

Universidade de Pernambuco

Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Dissertação de Mestrado

Área: Computação Inteligente ou Modelagem Computacional

Título: Predição de displasia broncopulmonar utilizando modelos de aprendizado de máquina com dados clínicos e de monitoramento de neonatos.

Orientador(a): Patricia Takako Endo (patricia.endo@upe.br)

Descrição:

Segundo o Fundo das Nações Unidas para a Infância (UNICEF), em 2022, ocorreram aproximadamente 2,3 milhões de óbitos no período neonatal no mundo, com 75% dessas mortes na primeira semana (óbito precoce) e os 25% restantes entre 7 e 28 dias de vida (óbito tardio) [1]. No Brasil, foram registrados 32.257 óbitos neonatais em 2022, resultando em uma taxa de 8,47 mortes por cada 1.000 nascidos vivos. Em Pernambuco, a taxa de mortalidade neonatal superou a média nacional, com 9,59 óbitos por cada 1.000 nascidos vivos [2, 3].

A Displasia Broncopulmonar (DBP) é reconhecida como uma das principais causas de mortalidade neonatal, especialmente entre os recém-nascidos prematuros que necessitam de ventilação mecânica prolongada e oxigenoterapia. Além disso, contribui diretamente para as taxas de óbitos neonatais, particularmente nas Unidades de Terapia Intensiva Neonatal (UTIN). Estudos indicam que a DBP é um importante fator de risco para complicações respiratórias crônicas, hospitalizações frequentes e prolongadas, crescimento pômbero-estatural comprometido e atrasos no desenvolvimento neuropsicomotor. Portanto, a DBP não só impacta diretamente as taxas de mortalidade neonatal, mas também representa um desafio contínuo para a saúde pública e os cuidados pediátricos [4, 5, 6].

Tanto a DPB e bimortalidade neonatal são frequentemente associadas a condições passíveis de prevenção, dada que sejam situações evitáveis que configuraram-se como problemas de saúde pública, influenciada por fatores socioeconômicos, tais como baixa renda, baixa escolaridade, ausência de saneamento básico, entre outros [7, 8, 9, 10]. Além disso, a falta de acesso a serviços de saúde pública e a qualidade da assistência prestada durante o pré-natal, parto e os primeiros dias de vida do neonato contribuem para a vulnerabilidade nesse período.

A escassez de recursos na área da saúde representa um desafio para regiões menos favorecidas, enfatizando a necessidade de soluções economicamente viáveis. Isso reforça a importância de estudos direcionados à implementação e desenvolvimento de políticas públicas e medidas afirmativas visando à redução das incidências de doenças e morte no período neonatal. Nesse contexto, a literatura destaca os modelos de aprendizado de máquina como instrumentos promissores para colaborar com os profissionais de saúde, fortalecendo a prática clínica e aprimorando a eficácia diagnóstica de diversas enfermidades [11]. Tais modelos têm sido empregados na predição de complicações durante e pós-gestação [12], abrangendo desde pré-eclâmpsia, diabetes gestacional, sepse, morte fetal, prematuridade, até morte neonatal, entre outros agravantes de saúde [13, 14, 15, 16, 17, 18].

O presente tema de pesquisa tem como principal foco o desenvolvimento de uma plataforma baseada em diferentes modelos de aprendizado de máquina com o propósito de prever risco de desenvolvimento de DPB em recém-nascidos, permitindo a intervenção de estratégias preventivas, que possam minimizar o desenvolvimento da condição, bem como planejar os planos de cuidados, garantindo acesso equitativo aos serviços de saúde do Sistema Único de Saúde (SUS) desde os primeiros dias de vida.

Referências Bibliográficas:

[1] UNICEF. United Nations Children's Fund. Levels and trends in child mortality - report 2023. 2024. Acesso em: 03/05/2024. Disponível em: <https://data.unicef.org/resources/levels-and-trends-in-child-mortality-2024/>.

[2] da saúde M. SINASC - Sistema de Informações sobre Nascidos Vivos a Serviço do SUS; 2022. Acesso em: 03/05/2024. Disponível em: <http://tabnet.datasus.gov.br/cgi/defthtm.exe?sinasc/cnv/hvuf.def>.

- [3] da saúde M. SIM - Sistema de Informação sobre Mortalidade a Serviço do SUS; 2022. Acesso em: 03/05/2024. Disponível em: <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?sim/cnv/obt10uf.def>.
- [4] Álvarez-Fuente M, Arruza L, Muro M, et al. The economic impact of prematurity and bronchopulmonary dysplasia. *Eur J Pediatr*. 2017;176(12):1587–1593.
- [5] Abiramalatha, Thangaraj et al. Interventions to prevent bronchopulmonary dysplasia in preterm neonates: an umbrella review of systematic reviews and meta-analyses. *JAMA pediatrics*, v. 176, n. 5, p. 502-516, 2022.
- [6] Homan, Travis D., and Ravi P. Nayak. "Short-and long-term complications of bronchopulmonary dysplasia." *Respiratory care* 66.10 (2021): 1618-1629.
- [7] Silva, Rosane Meire Munhak, et al. "Fatores epidemiológicos correlacionados ao risco para morte fetal: revisão integrativa da literatura." *Arquivos de Ciências da Saúde* 23.2 (2016): 09-15.
- [8] Rebutini, Patricia Zadorosnei, et al. "Association between COVID-19 pregnant women symptoms severity and placental morphologic features." *Frontiers in Immunology* 12 (2021).
- [9] Aminu, Mamuda, Sarah Bar-Zeev, and Nynke van den Broek. "Cause of and factors associated with stillbirth: a systematic review of classification systems." *Acta obstetrica et gynecologica Scandinavica* 96.5 (2017)
- [10] Lawn, Joy E., et al. "Stillbirths: rates, risk factors, and acceleration towards 2030." *The Lancet* 387.10018 (2016): 587-603.
- [11] Henry, C., Saffaran, S., Meeus, M., Bates, D., Van Laere, D., Boylan, G., Boardman, J.P. and Sharkey, D., 2022, October. Application and potential of artificial intelligence in neonatal medicine. In *Seminars in Fetal and Neonatal Medicine*, 2022. WB Saunders.
- [12] Ramakrishnan, Rema, Shishir Rao, and Jian-Rong He. "Perinatal health predictors using artificial intelligence: A review." *Women's Health* 17 (2021): 17455065211046132.
- [13] Shukla, Vivek V., et al. "Predictive modeling for perinatal mortality in resource-limited settings." *JAMA network open* 3.11 (2020): e2026750-e2026750.
- [14] Hoodbhoy, Zahra, et al. "Machine learning from fetal flow waveforms to predict adverse perinatal outcomes: A study protocol." *Gates open research* 2 (2018).
- [15] Mboya, Innocent B., et al. "Prediction of perinatal death using machine learning models: a birth registry-based cohort study in northern Tanzania." *BMJ open* 10.10 (2020): e040132.
- [16] Qureshi, Hammad, et al. "Association of pre-pregnancy weight and weight gain with perinatal mortality." *Proceedings of the 8th International Conference on Frontiers of Information Technology*. 2010.
- [17] Malacova, Eva, et al. "Stillbirth risk prediction using machine learning for a large cohort of births from Western Australia, 1980–2015." *Scientific reports* 10.1 (2020): 1-8.
- [18] Koivu, Aki, and Mikko Sairanen. "Predicting risk of stillbirth and preterm pregnancies with machine learning." *Health information science and systems* 8.1 (2020): 1-12.