

The history of Yanucho

by Gilmar and Yanacho

Alair professor de LabConsp



Reconhecimento de Emoções por Sinais Wireless

*Gustavo Mendes Maciel
Yannick T. Messias*

Apresentação

- Mingmin Zhao, Fadel Adib, Dina Katabi
- Massachusetts Institute of Technology



- *“It is motivated by a simple vision:
Can we build machines that sense our
emotions?”*

Motivação

- Smart homes
- Movie makers
- Marketing
- Diagnóstico de doenças psicológicas
- Interação homem-máquina
- Altos exemplos...

Soluções existentes

Visão computacional:

- Focado em expressões e gestos
- Prático: não requer acessórios
- Limitado (ex: pessoa sorri mas não está feliz)
- Pessoas expressam emoções diferentemente

Soluções existentes

ECG Monitor (eletrocardiograma)

- Baseado nos batimentos cardíacos
- Mais preciso
- Foca em sinais inconscientes do corpo
- Problema: uso de sensores pode interferir no resultado

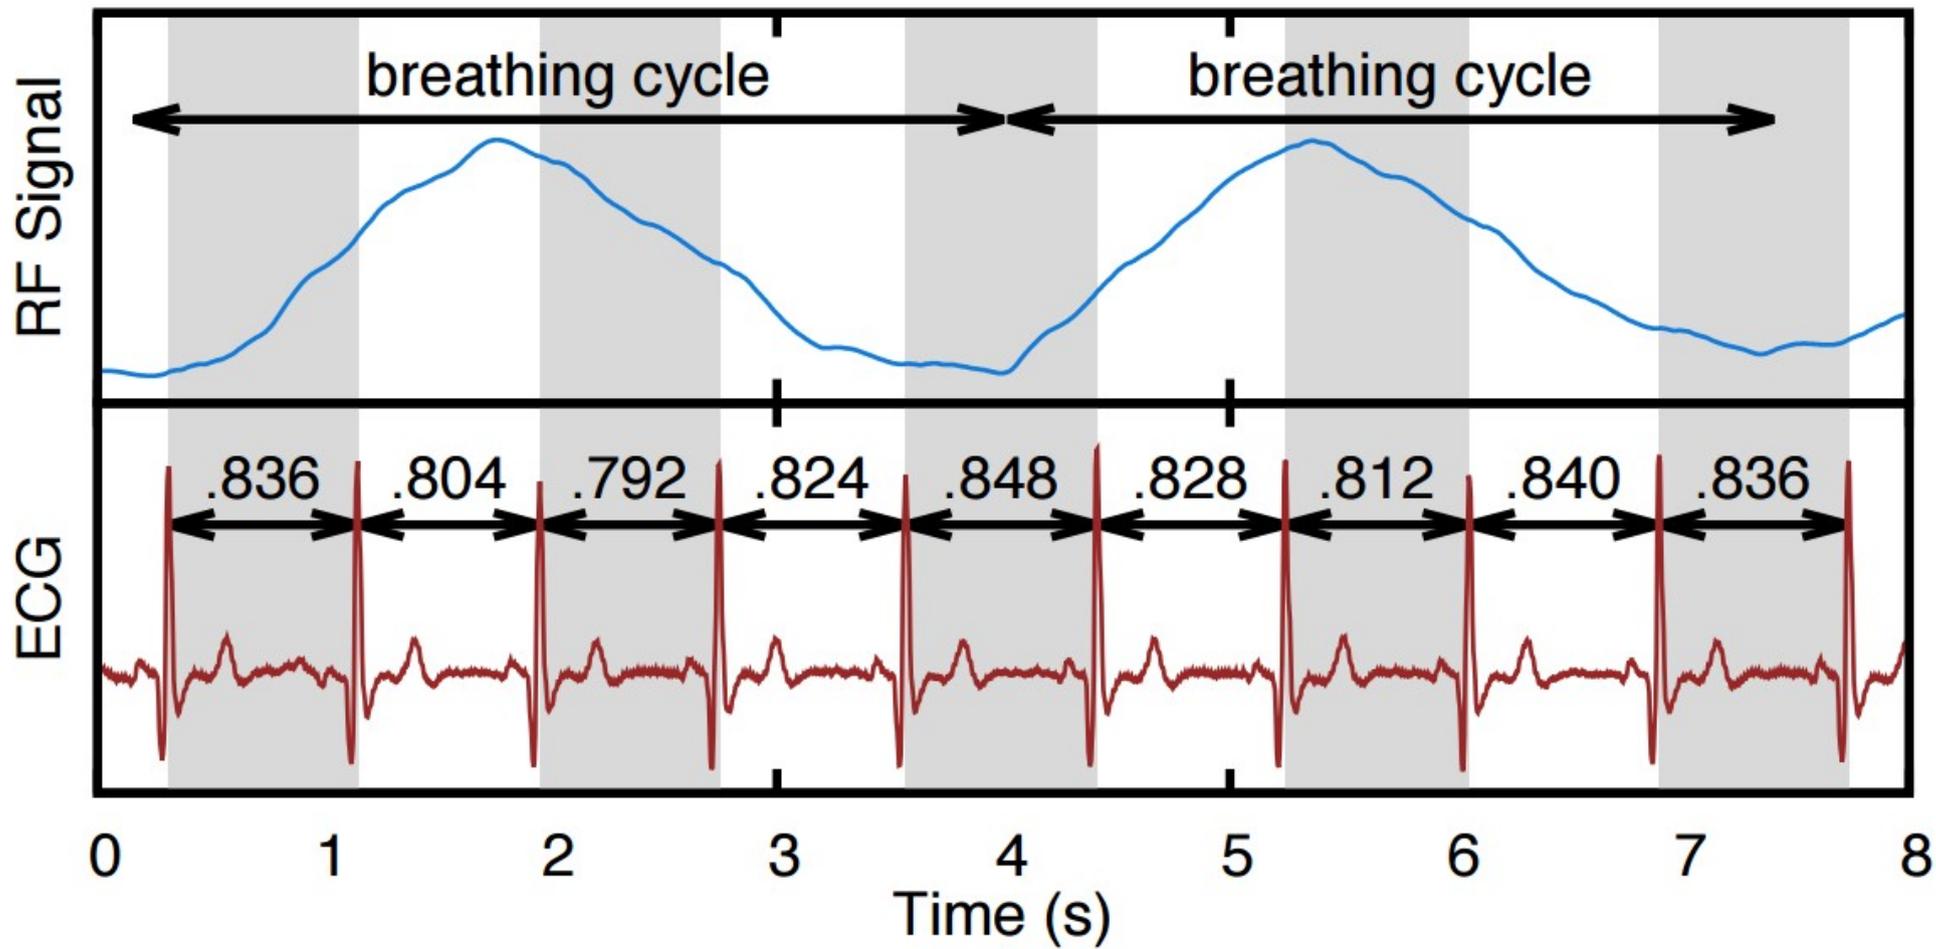
Nova Solução

EQ-Radio

- Também focado nos sinais inconscientes do corpo
- Respiração e batimento cardíaco
- Não necessita o uso de sensores no corpo
- Utiliza sinais de radiofrequência (RF) rebatidas pelo corpo

Desafios

- Impacto da respiração nos sinais
- Batimentos carecem de picos bem definidos
- Diferença dos intervalos entre cada batimento é pequeno



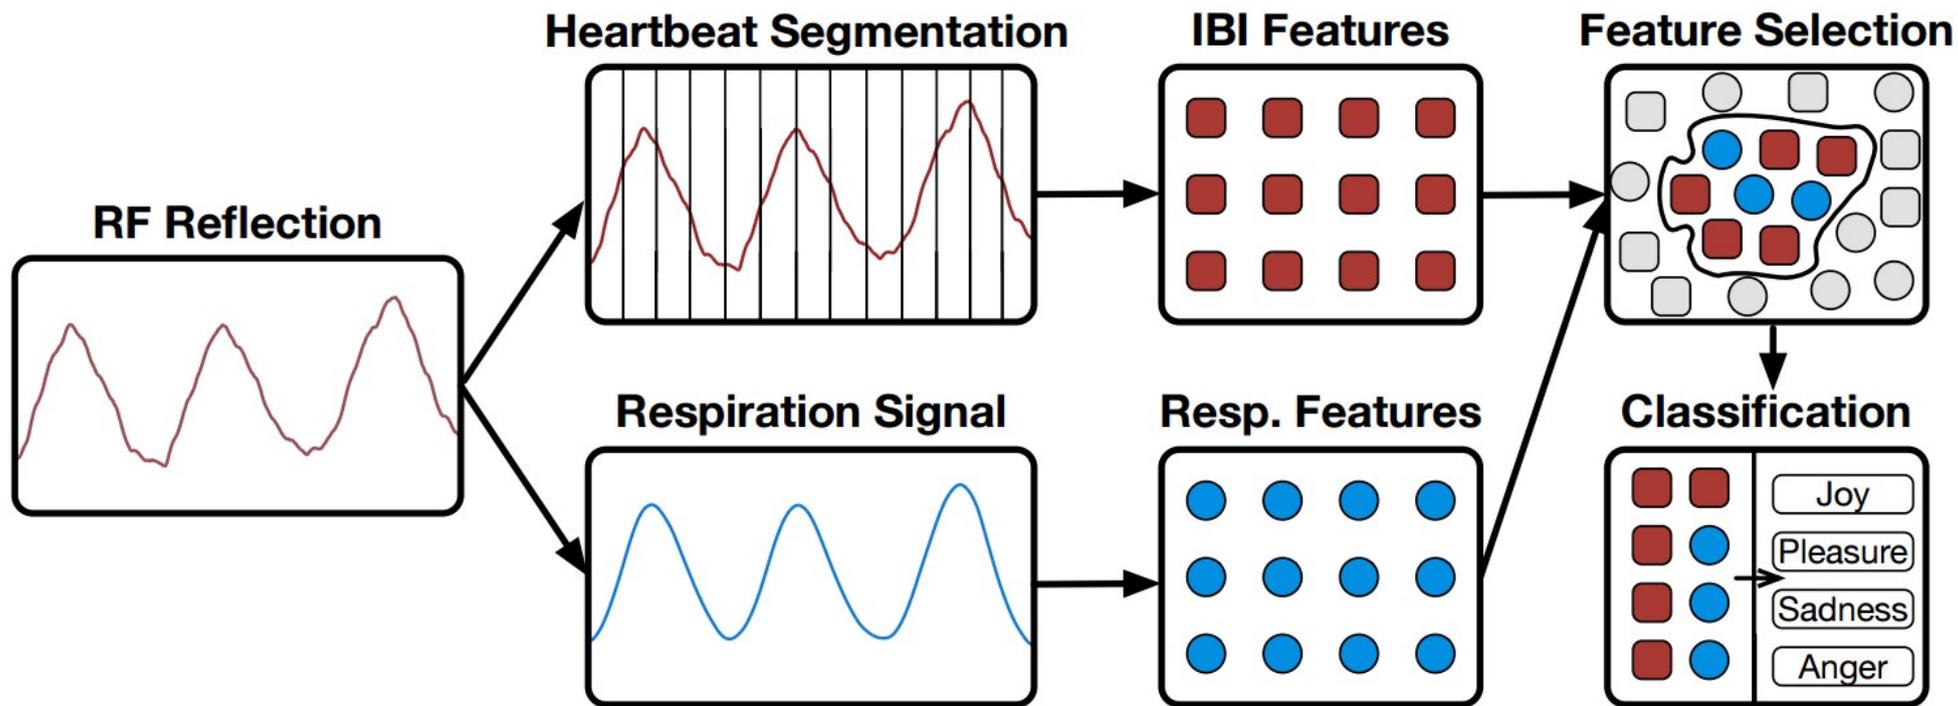
Soluções

- Diminuir o impacto da respiração no sinal
- Algoritmo para segmentar o sinal RF refletido em batidas individuais

Implementação

3 componentes

- FMCW (Frequency Modulated Carrier Waves) radio
- Extrator de batimentos
- Classificador de emoções



FMCW radio

- Transmite sinais RF e recebe suas reflexões
- Vantagem: consegue separar diferentes fontes de movimento

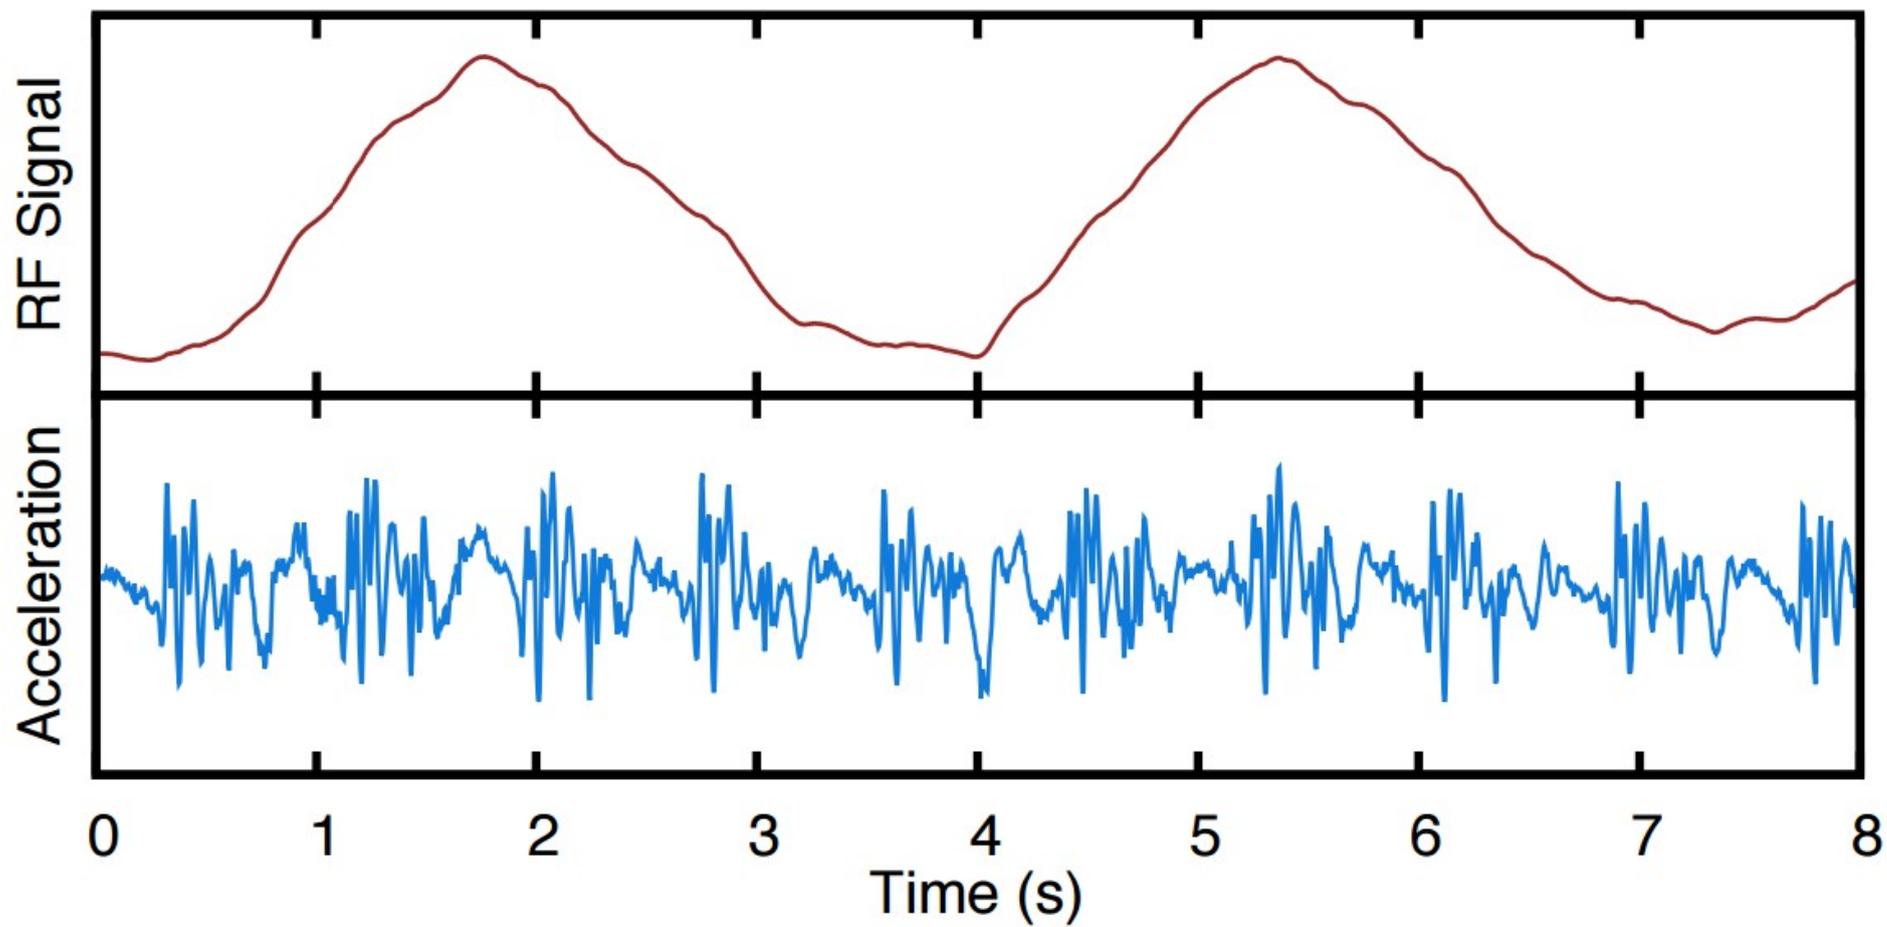
FMCW radio

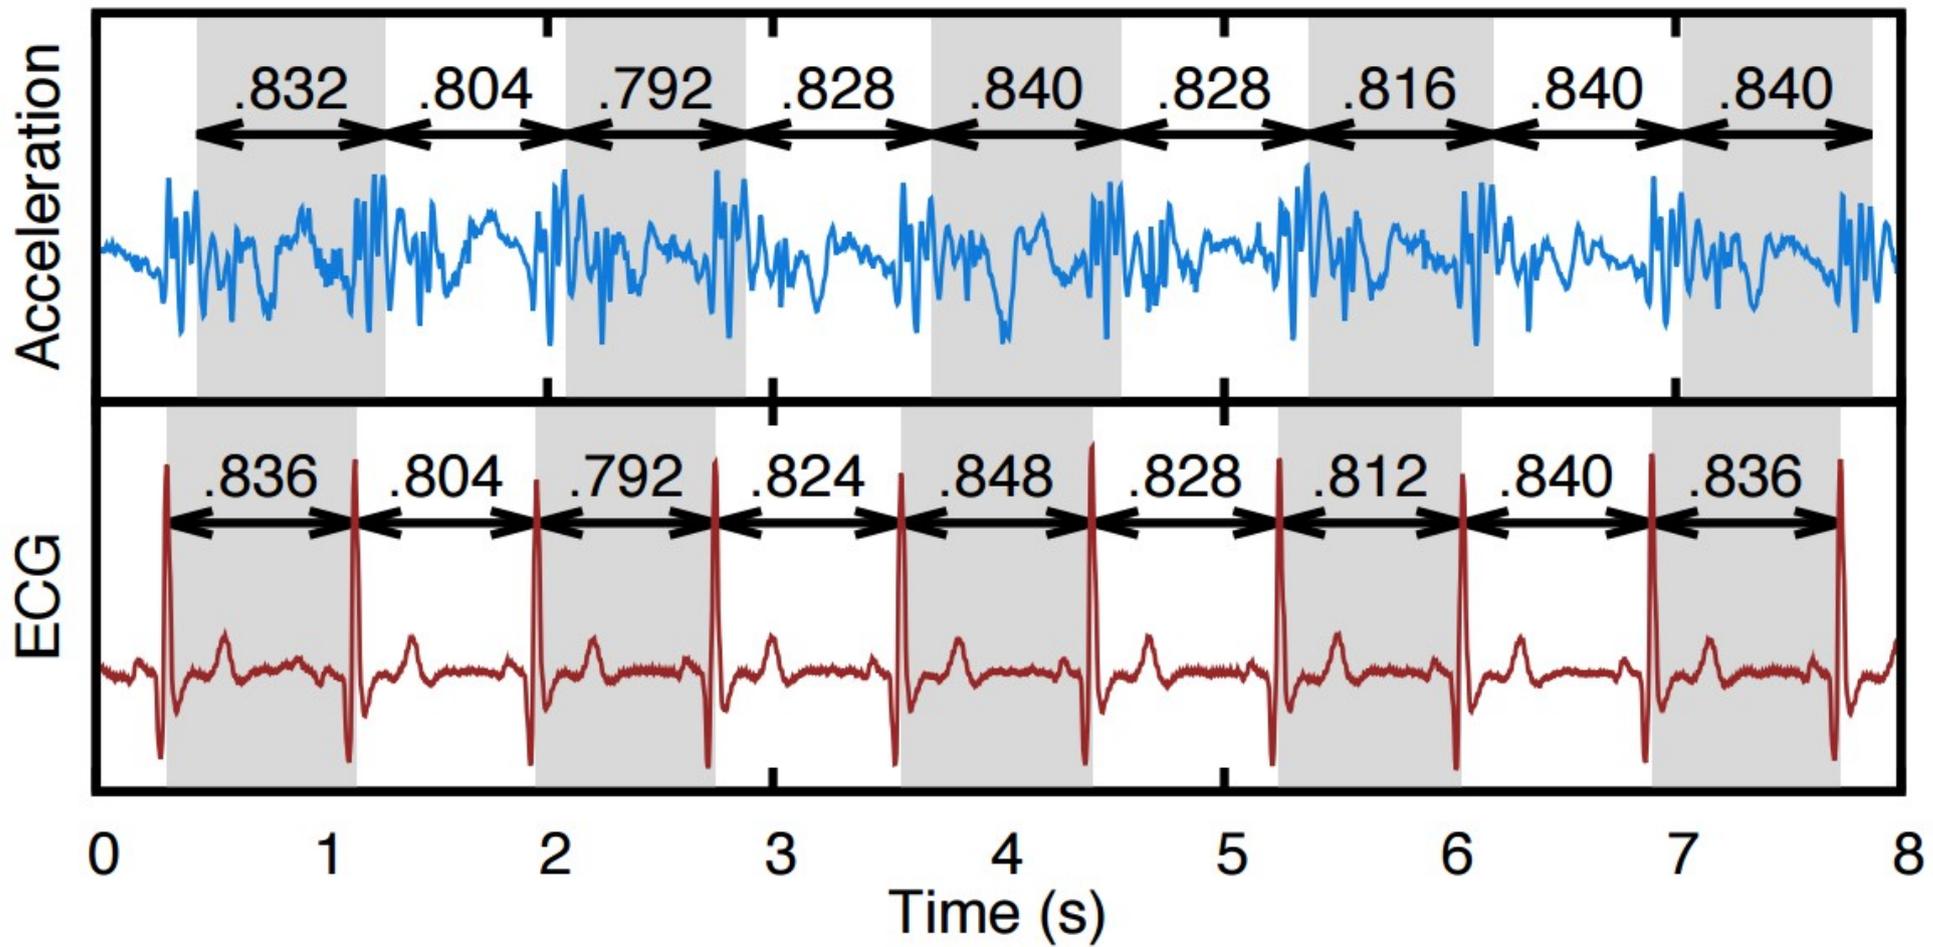
- Como o sinal é capturado?
 - mede o tempo de reflexão
 - separa reflexões de diferentes objetos
 - elimina reflexões de objetos estáticos
 - olha para a fase da onda RF, dada por:

$$\phi(t) = 2\pi \frac{d(t)}{\lambda}$$

Extrator de batimentos

- Recebe os sinais RF e devolvem uma segmentação de batimentos individuais
- Diminuir o impacto da respiração nos sinais:
 - trabalhar com a aceleração do sinal





Extrator de batimentos

- Segmentação dos batimentos:
 - não sabemos a morfologia dos batimentos
 - intuição: batidas sucessivas devem ter a mesma morfologia
 - otimização: minimizar as diferenças de forma entre as batidas e, ao mesmo tempo, descobrir a morfologia dos batimentos

Otimização

$\mathbf{x} = (x_1, x_2, \dots, x_n)$: sequência de tamanho n

$S = \{s_1, s_2, \dots\}$: segmentação de x

$\boldsymbol{\mu}$: modelo para a forma das batidas

- Objetivo: encontrar a segmentação ótima S^* tal que s_1, s_2, \dots sejam o mais similares entre si possível

$$Var(S) = \min_{\boldsymbol{\mu}} \sum_{s_i \in S} \|s_i - \omega(\boldsymbol{\mu}, |s_i|)\|^2$$

Otimização

$$S^* = \underset{S}{\operatorname{arg\,min}} \operatorname{Var}(S)$$

- Reescrevendo:

$$\underset{S, \boldsymbol{\mu}}{\operatorname{minimizar}} \sum_{s_i \in S} \|s_i - \omega(\boldsymbol{\mu}, |s_i|)\|^2$$

$$\textit{sujeito a } b_{\min} \leq |s_i| \leq b_{\max}, s_i \in S$$

- Problema difícil de otimização

Algoritmo

- Alterna ente atualizar a segmentação e atualizar o modelo (μ)
- UpdateSegmentation:

$$S^{l+1} = \underset{S}{\operatorname{arg\,min}} \sum_{s_i \in S} \|s_i - \omega(\boldsymbol{\mu}^l, |s_i|)\|^2 \quad O(n)$$

- UpdateTemplate:

$$\boldsymbol{\mu}^{l+1} = \underset{\mu}{\operatorname{arg\,min}} \sum_{s_i \in S^{l+1}} \|s_i - \omega(\boldsymbol{\mu}, |s_i|)\|^2 \quad O(1)$$

Algoritmo

- Inicialização: $\mu^0 = \mathbf{0}$
- Consumo de tempo: $O(kn)$
 - k: número de iterações para convergir
 - Nos experimentos realizados, k foi em média 8, e no máximo 16

Classificador de emoções

- 2D Emotion Model: valence and arousal
- Anger, Sadness, Pleasure, Joy
- Handling Dependencies: neutral state
- Feature Selection and Classification

Table 1: **Features used in EQ-Radio.**

Domain	Name
Time	Mean, Median, SDNN, pNN50 , RMSSD, SDNNi, meanRate, <i>sdRate</i> , HRVTi, <i>TINN</i> .
Frequency	Welch PSD: LF/HF , peakLF, peakHF.
	Burg PSD: LF/HF , peakLF, peakHF.
	Lomb-Scargle PSD: LF/HF , peakLF, peakHF.
Poincaré	SD ₁ , SD₂ , SD₂/SD₁ .
Nonlinear	SampEn₁ , SampEn₂ , DFA_{all} , DFA ₁ , DFA ₂ .

selected IBI features in **bold**;
selected respiration features in *italic*.

Resultados

- Precisão da extração de batimentos cardíacos:
 - Erro médio do IBI: 3,2 ms
 - IBI médio: 740 ms
- Precisão do reconhecimento de emoções:

Method	Person-dependent	Person-independent
EQ-Radio	87%	72.3%
ECG-based	88.2%	73.2%

Conclusões

