

Aplicação de métodos de aprendizado de máquina não-supervisionado em dados de metilação de DNA de pacientes de COVID-19

Palavras-chave: bioinformática, metilação de DNA, aprendizado de máquina não supervisionado, métodos de agrupamento, COVID-19, EWAS.

Autores

Guilherme Pereira de Freitas - Universidade Estadual de Campinas
Profa. Samara Flamini Kiihl - Universidade Estadual de Campinas

1 Introdução

Estudos recentes vêm demonstrando a importância da metilação de DNA, um marcador epigenético importante, na regulação da expressão gênica. Métodos de agrupamento ou de aprendizado de máquina não-supervisionado são utilizados para extrair informações para diagnóstico precoce e tratamentos a partir de dados de alta dimensão dos estudos epigênicos. Neste projeto, iremos aplicar métodos de agrupamento em dados de metilação de DNA de 407 pacientes de COVID-19, onde 194 (47.7%) desses foram diagnosticados com sintomas leves e 213 (52.3%) com sintomas severos, com o objetivo de encontrar grupos que podem ter sido formados por influência dessa doença.

Embora todas as células de um organismo apresentem, essencialmente, o mesmo conteúdo genético, suas funções e particularidades se dão por meio do regulamento da expressão gênica. Tal regulamento ocorre por meio de mecanismos epigenéticos, como a metilação do DNA, modificação de histonas e outros processos mediados por RNA, que influenciam principalmente a expressão gênica a nível de transcrição [1].

O mecanismo estudado é a metilação da citosina (5mC), que ocorre em áreas específicas de regulação, como regiões promotoras ou de heterocromatina. Esse fenômeno pode modificar, significativamente, a expressão temporal e espacial dos genes e a remodelação da cromatina [2]. Em mamíferos, as citosinas metiladas estão restritas às CpGs (citosina-fosfato-guanina), onde as mesmas antecedem uma guanina (G) na direção de 5'. Vale lembrar que o DNA é formado por 4 bases nitrogenadas e portanto existem 16 possibilidades de se formar um par em sequência, o que ajuda a identificar as ilhas CpGs, pois estas apresentam uma frequência maior desse par (CG) quando comparadas com outras regiões arbitrárias.

2 Banco de dados

O banco de dados utilizado foi retirado do estudo de associação epigenômica ampla (EWS - *epigenome-wide association study*) de COVID-19 [3]. Os dados estão disponíveis no repositório público *The Gene Expression Omnibus* (GEO), sob código de acesso GSE168739. Trata-se de 407 pacientes de COVID-19 sem comorbidades e com idade máxima de 61 anos, onde 194 (47.7%) foram diagnosticados com sintomas leves e 213 (52.3%) com sintomas graves. Os dados foram coletados através da plataforma *Infinium MethylationEPIC BeadChip*, totalizando em aproximadamente 850 mil sítios CpGs para cada indivíduo.

3 Pré-processamento

O fluxo de pré-processamento foi feito seguindo o passo a passo descrito no artigo "A cross-package Bioconductor workflow for analysing methylation array data" [4], por meio das ferramentas dispostas no pacote Bioconductor [5], disponíveis para a linguagem R [6].

Sem entrar em muitos detalhes, as etapas de pré-processamento consistiram em remover amostras de baixa qualidade, aplicar a normalização quantílica [7] e remover sondas de CpGs referentes ao sexo do paciente e/ou com reatividade cruzada [8].

Devido a limitações computacionais para realizar as etapas de pré-processamento, esse trabalho usou recursos do Centro Nacional de Processamento de Alto Desempenho em São Paulo (CENAPAD-SP). Todos os códigos do projeto podem ser acessados no repositório dessa pesquisa presente no GitHub [9].

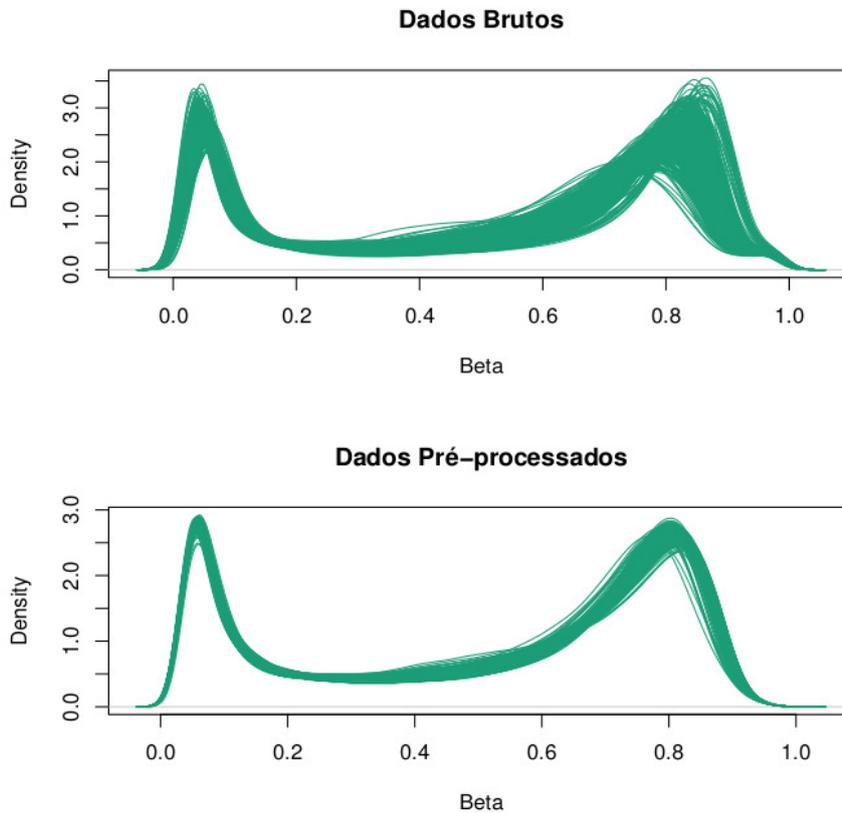


Figura 1: Densidade das taxas de metilação antes e depois do pré-processamento

Na Figura 1, é possível ver que o pré-processamento uniformizou as densidades dos betas de cada um dos indivíduos. Portanto, temos mais confiança para dizer que os efeitos de laboratório e da coleta de dados foram reduzidos e terão menos impacto em nossas análises.

4 Metodologia

O aprendizado de máquina não-supervisionado também é conhecido como análise de cluster, ou análise de agrupamento. Uma das maiores diferenças entre aprendizado de máquina supervisionado e não-supervisionado está na falta de dados de treinamento para a última, bem como a falta de um target para tal. Os pré-requisitos para aplicar as técnicas de agrupamento se dão na escolha das variáveis, hiperparâmetros e tipo de distância adotada [10].

Com a matriz final dos betas pré-processados, podemos calcular a matriz de dissimilaridade entre os indivíduos por meio da distância euclidiana, dada pela fórmula

$$D(X, Y) = \sqrt{\sum_i^n (x_i - y_i)^2},$$

onde n é o número total de CpGs e X e Y são os vetores de betas de dois indivíduos. Cada um dos métodos foi aplicado na matriz de distâncias completa e em duas componentes obtidas através do método Uniform Manifold Approximation and Projection (UMAP) [11].

Para avaliar a formação de clusters, em cada um dos métodos, utilizou-se as técnicas de Silhueta [12] e Gráfico de Elbow. [13].

- Silhueta: Dado um conjunto de clusters Λ , temos que a silhueta da observação i presente no cluster λ_k é dada por $s_{i\lambda_k} = \frac{b_i - a_i}{\max(b_i, a_i)}$, onde a_i é a dissimilaridade de i com relação aos elementos do cluster λ_k (que o contém) e b_i é a menor dissimilaridade de i com relação aos elementos de outro cluster λ , ou seja, $b_i = \min_{\lambda \neq \lambda_k} d(i, \lambda)$.

- Método de Elbow: O Método de Elbow é uma curva construída a partir da Soma de Quadrados Intra-cluster, ou inércia, cuja fórmula é dada por $WSS = \sum_{k=1}^K \sum_{i \in S_k} \sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2$. O melhor número de clusters é obtido no ponto de maior inclinação da curva.

Os métodos de agrupamento utilizados foram K-Médias [14], PAM - Partition Around Medoids [15], Agrupamento Hierárquico [16] e Agrupamentos Baseados em Modelos [17].

5 Resultados

Diferentes matrizes de dissimilaridade foram submetidas em cada um dos métodos comentados anteriormente, com o objetivo de verificar se existem dois grupos significativos possivelmente formados por efeito da Covid-19. Em cada um dos gráficos, os clusters (grupos) encontrados são representados por diferentes cores, sendo amarelo e preto nas duas primeiras figuras e vermelho e azul na última.

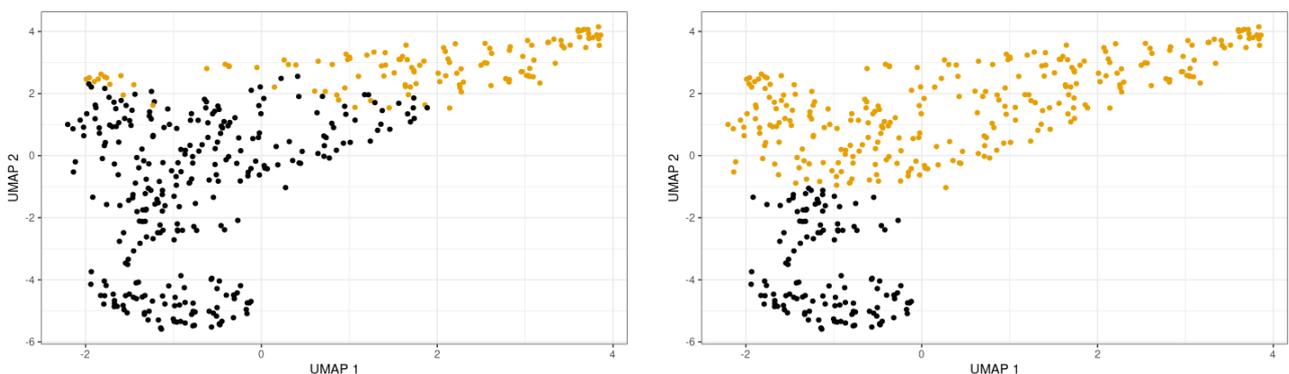


Figura 2: K-Médias: Agrupamentos encontrados através da matriz de distâncias completa (à esquerda) e através da matriz de distâncias das componentes UMAP (à direita). Em ambos os gráficos foram utilizadas as componentes do UMAP para gerar as visualizações.

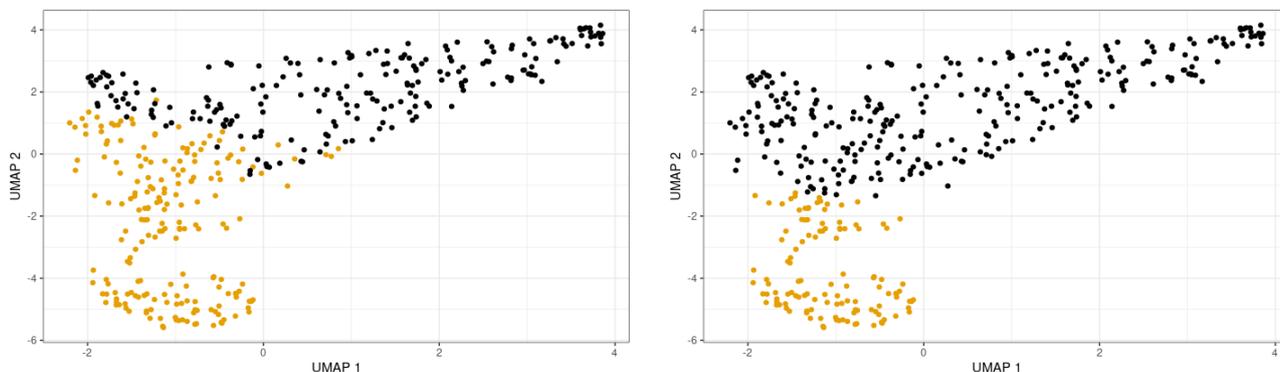


Figura 3: PAM: Agrupamentos encontrados através da matriz de distâncias completa (à esquerda) e através da matriz de distâncias das componentes UMAP (à direita). Em ambos os gráficos foram utilizadas as componentes do UMAP para gerar as visualizações.

De forma geral, os algoritmos PAM e K-Médias tiveram performances similares em termos de formação de grupos. Veja que os grupos formados lembram elipses, e por conta disso, pareceu interessante testar agrupamentos por Mistura de Modelos Gaussianos (GMM).

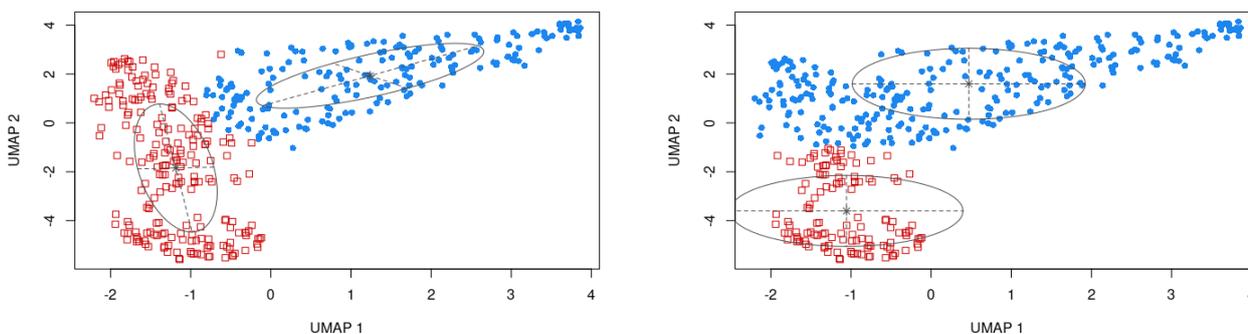


Figura 4: Mistura de Modelos Gaussianos: Agrupamentos encontrados através da matriz de distâncias das componentes UMAP. EVV (à esquerda) e EII (à direita). Em ambos os gráficos foram utilizadas as componentes do UMAP para gerar as visualizações.

6 Conclusão

Através dessa pesquisa, foi possível aprender diversos temas de biologia e bioinformática, bem como aprofundar em conceitos mais complexos de programação e métodos de aprendizado de máquina não-supervisionado.

Foram exploradas diversas técnicas de agrupamentos para cada um dos métodos comentados e as conclusões finais ainda estão sendo escritas e sumarizadas. De forma geral, podemos dizer que, utilizando de todas as CpGs que restaram após a etapa de pré-processamento, não foi possível detectar formação de grupos, pois a métrica da silhueta ficou muito pequena em todas as técnicas. No entanto, o clustering feito nas componentes do UMAP permitiu-nos encontrar 2 grupos significativos, cuja silhueta ficou próxima de 0,5. Devido à falta da indicação acerca da gravidade da COVID-19 no banco de dados utilizado, pois essa informação não foi disponibilizada pelos autores da pesquisa, não podemos checar se os grupos formados podem ter sido decorrentes do grau dessa doença.

Referências

- [1] E R Gibney e C M Nolan. “Epigenetics and gene expression”. Em: *Heredity* 105.1 (mai. de 2010), pp. 4–13. DOI: 10.1038/hdy.2010.54. URL: <https://doi.org/10.1038/hdy.2010.54>.
- [2] Holger Heyn e Manel Esteller. “DNA methylation profiling in the clinic: applications and challenges”. Em: *Nature Reviews Genetics* 13.10 (set. de 2012), pp. 679–692. DOI: 10.1038/nrg3270. URL: <https://doi.org/10.1038/nrg3270>.
- [3] Manuel Castro de Moura et al. “Epigenome-wide association study of COVID-19 severity with respiratory failure”. Em: *EBioMedicine* 66 (abr. de 2021), p. 103339. DOI: 10.1016/j.ebiom.2021.103339. URL: <https://doi.org/10.1016/j.ebiom.2021.103339>.
- [4] Jovana Maksimovic, Belinda Phipson e Alicia Oshlack. “A cross-package Bioconductor workflow for analysing methylation array data”. Em: *F1000Research* 5 (jun. de 2016), p. 1281. DOI: 10.12688/f1000research.8839.1. URL: <https://doi.org/10.12688/f1000research.8839.1>.
- [5] W. Huber et al. “Orchestrating high-throughput genomic analysis with Bioconductor”. Em: *Nature Methods* 12.2 (2015), pp. 115–121. URL: <http://www.nature.com/nmeth/journal/v12/n2/full/nmeth.3252.html>.
- [6] R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria, 2020. URL: <https://www.R-project.org/>.
- [7] Nizar Touleimat e Jörg Tost. “Complete pipeline for Infinium® Human Methylation 450K BeadChip data processing using subset quantile normalization for accurate DNA methylation estimation”. Em: *Epigenomics* 4.3 (jun. de 2012), pp. 325–341. DOI: 10.2217/epi.12.21. URL: <https://doi.org/10.2217/epi.12.21>.
- [8] Yi-an Chen et al. “Discovery of cross-reactive probes and polymorphic CpGs in the Illumina Infinium HumanMethylation450 microarray”. Em: *Epigenetics* 8.2 (fev. de 2013), pp. 203–209. DOI: 10.4161/epi.23470. URL: <https://doi.org/10.4161/epi.23470>.
- [9] Guilherme Freitas. *Projeto de Iniciação Científica*. Fev. de 2022. URL: <https://github.com/GuilhermeFreitas09/IC>.
- [10] R. Gentleman e V. J. Carey. “Unsupervised Machine Learning”. Em: *Bioconductor Case Studies*. Springer New York, 2008, pp. 137–157. DOI: 10.1007/978-0-387-77240-0_10. URL: https://doi.org/10.1007/978-0-387-77240-0_10.
- [11] Leland McInnes, John Healy e James Melville. *UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction*. 2020. arXiv: 1802.03426 [stat.ML].
- [12] Peter J. Rousseeuw. “Silhouettes: a graphical aid to the interpretation and validation of cluster analysis”. Em: (1986).
- [13] Satoru Hayasaka. *How many clusters?* Fev. de 2022. URL: <https://towardsdatascience.com/how-many-clusters-6b3f220f0ef5>.
- [14] S. Lloyd. “Least squares quantization in PCM”. Em: *IEEE Transactions on Information Theory* 28.2 (1982), pp. 129–137. DOI: 10.1109/TIT.1982.1056489.
- [15] Leonard Peter J - Kaufman Rousseeuw. *Finding Groups in Data*. John Wiley Sons, Inc., 2009.
- [16] K V Mardia, J M Bibby e J T Kent. *Multivariate analysis*. 1979, xv, 521 p. : ISBN: 0124712509 0124712525 0124712525. URL: <http://www.loc.gov/catdir/toc/els031/79040922.html>.
- [17] Charles Bouveyron et al. *Model-Based Clustering and Classification for Data Science*. Cambridge University Press, jun. de 2019. DOI: 10.1017/9781108644181. URL: <https://doi.org/10.1017/9781108644181>.