

Desenvolvimento de modelo de predição de óbito hospitalar utilizando regressão logística: Um estudo retrospectivo com 16.632 registros de um hospital universitário

Development of a predictive model for in-hospital mortality using logistic regression: A retrospective study of 16,632 records from a university hospital

Desarrollo de un modelo predictivo de mortalidad hospitalaria mediante regresión logística: Un estudio retrospectivo con 16.632 registros de un hospital universitario

Recebido: 27/08/2025 | Revisado: 04/09/2025 | Aceitado: 04/09/2025 | Publicado: 05/09/2025

Adriele da Mota de França Pinto

ORCID: <https://orcid.org/0009-0003-3430-8302>

Universidade Estadual de Ponta Grossa, Brasil

E-mail: adriele080101@gmail.com

Camila Marinelli Martins

ORCID: <https://orcid.org/0000-0002-8425-5769>

Universidade Estadual de Ponta Grossa, Brasil

E-mail: cmmartins@uepg.br

Resumo

Introdução: A mortalidade hospitalar é um indicador que serve como parâmetro para mensurar a efetividade da assistência em saúde, e sua predição pode auxiliar em estratégias e intervenções regionais. **Objetivo:** Desenvolver um modelo preditivo de óbito hospitalar baseado nos dados disponíveis no Sistema de Informações Hospitalares do Sistema Único de Saúde. **Método:** Estudo de coorte retrospectivo, realizado com 16.632 internações de um hospital regional universitário no Paraná, Brasil, entre o período de Maio de 2022 à Maio de 2024. Utilizou-se dados secundários obtidos através dos Relatórios de Internação Hospitalar e Relatórios de Óbitos de Pacientes. As variáveis preditoras foram identificadas pelo modelo de regressão logística multivariado, ajustado a partir do método stepwise backward elimination. **Resultados:** Foram desenvolvidos dois modelos de predição, sendo o primeiro ajustado por todas as variáveis analisadas e o segundo ajustado para interações entre as variáveis Setor e Tempo de internamento. Ambos identificaram como variáveis preditoras de óbito a faixa etária de 60 a 79 anos e 80 anos ou mais; internamento em UTI, e o tempo de internamento de 15 dias ou mais. **Conclusão:** Foram desenvolvidos dois modelos preditivos de óbito hospitalar, os quais podem contribuir para o aprimoramento da gestão clínica e assistencial.

Palavras-chave: Mortalidade Hospitalar; Modelos Logísticos; Monitoramento Epidemiológico.

Abstract

Introduction: Hospital mortality is an indicator used to measure the effectiveness of healthcare delivery, and its prediction may support regional strategies and interventions. **Objective:** To develop a predictive model of hospital mortality based on data available from the Hospital Information System of the Brazilian Unified Health System. **Method:** A retrospective cohort study was conducted with 16,632 hospitalizations from a regional university hospital in Paraná, Brazil, between May 2022 and May 2024. Secondary data were obtained from Hospitalization Reports and Patient Death Reports. Predictive variables were identified using a multivariate logistic regression model, adjusted through the stepwise backward elimination method. **Results:** Two predictive models were developed: the first adjusted for all analyzed variables, and the second adjusted for interactions between the variables "Hospital Ward" and "Length of Stay." Both models identified the following as predictors of in-hospital death: age groups of 60 to 79 years and 80 years or older, admission to the ICU, and a length of stay of 15 days or more. **Conclusion:** Two predictive models of hospital mortality were developed, which may contribute to improving clinical and care management.

Keywords: Hospital Mortality; Logistic Models; Epidemiological Monitoring.

Resumen

Introducción: La mortalidad hospitalaria es un indicador que sirve como parámetro para medir la efectividad de la atención en salud, y su predicción puede contribuir a estrategias e intervenciones regionales. **Objetivo:** Desarrollar un modelo predictivo de mortalidad hospitalaria basado en los datos disponibles en el Sistema de Información Hospitalaria del Sistema Único de Salud. **Método:** Estudio de cohorte retrospectivo, realizado con 16.632

hospitalizaciones en un hospital regional universitario en Paraná, Brasil, entre mayo de 2022 y mayo de 2024. Se utilizaron datos secundarios obtenidos a través de los Informes de Hospitalización y los Informes de Defunción de Pacientes. Las variables predictoras fueron identificadas mediante un modelo de regresión logística multivariada, ajustado con el método stepwise backward elimination. Resultados: Se desarrollaron dos modelos de predicción: el primero ajustado por todas las variables analizadas y el segundo ajustado para las interacciones entre las variables Sector y Tiempo de hospitalización. Ambos identificaron como variables predictoras de mortalidad la edad de 60 a 79 años y de 80 años o más; hospitalización en UCI, y tiempo de hospitalización de 15 días o más. Conclusión: Se desarrollaron dos modelos predictivos de mortalidad hospitalaria, los cuales pueden contribuir al perfeccionamiento de la gestión clínica y asistencial.

Palabras clave: Mortalidad Hospitalaria; Modelos Logísticos; Monitoreo Epidemiológico.

1. Introdução

A mortalidade hospitalar pode ser interpretada como um importante indicador da efetividade da assistência em saúde (Schilling et al., 2024). Estudos multicêntricos, por exemplo, utilizam análises de mortalidade como indicadores de intervenções com o objetivo de melhorar a estrutura e a qualidade da assistência (Geskey et al., 2022). Parâmetros de morbidade e mortalidade também são frequentemente utilizados na implementação e avaliação de políticas públicas, garantindo a qualidade dos serviços de saúde à população (Okoroiwu et al., 2020).

Nos últimos anos, as análises relacionadas à mortalidade têm se tornado excepcionalmente relevantes a partir das alterações do perfil epidemiológico e variações significativas nas taxas de mortalidade hospitalar (Costa et al., 2022; Walicka et al., 2020). O aumento da frequência de doenças crônicas, o envelhecimento populacional e a incorporação de novas tecnologias nos cuidados em saúde são fatores que podem interferir no tempo de internação hospitalar, risco de readmissão e causas de morte (Costa et al., 2022).

Em estudos com dados de internações em hospitais públicos brasileiros, a taxa de mortalidade hospitalar girou em torno de 13% entre os anos de 2017 à 2019 (Schilling et al., 2024; Cordeiro; Martins, 2018). Já em 2020, durante a pandemia pela doença COVID-19, o perfil dos óbitos mudou consideravelmente, chegando à um excesso de óbito estimado em até 16% (Macedo et al., 2024). A mortalidade também possui influência dos setores hospitalares, já que as taxas de mortalidade nas Unidades de Terapia Intensiva (UTI), por exemplo, podem variar de 9,6% a 58% (Aguir et al., 2021).

Estas mudanças, no entanto, ocorrem de forma divergente entre as regiões do Brasil, já que o país possui acentuadas discrepâncias epidemiológicas e sociodemográficas entre as regiões (Calazans; Guimarães; Nepomuceno, 2023). Desta forma, a análise preditiva da mortalidade e as causas de óbitos em um hospital de referência pode ser uma estratégia para avaliar a eficácia do sistema de saúde local, permitindo auxiliar intervenções regionais na busca de melhor efetividade assistencial (Faro et al., 2021).

Desta forma, o objetivo do presente trabalho foi desenvolver um modelo preditivo de óbito hospitalar baseado nos dados disponíveis no Sistema de Informações Hospitalares do Sistema Único de Saúde.

2. Metodologia

Estudo de coorte retrospectivo, realizado com 16.632 dados obtidos do Relatório de Internação e Óbitos Hospitalares de internações ocorridas em um hospital regional universitário no estado do Paraná, Brasil, entre o período de maio de 2022 à maio de 2024. Realizou-se uma pesquisa mista com pesquisa documental inicial no Sistema de Gestão da Assistência de Saúde do SUS e outra parte de investigação de natureza quantitativa (Pereira et al., 2018), utilizando-se de estatística descritiva com classes de dados e valores de frequência absoluta e de frequência relativa porcentual, com análise estatística (Dutt-Ross, 2020).

O estudo foi aprovado pelo Comitê de Ética em Pesquisa com Seres Humanos, sob o parecer nº

79441124.9.0000.0105 e conduzido de acordo com a ferramenta TRIPOD (Prediction Model Development and Validation) (TRIPOD, 2015).

Foram incluídos pacientes que apresentavam informações de tempo de permanência, desfecho e CID de internação e óbito nos relatórios analisados. Foram excluídos pacientes com idade menor que 18 anos, pacientes com sexo indefinido, internações duplicadas e registros com dados ausentes. Desta forma, dos 38.231 dados obtidos dos relatórios, 16.632 atenderam os critérios de inclusão e exclusão, compondo a amostra final.

A coleta de dados ocorreu no mês de setembro de 2024, por meio da plataforma GSUS® (Sistema de Gestão da Assistência de Saúde do SUS), utilizando-se de dados secundários obtidos através do Relatório de Internação Hospitalar e Relatório de Óbitos de Pacientes. Foram coletados dados de pacientes hospitalizados entre o período de dois anos, ocorridos entre maio de 2022 a maio de 2024. Este período foi definido levando em consideração o encerramento do período de Emergência em Saúde Pública decorrente da infecção humana pelo vírus SARS-Cov-2, ocorrido em maio de 2022 (BRASIL, 2022).

Foram avaliadas as seguintes variáveis: Sexo (feminino e masculino), Faixa etária (18 a 39 anos, 40 a 59 anos, 60 a 79 anos e 80 anos ou mais), Setor de internamento (enfermaria, pronto atendimento e unidade de terapia intensiva - UTI), Tempo de permanência hospitalar (até 4 dias, 5 a 9 dias, 10 a 14 dias e 15 dias ou mais), Capítulo de diagnóstico de internação (Capítulo 9 e 10, Capítulo 11 e 14, Capítulo 19, Capítulo 21 e Demais CID's) e Capítulo de diagnóstico de óbito (Capítulo 1, Capítulo 9 e 10, Capítulo 11 e 14, Capítulo 18 e Demais CID's), tidas como variáveis independentes. O Desfecho (óbito ou alta), foi atribuída como variável dependente.

Entre as categorias da variável Desfecho, foram classificadas como “alta” os desfechos obtidos através dos relatórios categorizados como Alta médica, Alta administrativa, Alta por Transferência, Alta por Pedido do Paciente, Evasão do paciente e Retorno para Ambulatório; já a classificação “óbito” se deu pelo desfecho de Alta por Óbito pelos referidos relatórios. A variável capítulo de diagnóstico de admissão e diagnóstico de óbito foram classificadas de acordo com a décima versão da Classificação Internacional de Doenças (CID-10). Já a variável tempo de permanência hospitalar, expressa em dias, foi definida considerando o dia 1 (D1) como o intervalo compreendido entre o momento da admissão e as 24 horas de internação em qualquer unidade da instituição analisada.

Os dados foram analisados por meio do software R (versão 4.4.0). A análise descritiva foi realizada através de frequências absolutas e relativas, utilizando funções nativas do programa. Para avaliar associações entre variáveis categóricas, foram aplicados o teste Qui-Quadrado e o cálculo do risco relativo (RR), com o auxílio do pacote epitools (Aragon, 2020). Posteriormente, as variáveis preditoras do óbito foram identificadas a partir de um modelo de regressão logística multivariado, ajustado a partir do método stepwise backward elimination quando $p < 0,20$.

O modelo final levou em consideração as interações entre as variáveis. O modelo relatou razões de chances (OR) e intervalos de confiança de 95% (IC95%), ajustados para fatores de confusão. A capacidade prognóstica do modelo foi avaliada conforme gráfico de curva ROC (Receiver Operating Characteristic) com IC95%. Os dados foram considerados estatisticamente significativos quando $p < 0,05$.

3. Resultados

Dos 16.632 pacientes incluídos no estudo, predominaram pacientes do sexo masculino (55,97%), que pertenciam à faixa etária de 40 a 59 anos (30,68%), internados nas enfermarias (74,13%), com um tempo de internamento hospitalar de até 4 dias (51,54%), que tiveram como CID do internamento o Capítulo 21 – Fatores que influenciam o estado de saúde (67,68%) e

que tiveram como desfecho a alta hospitalar (91,86%). Entre os pacientes que evoluíram a óbito, predominou como CID de óbito o Capítulo 9 e 10 – Aparelho circulatório e respiratório (02,84%).

Já entre os pacientes que evoluíram a óbito, predominaram pacientes do sexo feminino (8,40%), com faixa etária pertencente a 80 anos ou mais (26,45%), internados na UTI (57,95%), com tempo de internamento hospitalar de 15 dias ou mais (21,85%) e que tiveram como CID do internamento o Capítulo 9 e 10 – Aparelho circulatório e respiratório (10,54%), segundo exposto na Tabela 1.

O desfecho óbito foi associado às faixas etárias de 40 a 59 anos, 60 a 79 anos e 80 anos ou mais; aos pacientes internados nos setores de pronto atendimento e UTI; ao tempo de internação de 5 a 9 dias, 10 a 14 dias e 15 dias; e aos Capítulos 9 e 10 – Doenças do aparelho circulatório e do aparelho respiratório, bem como os Capítulos 11 e 14 – Doenças do aparelho digestivo e do aparelho geniturinário, conforme demonstrado na Tabela 1.

Foram desenvolvidos dois modelos de regressão logística multivariada: (1) ajustado por todas as variáveis analisadas; e (2) ajustado para interações entre as variáveis Setor e Tempo de internamento, conforme apresentado na Tabela 2. O modelo sem interações apresentou uma área sob a curva ROC (AUC) de 0,9641 (IC95%: 0,9524–0,9758), com uma acurácia de 93,70%. Por sua vez, o modelo com ajuste para interações obteve uma AUC de 0,9646 (IC95%: 0,9525–0,9767) e uma acurácia de 93,42%.

Tabela 1 – Frequência absoluta, relativa, risco relativo e associação entre as características avaliadas e o desfecho óbito entre os pacientes hospitalizados em um hospital regional universitário, Paraná, de maio de 2022 a maio de 2024.

| Variáveis | Total | | Óbito | | Alta | | RR ¹ (IC95%) ² | p-valor |
|-----------------------------------------------------|--------|---------|-------|---------|--------|---------|--------------------------------------|---------|
| | n | (%) | n | (%) | n | (%) | | |
| Sexo | | | | | | | | |
| Feminino | 7.323 | (44,03) | 615 | (8,40) | 6.708 | (91,60) | Referência | |
| Masculino | 9.309 | (55,97) | 738 | (7,93) | 8.571 | (92,07) | 0,94 (0,85; 1,04) | 0,271 |
| Faixa etária | | | | | | | | |
| 18 a 39 anos | 4.943 | (29,72) | 117 | (2,37) | 4.826 | (97,63) | Referência | |
| 40 a 59 anos | 5.103 | (30,68) | 257 | (5,04) | 4.846 | (94,96) | 2,13 (1,72; 2,64) | p<0,001 |
| 60 a 79 anos | 4.949 | (29,76) | 546 | (11,03) | 4.403 | (88,97) | 4,66 (3,83; 5,67) | p<0,001 |
| 80 anos ou mais | 1.637 | (9,84) | 433 | (26,45) | 1.204 | (73,55) | 11,17 (9,18; 13,60) | p<0,001 |
| Setor | | | | | | | | |
| Enfermaria | 12.330 | (74,13) | 281 | (2,28) | 12.049 | (97,72) | Referência | |
| Pronto Atendimento | 2.899 | (17,43) | 259 | (8,94) | 2.640 | (91,06) | 3,84 (3,26; 4,52) | p<0,001 |
| UTI | 1.403 | (8,44) | 813 | (57,95) | 590 | (42,05) | 24,91 (22,03; 28,16) | p<0,001 |
| Tempo de internamento | | | | | | | | |
| Até 4 dias | 8.572 | (51,54) | 434 | (5,06) | 8.138 | (94,94) | Referência | |
| 5 a 9 dias | 4.132 | (24,84) | 270 | (6,53) | 3.862 | (93,47) | 1,29 (1,11; 1,49) | p<0,001 |
| 10 a 14 dias | 1.841 | (11,07) | 193 | (10,48) | 1.648 | (89,52) | 2,07 (1,76; 2,43) | p<0,001 |
| 15 dias ou mais | 2.087 | (12,55) | 456 | (21,85) | 1.631 | (78,15) | 4,32 (3,81; 4,88) | p<0,001 |
| CID do Internamento | | | | | | | | |
| Demais CID's | 1.671 | (10,05) | 154 | (9,22) | 1.517 | (90,78) | Referência | |
| Cap. 9 e 10 – Aparelho circulatório e respiratório | 920 | (5,53) | 97 | (10,54) | 823 | (89,46) | 1,14 (0,90; 1,45) | 0,274 |
| Cap. 11 e 14 – Aparelho digestivo e geniturinário | 1.407 | (8,46) | 60 | (4,26) | 1.347 | (97,74) | 0,46 (0,35; 0,62) | p<0,001 |
| Cap. 19 – Lesões, envenenamentos e causas externas | 1.378 | (8,28) | 40 | (2,90) | 1.338 | (97,10) | 0,31 (0,22; 0,44) | p<0,001 |
| Cap. 21 – Fatores que influenciam o estado de saúde | 11.256 | (67,68) | 1.002 | (8,90) | 10.254 | (91,10) | 0,97 (0,82; 1,13) | 0,679 |

UTI, Unidade de Terapia Intensiva; CID, Classificação Internacional de Doenças; Cap., Capítulo;

¹ RR: Risco Relativo; ² IC95%: Intervalo de confiança de 95%; ³ p-valor: Nível de significância;

*Percentual em relação ao total de indivíduos por categoria de exposição.

Fonte: Autoria própria.

Tabela 2 – Modelos de Regressão Logística Multivariado, Paraná, de maio de 2022 a maio de 2024.

| Variáveis | Desfecho Óbito | | | | | |
|------------------------------------------------------|-----------------|----------------------|----------------------|-----------------|----------------------|----------------------|
| | Modelo 1* | | | Modelo 2* | | |
| | OR ¹ | (IC95%) ² | p-valor ³ | OR ¹ | (IC95%) ² | p-valor ³ |
| Faixa etária | | | | | | |
| 60 a 79 anos | 6,20 | (2,25; 17,04) | p<0,001 | 4,90 | (1,86; 12,86) | 0,001 |
| 80 anos ou mais | 35,92 | (12,25; 105,28) | p<0,001 | 26,66 | (9,33; 76,21) | p<0,001 |
| Setor | | | | | | |
| UTI | 39,23 | (19,87; 77,47) | p<0,001 | 265,27 | (69,38; 1.014,27) | p<0,001 |
| Tempo de internamento | | | | | | |
| 15 dias ou mais | 7,28 | (3,83; 13,84) | p<0,001 | 19,53 | (7,33; 52,06) | p<0,001 |
| CID do Internamento | | | | | | |
| Cap. 19 – Lesões, envenenamentos e causas externas | 0,35 | (0,18; 0,69) | 0,002 | 0,39 | (0,20; 0,74) | 0,004 |
| Interação | | | | | | |
| Setor UTI e Tempo de internamento de 15 dias ou mais | - | - | - | 0,06 | (0,01; 0,30) | p<0,001 |

UTI, Unidade de Terapia Intensiva; CID, Classificação Internacional de Doenças; Cap., Capítulo;

¹ OR: Odds Ratio; ² IC95%: Intervalo de confiança de 95%; ³ p-valor: Nível de significância;

*Modelo 1: modelo ajustado por todas as variáveis analisadas; Modelo 2: modelo ajustado para interações entre as variáveis Setor e Tempo de internamento.

Fonte: Autoria própria.

4. Discussão

Neste estudo, desenvolve-se um modelo preditivo de mortalidade hospitalar baseado nos dados disponíveis no Sistema de Informações Hospitalares do Sistema Único de Saúde. Os preditores associados ao desfecho óbito foram a faixa etária entre 60 e 79 anos, a faixa etária entre 80 anos ou mais, internamento em UTI e tempo de internamento de 15 dias ou mais.

Entre os preditores analisados no presente estudo, a faixa etária destaca-se como um fator já reconhecido em modelos anteriores de predição de mortalidade (Stoessel et al., 2023; Klug et al., 2020; Seki; Kawazoe & Ohe, 2021). A mortalidade é considerada um fator altamente dependente da idade, pois pacientes mais velhos tendem a apresentar múltiplas comorbidades e condições preexistentes, o que pode aumentar a gravidade e piorar o prognóstico clínico do paciente (Walicka et al., 2020; Rai et al., 2023).

O internamento em UTI, bem como a duração da internação igual ou superior a 15 dias, foi identificado como preditores significativos da mortalidade em ambos os modelos analisados neste estudo. Contudo, observou-se um aumento substancial nos coeficientes após a inclusão da interação entre essas variáveis. Esse fenômeno pode ser atribuído à complexidade intrínseca da relação entre a duração da internação, a gravidade do quadro clínico do paciente na UTI e a taxa de mortalidade (Walicka et al., 2020).

O desfecho óbito está associado a uma série de fatores, incluindo a gravidade da doença, comorbidades pré-existentes, tempo de internação e a necessidade de internamento em UTI (Aguiar et al., 2021). Nesse contexto, a relação entre o tempo de internação, o desfecho dos pacientes e o internamento em UTI é relatada de maneira heterogênea nas pesquisas, com evidências sugerindo que a mortalidade pode variar, sendo tanto maior quanto menor, dependendo da duração da internação e das características do setor hospitalar (Rodrigues et al., 2024; Maluangnon; Kanogpotjanant; Tongyoo, 2023).

No estudo de Maluangnon, Kanogpotjanant e Tongyoo (2023), pacientes internados em UTI apresentaram o dobro de mortalidade em 28 dias em comparação com aqueles tratados em enfermarias de clínicas gerais. Por outro lado, a pesquisa de Rodrigues et al. (2024) observou que a mortalidade aumentou progressivamente com a duração da internação na UTI até o 10º dia, permanecendo estável a partir deste ponto. Esses achados ressaltam a influência de fatores como a gravidade da doença e a evolução natural do quadro clínico após o esgotamento das opções terapêuticas, o que contribui para a

complexidade das interações entre essas variáveis (Aguiar et al., 2021; Maluangnon; Kanogpotjanant; Tongyoo, 2023).

Quanto ao preditor Capitulo do CID da internação, embora ainda pouco utilizado em modelos preditivos, possui evidências sugerindo que sua inclusão pode resultar em desempenho superior em comparação a conjuntos tradicionais de comorbidades (Cowling et al., 2021; Cowling et al., 2020). No entanto, é necessário cautela na interpretação desses resultados, uma vez que a baixa frequência de ocorrência entre certos códigos pode limitar seu potencial de interação e, consequentemente, o ganho de desempenho dos modelos (Cowling et al., 2021). Em decorrência dessas limitações, poucos estudos incorporam os códigos CID como variáveis preditoras, o que dificulta a comparação direta com os achados do presente trabalho.

Diversos estudos propuseram modelos de predição de óbito hospitalar aplicados a hospitais públicos ou privados, porém com foco restrito a subgrupos específicos de pacientes, como aqueles com sepse, síndromes respiratórias ou hemorragia intraparenquimatosa (Li et al., 2021; Ding et al., 2024; Valburg et al., 2024; Hydoub et al., 2023). Nesse cenário, o presente estudo se diferencia por considerar a população adulta em geral, ampliando o potencial de aplicação do modelo a uma variedade mais extensa de pacientes hospitalizados (Stoessel et al., 2023).

Ademais, o estudo foca em variáveis de fácil extração a partir de relatórios hospitalares, o que favorece sua aplicação prática e contribui para a economia de recursos humanos e financeiros (Costa et al., 2022; Hydoub et al., 2023). Modelos baseados em múltiplas variáveis podem ter sua usabilidade comprometida quando implementados em contextos clínicos reais, devido às limitações tecnológicas, sistemas de coleta de dados insuficientes e escassez de profissionais capacitados (Hydoub et al., 2023). Nesse sentido, a priorização de variáveis-chave pode prolongar a vida útil do modelo e melhorar sua aplicabilidade em cenários diversos (Costa et al., 2022; Hydoub et al., 2023).

Por fim, os modelos de predição de mortalidade hospitalar podem aprimorar a estratificação de risco dos pacientes, apoiar a tomada de decisões clínicas e otimizar a alocação de recursos financeiros (Walicka et al., 2020). Esses usos potencialmente contribuem para a melhoria da qualidade dos serviços de saúde prestados à população e da assistência individual ao paciente (Chen et al., 2023; Blanes-Selva et al., 2021).

O presente estudo apresenta diversas limitações, como seu caráter retrospectivo, com dados coletados apenas na admissão e no desfecho dos pacientes; ausência de informações sobre a gravidade clínica, exames laboratoriais e comorbidades dos indivíduos analisados; além do fato de que os dados foram provenientes de um único hospital universitário e processados por modelos com características específicas de um algoritmo interno. Apesar dessas limitações, destaca-se que as características metodológicas do estudo contribuíram para a construção de um modelo robusto e potencialmente reproduzível, uma vez que foram utilizados dados secundários de fácil acesso e uma amostra de tamanho considerável, fatores que favorecem o desempenho do modelo.

5. Conclusão

Neste estudo, foram desenvolvidos modelos preditivos de óbito hospitalar com base em dados do Sistema de Informações Hospitalares do Sistema Único de Saúde. As variáveis identificadas como preditoras significativas de mortalidade hospitalar foram: faixa etária entre 60 e 79 anos, faixa etária igual ou superior a 80 anos, internação em UTI e tempo de internamento de 15 dias ou mais. Os modelos demonstraram potencial para apoiar a avaliação do risco de mortalidade em pacientes hospitalizados, podendo contribuir para o aprimoramento da gestão clínica e assistencial.

Referências

- Aguiar, L. M. M., Martins, G. de S., Valduga, R., Gerez, A. P., Carmo, E. C. do, Cunha, K. da C., Cipriano, G. F. B., & Silva, M. L. da. (2022). Perfil de unidades de terapia intensiva adulto no Brasil: revisão sistemática de estudos observacionais. *Revista Brasileira de Terapia Intensiva*, 33, 624–634. <https://doi.org/10.5935/0103-507X.20210088>
- Aragon, T. J., Fay, M. P., Wollschlaeger, D., & Omidpanah, A. (2020). Package ‘epitools’. <https://doi.org/10.32614/CRAN.package.epitools>
- Blanes-Selva, V., Ruiz-García, V., Tortajada, S., Benedí, J.-M., Valdivieso, B., & García-Gómez, J. M. (2021). Design of 1-year mortality forecast at hospital admission: A machine learning approach. *Health Informatics Journal*, 27(1). <https://doi.org/10.1177/1460458220987580>
- Brasil. (2022). Ministério da Saúde. Portaria GM/MS nº 913, de 22 de abril de 2022. Declara o encerramento da Emergência em Saúde Pública de Importância Nacional (ESPIN) em decorrência da infecção humana pelo novo coronavírus (2019-nCoV) e revoga a Portaria GM/MS nº 188, de 3 de fevereiro de 2020. Diário Oficial da União. 2022; Seção 1:1.
- Calazans, J. A., Guimarães, R., & Nepomuceno, M. R. (2023). Diferenciais regionais da mortalidade no Brasil: Contribuição dos grupos etários e de causas de óbito sobre a variação da esperança de vida e da dispersão da idade à morte entre 2008 e 2018. *Revista Brasileira de Estudos de População*, 40, e0244. <https://doi.org/10.20947/S0102-3098a0244>
- Chen, Z., Li, T., Guo, S., Zeng, D., & Wang, K. (2023). Machine learning-based in-hospital mortality risk prediction tool for intensive care unit patients with heart failure. *Frontiers in Cardiovascular Medicine*, 10. <https://doi.org/10.3389/fcvm.2023.1119699>
- Cordeiro, P., & Martins, M. (2018). Mortalidade hospitalar em pacientes idosos no Sistema Único de Saúde, região Sudeste. *Revista de Saúde Pública*, 52, 69. <https://doi.org/10.11606/s1518-8787.2018052000146>
- Costa, M.L.M., Mafra, A. C. C. N., Cendoroglo, M. S., Rodrigues, P. S., Ferreira, M. S., Studenski, S. A., & Franco, F. G. de M. (2022). Development and validation of predictive model for long-term hospitalization, readmission, and in-hospital death of patients over 60 years old. *Einstein*, 20:eAO8012. https://doi.org/10.31744/einstein_journal/2022AO8012
- Cowling, T. E., Cromwell, D. A., Bellot, A., Sharples, L. D., & van der Meulen, J. (2021). Logistic regression and machine learning predicted patient mortality from large sets of diagnosis codes comparably. *Journal of Clinical Epidemiology*, 133, 43–52. <https://doi.org/10.1016/j.jclinepi.2020.12.018>
- Cowling, T. E., Cromwell, D. A., Sharples, L. D., & van der Meulen, J. (2020). A novel approach selected small sets of diagnosis codes with high prediction performance in large healthcare datasets. *J Clin Epidemiol*, 128:20-28. <https://doi.org/10.1016/j.jclinepi.2020.08.001>
- Ding, N., Nath, T., Mahendra Damarla, Gao, L., & Hassoun, P. M. (2024). Early predictive values of clinical assessments for ARDS mortality: a machine-learning approach. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-68653-8>
- Dutt-Ross, S. (2020). Manual de Análise de Dados. <https://livro.metodosquantitativos.com/docs/bookdown.pdf>
- Faro, A. R. M. C., Andrade, A. M., Guimarães, F. P. F., Belasco, A. G. S., Grandi, J. L., & Barbosa, D. A. (2021). Causas de óbitos em hospital de ensino da Amazônia Ocidental brasileira. *Acta paul enferm*, 34:eAPE002515. <https://doi.org/10.37689/acta-ape/2021AO002515>
- Geskey, J. M., Foreman, J. K., Witkowski, M. E., Huerta, S. M., Berkland, D., Hohmann, S. F., & Meurer, S. (2022). Improving Mortality Through a Multihospital, Collaborative Quality Improvement Project. *American Journal of Medical Quality*, 37(4), 321–326. <https://doi.org/10.1097/jmq.0000000000000039>
- Hydoub, Y. M., Walker, A. P., Kirchoff, R. W., Alzu'bi, H. M., Chipi, P. Y., Gerberi, D. J., M. Caroline Burton, M. Hassan Murad, & Dugani, S. B. (2023). Risk Prediction Models for Hospital Mortality in General Medical Patients: A Systematic Review. *American Journal of Medicine Open*, 10, 100044–100044. <https://doi.org/10.1016/j.ajmo.2023.100044>
- Klug, M., Barash, Y., Bechler, S., Resheff, Y. S., Tron, T., Ironi, A., Soffer, S., Zimlichman, E., & Klang, E. (2019). A Gradient Boosting Machine Learning Model for Predicting Early Mortality in the Emergency Department Triage: Devising a Nine-Point Triage Score. *Journal of General Internal Medicine*, 35(1), 220–227. <https://doi.org/10.1007/s11606-019-05512-7>
- Li, K., Shi, Q., Liu, S., Xie, Y., & Liu, J. (2021). Predicting in-hospital mortality in ICU patients with sepsis using gradient boosting decision tree. *Medicine*, 100(19), e25813. <https://doi.org/10.1097/md.00000000000025813>
- Macedo, L. R., Borges, C., Freire, L., Christiane, J., Paiva, N. S., & José, A. (2024). Excesso de mortalidade geral e mortalidade por COVID-19 no Brasil e regiões no ano de 2020. *Cadernos de Saúde Pública*, 40(11). <https://doi.org/10.1590/0102-311xpt217323>
- Maluangnon, C., Kanogpotjanant, P., & Tongyoo S. (2023). Comparing Outcomes of Critically Ill Patients in Intensive Care Units and General Wards: A Comprehensive Analysis. *Int J Gen Med*. 16:3779-3787. <https://doi.org/10.2147/IJGM.S422791>
- Okoroiwu, H. U., Uchendu, K. I., & Essien, R. A. (2020). Causes of morbidity and mortality among patients admitted in a tertiary hospital in southern Nigeria: A 6 year evaluation. *PLOS ONE*, 15(8), e0237313. <https://doi.org/10.1371/journal.pone.0237313>
- Pereira, A. S. et al. (2018). Metodologia da pesquisa científica. Santa Maria. Editora da UFSM.
- Rai, S., Brace, C. L., Ross, P., Jai Darvall, Haines, K., Mitchell, I., Frank Van Haren, & Pilcher, D. (2023). Characteristics and Outcomes of Very Elderly Patients Admitted to Intensive Care: A Retrospective Multicenter Cohort Analysis. *Critical Care Medicine*, 51(10):1328-1338. <https://doi.org/10.1097/ccm.0000000000005943>

- Rodrigues, A. R., Oliveira, A., Vieira, T., Assis, R., Lume, C., Gonçalves-Pereira, J., & Fernandes SM. (2024). A prolonged intensive care unit stay defines a worse long-term prognosis Insights from the critically ill mortality by age (Cimba) study. *Aust Crit Care*, 37(5):734-739. <https://doi.org/10.1016/j.aucc.2024.03.001>
- Schilling, M. P. R., Portela, M. C., & Martins, M. (2024). Razão de mortalidade hospitalar padronizada: limites e potencialidades do indicador para a avaliação do desempenho hospitalar no Sistema Único de Saúde, Brasil. *Cadernos de Saúde Pública*, 40(2). <https://doi.org/10.1590/0102-3111XPT080723>
- Seki, T., Kawazoe, Y., & Ohe, K. (2021). Machine learning-based prediction of in-hospital mortality using admission laboratory data: A retrospective, single-site study using electronic health record data. *PLOS ONE*. 16(2):e0246640. <https://doi.org/10.1371/journal.pone.0246640>
- Shitsuka, R.etal. (2014). Matemática fundamental para tecnologia. (2ed). Editora Érica.
- Stoessel, D., Fa, R., Artemova, S., von Schenck, U., Nowparast Rostami, H., Madiot, P.-E., Landelle, C., Olive, F., Foote, A., Moreau-Gaudry, A., & Bosson, J.-L. (2023). Early prediction of in-hospital mortality utilizing multivariate predictive modelling of electronic medical records and socio-determinants of health of the first day of hospitalization. *BMC Medical Informatics and Decision Making*, 23(1). <https://doi.org/10.1186/s12911-023-02356-4>
- TRIPOD. (2015). TRIPOD Checklist: Prediction Model Developmenth. <https://www.tripod-statement.org/resources/>
- van Valburg, M. K. (2024). Predicting 30-day mortality in intensive care unit patients with ischaemic stroke or intracerebral haemorrhage. *Eur J Anaesthesiol*, 41(2):136-145. <https://doi.org/10.1097/EJA.0000000000001920>
- Walicka, M., Chlebus, M., Śliwczyński, A., Brzozowska, M., Rutkowski, D., Czech, M., Tuszyńska, A., Jacyna, A., Puzianowska-Kuźnicka, M., & Franek, E. (2020). Non-surgical in-hospital mortality predictors: a multivariable regression analysis of 2,855,029 hospitalizations. *Polish Archives of Internal Medicine*. <https://doi.org/10.20452/pamw.15185>