

# Análise do Uso do Sinal de ECG em Baixas Frequências como Biometria

Eduardo José da Silva Luz, David Menotti  
UFOP - Federal University of Ouro Preto  
Computing Department  
Ouro Preto, MG, Brazil  
Email: {eduluz,menotti}@iceb.ufop.br

William Robson Schwartz  
UFMG - Universidade Federal de Minas Gerais  
Department of Computer Science  
Belo Horizonte, MG, Brazil  
Email: william@dcc.ufmg.br

**Abstract**—The technique called Eulerian Video Magnification (EVM) allows us to visualize the blood flow through videos of the face and makes possible the extraction of a signal correlated to the electrocardiogram (ECG), which has been used as a biometry for subject identification. However, videos are commonly acquired at low frequencies differently than the cardiac signals used for biometry. In this work, the ECG signal is resampled at low frequencies and used for identification up to 190 subjects. Results show an accuracy of 88% when the ECG signal is resampled at 30 Hz, which gives support to our hypothesis of using the signal extracted from EVM as a biometry. **Keywords**—Biometrics, ECG, frequency sampling.

**Resumo**—A técnica chamada de Eulerian Video Magnification (EVM) permite a visualização do fluxo sanguíneo através de vídeos da face e possibilita a extração de um sinal correlacionado ao eletrocardiograma (ECG), que vem sendo usada como uma biometria para identificação de indivíduos. Contudo, vídeos são comumente capturados em baixas frequências diferentemente dos sinais cardíacos usados para biometria. Neste trabalho, o sinal de ECG é re-amostrado em baixas frequências e utilizado para a identificação de até 190 indivíduos. Resultados em 30Hz mostram acurácia de 88%, o que suporta a hipótese de se utilizar a curva obtida com EVM como uma biometria.

**Keywords**—Biometria, ECG, frequência de amostragem.

## I. INTRODUÇÃO

A identificação de um indivíduo em uma população por meio de uma característica biológica única, *i.e.*, biométrica, é de grande importância na sociedade moderna, de forma que o estudo e desenvolvimento de sistemas automáticos e precisos para tal fim vem crescendo na literatura. Estratégias tradicionais, como o uso de impressões digitais, estão se tornando cada vez mais susceptíveis a fraudes. Consequentemente biometrias mais imunes à falsificação estão sendo estudadas, como por exemplo o padrão formado pelo batimento do coração, capturado pelo eletrocardiograma (ECG) [1] (ver Figura 1).

O ECG descreve a variação da atividade elétrica produzida pelo coração no tempo. A sua aquisição é extremamente simples (não-invasiva) e barata, o que facilita o uso do sinal para a tarefa de biometria. De acordo com [1], o sinal de ECG vem sendo investigado como uma biometria a pouco mais de uma década e tem se mostrado promissor. O primeiro trabalho apresentando ECG como uma biometria aparece em [3]. Os autores reportaram 100% de acurácia para identificação de

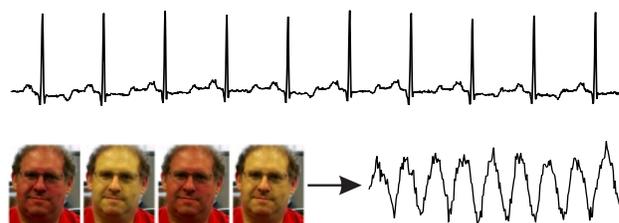


Figura 1. Sinais biométricos. Acima, uma representação de batimentos cardíacos extraídos a partir do ECG e embaixo, pulsos obtidos com Eulerian Video Magnification (EVM) [2].

22 indivíduos com um método que utilizou pontos fiduciais da curva de ECG reduzidos a 12 características por meio de *Principal Component Analysis* (PCA) e *Generative Model Classifier* (GMC) como classificador. Surgiram diversas outras iniciativas, como em [4], em que os autores reportaram 91% de acurácia para identificação de 104 indivíduos usando 15 pontos fiduciais escolhidos com *Wilks Lambda Feature Selection* e um classificador baseado em *Linear Discriminant Analysis* (LDA). Em [5], os autores extraíram 14 características dos pontos fiduciais e também fizeram uso de PCA em conjunto com GMC para identificar 520 indivíduos, reportando uma acurácia de 97,4%. Em [6], foram utilizados coeficientes da transformada wavelet a partir do sinal de ECG para identificação de 45 indivíduos e a acurácia reportada foi de 95,71%.

O sinal de ECG foi originalmente concebido para diagnóstico médico [7] e é normalmente capturado em alta frequência de amostragem (superior a 100 Hz) para permitir a visualização de minúcias associadas a doenças cardíacas. As bases de dados disponibilizadas publicamente para uso nas pesquisas de sinais de ECG (*e.g.*, [8]), fazem uso destes sinais amostrados em alta frequência.

Em [2], foi proposto um método chamado de *Eulerian Video Magnification* (EVM) que combina decomposição espacial seguida de filtragem temporal em vídeos de faces humanas. Este método permite a visualização do fluxo sanguíneo através da face e a extração de uma curva altamente correlacionada com a da pressão sanguínea (ver Figura 1), consequentemente, relacionada com o ECG. Acredita-se que a curva adquirida com o método proposto em [2] possa ser uma nova biometria para auxiliar na identificação de indivíduos por meio de

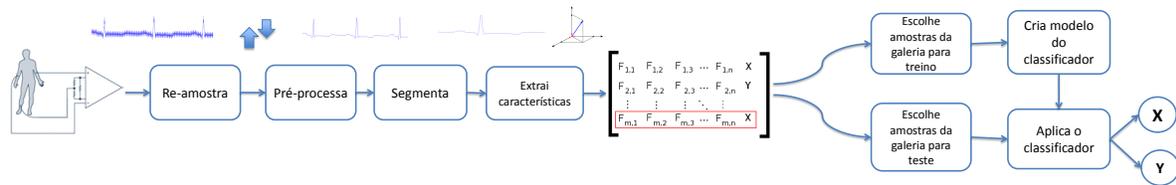


Figura 2. Diagrama de identificação de indivíduo a partir de sinais de ECG.

imagens de vídeo. Contudo, diferentemente dos sinais de ECG, vídeos são comumente capturados em baixas frequências (24fps - 30fps).

Em [9], foi investigado o impacto da frequência de amostragem do sinal de ECG, para a identificação de 70 indivíduos, em três abordagens. Os autores mostraram que o aumento da frequência de amostragem por meio de interpolação favoreceu a identificação dos indivíduos melhorando a acurácia das três abordagens. Todavia, os autores usaram bases de dados amostradas a no mínimo 128Hz e as acurácias obtidas nestas bases antes da superamostragem já eram compatíveis aos resultados reportados na literatura ( $> 95\%$ ). Até o momento, não foram encontrados trabalhos na literatura se propondo a investigar o impacto da frequência de amostragem baixa ( $< 100$  Hz) para identificação de indivíduos por meio de ECG.

O presente trabalho tem como objetivo investigar a eficácia de quatro extratores de características distintos para a representação do sinal do ECG, extraídos de curvas de ECG re-amostradas em baixas frequências, para identificação de indivíduos usando um classificador padrão - *Support Vector Machines* (SVM) [10]. Além disso, propõe-se avaliar a escalabilidade da biometria (*i.e.*, aumento do número de indivíduos) bem como o impacto da quantidade de amostras usadas no treino e teste por indivíduo na acurácia do classificador. Os resultados deste trabalho sustentarão o uso do pulso obtido com EVM a partir de vídeos de face na identificação de indivíduos.

## II. METODOLOGIA

A metodologia utilizada neste trabalho para realizar as análises propostas é descrita a seguir. Primeiramente, o sinal ECG é reamostrado em uma frequência estabelecida e então pré-processado. Pontos fiduciais do sinal são detectados (segmentação) visando a separação de cada batimento cardíaco e então a extração de características é realizada. Tendo esta representação, modelos de identificação de indivíduos são aprendidos por meio de um classificador padrão (*e.g.*, SVM [10]) a partir de uma base de treinamento, e então os modelos são avaliados usando amostras/batimentos de teste (não utilizadas durante o treinamento). O diagrama da Figura 2 ilustra esta metodologia, e mais detalhes sobre cada uma das etapas são descritos nos próximos parágrafos.

A princípio, os sinais de ECG, obtidos a partir de diferentes bases de dados disponíveis publicamente são normalizados usando interpolação linear simples. Mais detalhes sobre este

processo é apresentado na próxima seção. A fase de pré-processamento visa reduzir ruídos no sinal de ECG, normalmente oriundos de interferências musculares ou mais comumente da rede elétrica (50 ou 60Hz). Filtros digitais recursivos de resposta ao impulso finito (FIR) são os mais utilizados para atenuação dos mesmos. Também nesta fase é realizada a normalização da amplitude do sinal. A segmentação do ECG consiste em delimitar a parte de maior interesse do batimento cardíaco, o complexo QRS [11], bem como outros pontos fiduciais de interesse, como os pontos P, T e segmentos decorrentes dos pontos. Existem algoritmos na literatura com acurácia perto da otimalidade (*i.e.*, quase 100%) para realização desta tarefa, todavia neste trabalho utilizamos bases de dados onde estas informações foram anotadas previamente.

Com objetivo de avaliar diferentes representações, quatro conjuntos distintos de características foram extraídos a partir do sinal do ECG. Estes conjuntos foram selecionados de trabalhos que utilizam técnicas amplamente difundidas na literatura para representação de um batimento cardíaco e originalmente foram propostos para o problema de classificação de arritmias, visando discriminar um único batimento cardíaco de um indivíduo, ou seja, uma única amostra [12], [13], [14], [15]. Tais características são detalhadas a seguir.

1) *Chazal et al. [15]*: Utiliza 4 características extraídas a partir do intervalo RR (distância temporal entre o pico de dois batimentos consecutivos): o intervalo RR entre o batimento corrente e o antecessor (RR-anterior) e o sucessor (RR-posterior), a média de todos os intervalos RR de um registro (conjunto de batimentos de um paciente) e, por fim, a média entre os dez intervalos ao redor do batimento corrente. Além do intervalo RR, utiliza-se outros intervalos do batimento cardíaco como o intervalo QRS (ou a duração do complexo QRS), a largura da onda T, a presença/ausência da onda P. Em [15] e também neste trabalho, a extração destes pontos foi realizada com a abordagem proposta em [16].

Além de características extraídas a partir dos pontos fiduciais do sinal ECG, os autores em [15] propuseram o uso do próprio sinal. No entanto, para reduzir o tamanho do vetor de características, foi utilizado simples interpolação. Por exemplo, ao invés de usar 250 amostras (em uma representação de 360 Hz onde o tamanho do batimento é de 600 ms aproximadamente) utilizou-se apenas 19 pontos aproximados. Para este trabalho, empregou-se a melhor combinação de características reportadas em [15], totalizando 52 características.

2) *Song et al. [12]*: Os autores utilizaram a transformada wavelet para extrair 15 características de cada batimento car-

Tabela I  
DESCRIÇÃO DAS BASES DE DADOS UTILIZADAS.

Base de dados	Registros / Indivíduos	Duração	Freq. (Hz)
MITDB	48/47	30 min.	360
MITSUP	78/78	30 min.	128
NSRDB	18/18	24 horas	128
EDB	90/79	2 horas	250

díaco. O batimento cardíaco é representado por uma janela de 400 ms de amostras do sinal de ECG em torno do pico R. Estas amostras são decompostas em sete níveis da transformada wavelet, mas apenas as sub-bandas de detalhe são utilizadas. Em conjunto com estas características, outras duas oriundas do intervalo RR (RR-anterior e RR-posterior) foram incluídas ao vetor de características, totalizando 37.

3) *Güler & Übeyli [13]*: Os autores também utilizaram transformada wavelet para decompor um sinal de ECG de aproximadamente 700 ms em torno do pico R. Utilizou-se quatro bandas de detalhe e uma de aproximação da transformada wavelet. A fim de reduzir a dimensionalidade para 19 características, os autores propuseram o uso de técnicas estatísticas: média absoluta, desvio padrão e potência dos coeficientes de cada sub-banda wavelet, além da razão das médias absolutas das sub-bandas.

4) *Yu & Chou [14]*: Os autores utilizaram *Independent Component Analysis* (ICA) para extrair 100 coeficientes de um batimento composto por 200 amostras centradas no pico R. Os coeficientes do ICA foram calculados utilizando-se o algoritmo *Fast-ICA*, proposto em [17] e apenas os 33 primeiros coeficientes são utilizados. De acordo com os pesquisadores, o ICA é utilizado para decompor o sinal de ECG em uma soma ponderada de componentes que são estatisticamente e mutualmente independentes. Além desses coeficientes, é incluído o intervalo RR (RR-anterior), totalizando 13 características.

Após a extração de características, um modelo de classificação é aprendido pelo algoritmo SVM [10] a partir da base de treinamento. Este modelo é então utilizado para avaliar cada configuração em uma base de teste. O SVM foi escolhido por ser um dos classificadores mais populares encontrados na literatura hoje em dia e por reportar resultados promissores para identificação de indivíduos usando ECG [18].

### III. RESULTADOS EXPERIMENTAIS

**Criação da base de dados.** Existem várias bases de dados públicas para avaliação de sistemas destinados a reconhecer padrões em sinais de ECG. As mais populares estão disponíveis no site da Physionet [8] e neste trabalho quatro bases lá disponibilizadas foram utilizadas: MIT-BIH Arrhythmia (MITDB), MIT-BIH Supraventricular Arrhythmia Database (MITSUP), MIT-BIH Normal Sinus Rhythm (NSRDB) e European ST-T (EDB). A Tabela I apresenta detalhes sobre essas bases. Nota-se que alguns indivíduos têm registros duplicados nas bases do MITDB e EDB, os quais foram removidos, de forma que 193 indivíduos estão disponíveis para os experimentos.

As quatro bases utilizaram um mesmo tipo de *holter* para adquirir o sinal do ECG de todos os indivíduos de cada

base. Por outro lado, como existe diferença de frequência de amostragem inter-base (ver Tabela I - Freq.), foi necessário um processo de normalização (fixado para a maior frequência entre as bases, *i.e.*, 360 Hz) por meio de interpolação linear simples antes da fase de pré-processamento.

**Configuração dos experimentos.** Todos os experimentos deste trabalho foram executados 10 vezes e então calculado a média ( $\mu$ ) e desvio padrão ( $\sigma$ ) da acurácia. Os indivíduos e as amostras (batimentos cardíacos) foram escolhidos de forma aleatória dentro da base formada por 193 registros. Para o SVM, o *kernel* RBF foi utilizado e os parâmetros de regularização e do kernel foram ajustados sempre como  $C = 10$  e  $\gamma = 1/(8c)$ , em que  $c$  é o número de características do vetor.

Uma avaliação preliminar da frequência de amostragem (com o sinal reamostrado a 20Hz, 30Hz, 60Hz, 120Hz, 200Hz e 360Hz) foi realizada usando 44 indivíduos da base MITDB, por ser a base de dados com a maior frequência de amostragem (360 Hz), em que 900 e 100 batimentos de cada indivíduo foram selecionados aleatoriamente para comporem a base de treinamento e teste, respectivamente, usando o SVM como classificador. A acurácia média obtida na identificação de 40 indivíduos (em 10 execuções) para este primeiro experimento pode ser vista na Tabela II.

As acurácias obtidas em baixas frequências (20Hz, 30Hz e 60Hz) usando as características de [15], [12], [13] para identificação de indivíduos indicam resultados promissores para discriminar indivíduos por meio do sinal de ECG. Como vídeos são comumente capturados na faixa de 24 a 30 *fps*, o foco deste trabalho passa ser a análise em sinais amostrados a 30Hz. Mais especificamente, usando o conjunto de características de [12], por ter o melhor resultado em 30Hz e ser um método extremamente simples de ser implementado.

**Resultados.** Visando agora um cenário mais realístico e para suportar o uso do sinal extraído do ECG como biometria, realizamos quatro experimentos para analisar escalabilidade, acurácia vs frequência, aprendizado (treino) e identificação (teste). Em cada um destes experimentos fixamos os parâmetros em 190 indivíduos, frequência de 30 Hz, 100 e 60 batimentos de cada indivíduo para treino e teste, respectivamente e variamos apenas um deles.

- 1) **Acurácia vs Frequência:** a frequência é analisada para 20Hz, 30Hz, 60Hz, 120Hz, 200Hz e 360Hz. O objetivo deste experimento é verificar a acurácia com a variação

Tabela II  
EXPERIMENTO AVALIANDO 4 CONJUNTOS DE CARACTERÍSTICAS USANDO 44 INDIVÍDUOS EXTRAÍDOS DA BASE DE DADOS MITDB SENDO 900 E 100 INSTÂNCIAS PARA TREINO E TESTE, RESPECTIVAMENTE.

Freq. (Hz)	Métodos (Acurácia em %)			
	[15]	[14]	[12]	[13]
20	86,5	2,3	82,9	78,4
30	86,8	7,0	91,5	78,2
60	87,6	6,3	95,9	87,4
120	86,5	33,7	92,6	88,1
200	85,9	37,7	92,8	89,2
360	98,6	86,0	96,1	88,4

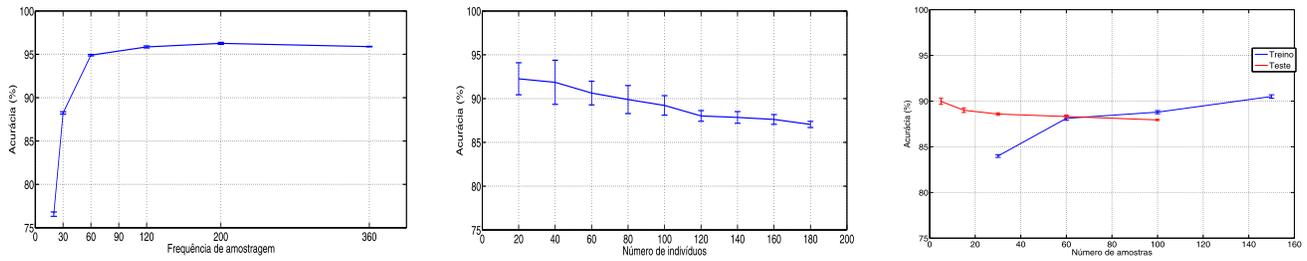


Figura 3. Experimentos de avaliação. a) Sinal reamostrado nas frequências 20Hz, 30Hz, 60Hz, 120Hz, 200Hz e 360Hz. b) Escalabilidade - número de indivíduos de 20 a 180. c) Aprendizado/Identificação - número de amostras de batimentos para treino e teste.

da frequência em uma base com mais indivíduos.

- 2) Escalabilidade: o sistema é avaliado usando 20, 40, 60, 80, 100, 120, 140, 160 e 180 indivíduos. Com a realização deste experimento procura-se estimar o tamanho do universo em que essa biometria pode ser utilizada.
- 3) Aprendizado: o classificador é treinado com 30, 60, 100 e 150 amostras/batimentos de cada indivíduo.
- 4) Identificação: a acurácia é medida por meio de 5, 15, 30, 60 e 100 amostras.

O objetivo destes dois últimos experimentos é verificar o funcionamento do sistema em função das bases de treino e teste. Os resultados obtidos por estes experimentos podem ser vistos nos gráficos da Figura 3.

**Discussão.** Com relação à frequência, observa-se que a acurácia é estável a partir de 60 Hz e degradando-se em 30 Hz. Todavia, considera-se promissor o resultado obtido com 30 Hz e consequentemente a possibilidade do uso do sinal extraído do EVM como biometria. Já a escalabilidade, como era de se esperar, diminui lentamente a medida em que o número de indivíduos aumenta. São necessários experimentos com grandes quantidades de indivíduos para verificar o “momento” de saturação e também com outros classificadores. Para o SVM, verificou-se que quanto maior o número batimentos de cada indivíduo para treinamento maior a acurácia do sistema de identificação de indivíduos, já o teste obtém melhores resultados com um menor número de amostras.

#### IV. CONCLUSÕES

Neste trabalho, investigou-se o impacto da amostragem do ECG em baixas frequências para o problema de identificação de indivíduos. Os experimentos realizados indicam que maiores frequências de amostragem resultam em maior acurácia na identificação de indivíduos. No entanto, com o ECG reamostrado em baixas frequências apresentou-se resultados promissores para se discriminar indivíduos. A acurácia para a identificação de 190 indivíduos, por meio de ECG reamostrado a 30Hz, foi de  $88,24\% \pm 0,13$ . Este resultado suporta a hipótese de se utilizar a curva de fluxo sanguíneo obtida com o método proposto em [2] como uma nova biometria. Portanto, nossa direção de trabalho futuro será a avaliação dessa curva extraída a partir de vídeos de faces para o problema em questão.

#### AGRADECIMENTOS

Os autores gostariam de agradecer o suporte financeiro dado pela FAPEMIG, CAPES e CNPq.

#### REFERÊNCIAS

- [1] I. Oginaka, P.-H. Lai, A. Kaplan, J. O’Sullivan, E. Sirevaag, and J. Rohrbaugh, “ECG biometric recognition: A comparative analysis,” *Information Forensics and Security, IEEE Transactions on*, 2012.
- [2] H.-Y. Wu, M. Rubinstein, E. Shih, J. Gutttag, F. Durand, and W. T. Freeman, “Eulerian video magnification for revealing subtle changes in the world,” *ACM Trans. Graph. (Proceedings SIGGRAPH 2012)*, 2012.
- [3] L. Biel, O. Pettersson, L. Philipson, and P. Wide, “ECG analysis: a new approach in human identification,” *Instrumentation and Measurement, IEEE Transactions on*, 2001.
- [4] J. M. Irvine, B. K. Wiederhold, L. W. Gavshon, and et al, “Heart rate variability: a new biometric for human identification,” in *International Conference on Artificial Intelligence*, 2001.
- [5] Z. Zhang and D. Wei, “A new ECG identification method using bayes’ theorem,” in *TENCON. IEEE Region 10 Conference*, 2006.
- [6] C.-C. Chiu, C.-M. Chuang, and C.-Y. Hsu, “A novel personal identity verification approach using a discrete wavelet transform of the ECG signal,” in *Multimedia and Ubiquitous Engineering (MUE). International Conference on*, 2008.
- [7] E. J. da S. Luz, T. M. Nunes, V. H. C. de Albuquerque, J. P. Papa, and D. Menotti, “ECG arrhythmia classification based on optimum-path forest,” *Expert Systems With Applications*, 2013.
- [8] G. B. Moody and R. G. Mark, “The impact of the MIT-BIH arrhythmia database,” *IEEE Engineering in Medicine and Biology Magazine*, 2001.
- [9] K. A. Sidek and I. Khalil, “Enhancement of low sampling frequency recordings for ECG biometric matching using interpolation,” *Computer Methods and Programs in Biomedicine*, 2013.
- [10] C. Cortes and V. N. Vapnik, “Support-vector networks,” *Machine Learning*, 1995.
- [11] O. Sayadi and M. B. Shamsollahi, “A model-based bayesian framework for ECG beat segmentation,” *Physiological Measurement*, 2009.
- [12] M. H. Song, J. Lee, S. P. Cho, K. J. Lee, and S. K. Yoo, “Support vector machine based arrhythmia classification using reduced features,” *International Journal of Control, Automation, and Systems*, 2005.
- [13] I. Güler and E. D. Übeyli, “ECG beat classifier designed by combined neural network model,” *Pattern Recognition*, 2005.
- [14] S. Yu and K. Chou, “Integration of independent component analysis and neural networks for ECG beat classification,” *Expert Systems with Applications*, 2008.
- [15] P. Chazal, M. O’Dwyer, and R. B. Reilly, “Automatic classification of heartbeats using ECG morphology and heartbeat interval features,” *IEEE Transactions on Biomedical Engineering*, 2004.
- [16] P. Laguna, R. Jané, and P. Caminal, “Automatic detection of wave boundaries in multilead ECG signals: Validation with the CSE database,” *Computers and Biomedical Research*, 1994.
- [17] A. Hyvärinen, “Fast and robust fixed-point algorithms for independent component analysis,” *IEEE Transactions on Neural Networks*, 1999.
- [18] C. Ye, M. T. Coimbra, and B. V. K. V. Kumar, “Arrhythmia detection and classification using morphological and dynamic features of ECG signals,” in *IEEE International Conference on Engineering in Medicine and Biology Society (EMBC)*, 2010.