

A Computational Model for Identifying Behavioral Patterns in People with Neuropsychiatric Disorders

P. C. Büttenbender, E. G. Azevedo Neto, W. F. Heckler, and J. L. V. Barbosa

Abstract—Neuropsychiatric disorders represent a great economic and social burden, whose estimates range from 14% to 32% of the global burden of diseases. One in four people suffer from mental disorders during their lifetime and the estimates of people suffering from depression and some type of neuropsychiatric disorder are about 322 million and 420 million, respectively. Therefore, this paper presents Eigenroutines, a model based on the hypothesis that the ubiquitous availability of mobile devices and the massive usage of these devices have created an opportunity of identifying behavior, supporting the management of neuropsychiatric disorders. The model is also capable of building psychiatric epidemiological profiles, using context histories. The model evaluation occurred in three steps, where the first confirmed that the model has the ability to identify and distinguish neuropsychiatric disorders, analyzing context histories from a group of 55 individuals, composed of 23 people with unipolar or bipolar depression and 32 healthy people. The model presented an accuracy of 78% for classifying the routine of an individual in depressed or healthy. The second step evaluated the extraction of epidemiological profiles based on context histories from 1066 individuals stored by the platform. Finally, the last step evaluated the limitations of the model regarding temporal complexity and scalability.

Index Terms—Context-Aware Computing, Context History, Similarity Analysis, Ubiquitous Computing.

I. INTRODUÇÃO

Transtornos neuropsiquiátricos representam um grande peso econômico e social, cujas estimativas variam entre 14% e 32% da carga global de doenças de acordo com a Organização Mundial de Saúde (OMS) [1]. Uma em cada quatro pessoas sofre com algum transtorno mental durante a vida. Além disso, estima-se que aproximadamente 322 milhões de pessoas sofrem com depressão e 420 milhões sofrem com algum tipo de transtorno neuropsiquiátrico [2].

A última década apresentou um grande avanço tecnológico em termos de plataformas de computação distribuída, algoritmos e ferramentas de aprendizado de máquina. Atualmente, essas ferramentas estão rápidas o suficiente para analisar dados massivos em pouco tempo [3], [4]. Aliando essa capacidade de processamento com a ubiquidade de dispositivos móveis, especialmente telefones celulares, presentes no cotidiano de grande parte da população, novas abordagens para esses problemas sociais e novas formas para compreender o comportamento e antecipar as ações de indivíduos estão surgindo.

P. C. Büttenbender, Universidade do Vale do Rio dos Sinos (Unisinos), São Leopoldo, RS, Brasil, insidy@gmail.com

E. G. Azevedo Neto, Universidade do Vale do Rio dos Sinos (Unisinos), São Leopoldo, RS, Brasil, eduardo7@edu.unisinos.br

W. F. Heckler, Universidade do Vale do Rio dos Sinos (Unisinos), São Leopoldo, RS, Brasil, weslleheckler@edu.unisinos.br

J. L. Barbosa, Universidade do Vale do Rio dos Sinos (Unisinos), São Leopoldo, RS, Brasil, jbarbosa@unisinos.br

Uma das estratégias para monitorar e antecipar as ações desses indivíduos é a utilização de históricos de contextos [5], [6], [7], que é a capacidade de sistemas construírem séries temporais vinculadas à localização e atividades de um indivíduo. Esses sistemas são capazes de examinar e reagir a mudanças no contexto do usuário ao longo do tempo, que é composto por todas as informações relevantes ao indivíduo em um determinado momento, considerando a localização, bem como pessoas e dispositivos próximos [8].

Este trabalho, portanto, propõe o Eigenroutines, um modelo computacional baseado em históricos de contextos capaz de identificar padrões de comportamento para auxiliar na identificação e tratamento de pessoas com transtornos neuropsiquiátricos. A avaliação consistiu em três etapas, onde a primeira visou confirmar a capacidade de identificar e distinguir padrões comportamentais em indivíduos saudáveis e com transtornos neuropsiquiátricos a partir de históricos de contextos. A segunda etapa avaliou o mapeamento e apresentação de perfis epidemiológicos. A última etapa avaliou as limitações do modelo, principalmente relacionadas à escalabilidade.

As principais contribuições deste artigo são: (1) o auxílio ao diagnóstico baseado em julgamento clínico utilizando históricos de contextos de indivíduos em fase final de tratamento e na fase inicial como forma de sugestão de caminho ao profissional de saúde, (2) a inclusão do profissional de saúde mental como agente chave na definição de intervenções e da opinião clínica como parte da escolha de algoritmos adaptativos para diagnóstico, e (3) a construção de perfis epidemiológicos psiquiátricos utilizando os históricos de contextos e diagnósticos dos profissionais.

O restante do artigo está dividido em 4 seções. A Seção II apresenta estudos relacionados ao tema de pesquisa. A Seção III aborda a arquitetura do modelo proposto. A Seção IV descreve e discute os resultados obtidos. Por fim, a Seção V apresenta as conclusões e orientações para trabalhos futuros.

II. TRABALHOS RELACIONADOS

Uma revisão sistemática foi realizada para avaliar o estado da arte sobre a aplicação de computação móvel e ubíqua no acompanhamento e tratamento de transtornos mentais [9]. A revisão considerou as bases de pesquisa *ACM Digital Library*, *IEEE Xplore*, *MEDLINE/PubMed* e *PsycINFO*, retornando os trabalhos relacionados descritos nesta seção.

Palmius [10] apresentaram o *Automated Monitoring of Symptom Severity (AMoSS)*, um sistema baseado em telefones celulares para monitoramento de sintomas de pacientes em tempo real, com objetivo de alocar recursos psiquiátricos de forma mais eficiente. Dang [11] propuseram o *FINE*, um apli-

cativo com o objetivo de identificar indicadores correlacionados a comportamentos de indivíduos com depressão profunda, analisando dados de acelerômetro e a área de magnitude do sinal como medida para correlacionar atividades físicas com os dados do sensor.

Watanabe [12] propuseram o *Fun to Learn to Act and Think through Technology* (FLATT), que visa avaliar se a Terapia Cognitivo Comportamental feita a partir de dispositivos móveis facilita a troca de medicação por pacientes diagnosticados com depressão profunda com resistência a farmacoterapia e em fase de transição de medicamentos. Mohr [13] apresentaram o *MedLink*, um modelo auxiliar no tratamento de depressão profunda. Os pesquisadores identificaram fatores relacionados ao paciente, principalmente a não aderência a medicação, e fatores relacionados aos profissionais, como dosagem inferior a recomendação e falta de ajuste na medicação.

Faurholt-Jepsen [14] e Mayora [15] propuseram o *MONARCA* (*MONitoring, treatment and pRediCtion of bipolar disorder episodes*), um modelo que utiliza telefones celulares para medir o transtorno bipolar, identificando indicadores e formas de intervenção e suporte ao profissional de saúde mental. Valenza [16] apresentaram o *PSYCHE* (*Personalized monitoring SYStems for Care in mental HEalth*), uma plataforma para identificar variações de humor em pacientes com transtorno afetivo bipolar baseado em computação ubíqua e tecnologia vestível, utilizando uma camiseta com sensores para ritmo cardíaco e para respiração.

Jaimes [17] apresentaram o *PREVENTER*, um sistema para predição de estresse em tempo real e aplicação de intervenções adaptativas, utilizando um “Modelo Oculto de Markov” como algoritmo para predição baseado em sensores físicos. Kamdar e Wu [18] apresentaram o *PRISM* (*Passive, Real-time Information for Sensing Mental Health*), que realiza um monitoramento passivo de pacientes para avaliar as condições de saúde, bem como extrair conceitos para classificar o humor do paciente a partir de um diário virtual.

Kerz [19] propuseram o *SleepSight*, um sistema para evitar relapsos em pacientes com esquizofrenia ou transtornos esquizoafetivos. Os autores realizaram um experimento com 16 pacientes diagnosticados com esquizofrenia, utilizando uma combinação de sensores vestíveis, tais como FitBit Charge, sensores de um telefone celular e um questionário no modelo *Positive and negative symptom scale* (PANSS).

A maioria dos trabalhos focou em transtornos específicos [11], [12], [13], [14], [15], [16], [17], [19]. Somente o PRISM [18] apresentou uma abordagem genérica, enquanto o AMoSS [10] abordou três transtornos com o objetivo de comparar a diferença no comportamento e identificar o melhor algoritmo para classificação do transtorno. Além disso, nenhum trabalho utilizou técnicas de aprendizado profundo e por reforço.

A Tabela I mostra uma comparação sobre funcionalidades gerais dos trabalhos relacionados, apresentando os transtornos mentais abordados, o uso ou suporte para dispositivos vestíveis e o uso ou suporte para actigrafia, que é um método não-invasivo para monitorar ciclos de atividade ou descanso humano [20]. A tabela também indica se o modelo apresenta alguma estratégia para intervenção automatizada ou prescrita e se a abordagem inclui ou possibilita a participação de

TABELA I
COMPARAÇÃO ENTRE OS TRABALHOS RELACIONADOS

Referências	Transtorno	Suporte a dispositivos vestíveis	Actigrafia/Sensores	Intervenção	Profissional
AMoSS [10]	Depressão, Bipolaridade e Personalidade	Sim	Sim	Não	Não
FINE [11]	Depressão profunda	Não	Sim	Não	Não
FLATT [12]	Depressão profunda	Não	Não	Sim	Não
MedLink [13]	Esquizofrenia	Sim	Não	Sim	Sim
MONARCA [14], [15]	Bipolaridade	Não	Sim	Sim	Sim
PSYCHE [16]	Estresse crônico	Sim	Sim	Sim	Não
PREVENTER [17]	Transtornos em geral	Sim	Sim	Não	Sim
PRISM [18]	Bipolaridade	Sim	Sim	Não	Não
SleepSight [19]	Esquizofrenia	Sim	Sim	Não	Sim

profissionais de saúde mental. Com isso, pode-se observar que o *Eigenroutines* possui como principal contribuição o uso de históricos de contextos na identificação de comportamentos que auxiliem nos diagnósticos e na construção de perfis epidemiológicos psiquiátricos.

III. MODELO EIGENROUTINES

A revisão sistemática descrita na seção anterior, bem como o estudo das áreas relacionadas ao tema de pesquisa, guiaram a criação dos conceitos utilizados no modelo. O *Eigenroutines* é baseado em nove conceitos, dos quais oito formam um fluxo contínuo de troca de informação, enquanto o conceito de históricos de contextos é representado como uma figura central, que permeia e interage com os demais.

A. Conceitos

O primeiro conceito, “Diagnóstico”, representa a interação entre profissional e paciente para diagnosticar o transtorno a partir de um julgamento clínico. O primeiro diagnóstico consiste no julgamento clínico, enquanto os subsequentes serão suportados por informações do comportamento do paciente.

Os “Indicadores”, conhecidos na literatura médica como biomarcadores, definem o estado de um indivíduo em um determinado período de tempo e cuja variação pode caracterizar um transtorno. O “Sensoriamento” é o resultado da definição dos indicadores. Cada indicador está vinculado às características que podem ser identificadas ao longo do tempo por movimentação, atividade social, luminosidade, localização ou questionando o paciente sobre seu estado e sintomas.

O “Contexto” é a transformação dos dados de sensores em indicadores, dispostos com a informação de localização, tempo e dados sociodemográficos do paciente, podendo o contexto ser modelado por transtorno ou por comorbidade. Os “Históricos de Contextos” [5], [6], [7] são a representação de uma série de contextos ao longo do tempo, caracterizados por rotinas baseadas em indicadores.

O conceito de “Comparação” de históricos de contextos é definido como a distância da rotina de comportamento do paciente em relação ao comportamento de outros indivíduos com diagnóstico clinicamente confirmado, utilizando uma seleção de algoritmos de análise de similaridade. A “Confirmação” do diagnóstico se repete ao longo dos encontros, nos quais o profissional de saúde mental ajusta ou confirma o diagnóstico anterior baseado no comportamento do indivíduo, definindo o estágio e a severidade do transtorno em questão.

O conceito de “Tratamento e Intervenção” ecológica é a aplicação de ferramentas, conteúdo, lembretes e interações

com o paciente para mitigar os sintomas do transtorno diagnosticado. O “acompanhamento” caracteriza-se pelo relatório das atividades e comportamento do indivíduo para o profissional e por alertas em casos de remissão.

A Fig. 1 ilustra a relação entre diagnóstico, sensoriamento e contexto, apresentando a entrada de dados de sensores, que passam por uma função de transformação para indicadores. Essa função é determinada pela própria característica de indicadores derivados do diagnóstico. Assim, o indicador determina quais sensores serão utilizados e como os dados serão transformados em indicadores. Outra função recebe esses indicadores juntamente com dados do perfil do paciente, dados de localização e dados temporais para construir o contexto.

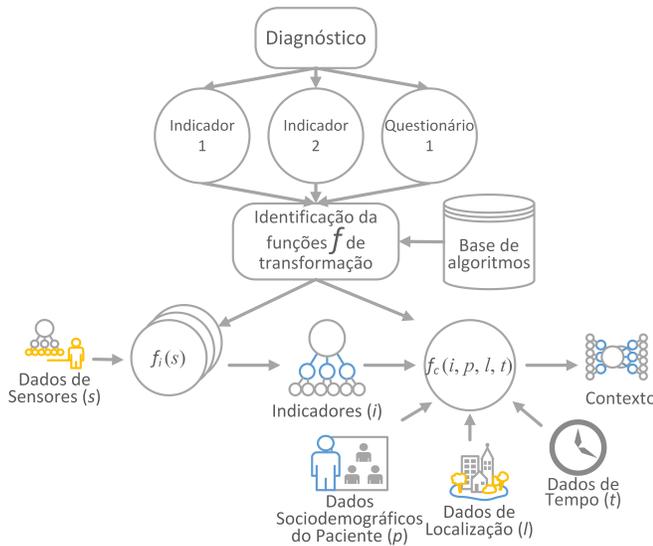


Fig. 1. Relação entre diagnóstico, sensoriamento e contexto.

B. Sensoriamentos e Contextos

No Eigenroutines, todo contexto é formado por indicadores, enquanto informações de sensores são armazenadas separadamente do contexto. Todo indicador é computado a partir de dados de sensores de dispositivos móveis inteligentes e resulta em uma variável discreta ou contínua. Um indicador é um estado computado a partir de um sensor conhecido, no qual o algoritmo utilizado para definir esse estado pode ser implementado de forma a suportar diferentes dispositivos e sensores. Assim como um mesmo sensor pode ser utilizado por diversos indicadores, também é possível que novos indicadores sejam descobertos por avanços científicos e modelados como formas mais precisas de identificar transtornos neuropsiquiátricos.

A Fig. 2 ilustra o modelo por uma perspectiva de mudança comportamental e sensoriamento passivo. Os sensores passivos respondem a estímulos externos, que são informações já existentes, apresentando o aspecto de separação dos repositórios de sensoriamento e contexto.

C. Perfis Epidemiológicos

O modelo tem capacidade de identificar os perfis epidemiológicos dos transtornos, utilizando os dados disponíveis

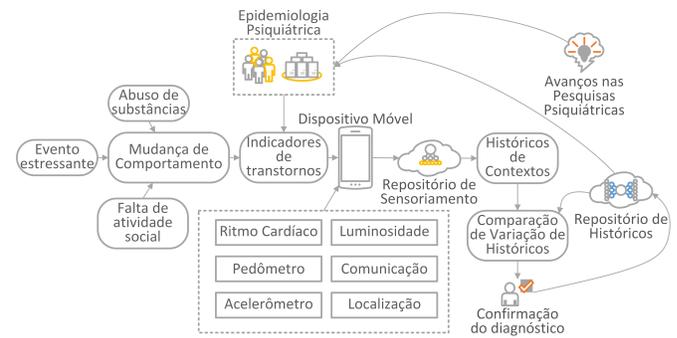


Fig. 2. Modelo por uma perspectiva de mudança comportamental.

na plataforma. Para isso, a primeira etapa é a aquisição das informações de pacientes em forma de contextos, onde o conceito de diagnóstico é responsável pela aquisição de informações sociodemográficas de um paciente. A segunda etapa é a conversão do contexto em características do transtorno em um determinado paciente.

A terceira etapa avalia os dados de pacientes na plataforma com as características propriamente classificadas, utilizando a ontologia para classificações de doenças oficialmente publicadas pela OMS. A quarta etapa corresponde à construção dos perfis por população, bem como à aplicação de algoritmos de classificação para identificação de padrões nos grupos afetados pelos transtornos. Isso permite a última etapa revisar os perfis epidemiológicos, investigar a etiologia de transtornos e adaptar políticas de saúde pública para ter maior impacto na população mais vulnerável a transtornos neuropsiquiátricos.

D. Processos do Modelo

O fluxo entre o primeiro encontro com o profissional de saúde até o segundo encontro possui onze etapas. A primeira, vinculada ao conceito de “Diagnóstico”, consiste no diagnóstico clínico, que ocorre geralmente a partir de uma entrevista entre o profissional e o paciente ou familiar. A segunda etapa, vinculada aos conceitos de “Diagnóstico” e “Indicadores”, realiza a identificação automática de comorbidades, considerando tanto os perfis epidemiológicos gerados pela plataforma quanto o repositório de informações de pesquisas da área de neuropsiquiatria.

Na terceira etapa, o modelo identifica os indicadores mais adequados para o diagnóstico, a partir do julgamento clínico, utilizando a mesma base de informações para comorbidades. Na quarta etapa, o modelo apresenta ao profissional as comorbidades, indicadores e intervenções identificados. Ambas as etapas são vinculadas ao conceito de “Indicadores”. A quinta etapa permite ao profissional modificar e agendar as intervenções e indicadores para o paciente em questão, caso entenda que os mesmos não são aplicáveis ou prefira outras formas de confirmação de diagnóstico.

A sexta etapa, vinculada ao “Sensoriamento”, identifica os sensores passivos necessários para a construção dos indicadores, bem como por determinar e agrupar as formas de sensoriamento ativo, que são sensores que utilizam estímulos

internos, necessários para indicadores que não suportem formas passivas de construção. Na sétima etapa, a plataforma passa efetivamente a monitorar e gerenciar os transtornos do paciente através do aplicativo e dos dispositivos relacionados. Na oitava etapa, relacionada aos conceitos de “Sensoriamento” e “Tratamento e Intervenção”, os sensoriamentos ativo e passivo são realizados, bem como aplicadas as intervenções determinadas pelo profissional.

Nona e décima etapas, relacionada ao “Contexto”, ocorrem em paralelo com a oitava. Na nona etapa, o modelo continuamente transforma dados de sensores em séries temporais e armazena no repositório de sensoriamento. Na décima etapa, os indicadores são transformados em contextos, gerando históricos de contextos. Na décima primeira etapa, relacionada aos “Históricos de Contextos”, o modelo compara a semelhança dos indicadores e contextos capturados até o momento com os de outros indivíduos com o mesmo diagnóstico.

Os encontros subsequentes ocorrem com base em um ciclo contínuo de diagnóstico, tratamento e acompanhamento, onde o modelo identifica comportamentos do paciente similares aos de outros pacientes e comunica o profissional da saúde, que pode confirmar ou não o diagnóstico. Após isso, o profissional determina as intervenções para o novo diagnóstico, que são carregadas no aplicativo utilizado pelo paciente. Assim, o modelo continua armazenando históricos de contextos e atualizando os perfis epidemiológicos.

E. *Eigenbehaviors e Eigenroutines*

A modelagem para identificação e comparação de históricos de contextos utiliza uma abordagem baseada em *Eigenbehaviors* [21], que consistem na identificação dos componentes principais de uma base de dados de comportamento de indivíduos. Este trabalho utiliza um conjunto de indicadores como forma de identificar um comportamento que caracterize um determinado transtorno. Desta forma, um indivíduo que tem dois potenciais transtornos identificados deve ter dois grupos de *Eigenbehaviors*. Os comportamentos dos indivíduos são mapeados de acordo com dias e horários, variando entre em casa e ativo, em casa e deitado, no trabalho e em outro lugar em períodos de tempo de uma hora.

Essa análise pode ser aplicada tanto ao comportamento de um indivíduo ao longo do tempo quanto ao comportamento médio de múltiplos indivíduos. A vantagem de calcular *Eigenbehaviors* para um grupo é a possibilidade de avaliar a distância do comportamento médio de um indivíduo da média do grupo. Se o comportamento de um determinado paciente em diagnóstico preliminar de depressão está próximo do comportamento de indivíduos com diagnóstico confirmado, é provável que o mesmo esteja efetivamente com depressão.

F. Arquitetura

A Fig. 3 apresenta a arquitetura proposta em alto nível e os principais módulos para esta implementação, subdivididos em (1) *CareModules*, (2) *CareRepositories*, (3) *CareContext*, (4) *AgentJS* e (5) *CareDiagnosis*.

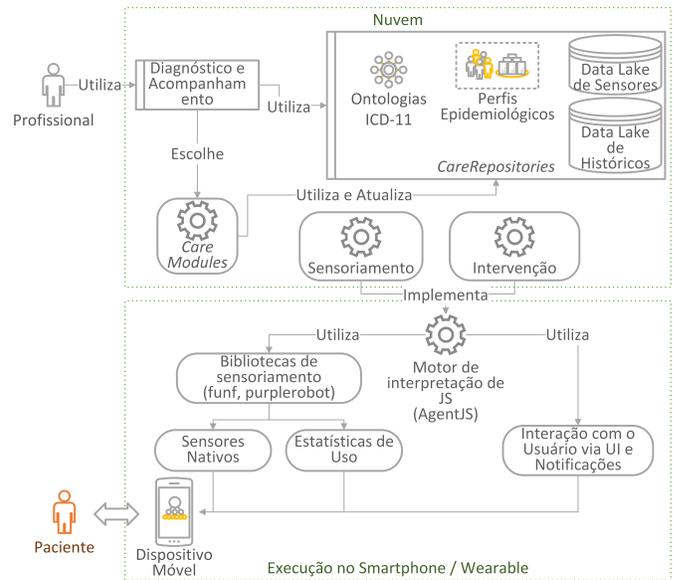


Fig. 3. Arquitetura em alto nível proposta para o modelo.

CareModules são os blocos básicos de interação da plataforma, que consistem em microsserviços. Esses blocos realizam sensoriamento, intervenção ou relatórios de acompanhamento. Um *CareModule* é semelhante a um diário que captura a escrita ou fala de um paciente, interpreta o texto e apresenta uma avaliação semântica para o profissional julgar se o quadro clínico do paciente está evoluindo.

Todo *CareModule* que precisa de acesso ao paciente e ao dispositivo móvel deve implementar uma interface do *AgentJS* para utilizar as ferramentas da plataforma. A Fig. 3 mostra dois *CareModules* genéricos (Sensoriamento e Intervenção) e sua relação com o *JavaScript® AgentJS*, que é uma *Application Programming Interface (API)* e um motor de execução de *JavaScript®* em dispositivos móveis. Esta plataforma utiliza uma versão estendida do *AgentJS* com instruções específicas de computação ubíqua para saúde mental [21]. Além disso, um *CareModule* pode ser um conjunto de indicadores e formas de sensoriamento utilizados pelo *CareContext* para identificar similaridades entre transtornos.

CareContext é uma extensão dos *CareModules* responsável pela implementação dos algoritmos adaptativos de construção e comparação de históricos de contextos. Esses históricos são baseados nas informações disponíveis nos *CareRepositories*, que são repositórios de informações compartilhadas entre os módulos da plataforma ou outras plataformas, deixando explícita a separação entre dados de sensores e contexto. O objetivo desses repositórios é organizar e armazenar essas informações compartilhadas. Ontologias e adaptadores de ontologias fazem parte dos *CareRepositories*.

CareDiagnosis é a ferramenta de interação com o profissional de saúde mental, responsável pelas funções de diagnóstico e acompanhamento do paciente. *CareDiagnosis* interage com *CareModules* e *CareContext* para apresentar relatórios e alertas ao profissional quanto ao andamento do tratamento e quanto à possibilidade de novos diagnósticos.

G. Ontologia Eigenroutines

A Fig. 4 apresenta a ontologia criada para a representação geral das entidades do modelo e suas relações. A ontologia também auxiliou a codificação do modelo e inferências de classes e atributos para identificar perfis epidemiológicos.

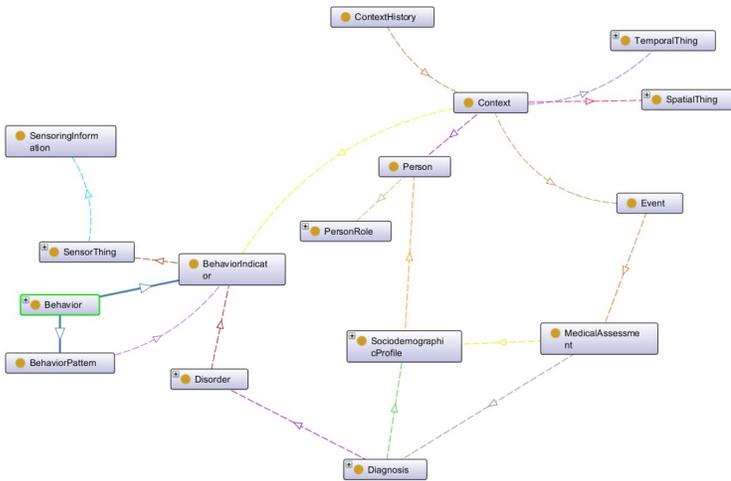


Fig. 4. Ontologia de Comportamento.

A classe “Comportamento” (*Behavior*) é composta por indicadores e padrões de comportamento. A classe “Indicador de Comportamento” (*BehaviorIndicator*) representa abstrações geradas por informações de sensoriamento vinculadas ao contexto. As rotinas de indicadores de comportamento vinculadas a um histórico de contexto são representadas pela classe “Padrão de Comportamento” (*BehaviorPattern*). A classe “Transtorno” (*Disorder*) abrange o transtorno que está sendo acompanhado. A classe “Diagnóstico” (*Diagnosis*) determina o diagnóstico realizado por um profissional de saúde mental.

Os eventos em um contexto são representados pela classe “Evento” (*Event*), que possui a subclasse “Avaliação Médica” (*MedicalAssessment*). A classe “Perfil Sociodemográfico” (*SociodemographicProfile*) contempla informações sociodemográficas dos pacientes, representados pela classe “Pessoa” (*Person*) e que possuem vínculo com a classe “Papel da Pessoa” (*PersonRole*). Os sensores são retratados pela classe “Sensoriamento” (*SensorThing*), enquanto as informações coletadas por eles pertencem à classe “Informação de Sensoriamento” (*SensoringInformation*).

Informações espaciais e temporais são descritas pelas classes “Espacial” (*SpatialThing*) e “Temporal” (*TemporalThing*), respectivamente. Por fim, os contextos são representados pela classe “Contexto” (*Context*) e os históricos de contextos pela classe “Histórico de Contexto” (*ContextHistory*).

IV. AVALIAÇÃO E RESULTADOS

Esta seção apresenta as estratégias e os resultados da validação do modelo. As avaliações apresentadas nesta seção estão divididas em três análises: (1) avaliação do algoritmo, (2) avaliação dos perfis epidemiológicos e (3) avaliação e discussão da escalabilidade de inferência da ontologia proposta.

A. Avaliação do Algoritmo

A primeira avaliação confirmou a capacidade do modelo em: (1) identificar e distinguir padrões comportamentais em indivíduos saudáveis e com transtornos neuropsiquiátricos a partir de históricos de contextos, e (2) identificar uma mudança no padrão comportamental que aproxime um indivíduo do grupo saudável quando comparado ao grupo diagnosticado com um transtorno neuropsiquiátrico.

A primeira avaliação considerou os dados disponibilizados por Garcia-Ceja [22], compostos pelo acompanhamento de 55 indivíduos que utilizaram um dispositivo vestível de pulso chamado *Actiwatch* por 12 horas em média, que coleta informações sobre a frequência de movimentação. Os dados de atividade foram coletados em 23 pessoas com depressão unipolar ou bipolar e 32 pessoas saudáveis durante 693 dias. A avaliação clínica dos indivíduos considerou o questionário *Montgomery-Asberg Depression Rating Scale* (MADRS) [23].

A primeira validação utilizou os algoritmos *K-Nearest Neighbors* (KNN), *Support Vector Machine*, *Árvore de Decisão*, *Random Forest*, *Redes Neurais Multi-Layer Perceptron*, *AdaBoost* com *Árvore de Decisão* como classificador base, *Gaussian Naive Bayes* e processo gaussiano com algoritmo de treinamento de função de base radial. Apesar de pertencer à classe de algoritmos não-supervisionados, o KNN foi utilizado na validação, uma vez que é capaz de realizar classificações com base na semelhança entre instâncias dos dados [24].

O modelo gerado com o algoritmo *Gaussian Naive Bayes* apresentou a maior acurácia média (78%) na classificação da rotina de um indivíduo entre depressivo e saudável. Os resultados foram superiores aos encontrados por Garcia-Ceja [22] (72,7%). KNN, *Support Vector Machine*, *Árvore de Decisão*, *Random Forest*, *Redes Neurais Multi-Layer Perceptron*, *AdaBoost* com *Árvore de Decisão* como classificador base e processo gaussiano atingiram acurácia média de 66%, 75%, 72%, 76%, 75%, 74% e 70%, respectivamente. Este estudo não identificou outras pesquisas que utilizaram a mesma base de dados, não sendo possível comparar os resultados com outros trabalhos da literatura. Assim, os resultados atingidos representam um registro de melhor desempenho em relação aos dados disponibilizados por Garcia-Ceja [22].

A segunda avaliação do algoritmo testou a capacidade do modelo em identificar o movimento da rotina de um indivíduo, distanciando-se do comportamento depressivo e aproximando-se do saudável. Para isso, foi selecionado o indivíduo *i* com depressão que apresentou a melhoria mais significativa, com avaliação inicial MADRS estimada em 24 pontos (depressão moderada) e final estimada em 11 pontos (depressão leve, próximo ao limiar de saudável). Esse indivíduo é um homem, solteiro, com idade entre 40 e 44 anos, que foi acompanhado por 18 dias e diagnosticado com transtorno bipolar II.

A Tabela II apresenta os resultados da comparação da distância média entre os primeiros e últimos 9 dias de acompanhamento do indivíduo *i* em relação aos dois grupos de pacientes. Cada indivíduo da base de dados teve seu comportamento projetado contra o comportamento médio do grupo e a distância euclidiana foi calculada entre os *Eigenbehaviors* das duas projeções. Desta forma, o modelo é capaz de identificar

TABELA II
COMPARAÇÃO DA DISTÂNCIA DA ROTINA ENTRE O
INDIVÍDUO COM DEPRESSÃO *i* E OS DEMAIS INDIVÍDUOS

	Primeiros 9 dias	Últimos 9 dias
Distância para indivíduos do grupo com depressão		
Total de registros comparados	22	22
Média	1.853628	2.007097
Desvio-padrão	0.485441	0.208242
Distância para indivíduos do grupo de controle		
Total de registros comparados	32	32
Média	2.142374	1.592183
Desvio-padrão	0.415020	0.412471

a proximidade de rotinas em um indivíduo que apresentou melhorias em seu diagnóstico clínico. Esse indivíduo esteve mais próximo ao grupo de pacientes com depressão nos primeiros 9 dias e ao grupo de controle nos últimos 9 dias.

B. Avaliação dos Perfis Epidemiológicos

A segunda avaliação verificou se a ontologia e os conceitos propostos possibilitam a construção de perfis epidemiológicos baseados nas informações obtidas pelo modelo. Um perfil epidemiológico é um indicador observacional das condições sociodemográficas e visa suportar trabalhos de investigação epidemiológica, bem como a construção de políticas de saúde pública a partir da análise dos grupos e dos fatores de risco associados a determinados transtornos.

A avaliação simulou o processo de diagnóstico e confirmação, utilizando as seguintes questões de competência: (i) qual a situação sociodemográfica para casos de depressão observados durante o período do experimento? (ii) quantos casos incidentes foram identificados durante o período do experimento? (iii) existe alguma comorbidade identificada no experimento? (iv) qual a medicação mais comum utilizada para depressão profunda? e (v) qual medicação com maior taxa de remissão para o período do estudo?

Para responder essas perguntas, foram utilizados dois conjuntos de informações. O primeiro, compartilhado por Garcia-Ceja [22], foi utilizado para responder a primeira questão. O segundo foi baseado em uma simulação de 1066 indivíduos, sendo utilizado para responder as demais questões. A extração de perfis ocorreu através de expressões de busca SPARQL.

A Fig. 5 ilustra um agrupamento por classe e outro por instância, bem como as expressões de busca referentes à última questão, que avalia a relação entre medicação e remissão. A figura mostra: (a) a restrição por um diagnóstico confirmado (item 1); (b) que o mesmo transtorno diagnosticado em outra avaliação como em remissão (item 3); e (c) que ambos sejam da mesma pessoa (itens 2 e 4). A restrição 5 da expressão ao lado esquerdo da figura identifica a classe em vez da instância.

A Tabela III apresenta a relação entre as medicações e as classes de transtornos. Na tabela, verifica-se a capacidade do modelo de inferir a classe do transtorno baseado nas características da instância, como é o caso da Sertralina na classe “Transtorno Depressivo Maior”, com 62 casos, que corresponde a Sertralina utilizada para o transtorno depressivo maior recorrente e transtorno depressivo maior em episódio único no periparto, com 57 e 5 casos, respectivamente. Sendo

Fig. 5. Expressões de busca para medicação com maior índice de remissão por transtorno, lado esquerdo a expressão por classe de transtorno, ao lado direito por instância de transtorno.

assim, o modelo foi capaz de identificar grupos de pacientes com base nas questões de competência, confirmando a capacidade para construção de perfis epidemiológicos.

TABELA III
RESULTADO DAS EXPRESSÕES DE BUSCA DA QUESTÃO DE
COMPETÊNCIA V

Medicação	Classe de transtorno ou transtorno específico	Casos em remissão
Resultado da busca por classe de transtorno		
Clonazepam	Transtorno de ansiedade generalizada	102
Sertralina	Transtorno de ansiedade generalizada	81
Sertralina	Transtorno depressivo maior	62
Clonazepam	Transtorno depressivo maior	62
Fluoxetina	Transtorno de ansiedade generalizada	57
Escitalopram	Transtorno de ansiedade generalizada	46
Diazepam	Transtorno de ansiedade generalizada	38
Fluoxetina	Transtorno depressivo maior	37
Escitalopram	Transtorno depressivo maior	36
Diazepam	Transtorno depressivo maior	28
Clonazepam	Transtorno de ansiedade generalizada	102
Sertralina	Transtorno de ansiedade generalizada	81
Sertralina	Transtorno depressivo maior	62
Resultado da busca por transtorno específico		
Clonazepam	Transtorno de ansiedade generalizada	102
Sertralina	Transtorno de ansiedade generalizada	81
Clonazepam	Transtorno depressivo maior recorrente	62
Sertralina	Transtorno depressivo maior recorrente	57
Fluoxetina	Transtorno de ansiedade generalizada	57
Escitalopram	Transtorno de ansiedade generalizada	46
Diazepam	Transtorno de ansiedade generalizada	38
Fluoxetina	Transtorno depressivo maior recorrente	35
Escitalopram	Transtorno depressivo maior recorrente	34
Diazepam	Transtorno depressivo maior recorrente	28
Sertralina	Transtorno depressivo maior em episódio único no periparto	5
Fluoxetina	Transtorno depressivo maior em episódio único no periparto	2
Escitalopram	Transtorno depressivo maior em episódio único no periparto	2

C. Avaliação e Discussão da Escalabilidade de Inferência da Ontologia Proposta

Para avaliar o motor de inferência, foram utilizados subgrupos com indivíduos extrapolados a partir dos dados da simulação apresentados na seção IV-B, contendo subgrupos de indivíduos com 25, 50, 100, 200, 400, 800, 1600, 3200 e

TABELA IV
RESULTADO DA AVALIAÇÃO DE DESEMPENHO,
CONSIDERANDO TEMPO EM SEGUNDOS POR INFERÊNCIA

Pacientes	Medições	Tempo de inferência	Expectativa em tempo linear	Expectativa em tempo linearitmico
25	1556	0.032 ± 0.001	0.025	0.035
50	1081	0.046 ± 0.001	0.050	0.085
100	539	0.093 ± 0.003	0.100	0.200
200	264	0.192 ± 0.007	0.200	0.460
400	108	0.474 ± 0.018	0.400	1.041
800	29	1.89 ± 0.069	0.800	2.322
1600	10	7.052 ± 1.295	1.600	5.127
3200	5	39.064 ± 3.666	3.200	11.216
6400	5	158.538 ± 46.232	6.400	24.360

6400 pacientes. Cada avaliação teve duração mínima de 10 segundos, onde medições adicionais foram realizadas para os grupos em que a inferência levou menos de 10 segundos.

O ambiente foi um sistema operacional Windows® 10 Enterprise 1809 64 bits com um processador Intel® i5-8350U e 16GB de RAM DDR4-2400, em uma máquina virtual OpenJDK 13.0.2 de 64 bits. O processo de execução da máquina virtual recebeu a prioridade máxima no sistema operacional para evitar interrupções durante a avaliação. Os dados foram carregados em memória anteriormente para evitar que o tempo de leitura dos arquivos afetasse o teste de desempenho. A Fig. 6 ilustra os resultados obtidos, nos quais o tempo médio para cada grupo de pacientes apresenta um aumento superior às curvas estimadas de tempo linear e linearitmico por grupo.

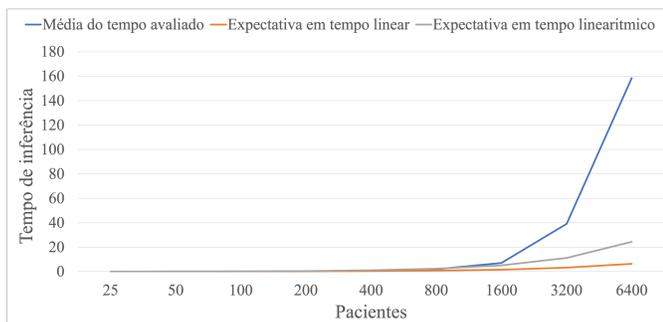


Fig. 6. Gráfico de desempenho de inferência.

A Tabela IV mostra que o tempo de inferência para uma ontologia composta por mais de 800 pacientes supera o crescimento linear e linearitmico estimado para o mesmo tempo de inferência. Considerando tanto o aumento do tempo de inferência quanto a possibilidade de realizar a inferência por instância, recomenda-se para uma implementação produtiva deste modelo a realização das inferências durante a ingestão dos dados no sistema de armazenamento, bem como a execução de inferências de forma assíncrona ao expandir-se a ontologia com novas classes para serem inferidas, a fim de evitar a necessidade de inferências durante a execução das expressões de busca para construção dos perfis epidemiológicos.

V. CONCLUSÃO

Este artigo propôs um modelo computacional para identificação de rotinas e comparação de padrões de comportamento baseado em histórico de contextos. O modelo

foi avaliado em três etapas, comprovando sua capacidade de classificar pessoas com distúrbios de comportamento e identificar mudanças no comportamento dos indivíduos ao longo do tempo. Além disso, a validação da ontologia proposta confirmou a capacidade do modelo em construir perfis epidemiológicos. A validação final realizou uma análise temporal de inferência das instâncias na ontologia proposta.

O trabalho apresenta ameaças à viabilidade e potencial viés, avaliando o modelo com base em dados de trabalhos anteriores e simulação sem um parecer de um profissional da área. Para mitigar o impacto, o modelo incorpora a utilização de biomarcadores avaliados independentemente deste trabalho e baseia-se em um dos principais modelos estatísticos para transtornos neuropsiquiátricos.

Trabalhos futuros podem aplicar o modelo no tratamento simultâneo de diferentes transtornos e comparar diferentes técnicas de modelagem de contexto e indicadores. A avaliação do modelo de identificação de perfis epidemiológicos em larga escala e com indivíduos de diversas culturas também permaneceu como um ponto em aberto neste trabalho. Por fim, trabalhos futuros podem explorar a aplicação do modelo para identificação de relapsos e a aplicação do modelo para identificação e comparação de rotinas que não estejam necessariamente relacionadas ao distúrbio de comportamento.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento deste trabalho.

REFERÊNCIAS

- [1] D. Vigo, G. Thornicroft, and R. Atun, "Estimating the true global burden of mental illness," *The Lancet Psych.*, vol. 3, no. 2, pp. 171–178, 2016. [https://doi.org/10.1016/S2215-0366\(15\)00505-2](https://doi.org/10.1016/S2215-0366(15)00505-2).
- [2] World Health Organization, "Depression and Other Common Mental Disorders: Global Health Estimates," tech. rep., 2017.
- [3] J. H. Da Rosa, J. L. Barbosa, and G. D. Ribeiro, "ORACON: An adaptive model for context prediction," *Expert Systems with App.*, vol. 45, pp. 56–70, 2016. <https://doi.org/10.1016/j.eswa.2015.09.016>.
- [4] J. Hong, E.-H. Suh, J. Kim, and S. Kim, "Context-aware system for proactive personalized service based on context history," *Expert Systems with App.*, vol. 36, no. 4, pp. 7448–7457, 2009. <https://doi.org/10.1016/j.eswa.2008.09.002>.
- [5] A. S. Filippetto, R. Lima, and J. L. V. Barbosa, "A risk prediction model for software project management based on similarity analysis of context histories," *Inf. and Software Technology*, vol. 131, 2021. <https://doi.org/10.1016/j.infsof.2020.106497>.
- [6] J. A. S. Aranda, R. S. Bavaresco, J. V. de Carvalho, A. C. Yamin, M. C. Tavares, and J. L. V. Barbosa, "A computational model for adaptive recording of vital signs through context histories," *J. of Ambient Intell. and Hum. Comp.*, pp. 1–15, 2021. <https://doi.org/10.1007/s12652-021-03126-8>.
- [7] B. G. Martini, G. A. Helfer, J. L. V. Barbosa, R. C. Espinosa Modolo, M. R. da Silva, R. M. de Figueiredo, A. S. Mendes, L. A. Silva, and V. R. Q. Leithardt, "Indoorplant: A model for intelligent services in indoor agriculture based on context histories," *Sensors*, vol. 21, no. 5, 2021. <https://doi.org/10.3390/s21051631>.
- [8] O. B. Sezer, E. Dogdu, and A. M. Ozbayoglu, "Context-aware computing, learning, and big data in internet of things: A survey," *IEEE Internet of Things Journal*, vol. 5, no. 1, pp. 1–27, 2018. <https://doi.org/10.1109/JIOT.2017.2773600>.

- [9] P. C. Büttendender, J. L. V. Barbosa, and M. G. Martins, "Ubiquitous computing applied to mental health: Trends and research focus," in *Proceedings of the 24th Brazilian Symposium on Multimedia and the Web*, WebMedia '18, (New York, NY, USA), p. 73–76, Association for Computing Machinery, 2018. <https://doi.org/10.1145/3243082.3267456>.
- [10] N. Palmius, M. Osipov, A. C. Bilderbeck, G. M. Goodwin, K. Saunders, A. Tsanas, and G. D. Clifford, "A multi-sensor monitoring system for objective mental health management in resource constrained environments," in *Appropriate Healthcare Technologies for Low Resource Settings (AHT 2014)*, pp. 1–4, 2014. <https://doi.org/10.1049/cp.2014.0764>.
- [11] M. Dang, C. Mielke, A. Diehl, and R. Haux, "Accompanying depression with fine - a smartphone-based approach," *Studies in health tech. and informatics*, vol. 228, pp. 195–9, 2016.
- [12] N. Watanabe, M. Horikoshi, M. Yamada, S. Shimodera, T. Akechi, K. Miki, M. Inagaki, N. Yonemoto, H. Imai, A. Tajika, Y. Ogawa, N. Takeshima, Y. Hayasaka, and T. A. Furukawa, "Adding smartphone-based cognitive-behavior therapy to pharmacotherapy for major depression (FLATT project): study protocol for a randomized controlled trial," *Trials*, vol. 16, no. 293, pp. 1–13, 2015. <https://doi.org/10.1186/s13063-015-0805-z>.
- [13] D. C. Mohr, E. Montague, C. Stiles-Shields, S. M. Kaiser, C. Brenner, E. Carty-Fickes, H. Palac, and J. Duffecy, "Medlink: A mobile intervention to address failure points in the treatment of depression in general medicine," in *2015 9th Int. Conf. on Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, pp. 100–107, 2015. <https://doi.org/10.4108/icst.pervasivehealth.2015.259042>.
- [14] M. Faurholt-Jepsen, M. Vinberg, M. Frost, E. M. Christensen, J. E. Bardram, and L. V. Kessing, "Smartphone data as an electronic biomarker of illness activity in bipolar disorder," *Bipolar Disorders*, vol. 17, no. 7, pp. 715–728, 2015. <https://doi.org/10.1111/bdi.12332>.
- [15] O. Mayora, B. Arnrich, J. Bardram, C. Dräger, A. Finke, M. Frost, S. Giordano, F. Gravenhorst, A. Grunerbl, C. Haring, R. Haux, P. Lukowicz, A. Muaremi, S. Mudda, S. Ohler, A. Puiatti, N. Reichwaldt, C. Scharnweber, G. Troester, L. V. Kessing, and G. Wurzer, "Personal health systems for bipolar disorder anecdotes, challenges and lessons learnt from monarca project," in *2013 7th Int. Conf. on Pervasive Computing Technologies for Healthcare and Workshops*, pp. 424–429, 2013. <https://doi.org/10.4108/icst.pervasivehealth.2013.252123>.
- [16] G. Valenza, C. Gentili, A. Lanati, and E. P. Scilingo, "Mood recognition in bipolar patients through the psyche platform: Preliminary evaluations and perspectives," *Artif. Intell. Med.*, vol. 57, no. 1, pp. 49–58, 2013. <https://doi.org/10.1016/j.artmed.2012.12.001>.
- [17] L. G. Jaimes, M. Llofriu, and A. Rajj, "Preventer, a selection mechanism for just-in-time preventive interventions," *IEEE Transact. on Affect. Comp.*, vol. 7, no. 3, pp. 243–257, 2016. <https://doi.org/10.1109/TAFFC.2015.2490062>.
- [18] M. R. Kamdar and M. J. Wu, "Prism: A data-driven platform for monitoring mental health," *Pac. Symp. on Biocomp.*, vol. 21, pp. 333–344, 2016.
- [19] M. Kerz, A. Folarin, N. Meyer, M. Begale, J. MacCabe, and R. J. Dobson, "Sleepsight: A wearables-based relapse prevention system for schizophrenia," in *Proceedings of the 2016 ACM Int. Joint Conf. on Pervasive and Ubiquitous Computing: Adjunct, UbiComp '16*, (New York, NY, USA), pp. 113–116, Association for Computing Machinery, 2016. <https://doi.org/10.1145/2968219.2971419>.
- [20] S. C. L. Telles, Érika Antunes Corrêa, B. L. Caversan, J. de Moraes Mattos, and R. S. C. Alves, "Significado clínico da actigrafia," *Rev. Neurociências*, vol. 19, no. 1, pp. 153–161, 2011. <https://doi.org/10.34024/rnc.2011.v19.8413>.
- [21] N. Eagle and A. S. Pentland, "Eigenbehaviors: identifying structure in routine," *Behavioral Ecology and Sociobiology*, vol. 63, no. 7, pp. 1057–1066, 2009. <https://doi.org/10.1007/s00265-009-0739-0>.
- [22] E. Garcia-Ceja, M. Riegler, P. Jakobsen, J. Tørresen, T. Nordgreen, K. J. Oedegaard, and O. B. Fasmer, "Depresjon: A motor activity database of depression episodes in unipolar and bipolar patients," in *Proceedings of the 9th ACM Multimedia Systems Conference, MMSys '18*, (New York, NY, USA), p. 472–477, Association for Computing Machinery, 2018. <https://doi.org/10.1145/3204949.3208125>.
- [23] S. A. Montgomery and M. Åsberg, "A new depression scale designed to be sensitive to change," *British J. of Psych.*, vol. 134, no. 4, pp. 382–389, 1979. <https://doi.org/10.1192/bjp.134.4.382>.
- [24] N. S. Altman, "An introduction to kernel and nearest-neighbor nonparametric regression," *The American Statistician*, vol. 46, no. 3, pp. 175–185, 1992. <https://doi.org/10.2307/2685209>.



Paulo César Büttendender Graduado em Análise e Desenvolvimento de Sistemas pela Unisinos em 2011, concluiu o curso recebendo a premiação de aluno destaque 2011 pela Sociedade Brasileira de Computação. Concluiu mestrado e doutorado em Computação Aplicada pela Unisinos em 2013 e 2020. Trabalhou de 2005 a 2010 como desenvolvedor de software no Grupo Meta, e a partir de 2010 como engenheiro de software no SAP Labs Latin America na arquitetura e projeto de uma solução para o mercado de Agronegócio desenvolvido em conjunto com times dos EUA, Índia e Brasil. Desde então foi responsável técnico pela 3ª versão do SAP Agricultural Contract Management liderando um time de 12 desenvolvedores e responsável técnico e funcional do SAP Commodity Management option for Deal Capture liderando um time de 40 desenvolvedores. Trabalhando com indústrias do setor de Óleo e Gás e de Metais e Mineração e clientes localizados nos EUA, Arábia Saudita, Inglaterra, Canadá, Colômbia e Suíça. Atualmente é engenheiro de software no SAP Data Warehouse Cloud.



Eduardo Gonçalves de Azevedo Neto Estudante de Ciência da Computação pela universidade Unisinos. Bolsista da PIBIC do CNPq, trabalhou em um projeto de mapeamento sistemático com o professor Jorge Luis Victória Barbosa e professor João Elison da Rosa Tavares.



Weslei Felipe Heckler Possui graduação em Ciência da Computação pela Universidade Feevale. É mestrando no Programa de Pós-Graduação em Computação Aplicada (PPGCA) da Universidade do Vale do Rio dos Sinos (Unisinos). Suas áreas de interesse são Data Science, Machine Learning e Tecnologia aplicada à Saúde.



Jorge Luis Victória Barbosa Possui graduação em Tecnologia em Processamento de Dados (1990) e Engenharia Elétrica (1991) pela Universidade Católica de Pelotas (UCPel). Ele obteve especialização em Engenharia de Software (UCPel, 1993) e concluiu mestrado e doutorado em ciência da computação na Universidade Federal do Rio Grande do Sul (UFRGS, 1996 e 2001). Em 2011 realizou pós-doutorado na Sungkyunkwan University (SKKU, Suwon, Coreia do Sul). Em 2020 realizou pós-doutorado na University of California Irvine (UCI, Irvine, USA) através de uma bolsa do Programa CAPES/PRINT (professor visitante no Exterior Sênior). Jorge é Professor Titular II na Universidade do Vale do Rio dos Sinos (Unisinos). Ele atua professor no Programa de Pós-graduação em Computação Aplicada (PPGCA) e no Mestrado Profissional em Engenharia Elétrica. Jorge coordena o Laboratório de Computação Móvel (Mobilab) e atua como Bolsista de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora (bolsa DT - atualmente no Nível 1C) do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).