisitada pela solução proposta, além de ser

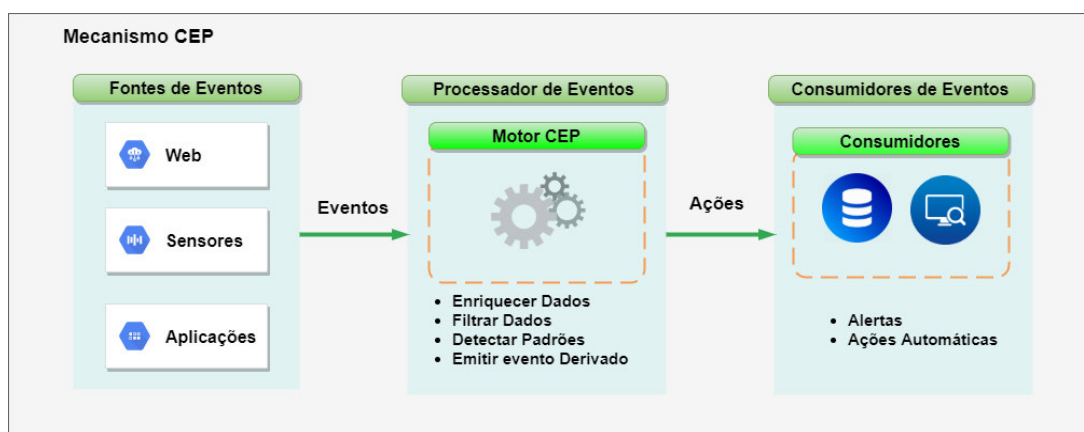


Figura 2.3: Visão geral de um mecanismo CEP.

um projeto de código aberto. Este motor CEP é baseado em cláusulas do tipo *Evento-Condição-Ação* (ECA), a qual especifica que o motor CEP analisa condições no fluxo de dados e, caso satisfeita, uma ação é acionada [71]. A instanciação dessas condições é realizada através de consultas CEP, as quais são descritas através de uma linguagem declarativa denominada *Linguagem de Processamento de Eventos* (EPL), que implementa e estende os operadores do *Structured Query Language* (SQL). Através desta linguagem de consulta, é possível extrair padrões de relacionamentos entre eventos, aplicar filtros, efetuar agregações e realizar cálculos de funções sobre conjuntos de eventos tais como: médias, máximos, mínimos e contagem. Assim, a expressividade desta linguagem permite realizar consultas complexas no fluxo de eventos, tornando-a adequada para tarefas que requisitem respostas em tempo real e processamento incremental.

2.5.1 Agentes de Processamento de Eventos e Rede de Processamento de Eventos

Na área de sistemas distribuídos, os fluxos de eventos gerados podem apresentar estruturas (sintaxe) e/ou significados (semântica) incompatíveis com os consumidores [45]. Em outros casos, o processamento de apenas um evento primitivo não é suficiente para desencadear uma ação no consumidor de eventos, necessitando de uma combinação complexa de eventos [45]. Assim, é necessário utilizar os Agentes de Processamento de Eventos (EPA), que são módulos de software responsáveis por detectar padrões e realizar modificações no fluxo de dados. O fluxo básico de trabalho de um EPA é (i) receber eventos de entrada; (ii) realizar processamento sobre o fluxo

de entrada; e (iii) encaminhar ou derivar novos eventos. O tipo de um EPA é definido através de suas regras instanciadas, sendo classificado da seguinte forma [26]:

- **Agentes de filtragem:** eliminam eventos que não satisfazem uma determinada condição.
- **Agentes de detecção de padrões:** examinam o fluxo para detectar a ocorrência de padrões específicos.
- **Agentes de transformação:** modificam o conteúdo dos eventos processados.

Geralmente, as arquiteturas dos sistemas CEPs são compostas por uma Rede de Processamento de Eventos (EPN), que é uma representação conceitual da interconexão de um conjunto de EPAs, as quais são responsáveis pela análise e manipulação do fluxo de eventos [45]. Assim, uma EPN pode ser definida como a representação do comportamento do mecanismo de processamento, definindo conceitualmente a conexão entre o conjunto de agentes de processamento, produtores e consumidores. Portanto, em uma EPN, os eventos derivados produzido por uma EPA podem criar um novo fluxo de eventos de entrada para outras EPAs, que por sua vez, poderá realizar processamentos adicionais.

2.5.2 Contexto e Partições de Contexto

O *Esper* também fornece o conceito de contextos [25], que permite agrupar um conjunto de eventos que estão relacionados a um determinado grupo, vindo a segmentar o fluxo em uma ou mais partições de contexto. Portanto, as operações de processamento de eventos são associadas a contextos específicos, operando em cada uma dessas partições independentemente [26]. As partições de contexto podem ser definidas como um subconjunto de eventos relacionados, em que a atribuição de eventos a partições de contextos é realizada com base em suas propriedades (e.g., lógico, espacial e temporal). Por exemplo, em um cenário de monitoramento do comportamento humano, cada pessoa pode ser considerada um contexto, no qual as regras de agregações, padrões ou janelas de dados são específicas do indivíduo.

O contexto segmentado por categoria é um conceito fornecido pelo *Esper* que permite agrupar instâncias de eventos em partições de contexto com base no valor

de um atributo ou coleção de atributos [25], isto é, utiliza uma expressão de predicado para definir a associação do evento a partição de contexto. Portanto, cada evento pode pertencer a nenhuma, uma ou várias partições de contexto, de acordo com o resultado das expressões de predicado. Por exemplo, considere um EPA que recebe um fluxo de eventos de atividades de um usuário, no qual cada evento contém o atributo dia da semana (e.g., segunda, terça, domingo, dentre outros). O valor desse atributo pode ser usado como predicado para agrupar eventos de tal forma que haja uma partição separada para cada dia. Cada partição de contexto contém eventos relacionados a um dia da semana, para que o comportamento do indivíduo seja modelado independente dos outros dias.

2.5.3 Janela de Tempo

O Motor CEP *Esper* também fornece o conceito de janelas de tempo, que é definido como um contexto temporal [26] que subdivide o fluxo de eventos em intervalos, aplicando as regras e operadores apenas a eventos contidos nesse espaço de tempo. Por exemplo, se definirmos uma regra com janela de tempo de 20 segundos, é criada automaticamente uma partição de contexto que agrupará os últimos eventos que ocorreram nesse intervalo, aplicando os operadores definidos a este grupo de eventos.

Existem alguns tipos de janelas de tempo que podem ser utilizadas, como as janelas *Landmark* e *Sliding*. Especificamente, estas janelas diferem no modo de manter os eventos mais atuais agrupados. A janela do tipo *Landmark* utiliza uma estratégia de processamento em lote, mantendo agrupado todos os eventos que ocorreram durante um intervalo de tempo t , aplicando as regras e operadores neste conjunto de eventos. Outro tipo de janela é a *Sliding*, que move uma janela de referência no decorrer do processamento do fluxo, ou seja, permite especificar regras que serão aplicadas apenas aos eventos que ocorreram nas últimas unidades de tempo t . Este conceito de janelamento de dados é importante para processamento de fluxos de dados, uma vez que oferece suporte ao processamento contínuo do fluxo de dados mais recente.

2.5.4 Tabela Nomeada

A tabela nomeada é uma estrutura de dados fornecida pelo motor CEP *Esper*, que possui um escopo global e consegue manter estado. As colunas dessa estrutura possuem a capacidade de reter o estado de agregação de um determinado atributo, permitindo manter na mesma estrutura os dados do evento e seu estado de agregação [25]. Por exemplo, cada coluna dessa estrutura pode manter estatística sobre um determinado tipo de evento (e.g., média, mínimo, máximo, mediana e contagem). Esta estrutura é globalmente visível dentro da EPN, permitindo diversas instruções consultar, criar e atualizar diretamente o estado de agregação. Portanto, esta estrutura é um importante conceito que oferece suporte para compartilhar estado entre instruções.

2.6 Mineração de Padrões Frequentes

A Mineração de Padrões Frequentes foi proposta por Agrawal et al. [3] para conceber uma abordagem capaz de realizar a análise da cesta de compra de clientes através da mineração de regras de associação. Esta abordagem mapeia os hábitos de compra de clientes, vindo a identificar as associações entre os produtos adicionados as cestas de compra. Logo, através desta metodologia foi possível identificar a probabilidade de os clientes comprarem certos tipos de produtos em conjunto. Posteriormente, esta solução deu origem a vários algoritmos que seguem esta lógica [2], sendo aplicado em diversos domínios.

Especificamente, esta abordagem objetiva descobrir padrões que ocorrem com uma frequência significativa em diferentes tipos de coleção de dados, como banco de dados relacionais e não relacionais, arquivos de texto e até fluxos de dados. Nesta abordagem, técnicas computacionais concentram-se em encontrar conjuntos de itens, subestruturas, sequência de itens, dentre outras estruturas que se repetem em uma quantidade suficiente para representar um padrão [35]. Por exemplo, se um conjunto de itens aparecem juntos em transações com quantidade superior a um limiar de suporte, então esta estrutura é um padrão frequente. Esta abordagem não objetiva apenas descobrir estruturas, mas também fornece as características dos dados processados, funcionando como uma ferramenta para muitos tipos de tarefas no

domínio de mineração de dados, como tarefas de clusterização, classificação, predição e associação [6, 12, 38].

Atualmente, a FPM tem sido explorada para minerar fluxos de dados contínuos, reconhecendo padrões frequentes de forma online e incremental [51]. Neste cenário, as soluções são capazes de detectar padrões continuamente, reconhecendo em tempo real estruturas frequentes, assim como quando estas estruturas não são consideradas mais padrões. Em geral, os algoritmos que exploram a FPM para processar fluxo de dados realizam apenas uma passagem sobre os dados [42], podendo manter apenas o resumo do fluxo processado ou utilizar janelamento para manter os padrões frequentes associados aos dados mais recentes.

2.7 Concept Drift

Comumente, os modelos de aprendizado de máquina consideram que os dados processados são derivados de fontes estacionárias, ou seja, a distribuição dos dados produzidos são constantes [4]. Desta forma, os modelos de aprendizagem são treinados com um conjunto de dados históricos para aprender padrões, partindo do pressuposto que estes dados refletem a realidade. Entretanto, em muitas aplicações do mundo real, esta premissa não é verdadeira, pois a distribuição dos dados pode variar no decorrer do tempo, implicando em baixo desempenho dos modelos que foram treinados utilizando dados históricos que não refletem a nova realidade. Por exemplo, um sistema que utilizou o histórico de consumo de um usuário para aprender padrões pode se tornar ineficiente quando o interesse do indivíduo mudar.

Este fenômeno de mudança na distribuição dos dados devido a dinamicidade dos ambientes é denominado *Concept Drift* [39], o qual cria a necessidade de projetar modelos de aprendizagem capazes de detectar e adaptar-se a mudanças em tempo real. Especificamente, os sistemas projetados devem implementar abordagens capazes de manter o modelo de aprendizagem eficiente mesmo estando inseridos em ambientes dinâmicos, necessitando tratar diversos tipos de *concept drift*. A Figura 2.4 apresenta os tipos de mudanças existentes [78], que podem ser definidos da seguinte forma:

- **Mudança abrupta:** o padrão contido no fluxo de dados muda de forma repentina, quando entre o momento t_0 e t_1 , o padrão muda subitamente de p_1 para p_2 .
- **Mudança gradual:** o padrão contido no fluxo de dados muda de forma gradual, quando entre o momento t_0 e t_1 , o padrão p_1 dá lugar a p_2 gradualmente, existindo momentos em que os dois padrões estão ativos.
- **Mudança incremental:** o padrão p_1 contido no fluxo de dados sofre pequenas mudanças no decorrer do tempo até representar totalmente o padrão p_2 .
- **Mudança recorrente:** o padrão anteriormente ativo volta a ser válido após algum tempo.




Figura 2.4: Tipos de *concept drift* [78].

Em geral, os modelos de aprendizado de máquina realizam a adaptação de maneira explícita ou implícita [39]. Na abordagem de adaptação explícita, objetiva-se identificar o momento exato ou aproximado da mudança, vindo a retreinar o modelo a partir do conjunto de dados que representa a nova distribuição. Na abordagem de detecção implícita, os mecanismos de adaptação buscam manter o modelo de aprendizagem sempre atualizado, ou seja, realizam o treinamento online a partir do fluxo de dados mais recente, partindo do pressuposto que este representa o estado atual da distribuição. No contexto deste estudo, foram exploradas as técnicas de adaptação explícitas, uma vez que estas são adequadas para reconhecer mudanças

da rotina social e permitem modelar o novo comportamento social do paciente monitorado.

Geralmente, a detecção do *concept drift* é realizada através de algoritmos que monitoram indicadores de desempenho (e.g., acurácia, sensibilidade, especificidade e *recall*) conforme o modelo processa as instâncias do fluxo de dados [78]. O algoritmo *Drift Detection Method* (DDM) [30] monitora a taxa de erro das predições do modelo para detectar a mudança no fluxo de dados. Assim, este algoritmo considera que o modelo classificará incorretamente as instâncias que são geradas por uma distribuição diferente da utilizada em seu treinamento, reconhecendo a mudança através do aumento significativo da taxa de erro. O algoritmo *Early Drift Detection Method* (EDDM) [7] foi projetado com base no DDM, porém, ao invés da taxa de erro, este algoritmo monitora a distância entre as classificações incorretas performada pelo modelo. Portanto, a mudança na distribuição é detectada quando a distância entre erros diminui no decorrer do processamento.

Em algumas aplicações a detecção do *concept drift* deve ser realizada através de métodos não supervisionados, uma vez que os rótulos da classe podem não estar disponíveis. Portanto, uma técnica viável de detecção de mudança neste contexto é particionar o fluxo em janelas de dados, vindo a reconhecer a mudança quando as estatísticas entre elas diferem significativamente. O algoritmo *Adaptive Windowing* (ADWIN) [13] utiliza uma janela deslizante que cresce enquanto não reconhece o *concept drift*, vindo a diminuí-la ao detectar a mudança. Para tanto, este algoritmo divide a janela deslizante em diferentes pontos, reconhecendo diferenças significativas entre as estatísticas das janelas avaliadas. Outra metodologia não supervisionada é monitorar a similaridade entre padrões e registros. Por exemplo, é possível analisar como a distribuição de dados evolui de um instante de tempo t_1 para t_2 , utilizando uma métrica de similaridade para esta avaliação.

2.8 Lógica Fuzzy

Em alguns domínios de aplicação, sistemas computacionais precisam realizar avaliações e decisões inerentemente humano de maneira automática, isto é, necessitam responder a tarefas de natureza imprecisa. Desta forma, as repostas

dos sistemas não representam conjuntos numéricos precisos, mas sim respostas com julgamento de grau de crença a diversos grupos de respostas possíveis [22]. Por exemplo, um sistema que calcula rotas entre duas localizações pode necessitar responder se o percurso é curto ou longo, em que dependendo da resposta, o usuário irá percorrê-lo de carro ou a pé. Neste exemplo, a tarefa de classificar o percurso como curto ou longo possui uma essência subjetiva e imprecisa, pois uma certa distância pode ser considerada perto para um indivíduo, ao passo que para outro é avaliada como longe. Portanto, para mitigar este desafio, desenvolveu-se a técnica de inteligência computacional denominada *Lógica Fuzzy* [77], que permite projetar modelos computacionais capazes de tratar certos níveis de incerteza. Através desta técnica, os sistemas são capazes de aproximar seu modelo de decisão e avaliação ao raciocínio humano, em vez de utilizar valores limítrofes rígidos.

Na *lógica fuzzy*, uma premissa pode implicar em várias conclusões com diferentes níveis de pertinência, isto é, um elemento pode estar contido parcialmente a um conjunto. Assim, o nível de pertinência de um elemento a um conjunto é definido por uma função $\mu(x)$, que resulta em valores contidos no intervalo $[0,1]$. Portanto, o nível de inclusão do elemento pode variar entre não pertinente (i.e., $\mu(x)=0$) até totalmente pertinente (i.e., $\mu(x)=1$). Por exemplo, para decidir se a velocidade de um veículo é baixa, média ou alta, um especialista poderia modelar este problema utilizando conjuntos *fuzzy* conforme ilustrado na Figura 2.5. Neste cenário, é possível observar que existe um certo nível de interseção entre os conjuntos, representando uma transição gradativa de pertinência. Por exemplo, o conjunto *Média* inicia com velocidade a partir de 10km (i.e., não incluso, pois $\mu(10)=0$), aumentando de maneira gradual até atingir 40km (i.e., totalmente incluso, pois $\mu(40)=1$), e depois o nível de pertinência decresce gradualmente conforme transita para o conjunto *Alta*.




Figura 2.5: Conjunto fuzzy para avaliar a velocidade de um veículo.

2.8.1 Sistemas de Inferência Fuzzy

Sistemas de Inferência Fuzzy (FIS) são modelos computacionais que objetivam representar incertezas e imprecisões através de regras, em vez de utilizar representações numéricas exatas [47]. Em FIS, o conhecimento do especialista é representado em forma de implicações lógicas, que possuem a estrutura básica se (condição) então (consequência). Os especialistas também podem usar os conectores lógicos *AND* e *OR* para representar conhecimentos mais complexos, validando assim estruturas como a seguinte: <condição> *AND* <condição> *THEN* <consequência>. Por exemplo, no cenário em que o sistema necessita decidir se o usuário deverá fazer um percurso a pé ou de carro com base nas variáveis distância e condição climática, o especialista poderia modelar a seguinte proposição: se (distância é longa) e (condição climática é ruim) então (percurso de carro). Através desta proposição, o FIS analisará as variáveis de entrada, que indicará percurso de carro nos casos de distâncias longas e climas ruins.

É importante destacar, que diferentemente da lógica clássica que define suas proposições como totalmente verdadeiras ou totalmente falsas, nos FIS as proposições assumem níveis de verdades, implicando em variáveis de saídas com diferentes graus de crenças. Portanto, quanto mais pertinentes as variáveis de entrada (e.g., distância e condição climática), maior será o grau de inclusão da variável de saída (e.g., percurso a pé ou de carro), viabilizando assim representar as incertezas inerente a tarefa proposta. A Figura 2.6 apresenta a arquitetura geral de um FIS [47], que é composto pelos seguintes componentes:

- **Processador de entrada (fuzzyfier):** Derivam dados nebulosos a partir da entrada de dados precisos.
- **Base de conhecimento:** contém as variáveis, os conjuntos fuzzy e as regras definidas pelos especialistas.
- **motor fuzzy:** processa as variáveis de entrada nebulosas com base nas regras definidas pelo especialista, vindo a realizar uma inferência de saída.
- **Processador de saída (defuzzifier):** deriva um dado preciso a partir da saída do motor *fuzzy*.

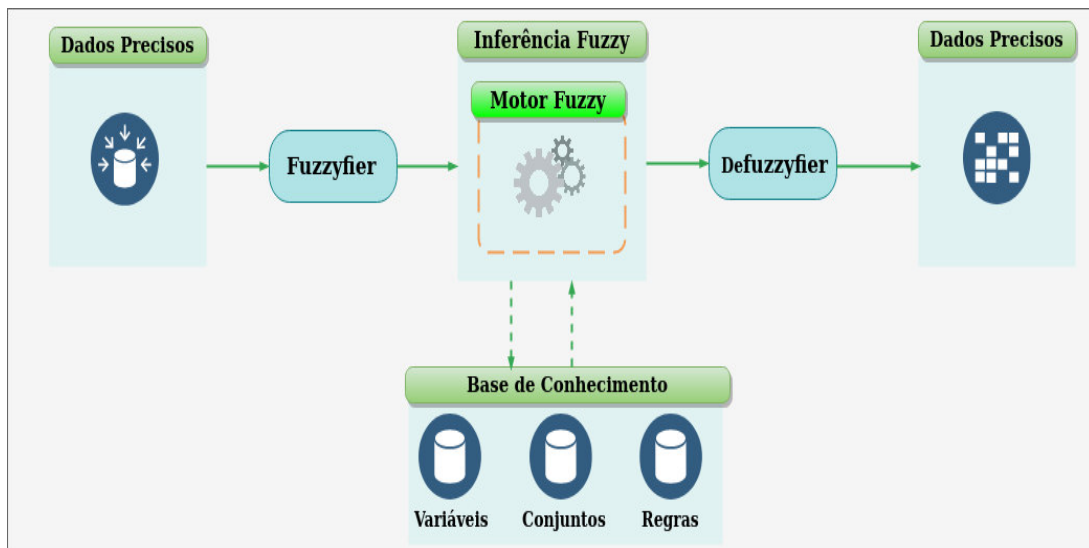


Figura 2.6: Arquitetura de um sistema fuzzy.

Portanto, esta maneira de modelar a subjetividade humana é aplicável a várias áreas que necessitam representar o conhecimento impreciso, como sistemas especialistas e sistemas de apoio à decisão. Este estudo utiliza esta técnica para modelar a avaliação subjetiva do especialista de saúde mental, aproveitando esta técnica na abordagem proposta de detecção de comportamentos anormais e mudanças de rotinas sociais.

2.9 Discussões

Esse capítulo apresentou um breve fundamental teórico, abordando tópicos sobre a aplicação das tecnologias ubíquas no monitoramento da saúde mental e expondo conceitos sobre EMA, EMI, fenotipagem digital e computação positiva. Neste capítulo, também foi apresentado a utilização dos sensores embutidos nos dispositivos ubíquos para reconhecer situações sociais, discutindo a aplicação desta consciência no monitoramento da saúde mental. Por fim, apresentou-se conceitos sobre as tecnologias utilizadas para desenvolver a solução proposta, elucidando as características do CEP, FPM, *concept drift* e *lógica fuzzy*.

3 Trabalhos Relacionados

Para caracterizar o estado da arte da pesquisa e os principais trabalhos relacionados ao monitoramento da saúde mental através da conscientização da situação social, foi realizada uma revisão sistemática da literatura. Este capítulo apresenta inicialmente a metodologia utilizada para a condução da presente revisão. Em seguida, esclarecemos as questões fundamentais sobre este tema de pesquisa e reconhecemos questões em aberto, bem como as oportunidades de pesquisas. Ao final do capítulo apresentam-se as discussões.

3.1 Metodologia de Pesquisa

A RSL é um método que fornece meios para identificar, avaliar e interpretar o estado da arte sobre uma questão de pesquisa de interesse [41]. Esses métodos sistemáticos utilizados para selecionar, avaliar, coletar e analisar pesquisas relevantes precisam seguir procedimentos validados presentes na literatura para aumentar a integridade da revisão realizada e permitir que outros pesquisadores reproduzam o método adotado. Assim, este estudo foi realizado com base nas diretrizes de revisão sistemática da literatura de engenharia de software proposta por Kitchenham e Charters [40, 41]. Essa RSL foi realizada de acordo com três fases principais: planejamento, execução e análise de resultados. A realização dessas fases foi gerenciada por meio do *Parsifal*¹, uma ferramenta de suporte online para executar RSLs no contexto da Engenharia de Software, que documenta os processos executados e fornece suporte aos pesquisadores por meio de um espaço de trabalho compartilhado. Nesta seção, apresentamos o protocolo de revisão adotado, que definiu objetivos, questões de pesquisa, estratégia de pesquisa, critérios de seleção e extração de dados.

¹<https://parsif.al/>

3.1.1 Objetivo e Questões de Pesquisa

Esta revisão sistemática tem como objetivo identificar o estado da arte sobre o uso de dispositivos ubíquos como instrumento para reconhecer situações sociais aplicadas ao domínio da saúde mental. Para isso, definimos as seguintes questões de pesquisa (RQ):

- (RQ1) Quais as características da literatura revisada?
- (RQ2) Como a conscientização da situação social é usada para apoiar o monitoramento da saúde mental?
- (RQ3) Quais são as questões em aberto existentes e as oportunidades de pesquisa?

3.1.2 Estratégia de pesquisa

Uma pesquisa exaustiva dos estudos primários foi realizada em 24 de maio de 2019, nas seguintes bibliotecas digitais: Science Direct, PubMed, Scopus, ACM Digital Library, Web of Science e IEEE Xplore. A busca teve como objetivo recuperar estudos que apresentassem métodos que pudessem reconhecer situações sociais por meio de dispositivos ubíquos, cujo objetivo principal era monitorar a saúde mental. Para maximizar os resultados, definimos a string de busca a partir de três termos principais, cada um deles consistindo em um conjunto de palavras-chave e seus sinônimos. As palavras-chave e seus sinônimos são mostrados na Tabela 3.1. O primeiro termo (A) refere-se ao domínio social, que abrange palavras-chave que expressam o significado das relações sociais; o segundo termo (B) especifica que o domínio social deve estar relacionado à saúde mental; e o terceiro termo (C) define palavras-chave relacionadas à *Mobile health* e aos dispositivos ubíquos.

A partir das palavras-chave especificadas, uma string de pesquisa foi construída para selecionar todos os estudos que reconheceram situações sociais por meio de dispositivos ubíquos e que utilizaram essa conscientização para investigar e desenvolver novos métodos para o monitoramento da saúde mental e, portanto, apoiar os profissionais da saúde mental. Esta revisão incluiu estudos publicados a partir de 2011. Para otimizar os resultados, aplicamos a string de pesquisa apenas

Tabela 3.1: Palavras-chave e seus sinônimos.

Term	Keywords	Synonyms
A	"Sociability"	"Social Interaction", "Social Behavior", "Social Isolation", "Social Contact", "Social Communication"
B	"Mental Health"	"Mental Disorder", "Mental State", "Mental Illnesses", "Psychological health"
C	"Mobile Health"	"Ubiquitous Device", "Mobile Device", "Mobile Health", "mHealth", "M-Health", "Smartphone", "Smart Phone", "Smart-Phone", "Wearable"

nos metadados (i.e., título, resumo e palavras-chave) das publicações nas bibliotecas digitais, refinando os resultados encontrados. A estrutura geral da string de pesquisa definida foi a seguinte:

```
<<(("Sociability" OR "Social Interaction*" OR "Social Behavior*" OR "Social Isolation" OR "Social Contact" OR "Social Communication") AND ("Mental Health" OR "Mental Disorder" OR "Mental State" OR "Mental Illnesses" OR "Psychological health") AND ("Ubiquitous Device*" OR "Mobile Device*" OR "Mobile Health" OR "mHealth" OR "M-Health" OR "Smartphone*" OR "Smart Phone" OR "Smart-Phone" OR "Wearable'))>>
```

No final, usamos a ferramenta online *Parsifal* para realizar a remoção de estudos duplicados, o qual executa essa tarefa automaticamente. Além disso, foi verificado manualmente se esse processo foi realizado corretamente.

3.1.3 Critérios de Seleção

A etapa de seleção consistiu na análise dos estudos encontrados na pesquisa executada nas bibliotecas digitais para definir quais se enquadram no escopo desta RSL. Para tanto, foram considerados os seguintes critérios de inclusão: (1) trabalhos escritos em inglês; (2) trabalhos publicados entre 2011 e 2019; (3) estudos que usaram dispositivos ubíquos para desenvolver novas metodologias de monitoramento da saúde mental; (4) estudos que propuseram métodos capazes de reconhecer o comportamento social dos indivíduos por meio de dados de sensores físicos e

virtuais conectados ou embutidos nos dispositivos; (5) trabalhos que utilizavam a conscientização da situação social para monitorar a saúde mental.

Para descartar estudos que não são relevantes para esta RSL, os seguintes critérios de exclusão foram definidos: (1) tipo de publicação, com a eliminação de materiais como resenhas, relatórios, resumos, pôsteres, breves relatos, livros, livros didáticos, teses e dissertações, cartas editoriais, comunicações breves, comentários e documentos de trabalho não publicados ; (2) artigos que não foram escritos em inglês; (3) estudos com texto indisponível na íntegra; (4) estudos que não abordaram o tópico da computação ubíqua aplicada ao monitoramento da saúde mental; (5) estudos que não apresentaram métodos capazes de identificar comportamentos sociais; (6) estudos que não usaram dados ou registros de sensores de dispositivos ubíquos para identificar situações sociais; (8) artigos que possuem outras publicações com uma versão mais atual e completa da solução proposta.

3.1.4 Extração de Dados

O processo de extração de dados visa identificar informações relevantes dos estudos selecionados [41]. Assim, após as etapas de seleção, passamos à fase de extração de dados. Nesta etapa, foi realizada a leitura completa dos estudos. Um formulário de extração de dados foi preparado para realizar este processo. Os campos deste formulário são itens que visam extrair e sintetizar o conhecimento apresentado pelos estudos. A tabela 3.2 apresenta os itens usados para extração de dados:

Tabela 3.2: Itens usados no processo de extração de dados.

ID	Questões
I1	Referência (autores e ano)
I2	Estado mental investigado
I3	Objetivo do estudo
I4	Dados de contexto usados para modelar a situação social
I5	Método, técnica ou processo usado para identificar situações sociais
I6	Uso da consciência da situação social no monitoramento da saúde mental
I7	Duração do estudo
I8	Tipo e quantidade de participantes
I9	Resultados e Limitações do Estudo

A leitura completa dos estudos e a aplicação do formulário projetado permitiram registrar informações abrangentes dos estudos selecionados, o que possibilitou extrair respostas para as questões de pesquisa consideradas por esta revisão.

3.2 Condução da RSL

A Figura 3.1 mostra os resultados dos processos de pesquisa e seleção de estudos. Aplicando a string de busca nas bibliotecas digitais, foram identificados 160 artigos. Em seguida, foi realizado o processo de remoção de trabalhos duplicados, resultando em 122 estudos identificados para o processo de seleção. Nesse processo, os critérios de inclusão e exclusão foram aplicados para a triagem dos artigos relevantes. Assim, foram realizadas a avaliação do título e do resumo, resultando em 22 estudos selecionados. Ao ler o texto completo para reconhecer sua adequação a esta SLR, 20 artigos atenderam a todos os critérios de seleção. Portanto, no final, os 20 artigos que atendiam aos critérios de seleção foram eleitos para o processo de extração de dados.

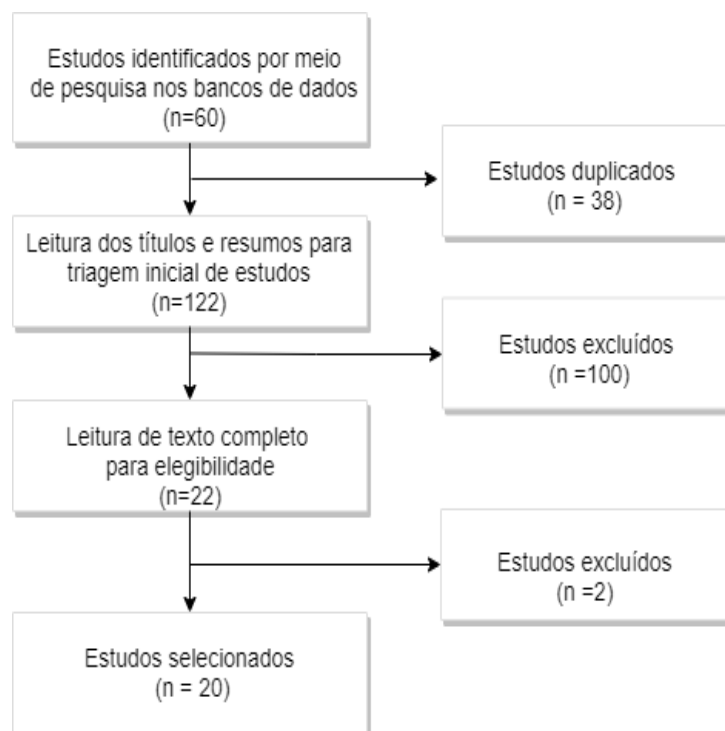


Figura 3.1: Diagrama do processo de revisão da literatura.

3.3 Resultados da RSL

As soluções apresentadas nos estudos revisados utilizaram a conscientização da situação social para desenvolver ferramentas promissoras para os profissionais da saúde mental. No entanto, as soluções propostas diferem em seus objetivos principais, usando a detecção de situações sociais para diferentes fins. Assim, classificamos os estudos com base em seus objetivos principais, ou seja, estudos de detecção e quantificação de sociabilidade e aqueles que visam classificar, prever e associar o comportamento social identificado ao estado mental. A tabela 3.3 apresenta o uso da consciência da situação social realizada por cada estudo revisado. Assim, embora esses modelos tenham objetivos diferentes, eles compartilham o objetivo de fornecer novos métodos de avaliação e monitoramento da saúde mental por meio dos dispositivos ubíquos.

Tabela 3.3: Usos da conscientização da situação social.

Tipo do Estudo	Objetivo	Referências
Detecção	Detectar e quantificar a sociabilidade.	[15,24,27,36,43,70]
Classificação	Classificar um estado mental através de características sociais.	[1,19,34,57,59,70,76]
Predição	Predizer um estado mental através de características sociais.	[1,8,9,76]
Associação	Associar sociabilidade a um estado mental.	[16,20,31,46,53,59,72,76]

3.3.1 Detectar e Quantificar a Sociabilidade

Algumas soluções focaram na detecção de atividades sociais por meio dos dispositivos ubíquos para reconhecer informações relevantes sobre o comportamento social dos indivíduos, como padrões de sociabilidade e isolamento social. Exler et al. [27] desenvolveram um modelo de classificação capaz de identificar se um indivíduo está sozinho ou acompanhado com uma precisão de 91,1%. Esse modelo realiza esta classificação com base na localização, hora do dia e informações da atividade do usuário monitorado. Barnett et al. [8] apresentaram um método estatístico capaz de detectar mudanças nos padrões de sociabilidade (i.e., características extraídas de

mensagens de texto e chamadas telefônicas) ao longo do tempo, que foram usadas para prever recaídas esquizofrênicas com duas semanas de antecedência. Harari et al. [36] identificaram padrões de estabilidade e mudanças no comportamento social (i.e., o tempo diário gasto com conversas) de um grupo de estudantes durante dez semanas. Bonilla et al. [15] apresentou um novo modelo de mistura de processos de Poisson para encontrar um conjunto de padrões (i.e., funções de intensidade de todas as interações nas quais os pacientes estavam envolvidos) analisando dados de chamadas telefônicas e uso de aplicativos sociais.

A conscientização da situação social também foi usada para quantificar o comportamento social dos indivíduos, fornecendo feedback em tempo real. Eskes et al. [24] propuseram o uso de dados de contexto produzidos por sensores de *smartphone* (e.g., registros de chamadas, GPS e *Bluetooth*) para capturar a comunicação social e a exploração social (e.g., padrões de mobilidade e densidade social). A conscientização desses comportamentos sociais foi utilizada para desenvolver um método estatístico capaz de gerar uma pontuação de sociabilidade, no qual maiores pontuações representam maior engajamento social. Wahle et al. [70] monitoraram o envolvimento dos participantes na comunicação mediada por dispositivo (i.e., chamadas telefônicas e mensagens de texto) para quantificar sua sociabilidade. Além disso, este estudo forneceu recomendações de atividades sociais com base na combinação do nível de sociabilidade com informações sobre a hora do dia e a localização do usuário. Lane et al. [43] apresentaram um aplicativo móvel denominado *BeWell*, que possui um classificador capaz de inferir a voz humana através do microfone. Assim, esse aplicativo calculou uma pontuação de sociabilidade aplicando uma regressão linear na duração total das conversas. Além disso, *BeWell* fornece feedback sobre o nível de engajamento social de seus usuários.

3.3.2 Associação entre Estado Mental e Características Sociais

Nesse tipo de estudo, os pesquisadores se esforçam para encontrar associações entre estados mentais (e.g., humor, depressão, ansiedade social e estresse), normalmente obtidos a partir de informações autorrelatadas, e as várias características extraídas dos comportamentos sociais identificados (e.g., frequência e duração da conversa, número de mensagens de texto, duração de chamadas telefônicas e

chamadas perdidas). Essa associação geralmente foi realizada usando métodos estatísticos para medir o grau de correlação entre variáveis, como a correlação de *Pearson* [10] e a correlação de *Spearman* [50]. Essas soluções tiveram como objetivo investigar e reconhecer o potencial do uso de dados de contexto para identificar marcadores comportamentais relacionados a estados mentais.

Em um estudo envolvendo estudantes universitários, Wang et al. [72] reconheceram que as rotinas sociais destes (i.e., conversas e co-localizações *Bluetooth*) apresentavam correlações com seus sintomas de depressão e níveis de estresse. Os resultados indicaram que os alunos que apresentaram frequências mais baixas e períodos de duração mais curtos em suas interações sociais diárias revelaram níveis mais altos de depressão e estresse. Chow et al. [20] identificaram relações temporais entre estado afetivo, depressão e ansiedade social com o tempo gasto em casa, que era uma informação medida usando dados de GPS. Boukhechba et al. [16] demonstraram que os papéis sociais dos locais visitados e os padrões de comunicação (i.e., chamadas telefônicas e mensagens de texto) dos estudantes apresentaram correlações significativas com os sintomas de depressão e ansiedade social.

Alguns estudos focaram especificamente em investigar a associação de situações sociais com os níveis de estresse dos participantes. Wu et al. [76] encontraram correlações significativas entre os níveis de estresse dos alunos e as características sociais extraídas de seus encontros sociais medidos pela co-localização *Bluetooth*. Ono et al. [53] utilizaram um dispositivo vestível equipado com um sensor infravermelho para identificar interações face a face. Este estudo encontrou relações entre os níveis de estresse dos participantes com a frequência, duração e o número de pessoas envolvidas nas interações sociais.

As situações sociais também estavam relacionadas à ansiedade social, que foi o tema central de alguns estudos. Gong et al. [31] realizaram a associação entre os níveis de ansiedade social dos participantes e seus comportamentos físicos, que foram baseados no movimento corporal rastreado pelo acelerômetro durante interações sociais mediadas por dispositivos, como telefonemas e mensagens de texto. Além disso, este estudo investigou se o local em que os usuários realizavam a comunicação mediada pela tecnologia influenciou os níveis de ansiedade social. Os resultados indicaram que pessoas com níveis mais altos de ansiedade social

exibem mais variações de movimento ao fazer ligações, principalmente em ambientes desconhecidos.

Outros estudos tiveram como objetivo correlacionar as atividades sociais dos participantes com seu estado de humor. Servia-Rodriguez et al. [59] encontraram associações entre padrões de sociabilidade, medidos pela análise de telefonemas e mensagens de texto, de um grande número de participantes com suas avaliações de humor autorrelatadas. Matic et al. [46] encontraram associações entre o tempo gasto em atividades de fala (i.e., participação em interações sociais verbais) e mudanças no afeto positivo.

3.3.3 Classificação e Predição do Estado Mental

Neste tipo de estudo, as soluções propostas se concentraram no uso de características sociais extraídas dos dados de contexto para projetar modelos capazes de classificar e prever o estado mental dos indivíduos. Modelos sociais estatísticos e algoritmos de aprendizado de máquina (e.g., *Random Forest*, *K-mean* e *Support Vector Machine*) foram usados para detectar distúrbios mentais.

Diferentes modelos sociais foram desenvolvidos para classificar o estado mental dos indivíduos. Para isso, Gu et al. [34] desenvolveu uma plataforma de computação vestível equipada com um microfone para extrair e analisar automaticamente características paralinguísticas (e.g., *Brightness _sp* e *MFCC5 _sp*) apresentadas na voz do participante durante interações sociais. Essas características foram usadas para treinar o algoritmo *K-Means* para classificar o nível de ansiedade dos participantes, que obteve uma precisão de 72,73%. Chen et al. [19] utilizaram o método de aprendizado de máquina denominado Aprendizado de Transferência [73] para identificar sintomas de autismo através da análise de características da fala extraídas dos dados de microfone de um dispositivo vestível.

As soluções apresentadas pelos estudos também desenvolveram modelos sociais para prever o estado mental dos indivíduos. Para isso, Wu et al. [76] utilizaram características extraídas de encontros presenciais identificadas por encontros *Bluetooth* de *smartphones* para treinar o algoritmo *Random Forest*, que foi capaz de prever os níveis de estresse dos participantes. Barnett et al. [8] desenvolveram e aplicaram um método estatístico para reconhecer mudanças nos padrões de comunicação dos

pacientes. O método proposto pode prever recaídas esquizofrênicas com duas semanas de antecedência.

As soluções propostas também combinaram características extraídas de situações sociais com outros tipos de comportamento dos participantes, como atividade física, padrões de mobilidade e qualidade do sono. Os pesquisadores identificaram vários tipos de comportamentos que possuem implicações no estado mental do paciente, o que lhes permite projetar características mais apropriadas para desenvolver modelos de classificação e previsão do estado mental. Por exemplo, esses recursos multimodais foram usados para projetar modelos de aprendizado de máquina capazes de identificar e prever pacientes com depressão [57,70], transtorno bipolar [1, 9] e estados de humor [59]. Portanto, essas soluções representam ferramentas promissoras para monitorar a saúde mental, pois reconhecem e utilizam vários comportamentos do paciente para executar esta tarefa.

3.4 Oportunidades de Pesquisas Identificadas Através da RSL

Os trabalhos revisados visam fazer associações, detecções, classificações e previsões sobre saúde mental. Portanto, é possível reconhecer que existe a necessidade de projetar soluções que explorem a conscientização da situação social para obter informações de alto nível para os profissionais de saúde mental, como padrões contidos nas atividades sociais identificadas. Tais padrões devem representar várias características do envolvimento social dos pacientes, como os períodos do dia em que o indivíduo geralmente se socializa. Assim, é necessário desenvolver soluções capazes de reconhecer as rotinas sociais dos pacientes para permitir que os profissionais de saúde mental as interpretem e, portanto, encontrem comportamentos que representem evidências sobre transtornos mentais.

Esta pesquisa objetiva conceber uma solução capaz de mitigar a questão em aberto apresentada acima, buscando explorar dados de contexto dos dispositivos ubíquos para fornecer informações de alto nível para os profissionais especializados. Esta pesquisa difere das anteriores nos seguintes aspectos. Primeiro, este estudo não se concentra no diagnóstico de um estado ou distúrbio mental específico, mas trabalha na

identificação de situações de interesse (i.e., a rotina de sociabilidade) para profissionais de saúde mental. Segundo, a solução proposta reconhece padrões de sociabilidade sensíveis ao contexto, permitindo distinguir a variação comportamental normal de comportamentos que são considerados anomalias. Terceiro, além de identificar os períodos do dia em que o indivíduo geralmente socializa, a solução proposta é capaz de reconhecer padrões sociais anormais (i.e., rotina social anormal), assim como a efetiva mudança de rotina social do paciente. Quarto, a solução proposta utiliza a abordagem de mineração de fluxo de dados para aprender continuamente a partir de observações sociais.

Os estudos [8] e [36] também se concentra na identificação de padrões de sociabilidade, mas difere da proposta deste estudo. Estes trabalhos consideram os padrões de sociabilidade como a frequência e a duração das interações sociais diárias, enquanto nossa abordagem os define como os intervalos de tempo em que o paciente geralmente socializa. Estes estudos também não realizam o reconhecimento de padrões com base em informações de contexto, comprometendo a eficácia das análises realizadas, uma vez que os indivíduos possuem comportamentos sociais distintos em condições de contexto diferentes. O trabalho em [8] não realiza aprendizado incremental com base no fluxo de dados comportamentais e precisa processar todo o conjunto de dados sociais para identificar anomalias. O estudo de Barnett et al. [8] concentra especificamente na previsão de recaídas de pessoas esquizofrênicas, não abrangendo o comportamento social de outro tipo de paciente. A solução proposta em [36] precisa processar todo o conjunto de dados para identificar padrões de sociabilidade e se concentra em um conjunto específico de indivíduos (i.e., estudantes universitários).

3.5 Discussões

Este capítulo apresentou uma RSL sobre o monitoramento da saúde mental através da conscientização do comportamento social. Essa é uma das contribuições desta pesquisa, uma vez que, de acordo com nosso conhecimento, não há uma profunda revisão recente sobre métodos capazes de reconhecer situações sociais por meio de dispositivos ubíquos para melhorar os serviços dos profissionais de saúde

mental. Assim, os resultados desta RSL contribuem para uma melhor compreensão do uso dos dispositivos ubíquos para monitorar objetivamente o comportamento social.

A partir da análise aprofundada dos estudos primários selecionados, foram identificadas oportunidades de pesquisas que motivam o desenvolvimento deste estudo. Portanto, este trabalho visa explorar a necessidade da concepção de novos estudos para utilizar a conscientização da situação social para obter informações de alto nível para os profissionais de saúde mental. Especificamente, este estudo contribui com a literatura atual através do desenvolvimento de uma solução capaz de reconhecer padrões de sociabilidade sensíveis ao contexto, assim como comportamentos anormais e mudanças de rotina social dos indivíduos monitorados.

4 Solução Proposta

Este capítulo apresenta inicialmente o algoritmo projetado para identificar os intervalos do dia nos quais o indivíduo monitorado socializa habitualmente. Em seguida, é demonstrada a implementação deste algoritmo que é baseada no CEP. Também é apresentada a abordagem implementada para detectar mudanças de comportamentos sociais. Ao final do capítulo apresenta-se discussões a respeito do algoritmo e suas limitações.

4.1 Cenário de Aplicação

Considere o seguinte cenário que apresenta a rotina social de um indivíduo e suas variações que ocorrem devido a mudanças contextuais:

João mora sozinho em sua casa. Ele geralmente chega ao trabalho por volta das 8h e interage com seus amigos até 8h25, que é o horário de início do trabalho. O horário do almoço é por volta das 12:00, quando João normalmente socializa com seus colegas até as 14:00. Quando termina o trabalho, volta para casa e fica o resto do dia sem interações sociais. Em dias de chuva, ele prefere trabalhar em casa e gosta de almoçar na casa de sua mãe às 11h. Durante o almoço, João geralmente conversa com sua mãe por cerca de 40 minutos. Nos fins de semana (sábado ou domingo, ou ambos), João visita seus amigos pela manhã, geralmente interagindo entre 9:00 e 12:00. Além disso, durante o fim de semana, João participa regularmente de uma reunião social com amigos em um bar entre as 19:00 e as 21:30.

No cenário acima, é possível identificar padrões de sociabilidade (i.e., a rotina das atividades sociais), representados pelos frequentes intervalos de tempo de início das atividades sociais. Por exemplo, no cenário apresentado, os intervalos [8:00 - 8:20] e [12:00 - 14:00] são padrões de sociabilidade para o indivíduo. Também é possível reconhecer a variação de comportamento devido a situações contextuais, como a mudança de rotina afetada nos finais de semana e nos dias chuvosos. As variações analisadas são esperadas e não devem ser reconhecidas como anormais. No entanto, o comportamento que se desvia dos padrões sociais reconhecidos pode ser

uma evidência da presença, início ou desenvolvimento de transtornos mentais. Por exemplo, há evidências de que anomalias nos comportamentos sociais podem revelar recaídas em pacientes com esquizofrenia [8], assim como a ansiedade social pode estar associada ao aumento do tempo gasto em casa [20].

4.2 Aprendendo Padrões de Sociabilidade Enriquecidos pelo Contexto

Considerando cenários semelhantes aos apresentados acima, este estudo propõe um algoritmo para aprender continuamente os padrões de sociabilidade dos indivíduos. Para isso, foi adaptado ao domínio da saúde mental o algoritmo apresentado por Lago et al. [42], que visa aprender padrões de atividades em *smart homes*. Para reconhecer o comportamento social, é realizado o processamento em tempo real do fluxo de observação de atividades sociais derivadas de dispositivos ubíquos, permitindo manter sempre atualizado o conhecimento sobre a rotina social de um indivíduo. A identificação desses padrões é realizada para diferentes condições de contexto, distinguindo variações comportamentais esperadas de situações anormais.

4.2.1 Identificação de Padrões de Sociabilidade

Consideramos que se a atividade social for frequentemente detectada para iniciar em um intervalo de tempo específico esse intervalo compõe o padrão de sociabilidade dos indivíduos monitorados. Assim, definimos padrões de sociabilidade como *períodos do dia em que o indivíduo geralmente socializa, ou seja, o conjunto de intervalos de tempo em que as atividades sociais ocorrem habitualmente*. O algoritmo proposto reconhece intervalos de tempo $[T_{start} - T_{end}]$ nos quais o número de ocorrências de atividades sociais é maior que $\phi * |n|$. Nesse sentido, $|n|$ é considerado como o número total de observações processadas e ϕ é um parâmetro a ser definido manualmente, responsável por indicar a sensibilidade do algoritmo.

A entrada do algoritmo proposto é um fluxo de eventos sociais com o horário de início de cada atividade social. Assim, a primeira etapa do algoritmo é determinar, com base no horário de início, a qual período de tempo cada evento social

pertence. Para isso, o algoritmo proposto segmenta o tempo em slots com tamanhos iguais. Cada slot representa uma fatia do dia e possui um identificador sequencial. Para definir o tamanho do slot (i.e., em quantos períodos o dia será dividido), o programador deve especificar um valor para o parâmetro t , responsável por criar uma matriz de contadores com o número total de slots. Por exemplo, se o programador decidir dividir o dia em períodos de 30 minutos, o parâmetro t deverá ser igual a 0.5, pois $\frac{24}{t} = 48$ slots. Essa fórmula é usada para criar a estrutura para armazenar a contagem de ocorrências de atividades sociais em cada slot.

Após definir o tamanho dos slots, agora descrevemos a fase de contagem do algoritmo. Nesse estágio, o algoritmo usa o timestamp de cada evento para definir seu slot. Ao identificar o slot do evento social, o algoritmo incrementa o valor do contador que representa esse slot na estrutura responsável por armazenar essas estatísticas. Portanto, ao processar o fluxo de eventos, a frequência das atividades sociais em cada slot é atualizada. Essa abordagem de salvar apenas o resumo (i.e., a contagem) permite reduzir o volume de dados, pois não é necessário memorizar o conteúdo completo dos eventos.

A próxima fase do algoritmo é a descoberta do padrão de sociabilidade, que usa o resumo da fase de contagem para identificar intervalos do dia que representam padrões de sociabilidade. Nesse estágio, é necessário definir quais slots possuem um número suficiente de observações, ou seja, uma quantidade que permita que eles sejam slots candidatos para formar um período frequente de sociabilidade. Para isso, a contagem do número de observações sociais do slot analisado deve ser maior ou igual ao *Slot Threshold* (S_{th}). O algoritmo usa a Equação 4.1 para definir o valor do S_{th} . O parâmetro θ é inserido pelo programador para configurar a sensibilidade da equação, ou seja, é responsável por configurar o nível de exigência para um slot ser considerado candidato.

$$S_{th} = |n| * \theta * \frac{1}{t} \quad (4.1)$$

Após definir o requisito para um slot ser candidato, a próxima etapa é identificar quais conjuntos de slots compõem um intervalo no qual as atividades sociais são rotineiras para o indivíduo monitorado. Para isso, o algoritmo mescla os slots candidatos adjacentes em uma única passagem, se a soma de suas contagens for maior

que $\phi * |n|$, o intervalo de tempo formado por esse conjunto de slots representa um padrão de sociabilidade, ou seja, o intervalo de tempo em que o indivíduo monitorado socializa habitualmente. A Equação 4.2 calcula quais conjuntos de slots adjacentes contidos na *Matriz de Contadores* (C_s) compõem esses intervalos.

$$\sum_i^{i+n} C_s[i] > \phi * |n| \quad (4.2)$$

No final, é possível identificar os intervalos de tempo que representam a rotina de sociabilidade do indivíduo, reconhecendo os padrões de sociabilidade.

4.2.2 Variações de Comportamentos Sociais Devido ao Contexto

Até o momento, o algoritmo proposto permite identificar a rotina de sociabilidade do indivíduo, mapeando o horário de início frequente das atividades sociais. No entanto, essa análise sem contexto pode resultar em ineficiência ao delinear o hábito social, uma vez que o comportamento do indivíduo pode variar devido a contextos específicos, como dias úteis, fins de semana, dias chuvosos, entre outros. Por esta razão, utilizamos a estratégia de *Atributos de Contexto* (CAs), na qual várias escalas podem ser usadas para representá-las. Por exemplo, um recurso temporal pode ter várias escalas, como uma escala ampla, diferenciando dias da semana e fins de semana, ou uma escala mais específica, distinguindo cada dia da semana (e.g., segunda, terça, quarta e quinta). Injetamos essas CAs no fluxo de observações sociais, as quais podem ser derivadas diretamente das propriedades do evento (e.g., timestamp) ou recuperadas de fontes externas (e.g., APIs climáticas). Ao habilitar essa configuração, os profissionais da saúde mental podem definir quais contextos são considerados mais adequados para cada paciente e tratamento.

Cada CA é usado como uma dimensão de segmentação de dados para identificar alterações de comportamento devido a situações de contexto específicas. Portanto, a identificação de padrões de sociabilidade é realizada a partir de um subconjunto de dados que possuem um CA específico. Por exemplo, todos os eventos sociais que ocorreram no fim de semana (e.g., CA = Fim de Semana) são usados para identificar a rotina social dos indivíduos nessa condição de contexto. O algoritmo precisa criar uma estrutura (e.g., uma matriz) para armazenar os contadores de slots

para cada dimensão de contexto. Durante a fase de contagem, cada evento social incrementa, no índice de seu respectivo slot, os valores nas estruturas que armazenam as estatísticas para cada CA da observação social processada. Por exemplo, se uma atividade social tiver os contextos segunda-feira, dia da semana e dia útil, apenas os slots na matriz dessas CAs serão incrementados. Em resumo, particionamos o fluxo de dados com base em atributos de contexto e realizamos o aprendizado incremental de padrões de sociabilidade para cada fluxo de dados derivado.

4.3 Implementações Utilizando CEP

Exploramos conceitos do CEP para implementar o algoritmo proposto. O CEP permite reagir em tempo real ao fluxo de dados por meio de uma linguagem de consulta contínua [26]. Este método processa dados como uma sequência de eventos, na qual cada evento modela uma observação em um domínio específico. Por exemplo, neste estudo, um evento representa uma atividade social em um horário específico do dia. Esses eventos são gerados por dispositivos ubíquos, que podem fazer inferências de situações sociais processando dados de contexto. Para implementar o algoritmo proposto foi utilizado o Esper [25], que é um mecanismo desenvolvido para processamento de eventos complexos e análise contínua de fluxos. Esse mecanismo fornece uma EPL, que implementa e estende o padrão SQL. Assim, o fluxo de processamento do algoritmo proposto (Figura 4.1) consiste nas seguintes etapas:

- **(a) *Enrich Social Event***: injeta o slot (extraído de seu timestamp) e os CAs (e.g., dia da semana e dia chuvoso) nos eventos sociais. O resultado desse processo é a emissão de um evento enriquecido intitulado *SocialUpdate*;
- **(b) *Context Partition EPA***: segmenta o fluxo *SocialUpdate* com base nos CAs. Portanto, um evento derivado chamado *ContextEvent*, que possui o slot e o rótulo do contexto, é emitido para cada CA do evento.
- **(c) *Count Table***: é uma tabela nomeada que é responsável por manter a contagem dos eventos que ocorreram em determinados contextos em cada slot. Assim, esta contagem é atualizada a cada evento derivado *ContextEvent* emitido;

- (d) *Candidate Slot EPA*: verifica quais slots alcançaram um número adequado de eventos para se tornarem candidatos a formar um intervalo de sociabilidade, enviando-os para a fase de extração de padrões;
- (e) *Extract Pattern*: Identifica quais conjuntos de slots candidatos formam um intervalo de tempo no qual o indivíduo habitualmente socializa.

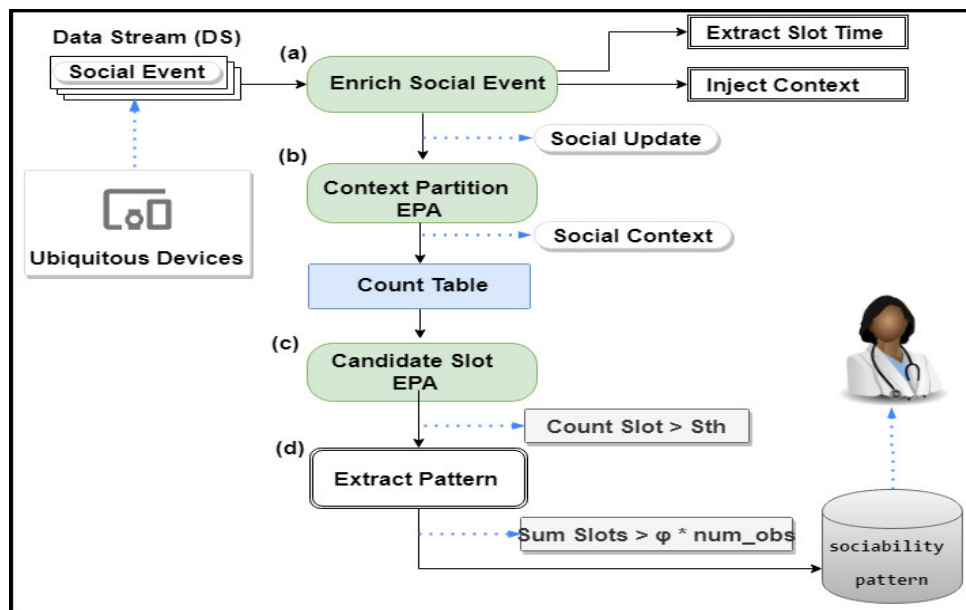


Figura 4.1: Fluxo de processamento.

4.3.1 Enriching Social Events

O fluxo de dados sociais (i.e., a sequência de observações de atividades sociais) passa pelo processo de inserção de informações essenciais para as próximas etapas. O Código 1 introduz o processo de injeção de dados em eventos sociais. A primeira informação necessária é o slot ao qual esse evento pertence. Para identificar essa informação, representamos o domínio do tempo como um horário circular de 24 horas, onde é necessário configurar o valor de um parâmetro t que represente o tamanho de cada slot contido nesse intervalo de tempo. Assim, cria-se uma estrutura para armazenar todos os slots $\frac{24}{t}$. O algoritmo proposto atribui cada evento a um slot contido nessa estrutura usando seu registro de data e hora. Outra informação essencial a ser injetada no fluxo são as CAs. Como mencionado anteriormente, os dados de contexto podem ser derivados de fontes externas ou do próprio fluxo. Por exemplo, é possível identificar condições como o dia da semana e fins de semana através do

timestamp. Assim, o conjunto de CAs é usado para enriquecer o fluxo de dados. No final, o evento social enriquecido chamado *SocialUpdate*, composto por um slot e seu conjunto de CAs, é enviado para a rede de processamento de eventos.

Código 1 Enriquecendo eventos sociais.

```
1: Inputs:  
2: Data Stream DS  
3: Context Attributes CAs[]  
4: Output:  
5: An enriched SocialUpdate event.  
6: while Data Stream DS is active do  
7:   slot ← extract from timestamp  
8:   contexts[] ← read from CAs[]  
9:   emit SocialUpdate(slot, contexts[])  
10: end while
```

4.3.2 Context Partition EPA

O *Context Partition EPA* é responsável por segmentar o fluxo *SocialUpdate* com base nos CAs. Este componente foi implementado com base na estratégia de reconhecimento de variação comportamental definida na Subseção 4.2.2, que utiliza os CAs como uma dimensão de segmentação de dados. Para fazer isso, usamos a abordagem de partições de contexto segmentadas por categoria [25], que atribui cada evento a partições de contexto com base nos valores de um ou mais atributos. Essa abordagem usa uma expressão de predicado para relacionar cada observação com uma categoria específica. Portanto, cada evento pode pertencer a uma, várias ou nenhuma partição de contexto. O Código 2 expressa uma EPL que define as categorias de contexto *ctxWeek* (i.e., semana e fim de Semana) e *ctxDay* (i.e., segunda, terça, sábado e domingo). Essa EPL permite o uso dos CAs contidos nos eventos *SocialUpdate* como um predicado para segmentar o fluxo de dados em partições de contexto.

Após estabelecer a EPL que determina as regras da partição de contexto (Código 2), agora descrevemos a EPL que a utiliza para segmentar o fluxo de eventos *SocialUpdate* (Código 3). A EPL apresentada no Código 3 cria um evento derivado

Código 2 Contexto segmentado por categoria.

```
1: CREATE CONTEXT CategoryContext
2: GROUP ctxWeek = Week AS WEEK,
3: GROUP ctxWeek = Weekend AS WEEKEND,
4: GROUP ctxDay = Friday AS FRIDAY,
5: GROUP ctxDay = Saturday AS SATURDAY
6: GROUP ctxDay = Sunday AS SUNDAY
7: FROM SocialUpdate =0
```

chamado *ContextEvent* para cada CA contido nos eventos do fluxo *SocialUpdate*. Esses eventos derivados são compostos pelo rótulo do CA e slot do evento.

Código 3 Particionamento do fluxo de dados com base no contexto.

```
1: CONTEXT CategoryContext
2: INSERT INTO ContextEvent
3: SELECT slot, context.label
4: FROM SocialUpdate
```

Cada evento *ContextEvent* processado atualiza o valor do contador presente em uma estrutura em memória denominada *CountTable*. Para criar essa estrutura, usamos o recurso de tabela nomeada, que é uma estrutura de dados visível globalmente onde suas colunas podem manter o estado de agregação [25]. Qualquer instrução na rede de processamento pode criar, atualizar e consultar o status de agregação. Para este estudo, a tabela nomeada usada possui o rótulo de contexto como chave primária, enquanto as colunas suportam a contagem total de observações e a contagem de observações para cada slot. Portanto, cada linha mantém o resumo dos eventos vinculados a cada CA, satisfazendo a etapa de divisão de dados necessária para identificar a variação comportamental de acordo com o contexto. A EPL representada no Código 4 é responsável por inserir dados nessa estrutura toda vez que um evento *ContextEvent* é derivado, atualizando a contagem de eventos por slot para todos os atributos de contexto (*CountTable* [label] [slot]). Os componentes subsequentes da rede de processamento consultam o status de agregação contido nesta tabela para identificar padrões de sociabilidade.

Código 4 Atualização da tabela *CountTable*.

```

1: INTO TABLE CountTable
2: SELECT count(*) AS countEvent
3: FROM ContextEvent.win:keepall()
4: GROUP BY slot, label

```

4.3.3 Candidate Slot EPA

O *Candidate Slot EPA* é responsável por identificar em quais slots ocorreu um número suficiente de eventos sociais para torná-los slots candidatos, isto é, slots habilitados a compor um intervalo de tempo que representa um hábito para a pessoa monitorada. Para projetar uma EPL capaz de executar esta tarefa, usamos a Equação 4.1, que define o limite para um slot ser candidato.

A EPL apresentada no Código 5 realiza uma consulta na tabela *CountTable*, em que *labelContext* é o nome do CA considerado. É essencial observar a presença de duas constantes, a saber, *nSlot* (número total de slots $\frac{24}{t}$) e *theta* (parâmetro para definir a sensibilidade θ). As constantes do CEP permitem disponibilizar esses valores para todas as instruções da rede de processamento. Nesta EPL, *countSlot* representa o número de eventos em um determinado slot e *numObs* ($|n|$) representa o número total de eventos que ocorreram em um determinado contexto. Em conclusão, o Código 5 apresenta a EPL responsável por selecionar os slots que podem formar um padrão de sociabilidade. Os slots que atendem à condição definida são enviados para a fase de extração de padrão, sendo responsável por identificar quais conjuntos de slots formam um intervalo de tempo no qual as atividades sociais ocorrem habitualmente.

Código 5 Seleção dos slots candidatos.

```

1: SELECT * FROM CountTable AS ct
2: WHERE ct.label = labelContext AND
3: ct.countSlot >= ct.numObs * teta * (1/(nSlot)))
4: ORDER BY slot

```

4.3.4 Extração do Padrão de Sociabilidade

Após selecionar os slots candidatos, é necessário avaliar quais conjuntos de slots representam padrões de sociabilidade. Para esse fim, o componente *Extract*

Pattern percorre a coleção de slots em apenas uma passagem, na qual os slots candidatos adjacentes são mesclados. Se a soma da contagem de eventos dos slots mesclados for maior que $\phi * |n|$, o intervalo de tempo composto por esse conjunto de slots candidatos representa um padrão de sociabilidade, ou seja, o intervalo de início frequente da atividade social. O Código 6 apresenta esse processo de extração de padrões de sociabilidade.

Código 6 Extração do padrão social.

```

1: Inputs:
2: Candidate Slots  $CS_s[]$ 
3: Phi  $varphi$ 
4: Number of Observations  $nobs$ 
5: Output:
6: A set of sociability patterns.
7:  $phi \leftarrow varphi$ 
8:  $n \leftarrow nobs$ 
9: for all slot  $\in CS_s$  do
10:   while slot isAdjacent(slot.next) do
11:      $adjacentSlots \leftarrow merge(slot, slot.next)$ 
12:      $slot \leftarrow slot.next$ 
13:   end while
14:   if  $sum(adjacentSlots) > n * phi$  then
15:      $intervals[] \leftarrow adjacentSlots$ 
16:   end if
17: end for
18: return  $intervals[]$ 

```

4.4 Detecção de Mudança de Rotina Social e Comportamentos Sociais Anormais

Tendo apresentado o mecanismo desenvolvido para a detecção contínua de padrões de sociabilidade, outra contribuição importante deste estudo é a concepção de uma abordagem de reconhecimento de mudança de rotina social e comportamentos sociais anormais. Esta solução visa detectar de maneira contínua e automática

informações sobre mudanças de comportamentos sociais do paciente monitorado, uma vez que esta informação é de vital importância para o tratamento e acompanhamento do indivíduo, permitindo aumentar as chances de efetividade das intervenções realizadas pelos profissionais especializados. O mecanismo de detecção de mudança de comportamento social concebido utiliza os padrões de sociabilidade reconhecidos pela solução apresentada anteriormente, além de conceitos de tecnologias como *concept drift* e *lógica fuzzy*.

4.4.1 Estratégia de Detecção de Mudança Comportamental

A definição da estratégia de detecção de mudança de comportamento foi concebida a partir da aplicação de técnicas de identificação de *concept drift*, que permite reconhecer mudanças do fluxo de socialização do indivíduo monitorado. Especificamente, foram exploradas técnicas não supervisionadas de detecção de mudanças na distribuição do fluxo de dados, pois não há uma verdade fundamental disponível no fluxo para utilizar a supervisão de indicadores de desempenho. Portanto, utilizamos a abordagem de processamento de janelas de dados em combinação com uma métrica de similaridade, que permite verificar a mudança de padrão de um instante de tempo t_1 para t_2 . É importante ressaltar que as detecções de mudanças são realizadas para cada atributo de contexto, permitindo diferenciar a variação comportamental esperada de mudanças efetivas de comportamentos sociais.

A estratégia de processamento de janelas de dados disponível pelo *Esper* foi explorada para reconhecer o comportamento social do indivíduo monitorado em determinadas janelas de tempo, permitindo extrair o padrão de sociabilidade através de diferentes conjuntos de dados. Assim, é possível extrair padrões de sociabilidade através de dados mais atuais e, posteriormente, compará-los com o padrão extraído em uma nova janela de dados futura, permitindo reconhecer a ocorrência de mudanças significativas na rotina social do indivíduo monitorado. A métrica de similaridade utilizada para quantificar a sobreposição dos padrões de sociabilidade é o índice de *Jaccard* (Equação 4.3), que permite medir a proporção entre a interseção dos intervalos dos padrões comparados e sua união.

$$J(A, B) = \frac{A \cap B}{A \cup B} \quad (4.3)$$

A partir da estratégia descrita acima, foi desenvolvido um mecanismo capaz de detectar dois tipos de situações de interesse para os profissionais especializados, a saber, comportamentos anormais e mudanças na rotina social. Os comportamentos anormais refletem uma baixa similaridade entre o padrão de sociabilidade atual com o comportamento do indivíduo em um dia específico. Quando comportamentos anormais são identificados em uma frequência substancial, infere-se que a rotina de sociabilidade do indivíduo monitorado pode ter mudando, necessitando analisar esta premissa. Para tanto, a mudança de rotina é reconhecida quando um padrão de sociabilidade extraído de uma janela de dados no tempo t tiver uma baixa similaridade com um padrão extraído na janela de dados $t + n$.

A Figura 4.2 apresenta a estratégia de detecção de comportamentos anormais desenvolvida por este estudo. Para realizar esta tarefa, o especialista deve definir o tamanho da janela de tempo que modela uma observação do comportamento social do indivíduo em um dado contexto (e.g., segundas feiras, dias chuvosos, fins de semanas, dentre outros). Por exemplo, no cenário da Figura 4.2, uma observação poderia ser composta por uma janela de dados de uma semana, necessitando de duas observações para extrair um padrão de sociabilidade consistente, isto é, conceber um modelo preditor dos intervalos do dia nos quais o indivíduo habitualmente socializa. Portanto, para reconhecer comportamentos anormais, o mecanismo proposto utiliza a métrica de similaridade (Equação 5.1) para comparar o padrão de sociabilidade atual com o comportamento social das próximas observações. Assim, caso a similaridade entre o padrão atual e o comportamento social reconhecido (i.e., uma observação) apresente valor inferior a um limiar definido pelo especialista, o mecanismo emite um evento para notificar as partes interessadas sobre a identificação de um comportamento social anormal.

A Figura 4.3 apresenta a estratégia de detecção de mudança de rotina social desenvolvida por este estudo. Neste cenário, padrões de sociabilidade são extraídos através de um número determinado de observações (e.g., duas observações), que representam a rotina social atual do indivíduo monitorado. O primeiro padrão de sociabilidade extraído é salvo em memória, o qual será considerado o modelo preditor ativo para a estratégia de detecção de comportamentos anormais e também será utilizado como modelo de comparação com os próximos padrões para reconhecer mudanças efetivas de rotina. Especificamente, quando o mecanismo proposto

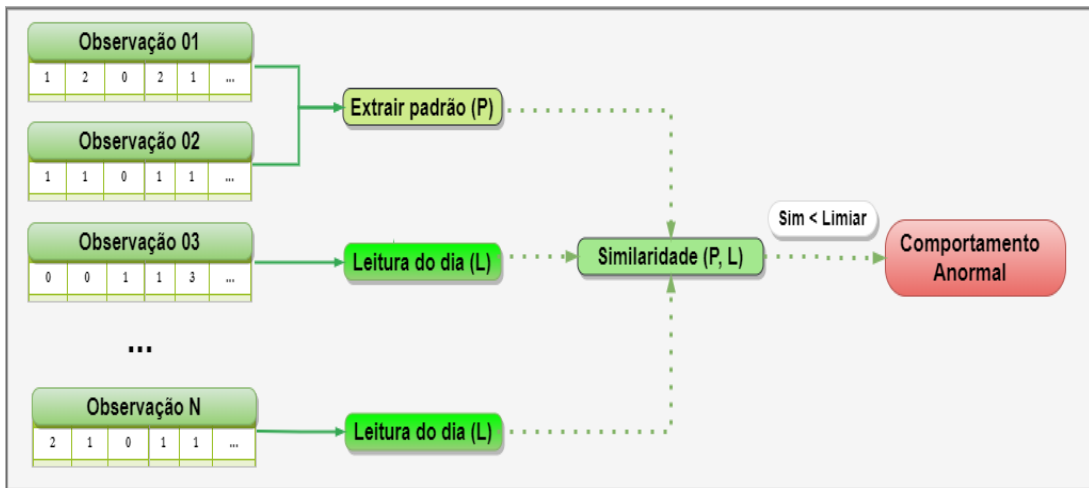


Figura 4.2: Estratégia de detecção de comportamentos sociais anormais.

reconhece que a similaridade entre o padrão social de referência (i.e., padrão válido) e um padrão posterior apresenta similaridade inferior a um limiar definido pelo especialista, duas tarefas são desencadeadas, a saber, (i) atualização do padrão de sociabilidade atual com a rotina mais recente; (ii) emissão de um evento para notificar as partes interessadas sobre a detecção de mudança de rotina social.

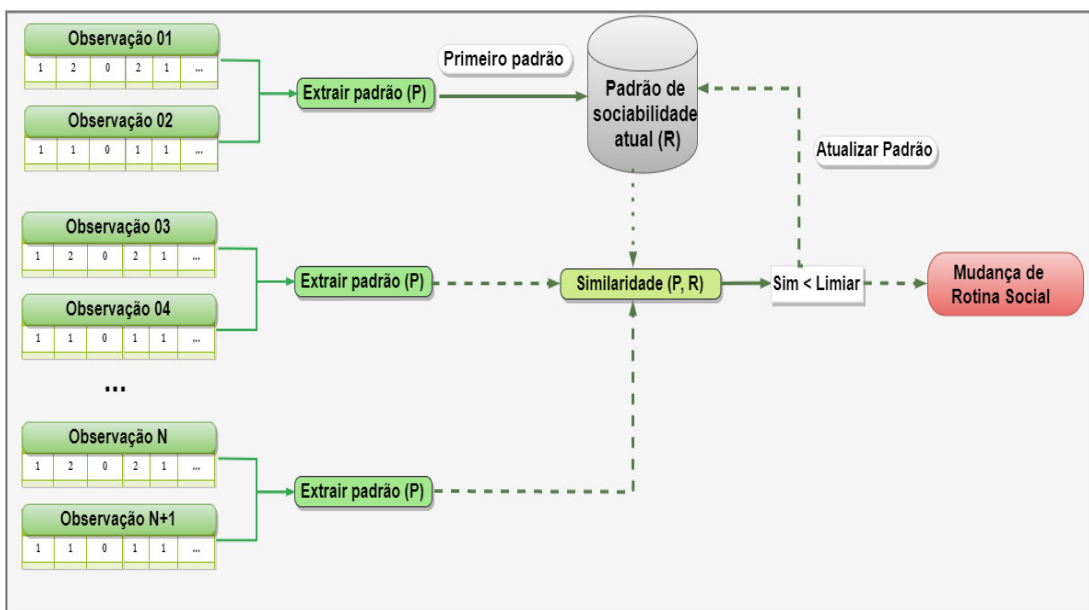


Figura 4.3: Estratégia de detecção de mudança de rotina social.

4.4.2 Modelagem do Conhecimento do Especialista

Analisando o mecanismo de detecção de mudanças de comportamentos sociais apresentado anteriormente, é possível identificar a necessidade do especialista

definir um limiar de similaridade entre padrões. Assim, a especificação do limiar de mudança possui um caráter subjetivo, pois depende do conhecimento do especialista, tendo também uma essência imprecisa, pois um limiar limítrofe rígido pode não modelar adequadamente a mudança ocorrida. Por exemplo, considere que um especialista configurou o mecanismo de detecção de mudança de comportamento com um limiar de 60% de similaridade. Neste cenário, caso a similaridade entre padrões de sociabilidade seja de 59.9%, o mecanismo notificará a mudança, mesmo estando bem próximo ao limiar especificado. Portanto, é necessário definir estratégias que possibilite o mecanismo modelar o conhecimento do especialista de maneira automática, permitindo-lhe emitir alertas de mudanças de comportamentos com julgamento de grau de crença.

Assim, a modelagem do conhecimento especialista foi implementada através dos conceitos da lógica *fuzzy*, que permitiu o mecanismo de detecção de mudanças comportamentais emitir notificações considerando a natureza imprecisa desta tarefa. Especificamente, foi utilizada a biblioteca de código aberto *jFuzzyLogic*¹, que viabiliza o desenvolvimento de controladores *fuzzy*. Esta biblioteca implementa a *Fuzzy Control Language* (FCL), que é uma linguagem específica de domínio para utilizar os conceitos da lógica *fuzzy*. Portanto, a *jFuzzyLogic* permitiu integrar na solução deste estudo um FIS, possibilitando o especialista especificar as variáveis, os conjuntos *fuzzy* e as regras.

Em princípio, o especialista deve determinar os conjuntos *fuzzy* que compõem o universo de discurso. Especificamente, são definidos três conjuntos *fuzzy*, a saber, *sensibilidade*, *similaridade* e *drift*. O conjunto *sensibilidade* é responsável por definir o nível de discrepância entre padrões que representa uma mudança, isto é, modela o conhecimento da sensibilidade de detecção de mudanças. O conjunto *similaridade* é responsável por definir os níveis de correspondência entre os padrões avaliados. E por fim, o conjunto "*drift*" representa a saída do FIS (i.e., *defuzzifier*), responsável por modelar os níveis de mudanças de comportamentos sociais.

Tendo definido os conjuntos *fuzzy*, o próximo passo é subdividir-los de modo a representar o conhecimento do especialista, ou seja, atribuir termos linguísticos aos intervalos de cada conjunto. Portanto, os especialistas devem utilizar a FCL para

¹jfuzzylogic.sourceforge.net

executar esta tarefa. No Código 7, é possível visualizar um exemplo de configuração das partições do conjunto *sensibilidade* utilizando a FCL, ao passo que a Figura 4.4 demonstra sua representação visual. Neste exemplo, o especialista especificou que a variável de entrada *sensibilidade* é dividida em três níveis: baixa, moderada e alta. Neste cenário, também é possível observar que existe um certo nível de interseção entre os intervalos, representando uma transição gradativa de pertinência.

Código 7 Definição das partições do conjunto *sensibilidade*.

```

1: FUZZIFY sensibilidade
2: TERM baixa := (0, 1) (25, 1) (50, 0) ;
3: TERM moderada := (25, 0) (50,1) (75, 0);
4: TERM alta := (50, 0) (75, 1) (100, 1);
5: END_FUZZIFY

```




Figura 4.4: Conjunto *fuzzy* para avaliar a sensibilidade de mudança.

De forma similar a definição do conjunto *sensibilidade*, o especialista deve representar seu conhecimento através da FCL para definir as partições do conjunto *similaridade* e seus respectivos termos linguísticos. O Código 8 apresenta um exemplo de configuração das partições do conjunto *similaridade*, ao passo que a Figura 4.5 demonstra uma representação visual desta configuração. Neste exemplo, o especialista subdividiu a variável de entrada *similaridade* em três níveis: baixa, moderada e alta. Neste cenário, também é possível observar que os intervalos que compõem este conjunto possuem certo nível de interseção, possibilitando modelar a incerteza através de uma transição gradativa de pertinência.

O terceiro conjunto a ser especificado é o *drift*, que é responsável por representar a saída do FIS (i.e., *defuzzifier*), isto é, modela a ocorrência de mudança do

Código 8 Definição das partições do conjunto similaridade.

```

1: FUZZIFY similaridade
2: TERM baixa := (0, 1) (40, 1) (60, 0) ;
3: TERM moderada := (50, 0) (60,1) (70, 0);
4: TERM alta := (60, 0) (75, 1) (100, 1);
5: END_FUZZIFY

```

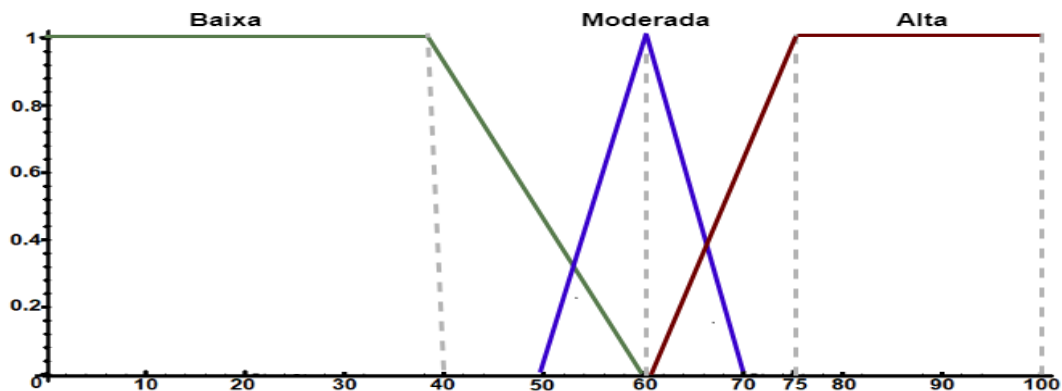


Figura 4.5: Conjunto *fuzzy* para avaliar a similaridade.

comportamento social do indivíduo monitorado. O Código 9 apresenta um exemplo de configuração de partições para este conjunto *fuzzy*, ao passo que a Figura 4.6 demonstra visualmente as partições definidas. Assim, o especialista definiu três termos linguísticos: *sem_mudanca*, *mudanca_moderada* e *mudanca*. Neste exemplo, foi utilizado o método de defuzzificação COG (i.e., Centro de Gravidade), responsável por emitir a variável de saída do FIS. A *jFuzzyLogic* suporta vários métodos de fuzzificação e defuzzificação, que diferem nas fórmulas matemáticas utilizadas.

Código 9 Definição das partições do conjunto *drift*.

```

1: DEFUZZIFY drift
2: TERM sem_mudanca := (0, 1) (50, 1) (65, 0) ;
3: TERM mudanca_moderada := (50, 0) (65, 1) (80, 0) ;
4: TERM mudanca := (65, 0) (80, 1) (100,1);
5: METHOD: COG;
6: END_DEFUZZIFY

```

Em seguida, o especialista deve especificar as preposições lógicas que nortearam a decisão do mecanismo. Estas preposições possuem a estrutura básica <condição> AND <condição> THEN <consequência>. Assim, as regras definidas




Figura 4.6: Conjunto *fuzzy* para avaliar a mudança.

pele especialista formaram a base de conhecimento utilizada pelo FIS para decidir o conjunto da variável de saída, assim como seu respectivo nível de pertinência. Portanto, com base nos conjuntos *fuzzy* apresentados anteriormente, poderiam ser especificadas através da FCL as proposições lógicas contidas no Código 10.

Código 10 Proposições lógicas de mudança de comportamento.

- 1: **RULEBLOCK** No1
 - 2: **RULE 1: IF** sensibilidade **IS** baixa **AND** similaridade **IS** baixa **THEN** drift **IS** mudanca;
 - 3: **RULE 2: IF** sensibilidade **IS** baixa **AND** similaridade **IS** moderada **THEN** drift **IS** sem_mudanca;
 - 4: **RULE 3: IF** sensibilidade **IS** baixa **AND** similaridade **IS** alta **THEN** drift **IS** sem_mudanca;
 - 5: **RULE 4: IF** sensibilidade **IS** moderada **AND** similaridade **IS** baixa **THEN** drift **IS** mudanca;
 - 6: **RULE 5: IF** sensibilidade **IS** moderada **AND** similaridade **IS** moderada **THEN** drift **IS** mudaca_moderada;
 - 7: **RULE 6: IF** sensibilidade **IS** moderada **AND** similaridade **IS** alta **THEN** drift **IS** sem_mudanca;
 - 8: **RULE 7: IF** sensibilidade **IS** alta **AND** similaridade **IS** baixa **THEN** drift **IS** mudanca;
 - 9: **RULE 8: IF** sensibilidade **IS** alta **AND** similaridade **IS** moderada **THEN** drift **IS** mudanca;
 - 10: **RULE 9: IF** sensibilidade **IS** alta **AND** similaridade **IS** alta **THEN** drift **IS** sem_mudanca;
 - 11: **END_RULEBLOCK**
-

Ao fim do processo de modelagem do conhecimento do especialista, o mecanismo desenvolvido por este estudo será capaz de detectar mudanças de comportamentos sociais considerando a incerteza desta tarefa, ou seja, emitirá notificações de mudanças comportamentais com níveis de pertinência ao conjunto

fuzzy de saída. Especificamente, o mecanismo emitirá um *JavaScript Object Notation* (JSON) que contém informações como a data, contexto, similaridade, e o grau de pertinência a cada intervalo do conjunto fuzzy de saída. O Código 11 apresenta um exemplo de notificação de mudança de comportamento social emitida considerando o conhecimento especialista modelado nos exemplos anteriores. Neste exemplo, é possível identificar que a variável de saída (i.e., valor de defuzzificação) assume o valor ≈ 74.86 , que está aproximadamente 65% contido no intervalo que representa mudança e 35% no intervalo que reflete mudança moderada.

Código 11 Notificação de mudança de comportamento social.

```
1: {  
2:     "data":"Qua 1, 2020, 9:17:48 PM",  
3:     "contexto":"Quarta",  
4:     "similaridade":56.000000000000001,  
5:     "valor de defuzzificação":74.86688093051647,  
6:     "mudanca":0.6577920620344315,  
7:     "sem_mudanca":0.0,  
8:     "mudanca_moderada":0.3422079379655685,  
9:     "mensagem":"Mudança de rotina social detectada"  
10: }
```

4.5 API de Programação

A solução concebida por este estudo fornece uma *Application Programming Interface* (API) para seus usuários, permitindo-lhes implementar facilmente as estratégias de detecção de padrões sociais, assim como habilitar o reconhecimento de mudanças comportamentais. O desenvolvimento desta API utilizou os conceitos do padrão de projeto *Builder* (Construtor) [29], que permite abstrair a complexidade de criação do objeto de gerenciamento do sistema, dividindo este processo em partes (i.e., etapas). Assim, através deste conceito, o usuário é abstraído da complexidade inerente a criação e instanciação da EPN, assim como da configuração do mecanismo de mudanças de comportamentos sociais.

O Algoritmo 12 apresenta um exemplo da utilização da API concebida por este estudo. Especificamente, o usuário deve criar um objeto denominado

SociabilityPattern, que é responsável por configurar e habilitar todo o funcionamento da solução. No construtor são especificados dois parâmetros, sendo estes o nome do contexto a ser considerado e o nível de sensibilidade de detecção. Logo após, é especificado o tópico raiz que será utilizado para enviar as notificações. Esta informação é necessária pois o mecanismo publica os novos padrões de sociabilidade e notificações de mudanças de comportamentos em um *broker* mqtt [61], permitindo aplicações clientes interessadas se inscreverem neste tópico para receber atualizações. Por fim, o usuário poderá habilitar as estratégias de detecção de comportamentos anormais e mudanças de rotina social.

Código 12 API de programação da solução concebida

```
1: SociabilityPattern sociabilityPattern = new SociabilityPattern
2:     .Builder(ContextEnum.MONDAY_.toString(), sensitivityOfChange: 50.0)
3:     .setRootTopic("com/lstdi/sociability")
4:     .setAbnormalBehavior(true)
5:     .setChangeBehavior(true)
6:     .build(); =0
```

4.6 Discussões

Este capítulo apresentou uma abordagem ubíqua de monitoramento da saúde mental através da consciência da situação social. Especificamente, foi introduzido o algoritmo projetado para realizar a detecção de padrões de sociabilidade enriquecidos por contexto através do processamento do fluxo social derivado dos dispositivos ubíquos. Posteriormente, apresentou-se sua implementação utilizando um conjunto de regras CEP, que permitiu realizar a identificação da rotina social do indivíduo monitorado de maneira incremental e online. Adicionalmente, demonstrou-se a abordagem de detecção de mudanças de comportamentos sociais concebida, assim como a modelagem do conhecimento especialista necessário para executar esta tarefa. Por fim, mostrou-se a API de programação do mecanismo desenvolvido por este estudo.

Considerando a classificação dos estudos relacionados apresentada na Tabela 3.3, este trabalho está inserido na categoria que objetiva detectar e quantificar

a sociabilidade, uma vez que este utiliza dados derivados dos dispositivos ubíquos para reconhecer informações relevantes sobre o comportamento social dos indivíduos. Portanto, o conjunto de soluções apresentado neste capítulo identifica informações objetivas do comportamento social do indivíduo monitorado, permitindo aos especialistas da saúde mental realizar avaliações e intervenções mais consistentes, uma vez que não precisam mais se limitar ao relato subjetivo e enviesado dos pacientes.

Em conclusão, o conjunto de soluções apresentado neste capítulo identifica informações objetivas do comportamento social do indivíduo monitorado, permitindo aos especialistas da saúde mental realizar avaliações e intervenções mais consistentes, uma vez que não precisam mais se limitar ao relato subjetivo e enviesado dos pacientes. Assim, através da solução concebida, os profissionais especializados terão a consciência da situação social de seus pacientes, tendo acesso as seguintes informações em tempo próximo ao real: (i) a rotina social de seu paciente, reconhecendo os intervalos do dia em que socializa habitualmente; (ii) os comportamentos sociais anormais apresentados pelos pacientes; (iii) a mudança efetiva de rotina social, permitindo comparar o comportamento antigo com o atual.

5 Avaliação

A abordagem de aprendizado não supervisionado apresentada pelo algoritmo proposto dificulta o uso de métricas comumente usadas para avaliar modelos de aprendizado, pois não existe uma verdade fundamental disponível para comparar os resultados. Assim, avaliamos o algoritmo proposto com o objetivo de validar a consistência dos padrões de sociabilidade reconhecidos. Para avaliar a solução proposta, é necessário ter dados reais da rotina de sociabilidade dos indivíduos por um período prolongado, além de informações contextuais nas quais essas atividades ocorreram. Para esse fim, avaliou-se o mecanismo proposto usando um conjunto de dados do mundo real, que permite validar seu desempenho ao reconhecer padrões de sociabilidade enriquecidos pelo contexto. Assim, essa avaliação possui os seguintes objetivos:

- (i) Identificar a precisão dos padrões de sociabilidade identificados pelo algoritmo proposto.
- (ii) Avaliar a utilidade dos padrões de sociabilidade enriquecidos pelo contexto para o reconhecimento da rotina social do indivíduo monitorado.
- (iii) Avaliar a capacidade dos padrões de sociabilidade enriquecidos pelo contexto de modelar a rotina social dos indivíduos monitorados.
- (iv) Avaliar a capacidade da abordagem proposta de detectar comportamentos sociais anormais e mudanças de rotinas sociais.

5.1 Descrição dos Dados

Foi utilizado o conjunto de dados *StudentLife* [72] para avaliar a solução proposta. Para coletar esses dados, Wang et al. [72] realizaram por 66 dias a detecção passiva de atividades sociais (i.e., conversações) derivadas de dados do microfone dos *smartphones* de 48 estudantes de graduação e pós-graduação de *Dartmouth College*.

Todos os dados coletados foram anonimizados para preservar a privacidade dos indivíduos monitorados.

As amostras de conversações são compostas por dois campos: registro de data e hora de início e fim da interação experimentada pelo indivíduo monitorado. A Figura 5.1 apresenta as primeiras linhas do arquivo de inferências de conversação de um participante. Por exemplo, a segunda linha demonstrada na Figura 5.1 registra que um participante vivenciou uma conversação que teve início no timestamp unix 1364359600 e finalizou no timestamp unix 1364359812.

```
1 start_timestamp, end_timestamp
2 1364359600,1364359812
3 1364382621,1364383065
4 1364383516,1364384993
5 1364385033,1364385094
6 1364385786,1364385866
```

Figura 5.1: Formato das amostras de conversação.

Primeiramente, foi realizado um processo de limpeza de dados para remover usuários que apresentavam dados insuficientes para a realização dos experimentos conduzidos. Portanto, foram mantidos neste experimento apenas usuários que continham pelo menos 52 dias de dados coletados ($\approx 80\%$ dos dias do estudo), vindo a remover 24 indivíduos que possuíam dados insuficientes.

Para projetar um fluxo de dados apropriado para a rede de processamento proposta, criou-se eventos sociais a partir dos registros de conversações. Para tanto, derivou-se a partir dos registros de atividades sociais as seguintes informações: tipo de atividade social (i.e., conversação), horário de início e um conjunto de CAs. O primeiro passo executado foi converter o timestamp unix para objeto Date java, que permitiu representar os atributos tempo de início do evento social, assim como derivar seus CAs. Assim, a partir da data dos registros de conversações, identificou-se o dia da semana em que estes ocorreram, permitindo especificar escalas de contextos temporais para o fluxo de eventos sociais. Assim, definiu-se duas escalas de contexto, uma refinada composta por todos os dias da semana (e.g., segunda, terça, quarta, quinta e sexta, sábado, domingo) e uma ampla para distinguir fins de semana (i.e., sábados e

domingos) do meio da semana (i.e., segunda a sexta). Portanto, ao final, a estrutura do fluxo de eventos sociais gerado foi a seguinte:

- 1 event = (activity: Conversation, start: 8:20, contexts: [Sunday, Weekend])
- 2 event = (activity: Conversation, start: 10:12, contexts: [Sunday, Weekend])
- 3 event = (activity: Conversation, start: 11:20, contexts: [Monday, Week])
- 4 event = (activity: Conversation, start: 18:15, contexts: [Tuesday, Week])

5.2 Design experimental

Para avaliar a precisão do mecanismo proposto, comparamos a similaridade entre os padrões de sociabilidade identificados pela solução proposta e os intervalos sociais reconhecidos pelo algoritmo *Gaussian Mixing Models* (GMM). GMMs são modelos probabilísticos que consideram que uma amostra de dados foi gerada a partir de distribuições gaussianas [14]. Sua execução atribui cada amostra a diferentes componentes (i.e., *clusters*) com diferentes níveis de associação. Assim, para encontrar os intervalos que representam os padrões de sociabilidade contidos no conjunto de dados, ajustamos um GMM aos horários de início das atividades sociais. Portanto, para cada componente encontrado, um padrão de sociabilidade é definido como $[\mu - \sigma, \mu + \sigma]$.

Embora o GMM possa reconhecer intervalos de tempo que representam padrões de sociabilidade, ele tem várias limitações em comparação com a solução proposta por este estudo. Primeiro, é um algoritmo mais complexo que requer várias interações para convergir. Segundo, não é adequado para o processamento de fluxo de dados, pois requer várias passagens nos dados. Portanto, o mecanismo proposto apresenta características para mitigar essas limitações, pois utiliza a mineração de fluxo de dados para realizar o aprendizado incremental e online dos padrões de sociabilidade.

Para demonstrar os resultados da precisão do algoritmo proposto, foi utilizada uma representação gráfica dos intervalos de sociabilidade por meio de um relógio de 24 horas. Nesta representação, é possível visualizar a sobreposição entre os intervalos de sociabilidade reconhecidos pelo algoritmo proposto e os do GMM. Para

quantificar o índice de sobreposição, utilizou-se o índice de *Jaccard* (Equação 5.1), que mede a proporção entre a interseção dos intervalos encontrados e sua união [56]. Este coeficiente de similaridade foi utilizado devido a sua capacidade de medir o nível de sobreposição entre os padrões de sociabilidade (i.e. intervalos de tempo).

$$Jaccard(A, B) = \frac{A \cap B}{A \cup B} \quad (5.1)$$

A avaliação da capacidade dos padrões de sociabilidade de modelar a rotina social consistiu em verificar se a solução proposta é capaz de explicar e prever os comportamentos sociais de usuários com rotinas mais estáveis (i.e., repetem seu comportamento ao longo dos dias), assim como mais dificuldade com participantes que não possuem uma rotina estável. Para tanto, utilizou-se o método de correlação de *Pearson* [10] para avaliar a associação entre a capacidade dos padrões de sociabilidade de explicar a rotina social e a estabilidade da rotina social do indivíduo. Este coeficiente mede a correlação linear (e a direção dessa correlação: positiva ou negativa) entre duas variáveis, que assume valores entre -1 (correlação negativa perfeita) e 1 (correlação positiva perfeita). Assim, maiores níveis de correlações positivas indicam que a solução proposta reconhece padrões de sociabilidade mais consistentes, isto é, apresentam maior capacidade de modelar o comportamento social do paciente monitorado.

Por fim, foi realizada a validação do mecanismo de detecção de mudança de comportamento social. Para tanto, foi executada a união dos dados de dois usuários que possuem rotinas sociais distintas, permitindo identificar com precisão o ponto no qual a mudança deve ser detectada, assim como a adaptação ao novo padrão de sociabilidade.

5.3 Precisão dos Intervalos Identificados

Nesta etapa, o conjunto de dados foi utilizado como entrada para o GMM e para a rede de processamento proposta. A Figura 5.2 apresenta os intervalos de sociabilidade reconhecidos pelos dois algoritmos. O GMM encontrou quatro distribuições nos dados processados, enquanto o algoritmo proposto identificou sete intervalos de sociabilidade. Os resultados mostram que ambos os algoritmos

podem identificar diferentes intervalos de sociabilidade durante o dia com diferentes tamanhos, permitindo mapear padrões de sociabilidade. Para validar a utilidade dos padrões de sociabilidade encontrados, comparamos a semelhança dos intervalos identificados pelos dois algoritmos. Ao aplicar o índice de *Jaccard*, encontrou-se um coeficiente de similaridade de 86,33%, que representa uma correspondência significativa entre os dois algoritmos.

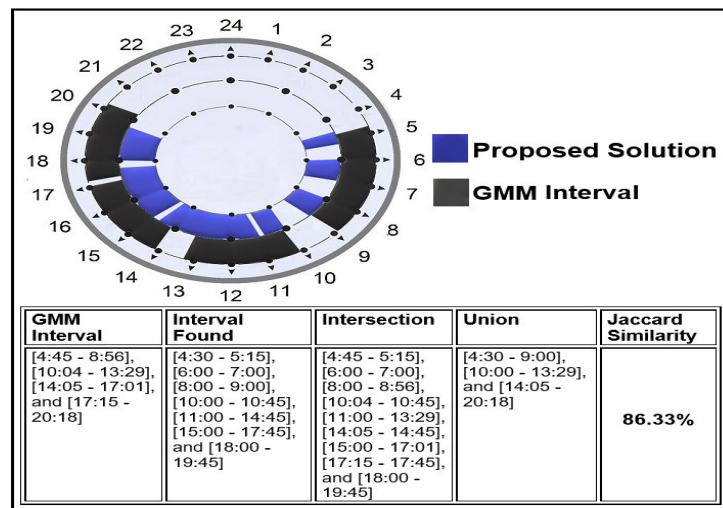


Figura 5.2: Padrões de sociabilidade identificados por ambos algoritmos.

Apesar de ambos algoritmos reconhecerem padrões de sociabilidade, os intervalos encontrados pelo GMM têm tamanhos maiores, mostrando que as distribuições encontradas têm um grande desvio padrão. Esse achado permite inferir que a rotina social apresenta uma variabilidade considerável, ou seja, esta atividade pode iniciar em diferentes períodos do dia, o que sugere que não existe uma rotina social estável. Ao contrário do GMM, o algoritmo proposto identificou intervalos menores que o GMM. Por exemplo, o GMM identificou o intervalo de sociabilidade [4:45, 8:56], enquanto o algoritmo proposto encontrou os intervalos [4:30, 5:15], [6:00, 7:00] e [8:00, 9:00]. Apesar de terem intervalos menores, algumas rotinas identificadas pelo algoritmo proposto também possuem tamanhos que refletem rotinas de sociabilidade com maior variabilidade no início das atividades sociais. Por exemplo, o intervalo [11:00, 14:45] possui uma duração de 3:45h, o que permite inferir que o início da atividade social flutua bastante nesse padrão.

5.4 Análise dos Padrões de Sociabilidade Enriquecidos Por Contexto

Por Contexto

Até o momento, validou-se os intervalos de sociabilidade encontrados, demonstrando sua precisão ao mapear as rotinas sociais. Agora, analisamos a utilidade dos padrões de sociabilidade enriquecidos pelo contexto, vindo a reconhecer sua contribuição para a compreensão da rotina social do paciente monitorado. Essa análise é motivada pela influência das condições de contexto no comportamento social, levando a mudanças comportamentais que podem não ser anormais.

Na Figura 5.3, é possível perceber a diferença da análise sem contexto para os padrões de sociabilidade contextualizados. Para padrões de sociabilidade enriquecidos por contexto, intervalos com durações mais curtas são identificados em comparação com a análise sem contexto. A partir dessa análise, é possível verificar que os padrões de sociabilidade enriquecidos pelo contexto representam melhor a rotina social, uma vez que revelam menor variabilidade no início das atividades sociais. Por exemplo, o intervalo [11:00, 14:45] da análise sem contexto indica uma rotina de sociabilidade com grande variabilidade no início das atividades sociais, enquanto nesse mesmo período um número maior de intervalos de sociabilidade com durações mais curtas foram identificados para a semana ([11:00, 11:45], [12:00, 12:30] e [12:45, 13:30]) e fins de semana ([12:15, 13:00] e [13:15, 14:15]), refletindo em uma rotina social com menor variabilidade.

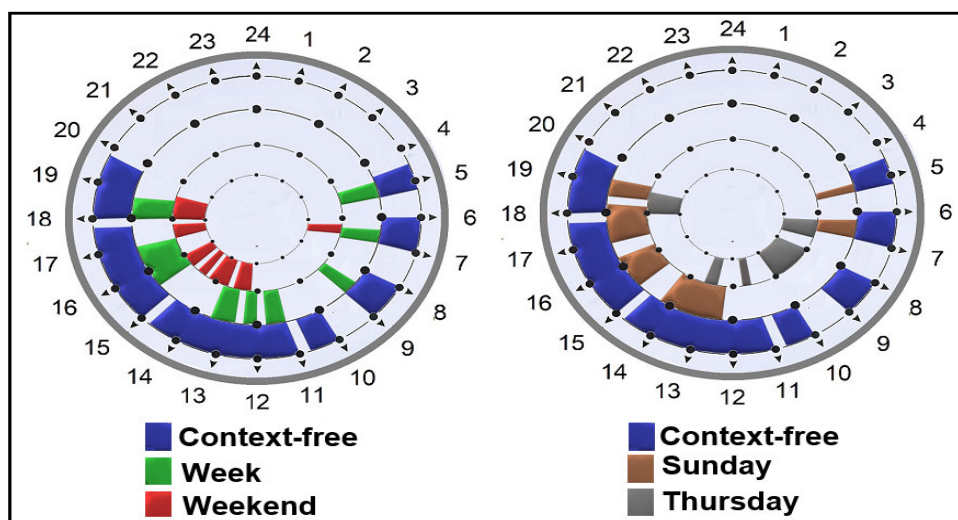


Figura 5.3: Padrões de sociabilidade utilizando CAs.

Em conclusão, a análise realizada demonstra que a não observância de condições contextuais no processo de reconhecimento do comportamento social pode resultar em padrões de sociabilidade inconsistentes. A rotina de sociabilidade real de um indivíduo pode ser ocultada pela análise sem contexto, resultando na mesclagem de intervalos de sociabilidade de todas as CAs. Portanto, o reconhecimento de padrões de sociabilidade enriquecidos pelo contexto apresentado pelo algoritmo proposto fornece uma maneira eficiente de mapear a rotina social dos indivíduos, possibilitando distinguir o comportamento anormal das mudanças esperadas devido a situações específicas, como dias úteis e fins de semana.

5.5 Capacidade de Modelagem da Rotina Social

Este experimento objetiva avaliar a capacidade dos padrões de sociabilidade reconhecidos modelar a rotina social. Especificamente, um padrão de sociabilidade deve explicar o comportamento social do indivíduo monitorado, necessitando este estar correlacionado com a rotina social, pois quanto mais estável for o comportamento social do indivíduo, maior deve ser a capacidade do padrão de prevê-lo. Portanto, realizou-se a análise da associação existente entre o nível de predição dos padrões de sociabilidade extraídos e a estabilidade da rotina social. Para tanto, utilizou-se o método de correlação de *Pearson* com o objetivo de quantificar esta associação. Assim, através do nível de correlação reconhecido nesta avaliação, será possível identificar a capacidade dos padrões para explicar e prever a rotina social dos indivíduos monitorados.

Definiu-se que uma observação social é composta por uma janela de dados de uma semana (i.e., sete dias). Por exemplo, para o contexto *MONDAY* uma observação é composta por um dia de dados, uma vez que uma semana possui apenas um dia com esse contexto. Portanto, o primeiro passo deste experimento é definir o número de observações necessárias para extrair padrões consistentes com o comportamento social do indivíduo monitorado. Nesta tarefa, especificou-se que os padrões de sociabilidade serão extraídos considerando cada dia da semana como um atributo de contexto (i.e., *MONDAY*, *TUESDAY*, *WEDNESDAY*, *THURSDAY*, *FRIDAY*, *SATURDAY* e *SUNDAY*), vindo a verificar e comparar o desempenho preditivo destes ao projetá-los com diferentes quantidades de observações sociais.

A Figura 5.4 apresenta um exemplo do cenário de avaliação da predição dos padrões de sociabilidade, em que considerou-se duas observações para extrair um padrão social. Especificamente, executou-se esta avaliação utilizando uma, duas, três e quatro observações para extrair os padrões sociais, possibilitando comparar o desempenho preditivo de cada configuração. Assim, cada execução desta tarefa consistiu nas seguintes etapas: (i) projetar o padrão de sociabilidade com o número de observações especificadas (i.e., uma, duas, três ou quatro); (ii) medir o índice de similaridade de *Jaccard* entre o padrão social extraído com as próximas observações sociais; e (iii) projetar um novo padrão social a partir das observações avaliadas, vindo a representar o novo padrão de referência.

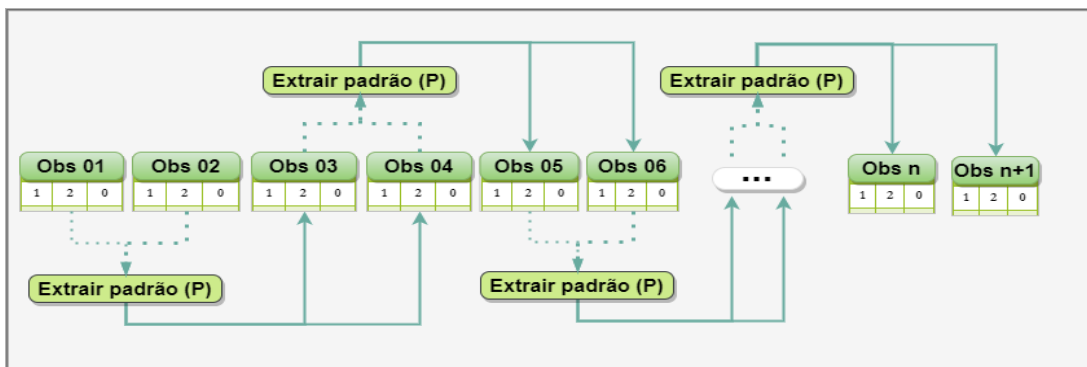


Figura 5.4: Configuração da avaliação da predição do padrão de sociabilidade.

O experimento apresentando acima foi executado para todos os usuários considerando os CAs especificados anteriormente (e.g., *MONDAY*, *TUESDAY* e *SUNDAY*), possibilitando reconhecer o desempenho preditivo dos padrões de sociabilidade para estas condições de contexto. Assim, para reconhecer qual a quantidade de observações melhor modela o comportamento social, foi calculado a média do nível de predição (i.e., similaridade entre padrão social e observações) resultante do experimento executado.

A Figura 5.5 apresenta as médias dos níveis de predições dos padrões de sociabilidade ao utilizar as quantidades de observações avaliadas. A partir deste resultado, é possível identificar que extrair o padrão de sociabilidade utilizando apenas uma observação resulta em menor desempenho preditivo em relação às outras configurações. Entretanto, a extração de padrões sociais a partir das demais quantidades de observações apresentam níveis similares de predições das rotinas sociais, não havendo uma diferença significativa. Assim, é possível concluir que a

abordagem mais eficiente é utilizar duas observações para modelar o comportamento social, uma vez que fornece respostas mais rápidas e com eficiência similar as outras configurações.

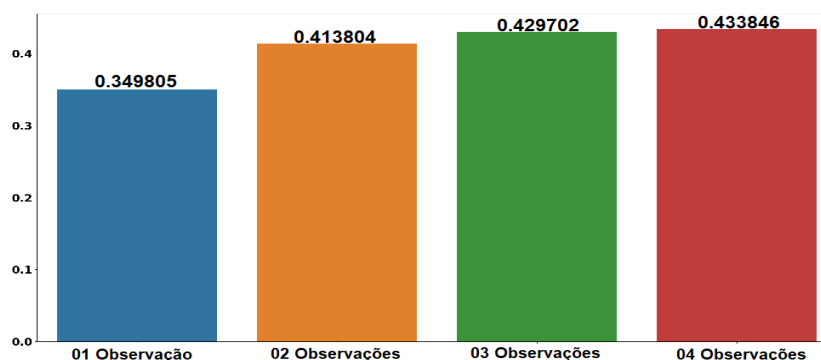


Figura 5.5: Médias das predições dos padrões de sociabilidade.

Após quantificar os níveis de predições dos padrões de sociabilidade extraídos, foi medido a estabilidade das rotinas sociais dos indivíduos que participaram deste estudo. Para tanto, calculou-se a média de similaridade entre um dia e o posterior, ou seja, quantificou-se a similaridade do comportamento social do indivíduo entre dias consecutivos. A configuração deste experimento está representada na Figura 5.6. Os atributos de contextos considerados foram cada dia da semana, semelhante ao experimento anterior. Ao final, identificou-se a média da estabilidade de rotina social de cada indivíduo, permitindo correlacionar esta variável com os níveis de predições dos padrões de sociabilidade.




Figura 5.6: Configuração da avaliação da estabilidade de rotina social.

Adicionalmente, realizou-se a análise da estabilidade de rotina social dos indivíduos, possibilitando reconhecer informações importantes para entender o comportamento social destes. A Figura 5.7 apresenta visualmente a estabilidade da rotina social de cada usuário (i.e., similaridade de comportamento social entre dias), possibilitando identificar que a maioria dos usuários possui rotinas sociais com estabilidade abaixo de 40%. Entretanto, alguns usuários apresentam rotinas mais estáveis, como o u04 e u27. Assim, a partir desta análise, espera-se que os padrões

de sociabilidade expliquem e prevejam de maneira mais consistente o comportamento social de usuários mais estáveis e que apresentem menores níveis de predições ao serem aplicados a indivíduos com rotinas sociais mais instáveis.




Figura 5.7: Estabilidade da rotina social dos indivíduos monitorados.

Até o momento, foram quantificados o desempenho de predição dos padrões de sociabilidades extraídos e o nível de estabilidade da rotina social dos indivíduos. Portanto, agora é possível realizar a análise de associação entre estas duas variáveis utilizando o coeficiente de correlação de *Pearson*, para assim validar o desempenho dos padrões de sociabilidade extraídos. A Figura 5.8 apresenta a plotagem desta associação, em que o eixo y representa a média do nível de predição dos padrões sociais e o eixo x representa a média da estabilidade de rotina social dos indivíduos. Portanto, ao analisar a Figura 5.8, é possível identificar visualmente uma clara correlação entre estas duas variáveis, representando assim uma relação linear. Ao aplicar o método de correlação de *Pearson*, resultou-se em 0.86, que representa uma forte associação positiva entre estas variáveis.

A Figura 5.9 apresenta a plotagem da relação entre o nível de predição dos padrões sociais e a estabilidade da rotina social dos indivíduos para cada condição de contexto, ao passo que a Figura 5.10 apresenta o resultado da aplicação do coeficiente de correlação de *Pearson* entre estas variáveis para cada CA especificado. A partir da Figura 5.9, é possível identificar visualmente uma relação linear entre estas variáveis, ao passo que a Figura 5.10 demonstra que a aplicação da correlação de *Pearson* resulta

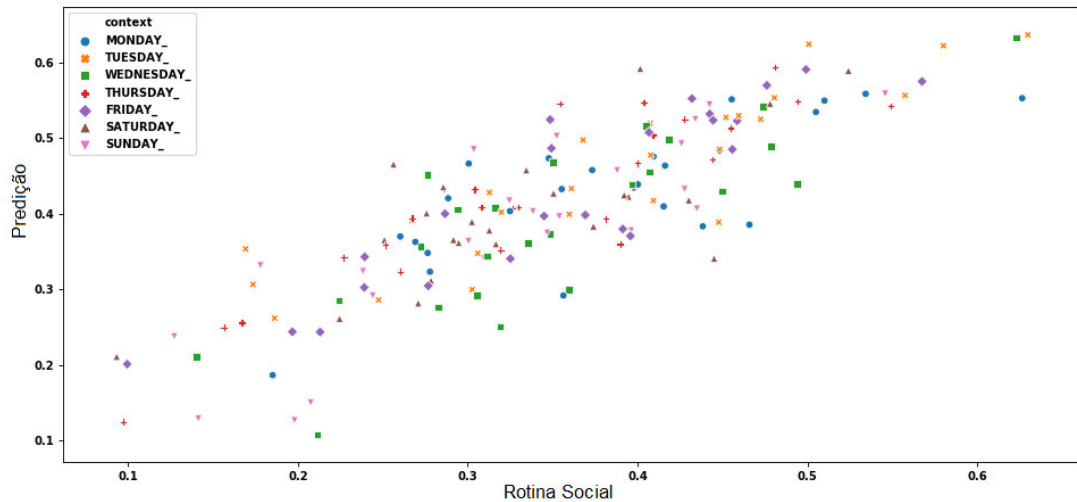


Figura 5.8: Visualização da correlação entre perdição e rotina de sociabilidade.

em valores superiores a 0.7, que representam correlações positivas fortes. Assim, ao analisar estes resultados, é possível reconhecer que o desempenho de predição dos padrões de sociabilidade extraídos permanece relacionado a estabilidade da rotina social em todas as condições de contexto avaliadas.

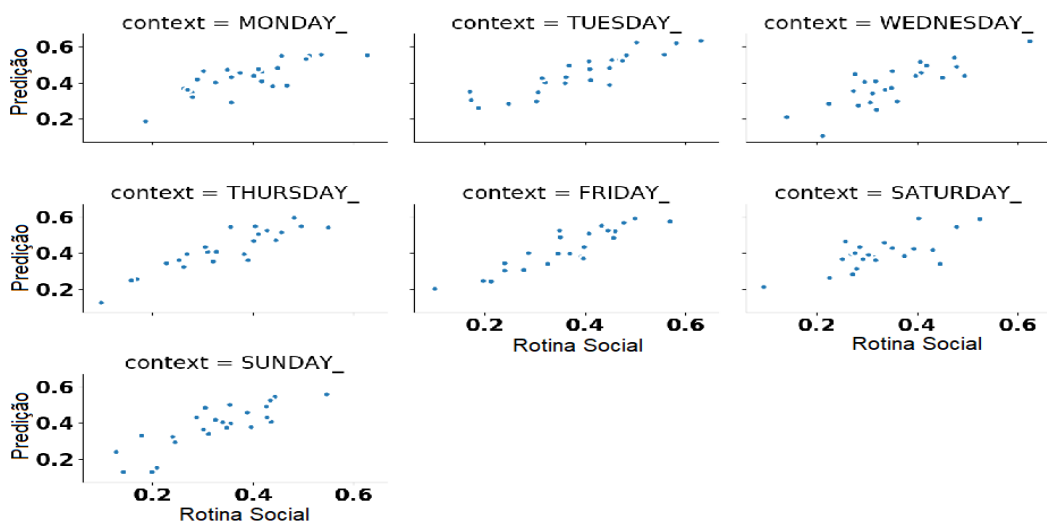


Figura 5.9: Correlação entre perdição e rotina de sociabilidade para cada condição de contexto.

A partir deste experimento, foi possível reconhecer que os padrões sociais extraídos pela solução proposta modelam de forma satisfatória a rotina social dos indivíduos. Portanto, os padrões de sociabilidade podem ser utilizados de forma confiável para entender e prever o comportamento social, uma vez que estes apresentam correlações fortes com a rotina social dos usuários.




Figura 5.10: Média do nível de correlação para cada condição de contexto.

5.6 Validação da Detecção de Mudança de Comportamento Social

Este experimento objetiva verificar a capacidade do mecanismo proposto de detectar mudanças de comportamento social. Em especial, será validado a capacidade da solução proposta de detectar mudanças de rotinas sociais e sua eficácia ao adaptar-se ao novo comportamento social do indivíduo monitorado. Portanto, espera-se que o mecanismo desenvolvido seja capaz de identificar com precisão observações que representem comportamentos sociais anormais, assim como a efetiva mudança de rotina social.

O primeiro passo deste experimento foi definir o limiar de similaridade que representa uma mudança de comportamento social. Para tanto, calculou-se a média e o desvio padrão da estabilidade da rotina social de todos usuários, vindo a representar este limiar como $[\mu + \sigma]$. Assim, similar a configuração do experimento anterior (Figura 5.6), mediu-se a média e o desvio padrão da similaridade do comportamento social dos indivíduos entre dias consecutivos, em que considerou-se cada dia da semana como um atributo de contexto (e.g., *MONDAY*, *FRIDAY* e *SUNDAY*). Ao final, identificou-se que os usuários apresentam em média 35.4% de estabilidade em suas rotinas sociais, apresentando também 10.7% de desvio padrão. Assim, especificou-se o limiar de mudança de comportamento social como 46.1%.

Com o objetivo de simular a mudança de comportamento social, combinou-se os dados de dois usuários que apresentam rotinas sociais significativamente diferentes. Para tanto, selecionou-se para este experimento usuários que apresentaram rotinas sociais mais estáveis (Figura 5.7) no experimento anterior. Assim, reconheceu-

se que os usuários u27 e u04 possuem rotinas sociais com estabilidade satisfatória para este experimento.

A Figura 5.11 apresenta a rotina social dos indivíduos u27 e u04, em que cada célula representa a quantidade de socialização em um determinado slot de tempo de 30 min ($t = \frac{24}{0.5}$). Assim, a partir desta visualização, é possível reconhecer uma clara mudança de comportamento social no limite que separa os dados dos dois usuários. Neste cenário, espera-se que o mecanismo proposto seja capaz de detectar comportamento anormais ao começar a processar os dados do usuário u04, vindo a reconhecer o mais rápido possível a efetiva mudança da rotina social. Adicionalmente, a solução proposta também deve ser capaz de adaptar-se ao novo padrão, fornecendo um novo modelo capaz de explicar e prever a nova rotina social.




Figura 5.11: Junção da rotina social dos usuários u27 e u04.

A partir dos dados que contém a rotina social dos usuários selecionados, criou-se o fluxo de eventos sociais de entrada para a solução proposta, a qual emitiu as detecções de mudanças de comportamentos sociais apresentadas na Tabela 5.1. Ao avaliar as respostas emitidas, reconheceu-se que o mecanismo proposto se comportou de maneira consistente, vindo a reconhecer comportamentos anormais e mudanças de rotinas sociais de maneira precisa. Especificamente, enquanto a solução proposta processava os dados do usuário u27 os níveis de similaridade apresentados eram altos (i.e., similaridade > 46.1%), não representando mudanças comportamentais. A partir

da primeira observação do usuário u04 (i.e., observação 07), o mecanismo começou a detectar comportamentos sociais anormais, vindo a reconhecer a efetiva mudança de rotina social ao extrair o primeiro padrão utilizando dados deste usuário (i.e., 5° padrão). Este novo padrão de referência permaneceu consistente com as próximas observações sociais processadas, permitindo inferir que a solução proposta se adaptou de maneira eficiente ao novo padrão.

Tabela 5.1: Processamento da detecção de mudança de comportamento social.

Observação	Uid	Similaridade	Mudança
03	u27	0.520000	Comportamento social normal
04	u27	0.727273	Comportamento social normal
2° Padrão	u27	0.680000	Manteve o padrão de referência
05	u27	0.652174	Comportamento social normal
06	u27	0.520000	Comportamento social normal
3° Padrão	u27	0.640000	Manteve o padrão de referência
07	u27	0.576923	Comportamento social normal
08	u27	0.555556	Comportamento social normal
4° Padrão	u27	0.666667	Manteve o padrão de referência
07	u04	0.411765	Comportamento social anômalo
08	u04	0.444444	Comportamento social anômalo
5° Padrão	u04	0.428571	Mudança de rotina social detectada
09	u04	0.657143	Comportamento social normal
10	u04	0.647143	Comportamento social normal
6° Padrão	u04	0.647059	Manteve o padrão de referência
11	u04	0.540541	Comportamento social normal
12	u04	0.575758	Comportamento social normal
7° Padrão	u04	0.600000	Manteve o padrão de referência
13	u04	0.666667	Comportamento social normal
14	u04	0.685714	Comportamento social normal
8° Padrão	u04	0.666667	Manteve o padrão de referência
15	u04	0.647059	Comportamento social normal

A partir deste experimento foi possível validar o comportamento do mecanismo de detecção de mudança de comportamento social, constatando que este é capaz de reconhecer observações sociais anormais e mudanças de rotinas sociais. Assim, reconheceu-se a utilidade deste mecanismo no processo de monitoramento da saúde mental, uma vez que este é capaz de emitir notificações de

mudanças comportamentais que podem representar indícios do início, presença ou desenvolvimento de transtornos mentais.

5.7 Discussões

Este capítulo apresentou uma avaliação experimental que valida a utilidade dos padrões de sociabilidade identificados pela solução proposta para modelar a rotina social. Para tanto, executou-se a avaliação dos componentes responsáveis por detectar padrões de sociabilidade enriquecidos por contexto e reconhecer mudanças de comportamentos sociais. A partir dos experimentos realizados, constata-se que a solução proposta modela adequadamente a rotina social dos indivíduos, permitindo utilizá-los para reconhecer seus hábitos sociais.

O primeiro experimento constatou a precisão dos padrões de sociabilidade reconhecidos pelo algoritmo proposto, que consisti em comparar a similaridade entre os intervalos sociais reconhecidos pela solução proposta com os intervalos identificados por um algoritmo de processamento em lote. A partir desta avaliação, identificou-se que os algoritmos comparados identificam padrões de sociabilidade com 86.33% de similaridade, permitindo inferir uma precisão significativa do algoritmo proposto.

No segundo experimento, realizou-se a análise da utilidade de reconhecer padrões de sociabilidade sensíveis ao contexto, que consisti em investigar a contribuição desta propriedade da solução proposta para o entendimento da rotina social do indivíduo monitorado. A partir desta análise, reconhece-se que a rotina social pode ser ocultada pela análise sem contexto, resultando em padrões inconsistentes. Assim, a identificação de padrões sociais baseados em contexto melhora o entendimento da rotina social, uma vez que permite distinguir o comportamento anormal das mudanças esperadas devido ao contexto.

Também executou-se a avaliação da capacidade dos padrões de sociabilidade reconhecidos pela solução proposta de modelar a rotina social dos indivíduos. Especificamente, identificou-se que o desempenho de predição dos padrões sociais está fortemente correlacionado com a estabilidade da rotina social, permitindo reconhecer que o mecanismo proposto detecta padrões consistentes com

o comportamento social dos indivíduos monitorados. Portanto, estes padrões podem ser utilizados de forma confiável para entender e prever a rotina social dos usuários.

Por fim, validou-se o mecanismo de detecção de mudança de comportamento social, que consisti em analisar sua consistência ao processar dados contendo mudanças de rotina social. A partir deste experimento, reconheceu-se que este mecanismo é capaz de detectar e notificar a ocorrência de comportamentos sociais anormais e mudanças efetivas de rotina social de maneira precisa, demonstrando que este pode ser usado para auxiliar os profissionais da saúde mental no processo de monitoramento do comportamento social de seus pacientes.

6 Conclusões e Trabalhos Futuros

Este trabalho apresentou uma abordagem de monitoramento da saúde mental através da consciência da situação social, que é capaz de detectar padrões de sociabilidades sensíveis ao contexto e mudanças de comportamentos sociais. Especificamente, foi introduzido um algoritmo baseado na FPM capaz de reconhecer os intervalos do dia nos quais o indivíduo monitorado habitualmente socializa, vindo a distinguir este comportamento para condições de contextos específicas. Posteriormente, foi apresentada a implementação do algoritmo proposto através dos conceitos do CEP, vindo a especificar uma EPN capaz de detectar padrões sociais enriquecidos por contexto de maneira incremental e online. Também foi demonstrada a estratégia implementada para identificar mudanças de comportamentos sociais, sendo capaz de notificar as partes interessadas sobre comportamentos sociais anormais e mudanças efetivas de rotina social de maneira automática. Adicionalmente, apresentou-se a modelagem do conhecimento especialista através dos conceitos da lógica *fuzzy*, que permitiu o mecanismo de detecção de mudanças comportamentais emitir notificações considerando a natureza imprecisa desta tarefa.

A partir da avaliação realizada, identificou-se a validade dos padrões de sociabilidade reconhecidos, que apresentam um nível de similaridade de 86% com um algoritmo de processamento em lote. Essa avaliação também demonstrou que a abordagem enriquecida pelo contexto oferecida pela solução proposta permite distinguir mudanças de rotinas esperadas devido ao contexto de comportamentos sociais anormais, proporcionando uma melhor compreensão da rotina social dos indivíduos monitorados.

A avaliação realizada também constatou que o desempenho de predição dos padrões de sociabilidade extraídos apresenta fortes correlações com a estabilidade de rotina social, possibilitando reconhecer que estes padrões podem ser utilizados para explicar e prever o comportamento social dos indivíduos de maneira consistente. E por fim, validou-se a abordagem de detecção de mudanças de comportamentos sociais, que verificou que este componente é capaz de identificar comportamentos

sociais anormais e efetivas mudanças de rotina social de maneira eficiente e precisa, demonstrando assim sua utilidade para o monitoramento da saúde mental.

6.1 Contribuições

Considera-se que as principais contribuições científicas desta pesquisa são:

- A condução de uma revisão abrangente da conscientização da situação social aplicada ao monitoramento e avaliação da saúde mental. Especificamente, esta revisão fornece uma taxonomia dos estudos presentes na literatura, classificando-os em estudos de detecção e quantificação de sociabilidade e aqueles que visam classificar, prever e associar o comportamento social identificado ao estado mental.
- A proposição de um algoritmo capaz de realizar o aprendizado incremental de padrões de sociabilidade enriquecidos por contexto, assim como a sua implementação através de uma EPN.
- A concepção de um mecanismo capaz de detectar comportamentos sociais anormais e a efetiva mudança de rotina social.

6.2 Trabalhos Futuros

Os próximos passos desta pesquisa vão em direção aos seguintes objetivos:

- Conceber um mecanismo capaz de emitir alertas quando padrões de sociabilidade pré-especificados pelos profissionais especializados forem detectados, permitindo a identificação de situações de interesse quase em tempo real.
- Desenvolver um sistema capaz de criar visualizações dos padrões de sociabilidade de maneira adequada para os profissionais especializados, vindo a facilitar a avaliação do comportamento social dos indivíduos monitorados.
- Projetar um sistema capaz de realizar inferências de situações sociais através de dados de contexto disponíveis nos dispositivos ubíquos.

- Desenvolver uma ferramenta capaz de extrair padrões comportamentais a partir dos padrões de sociabilidade identificados de um conjunto de indivíduos.
- Realizar avaliações da solução proposta com profissionais e seus pacientes.

6.3 Publicações

Para divulgação dos resultados desta pesquisa, foram escritos alguns artigos, que são apresentadas a seguir. Para cada publicação, informa-se o tipo de publicação, status em que ela se encontra e o Qualis do periódico ou conferência, se disponível.

- Ariel Teles, Flávio Barros, Ivan Rodrigues, Allan Barbosa, Francisco Silva, Luciano Coutinho e Silmar Teixeira. Internet of Things applied to MentalHealth: Concepts, Applications, and Perspectives. Role of IoT and ICT for Healthcare Applications, EAI/Springer Innovations in Communications and Computing, 2020.

Tipo de publicação: Capítulo de Livro.

Situação: Aceito.

- Ivan Rodrigues, Ariel Teles, Francisco Silva, Davi Viana, Luciano Coutinho, Flávio Barros, e Markus Endler. Mental Health Ubiquitous Monitoring Supported by Social Situation Awareness: A Systematic Review. Journal of Biomedical Informatics - JBI, 2020.

Tipo de publicação: Periódico.

Qualis CAPES(2013-2016): A2 em Ciência da Computação.

Situação: Em revisão.

- Ivan Rodrigues, Ariel Teles, Francisco Silva, Luciano Coutinho. Mental Health Ubiquitous Monitoring: Detecting Context-Enriched Sociability Patterns Through Complex Event Processing. In: Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos - SBRC, 2020, Rio de Janeiro, Rio de Janeiro, 2020.

Tipo de publicação: Conferência.

Qualis CAPES(2013-2016): B2 em Ciência da Computação.

Situação: Submetido.

Referências Bibliográficas

- [1] S. Abdullah, M. Matthews, E. Frank, G. Doherty, G. Gay, and T. Choudhury. Automatic detection of social rhythms in bipolar disorder. *Journal of the American Medical Informatics Association*, 23(3):538–543, 2016.
- [2] C. C. Aggarwal, M. A. Bhuiyan, and M. A. Hasan. *Frequent Pattern Mining Algorithms: A Survey*, pages 19–64. Springer International Publishing, Cham, 2014.
- [3] R. Agrawal, T. Imieliński, and A. Swami. Mining association rules between sets of items in large databases. *SIGMOD Rec.*, 22(2):207–216, June 1993.
- [4] O. Y. Al-Jarrah, P. D. Yoo, S. Muhaidat, G. K. Karagiannidis, and K. Taha. Efficient machine learning for big data: A review. *Big Data Research*, 2(3):87 – 93, 2015. Big Data, Analytics, and High-Performance Computing.
- [5] A. Althubaiti. Information bias in health research: Definition, pitfalls, and adjustment methods. *Journal of Multidisciplinary Healthcare*, 9:211, 2016.
- [6] M. Antonelli, P. Ducange, F. Marcelloni, and A. Segatori. A novel associative classification model based on a fuzzy frequent pattern mining algorithm. *Expert Systems with Applications*, 42(4):2086–2097, 2015.
- [7] M. Baena-Garcia, J. del Campo-Ávila, R. Fidalgo, A. Bifet, R. Gavalda, and R. Morales-Bueno. Early drift detection method. In *Fourth international workshop on knowledge discovery from data streams*, volume 6, pages 77–86, 2006.
- [8] I. Barnett, J. Torous, P. Staples, L. Sandoval, M. Keshavan, and J.-P. Onnela. Relapse prediction in schizophrenia through digital phenotyping: a pilot study. *Neuropsychopharmacology*, 43(8):1660, 2018.
- [9] T. Beiwinkel, S. Kindermann, A. Maier, C. Kerl, J. Moock, G. Barbian, and W. Rössler. Using smartphones to monitor bipolar disorder symptoms: a pilot study. *JMIR mental health*, 3(1), 2016.

- [10] J. Benesty, J. Chen, Y. Huang, and I. Cohen. Pearson correlation coefficient. In *Noise reduction in speech processing*, pages 1–4. Springer, 2009.
- [11] M. E. Beutel, E. M. Klein, E. Brähler, I. Reiner, C. Jünger, M. Michal, J. Wiltink, P. S. Wild, T. Münzel, K. J. Lackner, et al. Loneliness in the general population: prevalence, determinants and relations to mental health. *BMC psychiatry*, 17(1):97, 2017.
- [12] A. Bhandari, A. Gupta, and D. Das. Improved apriori algorithm using frequent pattern tree for real time applications in data mining. *Procedia Computer Science*, 46:644–651, 2015.
- [13] A. Bifet and R. Gavaldà. Learning from time-changing data with adaptive windowing. In *Proceedings of the 2007 SIAM international conference on data mining*, pages 443–448. SIAM, 2007.
- [14] C. M. Bishop. *Pattern recognition and machine learning*. springer, 2006.
- [15] P. Bonilla-Escribano, D. Ramírez, A. Sedano-Capdevila, J. J. Campaña-Montes, E. Baca-García, P. Courtet, and A. Artés-Rodríguez. Assessment of e-social activity in psychiatric patients. *IEEE Journal of Biomedical and Health Informatics*, 23(6):2247–2256, Nov 2019.
- [16] M. Boukhechba, A. R. Daros, K. Fua, P. I. Chow, B. A. Teachman, and L. E. Barnes. Demonicsalmon: Monitoring mental health and social interactions of college students using smartphones. *Smart Health*, 9-10:192–203, 2018. CHASE 2018 Special Issue.
- [17] R. A. Calvo and D. Peters. *Positive Computing: Technology for Well-Being and Human Potential*. The MIT Press, 2014.
- [18] I. Carreras, A. Matic, P. Saar, and V. Osmani. Comm2sense: Detecting proximity through smartphones. In *2012 IEEE International Conference on Pervasive Computing and Communications Workshops*, pages 253–258, 2012.
- [19] Y. Chen, B. Gao, L. Jiang, K. Yin, J. Gu, and W. L. Woo. Transfer learning for wearable long-term social speech evaluations. *IEEE Access*, 6:61305–61316, 2018.

- [20] P. I. Chow, K. Fua, Y. Huang, W. Bonelli, H. Xiong, L. E. Barnes, and B. A. Teachman. Using mobile sensing to test clinical models of depression, social anxiety, state affect, and social isolation among college students. *Journal of Medical Internet Research*, 19(3):e62, 2017.
- [21] N. Cummins, S. Scherer, J. Krajewski, S. Schnieder, J. Epps, and T. F. Quatieri. A review of depression and suicide risk assessment using speech analysis. *Speech Communication*, 71:10–49, 2015.
- [22] C. W. De Silva. *Intelligent control: fuzzy logic applications*. CRC press, 2018.
- [23] T. M. Do and D. Gatica-Perez. Human interaction discovery in smartphone proximity networks. *Personal and Ubiquitous Computing*, 17(3):413–431, 2013.
- [24] P. Eskes, M. Spruit, S. Brinkkemper, J. Vorstman, and M. J. Kas. The sociability score: App-based social profiling from a healthcare perspective. *Computers in Human Behavior*, 59:39–48, 2016.
- [25] EsperTech. Espertech, esper – complex event processing. <http://www.espertech.com/esper/>. Online; Accessed: Jul 7, 2019.
- [26] O. Etzion, P. Niblett, and D. C. Luckham. *Event processing in action*. Manning Greenwich, 2011.
- [27] A. Exler, M. Braith, K. Mincheva, A. Schankin, and M. Beigl. Smartphone-based estimation of a user being in company or alone based on place, time, and activity. In K. Murao, R. Ohmura, S. Inoue, and Y. Gotoh, editors, *Mobile Computing, Applications, and Services*, pages 74–89, Cham, 2018. Springer International Publishing.
- [28] E. B. Fauth, D. Gerstorff, N. Ram, and B. Malmberg. Changes in depressive symptoms in the context of disablement processes: Role of demographic characteristics, cognitive function, health, and social support. *The Journals of Gerontology: Series B*, 67B(2):167–177, 2011.
- [29] M. Fowler. *Refactoring: improving the design of existing code*. Addison-Wesley Professional, 2018.

- [30] J. Gama, P. Medas, G. Castillo, and P. Rodrigues. Learning with drift detection. In *Brazilian symposium on artificial intelligence*, pages 286–295. Springer, 2004.
- [31] J. Gong, Y. Huang, P. I. Chow, K. Fua, M. S. Gerber, B. A. Teachman, and L. E. Barnes. Understanding behavioral dynamics of social anxiety among college students through smartphone sensors. *Information Fusion*, 49:57 – 68, 2019.
- [32] S. Grav, O. Hellzèn, U. Romild, and E. Stordal. Association between social support and depression in the general population: the hunt study, a cross-sectional survey. *Journal of Clinical Nursing*, 21(1 [U+2010] 2):111–120, 2012.
- [33] S. Grav, O. Hellzèn, U. Romild, and E. Stordal. Association between social support and depression in the general population: the hunt study, a cross-sectional survey. *Journal of clinical nursing*, 21(1-2):111–120, 2012.
- [34] J. Gu, B. Gao, Y. Chen, L. Jiang, Z. Gao, X. Ma, Y. Ma, W. L. Woo, and J. Jin. Wearable social sensing: Content-based processing methodology and implementation. *IEEE Sensors Journal*, 17(21):7167–7176, 2017.
- [35] J. Han, H. Cheng, D. Xin, and X. Yan. Frequent pattern mining: current status and future directions. *Data mining and knowledge discovery*, 15(1):55–86, 2007.
- [36] G. M. Harari, S. D. Gosling, R. Wang, F. Chen, Z. Chen, and A. T. Campbell. Patterns of behavior change in students over an academic term: A preliminary study of activity and sociability behaviors using smartphone sensing methods. *Computers in Human Behavior*, 67:129–138, 2017.
- [37] K. E. Heron and J. M. Smyth. Ecological momentary interventions: Incorporating mobile technology into psychosocial and health behaviour treatments. *British Journal of Health Psychology*, 15(1):1–39, 2010.
- [38] S. Homayoun, A. Dehghantanha, M. Ahmadzadeh, S. Hashemi, and R. Khayami. Know abnormal, find evil: frequent pattern mining for ransomware threat hunting and intelligence. *IEEE transactions on emerging topics in computing*, 2017.
- [39] I. Khamassi, M. Sayed-Mouchaweh, M. Hammami, and K. Ghédira. Discussion and review on evolving data streams and concept drift adapting. *Evolving systems*, 9(1):1–23, 2018.

- [40] B. Kitchenham. Procedures for performing systematic reviews. Technical report, Keele University, Department of Computer Science, Keele University, UK, 2004.
- [41] B. Kitchenham and S. Charters. Guidelines for performing systematic literature reviews in software engineering. Technical Report EBSE 2007-001, Keele University and University of Durham, 2007.
- [42] P. Lago, C. Roncancio, and C. Jiménez-Guarín. Learning and managing context enriched behavior patterns in smart homes. *Future Generation Computer Systems*, 91:191 – 205, 2019.
- [43] N. D. Lane, M. Lin, M. Mohammod, X. Yang, H. Lu, G. Cardone, S. Ali, A. Doryab, E. Berke, A. T. Campbell, and T. Choudhury. Bewell: Sensing sleep, physical activities and social interactions to promote wellbeing. *Mobile Networks and Applications*, 19(3):345–359, 2014.
- [44] U. Lee, K. Han, H. Cho, K.-M. Chung, H. Hong, S.-J. Lee, Y. Noh, S. Park, and J. M. Carroll. Intelligent positive computing with mobile, wearable, and iot devices: Literature review and research directions. *Ad Hoc Networks*, 83:8–24, 2019.
- [45] D. Luckham. The power of events: An introduction to complex event processing in distributed enterprise systems. In N. Bassiliades, G. Governatori, and A. Paschke, editors, *Rule Representation, Interchange and Reasoning on the Web*, pages 3–3, Berlin, Heidelberg, 2008. Springer Berlin Heidelberg.
- [46] A. Matic, V. Osmani, and O. Mayora. *Automatic Sensing of Speech Activity and Correlation with Mood Changes*, chapter 9, pages 195–205. Springer Berlin Heidelberg, Berlin, Heidelberg, 2013.
- [47] F. M. McNeill and E. Thro. *Fuzzy logic: a practical approach*. Academic Press, 2014.
- [48] E. Miluzzo, N. D. Lane, K. Fodor, R. Peterson, H. Lu, M. Musolesi, S. B. Eisenman, X. Zheng, and A. T. Campbell. Sensing meets mobile social networks: The design, implementation and evaluation of the cenceme application. In *Proceedings of the 6th ACM Conference on Embedded Network Sensor Systems, SenSys '08*, pages 337–350, New York, NY, USA, 2008. ACM.
- [49] J.-K. Min, J. Wiese, J. I. Hong, and J. Zimmerman. Mining smartphone data to classify life-facets of social relationships. In *Proceedings of the 2013 Conference on*

- Computer Supported Cooperative Work, CSCW '13*, pages 285–294, New York, NY, USA, 2013. ACM.
- [50] L. Myers and M. J. Sirois. Spearman correlation coefficients, differences between. *Encyclopedia of statistical sciences*, 12, 2004.
- [51] S. Nasreen, M. A. Azam, K. Shehzad, U. Naeem, and M. A. Ghazanfar. Frequent pattern mining algorithms for finding associated frequent patterns for data streams: a survey. *Procedia Computer Science*, 37:109–116, 2014.
- [52] J.-P. Onnela, B. N. Waber, A. Pentland, S. Schnorf, and D. Lazer. Using sociometers to quantify social interaction patterns. *Scientific reports*, 4:5604, 2014.
- [53] E. Ono, T. Nozawa, T. Ogata, M. Motohashi, N. Higo, T. Kobayashi, K. Ishikawa, K. Ara, K. Yano, and Y. Miyake. Fundamental deliberation on exploring mental health through social interaction pattern. In *2012 ICME International Conference on Complex Medical Engineering (CME)*, pages 321–326, 2012.
- [54] D. Pilgrim. *Key concepts in mental health*. Sage, 2017.
- [55] L. Qiu, H. Rui, and A. Whinston. When cellular capacity meets wifi hotspots: A smart auction system for mobile data offloading. In *2015 48th Hawaii International Conference on System Sciences*, pages 4898–4907, 2015.
- [56] R. Real and J. M. Vargas. The probabilistic basis of jaccard’s index of similarity. *Systematic biology*, 45(3):380–385, 1996.
- [57] A. Sarda, S. Munuswamy, S. Sarda, and V. Subramanian. Using passive smartphone sensing for improved risk stratification of patients with depression and diabetes: Cross-sectional observational study. *mHealth and uHealth*, 7(1):e11041, 2019.
- [58] D. L. Schacter. The seven sins of memory: Insights from psychology and cognitive neuroscience. *American Psychologist*, 54(3):182, 1999.
- [59] S. Servia-Rodríguez, K. K. Rachuri, C. Mascolo, P. J. Rentfrow, N. Lathia, and G. M. Sandstrom. Mobile sensing at the service of mental well-being: A large-scale longitudinal study. In *Proceedings of the 26th International Conference on World Wide Web, WWW '17*, pages 103–112, Republic and Canton of Geneva, Switzerland, 2017. International World Wide Web Conferences Steering Committee.

- [60] S. Shiffman, A. A. Stone, and M. R. Hufford. Ecological momentary assessment. *Annual Review of Clinical Psychology*, 4(1):1–32, 2008.
- [61] S. A. Shinde, P. A. Nimkar, S. P. Singh, V. D. Salpe, and Y. R. Jadhav. Mqtt-message queuing telemetry transport protocol. *International Journal of Research*, 3(3):240–244, 2016.
- [62] A. Soares Teles, A. Rocha, F. José da Silva e Silva, J. Correia Lopes, D. O’Sullivan, P. Van de Ven, and M. Endler. Enriching mental health mobile assessment and intervention with situation awareness. *Sensors*, 17(1 – 127), 2017.
- [63] A. S. Teles, A. Rocha, F. J. Silva, J. C. Lopes, D. OSullivan, P. V. d. Ven, and M. Endler. Towards situation-aware mobile applications in mental health. In *2016 IEEE 29th International Symposium on Computer-Based Medical Systems (CBMS)*, pages 349–354, 2016.
- [64] J. Torous, , J.-P. Onnela, and M. Keshavan. New dimensions and new tools to realize the potential of rdod: digital phenotyping via smartphones and connected devices. *Translational Psychiatry*, 7, 2017.
- [65] J. Torous, M. V. Kiang, J. Lorme, and J.-P. Onnela. New tools for new research in psychiatry: A scalable and customizable platform to empower data driven smartphone research. *JMIR Mental Health*, 3(2), 2016.
- [66] J. Torous, P. Staples, I. Barnett, L. R. Sandoval, M. Keshavan, and J.-P. Onnela. Characterizing the clinical relevance of digital phenotyping data quality with applications to a cohort with schizophrenia. *npj Digital Medicine*, 1(1), 2018.
- [67] T. J. Trull and U. Ebner-Priemer. Ambulatory assessment. *Annual Review of Clinical Psychology*, 9(1):151–176, 2013.
- [68] D. Umberson and J. K. Montez. Social relationships and health: A flashpoint for health policy. *Journal of Health and Social Behavior*, 51:S54–S66, 2010.
- [69] T. F. Van de Mortel et al. Faking it: social desirability response bias in self-report research. *Australian Journal of Advanced Nursing, The*, 25(4):40, 2008.
- [70] F. Wahle, T. Kowatsch, E. Fleisch, M. Rufer, and S. Weidt. Mobile sensing and support for people with depression: a pilot trial in the wild. *mHealth and uHealth*, 4(3), 2016.

- [71] J. Wang. *Encyclopedia of business analytics and optimization*. IGI Global, 2014.
- [72] R. Wang, F. Chen, Z. Chen, T. Li, G. Harari, S. Tignor, X. Zhou, D. Ben-Zeev, and A. T. Campbell. *StudentLife: Using Smartphones to Assess Mental Health and Academic Performance of College Students*, pages 7–33. Springer International Publishing, Cham, 2017.
- [73] K. Weiss, T. M. Khoshgoftaar, and D. Wang. A survey of transfer learning. *Journal of Big data*, 3(1):9, 2016.
- [74] A. Wongkoblap, M. A. Vadillo, and V. Curcin. Researching mental health disorders in the era of social media: Systematic review. *Journal of Medical Internet Research*, 19(6):e228, 2017.
- [75] World Health Organization. Mental health action plan 2013-2020. Technical report, World Health Organization, WHO Document Production Services, 2013. Online; Accessed: Jan 11, 2019.
- [76] C. Wu, M. Boukhechba, L. Cai, L. E. Barnes, and M. S. Gerber. Improving momentary stress measurement and prediction with bluetooth encounter networks. *Smart Health*, 9-10:219–231, 2018. CHASE 2018 Special Issue.
- [77] L. A. Zadeh. Fuzzy logic. *Computer*, 21(4):83–93, April 1988.
- [78] I. Žliobaitė. Learning under concept drift: an overview. *arXiv preprint arXiv:1010.4784*, 2010.

A Apêndice A - Visão Geral dos Trabalhos Selecionados na RSL

A.1 Resumo dos Estudos Selecionados

Nas tabelas A.1 e A.2, apresenta-se um resumo de algumas características dos estudos selecionados ordenados por ano de publicação, incluindo o estado de saúde mental investigado, duração do estudo, tipo de participantes, sensores utilizados, principais resultados. A seguir, demonstram-se informações detalhadas sobre cada uma dessas características.

Tabela A.1: Resumo dos estudos revisados - Parte I.

Referência	Estado Mental	Participantes	Duração	Sensor
Ono et al. (2012) [53]	Estresse	Funcionários e usuários idosos	34 dias	Infravermelho
Matic et al. (2013) [46]	Estado afetivo	Trabalhadores do conhecimento	5 dias	Acelerômetro
Lane et al. (2014) [43]	Bem estar	Estudantes e pesquisadores médicos	19 dias	Microfone
Wahle et al. (2016) [70]	Depressão	Público em geral (sem critério de seleção)	2 semanas	Registros de chamadas e mensagens de texto
Beiwinkel et al. (2016) [9]	Transtorno bipolar	Pacientes	12 meses	Registros de chamadas e mensagens de texto
Eskes et al. (2016) [24]	Deficit social	Público em geral (sem critério de seleção)	11 dias	<i>Bluetooth</i> , GPS, and registros de chamadas
Abdullah et al. (2016) [1]	Transtorno bipolar	Pacientes	4 semanas	GPS e microfone

Servia-Rodríguez et al. (2017) [59]	Humor	Público em geral (sem critério de seleção)	3 anos	Registros de chamadas e mensagens de texto
Chow et al. (2017) [20]	Isolamento social, estado afetivo, depressão e ansiedade social	Estudantes	2 semanas	GPS
Wang et al. (2017) [72]	Depressão e estresse	Estudantes	66 dias	<i>Bluetooth</i> and microfone
Gu et al. (2017) [34]	Ansiedade	Estudantes	10 horas	Microfone
Harari et al. (2017) [36]	Bem estar	Estudantes	66 dias	Microfone
Exler et al. (2018) [27]	Isolamento social	Público em geral (sem critério de seleção)	3 semanas	GPS e acelerômetro
Wu et al. (2018) [76]	Estresse	Estudantes	66 dias	<i>Bluetooth</i>
Chen et al. (2018) [19]	Espectro do autismo	Estudantes	4 semanas	Microfone
Boukhechba et al. (2018) [16]	Ansiedade social e depressão	Estudantes	14 dias	GPS, registros de chamadas e mensagens de texto
Barnett et al. (2018) [8]	Esquizofrenia	Pacientes	3 meses	Registros de chamadas e mensagens de texto
Sarda et al. (2019) [57]	Depressão	Pacientes	20 semanas	Registros de chamadas e GPS
Gong et al. (2019) [31]	Ansiedade social	Estudantes	14 dias	GPS, acelerômetro, registros de chamadas e mensagens de texto

Bonilla-Escribano (2019) [15]	Abuso de substâncias, distúrbios psicóticos, depressão e transtornos obsessivos	Pacientes	30 dias	Uso de APPs e registros de chamadas
-------------------------------	---	-----------	---------	-------------------------------------

Tabela A.2: Resumo dos estudos revisados - Parte II.

Ref.	Principais resultados
[53]	Foram encontradas correlações entre interações sociais (i.e., frequência, duração e número de pessoas envolvidas) e níveis de estresse.
[46]	Foi apresentada uma abordagem para detectar a atividade da fala (i.e, frequências vocais que correspondem à fala humana) através de um acelerômetro montado no peito do participante. Os resultados deste estudo constataram correlações entre o número de atividades de fala e alterações de humor autorrelatadas.
[43]	<i>BeWell</i> foi proposto para fornecer <i>feedback</i> sobre três dimensões da saúde: sono, atividade física e interação social.
[70]	Um modelo de classificação foi desenvolvido para identificar indivíduos depressivos com 72,5% de sensibilidade e 60,8% especificidade.
[9]	Foi demonstrado que a comunicação social através do <i>smartphone</i> pode prever episódios maníacos e depressivos em pacientes com transtorno bipolar.
[24]	Foi desenvolvido um método estatístico capaz de atribuir uma pontuação que reflete o nível de sociabilidade dos indivíduos.
[1]	Foi desenvolvido um modelo computacional para estimar automaticamente o <i>Social Rhythm Metric</i> , um questionário clinicamente validado de estabilidade e ritmicidade para indivíduos com transtorno bipolar.
[59]	Foram encontradas relações entre as rotinas sociais dos indivíduos e seu humor em um conjunto de dados em larga escala.
[20]	Foram reconhecidas relações temporais entre afeto positivo, afeto negativo, depressão e ansiedade social com o tempo gasto em casa.
[72]	Foram identificadas correlações entre os níveis de estresse e depressão com a frequência e duração das interações sociais de um grupo de estudantes.
[34]	Foi desenvolvida uma plataforma de computação vestível para extrair e analisar automaticamente as características sociais do áudio, vindo a usá-las para quantificar o nível de ansiedade com 72,73% de precisão.
[36]	Foram identificados padrões de estabilidade e mudança no comportamento social (i.e., o tempo diário de duração gasto com conversas) de um conjunto de estudantes.

[27]	Foi apresentado um método para reconhecer se um indivíduo está sozinho ou acompanhado com uma precisão de 91,1%.
[76]	Foram encontradas correlações entre os níveis de estresse atuais e futuros de um conjunto de alunos com seus encontros presenciais identificados através da utilização do <i>Bluetooth</i> como sensor de presença.
[19]	Foi aplicado o aprendizado de transferência para identificar sintomas autistas usando características sociais (e.g., energia, entropia e brilho) extraídos dos dados do microfone de um dispositivo vestível.
[16]	Identificou que os papéis sociais dos locais e os padrões de comunicação dos alunos apresentam correlações significativas com sintomas de ansiedade social e depressão.
[8]	Propôs um método estatístico para avaliar as mudanças nos padrões de sociabilidade de um conjunto de pacientes ao longo do tempo, vindo a usar esta consciência para prever recaídas esquizofrênicas com duas semanas de antecedência.
[57]	Concebeu um modelo de aprendizado de máquina capaz de classificar pacientes com diabetes que apresentam sintomas depressivos com uma precisão de 81,1% e 75% de sensibilidade.
[31]	Foi demonstrado que o comportamento dos indivíduos difere com base nos níveis de ansiedade social e no local da interação social, nos quais indivíduos com níveis mais altos de ansiedade social exibem aumento de movimento (conforme rastreado pelo acelerômetro) durante o tempo das ligações, principalmente em locais desconhecidos (e.g., fora de casa ou no trabalho).
[15]	Foi apresentado um novo modelo de mistura de processos de <i>Poisson</i> , que pode ser aplicado para caracterizar a atividade e-social de pacientes psiquiátricos.

A.2 Data de Publicação dos Trabalhos Incluídos

Ao analisar a distribuição dos estudos selecionados ao longo dos anos (Figura A.1), é possível identificar um aumento significativo no número de artigos publicados que propõem a utilização dos dispositivos ubíquos para reconhecer situações sociais para monitorar a saúde mental. Especificamente, o número de estudos publicados aumentou consideravelmente a partir de 2016. Esse achado contribui para indicar o crescente interesse da comunidade científica nesse tema de pesquisa e reforça a motivação da RSL realizada.




Figura A.1: Distribuição dos estudos por ano.

A.3 Estados de saúde mental

Os estudos selecionados abordaram diversos tópicos de saúde mental, os quais têm associação com o comportamento social dos pacientes. Esses estudos focaram nos seguintes temas relacionados à saúde mental: estresse, transtorno bipolar, bem estar, isolamento social, depressão, estado afetivo, ansiedade social, humor, déficit social, espectro do autismo, ansiedade, esquizofrenia, Abuso de substâncias, distúrbios psicóticos e transtornos obsessivos. A Figura A.2 apresenta o número e a proporção em que os estudos selecionados exploraram cada estado de saúde mental. Observe-se que a depressão foi o distúrbio mais explorado, sendo abordado por 6 artigos. Em seguida, identifica-se que o estresse e a ansiedade social são investigados por três estudos, enquanto o transtorno bipolar, isolamento social, estado afetivo e o bem estar aparecem em 2 estudos. O item denominado Outros apresentado na Figura A.2 representa as condições mentais abordadas por apenas um artigo, a saber, humor, déficit social, espectro do autismo, ansiedade, esquizofrenia, abuso de substâncias, distúrbios psicóticos e transtornos obsessivos. Os estados de saúde mental foram explorados individualmente pela maioria dos estudos selecionados, mas, em alguns casos, os artigos abordaram mais de um deles.




Figura A.2: Estados de saúde mental explorados pelos estudos selecionados.

A.4 Duração e Participantes do Estudo

O período de duração das experiências realizadas pelos estudos selecionados variou de 10 horas a 3 anos (média $\approx 105,77$ dias; mediana = 28 dias). Essa alta discrepância entre média e mediana pode ser explicada pelo alto desvio padrão ($\approx 246,12$), indicando que os estudos têm diferentes tempos de duração. O experimento realizado por Gong et al. [31] teve apenas 10 horas de duração, devido ter ocorrido apenas no contexto de sala de aula. Por outro lado, Servia-Rodríguez et al. [59] desenvolveram um estudo longitudinal com duração de três anos. A maioria dos estudos selecionados teve períodos inferiores a cinquenta dias, sendo que apenas sete estudos apresentaram períodos de duração mais longos.

O número de participantes nos estudos varia de 7 a 18.000 (média $\approx 958,85$; mediana = 48). Assim como o tempo de duração, esse aspecto também possui um alto desvio padrão ($\approx 4011,58$), indicando uma alta variação no número de participantes. O estudo desenvolvido por Abdullah et al. [1] apresentou apenas 7 participantes, enquanto o artigo realizado por Servia-Rodríguez et al. [59] contou com 18.000 participantes. Em geral, os estudos tiveram menos de 50 participantes, enquanto apenas sete estudos tiveram quantidades superiores.

Outro aspecto a ser analisado é o tipo de participante em cada estudo selecionado. Assim, é possível identificar que a maioria dos participantes recrutados

não possuíam diagnóstico clínico (experimentos de 15 artigos), enquanto apenas cinco estudos apresentaram participantes clínicos. Os tipos de participantes recrutados foram público em geral (i.e., sem critérios de seleção), pesquisadores médicos, pacientes com transtorno bipolar, pacientes com esquizofrenia, estudantes, trabalhadores do conhecimento, funcionários e usuários idosos.

A.5 Dados Contextuais

Os estudos selecionados utilizaram vários tipos de dados contextuais disponíveis em dispositivos ubíquos para identificar situações sociais. Esses dados são provenientes de diferentes sensores presentes nesses dispositivos, que fornecem uma grande quantidade de dados comportamentais de seus usuários. Neste estudo, os sensores são definidos como qualquer forma de coletar informações de contexto e os classificamos em sensores físicos e virtuais. Sensores físicos representam componentes de hardware embutidos em dispositivos ubíquos capazes de coletar dados de contexto, como sensor de luz, microfone e *Bluetooth*. Por outro lado, sensores virtuais representam fontes de dados de aplicativos, que podem coletar dados sobre a interação do usuário com o dispositivo, como registros de chamadas e mensagens de texto.

A maioria dos estudos explorou sensores físicos e virtuais presentes em *smartphones*, enquanto apenas três artigos usaram dados de contexto coletados de dispositivos vestíveis. O *registro de chamadas* é a fonte de dados mais explorada (8 estudos), acompanhada pelo *GPS*, que está presente em 7 artigos. Outras fontes de dados de contexto também foram usadas com frequência, como *mensagens de texto*, *microfone*, *Bluetooth* e *acelerômetro*. As fontes menos utilizadas foram *infravermelho* e *uso de APPs*, presentes em apenas um estudo.