

Detecção de Anomalias em Frequências Cardíacas Utilizando Autocodificadores para Identificação Precoce de COVID-19

Thayná Rosa Silvestre, Eulanda Miranda dos Santos,
Rafael Albuquerque Pinto, Lucas Gabriel Coimbra Evangelista

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

{thayna.rosa, emsantos}@icomput.ufam.edu.br

{rafael.albuquerque, lucas.evangelista}@icomput.ufam.edu.br

Abstract. *The SARS-CoV-2 virus that causes the coronavirus disease has already been transmitted around the world for more than two years, in addition to its many mutations. Among different ways to test whether a person is infected, anomaly detection based on signals such as resting heart rate, which are collected using wearable devices, are investigated as an alternative to identify COVID-19 in its pre-symptomatic phase. There are some studies in the literature that have already demonstrated different techniques to detect these anomalies even with limited data representing this problem. In this work we investigate whether Autocodificadores designed with convolution layers are effective on detecting COVID-19 before the onset of symptoms. Our experiments are conducted using a public database composed by resting heart rate signals from 25 people infected with the virus.*

Resumo. *O vírus SARS-CoV-2 que causa a doença do coronavírus já está há mais de dois anos sendo transmitido pelo mundo, além de suas muitas mutações. Dentre as diversas maneiras de testar se uma pessoa está infectada, a detecção de anomalias em sinais vitais coletados por dispositivos vestíveis são investigados como uma alternativa para identificar COVID-19 em sua fase pré-sintomática. Alguns estudos demonstram diferentes técnicas empregadas para detectar tais anomalias, apesar de haver dados limitados sobre o problema. Neste trabalho, nós utilizamos Autocodificadores com camadas de convolução em dados de frequência cardíaca de pessoas infectadas pelo coronavírus a fim de identificar anomalias antes do início dos sintomas. Foi utilizada uma base de dados pública com dados de 25 pessoas infectadas com o vírus.*

1. Introdução

A detecção da COVID-19 causada pelo coronavírus é uma parte essencial para reduzir o número de pessoas contaminadas. No entanto, a testagem geralmente é feita após o aparecimento dos sintomas, quando surgem as suspeitas. Desse modo, uma pessoa infectada pode transmitir o vírus para muitas pessoas no intervalo de tempo entre o contágio e o início dos sintomas. Sendo assim, uma abordagem de detecção precoce da doença preenche uma lacuna importante na busca por soluções que favoreçam a diminuição dos casos de infecção.

Uma maneira de realizar a detecção precoce baseia-se no monitoramento de dados coletados por dispositivos móveis, os quais coletam constantemente sinais vitais de seus usuários, tais como frequência cardíaca, quantidade de passos, horas de sono, entre outros [Dunn et al. 2021]. Como [Mishra et al. 2020], [Alavi et al. 2022] e [Bogu and Snyder 2021] demonstraram, é possível identificar anomalias em sinais de frequência cardíaca antes do aparecimento dos sintomas. Dessa forma, pode-se alertar o usuário sobre uma possível infecção para encaminhá-lo para testagem e, quando necessário, iniciar o isolamento social.

Neste artigo, será apresentada uma técnica de detecção de anomalias que utiliza redes neurais profundas, mais especificamente um modelo chamado de Autocodificador (*Autocodificador*) com camadas de convolução de uma dimensão (1D). O modelo proposto é comparado a um trabalho existente que utiliza um Autocodificador com camadas de *Long short-term memory* (LSTM).

O restante do artigo está estruturado da seguinte maneira. Na Seção 2, são apresentados os trabalhos relacionados. Na Seção 3, é descrita a base de dados utilizada para alcançar os resultados. Em seguida, na Seção 4, será descrita a metodologia utilizada, enquanto que na Seção 5 são descritos os experimentos e apresentados os resultados. Por fim, na Seção 6 são apresentadas as considerações obtidas e a descrição dos possíveis trabalhos futuros da pesquisa.

2. Trabalhos Relacionados

Em [Mishra et al. 2020], os autores demonstraram que é possível utilizar dados de usuários de *smartwatches* para detecção pré-sintomática de infecções, incluindo COVID-19. Os resultados obtidos mostraram que 63% dos casos poderiam ter sido detectados antes do início dos sintomas em tempo real através do uso de um sistema de alerta utilizando o algoritmo estatístico *CuSum online detection*, o qual baseia-se na ocorrência de elevações extremas da frequência cardíaca em repouso em relação à linha de base individual de um usuário. Essa detecção é baseada em estatísticas cumulativas que monitoram os desvios dos batimentos cardíacos em repouso.

Seguindo a mesma linha, em [Alavi et al. 2022] três algoritmos estatísticos, incluindo o *CuSum online detection*, foram testados para detectar e rastrear alterações nos batimentos cardíacos em repouso devido à infecções, como a COVID-19, por exemplo. Esse trabalho confirmou que a análise de sinais de *smartwatch* por um algoritmo de detecção fornece aviso prévio de infecção por SARS-CoV-2 em uma alta porcentagem de casos. Os autores obtiveram média de 3,42 dias por pessoa de alerta pré-sintomático ao monitorar os batimentos cardíacos dos pacientes. Entretanto, eles também observaram que eventos não associados à infecção, como estresse, consumo de álcool, viagens, exercícios intensos, dentre outras atividades, podem desencadear alertas de anomalias, ocasionando muitas falsas detecções.

Diferentemente dos dois trabalhos anteriores que utilizaram testes estatísticos, em [Bogu and Snyder 2021] é proposto um modelo de aprendizagem profunda chamado (Long Short-Term Memory Networks-based Autocodificador)(LAAD). Esse modelo é composto por Autocodificador com camadas LSTM e aprende a reconstruir séries temporais baseado nos dados de treino, os quais são considerados como “normais”. O modelo define um limiar calculando o erro de reconstrução médio obtido durante o trei-

namento. Então, ao reconstruir os dados de teste, todo novo erro de reconstrução que ultrapassar esse limiar é considerado uma anomalia.

As séries-temporais em questão são valores de frequência cardíaca medida nos momentos em que a pessoa está em repouso. As séries foram divididas em treino e teste com base no início dos sintomas reportado pelos próprios usuários dos dispositivos vestíveis. Com esse modelo, dentre os 25 usuários classificados como infectados por COVID-19, foi possível identificar anomalias antes do início dos sintomas em 14 pessoas e depois do início dos sintomas em 9 pessoas. O modelo falhou em detectar anomalias em 2 dos participantes.

O modelo proposto em [Bogu and Snyder 2021] é o *baseline* do nosso trabalho. Enquanto o LAAD é composto por camadas LSTM, nós empregamos um Autocodificador formado por camadas de convolução, conforme descrito na Seção 4, como alternativa para tentar melhorar o desempenho do modelo.

3. Base de Dados

Neste artigo foi utilizada a mesma base de dados pública de [Bogu and Snyder 2021]. Esta base é composta por 25 participantes que testaram positivo para COVID-19 e registraram a data de início dos sintomas da doença. Para garantir o anonimato, cada um dos participantes foi identificado como uma sequência de caracteres e dígitos. Os dados disponibilizados correspondem à frequência cardíaca, quantidade de passos e horas de sono. Porém, neste trabalho foram utilizados somente os dois primeiros dados, pois, desse modo, é possível definir os valores da frequência cardíaca em repouso de um participante, os quais correspondem aos instantes em que a quantidade de passos permanece igual a 0 ao longo de 12 minutos.

Como não existem rótulos bem estabelecidos do que é ou não uma anomalia na base de dados, todo o intervalo entre 7 dias antes dos sintomas e 21 dias depois dos sintomas foi rotulado como anômalo. Esse intervalo foi definido com base na literatura atual para o valor médio dos dias de transmissão do vírus. A Figura 1 mostra um exemplo de uma instância da base de dados. A linha tracejada vermelha indica o início dos sintomas, a amarela corresponde a 7 dias antes do início dos sintomas, enquanto a linha roxa a 21 dias depois do início dos sintomas.




Figura 1. Exemplo de uma instância da base dados.

É importante observar que, visto que as informações do início dos sintomas foram relatadas pelos próprios usuários, é possível que existam datas relatadas erroneamente.

Portanto, essa situação pode gerar uma certa dificuldade em definir por definitivo em quais dias se espera encontrar ou não anomalias.

A série temporal de cada participante é dividida em dados de treino e de teste da seguinte forma. Todos os dados pertencentes ao intervalo que corresponde ao início da coleta dos dados até 21 dias antes do início dos sintomas compõem a base de treino. Espera-se que os dados da frequência cardíaca em repouso nesse período sejam normais e que um modelo possa aprender a reconstruir as séries temporais a partir desse padrão. Após separar os dados do treino, o restante da série compõe a base de teste. Portanto, deve ser treinado um modelo de detecção de anomalia para cada participante.

4. Metodologia

Conforme mencionado na Seção 2, o modelo utilizado neste trabalho é baseado no modelo proposto em [Bogu and Snyder 2021], que está disponível publicamente¹. O modelo de [Bogu and Snyder 2021] é um Autocodificador formado por camadas LSTM, o qual obteve resultados promissores, porém, com possibilidade de melhorias. Dado que alguns trabalhos que tratam de detecção de anomalias em séries temporais, como por exemplo [Gopali et al. 2021], indicam que Autocodificadores baseados em camadas de convolução superam camadas LSTM em termos de detecção de anomalia, neste trabalho nós substituímos as camadas LSTM do modelo de [Bogu and Snyder 2021] por camadas de convolução 1D.

A arquitetura do nosso modelo pode ser observada na Figura 2. Trata-se de um Autocodificador cujo codificador é composto por duas camadas de Convolução 1D e uma de *Dropout*, enquanto o decodificador é formado por três camadas de Convolução 1D Transposta e uma camada de *Dropout*. A função de ativação para todas as camadas, com exceção da última, é a ReLU (*Rectified Linear Unit*). Por fim, o otimizador Adam é utilizado com taxa de aprendizado 0,001.

Para garantir a comparação dos nossos resultados com os já existentes para essa base de dados, nós aplicamos o mesmo pré-processamento e técnicas de aumento de dados apresentados em [Bogu and Snyder 2021]. Primeiramente, os dados de treino e de teste são normalizados separadamente com média 0 e variância igual a 1. Em seguida, um janelamento com tamanho igual a 8 é executado. Esse passo indica quantos *time-lags* são processados pelo modelo que classifica a entrada como anomalia ou não. Por fim, foram aplicadas as seguintes 7 técnicas de aumento de dados: *Scaling*, *Rotations*, *Permutation*, *Magnitude-warping*, *Time-warping*, *Window-warping*, *Window-slicing*.

5. Experimentos e Resultados

Nós descrevemos nesta seção detalhes sobre as métricas de avaliação empregadas em nossos experimentos. Em seguida, os resultados dos experimentos são apresentados e discutidos.

5.1. Métricas de Avaliação

As métricas de avaliação utilizadas neste trabalho são precisão, revocação, F1-Score e uma métrica que considera o momento em que o modelo faz a primeira detecção de anomalia. As três primeiras métricas são descritas a seguir.

¹https://keras.io/examples/timeseries/timeseries_anomaly_detection/

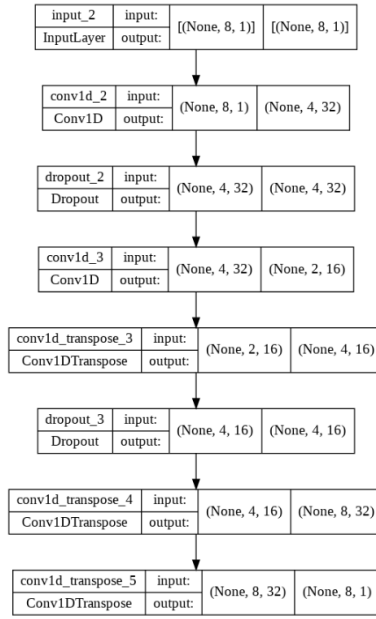


Figura 2. Arquitetura do modelo Autocodificador com camadas de Convolação 1D.

$$Precis\tilde{a}o = \frac{TP}{TP + FP} \quad (1)$$

$$Revoca\tilde{c}\tilde{a}o = \frac{TP}{TP + FN} \quad (2)$$

$$F1-Score = 2 \times \frac{Precis\tilde{a}o \times Revoca\tilde{c}\tilde{a}o}{Precis\tilde{a}o + Revoca\tilde{c}\tilde{a}o} \quad (3)$$

Nas equa\c{c}\~{o}es acima, verdadeiros positivos (TP) s\~{a}o as anomalias encontradas que est\~{a}o corretamente identificadas como anomalias. Falsos negativos (FN) s\~{a}o as anomalias que est\~{a}o incorretamente identificadas como normais. Falsos positivos (FP) s\~{a}o os pontos normais que s\~{a}o incorretamente identificados como anomalias. Enquanto os verdadeiros negativos (TN) s\~{a}o pontos normais que est\~{a}o corretamente identificados como normais. Conforme descrito na Se\c{c}\~{a}o 3, todos os dados no intervalo entre 7 dias antes dos sintomas e 21 dias depois foram rotulados como an\~{o}malos. Devido a isso, a m\~{e}trica de revoca\c{c}\~{a}o retorna valores muito baixos para a maioria dos participantes, pois, toda vez que um ponto \~{e} classificado como normal no intervalo de transmiss\~{a}o do v\~{i}rus, esse ponto ser\~{a} um falso negativo. Consequentemente, a m\~{e}trica F1-Score tamb\~{e}m \~{e} comprometida.

\~{E} importante citar uma falha na m\~{e}trica de precis\~{a}o que torna-a pouco conclusiva para avalia\c{c}\~{a}o. Um participante, no qual os modelos identificaram apenas uma janela detectada como an\~{o}mala, teve uma precis\~{a}o igual a 1 pois essa anomalia detectada era um verdadeiro positivo e n\~{a}o houveram falsos positivos. A precis\~{a}o desse participante foi maior que a de outros participantes que tiveram v\~{a}rias detec\c{c}\~{o}es de verdadeiros positivos, e por isso a precis\~{a}o n\~{a}o \~{e} uma m\~{e}trica justa para avaliar todos os participantes.

Devido a essa situa\c{c}\~{a}o, n\~{o}s tamb\~{e}m inclu\~{i}mos uma m\~{e}trica de avalia\c{c}\~{a}o baseada no momento inicial em que uma anomalia \~{e} detectada, ou seja, n\~{o}s verificamos o dia em

que a primeira anomalia é detectada. Essa métrica mede a capacidade de detecção pré-sintomática do modelo, pois, se a primeira detecção de anomalia ocorrer antes do período de sintomas da doença, considera-se que a existência da anomalia indica precocemente o contágio por COVID-19.

5.2. Comparação de Resultados

A Tabela 1 compara os resultados obtidos com os dois modelos de Autocodificador investigados neste trabalho. É importante mencionar que os resultados apresentados nessa tabela foram obtidos por meio do cálculo da média das métricas entre os 25 participantes incluídos na base de dados. Portanto, em relação à métrica que indica o dia da primeira detecção de anomalia, a média de todos os participantes é calculada para representar com quantos dias de antecipação em média o modelo é capaz de detectar COVID-19. O melhor valor de cada métrica está destacado em negrito.

Modelo	Precisão	Revocação	F1-Score	Dia da detecção
LSTM	0,91	0,36	0,79	1º dia sintomático
Convolução 1D	0,88	0,4	0,83	2 dias antes dos sintomas

Tabela 1. Comparação entre as médias das métricas obtidas pelo Autocodificador com camadas de Convolução 1D e com camadas LSTM.

A tabela mostra que a troca das camadas de LSTM por camadas de Convolução 1D ajudou a melhorar ligeiramente as métricas de Revocação e F1-Score. Além disso, considerando que o principal objetivo deste trabalho é apresentar um modelo que seja capaz de identificar uma anomalia antecedendo o início dos sintomas da COVID-19, o modelo baseado em Convolução 1D conseguiu superar o modelo baseado em LSTM. O Autocodificador baseado em LSTM identificou a anomalia em média no primeiro dia do aparecimento dos sintomas, enquanto o Autocodificador baseado em camadas de Convolução identificou anomalias em média dois dias antes do aparecimento dos sintomas, ou seja, ainda na fase pré-sintomática.

Considerando os participantes de forma individual, ambos os métodos obtiveram resultados semelhantes em termos de detecção pré e pós-sintomática. Dentre os 25 participantes, foram detectadas anomalias em 14 participantes antes do início dos sintomas. Para 9 participantes as anomalias foram detectadas após o início dos sintomas e, por fim, nenhuma anomalia foi detectada para 2 participantes. Porém, dentre os 14 participantes que tiveram detecção pré-sintomática, a média de dias de detecção antecipada foi de 5 dias antes do início dos sintomas para o modelo LAAD e de 6 dias antes do início dos sintomas para o Autocodificador baseado em camadas de convolução. Portanto, o nosso modelo detectou as anomalias com maior antecedência.

Nós acreditamos que o nosso método obteve melhor resultado em termos de detecção pré-sintomática devido ao fato de prover erros de reconstrução que possibilitam predições mais precisas. Por exemplo, a Figura 3 mostra as predições feitas pelo Autocodificador com camadas de Convolução 1D para o paciente A0VFT1N. Os pontos em azul indicam predição normal, enquanto os pontos em vermelho indicam predição de anomalia (quando o valor do erro de reconstrução ultrapassa o limiar - linha horizontal na cor cinza e tracejada). É possível observar um aumento significativo do erro de reconstrução




Figura 3. Predições do Autocodificador baseado em camadas de Convolução para o participante A0VFT1N.




Figura 4. Predições do Autocodificador baseado em camadas de LSTM para o participante A0VFT1N.

nos dias que antecedem os sintomas (antes da linha vertical na cor vermelha). Como consequência, o nosso modelo identificou anomalias nesse período pré-sintomático.

O mesmo não ocorre com o Autocodificador com camadas LSTM, como pode ser visto no Figura 4. O comportamento exibido pelo erro de reconstrução nesse caso é muito mais irregular. Especialmente nos 7 dias que antecedem os sintomas (intervalo entre as linhas verticais amarela e vermelha), os valores de erro de reconstrução ficaram bem abaixo do limiar. Esse comportamento ocasionou uma detecção de anomalia somente no período sintomático (ponto vermelho na figura).

6. Conclusão

Neste trabalho nós empregamos um Autocodificador formado por camadas de convolução como alternativa para tentar melhorar o desempenho de um modelo de Autocodificador composto por camadas LSTM na detecção de COVID-19 como uma tarefa de detecção de anomalias em dados de frequência cardíaca em repouso de um grupo de pessoas. Os resultados mostraram que o modelo proposto obteve resultados parecidos com o modelo já existente em termos de precisão, revocação e F1-score, como pode ser observado na Tabela 1. Porém, o nosso modelo conseguiu detectar as anomalias em média dois dias antes dos sintomas, superando o modelo existente no quesito de detecção pré-sintomática.

É importante mencionar que ambos os modelos detectaram anomalias na fase pré-sintomática em dados de apenas 14 participantes, dentre os 25 que compõem a base de dados. As causas para a não detecção de anomalias podem ser variadas, sendo necessário observar mais informações sobre cada participante para possibilitar um estudo mais aprofundado desse problema.

Para trabalhos futuros poderiam ser elaborados experimentos com bases de dados que incluam pessoas vacinadas, pois a base de dados investigada neste trabalho contém dados anteriores ao surgimento das vacinas. Dessa forma, seria possível fazer uma análise sobre a eficiência do método proposto em dados de pessoas vacinadas e até mesmo em dados de pessoas que apresentaram a doença mais de uma vez, pois, essas informações poderiam contribuir com a detecção.

7. Agradecimentos

Este artigo foi produzido no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), que foi financiada pela Samsung Eletrônica da Amazônia Ltda., nos termos da Lei Federal nº 8.387 / 1991, através do convênio 001/2020, firmado com a Universidade Federal do Amazonas e a FAEPI, Brasil.

Referências

- Alavi, A., Bogu, G. K., Wang, M., Rangan, E. S., Brooks, A. W., Wang, Q., Higgs, E., Celli, A., Mishra, T., Metwally, A. A., Cha, K., Knowles, P., Alavi, A. A., Bhasin, R., Panchamukhi, S., Celis, D., Aditya, T., Honkala, A., Rolnik, B., Hunting, E., Dagan-Rosenfeld, O., Chauhan, A., Li, J. W., Bejikian, C., Krishnan, V., McGuire, L., Li, X., Bahmani, A., and Snyder, M. P. (2022). Real-time alerting system for covid-19 and other stress events using wearable data. *Nature Medicine*.
- Bogu, G. K. and Snyder, M. P. (2021). Deep learning-based detection of covid-19 using wearables data. *medRxiv*.
- Dunn, J., Kidzinski, L., Runge, R., Witt, D., Hicks, J. L., Rose, S.-F., Miryam, S., Li, X., Bahmani, A., Delp, S. L., Hastie, T., and Snyder, M. P. (2021). Wearable sensors enable personalized predictions of clinical laboratory measurements. *Nature Medicine*.
- Gopali, S., Abri, F., Siami-Namini, S., and Namin, A. S. (2021). A comparative study of detecting anomalies in time series data using LSTM and TCN models. *CoRR*, abs/2112.09293.
- Mishra, T., Wang, M., Metwally, A. A., Bogu, G. K., Brooks, A. W., Bahmani, A., Alavi, A., Celli, A., Higgs, E., Dagan-Rosenfeld, O., Fay, B., Kirkpatrick, S., Kellogg, R., Gibson, M., Wang, T., Hunting, E. M., Mamic, P., Ganz, A. B., Rolnik, B., Li, X., and Snyder, M. P. (2020). Pre-symptomatic detection of covid-19 from smartwatch data. *Nature Biomedical Engineering*.