Journal of Health Informatics

J Health Inform. 2026;18:e1785
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1785

ARTIGO COMPLETO
CBIS 2026

Predição de eventos clínicos em dados do SUS com modelos dinâmicos de sobrevivência

Prediction of clinical events in SUS data with dynamic survival models

Helio de Albuquerque Siebra[1], Gizeuda Cariry Lacet de Barros Crispim[2], Vitória Cristhyna dos Santos Camelo[3], Maria Eduarda Ribeiro Donato da Silva[3], Guido Lemos de Souza Filho[4], Clauirton de Albuquerque Siebra[3] ✉

ORCID: 0009-0000-9317-0073 · 0009-0005-1857-4154 · 0009-0004-2351-225X · 0009-0000-0568-346X · 0000-0001-5834-5237 · 0000-0002-9742-2175

[1] DATAPREV, João Pessoa (PB), Brasil.
[2] Secretaria Municipal de Saúde, João Pessoa (PB), Brasil.
[3] Universidade Federal da Paraíba, João Pessoa (PB), Brasil.
[4] LAVID, Universidade Federal da Paraíba, João Pessoa (PB), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1785

DOI
10.59681/2175-4411.v18.iEspecial.2026.1785

RECEBIDO
17/05/2026

APROVADO
20/07/2026

PROCESSO DE AVALIAÇÃO
Double Blind Review

EDITOR RESPONSÁVEL
Juliano de Souza Gaspar

ACESSO
Aberto, CC BY 4.0

AUTOR CORRESPONDENTE
Clauirton de Albuquerque Siebra
clauirton@ci.ufpb.br

LICENÇA

Este é um artigo publicado em acesso aberto sob a licença Creative Commons CC BY 4.0, que permite uso, distribuição e reprodução em qualquer meio, desde que o trabalho original seja corretamente citado.

CC BY 4.0

RESUMO

Objetivo: Este estudo propõe uma abordagem dinâmica para modelos de sobrevivência com o objetivo de melhorar a acurácia na predição de eventos clínicos e a capacidade de resposta dos hospitais filiados ao Sistema Único de Saúde (SUS). **Método:** A arquitetura proposta integra o modelo de riscos proporcionais de Cox com a rede recorrente Gated Recurrent Unit (GRU) modificada para processar eventos temporais irregulares. O ganho é demonstrado em experimentos de predição de alta hospitalar envolvendo dados reais coletados de cinco diferentes hospitais da rede pública. **Resultados:** A abordagem dinâmica, com representação de dados faltantes e das diferenças temporais entre observações, superou todas as configurações comparadas. Além disso, o modelo mostrou potencial para apoiar o monitoramento contínuo da evolução clínica de pacientes hospitalizados. **Conclusão:** Embora os experimentos tenham se concentrado na predição de alta hospitalar, a arquitetura proposta é agnóstica em relação ao tipo de evento clínico, o que abre caminho para sua aplicação em outros contextos hospitalares.

Descritores: análise de sobrevivência; representação temporal; registros eletrônicos de saúde.

ABSTRACT

Objective: This study proposes a dynamic approach to survival models aimed at improving the accuracy of clinical event prediction and the responsiveness of hospitals affiliated with the Brazilian Unified Health System (SUS). **Method:** The proposed architecture integrates the Cox proportional hazards model with a recurrent neural network based on a modified Gated Recurrent Unit (GRU) designed to process irregularly timed events. The benefits of the approach are demonstrated through hospital discharge prediction experiments using real-world data collected from five public hospitals. **Results:** The dynamic approach, which identifies missing data and the temporal gaps between observations, outperformed all compared configurations. In addition, the model showed potential to support the continuous monitoring of the clinical evolution of hospitalized patients. **Conclusion:** Although the experiments focused on hospital discharge prediction, the architecture is agnostic to the type of clinical event, opening the possibility for its application to other hospital-related outcomes.

Keywords: survival analysis; temporal representation; electronic health records.

CBIS 2026 XXI CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE

Artigo apresentado no XXI Congresso Brasileiro de Informática em Saúde (CBIS 2026), realizado de 23 a 25 de setembro de 2026, em Brasília (DF), e publicado na seção CBIS 2026 do Journal of Health Informatics.

COMO CITAR ESTE ARTIGO: Siebra HA, Crispim GCLB, Camelo VCS, da Silva MERD, Souza Filho GL, Siebra CA. Predição de eventos clínicos em dados do SUS com modelos dinâmicos de sobrevivência. J Health Inform 2026;18:e1785. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1785

1 INTRODUÇÃO

Sistemas hospitalares enfrentam desafios crescentes relacionados ao gerenciamento eficiente de recursos e à garantia de qualidade assistencial em ambientes caracterizados por alta demanda e grande complexidade clínica. Um dos principais fatores que dificultam a gestão hospitalar é a limitada capacidade de prever a evolução clínica dos pacientes ao longo do tempo. A ausência de previsibilidade sobre eventos clínicos relevantes, como deterioração do estado de saúde, desenvolvimento de sepse, necessidade de transferência para unidades de terapia intensiva ou alta hospitalar, dificulta a adoção de intervenções precoces e compromete a capacidade de planejamento dos serviços de saúde [1].

A capacidade de identificar eventos clínicos antes de sua ocorrência tem sido reconhecida como um elemento central para melhorar a segurança do paciente e a eficiência operacional dos hospitais. Sistemas de alerta precoce e modelos preditivos vêm sendo amplamente investigados na literatura com o objetivo de identificar sinais de deterioração clínica e apoiar decisões médicas em tempo oportuno. Revisões recentes mostram que modelos baseados em aprendizado de máquina aplicados a registros eletrônicos de saúde podem identificar padrões associados ao desenvolvimento de condições críticas, como sepse ou parada cardiorrespiratória, antes da manifestação clínica evidente, permitindo intervenções mais rápidas e potencialmente reduzindo mortalidade e complicações hospitalares [2-4]. Além disso, diversos estudos demonstram que sistemas de alerta precoce baseados em inteligência artificial podem detectar sinais de deterioração fisiológica várias horas antes do reconhecimento clínico, contribuindo para intervenções mais oportunas e melhorando desfechos hospitalares [5].

Nesse contexto, a análise de dados longitudinais de pacientes tornou-se uma área central para a pesquisa em ciência de dados em saúde. Registros eletrônicos de saúde contêm sequências complexas de observações ao longo do tempo, incluindo sinais vitais, exames laboratoriais, procedimentos e diagnósticos clínicos. Entretanto, esses dados apresentam características que tornam sua modelagem particularmente desafiadora, como observações temporais irregulares, presença frequente de dados faltantes e grande heterogeneidade entre pacientes [6,7].

Modelos de sobrevivência têm sido amplamente utilizados para estudar fenômenos clínicos relacionados ao tempo até a ocorrência de um evento, oferecendo uma estrutura estatística robusta para estimar riscos e probabilidades condicionais ao longo do tempo. Entre as abordagens existentes, o modelo de riscos proporcionais de Cox (*Cox Proportional Hazards*, CoxPH) permanece como uma das abordagens mais utilizadas na literatura biomédica [8]. No entanto, abordagens tradicionais de sobrevivência frequentemente apresentam limitações ao lidar com dados clínicos dinâmicos e com a complexidade temporal observada em registros hospitalares. Ao mesmo tempo, avanços em aprendizado profundo têm possibilitado novas estratégias para modelar trajetórias clínicas e prever eventos médicos. Arquiteturas baseadas em redes neurais recorrentes, por exemplo, têm demonstrado resultados promissores na modelagem de dados clínicos sequenciais, especialmente quando aplicadas a registros eletrônicos de saúde [6,9]. Além disso, abordagens que integram redes neurais com modelos de sobrevivência vêm sendo propostas para capturar relações temporais complexas e melhorar a capacidade preditiva em tarefas clínicas [10,11]. Ainda assim, muitos desses modelos enfrentam dificuldades para lidar explicitamente com observações irregulares no tempo e dados faltantes, características frequentemente presentes em dados hospitalares reais.

Diante desse cenário, este trabalho propõe uma abordagem dinâmica para a predição de eventos clínicos em dados hospitalares, combinando o modelo CoxPH com uma arquitetura recorrente baseada em *Gated Recurrent Unit* (GRU) adaptada para lidar com eventos observados em intervalos temporais irregulares e dados faltantes. A abordagem é avaliada em experimentos de predição de alta hospitalar utilizando dados reais provenientes de cinco hospitais da rede pública brasileira. Estes hospitais possuem diferentes perfis e os dados dos pacientes (N=17.385) foram coletados durante um ano com a seguinte distribuição entre os hospitais: urgência e emergência em pediatria (N=2.045), maternidade (N=7.762), ortotrauma (N=5.211), oncologia (N=1.102) e urgências em geral (N=1.265). Embora o estudo de caso se concentre nesse desfecho específico (alta hospitalar), o modelo proposto é agnóstico em relação ao tipo de evento clínico, podendo ser aplicado à predição de eventos relevantes, como deterioração clínica, sepse ou necessidade de cuidados intensivos.

2 MÉTODOS

2.1 Visão Geral da Abordagem

Uma das contribuições da nossa abordagem é fazer suposições mínimas sobre a regularidade das observações ou sobre os mecanismos de ausência de dados (*missingness*). Ou seja, não realiza alterações nos dados. Por exemplo, não é realizada interpolação temporal nem reamostragem, e os valores ausentes não são imputados além do mapeamento para zero com indicadores explícitos de ausência. O modelo assume que os tempos de alta hospitalar estão sujeitos a censura à direita (*right censoring*: prazo máximo para a ocorrência do evento) e que os intervalos entre avaliações (Δt) fornecem contexto informativo sobre a evolução do paciente, em vez de representarem apenas

ruído. A Figura 1 resume o *pipeline* proposto pela nossa abordagem de acordo com essas premissas. Nesse *pipeline*, medições longitudinais de prontuários eletrônicos de saúde (EHR) são processadas sequencialmente utilizando um modelo recorrente de sobrevivência sensível ao tempo, que atualiza o risco de alta à medida que novos dados são coletados. Intervalos temporais irregulares e indicadores de ausência são fornecidos como entradas explícitas, enquanto observações preenchidas (*padding*) são mascaradas para evitar aprendizado "ilegítimo". As saídas do modelo são avaliadas utilizando métricas específicas de análise de sobrevivência e interpretadas por meio de oclusão de atributos dependente do tempo. Todos esses aspectos são detalhados nas seções seguintes.

2.2 Codificação dos Dados de Entrada (Input Encoding)

Nossa pesquisa considera o "dia" como unidade temporal. Assim, o tempo de internação foi modelado como um desfecho de tempo até o evento medido em dias, com os pacientes sendo acompanhados desde a admissão hospitalar até a alta ou censura (no 15º dia, conforme sugerido pela equipe médica). Considere o seguinte conjunto de dados como um exemplo ilustrativo (Tabela 1) que apresenta uma estrutura de dados longitudinais, na qual n variáveis clínicas ($x_1,\ldots,x_n$) são monitoradas ao longo do tempo. A variável "Dia de coleta" indica o dia de internação em que as variáveis da mesma linha foram observadas.

É importante destacar que nem todas as variáveis são medidas diariamente. Por exemplo, o paciente P1 tem todas as variáveis registradas apenas no primeiro dia de internação, enquanto o paciente P2 possui observações distribuídas em três dias diferentes (1, 3 e 6). Como as medições clínicas são coletadas de acordo com as rotinas de cuidado e não segundo um cronograma fixo de amostragem, as observações das variáveis são intrinsecamente irregulares ao longo do tempo.

2.3 Representação dos Dados Faltantes

Os valores ausentes não são imputados, mas sim codificados dentro da função de escalonamento. Desta forma, todos os valores observados são reescalados para o intervalo de 1 a 6, enquanto as entradas ausentes são mapeadas para 0, garantindo uma separação numérica clara entre dados ausentes e observados. Essa abordagem foi derivada de outros estudos [12], os quais empregaram essa abordagem com sucesso. Outro tipo de dado faltante são os complementados por meio do processo de *padding*, o qual é necessário para complementar sequências de pacientes que são

Figura 1. Visão geral da redefinição da arquitetura GRU-Cox

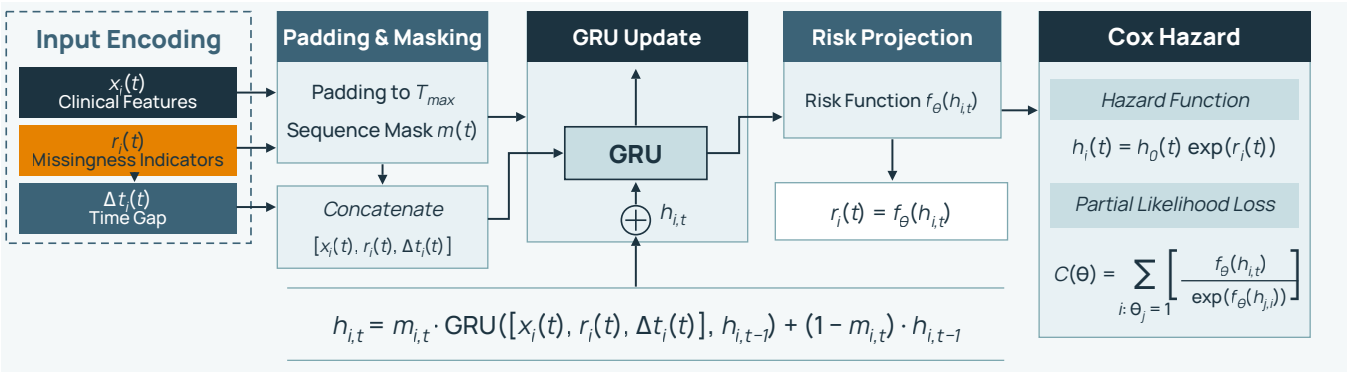

Fonte: Elaborado pelos autores (2026).

Tabela 1. Exemplo do formato de dataset usado em nossa pesquisa (censura = 15 dias)

Id	x_1	x_2	x_3	x_n	Dia de coleta	Duração	Evento
P1	20	200	17	33	1	4	1
P2	17	180	18	30	1	9	1
P2	nan	180	nan	nan	3	9	1
P2	20	nan	20	33	6	9	1
P3	17	nan	nan	30	2	5	1
P3	18	nan	nan	nan	4	5	1
P4	16	190	nan	28	2	20	0

Fonte: Elaborado pelos autores (2026).

menores que o valor considerado nessa abordagem (15 dias). Estes dois tipos de valores são diretamente indicados por meio de uma matriz (máscara) binária, onde "1" indica que o atributo foi observado em um tempo *t*i; e "0" se for um valor faltante ou um valor resultado do processo de *padding*. Na prática, máscaras de *padding* são utilizadas exclusivamente para impedir que passos temporais artificiais contribuam para as atualizações do estado recorrente e para o cálculo da função de perda. Em contraste, indicadores de ausência em nível de variável (*feature-level missingness indicators*) são fornecidos como entradas explícitas para o modelo, permitindo que ele aprenda padrões associados à ausência informativa de dados. Assim, observações adicionadas por *padding* são ignoradas, enquanto medições clínicas ausentes ainda podem influenciar as previsões por meio de seus indicadores de ausência.

2.4 Representação da Irregularidade Temporal

Intervalos de tempo irregulares são uma característica definidora dos dados clínicos do mundo real, uma vez que as avaliações dos pacientes são realizadas de acordo com as necessidades de cuidado, e não em taxas fixas de amostragem. Para lidar com esse desafio, adotamos uma estratégia que combina codificação explícita do tempo, modelagem baseada em sequências e aprendizado sensível à análise de sobrevivência, sem impor interpolação temporal ou reamostragem. Assim, cada paciente é representado como uma sequência de observações na forma de tuplas definidas como:

$$\{(x_{i,t},\ \Delta t_{i,t})\}_{t=1}^{T_i}, \quad (1)$$

Nesta formulação, xi,t denota o vetor de variáveis clínicas observadas na t-ésima avaliação, e Δti,t representa o tempo decorrido desde a observação anterior. Ao codificar explicitamente os intervalos de tempo, o modelo recebe informações tanto sobre a ordem quanto sobre o espaçamento das observações, permitindo distinguir entre medições próximas no tempo e amplamente espaçadas. É importante enfatizar que valores ausentes surgem naturalmente quando determinadas variáveis não são avaliadas em um dado momento, sendo mantidos dessa forma para preservar o processo original de observação, em vez de impor uma regularidade artificial aos dados. Além disso, a modelagem explícita de Δt permite que as transições de estados recorrentes se adaptem ao ritmo da evolução clínica. Medições repetidas em intervalos curtos podem indicar instabilidade ou monitoramento intensivo, enquanto intervalos longos entre avaliações podem refletir estabilidade clínica ou menor necessidade de intervenção, ambos sendo aspectos informativos para a estimativa do risco de alta hospitalar.

2.5 Arquitetura Híbrida

Nossa abordagem considera a predição de eventos clínicos como um problema de sobrevivência dinâmico, no qual o risco do evento ocorrer (*por exemplo*, alta hospitalar) depende do estado clínico em evolução do paciente. Os modelos clássicos de CoxPH assumem covariáveis estáticas e um preditor linear, o que limita sua capacidade de capturar dependências temporais não lineares e padrões longitudinais. Por outro lado, Redes Neurais Recorrentes (RNNs) são adequadas para modelar dados sequenciais, mas não lidam nativamente com censura ou com desfechos de tempo até o evento. A arquitetura GRU-Cox combina os pontos fortes de ambos os paradigmas ao incorporar uma variante de RNN chamada *GRU* dentro do *framework* CoxPH. A GRU codifica as trajetórias dos pacientes em uma representação latente dependente do tempo, enquanto o modelo de Cox traduz essa representação em uma função de risco, que lida naturalmente com censura à direita e permite inferência estatística apropriada em análise de sobrevivência. Ou seja, em vez de indicar um valor único probabilístico, o resultado é dado em termos de uma curva de probabilidades ao longo do tempo. Essa formulação híbrida, estendida com as representações de dados faltantes e irregularidade temporal proposta nesse estudo, é particularmente adequada para a predição do tempo de possível ocorrência de um evento clínico. De fato, a maioria destes eventos possuem amostragem irregular e observações ausentes (faltantes), características intrínsecas aos dados hospitalares do mundo real.

2.6 Estudo de Casos: Predição da alta hospitalar

A validação da proposta apresentada neste estudo considera a alta hospitalar como evento clínico. Para isso, foram coletados dados passados do prontuário eletrônico de cinco hospitais públicos municipais da cidade alvo. Todos os dados foram coletados dentro do mesmo período (novembro de 2022 a setembro de 2023). O início em novembro de 2022 foi decidido de modo a não incluir pacientes ainda decorrentes da pandemia de COVID-19. Os dados a partir de novembro de 2023 vão ser utilizados em um processo de validação futura que simula a entrada de pacientes ao longo do tempo. Desta forma, eles não foram inclusos na criação dos modelos do estudo. A Tabela 2 resume as características de cada grupo de dados.

O protocolo deste estudo foi revisado e aprovado em 03 de agosto de 2025 pelo Centro de Ciências da Saúde da UFPB (aprovação nº 8.021.685). Todas as análises foram realizadas com dados anonimizados, seguindo os princípios e as disposições da Lei Geral de Proteção de Dados Pessoais (Lei nº 13.709/2018).

Tabela 2. Características dos dados de cada hospital

Hospital	Especialidade	# de Pacientes	# de dias
H1	Oncologia	1.102	11.895
H2	Urgências e emergências	1.265	9.520
H3	Ortotrauma	5.211	19.621
H4	Urgências pediátricas	2.045	5.145
H5	Maternidade	7.762	16.059

Fonte: Elaborado pelos autores (2026).

2.7 Protocolo de Avaliação

Para garantir a robustez e a replicabilidade dos resultados, definimos um protocolo de avaliação padronizado aplicado a cinco modelos distintos:

- **M1:** modelo de análise de sobrevivência estático, onde as variáveis de entrada foram obtidas por meio da consolidação de sequências longitudinais em variáveis agregadas. Essa abordagem é amplamente adotada na literatura [13] e é utilizada aqui como *baseline*, a fim de evidenciar os potenciais benefícios da modelagem dinâmica.
- **M2:** modelo dinâmico baseado na arquitetura GRU-Cox.
- **M3:** modelo GRU-Cox (M2) ampliado com mecanismos de mascaramento, capazes de distinguir entre valores observados, valores imputados e dados adicionados por *padding*.
- **M4:** modelo baseado na arquitetura M3, mas enriquecido com informações explícitas sobre os intervalos de tempo entre avaliações sucessivas do paciente.
- **M5:** modelo GRU-Cox (M2) enriquecido com informações explícitas sobre os intervalos de tempo entre avaliações sucessivas do paciente.

O desempenho dos modelos foi avaliado utilizando duas métricas complementares. O índice de concordância (C-index) é uma medida baseada em ordenação, amplamente utilizada em análise de sobrevivência para quantificar a proporção de pares comparáveis de indivíduos para os quais o modelo prediz corretamente a ordem dos tempos de ocorrência do evento. Essa métrica foi utilizada para avaliar todos os modelos (M1–M5). Além disso, empregamos o C-index dependente do tempo com ponderação pela probabilidade inversa de censura (IPCW) para avaliar os modelos dinâmicos (M2–M5). Essa métrica responde à seguinte questão: "Em um determinado instante de tempo τ, quão bem o modelo ordena os indivíduos que experimentam o evento antes de τ em relação àqueles que permanecem sem evento após τ, considerando a presença de censura?"

Em linha com a prática comum na literatura de saúde e análise de sobrevivência, os valores do C-index são frequentemente interpretados qualitativamente da seguinte forma**:** 0,5 (discriminação aleatória); 0,6–0,7 (discriminação modesta); 0,7–0,8 (discriminação regular); 0,8–0,85 (boa discriminação); e >0,85 (excelente discriminação). Interpretações qualitativas semelhantes foram adotadas em estudos prévios de predição clínica [14]. Deve-se notar, contudo, que esses limiares são baseados em heurísticas amplamente utilizadas, e não em padrões rígidos. Diferentes áreas podem adotar pontos de corte ligeiramente distintos.

Nosso protocolo de avaliação divide o conjunto de dados em três subconjuntos disjuntos: treinamento (70%), validação (15%) e teste (15%). Esse procedimento foi repetido em 15 execuções independentes, com os dados sendo embaralhados aleatoriamente a cada iteração, a fim de avaliar a robustez em relação à variabilidade amostral. Para evitar vazamento de dados (*data leakage*), todas as divisões do conjunto de dados foram realizadas antes da aplicação de qualquer procedimento de escalonamento ou normalização. Para garantir reprodutibilidade e comparação justa entre os modelos, foram utilizadas sementes aleatórias fixas na geração das partições. Isso assegurou que os conjuntos de treinamento, validação e teste fossem idênticos para todos os cinco modelos (M1–M5) em cada execução experimental, isolando assim diferenças de desempenho atribuíveis exclusivamente às estratégias de modelagem, e não a variações na divisão dos dados. Os resultados do C-index e do C-index dependente do tempo são apresentados em termos de média e desvio padrão.

3 RESULTADOS

3.1 Análise exploratória

A análise de dados exploratória foi importante para caracterizar a qualidade dos dados, a taxa de dados faltantes e a estrutura temporal dos dados. Os resultados desta análise para os cinco hospitais incluídos no nosso estudo são mostrados na Tabela 3.

A Tabela 3 mostra que, em algumas situações (H1 e H5), a taxa de dados faltantes chega a um terço do total de dados disponibilizados pelo hospital. Além disso, a distância entre observações possui uma grande variabilidade dentro de uma faixa que pode chegar, no maior dos casos, até 50 dias. Note, porém, que

distâncias maiores que 3 dias são encontradas apenas em tipos de exames que são raros. Ou seja, a grande maioria das distâncias (aproximadamente 92%) vai ser encontrada dentro de um intervalo de 1 a 3 dias.

Tabela 3. Análise exploratória dos dados que compõem o dataset dos cinco hospitais analisados.

Hospital	Média do número de observações por paciente	Taxa de eventos ocorridos (%)	Taxa média de dados faltantes (%)	Distância entre observações [min,max]
H1	10,79	58,5	33,70	[1, 50]
H2	7,52	72,6	5,75	[1, 44]
H3	3,76	81,9	15,95	[1, 48]
H4	2,52	92,6	13,79	[1, 36]
H5	2,07	96,1	30,35	[1, 26]

Fonte: Elaborado pelos autores (2026).

Tabela 4. Resumo dos experimentos em relação à métrica C-index.

Hospital	M1 (estático)	M2 (dinâmico puro)	M3 (dinâmico + máscara)	M4 (dinâmico + máscara + Δt)	M5 (dinâmico + Δt)
H1	0,700 ± 0,015	0,847 ± 0,017	0,823 ± 0,016	0,901 ± 0,014	0,903 ± 0,014
H2	0,697 ± 0,046	0,858 ± 0,011	0,831 ± 0,024	0,873 ± 0,020	0,887 ± 0,017
H3	0,700 ± 0,012	0,779 ± 0,007	0,769 ± 0,009	0,795 ± 0,007	0,802 ± 0,007
H4	0,628 ± 0,023	0,741 ± 0,010	0,707 ± 0,018	0,769 ± 0,022	0,800 ± 0,014
H5	0,706 ± 0,013	0,782 ± 0,009	0,771 ± 0,011	0,786 ± 0,011	0,796 ± 0,012

Fonte: Elaborado pelos autores (2026).

3.2 Resultados C-index

A Tabela 4 apresenta o desempenho dos modelos avaliados em termos do índice de concordância (C-index), considerando os cinco conjuntos de dados hospitalares. De forma geral, observa-se que os modelos dinâmicos (M2–M5) superam o modelo estático (M1), evidenciando a importância de incorporar a evolução temporal das variáveis clínicas na predição de eventos. Entre os modelos dinâmicos, o M2 já apresenta ganhos substanciais em relação ao *baseline*, enquanto o M3, que inclui mecanismos explícitos de mascaramento para dados faltantes, não demonstra melhorias consistentes, apresentando desempenho ligeiramente inferior ao M2 em todos os cenários. Por outro lado, os modelos que incorporam explicitamente a informação temporal (M4 e M5) alcançam os melhores resultados em todos os hospitais, com destaque para o M5, que apresenta os maiores valores de C-index de forma consistente. Esses resultados indicam que a modelagem da irregularidade temporal tem impacto mais expressivo no desempenho preditivo do que a representação explícita de dados faltantes.

3.3 Resultados do C-index dependente do tempo

Para responder quão bem o modelo classifica os pacientes ao longo de horizontes de tempo clínicos relevantes, utilizamos o C-index dependente do tempo (*time-dependent C-index*) em múltiplos valores de τ, uniformemente amostrados entre os percentis 10 e 90 dos tempos de evento observados, a fim de garantir uma estimativa estável. Assim, essa métrica quantifica a probabilidade de que, em um determinado tempo τ, um paciente que experimenta o evento mais cedo receba um risco previsto maior do que aquele que

Figura 2. Comparação do C-index dependente do tempo para os modelos M2–M5. Os valores em cada curva representam a média e o desvio padrão da sequência.

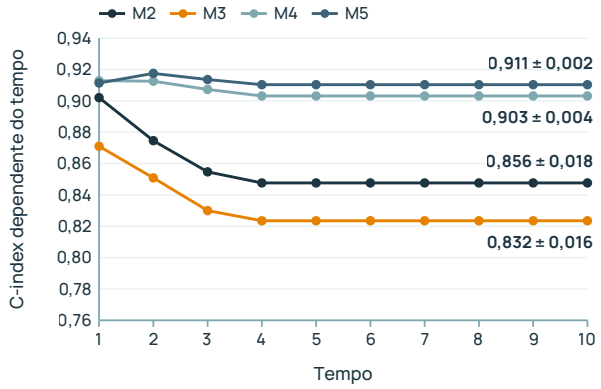

Fonte: Elaborado pelos autores (2026).

Figura 3. Probabilidade cumulativa do evento no tempo restante estimada em diferentes dias de referência (landmarks). Cada curva mostra a probabilidade condicional de que o evento ocorra nos próximos 7 dias, dado que o indivíduo sobreviveu até o respectivo marco temporal.

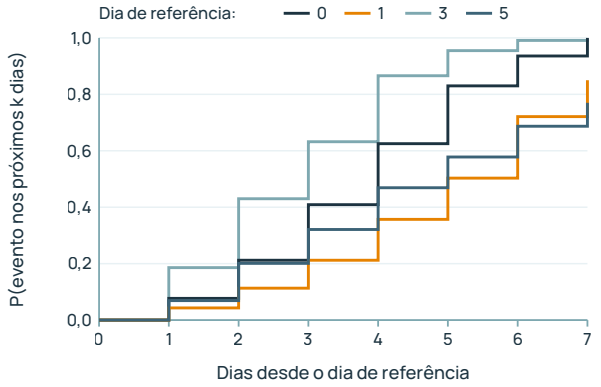

Fonte: Elaborado pelos autores (2026).

sobrevive por mais tempo (Figura 2).

Os gráficos gerados em nossos experimentos mostram que todos os modelos apresentam um declínio gradual no C-index dependente do tempo à medida que o horizonte de avaliação aumenta, refletindo a crescente dificuldade de classificar os desfechos sob maior censura. Importante destacar que a ordem relativa de desempenho permanece estável ao longo de τ, com o M4 e M5 (que lidam com o Δt) superando consistentemente o M3 e o M2, indicando ganhos robustos tanto em horizontes de predição de curto quanto de longo prazo. Além disso, a degradação limitada e a estabilização precoce do M4 e M5 sugerem que a estratégia de modelagem proposta captura sinais temporalmente informativos que permanecem preditivos ao longo de diferentes horizontes de tempo, enquanto outras abordagens (M2 e M3) apresentam uma queda de desempenho mais acentuada. Vale também ressaltar que, ainda que mais simples devido a não utilizar máscaras, M5 é ligeiramente melhor que M4, corroborando o resultado anterior (Seção 3.2).

3.4 Curvas Dinâmicas de Sobrevivência

Durante o treinamento, os parâmetros do modelo são otimizados utilizando todas as observações longitudinais disponíveis até o momento do evento ou da censura. Durante a inferência, as previsões são geradas em tempos de referência (*landmarks*) arbitrários, congelando o histórico do paciente até esse ponto e estimando o risco futuro de alta hospitalar. A Figura 3 ilustra a probabilidade cumulativa do tempo restante até a alta, estimada em diferentes dias de referência. Cada curva representa previsões condicionadas ao fato de o paciente ter permanecido hospitalizado até o respectivo marco temporal, utilizando todas as informações clínicas disponíveis naquele momento.

De forma geral, essa visualização responde diretamente à seguinte pergunta clinicamente relevante: "*Dado o estado atual do paciente, qual é a probabilidade de que o evento ocorra nos próximos dias*?". Desta forma, ao recalcular essa probabilidade em cada marco temporal (landmark), o modelo fornece um resumo dinâmico e temporalmente fundamentado da evolução do paciente ao longo do tempo.

4 DISCUSSÃO

Os resultados apresentados neste estudo evidenciam de forma consistente a importância da modelagem dinâmica na predição de eventos clínicos em dados hospitalares. Em comparação com o modelo estático (M1), todas as abordagens dinâmicas (M2–M5) demonstraram ganhos substanciais no C-index, reforçando a limitação de representações agregadas que desconsideram a evolução temporal das variáveis clínicas. Esse achado está alinhado com a literatura, que aponta que a preservação da estrutura longitudinal dos dados é fundamental para capturar padrões clínicos relevantes ao longo do tempo, especialmente em registros eletrônicos de saúde, conforme discutido por Lipton *et al.* [15] e Xiao *et al.* [16], que demonstram ganhos significativos ao utilizar modelos sequenciais em dados clínicos.

Entre os modelos dinâmicos, observa-se que a inclusão explícita de mecanismos de mascaramento para dados faltantes (M3) não resultou em melhorias de desempenho em relação ao modelo base (M2), apresentando, inclusive, uma leve degradação consistente em todos os cenários avaliados. Esse comportamento sugere que, no contexto dos dados analisados, a ausência de medições pode não ser fortemente informativa, refletindo predominantemente aspectos operacionais do processo de coleta, e não necessariamente o estado clínico do paciente. Além disso, a codificação adotada no M2 já permite uma distinção implícita entre valores observados e ausentes, o que pode reduzir o impacto da introdução explícita de máscaras. Esse resultado também pode ser interpretado à luz de trabalhos como o de Che *et al.* [17],

que mostram que o benefício de modelar dados faltantes depende fortemente do mecanismo de *missingness*. Esse resultado também pode estar associado ao aumento da complexidade do modelo em M3, potencialmente favorecendo efeitos de sobreajuste, especialmente em cenários com alta esparsidade e sequências curtas.

Por outro lado, os modelos que incorporam explicitamente a irregularidade temporal (M4 e M5) apresentaram os melhores desempenhos em todos os conjuntos de dados, tanto em termos de C-index quanto no C-index dependente do tempo. Esse resultado indica que a informação contida nos intervalos entre observações (Δt) desempenha um papel central na modelagem da evolução clínica dos pacientes. A análise ao longo de diferentes horizontes de tempo mostrou que esses modelos mantêm desempenho superior de forma consistente, com menor degradação à medida que o horizonte de predição aumenta. Isso sugere que a modelagem explícita do tempo permite capturar sinais mais robustos e generalizáveis, relevantes tanto para previsões de curto quanto de longo prazo.

Outro aspecto importante diz respeito à comparação entre M4 e M5. Apesar de M4 incorporar simultaneamente informações de tempo e mascaramento, o modelo M5 (mais simples por não utilizar máscaras explícitas) apresentou desempenho ligeiramente superior. Esse resultado reforça a hipótese de que a complexidade adicional introduzida pela modelagem de dados faltantes nem sempre se traduz em ganhos preditivos, especialmente quando a informação de ausência não é suficientemente discriminativa. Em contrapartida, a incorporação de Δt mostrou-se consistentemente benéfica, indicando que a dinâmica temporal é uma fonte de informação mais relevante nesse contexto.

As curvas dinâmicas de sobrevivência apresentadas também evidenciam o potencial prático da abordagem proposta. Ao permitir a atualização contínua das previsões com base no histórico mais recente do paciente, o modelo fornece estimativas condicionais do risco de ocorrência do evento em diferentes marcos temporais. Esse tipo de representação é particularmente útil em cenários clínicos reais, pois responde diretamente a perguntas operacionais relevantes, como a probabilidade de alta hospitalar nos próximos dias, dado o estado atual do paciente.

5 CONCLUSÕES

Apesar dos resultados promissores, este estudo apresenta algumas limitações. A análise foi conduzida com dados retrospectivos de um conjunto específico de hospitais, o que pode limitar a generalização dos resultados para outros contextos clínicos. Além disso, a abordagem adotada para modelagem de dados faltantes é relativamente simples e pode não capturar padrões mais complexos de *missingness* informativa. Como direções futuras, pretende-se investigar estratégias mais avançadas para modelagem de dados faltantes, incluindo abordagens baseadas em decaimento temporal e imputação aprendida, bem como explorar a integração de dados multimodais e a validação prospectiva em ambientes clínicos reais. Essas extensões podem contribuir para aumentar a robustez e a aplicabilidade da abordagem proposta em cenários de apoio à decisão clínica.

Contribuição dos autores. G.C. concebeu o estudo e desenhou o modelo metodológico. H.S., M.S. e V.S. implementaram os modelos, conduziram os experimentos e realizaram as análises estatísticas. H.S. contribuiu para a interpretação dos resultados e para o desenvolvimento da estrutura de interpretabilidade. C.S. elaborou o manuscrito, supervisionou o projeto e forneceu percepções clínicas. G.L. revisou criticamente o manuscrito quanto ao conteúdo intelectual e relevância clínica. Todos os autores revisaram e aprovaram o manuscrito final.

Agradecimentos. Os autores agradecem ao Hospital Santa Isabel e à Equipe de Desenvolvimento de Informática da Prefeitura de João Pessoa por fornecerem acesso seguro e prático aos conjuntos de dados do hospital.

Financiamento. Este trabalho foi financiado pela Secretaria de Ciência e Tecnologia (Secitec) da Prefeitura de João Pessoa, Auxílio/Chamada 006/2025, e pela Chamada CNPq/MCTI/FNDCT nº 44/2024 - Universal.

Disponibilidade de dados e materiais. Os autores não declararam a disponibilidade dos dados e materiais da pesquisa.

Conflitos de interesse. Os autores não declararam conflitos de interesse.

Declaração de uso de IA. Os autores declaram que utilizaram ferramentas de IA apenas para apoio à redação e revisão de texto (clareza, gramática e estilo), além de geração de imagem quando indicado no texto e auxílio na codificação.

REFERÊNCIAS

1. Veldhuis LI, Woittiez NJC, Nanayakkara PWB, Ludikhuize J. Artificial Intelligence for the Prediction of In-Hospital Clinical Deterioration: A Systematic Review. Crit Care Explor. 2022;4(9):e0744. doi: https://doi.org/10.1097/CCE.0000000000000744

2. Yadgarov MY, Landoni G, Berikashvili LB, Polyakov PA, Kadantseva KK, Smirnova AV, et al. Early detection of sepsis using machine learning algorithms: a systematic review and network meta-analysis. Front Med (Lausanne). 2024;11:1491358. doi: https://doi.org/10.3389/fmed.2024.1491358

3. Abbas GH, Sen P, Giri OA, Khan NH. Artificial Intelligence-Based Predictive Modeling for Early Detection of Sepsis in Hospitalized Patients: A Systematic Review and Meta-Analysis. Crit Care Explor. 2025;7(12):e1360. doi: https://doi.org/10.1097/CCE.0000000000001360

4. Al-Juhani A, Desoky R, Iskander Z, Alshehri KT, Alshehri AA, Almuhaimid A, et al. Advances in Data-Driven Early Warning Systems for Sepsis Recognition and Intervention in Emergency Care: A Systematic Review of Diagnostic Performance and Clinical Outcomes. Cureus. 2025;17(8):e89882. doi: https://doi.org/10.7759/cureus.89882

5. Yuan S, Yang Z, Li J, Wu C, Liu S. AI-Powered early warning systems for clinical deterioration significantly improve patient outcomes: a meta-analysis. BMC Med Inform Decis Mak. 2025;25(1):203. doi: https://doi.org/10.1186/s12911-025-03048-x

6. Lipton ZC, Kale DC, Elkan C, Wetzel R. Learning to diagnose with LSTM recurrent neural networks. In: Proceedings of the International Conference on Learning Representations (ICLR) Workshop. 2016.

7. Shickel B, Tighe PJ, Bihorac A, Rashidi P. Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis. IEEE J Biomed Health Inform. 2018;22(5):1589-604. doi: https://doi.org/10.1109/JBHI.2017.2767063

8. Cox DR. Regression Models and Life-Tables. Journal of the Royal Statistical Society Series B: Statistical Methodology. 1972;34(2):187-202. doi: https://doi.org/10.1111/j.2517-6161.1972.tb00899.x

9. Choi E, Bahadori MT, Schuetz A, Stewart WF, Sun J. Doctor AI: Predicting clinical events via recurrent neural networks. In: Proceedings of the Machine Learning for Healthcare Conference. 2016. p. 301–18.

10. Katzman JL, Shaham U, Cloninger A, Bates J, Jiang T, Kluger Y. DeepSurv: personalized treatment recommender system using a Cox proportional hazards deep neural network. BMC Med Res Methodol. 2018;18(1):24. doi: https://doi.org/10.1186/s12874-018-0482-1

11. Lee C, Zame W, Yoon J, Van der Schaar M. DeepHit: A Deep Learning Approach to Survival Analysis With Competing Risks. AAAI. 2018;32(1). doi: https://doi.org/10.1609/aaai.v32i1.11842

12. Strickler EAT, Thomas J, Thomas JP, Benjamin B, Shamsuddin R. Exploring a global interpretation mechanism for deep learning networks when predicting sepsis. Sci Rep. 2023;13(1):3067. doi: https://doi.org/10.1038/s41598-023-30091-3

13. Deschepper M, Smedt C, Colpaert K. A literature-based approach to predict continuous hospital length of stay in adult acute care patients using admission variables: A single university center experience. Int J Med Inform. 2025;193:105678. doi: https://doi.org/10.1016/j.ijmedinf.2024.105678

14. Steyerberg EW. Validation of Prediction Models. In: Statistics for Biology and Health. Cham: Springer International Publishing; 2019. p. 329-44. doi: https://doi.org/10.1007/978-3-030-16399-0_17

15. Lipton ZC, Kale DC, Wetzel R. Directly Modeling Missing Data in Sequences with RNNs: Improved Classification of Clinical Time Series. Proc Mach Learn Healthcare. 2016:253–70.

16. Xiao C, Choi E, Sun J. Opportunities and challenges in developing deep learning models using electronic health records data: a systematic review. J Am Med Inform Assoc. 2018;25(10):1419-28. doi: https://doi.org/10.1093/jamia/ocy068

17. Che Z, Purushotham S, Cho K, Sontag D, Liu Y. Recurrent Neural Networks for Multivariate Time Series with Missing Values. Sci Rep. 2018;8(1):6085. doi: https://doi.org/10.1038/s41598-018-24271-9

NOTAS EDITORIAIS

O Journal of Health Informatics é uma publicação científica mantida pela Sociedade Brasileira de Informática em Saúde, associação científica sem fins lucrativos dedicada ao desenvolvimento da Informática em Saúde e da Saúde Digital no Brasil. O processo editorial é conduzido com independência científica, sem interferência institucional, comercial ou de patrocinadores, e segue as boas práticas internacionais de ética em publicação científica.

Este artigo foi avaliado por pares, em sistema duplo-cego, por especialistas da área. A equipe editorial usou ferramentas de inteligência artificial, com supervisão humana, na triagem inicial, na conferência do texto, das referências e dos números e, quando necessário, no redesenho de figuras, quadros e tabelas, aprovado pelos autores na prova. As ferramentas e as salvaguardas estão na Política de uso de inteligência artificial da revista. As decisões editoriais foram tomadas por pessoas.

SBIS Sociedade Brasileira de Informática em Saúde