

Para além da tecnologia: a inteligência artificial pode apoiar decisões clínicas na predição da sepse?

Beyond technology: Can artificial intelligence support clinical decisions in the prediction of sepsis?

Más allá de la tecnología: ¿La inteligencia artificial puede apoyar la toma de decisiones clínicas en la predicción de la sepsis?

Juliane de Souza Scherer¹

ORCID: 0000-0002-9442-8619

Jéssica Silveira Pereira¹

ORCID: 0000-0001-5122-6665

Mariana Severo Debastiani¹

ORCID: 0000-0002-0635-514X

Claudia Giuliano Bica¹

ORCID: 0000-0002-6763-6631

¹Universidade Federal de Ciências da Saúde de Porto Alegre.
Porto Alegre, Rio Grande do Sul, Brasil.

Como citar este artigo:

Scherer JS, Pereira JS, Debastiani MS, Bica CG. Beyond technology: Can artificial intelligence support clinical decisions in the prediction of sepsis?. Rev Bras Enferm. 2022;75(5):e20210586. <https://doi.org/10.1590/0034-7167-2021-0586>

Autor Correspondente:

Juliane de Souza Scherer

E-mail: julianess@ufcspa.edu.br



EDITOR CHEFE: Antonio José de Almeida Filho
EDITOR ASSOCIADO: Ana Fátima Fernandes

Submissão: 30-08-2021 **Aprovação:** 14-10-2021

RESUMO

Objetivo: Analisar os alarmes críticos preditores de deterioração clínica/sepse para tomada de decisão clínica nos pacientes internados em complexo hospitalar de referência. **Métodos:** Estudo observacional de coorte retrospectivo. A ferramenta de *Machine Learning* (ML), Robô Laura[®], pontua alterações nos parâmetros vitais e exames laboratoriais, classificando-os por gravidade. Incluíram-se pacientes internados e maiores de 18 anos. **Resultados:** Extraíram-se 122.703 alarmes da plataforma, classificados de 2 até 9. A pré-seleção dos alarmes críticos (6 a 9) apontou 263 alertas urgentes (0,2%), dos quais, após o filtro de critérios de exclusão, delimitaram-se 254 alertas para 61 pacientes internados. A mortalidade dos pacientes por sepse foi de 75%, dos quais 52% devido à sepse relacionada ao novo coronavírus. Após os alarmes serem atendidos, 82% dos pacientes permaneceram nos setores. **Conclusões:** Muito além da tecnologia, modelos de ML podem agilizar a decisão clínica assertiva dos enfermeiros, otimizando tempos e recursos humanos especializados.

Descritores: Inteligência Artificial; Aprendizado de Máquina; Sepse; Tomada de Decisão Clínica; Inovação.

ABSTRACT

Objective: To analyze the critical alarms predictors of clinical deterioration/sepsis for clinical decision making in patients admitted to a reference hospital complex. **Methods:** An observational retrospective cohort study. The Machine Learning (ML) tool, Robot Laura[®], scores changes in vital parameters and lab tests, classifying them by severity. Inpatients and patients over 18 years of age were included. **Results:** A total of 122,703 alarms were extracted from the platform, classified as 2 to 9. The pre-selection of critical alarms (6 to 9) indicated 263 urgent alerts (0.2%), from which, after filtering exclusion criteria, 254 alerts were delimited for 61 inpatients. Patient mortality from sepsis was 75%, of which 52% was due to sepsis related to the new coronavirus. After the alarms were answered, 82% of the patients remained in the sectors. **Conclusions:** Far beyond technology, ML models can speed up assertive clinical decisions by nurses, optimizing time and specialized human resources. **Descriptors:** Artificial Intelligence; Machine Learning; Sepsis; Clinical Decision Support; Innovation.

RESUMEN

Objetivo: Analizar alarmas críticas predictoras de deterioración clínica/sepse para toma de decisiones clínicas en pacientes internados en complejo hospitalario de referencia. **Métodos:** Estudio observacional de cohorte retrospectivo. La herramienta *Machine Learning* (ML), Robot Laura[®], puntúa alteraciones en parámetros vitales y exámenes laboratoriales, clasificándolos por gravedad. Incluyeron pacientes internados y mayores de 18 años. **Resultados:** Extrajeron 122.703 alarmas de la plataforma, clasificadas de 2 hasta 9. La preselección de alarmas críticas (6 a 9) apuntó 263 alertas urgentes (0,2%), entre ellas, después del filtro de criterios de exclusión, delimitaron 254 alertas para 61 pacientes internados. La mortalidad de pacientes por sepsis fue de 75%, entre ellos 52% debido a sepsis relacionada al nuevo coronavirus. Después de las alarmas ser atendidas, 82% de los pacientes permanecieron en los sectores. **Conclusiones:** Más allá de la tecnología, modelos de ML pueden agilizar la decisión clínica assertiva de enfermeros, optimizando tiempos y recursos humanos especializados.

Descriptorios: Inteligencia Artificial; Aprendizaje Automático; Sepsis; Toma de Decisiones Clínicas; Inventiones.

INTRODUÇÃO

Estimativas mostram que a sepse é uma das principais causas de mortalidade global⁽¹⁾, sendo que, no Brasil, a taxa de mortalidade pode ultrapassar 55,7%, conforme estudo multicêntrico conduzido em centros de terapia intensiva, onde um terço dos leitos foram ocupados por pacientes sépticos⁽²⁾. Definida pelo último consenso como “disfunção orgânica ameaçadora da vida provocada por uma resposta exacerbada do hospedeiro a uma infecção”, a sepse necessita de diagnóstico precoce para um prognóstico mais favorável^(1,3).

Em seu prognóstico, o tratamento bem-sucedido é tempo-dependente, em que as recomendações para início de antibioticoterapia nas primeiras horas de apresentação da doença e monitoramento em tempo hábil interferem positivamente nos desfechos. Embora altamente desejável, o diagnóstico precoce é desafiador dada a natureza inespecífica dos sinais e sintomas, bem como sua semelhança com outras patologias⁽⁴⁻⁵⁾. Nesse cenário de assistência ao paciente com sepse, é fundamental a atuação da equipe multidisciplinar, com destaque para a equipe de enfermagem, pois está na beira do leito, prestando assistência, acompanhando e avaliando os desdobramentos da internação⁽⁶⁾.

Uma alternativa para auxiliar na tomada de decisão dos enfermeiros seria uma ferramenta tecnológica de triagem que identificasse pacientes em alto risco de sepse e permitisse tanto maiores taxas de diagnóstico precoce como um melhor aproveitamento de recursos humanos especializados. Por meio da coleta e avaliação de variáveis fisiológicas contínuas, tais como sinais vitais, usando algoritmos sofisticados de classificação, a inteligência artificial (IA) tem o potencial de fornecer detecção oportuna e precisa da sepse, ultrapassando as pontuações de alerta clínico atuais, que se baseiam em modelos matemáticos não tão avançados⁽⁷⁻⁹⁾.

Dessa forma, um sistema de apoio à decisão baseado em algoritmos de *Machine Learning* - ML (aprendizagem de máquina), treinados em dados de pacientes, geralmente baseados em prontuários eletrônicos, sinais vitais e/ou resultados de laboratório, poderia sustentar e encorajar a detecção precoce da sepse. O Robô Laura[®] é um sistema especialista em avaliação da deterioração clínica, cujo objetivo é se integrar a ambientes de dados para coletá-los, organizá-los e, por fim, executar cálculos estatísticos complexos, comparar resultados com faixas probabilísticas e concluir com precisão sobre as condições favoráveis, ou não, para ocorrência de um evento de risco⁽⁹⁾.

Tecnologias como ML continuam melhorando a precisão das previsões clínicas, mas, mesmo um modelo de previsão perfeitamente calibrado, pode não se traduzir em melhores cuidados clínicos. Uma previsão assertiva sobre um paciente não determina como mudar esse resultado; na verdade, não se pode sequer assumir que é possível mudar os resultados previstos⁽¹⁰⁻¹¹⁾. Nesse contexto, devem ser consideradas as dimensões e infraestrutura da instituição, seu sistema de informações e qualidade dos registros. Deve-se considerar que a dinâmica de trabalho dos enfermeiros e demais membros da equipe de saúde é intensa, na qual os registros são deixados, eventualmente, num segundo plano.

Ganhar agilidade para tomadas de decisões assertivas, principalmente em momentos peculiares como durante a pandemia de

COVID-19, quando as equipes de saúde estão sobrecarregadas, torna a IA uma ferramenta útil num cenário desfavorável e desafiador.

Entretanto, o uso de IA introduz, simultaneamente, certa desconfiança em relação à tecnologia devido a um possível impacto negativo sobre a equipe de enfermagem⁽¹²⁾. Isso coloca em questão quais vantagens e desvantagens os enfermeiros encontram na utilização de IA como preditor de sepse na sua rotina.

Para uma interpretação fidedigna dos registros, não basta minerar/capturar os dados sem que estes estejam correlacionados com a patologia de base e evolução esperada para cada caso, conforme os protocolos clínicos institucionais. Muito além da tecnologia, a lacuna da interface entre os registros dos prontuários eletrônicos (sinais vitais e outras informações simultâneas) e a real situação clínica do paciente justifica esta pesquisa, que busca elucidar se a tomada de decisão da equipe assistencial, nos casos de deterioração clínica/sepse, pode ser apoiada pela IA.

OBJETIVO

Analisar os alarmes críticos preditores de deterioração clínica/sepse para tomada de decisão clínica nos pacientes internados em complexo hospitalar de referência.

MÉTODOS

Aspectos éticos

Esta pesquisa obteve Certificado de Apresentação de Apreciação Ética emitido pelo Comitê de Ética em Pesquisa das instituições envolvidas e respeitou a Resolução N°466/2012 do Conselho Nacional de Saúde em todas as etapas.

Desenho, período e local do estudo

Estudo observacional de coorte norteado pela ferramenta STROBE⁽¹³⁾, realizado no período de março a setembro de 2020, em um complexo hospitalar de referência do município de Porto Alegre, estado do Rio Grande do Sul (RS), Brasil.

Descrição da ferramenta de *Machine Learning*

O Robô Laura[®] é um sistema especialista em avaliação da deterioração clínica, cujo objetivo é se integrar a ambientes de dados para coletá-los, organizá-los e, por fim, executar cálculos estatísticos complexos, comparar resultados com faixas probabilísticas e concluir com precisão sobre as condições favoráveis, ou não, para ocorrência de um evento de risco. Os algoritmos de aprendizagem de máquinas utilizados pelo Robô Laura[®] são baseados em sinais vitais e informações do prontuário dos pacientes. Dois algoritmos são utilizados, em conjunto: máquinas de suporte vetorial e redes neurais artificiais (*Support Vector Machines and Artificial Neural Networks*). A saída é uma média do índice de deterioração do paciente de ambos os algoritmos⁽¹⁴⁾.

Além disso, os programadores “ensinam” ao sistema o protocolo de sepse adotado na instituição, de maneira que possa classificar os pacientes com risco de deterioração clínica/sepse. O robô minera dados do histórico e dos exames laboratoriais do prontuário eletrônico do paciente, classifica a gravidade somando 1 ou 2

pontos para cada parâmetro alterado (valores crescentes de 2 a 9, ilustrados na seção “Material suplementar”) e avisa a equipe assistente mediante telas implantadas em locais estratégicos no hospital. Essas informações permanecem alertando a equipe até sua intervenção ou registro de novos dados corrigidos no sistema.

A coleta de dados ocorreu em duas etapas: na primeira, foram exportados da plataforma manualmente, tabulados e organizados em tabelas do programa Microsoft Excel[®]; na segunda, pesquisou-se no prontuário eletrônico do paciente em busca do tempo de resposta da equipe, intervenções realizadas, tempo de internação e desfechos (alta, óbito por sepse e outras causas).

Amostra, critérios de inclusão e exclusão

Foram avaliados os alarmes críticos (6 a 9) registrados pelo Robô Laura[®] no período descrito, totalizando 263 alertas urgentes para 61 pacientes. Os critérios de elegibilidade estabeleceram: pacientes maiores de 18 anos, internados, sinalizados com alerta de alteração de parâmetros clínicos pelo robô (frequências cardíaca e respiratória, pressão arterial, temperatura axilar, glicemia capilar, hemograma, plaquetas, eletrólitos, entre outros), conforme protocolo institucional disponível como material suplementar. Como critérios de exclusão: tempo mínimo de internação inferior a 48 horas, pacientes em cuidados paliativos com descrição de medidas exclusivas de conforto, alarmes inferiores a 6. Foram considerados positivos para COVID-19 os pacientes com teste RT-PCR registrados nos prontuários.

Análise estatística

Os resultados das variáveis qualitativas foram apresentados por meio de frequência e percentual; a idade e o percentual de atendimento, em média e desvio-padrão; e as demais variáveis quantitativas, em mediana e percentis 25 e 75. O percentual de atendimento foi calculado como a razão entre a quantidade de alarmes atendidos sobre a quantidade de alarmes de cada paciente vezes 100. Também foi calculada a quantidade de cada tipo de alarme. As correlações das quantidades de alarmes e percentual de atendimento com o tempo de internação foram verificadas pelo coeficiente de correlação de Spearman; com o óbito e COVID-19, por meio do teste Mann-Whitney; e com as demais variáveis, foi utilizado o teste Kruskal-Wallis com teste de Dunn para as comparações múltiplas. Foram considerados significativos os resultados cujo valor de *p* era menor que 0,05, e as análises foram realizadas no software estatístico SPSS (IBM-SPSS-Statistics for Windows, Version 25.0. Armonk, NY: IBM Corp.).

RESULTADOS

Foram extraídos 122.703 alarmes da plataforma, classificados desde a pontuação 2 até 9. A pré-seleção dos alarmes críticos (de 6 a 9) apontou 263 alertas urgentes, dos quais, após o filtro de critérios de exclusão, delimitaram-se 254 alertas (0,2%) para 61 pacientes internados.

A Tabela 1 caracteriza os alarmes atendidos. A idade média dos pacientes foi de 61 anos, em uma amostra de adultos e idosos, com predominância do sexo feminino (62%). A mortalidade dos pacientes por sepse foi de 75%, dos quais 52% por causa de sepse relacionada à COVID-19.

Os pacientes monitorados pelo Robô Laura[®] são acompanhados por uma variedade de especialidades médicas, a qual se justifica por se tratar de um complexo hospitalar de referência, cujos atendimentos absorvem os mais diversos casos (Tabela 1). Destaca-se que os pacientes da onco-hematologia concentraram a maior quantidade de alarmes 33%, seguidos de doentes acometidos por patologias renais (18%), respiratórias (10%) e gastrointestinais (10%).

Os óbitos de sepse por COVID-19 superaram o número de testados em função de diagnóstico clínico ou por meio de exames de imagem.

Cabe ressaltar que todos os alarmes foram respondidos na primeira hora, conforme preconizado pelo protocolo de sepse institucional; e 82% dos pacientes receberam alguma intervenção. Quanto à criticidade, a faixa de alarme 6 obteve mais prevalência de alarmes, algumas vezes para o mesmo paciente.

A mortalidade associada à sepse por COVID-19 atingiu 52% (n = 24) dos pacientes em estudo (Tabela 2). Para esse grupo, os alarmes tipo 6 foram mais prevalentes, cujos intervalos interquartís ilustram a oscilação de quantidades de alarmes para cada grupo: alta, óbito por sepse e sepse por COVID-19.

Nota-se, na Tabela 3, que 82% (n = 50) dos pacientes permaneceram em suas unidades originais, 15% (n = 9) foram transferidos à unidade de terapia intensiva (UTI). Entre os pacientes que foram manejados em unidades de internação ou pronto atendimento, encontram-se doentes renais crônicos, cujos alarmes de eletrólitos alterados eram da categoria de risco na faixa 6.

Tabela 1 – Caracterização da amostra e desfechos mensurados

	Todos (N = 61)	Óbito por sepse (n = 19)	Óbito por sepse COVID-19 (n = 24)
Idade, anos	61,3 ± 14,6	61,2 ± 14,8	62,0 ± 14,8
Sexo masculino, n (%)	23 (38)	12 (63)	17 (71)
Sexo feminino, n (%)	38 (62)	7 (37)	7 (29)
Patologias de base			
Sistema renal	11 (18)	5 (26)	4 (17)
Sistema cardiovascular	5 (8)	1 (5)	3 (12)
Sistema respiratório	6 (10)	1 (5)	4 (17)
Sistema neurológico	7 (11)	2 (11)	1 (4)
Sistema gastrointestinal	6 (10)	2 (11)	0 (0)
Onco-hematologia	20 (33)	7 (37)	8 (33)
Traumatologia	2 (3)	1 (5)	0 (0)
Sem informação	4 (7)	0 (0)	4 (17)
Transferência até 24 h, n (%)			
Para unidade de terapia intensiva	9 (15)	5 (26)	3 (12)
Para unidade de internação	2 (3)	1 (5)	1 (4)
Permaneceram no setor	50 (82)	13 (69)	20 (84)
Transferência após 24 h, n (%)			
Para unidade de terapia intensiva	3 (5)	1 (5)	1 (4)
Para unidade de internação	26 (43)	8 (42)	18 (75)
Permaneceram no setor	32 (52)	10 (53)	5 (21)
Testagem para COVID-19			
Positivo, n (%)	21 (35)	1 (5)	19 (79)*
Negativo, n (%)	7 (11)	2 (11)	3 (12)
Sem informação, n (%)	33 (54)	16 (84)	2 (9)*
Tempo de internação, dias	50 (20-87)	51 (22-85)	39 (17-88)
Desfecho, n (%)			
Alta	15 (25)	-	-
Óbito geral	46 (75)	-	-

Valores apresentados em média ± desvio-padrão ou mediana (intervalo interquartil) e n (%); *P < 0,05

Tabela 2 – Alarmes e desfechos em pacientes monitorados por inteligência artificial

	Não (Alta) (n = 15)	Óbito por Sepse Sim (n = 22)	Sepse por COVID-19 (n = 24)
Quantidade de alarme geral	1,0 (1,0-2,0)	1,0 (1,0-2,0)	1,0 (1,0-8,5)
Quantidade de alarme geral atendido, %	100 (0-100)	100 (100-100)	100 (100-100)
Quantidade de alarme			
Tipo 6	1,0 (1,0-2,0)	1,0 (0,0-2,0)	1,0 (0,0-6,5)
Tipo 7	0,0 (0,0-0,0)	0,0 (0,0-1,0)	1,0 (0,0-1,0)*
Tipo 8	0,0 (0,0-0,0)	0,0 (0,0-0,0)	0,0 (0,0-0,0)
Tipo 9	-	-	-

Valores apresentados em mediana (intervalo interquartil); *P < 0,05 entre os grupos Óbito por sepse COVID-19 e Óbito não COVID-19

Tabela 3 – Alarmes e transferências até 24 h em pacientes monitorados por inteligência artificial

	Permaneceu no setor (n = 50)	Transferência UTI (n = 9)	UI (n = 2)
Quantidade de alarme geral	1,0 (1,0-3,0)	1,0 (1,0-2,0)	1,0 (1,0-1,0)
Quantidade de alarme geral atendido, %	100 (70-100)	100 (100-100)	100 (100-100)
Quantidade de alarme			
Tipo 6	1,0 (1,0-3,0)	1,0 (0,0-1,0)	0,0 (0,0-0,0)
Tipo 7	0,0 (0,0-1,0)	0,0 (0,0-1,0)	1,0 (1,0-1,0)
Tipo 8	0,0 (0,0-0,0)	0,0 (0,0-1,0)	0,0 (0,0-0,0)*
Tipo 9	-	-	-

Valores apresentados em mediana (intervalo interquartil); UI – unidade de internação; UTI – unidade de terapia intensiva; *P < 0,05 entre os grupos Permaneceu no setor e Transferência para UTI

DISCUSSÃO

Foram analisados mais de 122 mil alertas, dos quais 0,2% pertencentes à faixa crítica (de 6 a 9), com necessidade de intervenção urgente. A plataforma “anula” o alerta quando identifica que houve resolução. Por exemplo, uma alteração na temperatura axilar será corrigida automaticamente quando um novo registro, dentro dos parâmetros do protocolo, for realizado. A faixa crítica é atingida quando o paciente possui vários parâmetros alterados ou não houve registro atualizado da correção ou ajuste fisiológico. Entende-se que os pacientes são heterogêneos e vulneráveis quando em risco de sepse, associado a doenças subjacentes⁽¹⁵⁾. Dessa maneira, a terapia deve ser necessariamente personalizada e adaptada para atender às exigências de cada indivíduo. Nesse caso, o registro fidedigno e atualizado é fundamental, além de ser prerrogativa legal⁽⁹⁾. Por outro lado, a dinâmica de trabalho dos profissionais de saúde é intensa, em que os registros são deixados, eventualmente, num segundo plano.

Quanto à sensibilidade e refinamento do protocolo, os alarmes críticos de nosso estudo apontaram deterioração clínica para variadas patologias de base, em pacientes de especialidades distintas, porém monitorados pelo mesmo protocolo. Os óbitos por sepse nos transplantados renais acometeu 82% dos casos, porém essa população é imunossuprimida e mais suscetível às infecções, assim como toleram níveis de eletrólitos diferenciados. Nessa linha de raciocínio, a onco-hematologia concentrou 75% de mortalidade nos doentes internados⁽¹⁶⁾. Tal cenário multifacetado permite discussões profundas acerca do refinamento das informações introduzidas no modelo de ML.

Pode-se compreender a resistência da equipe de enfermagem em uma unidade de internação para doentes renais crônicos, com inúmeros alertas disparando. No entanto, os níveis sorológicos de

eletrólitos e creatinina nesses casos são tolerados num patamar distinto dos demais pacientes. Para tais ajustes, respeitando as peculiaridades das especialidades, a participação e expertise dos enfermeiros especialistas se faz necessária. Nesse contexto, devem ser consideradas as dimensões e infraestrutura da instituição, seu sistema de informações e qualidade dos registros⁽¹⁷⁻¹⁸⁾. Pruinelli defende que “modelos da IA precisam ser construídos de forma segura, ética e centrada no ser humano”⁽¹⁹⁾. Dessa forma, os modelos acompanhariam a progressão das doenças, respeitando sua trajetória temporal e auxiliando na prestação de cuidados^(12,19). O refinamento dos parâmetros informados para a ferramenta ML é crucial para seu desempenho respeitando as peculiaridades do público atendido.

Nossos achados de alarmes críticos mais prevalentes nos pacientes com diagnóstico confirmado de sepse reforçam revisão conduzida na Espanha, na qual se afirma que ML e técnicas relacionadas podem melhorar o desempenho geral das equipes por meio de uma combinação de indicadores, já em uso com outras variáveis clínicas, todas as quais são medidas rotineiramente na prática clínica⁽²⁰⁾. Apesar de promissor, o uso de IA não pode substituir o manejo clínico da sepse por parte da equipe. Assim, a seleção das estratégias de tratamento mais apropriadas ainda exige o julgamento clínico da equipe assistencial, o exame físico do paciente e um profundo conhecimento de seu histórico⁽²¹⁾. Os modelos de IA podem nos auxiliar na identificação dos pacientes que requerem mais atenção a fim de concentrarmos tempo e recursos (humanos e logísticos) individualizando cada caso. Servem, inclusive, para gerenciar os recursos humanos especializados, escassos e exauridos durante o enfrentamento da pandemia de COVID-19.

Os enfermeiros possuem as habilidades e competências para identificar precocemente a sepse, além do fato de estarem de modo

ininterrupto ao lado do paciente. As ferramentas de IA contribuem para direcionar a atenção da equipe aos casos mais instáveis, para ajudar enfermeiros e equipe assistencial a fazer julgamentos assertivos, obter informações corretas a fim de apoiar a melhor tomada de decisões clínicas⁽¹⁸⁾. Consequentemente, colaboram na oferta de cuidados oportunos e precisos, o que pode afetar significativamente a prática baseada em evidências dos enfermeiros, melhorar a qualidade dos cuidados clínicos e dos resultados, diminuir os custos e garantir a segurança dos pacientes.

Neste estudo, grande parte dos doentes permaneceram nos setores de origem (Tabela 2), seja pronto atendimento, sejam unidades de internação, onde o tempo de internação é prolongado (20 a 87 dias). Em razão dos alarmes críticos disparados nesses locais, são as unidades de internação que requerem atenção quanto ao risco de sepse. Os achados desta pesquisa ratificam um estudo multicêntrico retrospectivo, que contou com um banco de dados de mais 50 mil pacientes e testou um modelo preditor de sepse nas 24 horas anteriores ao diagnóstico clínico recebido: tais resultados confirmaram a capacidade de modelos ML, comparados aos escores-padrão-ouro relacionados à sepse⁽⁷⁾. A triagem da sepse deveria ser integrada como parte de avaliações rotineiras de pacientes e rondas de cuidados com os pacientes internados.

Visto que os enfermeiros desempenham um papel significativo na identificação de pacientes com sepse mediante sua posição única de ter interação constante com o paciente, devem ser incluídos no desenvolvimento tanto de protocolos à beira leito quanto de modelos de IA^(12,22). Inclusive, segundo a *Nursing and Artificial Intelligence Leadership Collaborative* (NAAIL), há uma necessidade, por parte das lideranças de enfermagem, de apropriarem-se de modelos de IA a fim de otimizar a prestação de cuidados de enfermagem e liberar tempo para os enfermeiros gastarem no cuidado direto (versus indireto) do paciente. Outro benefício das tecnologias de IA seria o potencial de impulsionar competências e estimular que os enfermeiros forneçam um atendimento mais baseado em evidências e personalizado a seus pacientes.

Além disso, a IA pode ajudar os profissionais de saúde a fazer julgamentos corretos, obter informações precisas, no momento certo, para apoiar a melhor tomada de decisões clínicas e fornecer cuidados oportunos aos pacientes. Tal dinâmica se daria “através da difusão de conhecimentos cognitivos e apoio à tomada de decisão”⁽¹⁹⁾, por meio da visualização das tendências do paciente, que podem fornecer subsídios tanto para o cuidado imediato do paciente como para o planejamento e gerenciamento em longo prazo^(12,18).

Como vantagens, dentro de um contexto de saúde desigual, as aplicações de IA para a sepse podem oferecer muitas oportunidades onde faltam recursos e experiência, tornando-se uma “alavanca para fornecer acesso a cuidados de saúde universais, de alta qualidade e acessíveis para todos”. Entretanto, se a implementação dessa tecnologia não for enquadrada como parte de uma estratégia global de desenvolvimento sustentável, a IA pode exacerbar as questões de saúde pública em países que já lidam com problemas e urgências substanciais⁽²³⁾. Para equilibrar esta balança, devem ser encontradas alternativas dentro das próprias instituições, incluindo e treinando as equipes, buscando a inovação nos processos assistenciais, no sentido de repensar, redescobrir, inventar-se dentro de cada realidade.

Limitações do estudo

A pandemia de COVID-19 afetou os serviços de saúde de inúmeras maneiras, com repercussões em maior ou menor grau nas diversas áreas. Como conduzimos nossa pesquisa nesse período, isso modificou os processos e fluxos assistenciais e gerenciais da instituição que sediou o estudo.

Tal fato influenciou e limitou nossa amostra. Se a intenção das pesquisas é generalizar seus achados, durante a pandemia nossa amostra pode ter revelado os doentes mais graves, pois os atendimentos eletivos foram suspensos. Outro fator a ser considerado é a posição de referência ocupada pela instituição, para a qual os casos mais graves convergem.

Ademais, houve descaracterização sofrida pelos setores, pois os casos de COVID-19 foram recebidos onde havia leitos. Em consequência, as equipes foram realocadas e levadas à exaustão. Se, com um cenário favorável, já existe carência nos registros e retardo nas informações dos prontuários, pode-se imaginar um cenário caótico quando há necessidade de registros para desencadear um alerta de risco.

Contribuições para a Área da Saúde e Enfermagem

Esta pesquisa valoriza o debate sobre IA e ML relacionado à sepse, em um complexo hospitalar de referência, onde o refinamento dos processos assistenciais associados à tecnologia podem repercutir em melhorias no longo prazo. Também, ressalta a relevância da inclusão e participação ativa dos enfermeiros no desenvolvimento, implantação e alinhamento de modelos de IA relacionados à sua área de inserção.

Para tanto, esses profissionais devem vencer a resistência natural perante a inovação, a desconfiança diante da tecnologia em razão do receio de serem substituídos. É necessário “conhecer as possibilidades de ação em cenários de inovação tecnológica”⁽⁹⁾, visto que o Robô Laura* alerta para o risco de sepse, mas a interpretação desse risco é uma etapa fundamental do processo, que pode contribuir para um atendimento mais seguro, eficaz, baseado na tecnologia e centrado no paciente.

CONCLUSÕES

Muito além da tecnologia, modelos de ML podem agilizar a decisão clínica assertiva dos enfermeiros, por meio dos alarmes críticos, otimizando tempo e recursos humanos especializados.

Após analisarmos os alertas críticos preditores de deterioração clínica/sepse, nossos resultados sugerem que a IA pode sustentar decisões clínicas assertivas, desde que respeitados alguns pré-requisitos: adaptação dos protocolos com base nos perfis dos pacientes-alvo e envolvimento da equipe multiprofissional, com destaque aos enfermeiros, pela presença ininterrupta ao lado dos pacientes.

Sugere-se que as equipes de desenvolvimento de IA na área da saúde sejam interdisciplinares, incluindo enfermeiros, para garantir que as contribuições dos membros das equipes de informática e engenharia estejam alinhadas a realidades clínicas e ajustadas aos pacientes. Tais ferramentas estão e serão cada vez mais inseridas no ambiente de saúde, amparando e agilizando

as condutas, permitindo decisões mais assertivas. Entretanto, as questões éticas e morais relacionadas aos desfechos dos doentes sempre serão responsabilidade das equipes, as quais conhecem e estão envolvidas com as pessoas para além da tecnologia.

MATERIAL SUPLEMENTAR

Protocolo de alertas do Robô Laura®. <https://doi.org/10.48331/scielodata.PHGO2Q>

REFERÊNCIAS

1. Singer M, Deutschman CS, Seymour CW, Shankar-Hari M, Annane D, Bauer M. The Third International Consensus Definitions for Sepsis and Septic Shock (Sepsis-3). *JAMA*. 2016;2017;114(29–30):801–10. <https://doi.org/10.1001%2Fjama.2016.0287>
2. Machado FR, Cavalcanti AB, Bozza FA, Ferreira EM, Angotti Carrara FS, Sousa JL, et al. The epidemiology of sepsis in Brazilian intensive care units (the Sepsis PREvalence Assessment Database, SPREAD): an observational study. *Lancet Infect Dis*. 2017;17(11):1180–9. [https://doi.org/10.1016/S1473-3099\(17\)30322-5](https://doi.org/10.1016/S1473-3099(17)30322-5)
3. Levy MM, Evans LE, Rhodes A. The surviving sepsis campaign bundle: 2018 update. *Crit Care Med*. 2018;46(6). <https://doi.org/10.1007/s00134-018-5085-0>
4. Pepic I, Feldt R, Ljungström L, Torkar R, Dalevi D, Maurin Söderholm H, et al. Early detection of sepsis using artificial intelligence: a scoping review protocol. *Syst Rev*. 2021;10(1). <https://doi.org/10.1186/s13643-020-01561-w>
5. Kaukonen K-M, Bailey M, Pilcher D, Cooper DJ, Bellomo R. Systemic inflammatory response syndrome criteria in defining severe sepsis. *N Engl J Med*. 2015;17:1629–67. <https://doi.org/10.1056/nejmc1506819>
6. Jost MT, Machado KPM, Oliveira APA, Costa Linch GF, Paz AA, Aquino Caregnato RC, et al. Morbimortalidade e custo por internação dos pacientes com sepse no Brasil, Rio Grande do Sul e Porto Alegre. *Rev Epidemiol Control Infecção*. 2019;9(2). <https://doi.org/10.17058/reci.v9i2.12723>
7. Mao Q, Jay M, Hoffman JL, Calvert J, Barton C, Shimabukuro D, et al. Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU. *BMJ Open*. 2018;8(1). <https://doi.org/10.1136/bmjopen-2017-017833>
8. Yee CR, Narain NR, Akmaev VR, Vemulapalli V. A Data-Driven Approach to Predicting Septic Shock in the Intensive Care Unit. *Biomed Inform Insights*. 2019;11:117822261988514. <https://doi.org/10.1177%2F1178222619885147>
9. Gonçalves LS, Amaro MLM, Romero ALM, Schamne FK, Fressatto JL, Bezerra CW. Implementation of an Artificial Intelligence Algorithm for sepsis detection. *Rev Bras Enferm*. 2020;73(3). <https://doi.org/10.1590/0034-7167-2018-0421>
10. Chen JH, Asch SM. Machine Learning and Prediction in Medicine—Beyond the Peak of Inflated Expectations HHS Public Access. *N Engl J Med [Internet]*. 2017[cited 2021 Jul 10];376(26):2507–9. Available from: www.gartner.com/newsroom/id/3412017
11. Cesario EO, Nakamura CY, Gumiel YB, Carvalho DR. Técnicas de inteligência artificial para reconhecimento de sepse em ambientes hospitalares: revisão integrativa. *Rev Gestão Sist Saúde*. 2020;9(1):15–31. <https://doi.org/10.5585/rgss.v9i1.13932>
12. Ronquillo EC, Peltonen L-M, Pruinelli L, Chu GNC, Bakken FAANS, Beduschi LLBA, et al. Artificial intelligence in nursing: Priorities and opportunities from an international invitational think-tank of the Nursing and Artificial Intelligence Leadership Collaborative. *J Adv Nurs*. 2021;00:1–11. <https://doi.org/10.1111/jan.14855>
13. STROBE Statement-checklist of items that should be included in reports of observational studies [Internet]. 2015[cited 2021 Jul 10]. Available from: https://www.equator-network.org/wp-content/uploads/2015/10/STROBE_checklist_v4_combined.pdf
14. Kalil AJ, Dias VMCH, Rocha CC, Morales HMP, Fressatto JL, Faria RA. Sepsis risk assessment: A retrospective analysis after a cognitive risk management robot (Robot Laura®) implementation in a clinical-surgical unit. *Res Biomed Eng*. 2018;34(4):310–6. <https://doi.org/10.1590/2446-4740.180021>
15. ILAS. Roteiro de implementação de protocolo gerenciado de sepse: programa de melhoria de qualidade [Internet]. 2019[cited 2021 Jul 10]. Available from: www.ilas.org.br
16. Rhodes A, Evans LE, Alhazzani W, Levy MM, Antonelli M, Ferrer R, et al. *Sobrevivendo Sepsis 2016*. Vol. 43, Intensive Care Medicine. Springer Berlin Heidelberg; 2017. 304–377 p. <https://doi.org/10.1007/s00134-017-4683-6>
17. Poulos J, Zhu L, Shah AD. Data gaps in electronic health record (EHR) systems: an audit of problem list completeness during the COVID-19 pandemic. *Int J Med Inform*. 2021;150:104452. <https://doi.org/10.1016/j.ijmedinf.2021.104452>
18. Zhu R, Han S, Su Y, Zhang C, Yu Q, Duan Z. The application of big data and the development of nursing science: a discussion paper. *Int J Nurs Sci*. 2019;6(2):229–34. <https://doi.org/10.1016%2Fj.ijnss.2019.03.001>
19. Pruinelli L. Nursing and Data: Powering Nursing Leaders for Big Data Science. *Rev Bras Enferm*. 2021;74(4). <https://doi.org/10.1590/0034-7167.2021740401>
20. Vellido A, Ribas V, Morales C, Ruiz Sanmartín A, Ruiz Rodríguez JC. Machine learning in critical care: state-of-the-art and a sepsis case study. *Biomed Eng*. 2018;17(S1):1–18. Available from: <https://doi.org/10.1186/s12938-018-0569-2>
21. Garnacho-Montero J, Martín-Loeches I. Clinical management of sepsis can be improved by artificial intelligence: Vol. 46, Intensive Care Medicine. Springer Berlin Heidelberg; 2020. p. 378–80. <https://doi.org/10.1007/s00134-020-05947-1>

22. Kleinpell R. Promoting early identification of sepsis in hospitalized patients with nurse-led protocols. *Crit Care*. 2017;21(1):10. Available from: <https://doi.org/10.1186/s13054-016-1590-0>
 23. Alami H, Rivard L, Lehoux P, Hoffman SJ, Bernadette S, Cadeddu M, et al. Artificial intelligence in health care: laying the Foundation for Responsible, sustainable, and inclusive innovation in low-and middle-income countries. <https://doi.org/10.1186/s12992-020-00584-1>
-