

Rede Neural IncResU-Net para Inferência de Sinais Eletrocardiograma a partir de Sinais Fotopletismograma

Rafael Albuquerque Pinto, Hygo de Oliveira, Eduardo Souto, Rafael Giusti

¹ Instituto de Computação – Universidade Federal do Amazonas (UFAM)
Caixa Postal – 69080-900 – Manaus – AM – Brazil

{rafael.albuquerque,hygo.sousa,esouto,rgiusti}@icompu.ufam.edu.br

Abstract. *The electrocardiogram (ECG) is a medical exam that measures the electrical activity of the heart, while the photoplethysmogram (PPG) measures changes in blood volume through light-based technology. Although both methods are used to monitor heart rate, ECG is considered the gold standard method for diagnosing heart disease because it provides additional information about heart function. Despite efforts to integrate ECG detection into wearable devices for continuous and reliable heart monitoring, PPG sensors are currently the main viable solution. This work proposes a method called PPG2ECG, based on domain mapping, applying a set of convolution filters, using a U-net Inception neural network architecture to infer ECG signals from PPG signals. To evaluate the effectiveness of the proposed method, two evaluation strategies were adopted, based on personalized and generalized models. The results obtained demonstrated average error values of 0.015 and 0.026, respectively.*

Resumo. *O eletrocardiograma (ECG) é um exame médico que mede a atividade elétrica do coração, enquanto o fotopletismograma (PPG) mede as alterações no volume sanguíneo por meio de tecnologia baseada em luz. Embora ambos os métodos sejam usados para monitorar a frequência cardíaca, o ECG é considerado o método padrão ouro para o diagnóstico de doenças cardíacas porque fornece informações adicionais sobre o funcionamento do coração. Apesar dos esforços para integrar a detecção de ECG em dispositivos vestíveis para monitoramento cardíaco contínuo e confiável, os sensores PPG são atualmente a principal solução viável. Este trabalho propõe um método denominado PPG2ECG, baseado no mapeamento entre domínios, aplicando um conjunto de filtros de convolução, utilizando uma arquitetura de rede neural U-net Inception, para inferir sinais ECG a partir de sinais PPG. Para avaliar a eficácia do método proposto, foram adotadas duas estratégias de avaliação, baseadas em modelos personalizados e generalizados. Os resultados obtidos demonstraram valores médios de erros médio quadráticos de 0,015 e 0,026, respectivamente.*

1. Introdução

Estudos da Organização Mundial da Saúde (OMS) apontam que as doenças cardiovasculares são uma das principais causas de morte em todo o mundo nos últimos 20 anos [Organization 2021]. O número de mortes por doenças cardíacas aumentou em mais de 2 milhões desde 2000, chegando a quase 9 milhões em 2019, devido principalmente ao estilo de vida sedentário, estresse no trabalho, obesidade e tabagismo da população, segundo a OMS.

O monitoramento das atividades cardíacas é comumente realizado em ambientes clínicos. Entretanto, isso torna o diagnóstico de muitas doenças cardiovasculares uma tarefa não trivial, pois existem casos em que essas doenças se manifestam fora do ambiente clínico como, por exemplo, as arritmias intermitentes e anomalias cardíacas que podem ocorrer durante a prática de uma atividade física ou durante o sono. Por essa razão, o monitoramento contínuo das atividades cardíacas é visto como essencial para fornecer um diagnóstico precoce dessas doenças [Ravichandran et al. 2019].

Dois métodos são amplamente utilizados para obter medidas de frequência cardíaca: eletrocardiografia (ECG - electrocardiogram) e fotopletismografia (PPG - photoplethysmography).

O eletrocardiograma (ECG) de 12 derivações é comumente usado em ambientes clínicos e é considerado o padrão ouro para medir e monitorar as atividades elétricas realizadas pelo coração. No entanto, pode ser inconveniente obter os sinais ECG continuamente devido à necessidade da utilização de eletrodos, fios, gel, adesivos e pinos de metal em diferentes partes do corpo, o que pode restringir a movimentação do paciente. Além disso, esses materiais podem causar irritação e desconforto na pele durante o uso prolongado e contínuo. Para minimizar esses problemas, há uma quantidade significativa de pesquisas em andamento com o objetivo de criar dispositivos vestíveis com ECG que sejam adequados para o uso diário. Infelizmente, o progresso nesta área tem sido limitado até o momento. Existem poucos dispositivos de pulso (smartwatches e smartbands) que oferecem monitoramento de ECG. No entanto, mesmo esses dispositivos têm limitações, exigindo que os usuários fiquem parados e toquem o relógio com as duas mãos para registrar um segmento limitado de ECG [Sarkar and Etemad 2020].

O fotopletismograma (PPG) é um método óptico que detecta alterações do volume sanguíneo na camada microvascular do tecido da pele a cada batimento cardíaco [Elgendi et al. 2019]. Por ser simples, de baixo custo e não invasivo, o PPG é considerado uma alternativa ao ECG. Vários estudos tem mostrado que um número de características extraídas do sinal PPG (e.g. pulse rate variability) são altamente correlacionadas com métricas correspondentes extraídas do ECG (e.g. heart rate variability) [Chiu et al. 2020]. Embora os sensores PPG em dispositivos vestíveis sejam populares, o ECG ainda é considerado o método padrão para o diagnóstico de doenças cardíacas, com uma vasta literatura de apoio e estudos para os especialistas.

Embora os sinais ECG e PPG tenham similaridades, é necessário encontrar uma função de mapeamento que relacione os dois sinais para permitir o monitoramento contínuo de atividades cardíacas via PPG. Este trabalho propõe uma arquitetura de codificador-decodificador com o núcleo formado por Rede Neural Convolucional (CNN) para gerar um modelo capaz reconstruir o sinal ECG a partir do sinal PPG. Para melhorar o desempenho da rede, foram utilizados blocos residuais inception que permitem o uso de diferentes tamanhos de filtros de convolução em paralelo, capturando informações em diferentes escalas. Além disso, também foram adicionadas conexões de skip entre os caminhos do codificador e decodificador para preservar informações espaciais de alta granularidade. Experimentos realizados com a combinação dos conjuntos de dados BIDMC [Pimentel et al. 2017], CAPNO [Karlen et al. 2013], DALIA [Reiss et al. 2019] e WE-SAD [Schmidt et al. 2018] evidenciam que o método PPG2ECG possui a capacidade de reconstruir de forma precisa o sinal ECG original. Essa habilidade foi avaliada por meio

de duas estratégias, utilizando modelos personalizados e generalizados, obtendo valores médios de erro de 0,015 e 0,026, respectivamente.

O restante deste artigo está organizado da seguinte forma. A Seção 2 fornece uma discussão sobre pesquisas anteriores relacionadas ao estudo atual. A Seção 3 descreve os dados utilizados nesta pesquisa, bem como as manipulações aplicadas a esses dados, a arquitetura de rede neural, o método de validação e as métricas usadas. Na Seção 4 são apresentados os resultados obtidos e, por fim, na Seção 5 são apresentadas as conclusões e possíveis direções para pesquisas futuras.

2. Trabalhos Relacionados

Embora haja correlações entre os sinais ECG e PPG, poucas soluções para reconstruir o sinal ECG a partir do sinal PPG foram propostas. [Banerjee et al. 2013] inferiram parâmetros dos intervalos de ondas RR, PR, QRS e QT do sinal ECG a partir de características extraídas dos domínios do tempo e da frequência do sinal PPG. [Zhu et al. 2019] analisaram a relação entre os sinais ECG e PPG por meio de uma técnica de transformação que mapeia os coeficientes DCT de cada ciclo PPG em relação ao ciclo ECG correspondente. [Tian et al. 2020] apresentaram um método baseado em aprendizado de dicionário que encontra uma representação esparsa dos dados de PPG em relação ao ECG.

Considerando trabalhos com uso de redes neurais profundas para a reconstrução de sinais ECG a partir de sinais PPG. [Sarkar and Etemad 2020] propuseram um método baseado em Redes Adversárias Generativas (GANs) que utiliza mecanismos de atenção para focar em regiões específicas do sinal ECG como os complexos QRS. [Chiu et al. 2020] apresentaram um método composto por uma rede de transformadores de sequência para tratar o problema de deslocamento temporal de diferentes sinais, uma rede de atenção para aprender os pontos mais importantes do sinal PPG para a reconstrução do ECG e uma CNN codificador-decodificador para mapear a saída dos dois primeiros componentes para o sinal ECG.

Diferentemente das arquiteturas profundas descritas, este trabalho utiliza uma arquitetura mais compacta para reduzir a complexidade computacional. A reconstrução de sinal ECG é feita usando uma CNN unidimensional baseada em uma arquitetura codificador-decodificador. Para melhorar a precisão dos sinais ECG reconstruídos, são aplicadas técnicas de filtragem para aprimorar a morfologia do sinal e melhorar a generalização do modelo de aprendizado. Essas técnicas ajudam a enfrentar desafios comuns como ruído, atenuação de sinal e variabilidade na morfologia dos sinais.

3. Materiais e Método

O processo de geração do modelo de reconstrução do sinal ECG a partir do sinal PPG é composto por três etapas distintas, como ilustrado na Figura 1. O primeiro passo é a aquisição dos dados, que consiste na coleta dos sinais provenientes dos sensores PPG e ECG. Em seguida, é realizada a etapa de pré-processamento de sinais, que inclui procedimentos de filtragem, normalização e segmentação dos sinais ao longo do tempo. Por fim, o modelo é treinado. As seções seguintes fornecem detalhes sobre cada etapa do processo de geração do método proposto, denominado de PPG2ECG.

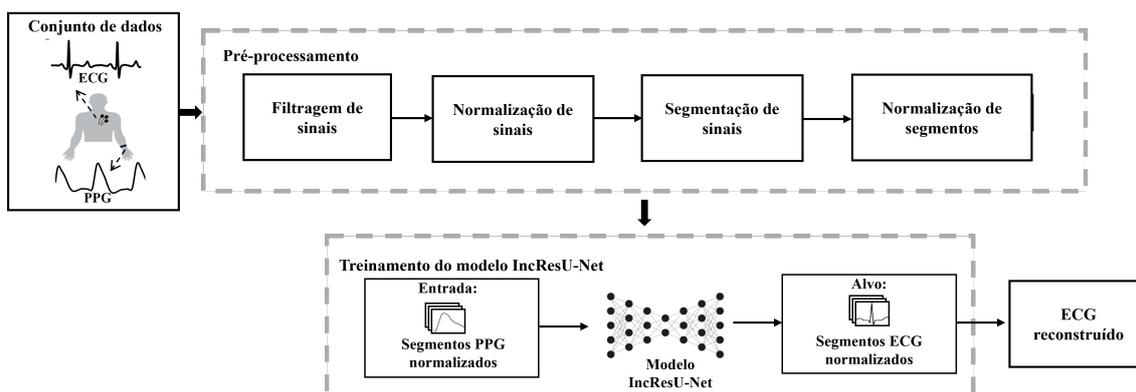


Figura 1. Visão geral do processo de geração do método PPG2ECG.

3.1. Conjuntos de Dados

Neste estudo foram utilizados quatro conjuntos de dados ECG-PPG: BIDMC [Pimentel et al. 2017], CAPNO [Karlen et al. 2013], DALIA [Reiss et al. 2019] e WESAD [Schmidt et al. 2018]. O conjunto de dados agregado contém um total de 125 participantes com uma proporção equilibrada entre homens e mulheres. A Tabela 1 apresenta um resumo das características dessas bases de dados. As formas de onda dos sinais PPG e ECG variam conforme o ambiente em que foram coletadas, podendo ser a partir de dispositivos clínicos em ambientes controlados ou de dispositivos vestíveis durante a execução de atividades diárias. Assim, o conjunto de dados agregado possui uma grande variedade de sinais ruidosos e anormais, exigindo a aplicação de técnicas de processamento de sinais. Como os conjuntos de dados foram coletados por diferentes dispositivos, cada conjunto apresenta diferentes frequências de amostragem, tornando necessária a realização de um processo de reamostragem nos sinais ECG e PPG para unificar a frequência de amostragem. Após o processo de reamostragem por meio de interpolação, o conjunto de dados agregado foi padronizado para uma frequência de amostragem de 128 Hz.

Tabela 1. Características das bases de dados utilizadas nos experimentos.

Base de dados	BIDMC	CAPNO	DALIA	WESAD
Número de pacientes	53	42	15	15
Atividade	pacientes em estado crítico	paciente em observação médica	sentar, caminhar, dirigir, andar de bicicleta	resolver tarefas aritméticas, assistir a vídeos
Frequência de amostragem	125 Hz	300 Hz	700 Hz e 64 Hz	700 Hz e 64 Hz
Tempo de observação	8 minutos	8 minutos	aproximadamente 120 minutos	mais de 60 minutos

3.2. Preprocessamento de Dados

Esta seção detalha as técnicas de processamento de sinal adotadas para melhorar a qualidade dos sinais ECG e PPG.

3.2.1. Filtragem de Sinais

Os sinais captados por sensores ECG e PPG podem ser afetados por diferentes tipos de ruído, tanto internos, como movimentos do corpo, quanto externos, como interferências elétricas. Para remover esses ruídos, é necessário aplicar métodos de filtragem. No entanto, devido à complexidade e variedade de ambientes de aplicação, o sinal PPG é mais suscetível a interferências do que o ECG. Por essa razão, a literatura sugere diferentes filtros para cada sinal. De acordo com [Liang et al. 2018], o filtro Butterworth é o mais indicado para aplicação em sinais PPG, pois pode eliminar oscilações de linha de base e frequências altas que prejudicam a morfologia do sinal. Assim, a aplicação do filtro Butterworth visa minimizar as alterações na morfologia do sinal PPG, que não são de origem cardíaca. Da mesma forma, os ruídos presentes nos sinais ECG também podem levar a avaliações erradas sobre os pacientes e reduzir a exatidão do diagnóstico [Berkaya et al. 2018]. Neste contexto, foi aplicada a técnica de filtragem de resposta ao impulso finito (FIR - Finite Impulse Response) no sinal ECG.

3.2.2. Normalização e Segmentação dos Sinais ECG e PPG

Para ajustar a série temporal dos sinais ECG e PPG a uma distribuição normal, é utilizada a técnica de normalização z-score. Essa técnica considera a média μ e o desvio padrão σ de cada sinal para normalizar seus valores e é obtida pela seguinte forma:

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

Após a normalização z-score, os dados são submetidos à etapa de segmentação, que consiste em dividir cada sinal em segmentos de comprimento fixo. Em seguida, os dados segmentados são normalizados novamente, mas desta vez com a técnica Min-Max, a fim de garantir que todos os valores de entrada para o modelo neural estejam dentro de um intervalo específico. Isso permite que o modelo lide de forma eficiente com os dados e reduz a sensibilidade a valores discrepantes.

$$x' = \frac{(x - \min(x))}{(\max(x) - \min(x))}, \quad (2)$$

O processo de segmentação é responsável por separar as séries temporais em intervalos menores definidos como segmentos ou janelas de tempo, de forma que cada segmento possua uma quantidade de amostra limitada, conforme o seu tamanho. O tamanho de cada segmento dos sinais PPG e ECG é definido conforme a frequência de amostragem dos sinais. O resultado da segmentação será um conjunto de dados $X = \{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\}$, que consiste no sinal PPG de entrada $x^{(i)}$ e o sinal ECG de referência $y^{(i)}$, onde o sinal de entrada $x^{(i)}$ deve ter o mesmo número de elementos do sinal de referência $y^{(i)}$. Cada segmento de dados $(x^{(i)}, y^{(i)})$, possui um tempo inicial t_i e um tempo final t_f , com uma sobreposição de 10% para evitar a perda de quaisquer picos dos sinais ECG e PPG.

3.3. Arquitetura de Rede Neural

A rede proposta foi inspirada na rede neural IncResU-Net que combina as arquiteturas U-net [Ronneberger et al. 2015] e Inception-ResNet [Szegedy et al. 2017]. Para o propósito deste trabalho, a arquitetura da rede IncResU-Net foi adaptada, com modificações no número de camadas e nas operações bidimensionais de convolução, pooling e upsampling, que foram substituídas por suas contrapartes unidimensionais.

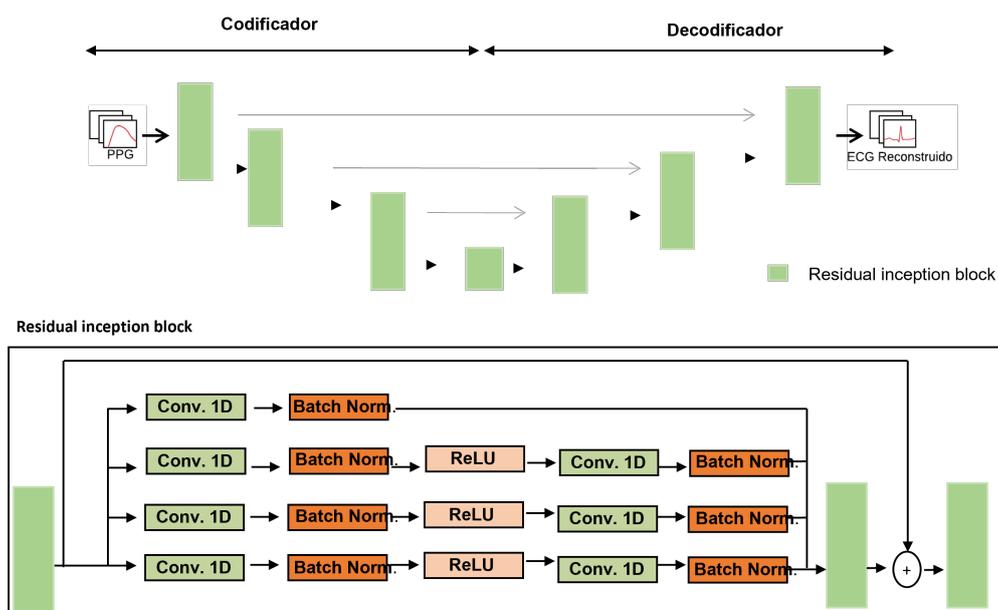


Figura 2. Arquitetura Unet Inception utilizada para gerar um sinal ECG.

A arquitetura proposta é composta por duas etapas: o codificador e o decodificador, conforme ilustrado na Figura 2. Na etapa do codificador, a operação de downsampling tem dois sinais de entrada: PPG e um canal do ECG (derivativa II). O codificador é composto por 4 níveis, onde a operação de convolução é realizada usando filtros de tamanho 1×4 , iniciando com 32 filtros. A operação de *downsampling* reduz o tamanho da entrada enquanto aumenta o número de filtros em cada nível, por um fator de dois, até que o número de filtros seja 256. Isso é seguido por uma camada *batch normalization*, função de ativação ReLU e um bloco inception residual dilatado. A camada de *batch normalization* ajuda a reduzir a covariância entre as ativações das camadas ocultas, transformando os valores de entrada em uma distribuição de média zero e variância um. A função de ativação ReLU produz ativações esparsas, retornando zero para valores de entrada negativos e o próprio valor para valores de entrada positivos, reduzindo a complexidade computacional do modelo e melhorando sua capacidade de generalização. O bloco residual melhora o poder de representação da rede, permitindo que ela capture características e padrões complexos no sinal PPG com uma área de observação maior, sem aumentar significativamente os parâmetros da rede, ajudando a reduzir o problema do *vanishing gradient* e a melhorar a convergência durante o treinamento.

A operação de *upsampling* é realizada no decodificador usando a operação de deconvolução em cada nível, similar a etapa do codificador. Além disso, a arquitetura incorpora conexões de *skip* entre os pares codificador-decodificador de mesmo nível para preservar informações espaciais de alta granularidade e melhorar o desempenho da rede.

4. Experimentos e Resultados

Neste estudo, o método proposto é avaliado seguindo duas configurações de treinamento:

- **Modelo de grupo (GM):** nós geramos um modelo usando os dados de treinamento de todos os indivíduos, ou seja, usamos um modelo genérico para capturar a relação dos sinais PPG e ECG para um grupo de indivíduos.
- **Modelo específico por sujeito (SM):** um modelo foi treinado e testado para cada indivíduo para obter um modelo específico de um sujeito.

No modelo generalista, o conjunto de dados foi particionado em uma proporção de 80:20 para treinamento e teste, respectivamente. O modelo foi treinado com dados de todos os sujeitos, excluindo os dados do sujeito selecionado para teste. A ideia é garantir que os resultados dos testes fossem baseados em dados não vistos e que o desempenho do modelo fosse bem generalizado para novos pacientes.

Para a geração do modelo específico por sujeito foi adotada uma abordagem híbrida. Semelhante ao adotado na abordagem generalista, o conjunto de dados foi particionado em uma proporção de 80:20 para treino e teste. Entretanto, devido à quantidade de dados por sujeito ser pequena, o conjunto de dados de treino foi composto por 80% dos dados do sujeito específico para qual o modelo será gerado e 20% dos dados dos outros sujeitos. O objetivo é criar um modelo que seja mais preciso e adaptado às características únicas do paciente em questão, ao mesmo tempo, em que se beneficia da inclusão de dados de outros pacientes para aumentar a eficácia geral do modelo. Os modelos propostos são comparados com dois métodos recentes: CardioGAN [Sarkar and Etemad 2020] e Rede de Transformadores [Chiu et al. 2020], descritos na Seção 2.

4.1. Métricas de avaliação

A avaliação da similaridade e dissimilaridade entre os sinais é realizada utilizando as seguintes métricas: distâncias Euclidiana e *Dynamic time warping* (DTW), correlação de Person e Spearman, e funções de perda erro quadrático médio (MSE) e erro absoluto médio (MAE). representadas nas equações exibidas na tabela 2 a seguir.

Tabela 2. Métricas de avaliação

Métricas	Fórmulas
Distância Euclidiana	$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$
Distância DTW	$DTW(x, y) = \sqrt{(\min_cost_path(x, y))^2}$
Correlação de Pearson	$r(x, y) = \frac{cov(x, y)}{(std(x) * std(y))}$
Correlação de Spearman	$r = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}$
MSE	$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2$
MAE	$MAE = \frac{1}{n} \sum_{i=1}^n x_i - y_i $

4.2. Treinamento

Durante o treinamento, a rede foi inicializada com pesos randômicos. O treinamento do modelo foi realizado por 300 épocas, com um batch size de 32 e um otimizador Adam com uma taxa de aprendizagem da rede configurada para 0,0001. Foram utilizados checkpoints

e parada antecipada, com espera de 5 épocas. O checkpoint permitiu que os pesos da rede neural fossem salvos periodicamente durante o treinamento, enquanto o método de parada antecipada interrompeu o treinamento prematuramente se a perda não melhorasse após um certo número de épocas. O Modelo foi desenvolvido e implementado usando a linguagem Python 3 e os frameworks Keras e TensorFlow.

4.3. Resultados

4.3.1. Modelo de grupo (GM)

A avaliação em questão tem como propósito testar a eficácia do método proposto em reconstruir sinais de ECG para múltiplos indivíduos. A Figura 3 exibe a reconstrução de segmentos de 4 segundos de sinais ECG aleatórios de diferentes pacientes para cada base de dados.

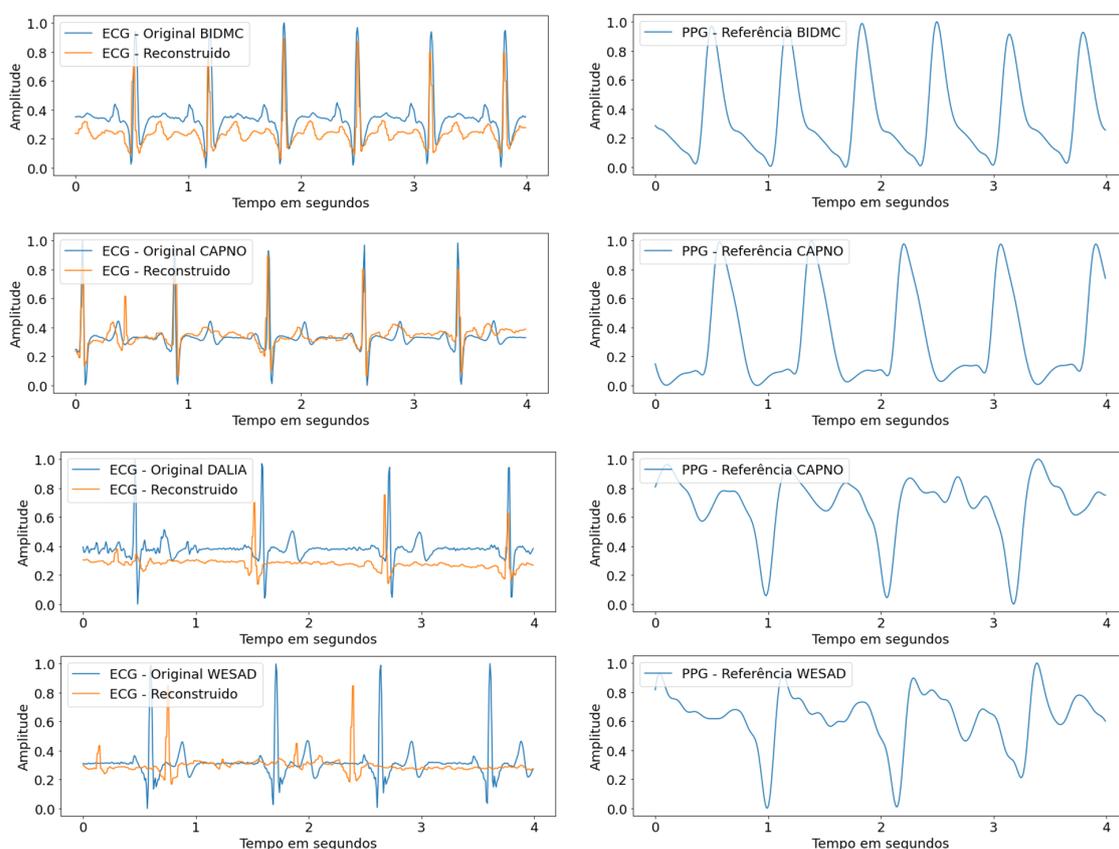


Figura 3. ECG reconstruído a partir PPG usando o modelo de grupo.

A partir dos resultados obtidos, pode-se observar que o método proposto apresentou uma melhor aproximação dos sinais nas bases de dados BIDMC e CAPNO em comparação com as bases de dados DALIA e WESAD. Isso pode ser explicado pela ampla variação dos sinais coletados a partir de dispositivos vestíveis nessas últimas bases de dados, o que resulta em uma maior variabilidade na morfologia do sinal entre os pacientes. Essa variabilidade pode ter dificultado a generalização do modelo para essas bases de dados, o que pode indicar que o método precisa ser aprimorado para lidar com essa maior diversidade de sinais.

A Tabela 3 compara o desempenho de diferentes métodos de mapeamento de sinais, utilizando a estratégia de avaliação de modelo generalizado. As métricas de distância e similaridade foram calculadas para quantificar as diferenças e semelhanças entre os sinais, validando os resultados da reconstrução do sinal ECG apresentados na Figura 3.

Tabela 3. Comparação de desempenho dos métodos de mapeamento de sinais utilizando a estratégia de avaliação do modelo de grupo (GM).

Método	Base	Métricas					
		Euclidiana	DTW	Person	Spearman	MSE	MAE
CardioGan	BIDMC	4,126	2,403	0,012	0,062	0,036	0,137
	CAPNO	3,518	2,143	0,037	0,104	0,026	0,116
	DALIA	3,732	2,480	-0,001	0,000	0,028	0,132
	WESAD	2,839	1,947	-0,001	-0,002	0,016	0,081
Médias das métricas		3,554	2,243	0,012	0,041	0,027	0,117
Transformadores com mecanismo de atenção	BIDMC	4,142	2,387	0,004	-0,015	0,033	0,126
	CAPNO	3,496	2,042	0,010	0,075	0,024	0,111
	DALIA	3,424	2,835	0,001	-0,002	0,023	0,119
	WESAD	2,553	2,262	0,000	-0,003	0,012	0,062
Médias das métricas		3,404	2,382	0,004	0,014	0,023	0,105
Método Proposto ECG2PPG	BIDMC	4,016	2,247	0,008	0,089	0,037	0,131
	CAPNO	3,504	2,022	0,064	0,102	0,025	0,114
	DALIA	3,676	2,472	0,001	0,113	0,027	0,127
	WESAD	4,016	2,247	0,008	0,089	0,037	0,131
Média das métricas		3,507	2,169	0,018	0,076	0,026	0,112

O método PPG2ECG apresentou métricas variando de 3,507 a 2,169. A métrica Euclidiana, que mede a distância entre os sinais, apresentou valores mais elevados, variando de 3,504 a 4,016, o que indica que os sinais mapeados pelo método PPG2ECG têm maior distância em relação aos sinais de referência em comparação com os outros métodos avaliados. Em contrapartida, as métricas DTW, Person, Spearman, MSE e MAE apresentaram valores dentro do intervalo de 2,022 a 2,472, indicando um desempenho similar em relação aos demais métodos. No entanto, podemos observar que o método PPG2ECG obteve as melhores médias para as métricas DTW, Person e Spearman em todas as bases de dados, sugerindo que os sinais reconstruídos com esse método possuem maior similaridade com o sinal original em relação aos demais métodos. O destaque do método PPG2ECG foi na métrica de correlação de Pearson, com valor de 0,018, o que indica uma correlação positiva entre os sinais mapeados e os sinais de referência, o que reforça a qualidade desse método em relação aos demais métodos avaliados na tabela.

4.3.2. Modelo específico por sujeito (SM)

O objetivo da avaliação foi mostrar a capacidade do método PPG2ECG em inferir sinais de ECG de um usuário específico a partir do sinal PPG correspondente, em comparação com os métodos de referência. A avaliação considerou a capacidade do método em mapear o sinal PPG para o sinal ECG, levando em consideração a correlação prévia entre esses sinais para um usuário específico. A Figura 4 apresenta a reconstrução de segmentos de 4 segundos de sinais ECG de diferentes pacientes selecionados aleatoriamente

para cada uma das bases de dados avaliadas. O método proposto pelo estudo demonstrou resultados mais precisos na inferência de sinais ECG similares ao ECG original ao utilizar as bases de dados BIDMC e CAPNO. Importante destacar que, para essas bases de dados, os dados dos usuários utilizados para treinar e testar os modelos de inferência foram coletados em ambientes hospitalares, nos quais os usuários estavam em repouso ou anestesiados, resultando em sinais mais estáveis e com pouca variação na morfologia. No entanto, a avaliação do modelo personalizado híbrido para as bases de dados DALIA e WESAD apresentou mais desafios devido à grande variação dos sinais, já que esses foram coletados durante a realização de diversas atividades diárias.

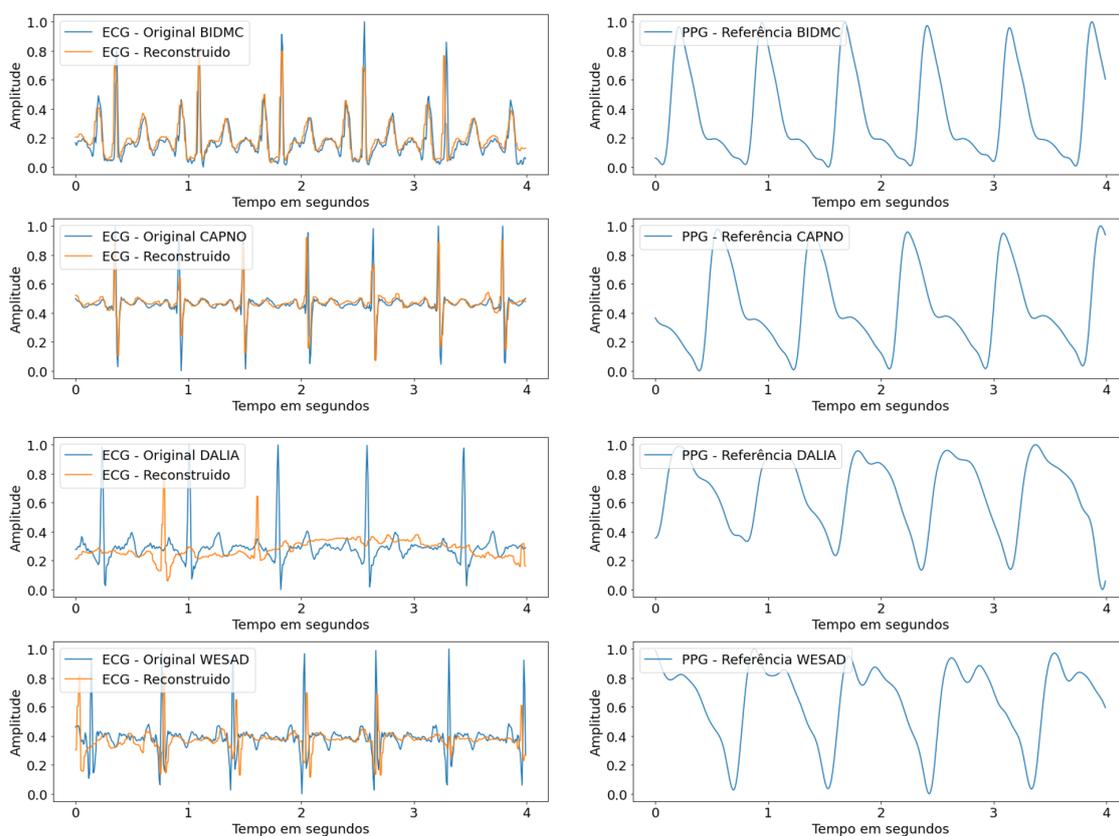


Figura 4. ECG reconstruído a partir PPG usando o modelo específico por sujeito.

A Tabela 4 compara o desempenho do método proposto com os métodos de referência na reconstrução do sinal ECG usando uma abordagem personalizada híbrida. Ao analisar as métricas médias para cada método, nota-se que o PPG2ECG obteve um desempenho semelhante aos outros métodos. A última linha da tabela apresenta a média das métricas para cada método. Para o PPG2ECG, a média das métricas foi de 2,680 para Euclidiana, 1,559 para DTW, 0,329 para Person, 0,334 para Spearman, 0,015 para MSE e 0,073 para MAE. Esses resultados indicam que o método proposto apresentou um erro médio menor na reconstrução do sinal ECG em relação ao sinal ECG original. Em resumo, a tabela sugere que o método PPG2ECG proposto tem um bom desempenho em comparação com os métodos de referência na reconstrução do sinal ECG a partir do sinal PPG.

Tabela 4. Comparação de desempenho dos métodos de mapeamento de sinais utilizando a estratégia de avaliação do modelo específico por sujeito (SM).

Método	Base	Métricas					
		Euclidiana	DTW	Person	Spearman	MSE	MAE
CardioGan	BIDMC	2,518	1,244	0,525	0,555	0,014	0,064
	CAPNO	1,654	1,053	0,753	0,69	0,006	0,038
	DALIA	3,321	2,003	0,004	0,007	0,022	0,104
	WESAD	3,252	2,118	0,004	0,008	0,02	0,093
Médias das métricas		2,686	1,604	0,321	0,315	0,015	0,074
Transformadores com mecanismo de atenção	BIDMC	2,924	1,751	0,366	0,360	0,018	0,082
	CAPNO	1,962	1,155	0,650	0,503	0,008	0,05
	DALIA	3,158	2,673	0,001	-0,003	0,020	0,101
	WESAD	2,865	2,529	0,001	-0,002	0,016	0,077
Médias das métricas		2,727	2,027	0,254	0,214	0,015	0,077
Método Proposto ECG2PPG	BIDMC	2,482	1,177	0,559	0,601	0,013	0,057
	CAPNO	1,691	0,977	0,747	0,714	0,006	0,035
	DALIA	3,387	2,125	0,007	0,013	0,023	0,104
	WESAD	3,162	1,958	0,004	0,009	0,021	0,096
Média das métricas		2,680	1,559	0,329	0,334	0,015	0,073

5. Conclusão

Com base nos resultados obtidos, o método PPG2ECG apresentou desempenho superior em relação aos métodos de comparação avaliados para a reconstrução do sinal ECG. Esse resultado é especialmente significativo considerando-se a complexidade da tarefa de reconstrução do sinal, devido às variações na morfologia do ECG de pacientes diferentes. O método PPG2ECG demonstrou uma menor distância em relação aos métodos baselines, indicando uma maior precisão na reconstrução do sinal ECG. Além disso, a abordagem personalizada híbrida utilizada no método proposto apresentou um menor erro de reconstrução em comparação com o método generalista. Essa vantagem pode ser atribuída à capacidade do método proposto de adaptar-se às características específicas de cada paciente, permitindo uma reconstrução mais precisa do sinal ECG. No entanto, apesar dos resultados promissores, o uso clínico do método PPG2ECG ainda enfrenta desafios. Um dos principais desafios é a necessidade de desenvolver um processo de compressão e otimização do modelo para torná-lo viável para execução em dispositivos móveis.

6. Agradecimentos

O presente trabalho é decorrente do projeto de Pesquisa e Desenvolvimento (PD) 001/2020, firmado entre a Fundação da Universidade do Amazonas e FAEPI, que conta com financiamento da Samsung, usando recursos da Lei de Informática para a Amazônia Ocidental (Lei Federal nº 8.387/1991), estando sua divulgação de acordo com o previsto no artigo 39.º do Decreto nº 10.521/2020.

Referências

Banerjee, R., Sinha, A., Pal, A., and Kumar, A. (2013). Estimation of ecg parameters using photoplethysmography. In *13th IEEE International Conference on BioInformatics and BioEngineering*, pages 1–5.

- Berkaya, S. K. et al. (2018). A survey on ecg analysis. *Biomedical Signal Processing and Control*, 43:216–235.
- Chiu, H.-Y., Shuai, H.-H., and Chao, P.-C. (2020). Reconstructing qrs complex from ppg by transformed attentional neural networks. *IEEE Sensors Journal*, 20(10):12374–12383.
- Elgendi, M. et al. (2019). The use of photoplethysmography for assessing hypertension. *npj Digital Medicine*, 6(Volume 2).
- Karlen, W., Raman, S., Ansermino, J. M., and Dumont, G. A. (2013). Multiparameter respiratory rate estimation from the photoplethysmogram. *IEEE transactions on biomedical engineering*, 60(7):1946–1953.
- Liang, Y., Chen, Z., Ward, R., and Elgendi, M. (2018). Hypertension assessment via ecg and ppg signals: An evaluation using mimic database. *Diagnostics*, 8(3):65.
- Organization, W. H. (2021). *World health statistics 2020: monitoring health for the SDGs, sustainable development goals*. World Health Organization, Geneva, Switzerland.
- Pimentel, M. A., Clifton, D. A., and Clifton, L. (2017). Toward a robust estimation of respiratory rate from pulse oximeters. *IEEE Transactions on Biomedical Engineering*, 64(8):1914–1923.
- Ravichandran, V., Murugesan, B., Shankaranarayana, S. M., Ram, K., S.P., P., Joseph, J., and Sivaprakasam, M. (2019). Deep network for capacitive ecg denoising. In *2019 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, pages 1–6.
- Reiss, A., Indlekofer, I., Schmidt, P., and Van Laerhoven, K. (2019). Deep ppg: Large-scale heart rate estimation with convolutional neural networks. *Sensors*, 19(14):3079.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Lecture Notes in Computer Science*, pages 234–241. Springer International Publishing.
- Sarkar, P. and Etemad, A. (2020). Cardiogan: Attentive generative adversarial network with dual discriminators for synthesis of ecg from ppg. In *AAAI Conference on Artificial Intelligence*.
- Schmidt, P., Reiss, A., Duerichen, R., Marberger, C., and Van Laerhoven, K. (2018). Introducing wesad, a multimodal dataset for wearable stress and affect detection. In *Proceedings of the 20th ACM International Conference on Multimodal Interaction*, pages 400–408. ACM.
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, AAAI'17*, page 4278–4284. AAAI Press.
- Tian, X., Zhu, Q., Li, Y., and Wu, M. (2020). Cross-domain joint dictionary learning for ecg reconstruction from ppg. In *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*.
- Zhu, Q., Tian, X., Wong, C.-W., and Wu, M. (2019). Ecg reconstruction via ppg: A pilot study. In *2019 IEEE EMBS International Conference on Biomedical Health Informatics (BHI)*, pages 1–4.