



UNIVERSIDADE CATÓLICA DE PELOTAS
Mestrado em Engenharia Eletrônica e Computação

Análise de Históricos de Contextos para Classificação do Estresse Mental em Situações Reais por meio da Variabilidade da Frequência Cardíaca

Disciplina: Métodos Matemáticos

Pedro Tavares

Prof. Everton Granemann Souza

Pelotas, junho de 2020


Contextualizando...

- Tema da dissertação: construir um sistema de monitoramento no âmbito da IoT e da computação móvel para coletar dados de cadeiras de rodas motorizadas e inferir situações através do processamento de históricos de contexto;
 1. Sensoriamento: coleta e transmissão de dados;
 2. Armazenamento e organização dos dados históricos;
 3. Inferências de situação através de algoritmos de aprendizado de máquina e análise de séries temporais;
 4. Predição de situações.

Objeto de estudo



Módulo
Painel



CAN



Módulo
Drive

System Overview







Diagrama de Blocos



TTGO T-Call V1.3 ESP32 + SIM800L




Prototipação do Sistema



Aplicativo Móvel

ThingSpeak App



Alert

Chg

Diag


Cal

FW

Run

Rdy

Off



Status atual

- Sensoriamento e transmissão (*ok*);
- Escolha da base de dados temporal (*em andamento*);
- Organização quais situações serão inferidas e o interesse dos atores do sistema (*em andamento*);
- **Estudo (*survey*) sobre processamento de histórico de contexto;**
- Implementação das técnicas de análise de séries temporais e algoritmos de aprendizado de máquina para fazer as inferências;


Introdução

- O estresse mental é um dos principais causadores de problemas de saúde física e emocional, e está diretamente relacionado a desordens mentais como ansiedade e depressão;
- Também está associado a doenças cardiovasculares e autoimunes, entre outras;
- Importante detectar o estado de estresse diário para o desenvolvimento de aplicações que visem o bem-estar do indivíduo;



Introdução

- O Sistema Nervoso Autônomo (SNA) é responsável por coordenar a atividade cardiovascular, digestiva e respiratória, e também controla respostas involuntárias à estímulos externos.
- Estresse mental influencia diretamente o nível da atividade autonômica, causando respostas fisiológicas como:
 - Aumento/redução da Frequência Cardíaca (FC)
 - Variabilidade da Frequência Cardíaca (VFC)



Introdução

- Os métodos atuais para detecção de situação de estresse, se baseiam em mapas de ECG associados ao relato do paciente e preenchimento de formulários para confirmar estas situações;
- Este artigo propõe o uso de um wearable associado ao celular para identificar em tempo real as situações de estresse;



Introdução

- O método proposto possui as seguintes vantagens:
 1. Captura os dados nas situações reais e não em situações “forçadas” em laboratório;
 2. Minimiza erros de viés de memória;
 3. Identifica e remove ruídos tais como movimentação e atividades físicas, pois considera o contexto para análise;
 4. Mostra a relação dos níveis de estresse e a localização em que foram mensurados;

Trabalhos relacionados



	Medidas Fisiológicas	Elementos do Contexto	Remoção de Ruído	Estresse x Localização
[Peternel et al. 2012]	EDA	Ligação, Localização, Atividade, Áudio, PC	Atividade Física	Casa e Trabalho
[Alharthi et al. 2017]	VFC	Hora, Dia, Localização, Clima, Atividade	Não	Casa e Trabalho
[Gjoreski et al. 2017]	BVP, EDA, HR, IBI, ST	Hora, Dia, Atividade	Atividade Física	Não
[Mishra et al. 2018]	VFC	Hora, Dia da semana e Atividade	Fisiológico	Não

Método (Overview)

- Foi desenvolvido um aplicativo para smartphone conectado a um sensor de frequência cardíaca. Implementou-se a coleta contínua de diversos dados que compreendem o contexto
- Essa coleta contínua de dados diversos com finalidades distintas, quando associadas compreendem o **contexto**. Esses contextos foram enviados para uma base dados na nuvem formando séries temporais de contextos; A sequência destas séries, são denominados **históricos de contexto**;



Método (Overview)

- Cada contexto possui as seguintes entidades:

- Identidade
- Fisiologia
- Atividade
- Localização
- DataHora
- Avaliação

Classificação

Coleta de Dados

- 5 voluntários durante 8 dias cada (40 dias de uso total);
- Até 8 horas diárias;
- Frequência cardíaca e intervalos RR;
- Avaliações periódicas via notificação ou a qualquer momento que o usuário desejasse;



Polar H7 BLE

Rotulagem

- Os voluntários selecionavam o nível de estresse em uma escala de “0” (não estressado) até “4” (muito estressado)
- Como na literatura não há uma definição concreta da duração do estresse nas atividades diárias, considerou-se uma janela de 10 minutos (antes e depois) de cada avaliação;
- As séries temporais deste intervalo foram rotuladas como “não estressado” para as notas 0 e 1 e “estressado” para as outras notas;

Segmentação e Pré-processamento

- **Segmentação** das séries temporais foi realizada considerando a *norma* de tempo curto com 5 minutos de duração;
- Após a segmentação, aplica-se o primeiro filtro para descartar séries temporais que apresentaram diferença maior do que 2 segundos entre dois contextos consecutivos;



Segmentação e Pré-processamento

- O **pré-processamento** das séries temporais foi dividido em duas etapas:
 1. Remoção de ruídos causados por movimentação e atividades físicas:

$$\sum_{i=1}^n (\alpha_i + \beta_i) \geq n \cdot 0.9 \wedge C_{\alpha,\beta} \geq 60$$

n = tamanho da amostra da série temporal, *short-term norm*

α = contextos com a atividade *No Veiculo*, $\alpha \in \mathbb{N}^{[0,1]}$

β = contextos coma a atividade *Imóvel*, $\beta \in \mathbb{N}^{[0,1]}$

$C_{\alpha,\beta}$ = grau de confiança da atividade, $C \in \mathbb{N}^{[0,100]}$

Segmentação e Pré-processamento

2. A segunda etapa visou eliminar ruídos fisiológicos, tal como batidas ectópicas ou ainda, dados caracterizados pelo sensor mal conectado:
 - $VFC < 0,3 \text{ seg}$ ou $VFC > 2 \text{ segundos}$ foram removidas.
 - Intervalos de VFC que diferiram mais do que 25% dos 50 intervalos anteriores ou sucessivos foram interpolados. A estratégia de interpolação visa não excluir os intervalos, possibilitando manter o tamanho próximo da série temporal original.



Extração e Seleção de Características


Característica	Unid.	Fórmula
<i>Domínio de Tempo</i>		
<i>Average of RR interval (AVRR)</i>	<i>ms</i>	$\overline{RR} = \frac{1}{N} \sum_{j=1}^N RR_j$
<i>Standard Deviation of RR intervals (SDRR)</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 (SDARR)</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. (RMSSD)</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 (pRR50)</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

Extração e Seleção de Características

Característica	Unid.	Fórmula
Domínio de Tempo		
Average of RR interval (AVRR)	$S = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n - 1}}$	$\overline{RR} = \frac{1}{N} \sum_{j=1}^N RR_j$
Standard Deviation of RR intervals (SDRR)		$\sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_j - \overline{RR})^2}$
Standard Deviation of the Average RR (SDAVRR)		$\sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_{1j} - \overline{RR_1})^2}$
Root Mean Square of RR interval Diff. (RMSSD)		$\sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_{j+1} - RR_j)^2}$
% of RR intervals that differ by more than 50 ms (pRR50)		$\frac{NN50}{N-1} \times 100\%$
Domínio de Frequência		
Low Frequency (LF)	ms ²	Potência espectral entre 0,04 e 0,15 Hz
High Frequency (HF)	ms ²	Potência espectral entre 0,15 e 0,4 Hz
Ratio LF/HF	ms ²	Razão entre LF e HF

Extração e Seleção de Características

Característica		Fórmula
Domínio de		
Average of R	$(RR \text{ Interval } 1 - RR \text{ Interval } 2)^2$ $+$ $(RR \text{ Interval } 2 - RR \text{ Interval } 3)^2 \dots$	$\sum_{j=1}^N RR_j$
Standard De		$\frac{(RR_j - \overline{RR})^2}{RR_{1j} - \overline{RR}_1)^2}$
Standard De		$RR_{j+1} - RR_j)^2$
Root Mean S		$\times 100\%$
% of RR inte		
Domínio de		
Low Freque		entre 0,04 e 0,15 Hz
High Freque		entre 0,15 e 0,4 Hz
Ratio LF/HF		de LF e HF



Classificação

- Três algoritmos de aprendizado de máquina foram testados:
 - Naive Bayes (NB)
 - K-Nearest Neighbors (KNN)
 - Support Vector Machines (SVM)
- Dados totais divididos em:
 - 75% para treino
 - 25% para teste
- Total de 304 séries temporais de 5 minutos cada;


Classificação

- No experimento de teste, 60% da amostra compreendeu o estado “não estressado” e 40% o estado “estressado”.

Classificador	Sensitiv.	Especif.	Prec.	Acur.	F1-Score
<i>Naive Bayes</i>	0,77	0,62	0,58	0,68	0,66
<i>KNN</i>	0,74	0,84	0,76	0,80	0,75
<i>SVM</i>	0,64	0,95	0,90	0,82	0,75

Estresse e Localização

- Além de possibilitar a remoção de ruído, os dados sensíveis ao contexto coletados tornaram possível relacionar o estado de estresse computado com a localização em que foram mensurados:



Conclusão

- Este trabalho apresentou a coleta de dados sensíveis ao contexto com o intuito da classificação do estresse mental. Estes dados possibilitaram identificar e remover ruído da frequência cardíaca, tais como a movimentação e as atividades físicas, bem como mostrar uma relação dos níveis de estresse e a localização em que foram mensurados.
- Também foi proposto um classificador através da análise e comparação de 3 algoritmos de aprendizado de máquina, onde constatou-se que o SVM foi o que apresentou melhor performance com acurácia de 82% e F1-Score de 75%.

Trabalhos futuros

- Ampliar a variedade e quantidade de voluntários;
- Incorporar os métodos apresentados em aplicações que visem o bem-estar dos indivíduos. Assim, podem ser exploradas técnicas de intervenções à medida que identificam-se momentos de estresse no cotidiano, visando reduzir os efeitos negativos do estresse mental.



Referências

- BAVARESCO, Rodrigo; BARBOSA, Jorge . ***Análise de Históricos de Contextos para Classificação do Estresse Mental em Situações Reais por meio da Variabilidade da Frequência Cardíaca***. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO UBÍQUA E PERVASIVA (SBCUP), 11. , 2019, Belém. Anais do XI Simpósio Brasileiro de Computação Ubíqua e Pervasiva. Porto Alegre: Sociedade Brasileira de Computação, july 2019 . ISSN 2595-6183. DOI:
- Alharthi, R., Alharthi, R., Guthier, B., and El Saddik, A. (2017). ***CASP: context-aware stress prediction system***. Multimedia Tools and Applications, pages 1–21.