

Análise da Decomposição de Sinais de Atividade Eletrodérmica em Múltiplos Dicionários Usando Algoritmos Vorazes

Gabriel Almeida de Oliveira, Michel Pompeu Tcheou e Lisandro Lovisolo

Resumo—O grande volume de dados provenientes de sinais fisiológicos, como a atividade eletrodérmica (EDA), torna necessária a utilização de ferramentas capazes de representá-los eficientemente. Uma opção são métodos de decomposição adaptativa como o *Matching Pursuit* (MP) e o *Orthogonal Matching Pursuit* (OMP) aplicados com dicionários apropriados, de forma a fornecer representações esparsas. Neste trabalho, avalia-se a decomposição de sinais de EDA via MP e OMP utilizando múltiplos dicionários simultâneos/concorrentes (*Bateman*, *Gabor* e *Triângulos*). Os resultados indicam que utilizar múltiplos dicionários pode ser vantajoso e que, dentre os utilizados, o dicionário de *Bateman* é o mais relevante em termos de extração da energia de sinais de EDA.

Palavras-Chave—Atividade Eletrodérmica, Representação Esparsa, *Matching Pursuit*, *Orthogonal Matching Pursuit*

Abstract—The large volume of data in physiological signals, like electrodermal activity (EDA), requires tools capable of representing such signals efficiently. Adaptive decomposition methods, such as *Matching Pursuit* and *Orthogonal Matching Pursuit* may provide such representations if employed with the appropriate dictionary, guaranteeing compact and meaningful representations. In this work, we evaluate the decomposition of EDA signals using multiple simultaneous/concurrent dictionaries (*Bateman*, *Gabor* and *Triangles*) with both algorithms. Simulation results show that using multiple dictionaries may be advantageous, and that the *Bateman* dictionary is the most relevant one in terms of energy extraction among them for EDA signals.

Keywords—Electrodermal Activity, Sparse Representation, *Matching Pursuit*, *Orthogonal Matching Pursuit*.

I. INTRODUÇÃO

Avanços tecnológicos recentes têm permitido o uso expressivo de dispositivos vestíveis capazes de capturar sinais fisiológicos com propósitos médicos [1] ou simplesmente para avaliação do estado de saúde física e mental do indivíduo [2]. Por serem vestíveis, os dispositivos são portáteis e possuem memória para armazenamento de dados provenientes dos pequenos sensores biométricos. O grande volume de registros produzidos por esses sensores, seu uso na vida cotidiana e em clínicas especializadas, a variabilidade da qualidade dos dados e a escassez de especialistas treinados na análise dos sinais biométricos reforçam a necessidade de se desenvolver ferramentas computacionais que processem e automatizem a análise/interpretação destes registros. Para isso, deve-se buscar modelos fisiológicos robustos que possibilitem representar, analisar e interpretar os sinais adquiridos de forma eficiente.

Gabriel Almeida de Oliveira, Michel Pompeu Tcheou e Lisandro Lovisolo, Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro-RJ, Brasil, E-mails: gabriel.oliveira@uerj.br, mtcheou@uerj.br, lisandro@uerj.br.

A atividade eletrodérmica (EDA - *Electrodermal Activity*) é um parâmetro psicofisiológico amplamente utilizado em avaliação médica, em polígrafos (detectores de mentiras), e na verificação da saúde mental [3], [4]. A aquisição de sinais de EDA de longa duração através de dispositivos vestíveis fora do ambiente laboratorial, apesar de simples, gera uma quantidade de dados que requer codificação e representação eficientes, em termos de compressão e de extração de padrões fisiológicos que permitam a análise e a interpretação diretas e até mesmo automatizadas desses sinais.

As técnicas de representação esparsa modelam sinais usando uma combinação linear de um sub-conjunto de átomos de um dicionário redundante. Os átomos representam estruturas específicas do sinal, modelando-o compactamente [5], [6] – quanto menor a quantidade de átomos empregados mais compacta/esparsa é a representação. Dado que sinais psicofisiológicos, como EDA, apresentam padrões típicos, a aplicação de técnicas de decomposições esparsas pode resultar em representações eficientes em termos de compressão e de extração de padrões fisicamente interpretáveis para facilitar o diagnóstico e até mesmo automatizar a detecção de enfermidades ou de alterações de estado psicofisiológico [7], [8].

Os métodos de decomposição empregados neste trabalho são o *Matching Pursuit* [9] e o *Orthogonal Matching Pursuit* [10]. Na literatura, esses algoritmos vorazes foram utilizados para decompor EDA usando, principalmente, o dicionário de *Bateman* [7], [8], [11]. Neste artigo, porém, propõe-se a utilização de múltiplos dicionários simultâneos/concorrentes (*Bateman*, *Gabor* [9], [12] e *Triângulos* [13]), a fim de avaliar a relevância dos elementos de cada sub-dicionário na decomposição de diferentes sinais de EDA.

A Seção II apresenta os sinais de Atividade Eletrodérmica e suas componentes: fásica e tônica. A Seção III descreve os algoritmos *Matching Pursuit* e *Orthogonal Matching Pursuit*. O dicionário (e seus sub-dicionários) utilizado é detalhado na Seção IV, bem como a discretização de seus parâmetros. Na Seção V descrevem-se os experimentos realizados e os resultados obtidos. A Seção VI apresenta as conclusões.

II. ATIVIDADE ELETRODÉRMICA

A atividade eletrodérmica (EDA) é o registro de alterações da resposta da condutância da pele (SCR - *Skin Conductance Response*) causadas, em grande parte, pela flutuação da atividade de glândulas sudoríparas. Ela é altamente sensível a uma grande variedade de estados psicofisiológicos (atenção, processamento de informação, respostas emocionais, dor e excitação, etc) sendo capaz de revelar ocorrências de eventos psicologicamente marcantes [4]. Contudo, a EDA registra ainda padrões

não psicofisiológicos (atividade física aumentada, umidade, variações de temperatura) e pode ser corrompida ainda por ruído elétrico, e movimentos do dispositivo de medição [14]. Tais artefatos podem impedir avaliações psicofisiológicas por parte de especialistas, se não forem cuidadosamente tratados e removidos.

Um típico sinal de EDA é caracterizado por componentes tônica e “fásica” [15]. A componente tônica corresponde a uma variação lenta, ascendente ou descendente, do nível de condutância da pele. A componente “fásica” consiste numa variação abrupta que se superpõe à componente tônica. O nível e o comportamento da componente tônica variam entre indivíduos, além de dependerem do nível de hidratação, da densidade de glândulas sudoríparas no local de medição, e de fatores ambientais como umidade e temperatura. Os níveis de componente tônica variam normalmente de 2 a 20 μS na maioria dos adultos [4], e tendem a aumentar lentamente em períodos de alta excitação e diminuir em períodos de baixa excitação ou descanso. Já a componente fásica apresenta uma variação muito mais rápida que a da componente tônica, e está diretamente ligada à resposta de condutância da pele (SCR) usada por especialistas em suas avaliações psicofisiológicas.

Em geral, se remove a componente tônica do sinal de EDA, já que não fornece informação clara ou útil para diagnósticos de alteração psicológica. Assim, a análise de sinais de EDA considera a resposta fásica, que usualmente segue um padrão bem definido, como ilustrado na Figura 1. Esse padrão é composto por três partes [14]: tempo de subida, pico da resposta, e meio período de recuperação. Observa-se que a subida é abrupta e o retorno à linha de base é razoavelmente lento. Para adultos saudáveis, o tempo de subida está normalmente entre 1 e 3 segundos, o limiar mínimo de pico está entre 0,01 e 0,05 μS , e o meio período de recuperação entre 2 e 10 segundos [14]. É possível ocorrerem SCRs compostos, um SCR surge antes da completa recuperação do SCR anterior. Como as componentes fásicas ocorrem geralmente de forma esparsa no tempo, em média a cada 2 minutos, nada mais adequado do que lançar mão de métodos de decomposições esparsas para representá-las de maneira eficiente em termos de compressão e extração de características.

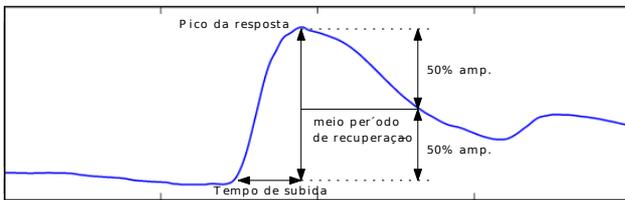


Fig. 1. Sinal de resposta de condutância da pele.

A. Estimativa e Remoção da Componente Tônica

Para que seja possível analisar a componente fásica de sinais de EDA, é necessário, antes, remover a componente tônica. Para estimar a componente tônica, utiliza-se o Método dos Mínimos Quadrados (MMQ) [16] para obter as retas dos blocos (componente tônica). Dado um sinal, \mathbf{x} , divide-se o mesmo em blocos, e em cada bloco, calcula-se a reta que mais se ajusta ao bloco (usando MMQ) com a primeira amostra da reta (numericamente equivalente ao coeficiente linear) sendo igual à última amostra da reta obtida para o bloco anterior.

III. MÉTODOS DE DECOMPOSIÇÃO

A. Matching Pursuit

O algoritmo *Matching Pursuit* (MP) aproxima um sinal \mathbf{x} sucessivamente de forma iterativa e adaptativa [9]. O MP requer um dicionário redundante D (com mais átomos/elementos que os necessários para gerar o espaço no qual o sinal é definido) de cardinalidade $\#D$ (a quantidade de elementos em D). Os elementos do dicionário são chamados átomos, \mathbf{g}_γ , têm norma unitária $\|\mathbf{g}_\gamma\| = 1$ e $\gamma \in \Gamma$ é um conjunto de parâmetros que define ou indexa o átomo, sendo Γ o espaço de parâmetros.

A cada iteração, o MP procura o átomo que mais se assemelha ao resíduo. Define-se como resíduo inicial o próprio sinal, $\mathbf{r}_\mathbf{x}^0 = \mathbf{x}$, assim a cada iteração i , faz-se:

- 1) Calculam-se as correlações/similaridades entre o resíduo $\mathbf{r}_\mathbf{x}^{i-1}$ e cada átomo \mathbf{g}_γ utilizando os produtos internos $\langle \mathbf{r}_\mathbf{x}^{i-1}, \mathbf{g}_\gamma \rangle, \forall \mathbf{g}_\gamma \in D$;
- 2) Busca-se o átomo mais correlacionado com o resíduo, resultando em

$$\gamma(i) = \operatorname{argm\acute{a}x}_{\gamma \in \Gamma} |\langle \mathbf{r}_\mathbf{x}^{i-1}, \mathbf{g}_\gamma \rangle| \text{ e } \alpha_i = \langle \mathbf{r}_\mathbf{x}^{i-1}, \mathbf{g}_{\gamma(i)} \rangle; \quad (1)$$

- 3) Subtrai-se o átomo ponderado $\alpha_i \mathbf{g}_{\gamma(i)}$ do resíduo $\mathbf{r}_\mathbf{x}^{i-1}$, obtendo-se o i -ésimo resíduo

$$\mathbf{r}_\mathbf{x}^i = \mathbf{r}_\mathbf{x}^{i-1} - \alpha_i \mathbf{g}_{\gamma(i)}; \quad (2)$$

- 4) Se o critério de parada for satisfeito, termina-se a decomposição; caso contrário, faz-se $i = i + 1$ e retorna-se ao passo 1.

Ao fim da decomposição, obtém-se a aproximação em M termos do sinal \mathbf{x}

$$\mathbf{x} \approx \hat{\mathbf{x}} = \sum_{i=1}^M \alpha_i \mathbf{g}_{\gamma(i)}. \quad (3)$$

B. Orthogonal Matching Pursuit

O algoritmo *Orthogonal Matching Pursuit* (OMP), assim como o MP, aproxima um sinal \mathbf{x} sucessivamente de forma iterativa e adaptativa [10]. Porém, durante o processo de decomposição, ortogonaliza-se a aproximação obtida ao resíduo, usando a ortogonalização de *Gram-Schmidt*. Consequentemente, o OMP converge em uma quantidade finita de iterações, diferentemente do MP, apesar de comparativamente apresenta maior custo computacional.

No OMP, impõe-se que o resíduo $\mathbf{r}_\mathbf{x}^i$ seja ortogonal aos átomos selecionados em iterações anteriores. Como os átomos podem não ser ortogonais entre si, tem-se que atualizar os coeficientes $\{\alpha_k\}_{k=1}^i$ a cada iteração. No algoritmo MP, o resíduo da i -ésima iteração é dado pela equação (2) que pode ser expresso como

$$\mathbf{r}_\mathbf{x}^i = \mathbf{x} - \sum_{k=1}^i \alpha_k \mathbf{g}_{\gamma(k)}. \quad (4)$$

No OMP, altera-se os α_k em função dos átomos, assim

$$\mathbf{r}_\mathbf{x}^i = \mathbf{x} - \sum_{k=1}^i \alpha_{k,i} \mathbf{g}_{\gamma(k)}. \quad (5)$$

O índice i nos coeficientes $\alpha_{k,i}$ indica a dependência dos mesmos o índice da iteração i . Como os átomos em D não são, necessariamente, ortogonais, é necessário atualizar os

coeficientes na iteração i em função das correlações entre o átomo $\mathbf{g}_{\gamma(i)}$ e os anteriores $\mathbf{g}_{\gamma(k)}$ ($k = 1 \dots i-1$). Seja

$$\mathbf{g}_{\gamma(i)} = \sum_{k=1}^{i-1} b_{k,i-1} \mathbf{g}_{\gamma(k)} + \mathbf{u}_i, \text{ tal que } \langle \mathbf{u}_i, \mathbf{g}_{\gamma(k)} \rangle = 0. \quad (6)$$

Vemos que a atualização dos coeficientes OMP entre iterações sucessivas é

$$\alpha_{k,i} = \alpha_{k,i-1} - a_i b_k^{i-1}, \quad k = \{1, \dots, i-1\}, \quad (7)$$

$$\text{onde } a_i = \alpha_{i,i} = \frac{\langle \mathbf{r}_{\mathbf{x}}^{i-1}, \mathbf{g}_{\gamma(i)} \rangle}{\|\mathbf{u}_i\|^2} = \frac{\langle \mathbf{r}_{\mathbf{x}}^{i-1}, \mathbf{g}_{\gamma(i)} \rangle}{\|\mathbf{g}_{\gamma(i)}\|^2 - \sum_{k=1}^{i-1} b_k^i \langle \mathbf{g}_{\gamma(k)}, \mathbf{g}_{\gamma(i)} \rangle}. \quad (8)$$

Além disso, como $\mathbf{r}_{\mathbf{x}}^i = \mathbf{r}_{\mathbf{x}}^{i-1} - a_i \mathbf{u}_i$, tem-se que

$$\|\mathbf{r}_{\mathbf{x}}^i\|^2 = \|\mathbf{r}_{\mathbf{x}}^{i-1}\|^2 - \|\mathbf{u}_i\|^2 + |\langle \mathbf{r}_{\mathbf{x}}^{i-1}, \mathbf{g}_{\gamma(i)} \rangle|^2. \quad (9)$$

Com isso, define-se o algoritmo *Orthogonal Matching Pursuit*. O resíduo inicial é $\mathbf{r}_{\mathbf{x}}^0 = \mathbf{x}$ e, a cada iteração i , faz-se (onde a diferença em relação ao MP reside nos passos (3) e (4):

1) Calculam-se as correlações/similaridades entre o resíduo $\mathbf{r}_{\mathbf{x}}^{i-1}$ e cada átomo \mathbf{g}_{γ} utilizando os produtos internos $\langle \mathbf{r}_{\mathbf{x}}^{i-1}, \mathbf{g}_{\gamma} \rangle, \forall \mathbf{g}_{\gamma} \in D$;

2) Busca-se o átomo mais correlacionado com o resíduo, resultando em

$$\gamma(i) = \text{argmáx}_{\gamma \in \Gamma} |\langle \mathbf{r}_{\mathbf{x}}^{i-1}, \mathbf{g}_{\gamma} \rangle|; \quad (10)$$

3) Calcula-se $\{b_{k,i-1}\}_{k=1}^{i-1}$ usando a equação (6);

4) Definem-se os coeficientes da atual iteração $\{\alpha_{k,i}\}_{k=1}^{i-1}$ a partir das equações (7) e (8);

5) Subtraem-se os átomos ponderados $\alpha_{k,i} \mathbf{g}_{\gamma(k)}$, $k \in \{1, \dots, i-1\}$ do sinal original \mathbf{x} , obtendo-se o i -ésimo resíduo

$$\mathbf{r}_{\mathbf{x}}^i = \mathbf{x} - \sum_{k=1}^i \alpha_{k,i} \mathbf{g}_{\gamma(k)}; \quad (11)$$

6) Se o critério de parada for satisfeito, termina-se a decomposição; caso contrário, faz-se $i = i+1$ e retorna-se ao passo 1.

Ao fim da decomposição, obtém-se a aproximação em M termos do sinal \mathbf{x}

$$\mathbf{x} \approx \hat{\mathbf{x}} = \sum_{i=1}^M \alpha_{i,M} \mathbf{g}_{\gamma(i)}. \quad (12)$$

IV. DICIONÁRIO

Na definição do MP e do OMP, não se fez nenhuma assunção sobre a forma dos elementos do dicionário, que pode abranger sub-dicionários, como, por exemplo, *Gabor*, *Triangular* e *Bateman*. Neste trabalho, esse três sub-dicionários são agregados num dicionário para a decomposição da componente física dos sinais de EDA: i) o dicionário de *Bateman*, comumente utilizado na decomposição de EDA [7], [8], [11]; ii) o dicionário de *Gabor*, tradicionalmente utilizado com o MP [9], [12]; e iii) o dicionário de triângulos, anteriormente utilizado para a decomposição de sinais de ECG [13].

A. Protótipos do Dicionário

1) *Dicionário de Bateman*: O dicionário de *Bateman* (i.e. função bi-exponencial) [17] é composto por átomos

$$g_{\gamma}(n) = K_{\gamma}(e^{-\rho(n-\tau)} - e^{-\eta(n-\tau)}) \times [u(n-n^s) - u(n-n^e)], \quad (13)$$

onde γ são os parâmetros definidores do átomo ($n \in [0, \dots, N-1]$), no caso $\gamma = (\rho, \eta, \tau)$, ρ é o decaimento, η é o crescimento e τ é o deslocamento, K_{γ} é o fator de normalização, n^s e n^e definem o suporte do átomo e $u(\cdot)$ denota a função degrau unitário.

2) *Dicionário de Gabor*: É possível gerar uma família de átomos localizados no domínio tempo-frequência a partir do deslocamento, modulação e escalamento de uma Gaussiana [5], [18]. Assim, se define o “Dicionário de Gabor” como composto pelas funções geradas através do escalamento, modulação e translação de uma janela Gaussiana, i.e.,

$$g_{\gamma}(n) = K_{\gamma} 2^{\frac{1}{4}} e^{-\pi(\frac{n-\tau}{s})^2} \cos(\xi n + \phi) \times [u(n-n^s) - u(n-n^e)], \quad (14)$$

onde $n \in [0, \dots, N-1]$, $\gamma = (s, \tau, \xi, \phi, n^s, n^e)$, s é a escala, τ é o deslocamento, ξ é a frequência, ϕ é a fase do átomo, K_{γ} é o fator de normalização, n^s e n^e definem o suporte do átomo e $u(\cdot)$ denota a função degrau unitário.

3) *Dicionário de triângulos*: Utiliza-se triângulos de diferentes escalas e níveis de assimetria [13], seus elementos são definidos usando

$$g_{\gamma}(n) = \begin{cases} 0, & \text{se } n \leq TL \\ h \frac{n-TL}{TC-TL}, & \text{se } TL < n < TC \\ h, & \text{se } n = TC \\ h \frac{TR-n}{TR-TC}, & \text{se } TC < n < TR \\ 0, & \text{se } n \geq TR \end{cases} \quad (15)$$

onde $n \in [0, \dots, N-1]$, $\gamma = (TL, TC, TR)$, TL define o limite esquerdo, TC é o pico central e TR define o limite direito. h é computado para a área do triângulo seja 1 (energia do átomo unitária), ou seja, $h = 2(TR - TL)^{-1}$.

B. Discretização dos parâmetros

Considerando que uma SCR dura de 10 a 30 segundos [4], a fim de se representar a grande variedade de SCRs, os parâmetros dos dicionários foram discretizados como na Tabela I. Os dicionários, a partir de agora, serão referidos como sub-dicionários. A discretização do sub-dicionário de *Bateman* é baseada na usada em [7] e as discretizações dos sub-dicionários de *Gabor* e de Triângulos são definidas visando alguma semelhança, tanto na forma dos átomos, quanto na cardinalidade dos três sub-dicionários. É importante notar que, para os átomos do sub-dicionário de *Gabor*, faz-se a frequência ξ e fase ϕ iguais a zero, produzindo Gaussiana não moduladas. Cada sub-dicionário contém 90 protótipos com 512 (comprimento dos blocos) deslocamentos possíveis, totalizando 138240 átomos no dicionário. A Figura 2 apresenta as formas dos átomos dos três sub-dicionários para o deslocamento $\tau = 10$ s.

TABELA I
SUB-DICIONÁRIOS E A DISCRETIZAÇÃO DE SEUS PARÂMETROS.

Sub-dicionários	Discretização dos Parâmetros
Bateman	$\rho \in [0, 05; 0, 075; \dots; 0, 5]$, $\rho < \eta$ $\eta \in [0, 1; 0, 15; \dots; 0, 5]$, $\tau \in [0, \dots, N-1]$, $n^s = \tau$, $n^e = N-1$.
Gabor	$s \in [4, 4, 4, 8, \dots, 40]$, $\tau \in [0, \dots, N-1]$ $\xi = 0$, $\phi = 0$, $n^s = 0$, $n^e = N-1$.
Triângulos	$TC \in [1, \dots, N-1]$, $TL = TC - a$, $a \in [1, 5, \dots, 16]$ $TR = TL + s - 1$, $s/8 \leq a \leq s/5$ $s \in [10, 11, \dots, 20] \cup [22, 24, \dots, 40] \cup [44, 48, \dots, 64]$.

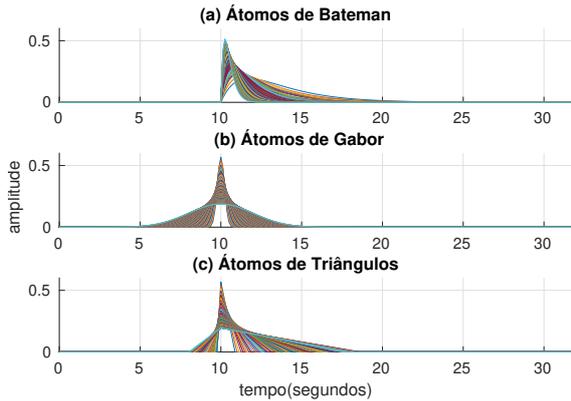


Fig. 2. Átomos dos sub-dicionários de (a) *Bateman*, (b) *Gabor* e (c) Triângulos, todos com deslocamento $\tau = 10$ segundos.

V. EXPERIMENTOS

A. Descrição

1) *Sinais Analisados*: Dezoito (18) sinais de EDA extraídos da base de dados *Physionet* [19], [20], com aproximadamente 38 minutos de duração e taxa de amostragem de 8Hz.

2) *Pré-processamento*: Primeiramente, os sinais de EDA foram filtrados por um passa-baixas de 0.5Hz, para a remoção de artefatos [11]. Depois, a componente tônica foi removida pelo método dos mínimos quadrados em blocos contíguos.

3) *Decomposição*: Decompôs-se os sinais de EDA utilizando os algoritmos MP e OMP com cada sub-dicionário separadamente e com o dicionário composto pelos três. Os sinais foram divididos em blocos de 512 amostras não sobrepostos (com janela retangular). O algoritmo itera até que a energia do resíduo seja inferior a 0.5% da energia do resíduo inicial.

4) *Algoritmos*: De forma a avaliar as relevâncias dos sub-dicionários na decomposição de sinais de EDA, implementou-se o MP e o OMP em C++. As correlações $\langle \mathbf{r}_x^{i-1}, \mathbf{g}_\gamma \rangle$ são calculadas através de um algoritmo rápido proposto em [21], que calcula as projeções dos átomos no resíduo para todos os deslocamentos por meio de convoluções usando a Transformada Rápida de Fourier. Este algoritmo tem complexidade $\mathcal{O}(12N \log_2 N)$. A complexidade do MP rápido, portanto, é $\mathcal{O}(M(12N \log_2 N + N\#_D))$ para M iterações. Já a complexidade do OMP rápido é $\mathcal{O}(M(12N \log_2 N + N\#_D + M^2))$. É notável que, para $M \ll N$, a complexidade do OMP rápido fica $\mathcal{O}(M(12N \log_2 N + N\#_D))$, equivalente à do MP.

B. Resultados

A Figura 3 apresenta o SNR médio do sinal reconstruído em função da quantidade de iterações considerando todos os sinais para a representação obtida via MP e OMP com cada sub-dicionário separadamente e com o dicionário completo. Como o critério de parada adotado torna o número de iterações variável a cada bloco, optou-se por utilizar a média da razão sinal-ruído (SNR - *signal-to-noise ratio*) entre todos os sinais, considerando seus suportes completos. Para o índice i , o bloco de sinal reconstruído é a soma dos átomos ponderados até a i -ésima iteração.

Estes resultados mostram que as decomposições com o dicionário completo, tanto usando MP, quanto OMP, obtêm melhores resultados se comparadas às decomposições com cada sub-dicionário separadamente, pois captura mais energia

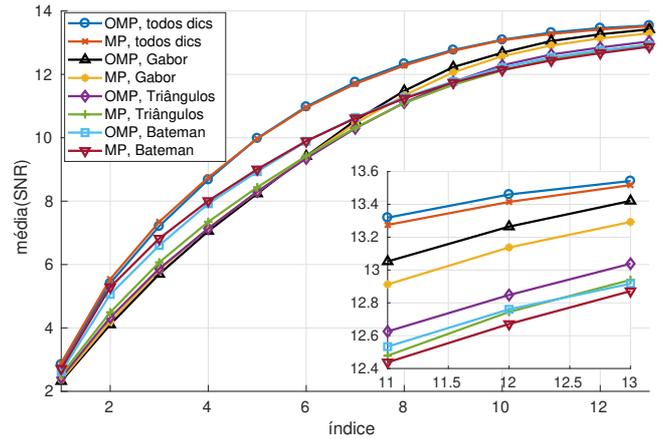


Fig. 3. Média da SNR das decomposições de todos os sinais.

com menos átomos. Porém, a um custo computacional três vezes maior. Vê-se ainda que dentre os dicionários individuais, o dicionário de *Bateman* supera os outros até uma quantidade de 7 iterações, sendo superado pelos outros dois para 8 ou mais iterações.

Com o dicionário completo, MP e OMP apresentam desempenhos muito semelhantes. Assim, de agora em diante apresentamos resultados usando o OMP com o dicionário completo. O gráfico na Figura 4 apresenta os percentuais de átomos de cada sub-dicionário empregados na decomposição de cada um dos sinais de EDA considerados usando OMP com o dicionário completo. É possível notar que os átomos do sub-dicionário de *Gabor* são usados com maior frequência na decomposição (47% das vezes), enquanto os menos frequentemente usados são os do sub-dicionário de Triângulos (23%). Porém, para avaliar a relevância de cada sub-dicionário na decomposição, devemos considerar não só a frequência de uso, mas também o percentual de energia dos sinais que cada sub-dicionário representa. A Figura 5 apresenta o percentual de energia acumulada representada pelos átomos de cada sub-dicionário. Destes resultados, depreende-se que o sub-dicionário mais relevante na decomposições da maioria dos sinais de EDA analisados é o de *Bateman*, cujos átomos representam a maior parte (47%) das energias das decomposições, seguido pelo de *Gabor* (33%). O sub-dicionário de Triângulos aparece como o menos relevante neste experimento, pois captura uma fração menor da energia dos sinais na decomposição (20%). Apesar de não serem genericamente os mais relevantes, os sub-dicionários de *Gabor* e de Triângulos ainda assim o são mais relevantes em alguns casos, como para o sinal “EDA 1” e o sinal “EDA 7”, respectivamente.

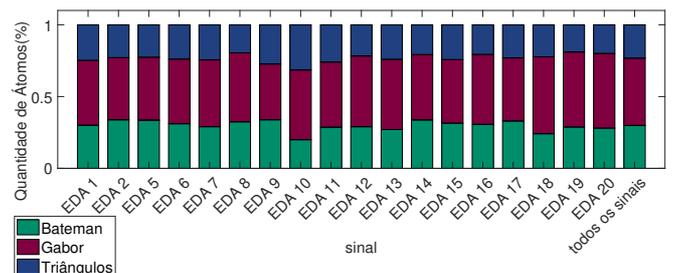


Fig. 4. Quantidade percentual de átomos de cada sub-dicionário.

A Figura 6 apresenta histogramas da iteração em que átomos

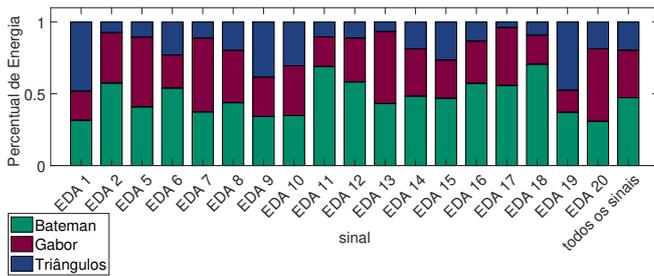


Fig. 5. Energia percentual acumulada dos átomos de cada sub-dicionário.

de cada sub-dicionário são usados na decomposição dos blocos dos sinais de EDA. Estes histogramas corroboram as análises relativas ao percentual de energia. Átomos escolhidos nas primeiras iterações em geral representam frações maiores das energias dos sinais, portanto, como os átomos de *Bateman* são usados quase quatro vezes mais que os outros na primeira iteração OMP de cada bloco, conclui-se novamente sua relevância para a decomposição compacta da energia presente em sinais de EDA.

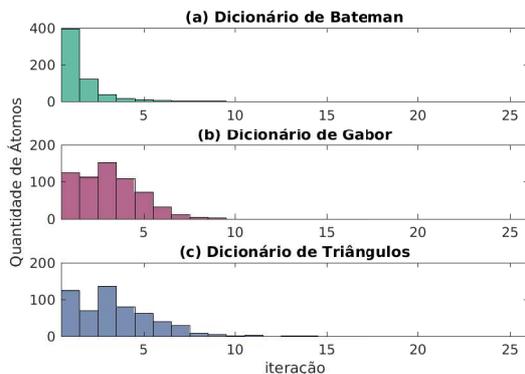


Fig. 6. (a) Histograma correspondente ao sub-dicionário de *Bateman*, (b) Histograma correspondente ao sub-dicionário de *Gabor*, (c) Histograma correspondente ao sub-dicionário de *Triângulos*,

Observamos que, em testes complementares, átomos dos sub-dicionários de *Gabor* e de *Triângulos* com grandes escalas, maiores do que as usadas neste trabalho, foram escolhidos durante a decomposição para corrigir artefatos gerados pela remoção da fase tônica. Assim, futuramente pretende-se avaliar a utilização desses átomos no pré-processamento dos sinais de EDA.

VI. CONCLUSÃO

Neste trabalho, avaliou-se a decomposição de sinais de atividade eletrodérmica com múltiplos dicionários simultâneos/concorrentes. As decomposições foram obtidas utilizando estratégias de decomposição adaptativa como o *Orthogonal Matching Pursuit*. A análise comparativa da utilização dos elementos dos diferentes sub-dicionários, permite concluir pela relevância do sub-dicionário de *Bateman* em termos de compactação da energia, sendo o responsável por 47% da energia das aproximações. Apesar disso, a utilização de todos os dicionários simultaneamente se mostra mais eficiente em termos de razão sinal-ruído (SNR). Em trabalhos futuros, pretende-se empregar bases de dados que contenham a localização das SCRs anotadas para que se possa avaliar a detecção de SCRs através dos átomos das decomposições, permitindo, assim, o desenvolvimento de uma análise automatizada dos sinais de EDA.

REFERÊNCIAS

- [1] T. Vuorela, V.-P. Seppä, J. Vanhala, and J. Hyttinen, "Design and implementation of a portable long-term physiological signal recorder," *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, no. 3, pp. 718–725, 2010.
- [2] U. Mitra, B. A. Emken, S. Lee, M. Li, V. Rozgic, G. Thatte, H. Vathsangam, D.-S. Zois, M. Annaram, S. Narayanan *et al.*, "Knowme: a case study in wireless body area sensor network design," *IEEE Communications Magazine*, vol. 50, no. 5, 2012.
- [3] A. Greco, G. Valenza, and E. P. Scilingo, *Advances in Electrodermal Activity Processing with Applications for Mental Health: From Heuristic Methods to Convex Optimization*. Springer, 2016.
- [4] *Handbook of Psychophysiology*, 3rd ed. Cambridge University Press, 2007.
- [5] S. Mallat, *A wavelet tour of signal processing: the sparse way*. Academic press, 2008.
- [6] M. Elad, *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing*, 1st ed. Springer Publishing Company, Incorporated, 2010.
- [7] T. Chaspari, A. Tsiartas, L. I. Stein, S. A. Cermak, and S. S. Narayanan, "Sparse representation of electrodermal activity with knowledge-driven dictionaries," *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 3, pp. 960–971, March 2015.
- [8] M. Kelsey, A. Dallal, S. Eldeeb, M. Akcakaya, I. Kleckner, C. Gerard, K. S. Quigley, and M. S. Goodwin, "Dictionary learning and sparse recovery for electrodermal activity analysis," pp. 9857 – 9857 – 18, 2016. [Online]. Available: <https://doi.org/10.1117/12.227142>
- [9] S. Mallat and Z. Zhang, "Matching pursuits with time-frequency dictionaries," *IEEE Transactions on Signal Processing*, vol. 41, no. 12, pp. 3397–3415, Dez. 1993.
- [10] Y. C. Pati, R. Rezaeiifar, and P. S. Krishnaprasad, "Orthogonal matching pursuit: Recursive function approximation with applications to wavelet decomposition," in *Signals, Systems and Computers, 1993. 1993 Conference Record of The Twenty-Seventh Asilomar Conference on*. IEEE, 1993, pp. 40–44.
- [11] M. Kelsey, R. V. Palumbo, A. Urbaneja, M. Akcakaya, J. Huang, I. R. Kleckner, L. F. Barrett, K. S. Quigley, E. Sejdic, and M. S. Goodwin, "Artifact detection in electrodermal activity using sparse recovery," pp. 10211 – 10211 – 10, 2017. [Online]. Available: <https://doi.org/10.1117/12.2264027>
- [12] J. C. Wang, C. H. Lin, B. W. Chen, and M. K. Tsai, "Gabor-based nonuniform scale-frequency map for environmental sound classification in home automation," *IEEE Transactions on Automation Science and Engineering*, vol. 11, no. 2, pp. 607–613, April 2014.
- [13] F. dos Santos Guimaraes, L. Lovisolio, M. Blanco-Velasco, and F. Cruz-Roldán, "On the compression of ecg records employing triangular elements and analysis-by-synthesis modeling," in *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, May 2010, pp. 3084–3087.
- [14] W. T. Roth, M. E. Dawson, and D. L. Filion, "Publication recommendations for electrodermal measurements," *Psychophysiology*, vol. 49, no. 8, pp. 1017–1034, 2012.
- [15] C. L. Lim, C. Rennie, R. J. Barry, H. Bahramali, I. Lazzaro, B. Manor, and E. Gordon, "Decomposing skin conductance into tonic and phasic components," *International Journal of Psychophysiology*, vol. 25, no. 2, pp. 97–109, 1997.
- [16] G. H. Golub and C. F. Van Loan, *Matrix Computations (3rd Ed.)*. Baltimore, MD, USA: Johns Hopkins University Press, 1996.
- [17] D. Alexander, C. Trengove, P. Johnston, T. Cooper, J. August, and E. Gordon, "Separating individual skin conductance responses in a short interstimulus-interval paradigm," *Journal of Neuroscience Methods*, vol. 146, no. 1, pp. 116 – 123, 2005. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0165027005000464>
- [18] L. Cohen, *Time-frequency analysis*. Prentice Hall PTR Englewood Cliffs, NJ, 1995, vol. 778.
- [19] J. Birjandtalab, D. Cogan, M. B. Pouyan, and M. Nourani, "A non-ecg biosignals dataset for assessment and visualization of neurological status," pp. 110–114, 2016.
- [20] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215–e220, June 2000. [Online]. Available: <http://circ.ahajournals.org/content/101/23/e215>
- [21] M. P. Tcheou, "Compressão de sinais usando decomposições atômicas," Tese de Doutorado, PEE/COPPE, UFRJ, Rio de Janeiro, Brasil, 2011.