

Um Modelo Sensível ao Contexto para Avaliação da Saúde Mental por meio da Variabilidade da Frequência Cardíaca

Rodrigo Simon Bavaresco¹, Jorge Luis Victória Barbosa¹

¹Universidade do Vale do Rio dos Sinos (UNISINOS)
Av. Unisinos, 950 – Cristo Rei, São Leopoldo – RS, 93022-000

rsbavaresco@gmail.com, jbarbosa@unisinoss.br

Abstract. *The traditional method of mental health assessment, usually performed by a psychotherapist, shows relevant rates of inaccuracy. This work presents RevitalMe model, which analyzes the heart rate in order to contribute to the traditional method. The model provides daily information of the individual to psychotherapist, establishing a correlation between the mental health and the places frequented, through context-awareness. The evaluation of the model was performed with the implementation and use of a prototype applied to stress, which presents F1-Score of 88% in classification status of the individual between “stressed” and “not stressed”. The perceived utility of the model is 83% according to 5 psychotherapists.*

Resumo. *O método tradicional de avaliação da saúde mental, realizado normalmente por um psicoterapeuta, mostra índices de imprecisão relevantes. Este trabalho apresenta o modelo RevitalMe, que analisa a frequência cardíaca a fim de contribuir ao método tradicional. O modelo proporciona ao psicoterapeuta informações do dia a dia do indivíduo, estabelecendo uma correlação entre a saúde mental e os lugares frequentados, por meio da sensibilidade ao contexto. A avaliação do modelo foi realizada com a implementação e uso de um protótipo aplicado ao estresse, que apresenta F1-Score de 88% na classificação do estado do indivíduo entre “estressado” e “não estressado”. A utilidade percebida do modelo é de 83% de acordo com 5 psicoterapeutas.*

1. Introdução

Segundo estimativas realizadas pelo *World Health Organization* [WHO 2017], mais de 300 milhões de pessoas no mundo sofrem com transtornos depressivos e 264 milhões sofrem com transtornos de ansiedade, o que representa respectivamente 4,4% e 3,6% da população mundial. Ambos podem ocorrer como resultado de não lidar adequadamente com um evento estressante na vida. Desta forma, o estresse mental também deve ser levado em consideração. Ele pode reduzir o desempenho diário do indivíduo, causar disfunções cognitivas, doenças cardiovasculares, depressão e conduzir à morte [WHO 2001].

Nas últimas décadas, novas informações dos campos da neurociência e da medicina têm avançado na compreensão do funcionamento mental. Elas indicam que transtornos mentais resultam da interação biológica (predisposição genética) com fatores psicológicos e sociais, e formam-se essencialmente no cérebro [WHO 2001]. No entanto,

mesmo possuindo uma origem psicológica, transtornos mentais afetam diversos processos fisiológicos do corpo humano [Quintana et al. 2016].

A frequência cardíaca é um processo fisiológico que quando exposta a transtornos mentais sofre alteração. O Sistema Nervoso Autônomo (SNA) é um sistema que envolve-se na geração dessa excitação fisiológica [Rajendra Acharya et al. 2006]. O SNA é composto pelo Sistema Nervoso Simpático (SNS) e pelo Sistema Nervoso Parassimpático (SNP). No momento em que o SNA é desencadeado, o Sistema Nervoso Parassimpático (SNP) é suprimido e o Sistema Nervoso Simpático (SNS) torna-se ativo [Taelman et al. 2008]. Isso resulta na secreção dos hormônios epinefrina e norepinefrina no fluxo sanguíneo, que conduzem à mudanças na Frequência Cardíaca (FC) e na Variabilidade da Frequência Cardíaca (VFC).

Segundo Rajendra Acharya et al. (2006), conceitua-se a VFC como a variação ao longo do tempo entre batimentos cardíacos consecutivos. A VFC é normalmente obtida por meio da leitura dos sinais de um eletrocardiograma (ECG), com duração de minutos ou horas, e calculada a diferença entre duas ondas R, denominando-se esta diferença de intervalos RR [Peltola 2012]. A fim de obter os índices da VFC, pode-se analisar instrumentos tais como o cardiófrequencímetro. Este instrumento encontra-se em dispositivos vestíveis - *wearables* - e apresenta resultado aceitável quando comparado ao ECG.

Para a avaliação de indivíduos que possam apresentar problemas com a saúde mental, o método tradicional realizado por um especialista, normalmente um psicoterapeuta, apresenta grandes índices de imprecisão [Webb and Parks 2016, Quintana et al. 2016, Choi et al. 2017]. Esta avaliação acontece por meio de uma análise cuidadosa de informações históricas do indivíduo e dos familiares, bem como entrevistas clínicas esquematizadas estruturalmente, onde o paciente informa seus sintomas e o nível do estado psicológico [WHO 2001]. De acordo com Webb e Parks (2016), este processo é subjetivo e pode ser afetado pelos próprios problemas de saúde mental do indivíduo, problemas de memória ou habilidades de articular o que está sendo vivenciado. Além disso, os pacientes podem relatar menores sintomas dependendo das consequências reais de um diagnóstico. Conforme Quintana, Alvares e Heathers (2016), podem existir dificuldades no diagnóstico preciso caso o entrevistador seja alguém inexperiente. Ademais, os diagnósticos obtidos através de questionários e auto-avaliações são os meios menos precisos para coletar informações, porque a maioria dos pacientes desconhece ou não consegue identificar corretamente o que é importante [Quintana et al. 2016, Choi et al. 2017].

Portanto, o modelo descrito neste artigo, denominado *RevitalMe*, apresenta como contribuições: (i) analisar a fisiologia como meio mais objetivo a fim de contribuir ao método tradicional; (ii) utilizar o potencial de dispositivos móveis para coletar dados do dia a dia com o uso da sensibilidade ao contexto e (iii) apresentar índices de saúde mental de um paciente para um psicoterapeuta, correlacionando-os com os lugares frequentados, para fornecer um conjunto de informações que auxiliem as decisões psicoterapêuticas. Salienta-se que estes objetivos vão ao encontro das colocações de Tal e Torous (2017). De acordo com os autores, o mundo encontra-se no início de uma era que deve prover novos conhecimentos e novas ferramentas para estimular o diagnóstico, tratamento, reabilitação e recuperação da saúde mental [Tal and Torous 2017].

Este artigo está organizado em seis seções. A seção 2 apresenta os trabalhos re-

lacionados. A seção 3 descreve o modelo proposto, denominado *RevitalMe*. A seção 4 apresenta os aspectos da implementação do *RevitalMe* e na seção 5 descrevem-se os métodos de avaliação e os resultados. Por fim, na seção 6 apresentam-se as conclusões e os trabalhos futuros.

2. Trabalhos Relacionados

Esta seção apresenta uma revisão da literatura em busca dos trabalhos relacionados com o modelo proposto. Para esta revisão, considerou-se como principal referência um estudo sistemático previamente realizado pelo autor. Neste estudo, cujo objetivo foi mapear o estado da arte da computação ubíqua aplicada à fisiologia, enfatizando à saúde mental, buscaram-se artigos acadêmicos em 8 bases de dados na área da ciência da computação e da saúde. Desta forma, aplicaram-se critérios de inclusão e exclusão de artigos que, por fim, resultaram em 5 trabalhos. Estes trabalhos serão apresentados e comparados a seguir.

Tabela 1. Comparativo entre os trabalhos relacionados

	Ambiente	Aspectos Fisiológicos	Contexto	Saúde Mental
[Mayya et al. 2015]	Laboratório	VFC	Não	Estresse
[Al Osman et al. 2014]	Real	VFC	Não	Estresse
[Hovsepian et al. 2015]	Real	VFC, Resp.	Não	Estresse
[Dobbins and Fairclough 2017]	Real	VFC	Apresenta	Ansiedade
[Gjoreski et al. 2016]	Real	FC, VFC, BVP, GSR, ST	Apresenta	Estresse

Mayya et al. (2015) apresentaram um trabalho para distinguir o estado das pessoas entre estressado e não estressado, ajudando o usuário a entender melhor os padrões de estresse ao longo do dia e a tomar as medidas apropriadas para gerenciar situações estressantes. No trabalho de Al Osman, Eid e El Saddik (2014) propôs-se um modelo de referência para monitoramento contínuo da fisiologia e transmissão de mensagens relacionadas com o estado mental do usuário. Os testes da aplicação foram realizados inicialmente em laboratório e posteriormente em um ambiente de trabalho.

Os autores Hovsepian et al. (2015) apresentaram um modelo para avaliação contínua do estresse. O modelo foi treinado utilizando dados coletados em laboratório e testado tanto em laboratório como durante atividades diárias. No trabalho realizado por Dobbins e Fairclough (2017), visou-se a criação de uma plataforma móvel para prover autoconhecimento aos usuários, monitorando ansiedade e raiva durante a atividade de dirigir veículos frente a situações reais. No trabalho de Gjoreski et al. (2016), apresentou-se um método para detecção contínua do estresse usando dados fornecidos por um dispositivo de pulso comercial. Além disso, os autores utilizaram ciência de contexto para compôr o método.

A fim de comparar os trabalhos relacionados, definiram-se 4 critérios como pode-se visualizar na Tabela 1. Portanto, os critérios de comparação são: (i) ambiente de aplicação, que sinaliza os trabalhos criados e testados ou diante de atividades reais do dia a dia ou em laboratórios; (ii) relação dos aspectos fisiológicos utilizados para computação, sendo obrigatório a presença da VFC; (iii) utilização de dados de contexto, considerado por Hovsepian et al. (2015) como relevante na tomada de decisão decorrente da fisiologia; (iv) saúde mental, evidenciando qual é a aplicação dos modelos propostos. A contribuição

deste trabalho é composta pelos quatro critérios de comparação: analisa-se aspectos fisiológicos em ambientes reais utilizando sensibilidade ao contexto para inferir o estado psicológico de indivíduos, com o intuito de fornecer gráficos para psicoterapeutas.

3. Modelo RevitalMe

O *RevitalMe* propõe um modelo computacional com a finalidade de fornecer resultados do cotidiano de indivíduos para acompanhamento psicoterapêutico diante das terapias estabelecidas. Para alcançar tal finalidade, dois atores devem ser envolvidos na interação com o modelo: o psicoterapeuta, normalmente um psicólogo ou psiquiatra, e o paciente, um indivíduo adulto qualquer.

A primeira interação entre atores e modelo acontece em uma clínica, onde o modelo permite o vínculo de tratamento entre o paciente e o psicoterapeuta envolvido. Na clínica, o modelo *RevitalMe* permite que, a partir de um aplicativo para dispositivo móvel, denominado *RevitalMe-Mobile*, seja pareado um *wearable* com sensor de frequência cardíaca para obter dados fisiológicos tais como a FC e a VFC.

Em seguida, o paciente deverá selecionar localizações semânticas em conjunto com o profissional. A localização semântica refere-se à um lugar qualquer que faça parte do cotidiano do paciente, sendo nomeado por ele próprio. O profissional irá conduzi-lo a identificar lugares estratégicos que possam estar desencadeando problemas na sua saúde mental ou trazendo benefícios. Para tal atividade, o aplicativo *RevitalMe-Mobile* possui uma interface gráfica específica.

No decorrer da utilização do *RevitalMe-Mobile*, são formados históricos de contextos [Da Rosa et al. 2016], provenientes dos deslocamentos diários do paciente. Considerando-os como fonte de dados, o modelo é responsável por realizar processamento com objetivo de obter os índices de saúde mental, correlacionando-os com a localização semântica. Entende-se por índices de saúde mental o resultado psicofisiológico em valor numérico computado pelo modelo, proveniente da execução de um *pipeline* de aprendizado de máquina. Este resultado indica o percentual de tempo em que o paciente apresenta determinado estado psicológico, de acordo com a permanência na localização semântica.

A fim de apresentar os resultados ao psicoterapeuta, disponibiliza-se um *website*, denominado *RevitalMe-Web*, para realizar consultas no histórico de contextos. Assim, torna-se possível que o profissional acompanhe as atividades do paciente, realizando comparações diárias e entre localizações semânticas, dando importância aos índices de saúde mental computados, com o intuito de tomar decisões para as terapias estabelecidas.

3.1. Arquitetura do Modelo

Conforme pode-se visualizar na Figura 1, fazem parte da arquitetura três componentes: o aplicativo para dispositivo móvel denominado *RevitalMe-Mobile*, o *website* denominado *RevitalMe-Web* e o componente servidor, denominado *RevitalMe-Server*.

Cada componente possui responsabilidades distintas. O *RevitalMe-Mobile* coleta dados sensíveis ao contexto do paciente, provenientes de sensores do dispositivo móvel e do *wearable*, por meio de um agente de *software*. Pode-se citar como requisitos funcionais deste componente: *cadastrar e autenticar usuário, cadastrar localização*

semântica, *parear wearable*, *visualizar dados cardíacos* e *permitir vínculo terapêutico*. O *RevitalMe-Web* mantém informações do psicoterapeuta e apresenta resultados computados pelo servidor para o profissional. Os requisitos funcionais são: *cadastrar e autenticar profissional*, *solicitar vínculo ao paciente*, *consultar dados do paciente* e *controlar estado da leitura*.

O *RevitalMe-Server* é responsável principalmente por receber dados do *RevitalMe-Mobile*, manter históricos de contextos, processar dados para o estado psicológico e fornecer consultas ao *RevitalMe-Web*. Na Figura 1, pode-se ver a interação entre os três componentes mencionados, bem como a definição das estruturas de *software* do *RevitalMe-Server*, subdivididos em camadas, módulos e agentes.

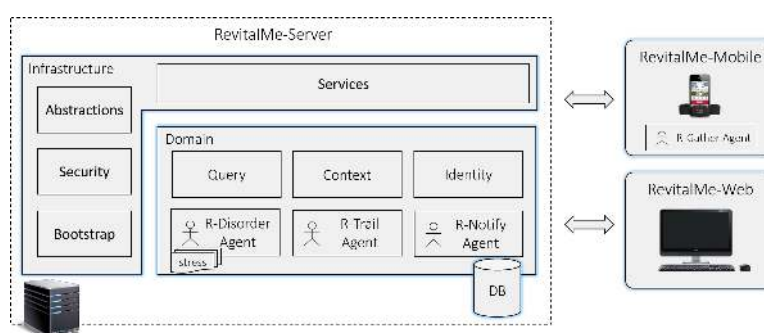


Figura 1. Arquitetura do modelo *RevitalMe*

As camadas *Infrastructure* e *Domain* provêm baixo acoplamento entre seus respectivos módulos. Os módulos de infraestrutura são quatro: *Services*, responsável por encontrar as *Uniform Resource Identifiers (URI)* dos módulos de domínio, expondo-as como serviços; *Abstraction*, modelado para que encapsule a complexidade de determinadas necessidades do servidor, abstraindo-as e reaproveitando código comum aos componentes; e *Security*, que fornece autenticação e autorização ao modelo. Por fim, o módulo *Bootstrap* é responsável por invocar métodos de inicialização de cada módulo de domínio bem como inicializar os agentes de *software*.

Os módulos de domínio são três: *Identity*, que visa manter as identidades de usuários e seus perfis, bem como os relacionamentos de vínculo terapêutico; e *Context*, que recebe em seus serviços os elementos de contexto referentes à entidade paciente, formando históricos de contextos. Desta forma, os elementos que compreendem o contexto são: a identidade do usuário, a localização, a data e a hora, a FC, a VFC, a atividade do usuário (parado, caminhando, correndo, de bicicleta e em veículo) e o estado da leitura. Além disso, este módulo apresenta serviços para manter localizações semânticas. Por fim, o módulo *Query* é responsável por receber as consultas que serão executadas no histórico de contextos e acionar o *Agente R-Trail*.

3.1.1. Agentes do *RevitalMe*

Nesta seção apresentam-se os agentes de *software* do *RevitalMe*. Os agentes foram modelados por meio da metodologia *Prometheus*, fazendo uso de um ambiente gráfico de

modelagem denominado *Prometheus Design Tool (PDT)* ¹.

Escolheu-se utilizar agentes de *software* para modelar estes componentes pelas características que os mesmos apresentam, como a autonomia para execução de tarefas de acordo com as mudanças no ambiente a fim de cumprir determinados objetivos. Além disso, possuem características sociáveis, ou seja, para alcançar um objetivo em comum necessitam a interação com outros agentes, providas por meio de mensagens. Na Figura 2 pode-se visualizar a visão geral dos agentes do *RevitalMe*, onde cada agente é detalhado com suas ações, percepções e mensagens.

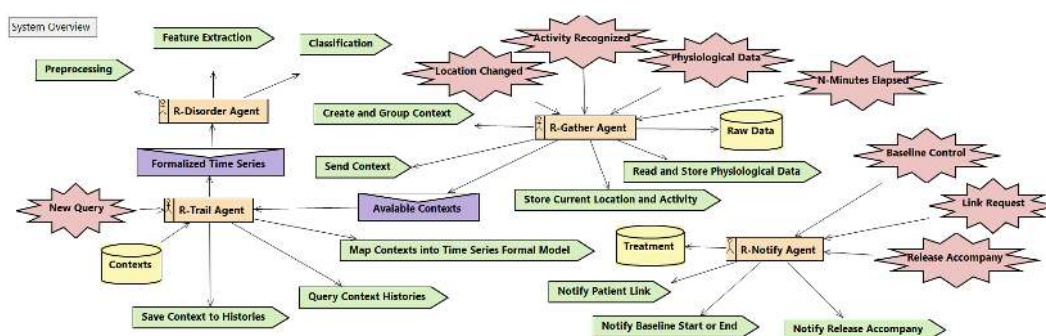


Figura 2. Diagrama da visão geral dos agentes do sistema

O *Agente R-Gather* é responsável por identificar mudanças no ambiente relacionadas com a atividade, localização, fisiologia e tempo, no decorrer da utilização do *RevitalMe-Mobile* por parte do paciente. O *Agente R-Trail* é responsável por identificar a chegada de novas mensagens ou a execução de uma nova consulta, com a finalidade de persistir registros de contextos ou recuperá-los, preparando-os para processamento dos índices da saúde mental. O *Agente R-Disorder*, por sua vez, deve realizar três etapas de processamento sob séries temporais extraídas do histórico de contextos, a fim de obter resultados numéricos que representem índices de saúde mental. As três etapas são: pré-processamento, extração de características e classificação. Elas caracterizam um *pipeline* de aprendizado de máquina. Este agente considera uma série temporal válida para processamento apenas se não possui atividade física, ou seja, apresentar a atividade “parado”. Por fim, o *Agente R-Notify* deve identificar operações e eventos que aconteceram no modelo referente aos tratamentos entre o psicoterapeuta e o paciente, notificando-os.

4. Aspectos da Implementação

Com o intuito de avaliar o modelo *RevitalMe*, tornou-se necessário realizar a implementação de um protótipo. Portanto, codificaram-se os três componentes da arquitetura do modelo: *RevitalMe-Mobile*, *RevitalMe-Web* e o *RevitalMe-Server*.

Para o protótipo do *RevitalMe-Mobile* realizou-se a codificação de um aplicativo na plataforma *Android* compilado com a API mínima 19, que corresponde ao *Android 4.4 (Kit Kat)*. No *RevitalMe-Mobile*, implementaram-se interfaces gráficas específicas para cada requisito funcional descrito anteriormente. Além disso, implementou-se o agente de *software R-Gather*. As percepções do agente foram codificadas como *Android Services* por possuírem três características: são operações de longa duração, monitoram elementos

¹ <https://sites.google.com/site/rmitagents/software/prometheusPDT>

Tabela 2. Características no domínio de tempo e frequência

Característica	Unidade	Fórmula
<i>Domínio de Tempo</i>		
<i>Average of RR interval</i>	<i>ms</i>	$\overline{RR} = \frac{1}{N} \sum_{j=1}^N RR_j$
<i>Standard Deviation of RR intervals</i>	<i>ms</i>	$\sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_j - \overline{RR})^2}$
<i>Standard Deviation of the Average RR intervals</i>	<i>ms</i>	$\sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_{1j} - \overline{RR}_1)^2}$
<i>Root Mean Square of RR interval Diff.</i>	<i>ms</i>	$\sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_{j+1} - RR_j)^2}$
<i>% of RR intervals that differ by more than 50 ms</i>	<i>%</i>	$\frac{NN50}{N-1} \times 100\%$
<i>Domínio de Frequência</i>		
<i>Low Frequency (LF)</i>	<i>ms²</i>	Potência espectral entre 0,04 e 0,15 Hz
<i>High Frequency (HF)</i>	<i>ms²</i>	Potência espectral entre 0,15 e 0,4 Hz
<i>Ratio LF/HF</i>	<i>ms²</i>	Razão entre LF e HF

de *hardware* e realizam chamadas à APIs externas. Realizam-se todas estas operações em *background*, ou seja, sem a intervenção do paciente. Para verificar as mudanças de localização bem como o reconhecimento das atividades do usuário utilizou-se a API *Google Location Services* ². Para a leitura da frequência cardíaca e dos intervalos RR, codificou-se um *Android Service* para as conexões *Bluetooth Low Energy* do monitor cardíaco. Os intervalos RR foram lidos de forma contínua e com curta duração (*short-term*) a cada 5 minutos [Quintana et al. 2016] e enviados ao *RevitalMe-Server* por meio de uma chamada à API RESTful, utilizando o protocolo HTTP.

Implementou-se o componente *RevitalMe-Web* como um *website*, fazendo uso do *framework .Net Core* na versão 2.0 com uso das linguagens C# e Javascript, bem como HTML 5 e CSS 3 para construção das telas. Para o cadastro, a autenticação e a identificação do psicoterapeuta utilizou-se a API do *Google Plus* ³.

Realizou-se a codificação do *RevitalMe-Server* com uso do *framework .Net Core* na versão 2.0 e na linguagem C#. Os módulos de infraestrutura bem como os módulos de domínio foram codificados com a utilização de interfaces, classes abstratas e classes, de acordo com cada responsabilidade mencionada no modelo. No módulo *Context*, considerou-se um raio menor ou igual a 10 metros para identificar a relação de pertinência entre contextos e a localização semântica, com a utilização da fórmula de *Haversine*. Além disso, implementaram-se os agentes de *software R-Trail* e o *R-Disorder*, não sendo necessária a codificação do *Agente R-Notify* para validação do modelo, porque este apenas disponibiliza uma melhor usabilidade para os usuários. Ambos os agentes implementados foram codificados com o uso de classes, onde os *percepts* e mensagens dos agentes foram codificados como métodos das classes.

Implementou-se o *Agente R-Disorder* fazendo uso de classes na linguagem C# que interoperam com *scripts* na linguagem R. Estes *scripts* foram codificados com uso da biblioteca *RHRV*. Para pré-processamento, codificou-se o agente para enviar uma série temporal de 5 minutos à um *script* na linguagem R. Este *script* computa a remoção dos artefatos fisiológicos ou técnicos dos intervalos [Peltola 2012]. Desta forma, codificou-se a remoção das batidas cardíacas que apresentam diferença no intervalo maior do que 10% da média dos últimos 50 intervalos. Além disso, considerou-se aceitável os valores da FC

²<https://developer.android.com/training/location/>

³<https://developers.google.com/+/web/api/rest/>

com mínimo de 25 bpm e máximo de 180 bpm. Com o intuito de extrair características das séries temporais no domínio de tempo e no domínio da frequência, conforme a Tabela 2, codificou-se outro *script*. As características no domínio de tempo foram obtidas por cálculos estatísticos, conforme apresentado. As características do domínio de frequência foram obtidas computando a *Transformada Rápida de Fourier* das séries de intervalos RR reamostrados de forma uniforme a 4 Hz, utilizando interpolação linear.

Adicionalmente, para a etapa de classificação da saúde mental do indivíduo, implementou-se no *Agente R-Disorder* rotinas para classificar o nível de estresse. Desta forma, utilizou-se aprendizado de máquina para classificar entre o estado de “estressado” e o estado “não estressado”, por meio de um modelo treinado com o algoritmo de classificação *Support Vector Machine*, o qual obteve o melhor desempenho dentre três classificadores, de acordo com testes estatísticos que foram realizados. Apresenta-se na próxima seção os testes estatísticos, os métodos de treinamento, validação e avaliação do modelo.

5. Avaliação e Resultados

A metodologia de avaliação e resultados está organizada em três perspectivas, conforme detalha-se a seguir.

5.1. Computação dos Índices de Saúde Mental

Nesta perspectiva busca-se avaliar o *pipeline* de aprendizado de máquina por meio do desempenho de classificação de três algoritmos para prever o estado psicológico como “estressado” ou “não estressado”. Assim, esta avaliação nos permite descobrir o melhor dos três classificadores a serem usados na implementação do protótipo.

Os três classificadores utilizados na avaliação foram o *Naive Bayes (NB)*, *K-Nearest Neighbors (KNN)* e *Support Vector Machines (SVM)*. Eles foram escolhidos experimentalmente e treinados usando o mesmo *pipeline* de aprendizado de máquina apresentado anteriormente, isto é, pré-processamento e extração de características. A entrada de dados fisiológicos para treinamento e teste foi derivada do trabalho de [Healey and Picard 2005], presente na base de dados *Physionet* [Goldberger et al. 2000], onde foram mensurados fisiologicamente os níveis de estresse de 17 indivíduos em situação de condução de veículo.

Para cada indivíduo foram geradas séries temporais de 5 minutos com intervalos RR, provenientes do ECG, rotulados de acordo com os resultados do trabalho de Healey and Picard (2005) (*ground truth*). Isto é, para a condição de repouso, neste trabalho, considerou-se como o estado “não estressado” e para as duas condições de condução (rodovia e cidade), considerou-se como o estado “estressado”. Os dados totais foram divididos em dois segmentos, compreendendo 70% para o *dataset* de treino e 30% para *dataset* de teste. No experimento de treino foi realizado um *grid search* com validação cruzada (*k-fold cross validation*) permitindo encontrar hiperparâmetros para cada classificador. No experimento de teste foi utilizado o modelo treinado com os hiperparâmetros e para avaliar a performance deste, a amostra desconhecida, ou seja, o *dataset* de teste, foi dado como entrada.

Com os resultados, calcularam-se métricas estatísticas para avaliar cada classificador: *Sensitividade* ou *Recall*, que se refere a identificar corretamente indivíduos sob es-

três; *Especificidade*, que se refere a identificar corretamente os indivíduos que não estão sob estresse; *Precisão*, que é uma medida que nos diz qual a proporção de indivíduos que foram identificados como estressados e na verdade, estavam estressados e *Acurácia*, que é uma medida de previsões corretas de indivíduos estressados e não estressados. Por fim, também é apresentado o *F1-Score*, que é a média ponderada da *Precisão* e do *Recall*.

Tabela 3. Resultados estatísticos da avaliação dos três classificadores

Classificador	Sens.	Espec.	Prec.	Acc.	F1
Naive Bayes	0.72	1.0	1.0	0.81	0.83
K-Nearest Neighbors	0.78	0.83	0.90	0.80	0.83
Support Vector Machine	0.88	0.75	0.88	0.84	0.88

A Tabela 3 apresenta os resultados das métricas de cada classificador. Estes resultados mostram que, embora o SVM tenha a menor *Especificidade*, quando analisamos *Acurácia*, o SVM possui o maior valor. Além disso, procura-se um equilíbrio entre *Recall* e *Precisão*, então deve-se analisar o maior *F1-Score*. Nesse caso, o SVM também obteve o maior valor. Portanto, o SVM foi o melhor dos três classificadores nesta avaliação e foi usado no desenvolvimento do protótipo.

5.2. Correlação dos Índices de Saúde Mental e Localização Semântica

Para esta perspectiva foi realizado um teste de aceitação, denominado teste alfa, do *RevitalMe*. Desta forma, avaliou-se indiretamente os aspectos de modelagem e funcionalidades do sistema, por meio da utilização do protótipo durante 8 dias de um indivíduo.

Inicialmente, foi realizada a publicação do *RevitalMe-Server* no *Azure*, ambiente de *Cloud Computing* da *Microsoft*, e foi instalado o *RevitalMe-Mobile* no *smartphone* do indivíduo. O *RevitalMe-Web* foi publicado localmente e um vínculo terapêutico fictício foi realizado. Em seguida, o indivíduo cadastrou 5 localizações semânticas de três cidades distintas, pareou o *wearable Polar H7* e iniciou o monitoramento.

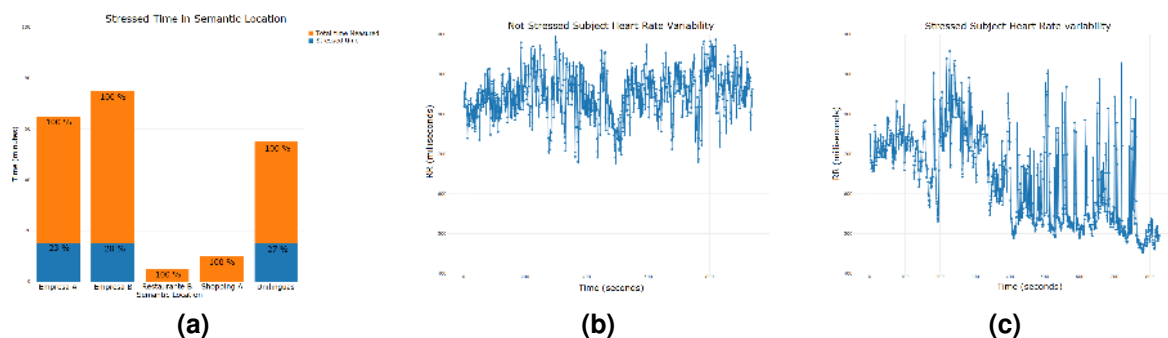


Figura 3. Gráficos provenientes da utilização do *RevitalMe*

Após a utilização, uma consulta da correlação dos índices de estresse e a localização semântica foi executada de forma *online* pelo *RevitalMe-Web*, e foi processada e gerada pelo *RevitalMe-Server*. Utilizou-se um filtro de data abrangendo um dos oito dias de uso do sistema, e a Figura 3a representa o resultado da consulta. Nela observa-se

a correlação entre as 5 localizações semânticas frequentadas e os minutos de permanência nas mesmas, sendo evidenciado o percentual de tempo em que o indivíduo apresentou estresse. Além disso, a Figura 3b ilustra um tacograma dos intervalos RR do indivíduo neste dia em horário que não apresentou estresse. Por outro lado, a Figura 3c ilustra um tacograma dos intervalos RR em horário que apresentou estresse. Ambos os tacogramas ilustram a real variação fisiológica coletada pelo protótipo em cada situação.

5.3. Utilidade Percebida do RevitalMe

Esta perspectiva foi criada para avaliar a contribuição que as ideias gerais do modelo podem fornecer para a tomada de decisão psicoterapêutica. Desta forma, para organizar esta perspectiva na busca por resultados baseou-se no Modelo de Aceitação de Tecnologia (TAM) [Marangunic and Granic 2015].

Por meio da aplicação de um questionário com 6 afirmações para 5 especialistas da área psicoterapêutica, buscou-se avaliar a utilidade percebida de acordo com o TAM, visto que os especialistas não utilizaram o sistema. Desta forma, foi disponibilizado uma descrição detalhada do modelo, englobando funcionalidades, objetivos e resultados direcionados totalmente para a área psicoterapêutica. As opções de respostas para as questões seguiram o padrão da escala *Likert* de cinco pontos, variando entre 1 (discordo totalmente) até 5 (concordo totalmente). As afirmações aplicadas por meio do questionário foram: (i) *concordo que existe uma relação entre o estresse mental e os lugares que o indivíduo frequenta*; (ii) *a atividade de identificar lugares que o indivíduo frequenta induz a um diálogo sobre a rotina do mesmo, facilitando a compreensão sobre seus hábitos*; (iii) *os gráficos gerados poderão me ajudar no diagnóstico e no decorrer das terapias*; (iv) *ter conhecimento prévio às consultas sobre os níveis de estresse do indivíduo traria benefícios para minha tomada de decisão*; (v) *concordo que é possível identificar uma melhora no quadro clínico do indivíduo por meio da comparação de dois gráficos gerados*; (vi) *mediante indicação, meus pacientes usariam o sistema*. Ademais, uma pergunta com resposta discursiva foi aplicada aos especialistas: *Quais os principais pontos positivos e negativos você pode observar no sistema?*

Portanto, em relação a utilidade percebida, atingida por meio do agrupamento das respostas das 6 afirmações e apresentadas na Figura 4, é possível obter como resultado que 83% dos especialistas acreditam na utilidade do *RevitalMe* diante suas propostas, sendo de forma parcial ou total. Outros 10% dos especialistas discordam parcialmente e 7% acreditam ser indiferente.




Figura 4. Utilidade Percebida do RevitalMe

No que diz respeito às respostas discursivas, pode-se elencar os pontos positivos descritos pelos especialistas, tais como: “aderência ao tratamento devido um re-

curso interessante”, “possibilidade de validar e reforçar os locais que provocam sensações agradáveis as pessoas”, “facilidade na construção do diagnóstico e na avaliação da redução dos sintomas” e “objetividade na coleta de dados, uma vez que não depende de aspectos do paciente que podem apresentar falhas, como a memória”. Por outro lado, pode-se elencar os pontos negativos, tais como: “possível sensação de perseguição no paciente” e “possível ‘boicote’ de respostas pelo paciente”. Salienta-se que o principal ponto negativo que foi relatado por um dos especialistas é: “monitorar o dia a dia do paciente não vai ao encontro com a técnica psicanalítica, que tem a associação livre como um dos pilares básicos”. Por meio deste último relato, pode-se relacionar o resultado de 10% dos especialistas discordarem parcialmente e 7% serem indiferente quanto as propostas do modelo, porque existem perfis de especialistas que apresentam atuações psicanalíticas.

6. Conclusão

Este trabalho apresentou o modelo *RevitalMe*, que auxilia a tomada de decisão dos psicoterapeutas com informações da saúde mental, provenientes do dia a dia dos pacientes. A performance do modelo foi medida pela acurácia de 84% e *F1-Score* de 88% para o melhor desempenho, utilizando o algoritmo SVM. Além disso, um teste de aceitação foi realizado no cotidiano de um indivíduo, contemplando 8 dias de uso. Este teste avaliou o potencial de correlacionar localizações semânticas com o estado psicológico do indivíduo.

Por fim, um questionário com 6 afirmações e 1 pergunta discursiva foi aplicado em 5 psicoterapeutas, para avaliar a proposta do *RevitalMe* em termos da sua utilidade. Por meio dos resultados, é possível concluir que as propostas do *RevitalMe* não se encaixam aos psicoterapeutas que seguem a linha teórica da psicanálise, visto que esta adota um método tradicional de associação livre. Por outro lado, as propostas são bem aceitas nos métodos da teoria cognitivo comportamental, porque podem utilizar o *RevitalMe* para estender ações e procurar resultados no dia a dia do paciente.

Para os trabalhos futuros, considera-se relevante melhorar o desempenho do algoritmo de classificação e aplicar testes em clínicas de psicoterapia com pacientes reais, visando obter dados que evidenciem a utilidade do *RevitalMe* na prática psicoterapêutica.

Agradecimentos

Os autores agradecem à FAPERGS, ao CNPq, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento desse trabalho.

Referências

- Al Osman, H., Eid, M., and El Saddik, A. (2014). U-biofeedback: a multimedia-based reference model for ubiquitous biofeedback systems. *Multimedia Tools and Applications*, 72(3):3143–3168.
- Choi, K.-H., Kim, J., Kwon, O. S., Kim, M. J., Ryu, Y. H., and Park, J.-E. (2017). Is heart rate variability (hrv) an adequate tool for evaluating human emotions? a focus on the use of the international affective picture system (iaps). *Psychiatry Research*, 251:192–196.
- Da Rosa, J. H., Barbosa, J. L., and Ribeiro, G. D. (2016). Oracon: An adaptive model for context prediction. *Expert Systems with Applications*, 45:56–70.

- Dobbins, C. and Fairclough, S. (2017). A mobile lifelogging platform to measure anxiety and anger during real-life driving. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pages 327–332.
- Gjoreski, M., Gjoreski, H., Luštrek, M., and Gams, M. (2016). Continuous stress detection using a wrist device – in laboratory and real life. In *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing Adjunct - UbiComp '16*, pages 1185–1193. ACM Press.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., and Stanley, H. E. (2000). Physiobank, physiotoolkit, and physionet : Components of a new research resource for complex physiologic signals. *Circulation*, 101(23):e215–e220.
- Healey, J. and Picard, R. (2005). Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on Intelligent Transportation Systems*, 6(2):156–166.
- Hovsepian, K., Al'Absi, M., Ertin, E., Kamarck, T., Nakajima, M., and Kumar, S. (2015). cstress: Towards a gold standard for continuous stress assessment in the mobile environment. In *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing - UbiComp '15*, volume 2015, pages 493–504. ACM Press.
- Marangunic, N. and Granic, A. (2015). Technology acceptance model: a literature review from 1986 to 2013. *Universal Access in the Information Society*, 14(1):81–95.
- Mayya, S., Jilla, V., Tiwari, V. N., Nayak, M. M., and Narayanan, R. (2015). Continuous monitoring of stress on smartphone using heart rate variability. In *2015 IEEE 15th International Conference on Bioinformatics and Bioengineering (BIBE)*, pages 1–5.
- Peltola, M. (2012). Role of editing of r-r intervals in the analysis of heart rate variability. *Frontiers in Physiology*, 3:148.
- Quintana, D. S., Alvares, G. A., and Heathers, J. A. J. (2016). Guidelines for reporting articles on psychiatry and heart rate variability (graph): recommendations to advance research communication. *Translational Psychiatry*, 6(5):e803–e803.
- Rajendra Acharya, U., Paul Joseph, K., Kannathal, N., Lim, C. M., and Suri, J. S. (2006). Heart rate variability: a review. *Medical & Biological Engineering & Computing*, 44(12):1031–1051.
- Taelman, J., Vandepuut, S., Spaepen, A., and Van Huffel, S. (2008). Influence of mental stress on heart rate and heart rate variability. In *IFMBE Proceedings*, volume 22, pages 1366–1369.
- Tal, A. and Torous, J. (2017). The digital mental health revolution: Opportunities and risks. *Psychiatric Rehabilitation Journal*, 40(3):263–265.
- Webb, A. K. and Parks, P. D. (2016). Psychophysiological monitoring: An approach for the diagnosis and treatment of mental health disorders. *IEEE Pulse*, 7(1):31–34.
- WHO (2001). The world health report 2001 - mental health: new understanding, new hope. Technical report.
- WHO (2017). Depression and other common mental disorders: Global health estimates. Technical report.