

**UNIVERSIDADE NOVE DE JULHO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

GLÓRIA DE FÁTIMA PEREIRA VENTURINI

**INTELIGÊNCIA ARTIFICIAL EM GESTÃO DE OPERAÇÕES DE SAÚDE:
AVANÇOS PARA IDENTIFICAÇÃO PRECOCE DE SINAIS DE DETERIORAÇÃO
CLÍNICA DE PACIENTES**

São Paulo

2021

GLÓRIA DE FÁTIMA PEREIRA VENTURINI

**INTELIGÊNCIA ARTIFICIAL EM GESTÃO DE OPERAÇÕES DE SAÚDE:
AVANÇOS PARA IDENTIFICAÇÃO PRECOCE DE SINAIS DE DETERIORAÇÃO
CLÍNICA DE PACIENTES**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Nove de Julho - UNINOVE, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção.

Orientador: Prof. Dr. Luiz Fernando Rodrigues Pinto

São Paulo

2021

Venturini, Glória de Fátima Pereira.

Inteligência artificial em gestão de operações de saúde: avanços para identificação precoce de sinais de deterioração clínica de pacientes. / Glória de Fátima Pereira Venturini. 2021.

83 f.

Dissertação (Mestrado) – Universidade Nove de Julho - UNINOVE, São Paulo, 2021.

Orientador (a): Prof. Dr. Luiz Fernando Rodrigues Pinto.

1. Inteligência artificial. 2. Monitoramento de pacientes. 3. Sinais vitais. 4. Deterioração clínica. 5. Gestão de operações.

I. Pinto, Luiz Fernando Rodrigues. II. Título

CDU 658.5



PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE DISSERTAÇÃO

DE

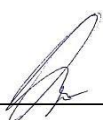
Glória de Fátima Pereira Venturini

Título da Dissertação: Inteligência Artificial em Gestão de Operações de Saúde: Avanços para Identificação Precoce de Sinais de Deterioração Clínica de Pacientes.

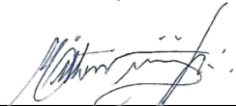
A Comissão examinadora, composta pelos professores abaixo, considera o(a) candidato(a) Glória de Fátima Pereira Venturini APROVADA.

São Paulo, 18 de agosto de 2021.

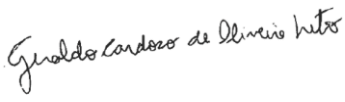
Prof(a). Dr(a). Luiz Fernando Rodrigues Pinto (UNINOVE / PPGEP) - Orientador



Prof(a). Dr(a). Milton Vieira Junior (UNIMEP / PPGEP) - Membro Externo- Membro Externo



Prof(a). Dr(a). Geraldo Cardoso de Oliveira Neto (UNINOVE/PPGEP) - Membro Interno



Dedico este trabalho a meus pais e meu irmão. Vocês são os melhores amigos que alguém poderia ter.

AGRADECIMENTOS

Agradeço imensamente ao Prof. Dr. Luiz, meu orientador, por compartilhar comigo seu conhecimento, por toda a atenção, respeito e paciência, mesmo numa fase tão difícil. Admiro muito seu profissionalismo e sua integridade. Foi uma honra poder contar com você nesta jornada. Serei sempre muito grata.

Ao Prof. Dr. Geraldo, agradeço por ter acreditado em mim. Você foi o responsável pelo início de tudo.

A Thays, que compartilhou comigo cada fase dessa caminhada. Tenho muito orgulho de você.

Ao San, por fazer a vida mais leve e feliz.

A minha família e amigos, que compreenderam minha ausência e, mesmo de longe, me apoiaram e torceram por mim.

RESUMO

Controle de processo é condição base no gerenciamento de operações empresariais. Setores produtivos têm incorporado tecnologias de Indústria 4.0 para aumentar confiabilidade de seus processos, por meio da automatização de coleta de dados e tomada de decisão. O setor de saúde tem como referência práticas de indústrias no gerenciamento de seus processos. No entanto, sistemas médicos ainda estão no modo analógico. Mudanças digitais recentes, como o uso de Inteligência Artificial (IA) em monitoramento de condições clínicas de pacientes, têm aumentado a confiabilidade de processos hospitalares. Apesar de IA estar presente na gestão de hospitais, esta pesquisa identificou ausência de estudo que tenha mostrado resultados clínicos e impactos assistenciais do uso de IA em monitoramento de sinais vitais para redução de riscos de deterioração clínica de pacientes. O objetivo deste estudo foi analisar um sistema de IA utilizado no monitoramento de sinais vitais de pacientes para a redução de riscos de deterioração clínica. O método utilizado foi um estudo de caso realizado em uma instituição hospitalar baseado e fundamentado em revisão sistemática da literatura sobre o tema. Esta pesquisa contribuiu com a comunidade científica por meio da apresentação de evidências estruturadas após a realização de um estudo de caso, bem como avaliação de resultados obtidos frente a implantação de uma nova tecnologia em ambiente hospitalar, permitindo maior conhecimento sobre a área de saúde e a adoção de tecnologias em seus processos. Contribuiu também com a gestão de operações hospitalar visando garantir resultados favoráveis, competitividade no mercado, melhoria contínua de processos e mitigação de danos associados a assistência. Frente a possibilidade de conferir processos assistenciais mais seguros, há contribuições também a sociedade.

Palavras - Chave: Inteligência Artificial, Monitoramento de Pacientes, Sinais Vitais, Deterioração Clínica, Gestão de Operações

ABSTRACT

Process control is a basic condition in business operations management. Productive sectors have incorporated Industry 4.0 technologies to increase the reliability of their processes, through the automation of data collection and decision making. The healthcare sector has industry practices as a reference in managing their processes. However, medical systems are still in analog mode. Recent digital changes, such as the use of Artificial Intelligence (AI) in monitoring patients' clinical conditions, have increased the reliability of hospital processes. Although AI is present in hospital management, this research identified the absence of a study that has shown clinical results and care impacts of the use of AI in monitoring vital signs to reduce the risk of clinical deterioration of patients. The purpose of this study was to analyze an AI system applied to monitor vital signs of patients to reduce the risk of clinical deterioration. The method used was a case study carried out in a hospital institution based on a systematic review of the literature on the subject. This research contributed to the scientific community through the presentation of structured evidence after conducting a case study, as well as evaluating the results obtained from the implementation of a new technology in a hospital environment, allowing greater knowledge about healthcare area and adoption of technologies in their processes. It also contributed to the management of hospital operations to ensure favorable results, competitiveness, continuous improvement of processes and mitigation of harm associated with health care. With the possibility of providing safer care processes, there are also contributions to society.

Keywords: Artificial Intelligence, Patient Monitoring, Vital Signs, Clinical Deterioration, Operations Management

LISTA DE ILUSTRAÇÕES

Gráfico 1: Publicações ao longo dos anos.....	12
Gráfico 2: Publicações por país.....	13
Gráfico 3: Publicações por periódico.....	13
Gráfico 4: Métodos de pesquisa dos artigos.....	14
Gráfico 5: Parâmetros de monitoramento de sinais vitais.....	15
Gráfico 6: Setores de saúde onde foi aplicada IA.....	16
Gráfico 7: Abordagem dos trabalhos.....	30
Gráfico 8: Representatividade dos motivos dos acionamentos de códigos amarelos	48
Gráfico 9: Resultados Assistenciais Gerais.....	50
Figura 1: Condução de estudo de Caso.....	25
Figura 2: Seleção de artigos.....	28
Figura 3: Estrutura da Inteligência Artificial.....	42

LISTA DE TABELAS

Quadro 1: Estrutura conceitual.....	24
Quadro 2: Palavras-chave.....	26
Quadro 3: Agrupamento de palavras-chave.....	26
Quadro 4 Lista de artigos não selecionados	31
Quadro 5: Dados do prontuário eletrônico.....	40
Quadro 6: Parâmetros monitorados no estudo de caso.....	46
Quadro 7: Valores totais dos motivos dos acionamentos.....	46

SUMÁRIO

1 INTRODUÇÃO	4
1.1 CONTEXTUALIZAÇÃO	4
1.2 PROBLEMA DE PESQUISA	5
1.3 OBJETIVO	7
1.4 JUSTIFICATIVA	8
1.5 ESTRUTURA DA DISSERTAÇÃO	10
2 REVISÃO DA LITERATURA	11
2.1 REVISÃO BIBLIOMÉTRICA	11
2.1.1 Publicação ao longo os anos	11
2.1.2 Pais de origem das publicações	12
2.1.3 Periódicos	13
2.1.4 Métodos de pesquisa dos artigos	13
2.1.5 Monitoramento de sinais vitais e deterioração clínica	14
2.1.6 IA em saúde	15
2.2 REVISÃO SISTEMÁTICA DA LITERATURA	16
2.2.1 Monitoramento de Sinais Vitais e Deterioração Clínica	16
2.2.2 Inteligência Artificial em Saúde	18
2.2.3 Modelos e Métodos de Inteligência Artificial	20
2.2.4 Aplicações de inteligência artificial ao monitoramento de pacientes para identificação precoce de deterioração clínica	22
3 METODOLOGIA	25
3.1 MÉTODO PARA REVISÃO DA LITERATURA	25
3.1.1 Palavras-chave	26
3.1.2 Bases de Pesquisa	26
3.1.3 Critério de Seleção dos artigos	27
3.1.4 Etapas de Seleção	27
3.2 MÉTODO ESTUDO DE CASO	34
4 ESTUDO DE CASO	37
4.1 A INSTITUIÇÃO E A IMPLANTAÇÃO DA TECNOLOGIA	37
4.2 COLETA DE DADOS	44
4.3 RESULTADOS CLÍNICOS	48

5 DISCUSSÕES.....	52
6 CONCLUSÃO	56
REFERÊNCIAS BIBLIOGRÁFICAS.....	58

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Nesta seção serão apresentadas informações gerais sobre o contexto no qual o tema de pesquisa está inserido.

Para garantir a sustentabilidade de uma empresa é imprescindível mensurar seu desempenho operacional com o objetivo de promover correta tomada de decisões. Para isso, a estruturação de indicadores de desempenho eficazes permite a avaliação dos processos com o objetivo de reduzir não conformidades e aumentar as oportunidades de sucesso das empresas (HWANG, 2020).

Com foco no crescimento sustentável de uma instituição e num bom nível de competitividade de mercado é necessária gestão e inovação. Desta forma, a utilização de tecnologias pode apoiar o desenvolvimento institucional, pois diverge do tradicional planejamento de processos, independe da subjetividade e interferência de indivíduos quando considerados planejamentos e resultados relacionados a tendências globais e estratégias de mercado (TRSTENJAK, 2020).

Para empresas do ramo da saúde, é necessário compreender as mudanças demográficas e o aumento da complexidade das comorbidades que contribuem para um número crescente de pacientes com doenças crônicas que precisam de tratamento de alta acuidade (KHANNA *et al.*, 2019).

As principais causas globais de morte estão associadas a disfunções cardiovasculares, respiratórias e condições neonatais (WHO, 2020). Estas patologias são frequentemente identificadas já no estágio grave da doença, sendo necessário uma rápida identificação para proporcionar melhora efetiva da condição do paciente (TYLMAN *et al.*, 2016). Apenas um terço da população mundial diagnosticada com hipertensão mantém um controle constante de sua pressão arterial por consequência da indisponibilidade de acesso a sistemas de monitoramento contínuo (EL-HAJJ e PA- KYRIACOU, 2020).

Frente ao aumento do número de pacientes que buscam por atendimento médico, departamentos de emergência são obrigados a utilizar sistemas eficientes para avaliar e gerenciar pacientes, bem como definir prioridades para alocação de recursos (FARAHMAND *et al.*, 2017). Devido à disponibilidade limitada e alto custo de leitos em unidades de terapia intensiva, pacientes são frequentemente admitidos

em outras unidades, principalmente em unidades de tratamento intermediário (HEILI-FRADES *et al.*, 2020).

Sendo os hospitais ambientes complexos com diferentes unidades e níveis de atenção (KAIESKI *et al.*, 2020), admissões não planejadas em unidades de cuidados intensivos estão associadas a aumento da mortalidade, tempo de internação e um impacto econômico significativo (KHANNA *et al.*, 2019). Com o objetivo de apoiar a gestão de leitos e alocação de recursos em instituições de saúde, a adoção de soluções associadas a tecnologia tem sido bem-vinda, e contribui para atendimentos médicos cada vez mais digitalizados (KAIESKI *et al.*, 2020).

A Inteligência Artificial é um exemplo de tecnologia com potencial para agregar valor a processos de saúde. Apresenta uma abordagem interdisciplinar que adota princípios e dispositivos de uma variedade de campos, como computação, matemática, lógica e biologia com o objetivo promover compreensão, modelagem e replicação de processos cognitivos e de inteligência (TRAN *et al.*, 2019a). Ferramentas baseadas em IA têm sido usadas para prever vários fatores envolvendo medicamento, incluindo estratificação de risco, diagnóstico e escolha do tratamento (FARAHMAND *et al.*, 2017).

A identificação precoce dos resultados dos pacientes poderia otimizar o atendimento e reduzir os custos de sistemas de saúde (KAIESKI *et al.*, 2020). Uma ferramenta que possibilite a previsão deve ser capaz de identificar a população com maior risco de falha na assistência (LORETO, LISBOA E MOREIRA, 2020).

No ano de 2019, o COVID-19 foi descoberto e evoluiu para uma pandemia. Para enfrentar esta crise global de saúde, a inteligência artificial (IA) foi uma das tecnologias adotadas em vários níveis da saúde sistema de atendimento (CHEN e SEE, 2020).

1.2 PROBLEMA DE PESQUISA

Nesta seção, serão apresentadas aplicações de IA para o monitoramento de pacientes. Iniciativas relacionadas a redução de riscos assistenciais decorrentes de alterações de sinais vitais de pacientes foram encontradas na literatura.

A natureza complexa da doença crítica exige uma exploração de abordagens alternativas para auxiliar os médicos na definição de diagnósticos e tratamentos oportunos (LAL *et al.*, 2002). Os profissionais de saúde enfrentam o desafio de

interpretar grandes volumes de dados para diagnosticar e tratar pacientes. Um modelo preditivo simples, interpretável e confiável agiliza a tomada de decisão para tratamento de pacientes em ambiente hospitalar (KAIESKI *et al.*, 2020). Há, portanto, uma necessidade de monitoramento contínuo, e de qualidade, de sinais vitais em unidades de internação (KHANNA *et al.*, 2019).

Kruger e Tremper (2011) apresentaram uma revisão do estado da arte para compreender o momento dos hospitais no uso de tecnologias e o aumento de informações disponíveis para profissionais de saúde e evidenciaram oportunidades de estudo no desenvolvimento de algoritmos para integrações e interpretação de dados de saúde, bem como disponibilização de alertas que apoiem as equipes de saúde. Afirmaram que somente o registro e a visualização de informações, como é atualmente o processo de utilização de prontuários eletrônicos de pacientes, não é suficiente para perceber a melhoria da qualidade do atendimento ao paciente. Os dados lá contidos devem ser contínuos e sintetizados de modo a extrair informações críticas que descrevem o estado geral dos pacientes e cuidados necessários.

Khanna *et al.* (2019) apresentaram uma revisão abrangente sobre o monitoramento dos sinais vitais em unidades de internação, denominadas enfermarias. A necessidade de monitoramento cardíaco e respiratório contínuo foi ressaltada, pois são dados dinâmicos. Evidenciaram que o monitoramento de pacientes em pós-operatório está inadequado, pois não detecta alterações sutis dos sinais vitais de pacientes.

O estudo de Kaieski *et al.* (2020) relacionou o uso de IA a análise de sinais vitais de pacientes adultos hospitalizados com o objetivo de melhorar resultados de saúde. Foram evidenciadas pesquisas relacionadas ao tema, porém não encontraram propostas que avaliem isoladamente sinais vitais com o objetivo de prever deterioração clínica.

Tran *et al.* (2019b) afirmaram a falta de relatórios abrangentes sobre a produtividade, fluxo de trabalho, tópicos e pesquisas sobre IA neste campo.

O estudo de Churpek *et al.* (2016) comparou a precisão de diferentes técnicas para detectar a deterioração clínica nas enfermarias utilizando algoritmos conhecidos como aprendizado de máquina e afirmou que o uso de algoritmos pode apoiar a identificação da gravidade dos pacientes.

O desenvolvimento de um algoritmo de IA projetado para o diagnóstico de sepse foi apresentado por Yuan *et al.* (2020), com resultado de 80% de precisão no diagnóstico de sepse.

Gultepe *et al.* (2013) abordou um novo modelo de predição do risco de mortalidade de pacientes de acordo com a avaliação dos níveis de lactato. Este estudo abordou os sinais vitais como apoio para utilização do lactato como ferramenta principal para identificar o risco de deterioração clínica característica de sepse. Resultados positivos foram evidenciados quando registros de saúde foram realizados em tempo adequado para sua interpretação.

No estudo de Kaieski *et al.* (2020), que apresentou uma revisão da literatura sobre propostas de implantação de I.A. em saúde, não foram identificadas abordagens sobre a participação de profissionais de saúde para projetar e testar os modelos de IA, o que poderia representar um limitador significativo para avanços práticos na área da saúde. Khanna *et al.* (2019), ao abordarem a utilização de sensores sem fio para o monitoramento contínuo de pacientes, afirmaram que não há ensaios clínicos robustos evidenciando as contribuições do monitoramento contínuo de pacientes com relação a resultados graves, como mortalidade e/ou lesão miocárdica em pacientes.

Diversas iniciativas relacionadas a estrutura de sistemas de IA aplicadas a saúde foram evidenciadas em literatura. Abordagens relacionadas a identificação de diagnósticos específicos, estruturação de mecanismos para implantação de algoritmos que contribuem para a predição de deterioração clínica. No entanto, não foi evidenciado estudo que tenha realizado a análise de iniciativas de utilização de IA em monitoramento de sinais vitais para reduzir riscos de deterioração clínica de pacientes, com a apresentação de resultados clínicos e impactos assistenciais da aplicação desta tecnologia.

As constatações identificadas na literatura sugerem a seguinte questão de pesquisa: O uso de IA em monitoramento de sinais vitais contribui para melhorar a identificação precoce de deterioração clínica de pacientes?

1.3 OBJETIVO

Com o intuito de obter a resposta à pergunta levantada por esta pesquisa, o objetivo geral deste estudo foi levantar e analisar a aplicação de IA no monitoramento de sinais vitais de pacientes para redução de riscos de deterioração

clínica O objetivo geral deste trabalho foi desdobrado em quatro objetivos específicos:

(i) Encontrar na literatura as aplicações de IA no monitoramento de sinais vitais para identificação precoce de riscos de deterioração clínica;

(ii) Identificar nos artigos os parâmetros de monitoramento e seus propósitos;

(iii) Analisar o uso de um sistema de IA em hospital para identificação precoce de deterioração clínica por meio de estudo de caso em um hospital geral do estado de São Paulo.

(iv) Comparar os resultados de identificação precoce de deterioração clínica de pacientes antes e depois da implantação da IA.

1.4 JUSTIFICATIVA

Esta seção evidencia a relevância deste tema, bem como contribui para fortalecer a necessidade de desenvolver conteúdo científico relevante sobre a aplicação de tecnologias em gestão de operações na área da saúde.

Instituições médicas em todo o mundo enfrentam cargas de trabalho maiores devido à escassez de mão de obra qualificada e custo crescente. Desta forma, a implementação sustentável e confiável de tecnologias eletrônicas pode contribuir com a redução desta sobrecarga (KHANNA *et al.*, 2019). Informações de saúde, como dados de mortalidade, podem apoiar a priorização de atividades e a alocação de recursos em setores como o da saúde (WHO, 2020).

Mudanças sutis nos sinais vitais de pacientes costumam ocorrer horas antes de um evento agudo. O monitoramento contínuo dos sinais vitais permite intervenções terapêuticas eficazes com potencial real de evitar a ocorrência de eventos adversos, como uma parada cardiorrespiratória (KHANNA *et al.*, 2019). Técnicas de IA podem fornecer melhores evidências para apoiar as decisões dos profissionais de saúde e, conseqüentemente, ajudar a melhorar os resultados de saúde do paciente em hospitais (KAIESKI *et al.*, 2020).

O monitoramento atualmente realizado em unidades de internação tem foco prioritário em registros de dados estáticos de sinais vitais, geralmente feitos em intervalos de 4 a 6 horas. A falta de interpretação de mudanças sutis nos sinais vitais ou a detecção de padrão propicia a não identificação de deterioração clínica (EL-HAJJ e PA KYRIACOU, 2020). Desta forma, a maioria das mudanças de padrão na

fisiologia cardiorrespiratória são perdidas ou detectadas tarde demais para permitir intervenções eficazes antes da deterioração clínica (KHANNA *et al.*, 2019).

As tecnologias baseadas em IA se desenvolvem rapidamente e têm inúmeras aplicações na medicina e na saúde (TRAN *et al.*, 2019b). Revisões retrospectivas de readmissões na UTI evidenciaram que mais de 10% dessas readmissões eram potencialmente evitáveis por meio do monitoramento contínuo de sinais vitais (LORETO, LISBOA e MOREIRA, 2020). Assim, é essencial prever o início do estágio grave, pois isso permite tomar medidas preventivas antes que ocorra deterioração clínica (TYLMAN, *et al.*, 2016)

O estudo de Tran *et al.* (2019a) evidenciou diversos benefícios da aplicação de IA na área da saúde, destacando a melhoria da precisão diagnóstica e terapêutica e o processo geral de tratamento clínico. Tran *et al.* (2019b) abordaram a redução do tempo dispendido para encontrar evidências relevantes e redução também dos erros médicos, que melhoram a qualidade de diagnóstico em assistência médica.

Aumentar a disponibilidade de serviços de alta tecnologia pode melhorar o desempenho financeiro, especialmente entre hospitais sem fins lucrativos (KHANNA *et al.*, 2019). Estudos evidenciaram um alto potencial de contenção de custos em saúde por meio da aplicação de IA. Esta tecnologia é uma promessa para mudar os serviços de saúde em países de baixa renda (TRAN *et al.*, 2019b). Nesta área da medicina, pequenas melhorias na precisão podem ter grandes benefícios, devido à alta mortalidade associada à deterioração clínica e custos da utilização de recursos de maneira não efetiva, gerando alarmes falsos (CHURPEK *et al.*, 2016).

Desta forma, frente as diversas oportunidades de melhoria relacionadas a aplicação de IA na assistência ao paciente, faz-se necessário realizar um estudo que evidencie os resultados de tais contribuições.

Para contribuir com a teoria, a motivação deste estudo foi proporcionar à comunidade científica o aprofundamento do conhecimento sobre o uso de IA em cuidado de pacientes por meio de resultados operacionais relacionados a assistência.

Outra motivação deste estudo foi trazer contribuições as práticas de gestão hospitalar, que envolvem a gestão por processos e utilização de marcadores para acompanhamento da eficácia de seus processos, bem como a busca por assertivas tomadas de decisão.

Além disso, o uso de IA no monitoramento de sinais vitais agiliza a tomada de decisão clínica e oferece a pacientes cuidado integral e individualizado, o que é uma contribuição à sociedade

1.5 ESTRUTURA DA DISSERTAÇÃO

O presente estudo está organizado da seguinte forma:

- Capítulo 1 - apresentada a introdução do tema de pesquisa;
- Capítulo 2 - explora a revisão da literatura, com abordagem bibliométrica e sistemática de trabalhos relevantes sobre o assunto;
- Capítulo 3 - desdobra os métodos de pesquisa utilizados neste estudo;
- Capítulo 4 - apresenta os resultados do estudo de caso.
- Capítulo 5 - aborda as discussões das constatações práticas e teóricas;
- Capítulo 6 - apresenta a conclusão deste trabalho, com os destaques das contribuições e limitações do estudo.

2 REVISÃO DA LITERATURA

A fundamentação teórica deste estudo consistiu na busca abrangente de artigos que abordaram o emprego IA no monitoramento de pacientes para a identificação precoce de sinais de deterioração clínica. A revisão da literatura será apresentada em duas seções. Inicialmente, a revisão bibliométrica mostrará o extrato dos artigos encontrados nas bases de busca. Na segunda seção, revisão sistemática, é realizada a análise de conteúdo dos artigos diretamente relacionados a esta pesquisa.


2.1 REVISÃO BIBLIOMÉTRICA

Este trabalho estruturou seu método por meio da realização de um estudo de caso fundamentado por uma revisão da literatura. Esta revisão contou com a seleção de palavras chaves que abordaram o monitoramento de sinais vitais de pacientes, a utilização de IA e foco na identificação precoce de sinais de deterioração clínica de pacientes, abordando integralmente o tema de pesquisa. A busca nos bancos de dados e avaliação do conteúdo de 235 artigos encontrados resultou em 12 trabalhos elegíveis aos critérios de seleção definidos, utilizados para estruturar a apresentação de dados bibliométricos a seguir.

2.1.1 Publicação ao longo os anos

O crescimento das publicações relacionadas ao tema de pesquisa tem direta relação com a evolução tecnológica e o constante interesse do setor de saúde em otimizar seus processos e agregar valor a suas atividades. Nota-se que o interesse em aplicar IA na área da saúde a partir de 1998. Iniciativas recentes representam maior número de pesquisas, com destaque aos anos de 2016 e 2020, como identificado no Gráfico 1. O recente período associado a pandemia do COVID-19 contribuiu para o desenvolvimento de tecnologias em saúde, sendo pesquisadas diversas alternativas para a otimização de diagnósticos, acesso a tratamento e orientações necessárias para evitar a sobrecarga de atendimentos em ambientes hospitalares.

Gráfico 1: Publicações ao longo dos anos




Fonte: O autor

2.1.2 País de origem das publicações

Foram selecionados estudos provenientes de 7 países, sendo os Estados Unidos responsáveis pela publicação de mais artigos sobre o tema. Brasil e Espanha apresentaram 2 estudos relacionados ao tema de pesquisa, evidenciando que diferentes modelos de saúde podem se beneficiar da aplicação de IA para pacientes. Em busca de competitividade econômica, os Estados Unidos lideram iniciativas e pesquisas associadas a aplicação de IA em diversos setores, incluindo a área da saúde. Da mesma forma, avanços significativos são apresentados pela União Europeia, representada pela Espanha conforme apresentado. O Brasil se destaca com dois estudos, evidenciando interesse sobre o tema.

Gráfico 2: Publicações por país




Fonte: O autor

2.1.3 Periódicos

Os periódicos responsáveis pela publicação de trabalhos relacionados ao tema de pesquisa evidenciam o interesse não só de revistas de seguimentos do setor de saúde em buscar alternativas relacionadas a tecnologia para a melhoria contínua e otimização de atividades relacionadas ao cuidado de pacientes. Apesar do tema de pesquisa abordar tecnologias de indústria 4.0, a busca de artigos não retornou artigos publicados em periódicos voltados a Engenharia de Produção. Dentre os artigos selecionados, *Computers in Biology and Medicine* teve destaque, publicando dois artigos sobre o tema, conforme apresentado no Gráfico 3.

Gráfico 3: Publicações por periódico




Fonte: O autor

2.1.4 Métodos de pesquisa dos artigos

A metodologia de pesquisa utilizada em 8 dos trabalhos selecionados, conforme Gráfico 4, é o estudo de caso. Estes dados estão alinhados a informação do Gráfico 5, evidenciando a natureza exploratória em 11 artigos, visto que se trata de um tema ainda em desenvolvimento. Apenas um trabalho apresentou coleta de dados por meio de entrevistas, 7 apresentaram coleta de dados por meio de observação, buscando em literatura informações sobre o tema de pesquisa

proposto. dos artigos apresentou coleta de dados por meio de observação. Apresenta evidencia um total de 20% de estudos com abordagem qualitativa, enquanto 80% optaram por uma abordagem quantitativa.

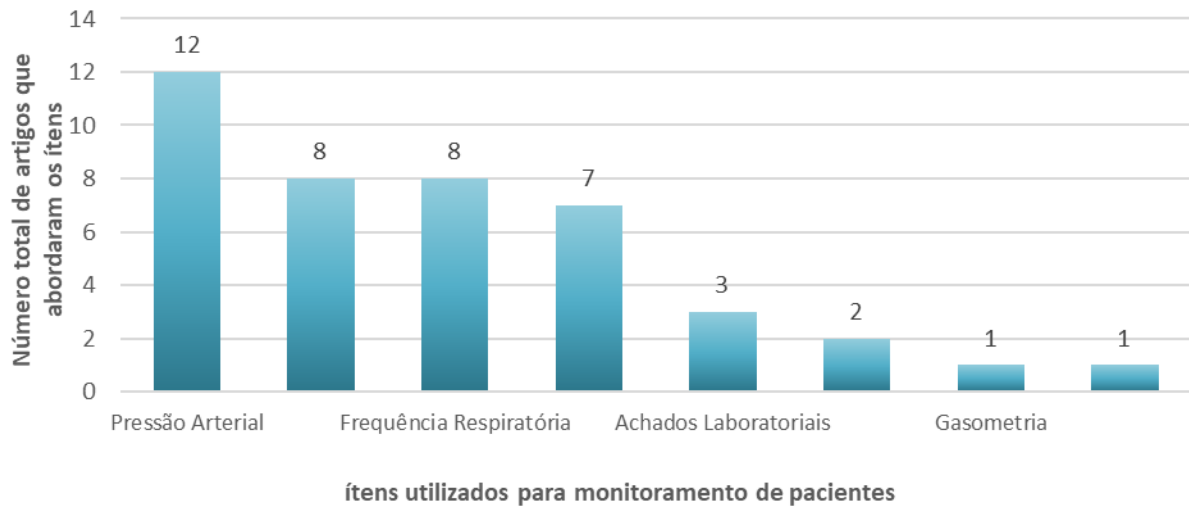


Fonte: O autor

2.1.5 Monitoramento de sinais vitais e deterioração clínica

Com relação aos parâmetros vitais monitorados, foram utilizados com maior frequência os sinais vitais determinados em literatura: Pressão arterial, abordado em todos os trabalhos selecionados, temperatura corporal, em 8 dos trabalhos, assim como frequência respiratória, e frequência cardíaca monitorada em 7 dos trabalhos. Além dos sinais vitais, outros parâmetros foram avaliados, sendo exames laboratoriais apresentados em 3 artigos, eletrocardiogramas em 2 artigos. Gasometria e medicamentos utilizados pelo paciente foram abordados em somente um artigo, conforme evidenciado no Gráfico 5

Gráfico 5: Parâmetros de monitoramento de sinais vitais



Fonte: O autor


2.1.6 IA em saúde

Alinhados aos objetivos da aplicação de IA em saúde, foi evidenciado que esta tecnologia foi aplicada em diferentes áreas hospitalares, responsáveis por pacientes durante seu período de internação. Somente 3 artigos não determinaram áreas específicas para a utilização de IA, El-Hajj e Kyriacou (2020), Kaieski *et al.* (2020) e Gultepe *et al.* (2013).

Unidades de Terapia Intensiva foram selecionadas para os estudos de Moret-Bonillo, Cabrero-Canosa e Hernandez-Pereira (1998), Churpek *et al.* (2016) e Yuan *et al.* (2020). Unidades de internação receberam a aplicação de IA em seus processos nos trabalhos de Tylman *et al.* (2016), Loreto, Lisboa e Moreira (2020) e Khanna *et al.* (2019).

Somente Heili-Frades *et al.* (2020) realizou seu trabalho em Unidade de Tratamento Respiratório Intermediário. Já Farahmand *et al.* (2017) optou por atuar em serviços de emergência e Kruger e Tremper (2011) apresentaram a aplicação de IA em unidades de terapia intensiva e centros cirúrgicos, por abordarem a atuação de um profissional específico, o anestesista. O agrupamento de artigos por setor de saúde que usa IA é evidenciado no gráfico 6.

Gráfico 6: Setores de saúde onde foi aplicada IA



Fonte: O autor

2.2 REVISÃO SISTEMÁTICA DA LITERATURA

Esta seção apresenta dados relacionados ao tema de pesquisa por meio de informações disponíveis na literatura relacionadas ao Monitoramento de Sinais Vitais e Deterioração Clínica, IA em Saúde e apresentação de um modelo teórico que abrange os principais Sinais Vitais Monitorados, bem como o motivo deste monitoramento e as áreas de saúde onde foram realizados.

2.2.1 Monitoramento de Sinais Vitais e Deterioração Clínica

Em instituições hospitalares, pacientes são monitorados continuamente por profissionais da saúde e por dispositivos eletrônicos, havendo então, uma grande quantidade de dados coletados e armazenados em prontuários eletrônicos. Os sinais vitais são os dados de maior relevância para monitorar pacientes e evidenciar seu estado de saúde. Conforme indicados pela literatura, são eles: pressão arterial (diastólica e sistólica), temperatura corporal, frequência cardíaca e frequência respiratória (KAIESKI *et al.*, 2020).

A prática convencional para mensuração de sinais vitais é principalmente com base na interpretação subjetiva das equipes assistenciais (KHANNA *et al.*, 2019). O acompanhamento intermitente de sinais vitais contribui para a atuação de especialistas e facilita a organização de intervenções (FARAHMAND *et al.*, 2017).

A utilização de alertas eletrônicos automatizados que evidenciem sinais de deterioração clínica em tempo real pode apoiar a identificação de instabilidades e eventos (CHURPEK *et al.*, 2016).

Unidades de internação possuem diversos sistemas validados para definir pontuações de predição de mortalidade (HEILI-FRADES, *et al.*, 2020). A aplicação de pontuações como o de MEWS (*Modified Early Warning Scores*) apoia a redução de riscos de desfecho clínico desfavorável, como o de parada cardíaca súbita (TYLMAN, *et al.*, 2016).

Em unidades de terapia intensiva, equipamentos de monitoramento traduzem o estado de pacientes por meio de dados fisiológicos, a avaliação destas variáveis pode definir limiares de normalidade e situações em que estes dados foram ultrapassados (MORET-BONILLO, CABRERO-CANOSA e HERNANDEZ-PEREIRA, 1998).

O monitoramento periódico de sinais vitais, conforme literatura, confere uma maneira prática para possibilitar profissionais de saúde o acompanhamento de muitos pacientes. Esta prática oferece riscos, pois eventos não identificados no período em que não há monitoramento podem gerar danos aos pacientes (KRUGER e TREMPER, 2011).

Pacientes em unidades de internação no período pós-operatório apresentam alto risco de deterioração clínica, sendo causa de aproximadamente 50% das paradas cardiorrespiratórias em hospitais (KHANNA *et al.*, 2019).

Mesmo com diagnósticos similares, pacientes podem apresentar sintomas e desfechos diferentes, associados a suas comorbidades pré-existentes (LORETO, LISBOA e MOREIRA, 2020).

Quando em unidades de terapia intensiva, diversos dispositivos médicos oferecem suporte a vida para pacientes, bem como monitoramento de dados de saúde (KRUGER e TREMPER, 2011). O monitoramento contínuo de sinais vitais evita que disfunções e eventos não sejam identificados nas unidades de internação (KHANNA *et al.*, 2019).

Estudos clínicos evidenciam que intervenções oportunas decorrentes da identificação precoce de sinais de deterioração clínica são essenciais para evitar desfechos desfavoráveis aos pacientes durante o atendimento hospitalar em diversas unidades de internação (KAIESKI *et al.*, 2020).

A capacidade de identificar precocemente o risco de mortalidade apoia a alocação de recursos humanos e tecnológicos para garantir intervenções oportunas (HELLI-FRADES *et al.*, 2020).

Quadros como hipotensão (baixa pressão arterial) podem evidenciar casos de lesão do miocárdio, lesão renal aguda, delírio e acidente vascular cerebral. (KHANNA *et al.*, 2019)

Hipertensão (aumento da pressão arterial) configura uma das mais relevantes causas de mortes em contexto mundial e contribui para o aumento do risco de injúrias graves, como as doenças cardiovasculares, como acidente vascular cerebral, insuficiência cardíaca e doenças renais (EL-HAJJ e PA KYRIACOU, 2020).

A monitoração cardíaca (representada pelo acompanhamento da frequência cardíaca) tem relação direta com ocorrências de lesões cardíacas, principalmente no período pré e pós-operatório, bem como casos de falência de outros órgãos e sepse (KHANNA *et al.*, 2019). A sepse é uma síndrome de resposta inflamatória sistêmica causada por infecções de diferentes focos, causando disfunção orgânica (YUAN *et al.*, 2020). Por não ser um quadro clinicamente evidente, a identificação precoce de sinais de sepse é um desafio nas instituições de saúde de todo o mundo (GULTEPE *et al.*, 2013).

Mesmo considerada uma prática comum em todas as instituições de saúde, a aferição de sinais vitais e seu monitoramento ainda apresenta lacunas relacionadas a frequência ideal para sua medição, conforme destacado por Kaieski *et al.* (2020).

2.2.2 Inteligência Artificial em Saúde

Embora este trabalho aborde tecnologias habilitadoras de Indústria 4.0, como IA e Big Data, esta nomenclatura não será utilizada pois o presente estudo não apresenta interconectividade total entre processos e tecnologias.

A primeira ideia de uma máquina pensante foi desenvolvida em 1945, quando um sistema que poderia amplificar o conhecimento humano (TRAN *et al.* 2019b). Desde então, IA tem sido abordada em literatura desde a década de 50, período em que Alan Turing desenvolve uma máquina capaz de interpretar dados de forma similar ao pensamento humano. Desta forma, surge a possibilidade de que esta

tecnologia possa analisar dados e adaptar-se as informações as quais é apresentada, aprendendo com elas (KAPLAN e HAENLEIN, 2019).

IA é estudada como parte das soluções tecnológicas que resulta em metodologias e algoritmos capazes de oferecer soluções equiparadas as de especialistas (KRUGER e TREMPER, 2011).

O Aprendizado de Máquina é um subcampo de IA capaz de desenvolver modelos de análise estatística por meio de tecnologias computacionais aplicadas a grandes quantidades de dados - Big Data. (LAL et al., 2020). Devido a avanços nos últimos anos, novos algoritmos agora alcançam ou excedem muito o desempenho de nível humano em diversas tarefas (KAIESKI *et al.*, 2020). Métodos de aprendizado de máquina permitem previsões precisas (CHURPEK *et al.*, 2016). Algoritmos de Aprendizado de máquina podem ser aplicados a diferentes unidades de internação, oferecendo resultados personalizados a demanda existente (HEILI-FRADES *et al.*, 2020).

A área da saúde considera o corpo humano como um sistema complexo suscetível a influência de diversas variáveis. Assim, modelos de IA treinados para explorar relações não lineares relacionadas a fenômenos igualmente complexos podem apoiar a assistência aos pacientes (KAKAVAS, 2019). Por este motivo, há evidências da utilização de IA na área médica desde a década de 50 com o objetivo de empregar sistemas inteligentes para aprimorar diagnósticos (TRAN, 2019).

De acordo com Tylman *et al.* (2016), sistemas computadorizados utilizados como apoio a decisões clínicas aplicados a doenças cardiovasculares estão relacionados a crescente evolução tecnológica. Algoritmos de IA têm apresentado diversos resultados favoráveis na codificação de conhecimento.

IA é uma ciência emergente que pode analisar extensos dados disponíveis no prontuário eletrônico de pacientes (YUAN *et al.*, 2020). A vantagem dos métodos de IA é a capacidade de analisar e interpretar grandes conjuntos de dados em tempo satisfatório (KAIESKI *et al.*, 2020). Há necessidade de IA acessível e contínua com suporte e plataformas baseadas em dados, juntamente com a necessidade de geração de evidências mais fortes para apoiar esta mudança nos padrões de monitoramento (KHANNA *et al.*, 2019).

A aplicação da IA na triagem de pacientes com dor abdominal aguda resultou em um modelo com benefício de projetar o modelo de triagem baseado em IA que pode fazer a triagem precisa e independente dos pacientes (FARAHMAND *et al.*,

2017). Métodos de aprendizagem de máquina podem prever estados de sepse por meio da identificação de alterações do estado fisiológico de pacientes (GULTEPE *et al.*, 2013).

Em estudos sobre a aplicação de IA para analisar os dados de pacientes, foi evidenciada a integração de recursos tecnológicos relacionados a intervenções clínicas, medicações, testes de laboratório e características fisiológicas. Métodos de IA podem ser integrados a sistemas de registro médico eletrônico para gerar previsões de eventos de maneira dinâmica, conforme novos dados são coletados (KAIESKI *et al.*, 2020).

A concentração humana diminui em função do tempo, intensidade e quantidade das informações recebidas, o que dificulta manter um estado de vigilância ao longo de um período (KRUGER e TREMPER, 2011).

O método proposto por Moret-Bonillo *et al.* (1998) permitiu a conexão entre monitores de cabeceira e computadores por meio de uma rede de dados a um monitor central, fornecendo diagnóstico terapêuticos.

O desenvolvimento de ferramentas de computação para análise de dados facilitou o processamento de dados fisiológicos, como pressão arterial. Esses recursos são normalmente usados para criar modelos usando aprendizado de máquina e redes neurais profundas para calcular estimativas confiáveis (EL-HAJJ e PA KYRIACOU, 2020). Algoritmos de aprendizado de máquina foram aplicados para a previsão de resultados clínicos que podem resultar no risco de readmissão em unidades de terapia intensiva (LORETO, LISBOA e MOREIRA, 2020).

2.2.3 Modelos e Métodos de Inteligência Artificial

Por meio de uma revisão sistemática da literatura, Kaieski *et al.* (2020) sintetizaram diversas perspectivas sobre a utilização desta tecnologia disponíveis na literatura como o objetivo de monitorar sinais vitais de pacientes adultos internados em instituições hospitalares. Verificaram, também que grande parte das publicações não abordou de forma clara os métodos utilizados (58%).

El-Hajj e Kyriacou (2020) buscaram a aplicação de IA para mensuração não invasiva da pressão arterial de pacientes por meio da fotopletismografia. Esta técnica detecta alterações relacionadas ao volume sanguíneo na constituição dos

tecidos. Desta forma, a associação da técnica ao aprendizado de máquina e modelos lineares de regressão apoia a detecção precoce de doenças cardiovasculares.

Uma proposta de avaliação de dados relacionados a pacientes que passaram por nova internação em unidades de terapia intensiva foi desenvolvida por Loreto, Lisboa e Moreira (2020). Foram analisados dados destes pacientes, considerando 158 atributos, que foram testados por meio de oito classificações de algoritmos, comparando seus resultados quanto a eficácia, com o objetivo de prever pacientes com perspectivas de novas internações em UTI.

Heili-Frades *et al.* (2020) desenvolveram um mecanismo de predição de mortalidade, por meio de aprendizado de máquina, para pacientes em unidades de tratamento respiratório intermediários, onde há pacientes que necessitam de cuidados mais complexos que unidades clínicas, mas não possuem os mesmos recursos de uma unidade de terapia intensiva. A utilização de redes neurais possibilitou identificar e classificar o risco de morte dos pacientes destas unidades de internação.

Yuan *et al.* (2020) estudaram o diagnóstico precoce de sepse. Utilizaram algoritmos de IA para treinamento frente a uma extensa base de dados e posteriormente aplicaram testes para validação das predições fornecidas pela tecnologia. A avaliação de dados em tempo real permitiu atuação precoce das equipes assistências envolvidas no cuidado de pacientes.

Khanna *et al.* (2019) apresentaram uma revisão da literatura para identificar iniciativas atuais para o monitoramento de sinais vitais dos pacientes e abordaram a necessidade de integração entre sistemas e IA com foco em acompanhar pacientes no período pós-operatório.

O estudo de Farahmand *et al.* (2017) visou definir estratificações de risco por meio da definição de um índice de gravidade por pontuação para pacientes com quadro clínico agudo dor abdominal. Em seu modelo, realizaram um comparativo entre os dados apresentados pela tecnologia para o processo de triagem frente a validação de profissionais médicos da emergência, resultando num modelo com aceitável nível de predição.

Churpek *et al.* (2016) realizaram um comparativo entre modelos de aprendizado de máquina no monitoramento de sinais vitais de uma enfermaria, determinando uma pontuação de riscos frente a novos dados disponíveis sobre a

clínica dos pacientes utilizando bancos de dados. Foram comparados diversos métodos de aprendizado de máquina para identificar a deterioração de pacientes.

Tylman *et al.* (2016) estruturaram seu estudo em unidades de emergência e desenvolveram um sistema de apoio a decisão clínica por meio da identificação de riscos e priorização de atendimentos e utilização de algoritmos de IA associados a monitores multiparâmetros.

Gultepe *et al.* (2013) desenvolveram mecanismos, por meio da avaliação de sinais vitais e exames laboratoriais, para apoio a decisão clínica relacionado a pacientes que apresentem riscos de alteração em seu resultado de lactato, bem como risco de mortalidade associado a esta alteração.

Kruger e Tremper (2011) apresentaram uma visão ampla sobre contribuições que a tecnologias de IA pode ter para a determinação de alertas mais efetivos e direcionados para otimizar a absorção de informações relevantes em momentos de tomada de decisão clínica feita por profissionais anestesistas.

Moret-Bonillo, Cabrero-Canosa e Hernandez-Pereira (1998) estudaram a integração de IA para o monitoramento de pacientes com equipamentos médicos disponíveis para apoio a tomada de decisões no tratamento de pacientes em unidade de terapia intensiva.

2.2.4 Aplicações de inteligência artificial ao monitoramento de pacientes para identificação precoce de deterioração clínica

Atendendo ao primeiro objetivo específico deste trabalho, foram evidenciadas na literatura aplicações de IA no monitoramento de sinais vitais para identificação precoce de riscos de deterioração clínica. Os artigos selecionados apresentaram abordagens relacionadas aos três critérios de inclusão, a estrutura conceitual desenvolvida a partir das informações disponíveis neste material é evidenciada no Quadro 1.

Foi identificado nos estudos selecionados como principal objetivo para a aplicação de IA em Saúde o monitoramento de pacientes para fins de predição. Seis dos artigos apresentaram métodos de avaliação da predição de mortalidade (HEILIFRADES *et al.*, 2020), risco de eventos cardiovasculares (TYLMAN *et al.*, 2016 e El-Hajj e KYRIACOU, 2020), diagnóstico de abdome agudo (FARAHMAND *et al.*,

2017), reinternações em Unidades de Terapia Intensiva (LORETO, LISBOA e MOREIRA, 2020) e deterioração clínica (CHURPEK *et al.*, 2016).

O monitoramento de pacientes foi o objetivo dos estudos de Khanna *et al.* (2019) com foco nos pacientes internados no período pós-operatório, Kruger e Tremper (2011) com o intuito de desenvolver alertas mais assertivos e Kaieski *et al.* (2020) para o monitoramento de condições clínicas dos pacientes.

A identificação precoce de sepse foi o objetivo do estudo de Yuan *et al.* (2020) e Gultepe *et al.* (2013). O apoio a decisão clínica foi objeto de estudo de Moret-Bonillo, Cabrero-Canosa e Hernandez-Pereira, 1998. Desta forma, é possível evidenciar que há preocupação dos autores em identificar precocemente desfechos desfavoráveis de pacientes, de modo que as informações disponíveis sejam utilizadas para atuação precoce das equipes de saúde.

Quadro 1: Estrutura conceitual

Autores	Ano	Sinais Vitais				Outros Parâmetros					Objetivo do Monitoramento	Subclassificação	Unidade de Aplicação
		Pressão Arterial	Temperatura	Frequência Cardíaca	Frequência Respiratória	Saturação de O2	Achados Laboratoriais	Gasometria	ECC	Medicamentos em Uso			
El-Hajj e Kyriacou	2020	X	-	-	-	-	-	-	-	-	Predição	Risco de eventos cardiovasculares	Não especificado
Heili-Frades et al.	2020	X	X	-	X	-	X	-	-	-	Predição	Mortalidade	Unidade de Tratamento Respiratório Intermediário (IRCU)
Kaieski et al.	2020	X	X	X	X	-	-	-	-	-	Acompanhar condições clínicas	Condições Clínicas	Não especificado
Loreto, Lisboa e Moreira	2020	X	-	-	X	-	-	-	-	-	Predição	Reinternações em Unidades de Terapia Intensiva	Unidades de Internação
Yuan et al.	2020	X	X	X	X	-	X	-	-	X	Identificação precoce Sepsis		Unidade de Terapia Intensiva
Khanna et al.	2019	X	-	-	-	-	-	-	X	-	Acompanhar condições clínicas	Pós-Operatório	Unidades de Internação
Farahmand et al.	2017	X	X	X	X	X	-	-	-	-	Predição	Diagnóstica de abdome agudo	Serviços de Emergência
Churpek et al.	2016	X	X	X	X	-	-	-	-	-	Predição	Deterioração Clínica	Unidade de Terapia Intensiva
Tylman et al.	2016	X	X	-	-	-	-	-	X	-	Predição	Risco de eventos cardiovasculares	Unidades de Internação
Gultepe et al.	2013	X	X	X	X	-	X	-	-	-	Identificação precoce Sepsis		Não especificado
Kruger e Tremper	2011	X	X	X	X	-	-	-	-	-	Acompanhar condições clínicas	Alertas mais assertivos	Unidade de Terapia Intensiva e Centros Cirúrgicos
Moret-Bonillo, Cabrero-Canosa e Hernandez-Pereira	1998	X	-	X	-	X	-	X	-	-	Apoio a decisão Clínica		Unidade de Terapia Intensiva

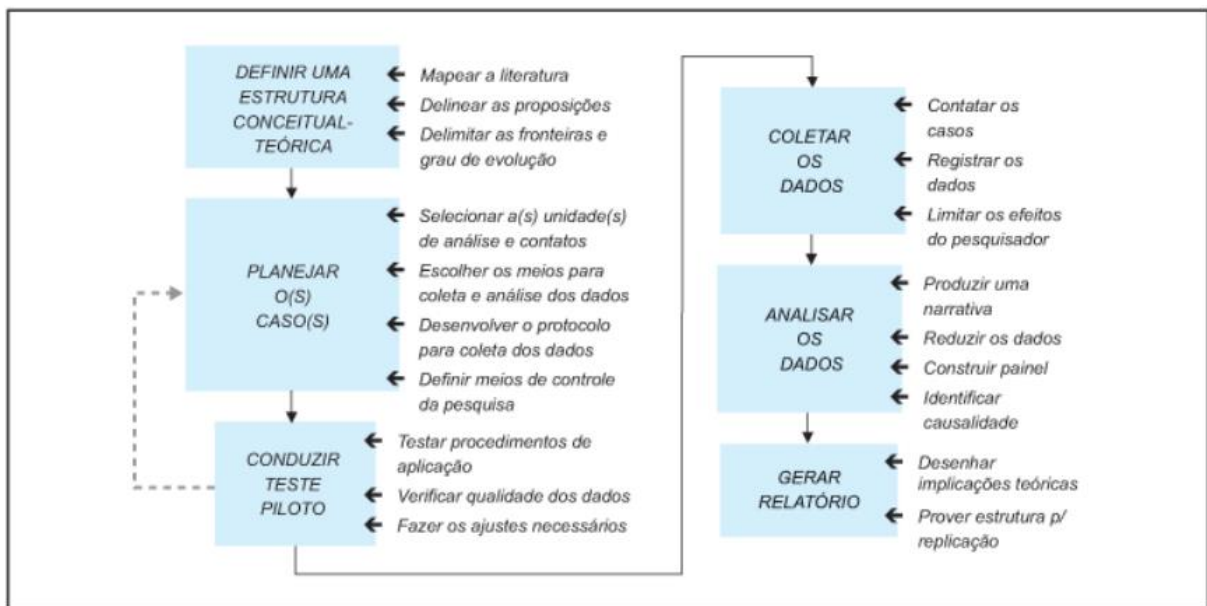
Fonte: O autor

3 METODOLOGIA

Este estudo apresenta uma pesquisa de abordagem qualitativa com objetivo exploratório, realizada por meio de um estudo de caso fundamentado em revisão bibliométrica e sistemática.

A condução do estudo de caso seguiu o a estrutura apresentada por Miguel (2007) em seu modelo, conforme evidenciado na Figura 1.

Figura 1 - Condução de estudo de Caso



Fonte: Miguel, 2007.

3.1 MÉTODO PARA REVISÃO DA LITERATURA

Esta seção explicitará a estrutura definida para organização e execução deste estudo, que visa abranger as informações necessárias disponíveis em literatura para alcançar os objetivos deste estudo de maneira estruturada e eficaz.

A parte teórica desta dissertação foi fundamentada em revisão bibliométrica e sistemática da literatura acerca do uso de IA aplicada ao monitoramento de sinais vitais de pacientes com o objetivo de identificar precocemente sinais de deterioração clínica.

Um levantamento bibliométrico quantifica a literatura científica sobre um tópico específico (COOPER, 1998), por meio do qual é possível identificar os dados empíricos que podem ser exibidos em configurações de seleção predefinidas (MOHER *et al.*, 2009). A síntese dos resultados fornecidos por uma pesquisa bibliométrica realizada de forma sistemática pode ser reproduzida (DAVIS, 2014). A

apresentação de uma compilação de informações relevantes sobre um determinado assunto torna-se estratégica para estudos futuros que abordem o tópico pesquisado (BAUMEISTER, 1997).

3.1.1 Palavras-chave

Com o intuito de direcionar as pesquisas de maneira assertiva e abranger todo o tema de pesquisa, foram determinadas palavras-chave relacionadas a tecnologia IA e a estrutura necessária para sua aplicação, bem como um conjunto de palavras relacionadas a atividade de monitoramento de sinais vitais de pacientes, sem delimitações relacionadas a setores hospitalares ou especialidades, conforme evidenciado no quadro 2.

Quadro 2: Palavras-chave

Tecnologias	Monitoramento de Pacientes
<i>Artificial Intelligence</i> <i>I.A.</i> <i>Machine Learning</i> <i>Data Analytics</i> <i>Cognitive Robotics</i> <i>Cloud Computing</i>	<i>Clinical Deterioration</i> <i>Vital signs</i> <i>Patients Monitoring</i>

Fonte: O autor

As palavras-chave foram relacionadas de acordo com os dois grupos citados acima, resultando em 18 agrupamentos, conforme apresentado no quadro 3, abaixo.

Quadro 3: Agrupamento de palavras-chave

<i>"Artificial Intelligence" AND "Clinical Deterioration"</i> <i>"Artificial Intelligence" AND "Patients Monitoring"</i> <i>"Artificial Intelligence" AND "Vital signs"</i> <i>"I.A." AND "Clinical Deterioration"</i> <i>"I.A." AND "Patients Monitoring"</i> <i>"I.A." AND "Vital signs"</i> <i>"Machine Learning" AND "Clinical Deterioration"</i> <i>"Machine Learning" AND "Patients Monitoring"</i> <i>"Machine Learning" AND "Vital signs"</i>	<i>"Data Analytics" AND "Clinical Deterioration"</i> <i>"Data Analytics" AND "Patients Monitoring"</i> <i>"Data Analytics" AND "Vital signs"</i> <i>"Cognitive robotics" AND "Clinical Deterioration"</i> <i>"Cognitive robotics" AND "Patients Monitoring"</i> <i>"Cognitive robotics" AND "Vital signs"</i> <i>"Cloud Computing" AND "Clinical Deterioration"</i> <i>"Cloud Computing" AND "Patients Monitoring"</i> <i>"Cloud Computing" AND "Vital signs"</i>
---	---

Fonte: O autor

3.1.2 Bases de Pesquisa

Para realizar as buscas por artigos publicados, de modo a consultar, de maneira sistêmica, os diversos periódicos que possam abordar o tema de pesquisa, foram utilizadas as bases de dados: *Science Direct*, *Scopus*, *ProQuest*, *Emerald*, *Scielo*, *Wiley Library* e *Taylor and Francis*. As buscas foram realizadas entre os meses de março e novembro de 2020, resultando em 92 artigos. Posteriormente, em agosto de 2021, foram realizadas novas buscas que consideraram o período de novembro de 2020 a agosto de 2021 e resultaram em 143 artigos.

3.1.3 Critério de Seleção dos artigos

Foram considerados, como premissa do estudo e critérios de inclusão, artigos científicos e revisões publicados em periódicos contendo as palavras-chave selecionadas em seu Título, Resumo e Palavras-chave. Não foi definido como critério um intervalo específico para publicação dos artigos.

Para delimitar os estudos elegíveis, foram determinadas as seguintes perguntas de avaliação de qualidade:

- (i) O artigo aborda o monitoramento de sinais vitais de pacientes?
- (ii) O artigo aborda a aplicação de IA na área da Saúde?
- (iii) O artigo aborda mecanismos de identificação precoce de sinais de deterioração clínica de pacientes?

Como critérios de exclusão, não foram utilizados neste estudo artigos apresentados em congresso e capítulos de livros.

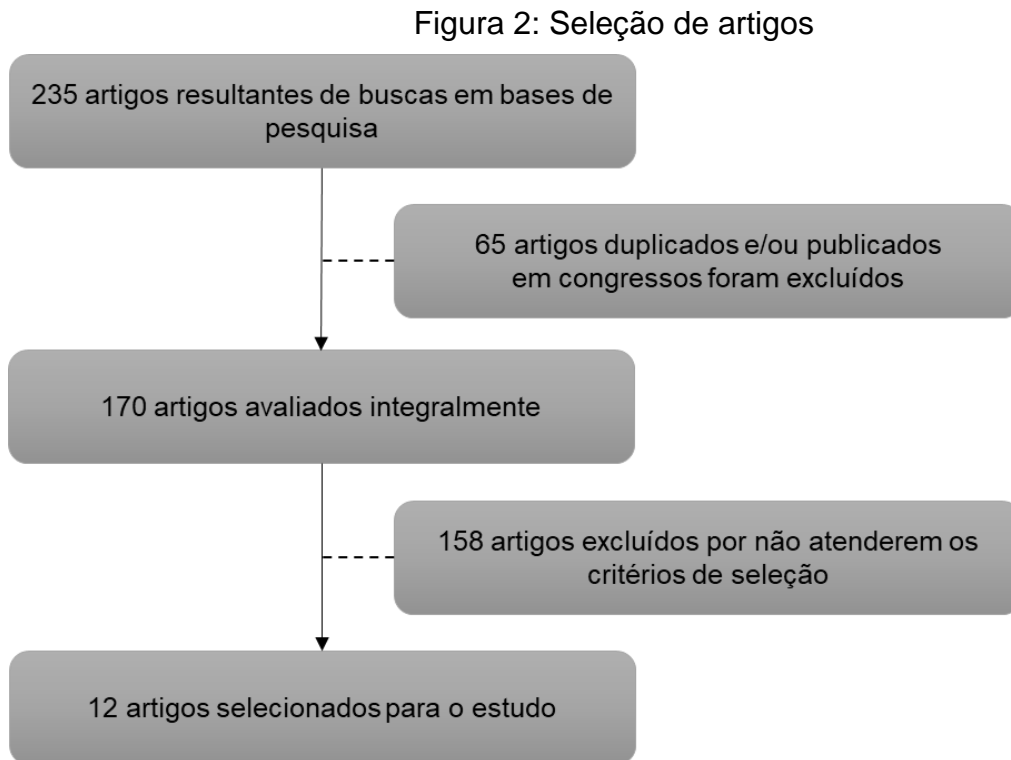
A seguir, são apresentadas as etapas aplicadas para garantir conformidade aos critérios estabelecidos.

3.1.4 Etapas de Seleção

Na primeira etapa foram avaliados os 235 artigos resultantes das buscas nas bases de dados. Foram avaliados os meios de publicação com o objetivo de evidenciar artigos de conferências, capítulos de livros, pôsteres e artigos duplicados. Esta etapa resultou na exclusão de 65 artigos.

A etapa seguinte contou com a avaliação integral dos 170 artigos resultantes.

Desta etapa foram excluídos 158 artigos, que não corresponderam integralmente aos critérios de seleção. Foram selecionados 12 artigos para a revisão bibliográfica deste trabalho, conforme representado na Figura 2.



Fonte: Adaptado de Moher *et al.* (2009)

Na sequência será apresentado o detalhamento dos 158 artigos não selecionados na análise integral das publicações.

Foram evidenciados em literatura 66 artigos cujo objetivo foi desenvolver ou validar modelos de inteligência artificial para aplicação na área da saúde. Tais iniciativas, como Velardo (2021) e Pimentel (2021) desenvolveram seus trabalhos com foco na operacionalização e viabilização da tecnologia, sem abordar resultados clínicos.

Em 29 trabalhos foram apresentadas iniciativas de Interpretação de dados de saúde, sem abordar o monitoramento de sinais vitais de pacientes. No trabalho de

Greenbaum *et al.* (2019) foram abordadas melhoria nos registros médicos por meio de aprendizado de máquina. Wang *et al.* (2017) avaliaram a aplicação de aprendizado de máquina para determinar divergências entre idade cronológica e fisiológica de pacientes com o intuito de personalizar o cuidado clínico.

Definição Diagnóstica não preditiva foi o tema de 20 dos estudos não selecionados. Ebrahimian *et al.* (2012) estudaram a utilização de IA para identificar pacientes que necessitaram de ventilação mecânica por meio da análise de radiografias e Nguyen *et al.* (2019), a aplicação de aprendizado de máquina para identificar paciente com quadro infeccioso. As propostas destes estudos visaram utilizar a tecnologia IA como apoio a assistência ao paciente, porém sem caráter preditivo.

Estruturar mecanismos para coleta de dados clínicos foi tema de 18 trabalhos, porém sem objetivo de predição e/ou utilização da tecnologia IA. Hassen *et al.* (2020) abordaram o monitoramento de pacientes em ambiente domiciliar e Hu *et al.* (2018) apresentaram o uso de roupas inteligentes com o objetivo de monitorar sinais vitais de pacientes por meio de sensores. Forkan *et al.* (2017) e Chatrati *et al.* (2019) desenvolveram suas pesquisas com foco no monitoramento de pacientes em ambiente domiciliar.


Em 16 dos trabalhos, foram apresentados estudos teóricos sobre o tema, como os desafios da saúde inteligente com a utilização de Big Data (SAKR e ELGAMMAL, 2016) e desenvolvimento de alarmes inteligentes (BLOCK, 2012).

Aplicação de IA em robótica foi abordada em 7 dos artigos, o desenvolvimento de robôs inteligentes para reconhecimento visual foi apresentado por Leitner *et al.* (2013), e a utilização de IA para o reconhecimento de materiais por meio de sensores foi o tema do trabalho de Kerr *et al.* (2018).

Segurança da informação foi abordada nos trabalhos de Al-Zinati *et al.* (2020) e Celdrán *et al.* (2018).

O Gráfico 7 representa a distribuição por classificação dos artigos não selecionados. O quadro 4 apresenta a relação de artigos não selecionados, relaciona os critérios de seleção definidos para esta pesquisa e evidencia o não cumprimento integral aos critérios requeridos.

Gráfico 7: Abordagem dos trabalhos não selecionados



Fonte: O autor

Quadro 4 - Lista de artigos não selecionados

Abordagem dos Trabalhos	Autor	Ano	Aplicação de Inteligência Artificial	Monitoramento de sinais vitais	Predição de deterioração clínica
Coleta de dados clínicos	Al-Mutairi et al.	2021	-	X	-
	Jiang et al.	2021	X	X	-
	Roy et al.	2021	X	-	-
	Aiassa et al.	2021	X	-	-
	Celest et al.	2020	-	-	-
	Chatrati et al.	2020	-	X	-
	Hassen et al.	2020	-	X	-
	Shen et al.	2020	X	-	-
	Alam et al.	2019	-	X	-
	Malycha et al.	2019	-	-	-
	Ramkumar et al.	2019	X	-	-
	Zouka e Hosni	2019	-	X	-
	Hu et al.	2018	-	X	-
	Forkan e Khalil	2017	-	X	X
	Forkan et al.	2017	-	X	X
	Forkan e Khalil	2016	-	X	X
	Forkan et al.	2015	-	X	X
Kim e Kim	2012	-	X	-	
Definição Diagnóstica não preditiva	Ebrahimian et al.	2021	X	-	X
	Vaccari et al.	2021	X	-	-
	Souza et al.	2021	X	-	-
	Ryzhikova et al.	2021	X	-	-
	Tsvetkov et al.	2021	X	-	-
	Pérez-Sanz et al.	2021	X	-	-

	Elwahsh et al.	2021	X	-	-
	Kumar et al.	2021	X	-	-
	Kim et al.	2021	X	-	-
	Luo et al.	2021	X	-	-
	Panaggio et al.	2021	X	-	-
	Ashleibta et al.	2021	X	X	-
	Han et al.	2021	X	X	-
	Tunthanathip et al.	2021	X	-	-
	Wei et al.	2021	X	-	-
	Krysko et al.	2021	X	-	-
	Soltan et al.	2020	X	X	-
	Coquet et al.	2019	-	-	-
	Nguyen et al.	2019	-	X	-
	Yousefi et al.	2015	-	-	X
Desenvolvimento/Validação de modelo	Holdsworth et al.	2021	X	-	-
	Chabi et al.	2021	X	-	-
	Signoroni et al.	2021	X	-	-
	Ebrahimian et al.	2021	X	-	-
	Kerr et al.	2021	X	X	-
	Joo et al.	2021	X	X	-
	Rice et al.	2021	X	X	-
	Amin et al.	2021	X	-	-
	Chao et al.	2021	X	-	-
	Un et al.	2021	X	X	-
	Neves et al.	2021	X	X	-
	Wu et al.	2021	X	X	-
	Cobre et al.	2021	X	-	-
	Meliá et al.	2021	X	-	-
	Ramesh et al.	2021	X	-	-
	Takahashi et al.	2021	X	-	-
	Nsugbe	2021	X	-	-
	Velardo et al.	2021	X	-	-
	Luštrek et al.	2021	X	X	-
	Altilio et al.	2021	X	-	-
	Cousyn et al.	2021	X	-	-
	Shah et al.	2021	X	-	-
	Jacques et al.	2021	X	-	-
	Raza et al.	2021	X	-	-
	Chicco e Jurman	2021	X	-	-
	Ng et al.	2021	X	-	-
	Verma et al.	2021	X	X	-
	Du et al.	2021	X	-	-
	Hanitra et al.	2021	X	-	-
	Rathee et al.	2021	X	-	-
	Bonakdari et al.	2021	X	-	-
	Ohata et al.	2021	X	-	-

	Dabbah et al.	2021	X	-	-
	Karlsson et al.	2021	X	-	-
	Yanamala et al.	2021	X	X	-
	Feng et al.	2021	X	-	-
	Cruz et al.	2021	X	X	-
	Hirano et. al	2021	X	X	-
	Radhachandran et al.	2021	X	X	-
	Kobayashi et al.	2021	X	X	-
	Radhachandran et al.	2021	X	-	-
	Aznar-Gimeno et al.	2021	X	-	-
	Vaid et al.	2021	X	X	-
	De Hond et al.	2021	X	X	-
	Huang et al.	2021	X	X	-
	Zhu et al.	2021	X	-	-
	Khan et al.	2021	X	X	-
	Pimentel et al.	2021	X	-	-
	Shah et al.	2021	X	-	-
	Mauer et al.	2021	X	-	-
	Tezza et al.	2021	X	-	-
	Alghatani et al.	2021	X	X	-
	Purnomo et al.	2021	X	-	-
	Lybarger et al.	2021	X	-	-
	Li et al.	2021	X	-	-
	Schultebrucks et al.	2021	X	-	-
	Lu et al.	2021	X	-	-
	Yu et al.	2021	X	-	-
	Wardi et al.	2021	X	-	-
	Ikemura et al.	2021	X	-	-
	Soltan et al.	2021	X	-	-
	Ibrahim et al.	2021	X	-	-
	Mao et al.	2021	X	X	-
	Nadeem et al.	2021	X	-	-
	Mathioudakis et al.	2021	X	-	-
	Chicco e Jurman	2021	X	-	-
Estudios teóricos sobre o tema	Firouzi et al.	2021	X	-	-
	Gauthier et al.	2021	X	-	-
	Qureshi et al.	2021	X	-	-
	Hussain et al.	2021	X	X	-
	Song et al.	2021	X	-	-
	Muralitharan et al.	2021	X	-	-
	Site et al.	2021	X	-	-
	Rohmetra et al.	2021	X	X	-
	Lal et al.	2020	X	-	-
	Lowery	2020	-	X	-
	Tran et al.	2019b	X	-	-
	Tran et al.	2019a	X	-	-

	Harrer et al.	2019	X	-	-
	Sahoo et al.	2018	-	X	-
	Sakr e Elgammal	2016	-	-	-
	Block	2012	-	X	-
Inteligência Artificial em robótica	Kerr et al.	2018	X	-	-
	Augello et al.	2016	X	-	-
	Lemaignan et al.	2016	X	-	-
	Colin et al.	2015	X	-	-
	Leitner et al.	2013	X	-	-
	Stojanov et al.	2006	X	-	-
	Sharkey e Ziemke	2001	X	-	-
Interpretação de dados de saúde	López-Sastre et al.	2021	X	-	-
	Ji at. al.	2021	-	X	-
	Oikonomidi et al.	2021	X	-	-
	Haghighy et al.	2021	X	-	-
	Hahm et al.	2021	X	-	-
	Marincowitz et al.	2021	X	-	-
	Pegoraro et al.	2021	X	X	-
	Kamoussi et al.	2021	X	-	-
	Sodhi et al.	2021	X	-	-
	Rezaei et al.	2021	X	-	-
	Belbin et al.	2021	X	-	-
	Ma et al.	2021	X	-	-
	Sang et al.	2021	X	-	-
	Parikh et al.	2021	X	-	-
	Tao et al.	2021	X	-	-
	Chen e See	2020	X	-	-
	Chou et al.	2020	-	-	-
	Olson et al.	2020	-	X	-
	Shaikh et al.	2020	X	-	X
	Shahi et al.	2020	-	-	-
	Greenbaum et al.	2019	-	-	-
	Kakavas et al.	2019	X	-	-
	Nielsen et al.	2019	-	X	-
	Sanchez-Pinto et al.	2018	-	X	X
	Wang et al.	2017	X	-	-
	Soguero-Ruiz et al.	2016	-	-	-
	Zhai et al.	2014	-	X	X
	Hauskrecht et al.	2013	-	-	-
Presedo et al.	1996	-	-	-	
Segurança da informação	Al-Zinati et al.	2020	-	-	-
	Celdrán et al.	2018	-	-	-

Fonte: o autor

Os 12 artigos selecionados foram avaliados apresentados na seção 2.1 Revisão Bibliométrica, de acordo com os seguintes tópicos:

- (i) Publicação ao longo dos anos;
- (ii) Países de origem das publicações;
- (iii) Periódicos em que os artigos foram publicados;
- (iv) Metodologia;
- (v) Monitoramento de sinais vitais e deterioração clínica;
- (vi) IA em saúde;
- (vii) Objetivo do monitoramento de pacientes.

3.2 MÉTODO ESTUDO DE CASO

Com o objetivo de abranger informações necessárias e relevantes para o desenvolvimento de um estudo de caso, esta seção apresenta a estruturação das etapas instituídas para a elaboração do estudo de caso.

Após a condução de uma revisão bibliográfica e definição da questão de pesquisa, foi proposto um estudo de caso para avaliar as contribuições da implantação de um sistema de IA em uma unidade de internação hospitalar com o para identificar precocemente sinais de deterioração clínica por meio do monitoramento de sinais vitais de pacientes.

Segundo Cauchick Miguel e Sousa (2012, p.131), “o estudo de caso é um trabalho de caráter empírico que investiga um dado fenômeno dentro de um contexto real contemporâneo por meio da análise aprofundada de um ou mais objetos de análise (casos)”.

De acordo com Voss (2002) os estudos de caso têm constante aplicação em estudos e pesquisas relacionados ao gerenciamento de operações. Para Yin (2014) os estudos de caso permitem avaliar rotinas de maneira holística, enfatizando a investigação de fenômenos contemporâneos em seu caráter empírico. São estudos que apresentam pesquisas descritivas que apresentam, por meio de amostragem, situações incomuns aos pesquisadores por meio da avaliação de dados qualitativos.

São apresentados a seguir as cinco etapas definidas por Yin (2014) para o desenvolvimento de um estudo de caso:

- (i) Delineamento da pesquisa: definição do tema estudado;

- (ii) Desenho da pesquisa: identificação da lacuna de pesquisa e definição do hospital foco do estudo;
- (iii) Preparação e Coleta dos dados: observação e análise de relatórios;
- (iv) Análise dos dados: análise de indicadores de deterioração clínica de pacientes antes e depois da implantação da IA;
- (v) Elaboração dos Relatórios: construção da dissertação.

O estudo de caso desta dissertação consiste na avaliação de dados já monitorados pela instituição, sendo estes indicadores de resultados da unidade de internação em questão. Desta forma, durante o desenho da pesquisa, foi necessário definir critérios para a seleção do hospital foco do estudo.

Critério 1. Utilização de prontuário eletrônico para disponibilização de dados de saúde informatizados;

Critério 2. Gerenciar, há mais de um semestre, indicadores de resultado assistencial relacionados a unidade piloto, para possibilitar o comparativo entre os períodos pré e pós-implantação de I.A.;

Critério 3. Compromisso com a disponibilização de dados pertinentes a proposta do estudo.

A instituição hospitalar selecionada como foco do estudo de caso atendeu integralmente os três critérios propostos.

Foram avaliados os acionamentos de códigos amarelos antes e após a implantação da tecnologia. Este mecanismo de acionamento é responsável por identificar o momento em que a equipe operacional da unidade evidencia alterações clínicas dos pacientes (já com quadro de deterioração ou parada cardiorrespiratória). Desta forma, é possível avaliar a contribuição da aplicação de IA no processo do setor e seu impacto no marcador de efetividade clínica gerenciado pela diretoria clínica do hospital e discutidos em esfera estratégica.

Estes acionamentos são monitorados mensalmente, por meio de relatórios estruturados disponibilizados pelo setor de Tecnologia da informação, uma vez que todo acionamento requer registro em prontuário eletrônico do paciente.

Para garantir avaliação integral da operação assistencial frente a estrutura conceitual apresentada, foram avaliados todos os prontuários que registraram, durante o período, acionamento de códigos amarelos. Foram considerados os

motivos do acionamento destes códigos, os sinais vitais avaliados e outros parâmetros da estrutura conceitual.

Os motivos dos acionamentos foram obtidos por meio de informações disponíveis do prontuário eletrônico dos pacientes, por meio relatórios estruturados pelo setor de tecnologia da informação.

Os períodos selecionados foram o primeiro trimestre de 2020 e primeiro trimestre de 2021. Desta forma, foram reduzidos os riscos de variações sazonais. Serão confrontados também os desfechos clínicos dos pacientes na unidade monitorada nos dois períodos. Desta forma, além do acionamento dos códigos amarelos e avaliação dos motivos dos acionamentos, serão apresentados também os resultados referentes a necessidade de transferência de pacientes para unidade de maior complexidade, acionamento de códigos azuis (quando constatadas paradas cardiorrespiratórias) e óbitos dos pacientes desta unidade.

4 ESTUDO DE CASO

4.1 A INSTITUIÇÃO E A IMPLANTAÇÃO DA TECNOLOGIA

Esta seção visa conceituar o leitor das principais características da unidade de saúde selecionada para o desenvolvimento do estudo de caso.

A instituição objeto do presente estudo é um hospital geral com estrutura terciária, caracterizada por ser um Hospital especializado ou com especialidades, destinado a prestar assistência a clientes em outras especialidades médicas além das básicas, localizado na cidade de São Paulo. A instituição conta com 260 leitos operacionais, distribuídos em unidades de pronto atendimento, internação clínicas e cirúrgicas, unidade de transplante de medula óssea, hospital dia, pediatria, unidades de terapia intensiva (adulto, pediátrico e neonatal), maternidade, centro cirúrgico e centro obstétrico.

O hospital conta com serviço de nutrição e dietética próprio, bem como engenharia clínica hospitalar, manutenção, higienização e segurança patrimonial. Os serviços de diagnóstico por imagem, análises clínicas, lavanderia e transporte são externos.

Atuam nesta instituição cerca de dois mil e quinhentos profissionais em regime de contratação CLT, quinhentos profissionais alocados no hospital que correspondem a fornecedores externos e um corpo clínico aberto de aproximadamente dois mil médicos cadastrados.

Resultado de uma trajetória de amadurecimento de seus processos por meio do aprimoramento contínuo da gestão de operações em saúde, a organização de saúde estudada conquistou certificações que avaliam e garantem a qualidade de seus processos e foco na segurança de pacientes desde o ano de 2008. Para garantir a gestão sistêmica de seus processos, atua com mecanismos de gerenciamento e ferramentas da qualidade, bem como atividades relacionadas a melhoria contínua de seus resultados.

Alinhados ao planejamento estratégico da instituição, os objetivos estratégicos são desdobrados da esfera estratégica a tática e operacional, de modo que a cultura de qualidade permeia todos os processos e tomadas de decisão institucional.

Reuniões de *Balance Score Card*, bem como com o acompanhamento de indicadores de processo e resultado, controle de documentos e registros, gestão da qualidade e gerenciamento de riscos são práticas institucionais contínuas.

Com a intenção de aprimorar a qualidade de seus processos e garantir impacto positivo relacionado a ganhos financeiros e assistenciais, a instituição preza por inovação por meio da adoção de novas tecnologias. Por se tratar de uma instituição de saúde, a segurança do paciente e otimização do cuidado são objetivos estratégicos. Desta forma, a incorporação de novas tecnologias a práticas já existentes representa oportunidade de ganhos substanciais a instituição, seus profissionais e pacientes.

A instituição atua há aproximadamente cinco anos com sistema de prontuário eletrônico, o que garante registros seguros e evidências confiáveis dos cuidados prestados aos pacientes, bem como tomadas de decisões, e garante o gerenciamento integral dos custos do cuidado. Viabiliza também maior confiabilidade nos dados utilizados para gerenciar o perfil epidemiológico da população atendida. Assim, são tomadas ações assertivas para garantir adequada alocação de recursos tecnológicos, financeiros e humanos para a execução de seus processos.

A utilização de IA como apoio a decisão clínica e monitoramento contínuo de pacientes caracterizou uma oportunidade de amadurecer processos de gestão de operações relacionadas ao cuidado.

IA ofereceu a possibilidade de utilizar recursos tecnológicos para obtenção resultados otimizados, por meio da aplicação de algoritmos que analisam e sintetizam grandes quantidades de dados (Big Data). O tratamento contínuo de dados permitiu que mecanismos de aprendizado de máquina definissem padrões e algoritmos capazes de se desenvolver ao longo de sua operação, aprendessem, de forma literal, a gerenciá-los e entregar os resultados esperados.

Para que tal operação fosse efetiva, foi necessário contar com processos definidos e padronizados de coleta de dados e tomadas de decisão. Assim, a estrutura de prontuário eletrônico apoiou o desenvolvimento do Aprendizado de Máquina e a aplicação de IA em seus processos. Desta forma, a identificação de tendências, riscos e resultados críticos foi apresentada por esta tecnologia, assimilando-se ao raciocínio de profissionais especialistas no processo adotado.

Por meio de tecnologia de IA a análise de Big Data pode ser realizada numa velocidade muito maior do que a análise feita por profissionais de saúde,

considerando também a inclusão imediata de novos dados de saúde inseridos em prontuário eletrônico. Informações atualizadas e confiáveis foram disponibilizadas a profissionais de saúde por meio de relatórios e alertas personalizados associados a parâmetros pré-determinados que evidenciaram alterações relevantes no estado clínico e evolução de pacientes.

A utilização de prontuários eletrônicos só foi possível quando disponibilizados estrutura e recursos para seu funcionamento. A instituição objeto do estudo contou com computadores disponíveis em todas as áreas do cuidado, como postos de enfermagem, salas operatórias, salas de triagem e consultórios para pronto atendimento. O acesso a internet e servidores seguros foram recursos essenciais para garantir a segurança da informação. *Backups* foram realizados periodicamente e disponibilizados em local fora da instituição, o que permitiu acesso a informações do prontuário eletrônico mesmo em períodos sem acesso a rede.

A interconectividade foi essencial para a implantação de IA associada a dados de prontuário eletrônico, de modo que projetos relacionados a segurança da informação envolvessem os desenvolvedores do sistema de IA e de prontuário eletrônico, para garantir que a utilização de dados fosse otimizada e segura.

O sistema de IA realiza uma varredura contínua, em tempo real, de dados clínicos registrados por profissionais e provenientes de outros sistemas integrados, como laboratório de análises clínicas.

Para garantir o acesso otimizado aos dados disponíveis no sistema de prontuário eletrônico de maneira segura e otimizada, foi necessário mapear os campos responsáveis pelo registro e armazenamento dos dados necessários para o desenvolvimento de Aprendizado de Máquina. A instituição selecionou os dados com os quais estrutura o cuidado de seus pacientes e que foram necessários para a atuação da IA. Ao todo, foram selecionados 26 campos de documentos do prontuário eletrônico relacionados a sinais vitais, evoluções multiprofissionais (médicos, enfermeiros, fisioterapeutas, farmacêuticos e nutricionistas), bem como resultados de exames laboratoriais. Tais dados tiveram seus campos de inclusão mapeados para que estivessem disponíveis para leitura da tecnologia de I.A. A relação de dados mapeados e disponibilizados está evidenciado no quadro 5.

Quadro 5 - Dados do prontuário eletrônico

Informações coletadas do Prontuário Eletrônico do Paciente	
1	Identificador único do prontuário
2	Identificador único do paciente
3	Identificador único do atendimento
4	Identificador único do profissional que realizou a coleta dos sinais vitais
5	Nome do profissional que realizou a coleta dos sinais vitais
6	Data da coleta dos sinais vitais
7	Data da liberação da coleta
8	Identificador único do setor em que a coleta foi feita
9	Nome/Descrição do setor que o paciente se encontra
10	Abreviação do setor que o paciente se encontra
11	Posição em que o paciente se encontra (Decúbito)
12	Valor da pressão arterial diastólica
13	Escala da temperatura coletada
14	Escala de dor
15	Intensidade da dor
16	Número de sequência do resultado de dor
17	Valor da saturação de O ₂
18	Membro em que foi medida a saturação de O ₂
19	Valor da glicemia capilar
20	Nível de consciência do paciente no momento da coleta
21	Valor da temperatura do paciente
22	Valor da frequência respiratória
23	Valor da frequência cardíaca
24	Valor da pressão arterial média
25	Valor da pressão arterial sistólica
26	Data da última atualização do registro

Dados como idade, diagnósticos, tempo de internação, transferências entre setores e unidades de internação foram considerados pela tecnologia de aprendizado de máquina, o que permitiu aos algoritmos a avaliação parâmetros registrados no prontuário eletrônico para caracterização de pontuação de risco, associados a predição de deterioração clínica dos pacientes.

Dados pessoais de pacientes (como nome e data de nascimento) não foram considerados pelo sistema, atendendo assim, de forma estratégica e segura, critérios estabelecidos pela Lei Geral de Proteção de Dado trazendo confiabilidade a instituição e seus pacientes.

A tecnologia tem como premissa utilizar um algoritmo de aprendizagem supervisionada por meio de árvores de decisão. Dados disponíveis em prontuário

eletrônico, como evidenciados no Quadro 5, são associados a diferentes pontos de tomada de decisão (perguntas e parâmetros) que possibilitam determinar tendências, neste caso, de deterioração clínica dos pacientes, considerando os últimos cinco conjuntos de parâmetros vitais e demais informações selecionadas incluídos no sistema de prontuário eletrônico. Desta forma o sistema de aprendizado de máquina apresenta soluções para o monitoramento de pacientes por meio da classificação de riscos. A caracterização do quadro clínico dos pacientes monitorados e o intervalo de tempo definido pela IA garantem que os parâmetros dos pacientes sejam acompanhados com menor intervalo de tempo para aplicar o algoritmo com maior precisão. Este cenário permite que a equipe multidisciplinar responsável pelo cuidado tome atitudes e defina ações assistenciais efetivas de forma precoce, baseados em tendências e não na identificação de alterações já instaladas e com impacto clínico negativo para o desfecho dos pacientes.

A varredura dos dados de prontuários eletrônicos ocorreu a cada 60 segundos, para todos os pacientes internados na unidade piloto. Desta forma, foi possível apresentar de maneira direcionada aqueles pacientes que necessitaram de acompanhamento mais constante. A disponibilização de alertas imediatamente após a coleta e registro dos parâmetros dos pacientes por meio da esta estrutura de aprendizado de máquina, permitiu a equipe multiprofissional direcionar, de forma otimizada, atenção aos casos de maior risco de deterioração. A estruturação dos alertas consiste na seguinte definição:

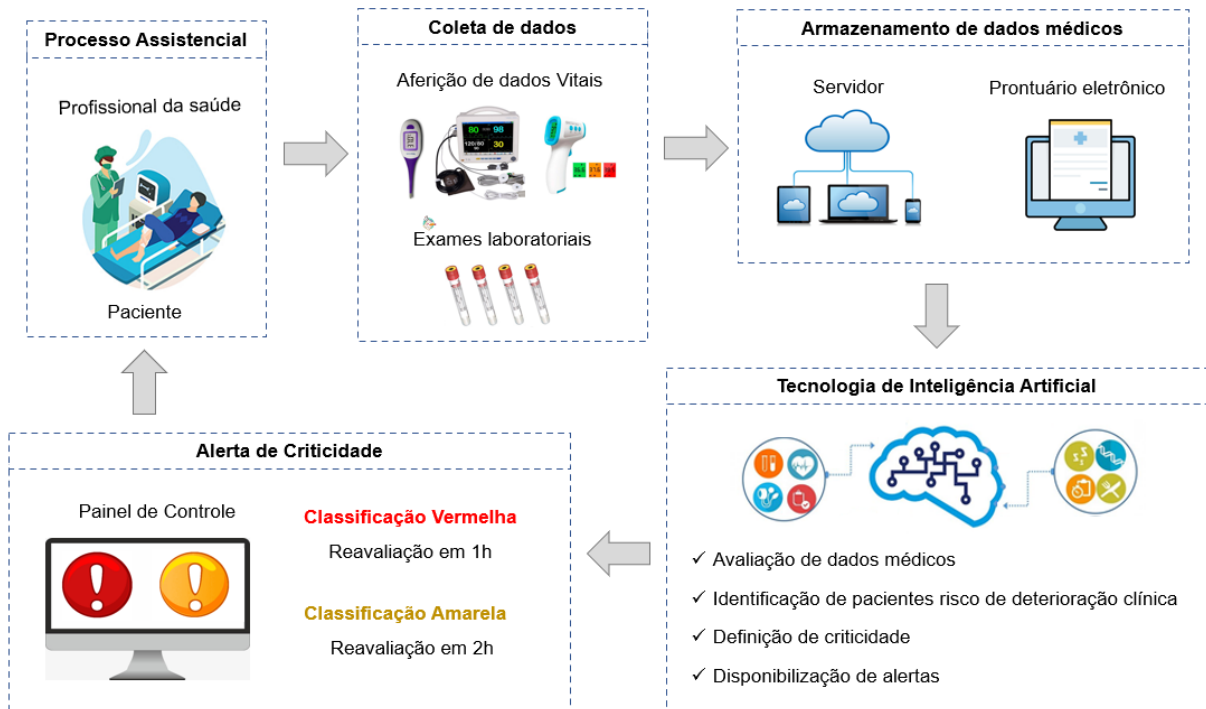
- Alerta amarelo: caracterizou pacientes com quadro clínico contendo alterações significativas, porém identificando sinais de deterioração clínica associadas a somente um parâmetro. Pacientes elegíveis a classificação amarela deveriam ser reavaliados e ter novos parâmetros registrados em prontuário em até duas horas.

- Alerta vermelho: caracterizou pacientes com alterações significativas em dois ou mais parâmetros monitorados. Pacientes elegíveis a classificação vermelha deveriam ser reavaliados e ter novos parâmetros registrados em prontuário em até uma hora.

Esta sinalização de criticidade foi acessível diretamente no sistema de IA por meio de computadores disponíveis nos postos de enfermagem e carros beira-leito (computadores disponíveis sobre os carros de medicação que permitem inclusão de dados em prontuário eletrônico de maneira imediata, junto ao leito do paciente), bem

como em um monitor disponível no posto de enfermagem com atualização da varredura, a cada minuto, para toda a equipe atuante na unidade.

Figura 3 - Estrutura da Inteligência Artificial



Fonte: o autor

Para a implantação desta tecnologia, foi necessário disponibilizar acesso a rede aberta em todos os computadores, bem como a instalação de um monitor adicional, com recursos de rede para projeção do painel de controle. Não foram necessários logins e senhas a todos os funcionários, apenas aos gestores da unidade, que puderam acompanhar a evolução de cada paciente por meio de gráficos e linhas do tempo. Para a operação (técnicos de enfermagem responsáveis pela coleta e inclusão de dados no sistema) a informação necessária estava disponível no monitor principal, indicando quais pacientes necessitavam de avaliação de acordo com os alarmes. Para os gestores, foi possível consultar com maiores detalhes a evolução dos chamados. O sistema disponibilizou um gráfico de tempo em colunas que evidenciou quais sinais apresentaram alterações, os parâmetros considerados alterados dentro da normalidade esperada e qual alerta foi emitido (amarelo ou vermelho) a linha do tempo disponibilizou todas as inclusões de dados em prontuários eletrônicos, o momento em que foram incluídos, e

informações adicionais como inclusão de evolução médica, coleta de amostras para exames.

Todos os funcionários atuantes no setor, de toda a equipe multidisciplinar, foram capacitados nas semanas anteriores a data de início do projeto piloto, sendo informados dos critérios de avaliação, necessidade e proposta de reavaliação de pacientes proposta pela tecnologia.

A unidade selecionada foi uma unidade de internação clínica e cirúrgica, com trinta e seis leitos operacionais, que atende pacientes de diversas especialidades, em período pré e pós-operatório. Nesta unidade não são admitidos pacientes que necessitam de cuidados intensivos (suporte respiratório contínuo e uso de drogas vasoativas) bem como pacientes pediátricos, menores de quatorze anos.

A unidade é estruturada no modelo enfermagem, havendo dois leitos por quarto. No sistema de IA, os pacientes são identificados por seu número de atendimento e leito onde estão internados.

Estão presentes na unidade profissionais da equipe multidisciplinar vinte e quatro horas por dia. A enfermagem, responsável pelo cuidado do paciente, atua em dois plantões diurnos de 6h, das seis horas ao meio-dia, e do meio-dia as dezoito horas. Dois plantões noturnos de 12h (A e B) das dezoito às seis horas, em noites alternadas. Um médico hospitalista (clínico geral capacitado para atendimento a emergências) acompanha os pacientes durante todo o período em modelo de escala. Os demais profissionais atuam por meio de interconsulta, solicitada por médicos e enfermeiros de acordo com as necessidades clínicas do paciente, bem como avaliações médicas de especialistas (como nefrologia e neurologia).

Por seu perfil de atendimento geral, a taxa de ocupação da unidade manteve-se acima da meta definida em planejamento estratégico, e atingiu 100% de ocupação nos períodos selecionado para este estudo. Não houve impacto relacionado a intervenções sazonais, como doenças do aparelho respiratório (associadas ao início do inverno) e a pandemia do COVID-19, pois trata-se de uma unidade que não atende pacientes com diagnóstico de COVID.

A unidade é gerenciada por meio do acompanhamento de indicadores de resultado e processo. Os indicadores de processo estão diretamente relacionados a assistência, e abrangem a conformidade de avaliações periódicas de risco, conformidade de registros em prontuário, realização de procedimentos e

medicamentos prescritos, entre outros. Neste estudo, serão considerados os indicadores de resultado, apresentados a seguir:

- Número de intercorrências associadas a deterioração clínica de pacientes internados na unidade;
- Número de transferências de pacientes pra unidades de maior complexidade.
- Número de óbitos de pacientes não paliativos internados na unidade.

Pacientes paliativos são assim classificados após alinhamento entre a equipe médica responsável pelo cuidado e os responsáveis legais/familiares do paciente. Desta forma, fica determinado que, por conta da fragilidade clínicas destes pacientes (idade avançada, prognóstico desfavorável) são ofertadas medidas de conforto, porém não indicadas manobras invasivas como a ressuscitação cardiopulmonar frente a parada cardiorrespiratória, transferência para unidade de maior complexidade e abordagens cirúrgicas.

Com o objetivo de avaliar integralmente os resultados gerenciais da unidade selecionada para este estudo, foi realizado um estudo comparativo entre períodos determinados antes da implantação da tecnologia de IA e após a implantação desta tecnologia na unidade de internação em questão.

Os indicadores foram instituídos com o objetivo de gerenciar de maneira assertiva os resultados desta unidade e permitir a identificação de desvios, bem como a possibilidade de implantar ações de melhoria.

4.2 AVALIAÇÃO DE DADOS DE SAÚDE

Esta seção apresenta de forma detalhada os dados gerenciados pela instituição antes da implantação de IA, que possibilitaram o comparativo dos resultados clínicos após a adoção da tecnologia.

A instituição de saúde objeto do seguinte estudo utiliza uma ferramenta chamada escala de MEWS - *Modified Early Warning Score*, para identificar precocemente sinais de deterioração clínica de pacientes em cuidados não críticos por meio da atribuição de pontos (escala numérica) associada a variação de sinais vitais de acordo com seu parâmetro de normalidade, bem como determinar a periodicidade de reavaliação de pacientes que apresentaram alterações em seus

parâmetros vitais. A escala é aplicada por profissionais de enfermagem e permite acionamento oportuno de profissionais médicos quando necessário.

Os médicos responsáveis pela avaliação de pacientes que apresentam alterações de sinais vitais fazem parte do Time de Resposta Rápida, bem como outros profissionais de saúde (fisioterapeutas). Este time é acionado quando sinais de alerta são identificados, por meio da alteração de sinais vitais de pacientes, sendo eles temperatura, frequência cardíaca, frequência respiratória, pressão arterial, dor, alteração de comportamento e diminuição da perfusão periférica.

A ocorrência de acionamentos do time de resposta rápida é monitorada pela instituição com o objetivo de acompanhar a identificação precoce de sinais de deterioração clínica de pacientes.

Desta forma, podem ser acionados os seguintes atendimentos:

- Código Amarelo: avaliação médica por deterioração clínica resultante de alterações de sinais vitais e de seu estado de saúde, sendo necessária avaliação por meio de exames laboratoriais, de imagem ou de especialistas

- Código Azul: Ressuscitação Cardiopulmonar (RCP) pois a deterioração clínica culminou em colapso do sistema respiratório e circulatório. Este tipo de intervenção pode ser revertido na unidade de internação e permitir que o paciente permaneça nesta unidade, sob cuidados não críticos ou, em caso de intubação orotraqueal e necessidade de ventilação ou uso de drogas vasoativas, culminar na necessidade de transferência para unidades de maior complexidade.

O acionamento de códigos amarelos evidencia a correta identificação de deterioração clínica, de modo que a intervenção média oportuna permite adequação do plano de cuidado e a estabilização do quadro clínico do paciente. Por outro lado, o acionamento de código azul ocorre quando os sinais de deterioração clínica resultaram em Parada Cardiorrespiratória (PCR).

O método utilizado para avaliação das informações disponíveis em prontuário foi definido de modo que identificasse os motivos que definiram a necessidade de acionamento de códigos amarelos. Foram disponibilizados relatórios estruturados pelo setor de tecnologia da informação, disponibilizando data, hora e número de atendimento dos pacientes atendidos por meio do acionamento de códigos amarelos. Frente a esta listagem, foram avaliados individualmente todos os documentos de prontuário relacionados a registros do atendimento que identificou

sinais de deterioração clínica nos pacientes, bem como quais foram estes sinais/parâmetros.

O quadro a seguir evidencia a representatividade dos sinais vitais e parâmetros identificados no estudo de caso em comparação com os dados evidenciados em literatura, resultando na estrutura conceitual apresentada no quadro 6.

Quadro 6 - Parâmetros monitorados no estudo de caso

Período	Sinais Vitais				Outros Parâmetros				
	Pressão Arterial	Temperatura	Frequência Cardíaca	Frequência Respiratória	Saturação de O2	Exames Laboratoriais	Gasometria	Eletrocardiograma	Medicamentos em uso
1º Trimestre 2020	X	X	X	X	X	X	X	-	-
1º Trimestre 2021	X	X	X	X	X	X	X	-	-

Fonte: o autor

Este quadro tem como objetivo confrontar os sinais vitais e demais parâmetros considerados para o monitoramento de pacientes para identificação precoce de deterioração clínica de acordo com os achados da literatura. É possível evidenciar que, com exceção dos parâmetros eletrocardiograma e medicamentos em uso, os demais itens foram utilizados como critério de avaliação pela tecnologia de IA, considerados relevantes e decisivos para o início da tomada de decisões clínicas com o objetivo de identificar precocemente o risco de deterioração clínica dos pacientes internados na unidade piloto do estudo de caso.

Para elucidar de forma mais abrangente os motivos dos acionamentos de códigos amarelos neste estudo de caso, o quadro 7 apresenta a representatividade destes sinais e parâmetros por meio de números absolutos, bem como dos demais motivos considerados relevantes para o acionamento.

Quadro 7 - Valores totais dos motivos dos acionamentos de códigos amarelos

Período	Sinais Vitais				Outros Parâmetros			
	Pressão Arterial	Temperatura	Frequência Cardíaca	Frequência Respiratória	Saturação de O2	Exames Laboratoriais	Gasometria	Eletrocardiograma
1º Trimestre 2020	0	1	3	5	2	7	1	-
1º Trimestre 2021	44	5	23	18	42	15	1	-


Fonte: O autor

O quadro acima evidencia o comparativo entre os períodos analisados neste estudo de caso. Além do aumento de números de acionamentos, a representatividade dos sinais vitais para esta tomada de decisão se destaca no 1º trimestre de 2021. É importante considerar o alto número de acionamentos também relacionados a alterações do parâmetro “Saturação de O2”, associado ao transporte de oxigênio na corrente sanguínea. Durante o período que corresponde ao ano de 2021, além de importante marcador de deterioração clínica, foi diretamente associado a identificação de sinais clínicos de COVID-19, infecção responsável por afetar prioritariamente o sistema respiratório.

A dor, embora considerada o 5º sinal vital a partir de 1995, foi considerada um acionamento por outros motivos, frente a proposta de reproduzir no estudo de caso os dados relacionados na estrutura conceitual. Em todos os casos avaliados neste estudo, as queixas de dor não apresentavam nenhuma alteração de sinal vital associada.

O gráfico 8, abaixo, ressalta a representatividade dos motivos dos acionamentos de códigos amarelos quando consideramos o grupo de dados classificados como sinais vitais e outros parâmetros conforme estrutura conceitual.

Gráfico 8: Representatividade dos motivos dos acionamentos de códigos amarelo



Fonte: O autor

Em comparação com a estrutura conceitual, é possível identificar que o sinal vital “Pressão Arterial” apresenta maior representatividade quando analisados os sinais vitais considerados para o acionamento de um código amarelo. Em segundo lugar, destaca-se o parâmetro “Saturação de O2”, citado em apenas 2 dos 12 trabalhos analisados neste estudo. A representatividade dos acionamentos considerando alteração deste parâmetro podem ser relacionadas diretamente a pandemia do COVID-19. Parâmetros como Frequência Cardíaca, Frequência Respiratória e Temperatura foram motivos de acionamento, em acordo com a estrutura conceitual. Houve maior representatividade de acionamentos resultantes de alterações em exames laboratoriais nos dados do estudo de caso. As gasometrias, permaneceram com apenas um acionamento por período, sempre associadas a alterações de outros parâmetros. Não houve acionamento de código amarelo causado por alterações relacionadas a eletrocardiogramas.

4.3 AVALIAÇÃO DOS INDICADORES DE RESULTADOS CLÍNICOS

A presente seção evidencia os resultados obtidos por meio da análise do estudo de caso, considerando a aplicação de IA no monitoramento de pacientes e a

contribuição desta tecnologia em apoiar a identificação precoce de deterioração clínica, evitando desfechos desfavoráveis aos pacientes.

Ao considerar os dados obtidos sobre os acionamentos de códigos amarelos é possível evidenciar relevante impacto da aplicação da tecnologia de I.A. quando comparado o número total de acionamentos por período. Nota-se que no período de 2020 houve um total de 31 acionamentos, enquanto no mesmo período de 2021 foram realizados 158 acionamentos de código amarelo. É relevante ressaltar que a unidade piloto manteve sua ocupação em 100% em ambos os períodos avaliados. Desta forma o aumento dos acionamentos se deve a redução do intervalo entre avaliações dos pacientes que apresentaram tendência a deterioração clínica de acordo com a aplicação de IA, bem como maior proximidade da equipe assistencial ao paciente.

Os pacientes que não apresentaram sinais de alerta decorrentes da tecnologia foram avaliados de acordo com as práticas institucionais já adotadas. Desta forma, o acompanhamento direcionado aos pacientes que realmente necessitaram de maior atenção pode otimizar o processo de avaliação de parâmetros vitais por parte da equipe assistencial, direcionando esforços e permitindo que a alocação de recursos humanos fosse realizada de maneira mais efetiva.

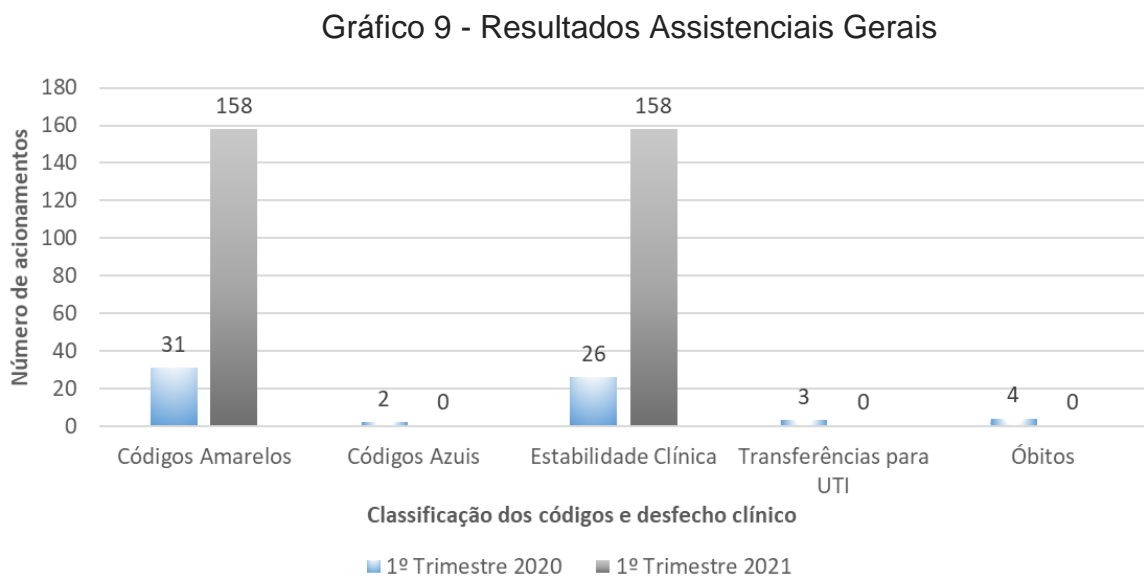
O acionamento de códigos amarelos também foi avaliado quanto a seu desfecho. No período de 2020, um total de 26 pacientes que necessitaram de reavaliações mais constantes mantiveram sua estabilidade clínica, enquanto 3 necessitaram de transferência para unidade de maior complexidade. Esta transferência dos pacientes a Unidade de Terapia Intensiva trata-se de uma tomada de decisão clínica associada a pacientes em condições clínicas que exigem cuidados e suporte assistencial mais complexos, pode-se considerar esta transferência como cuidado precoce para desfechos desfavoráveis, porém, a necessidade de maior atenção ocorreu após quadro de deterioração clínica. Dois pacientes atendidos após acionamento de códigos amarelos foram a óbito.

Estas ocorrências denotam que a deterioração destes pacientes ocorreu sem identificação precoce, tomada de decisão pontual, transferência para UTI ou outras condutas invasivas. Trata-se de um desfecho desfavorável não esperado para pacientes em unidades de internação clínicas, resultando em aumento de custos assistenciais, gerando impacto no processo de gerenciamento de leitos e

indisponibilizando leitos de UTI a novos pacientes que não estava previamente recebendo cuidados de saúde em ambiente hospitalar.

No período avaliado de 2021, os 158 atendimentos após acionamento de códigos amarelos tiveram como desfecho a estabilidade clínica dos pacientes. Assim, compreende-se que os acionamentos foram realizados de maneira assertiva, no momento ideal para tomada de decisões relevantes que resultaram na melhoria geral do quadro clínico destes pacientes, sem agravamento de suas condições clínicas e, posteriormente, resultando em alta hospitalar.

O gráfico 9 apresenta os resultados gerais dos indicadores de resultados clínicos utilizados pela instituição.



Fonte: O autor

Ao avaliar os dados assistenciais, conforme proposto para este estudo de caso, é possível evidenciar que os resultados de desfecho clínico desfavoráveis representados no gráfico acima, ocorridos em 2020 não se mantiveram no período de 2021.

Os dados relacionados a transferência para unidade de maior complexidade englobam os dados dos desfechos do acionamento de código amarelo (dois casos) e um desfecho decorrente do acionamento de código azul. Os 4 óbitos que ocorreram em 2020 também estão associados aos códigos amarelos e azuis, sendo o desfecho óbito de dois pacientes relacionado a cada código.

A aplicação da tecnologia conta como um apoio para o direcionamento de cuidados, priorizando o monitoramento de pacientes com informações que permitem a identificação do risco de deterioração clínica por meio da avaliação de sinais vitais e outros parâmetros. O impacto operacional da necessidade de reavaliações de pacientes com critérios de deterioração resultou num aumento considerável dos chamados relacionados a alterações de sinais vitais, a despeito de acionamentos acionados por outros parâmetros e outros motivos. No ano de 2020, 26% dos acionamentos de códigos amarelos foram resultantes de alterações se sinais vitais, no ano de 2021 os acionamentos pelo mesmo motivo representaram 42% dos acionamentos.

Assim, entende-se que a aplicação de IA no monitoramento de pacientes mostrou resultados positivos na identificação precoce de sinais de deterioração clínica. Reduzindo, desta forma, desfechos desfavoráveis como óbito e transferências para unidade de maior complexidade por meio do monitoramento preciso e possibilidade de tomada de decisões assertivas e de forma precoce a piora clínica dos pacientes.

5 DISCUSSÕES

Um resultado identificado por este estudo foi que **o principal motivo de acionamento de código amarelo pelo sistema de IA foi pressão arterial. Sem a IA, a necessidade de realização de exames laboratoriais foi a causa principal.** Desta forma, ao analisar as informações disponíveis no Gráfico 8, representando o número total de acionamentos que consideraram cada item, exclusivamente ou não, para sua abertura, é possível constatar relevante mudança nos motivos de acionamento de códigos amarelos correlacionando os dois períodos estudados.

No 1º trimestre de 2020 nota-se que o principal motivo de acionamento, está relacionado a alteração em exames laboratoriais. A instituição objeto do estudo de caso atua com barreiras de segurança associadas a liberação de resultados de exames laboratoriais, de modo que não se faz necessária intervenção humana para interpretação dos resultados. Estes, quando fora dos parâmetros de normalidade definidos em literatura, acionam automaticamente um alerta de resultados de pânico. Por outro lado, não houve acionamento resultante de alterações relacionadas a pressão arterial de pacientes, bem como Saturação de O₂, Frequência Cardíaca e Frequência Respiratória, que foram motivos de acionamento em dois, três e cinco acionamentos, respectivamente.

Este quadro mudou no 1º trimestre de 2021, trazendo a alteração de sinais vitais de forma mais representativa. Tal resultado é considerado positivo, visto que sinais vitais são os principais marcadores de estabilidade clínica para o monitoramento de pacientes. Identifica-se, também, que os alertas emitidos pela tecnologia de IA consideram alterações em um ou mais parâmetros, sendo assim, mais sensíveis a mudanças no quadro clínico dos pacientes monitorados. Tal mudança está associada a implantação da tecnologia de IA como norteador de condutas a equipe assistencial, bem como apoio a tomada de decisão clínica por meio da avaliação de tendências definidas por aprendizado de máquina. A atuação humana no monitoramento de pacientes permite identificar alterações no momento da coleta de dados e, desta forma, tomar condutas frente aos dados apresentados naquele momento. Porém, apesar do raciocínio clínico e da possibilidade de revisar dados vitais das coletas anteriores, os profissionais de saúde não possuem a capacidade de avaliar de forma imediata, em tempo real, diversas informações disponíveis em prontuário e identificarem a tendência a deterioração clínica frente a

informações individualizadas de cada paciente. O sistema de IA não só direciona os profissionais a priorizar pacientes que necessitam de monitoramento por apresentarem tendência a deterioração, mas identifica quais sinais vitais e demais parâmetros apresentam, de acordo com a aplicação do algoritmo, tendência a apresentar alterações mais relevantes. Desta forma, o profissional de saúde inicia sua atividade de monitoramento com foco nos parâmetros alterados. Esta prática contribui para a valorização do monitoramento de sinais vitais e atua como barreira de segurança frente a vulnerabilidade inerente a condutas pessoa-dependentes.

Tais constatações corroboram El-Hajj e Kyriacou (2020), que voltaram seu estudo ao monitoramento da pressão arterial de pacientes devido a sua relevância, visto que alterações relacionadas a este sinal vital, como a hipertensão, configuram fator de risco para doenças graves, bem como uma das principais causas mundiais de morte. Há também apoio ao trabalho de Khanna *et al.* (2019), que ressaltaram a importância de mecanismos de monitoramento mais sensíveis que consideram mudanças sutis de sinais vitais e possibilitem atuação precoce. Da mesma forma, Kruger e Tremper (2011) afirmaram que decisões baseadas em IA apoiam as equipes para superar limitações humanas no processo assistencial, pois contam com mais informações para a tomadas de decisões clínicas e priorização do cuidado.

No entanto, diverge dos achados de Kaieski *et al.* (2020) no qual usualmente sinais vitais não são isoladamente analisados com o objetivo de predição, visto que a tecnologia de IA estudada considera individualmente cada parâmetro monitorado.

Outro resultado foi o **aumento de ocorrência de acionamentos de códigos amarelos com o uso de IA**. Considerado um resultado positivo para este estudo, conforme apresentado no Gráfico 9, houve um aumento de 400% no número total de acionamentos de códigos amarelos quando comparados os períodos de 2020 e 2021. Frente a um número similar de pacientes internados na unidade, com mesmo perfil epidemiológico da população, pode-se associar o aumento do número de acionamentos a implantação da tecnologia de IA e sua contribuição para o monitoramento de pacientes. O direcionamento oferecido pela tecnologia de IA exigiu que os pacientes fossem reavaliados, por meio de nova coleta de sinais vitais, de acordo com as classificações decorrentes de seu algoritmo de AM. Esta mudança de método foi aplicada somente aos pacientes que apresentaram risco de

deterioração de acordo com os critérios definidos pela tecnologia, de modo que os demais pacientes foram reavaliados de acordo com a periodicidade adotada anteriormente pela instituição. A efetividade no acionamento de códigos amarelos impactou diretamente o número de acionamentos por código azul. No 1º Trimestre de 2020 ocorreu o acionamento de 2 códigos azuis por parada cardiorrespiratória. No mesmo período de 2021, não houve acionamento de código azul, um resultado positivo por apresentar acompanhamento integral dos pacientes, direcionamento assertivo da tecnologia de IA em prever riscos de deterioração clínica e atuação oportuna da equipe assistencial, de modo que nenhum paciente apresentou deterioração clínica resultante em parada cardiorrespiratória. Estas constatações corroboram Moret-Bonillo, Cabrero-Canosa e Hernandez-Pereira (1998) que evidenciaram melhores resultados assistenciais relacionados a otimização das tarefas dos profissionais de saúde quando apoiados por sinalizações confiáveis e assertivas associadas ao cuidado por meio da adoção de IA no monitoramento de pacientes. Bem como Tylman *et al.* (2016) que apresentaram a importância da obtenção de dados clínicos que possam ser correlacionados com o objetivo de detectar precocemente problemas e ameaças futuras, no caso do presente estudo, e possibilitar o acionamento de códigos amarelos para avaliação oportuna de pacientes. Da mesma forma, Farahmand *et al.* (2017), cujo trabalho apresenta a importância da disponibilização de predições clínicas individualizadas, sendo apoio para tomadas de decisão mais precisas e Gultepe *et al.* (2013) que reforçaram a necessidade de registro em tempo oportuno para permitir a previsão de eventos, considerando a atuação de IA ao monitoramento de pacientes.

Também foi evidenciado como resultado deste trabalho que **todos os acionamentos realizados pela AI tiveram como desfecho a estabilidade clínica**. No 1º Trimestre de 2020 foram contabilizados, dos 31 acionamento de código amarelo, 26 desfechos relacionados a estabilidade clínica, 3 transferências a UTI e 4 óbitos. Estes eventos adversos estão relacionados a não detecção precoce de sinais de deterioração clínica, visto que o paciente apresentou condições clínicas características de evolução desfavorável de seu quadro sem que houvesse atuação preventiva. No mesmo período de 2021, não foram acionados códigos azuis (pois não ocorreram paradas cardiorrespiratórias) bem como não houve necessidade de transferir nenhum paciente a unidades de maior complexidade. A atuação de algoritmos de IA permitiu direcionar as equipes assistenciais a um monitoramento

mais efetivo, favorecer que os profissionais ficassem mais próximos dos pacientes, norteou coletas de dados com menores intervalos de tempo e agiu de forma preditiva por meio de tomadas de decisão precoces ao surgimento de alterações clínicas que resultariam em desfechos desfavoráveis. Desta forma, é possível evidenciar que o direcionamento dos alarmes disponibilizados pela tecnologia fora assertivo, uma vez que os demais pacientes, fora de criticidade conforme parâmetros da tecnologia de IA, não apresentaram sinais de deterioração e evoluíram com prognóstico favorável e tiveram alta por melhora clínica. Tais constatações avigoram o trabalho de Heili-Frades *et al.* (2020), que evidencia a contribuição da tecnologia IA e a aplicação de sistemas neurais na identificação de sinais preditores ao considerar o risco de mortalidade, por meio de avaliações individualizadas e oportunas dos pacientes, bem como a redução de falhas assistenciais após a implantação de tecnologia de IA para o monitoramento de pacientes. Da mesma forma, Khanna *et al.* (2019) afirmaram a importância do monitoramento contínuo de pacientes e aplicação de mecanismos peditórios para prevenir deterioração clínica e evitar a ocorrência de parada cardiorrespiratória em tempo hábil para garantir a estabilidade clínica de pacientes.

6 CONCLUSÃO

Este estudo alcançou seu objetivo de apresentar uma análise da aplicação de IA no monitoramento de sinais vitais de pacientes para redução de riscos de deterioração clínica. As informações da literatura, bem como a estruturação e o desenvolvimento do estudo de caso proposto permitiu comparar os resultados assistenciais anteriores e posteriores a implantação da tecnologia IA como apoio a identificação precoce de sinais de deterioração clínica em pacientes.

Desta forma, foi possível responder à questão de pesquisa sugerida, de modo que os resultados obtidos validaram a contribuição da tecnologia na melhoria do monitoramento e identificação precoce de sinais de deterioração clínica de pacientes. Observou-se que o mecanismo de avaliação clínica de pacientes passou a ter maior foco em alterações de sinais vitais como marcador de risco para deterioração clínica, assim como houve aumento expressivo no acionamento de apoio assistencial para avaliação de paciente com sinais de deterioração, porém de forma precoce ao surgimento de desfechos desfavoráveis. Não houve, após a implantação da tecnologia de IA, óbito ou transferência para unidades de maior complexidade de pacientes monitorados durante o estudo de caso.

Esta pesquisa contribui com a comunidade científica por meio da apresentação de evidências estruturadas após a realização de um estudo de caso, bem como avaliação de resultados obtidos frente a implantação de uma nova tecnologia em ambiente hospitalar. Desta forma, permitiu maior conhecimento sobre a área de saúde e a adoção de tecnologias em seus processos.

Há também contribuições para gestão de operações hospitalar. Como qualquer empresa, para garantir resultados favoráveis e manter seu nível de competitividade no mercado, instituições de saúde contam com indicadores para o monitoramento de seus processos, pois subsidiam a tomada de decisões estratégicas. Por ter como principal objetivo a assistência a pacientes, resultados assistenciais devem ser acompanhados com a intenção de garantir melhoria contínua de processos e mitigação de danos associados a assistência.

Como contribuição a sociedade, este estudo apresenta a possibilidade de conferir maior segurança e assertividade por meio da adoção de tecnologias. Processos assistenciais mais seguros e a possibilidade de integração de tecnologias

as rotinas do cuidado garantem a população assistência cuidado integral e individualizado.

O presente trabalho teve como limitação a realização de seu estudo em uma única unidade de internação hospitalar não crítica com atendimento exclusivo a população adulta. Recomenda-se futuros estudos voltados à avaliação das contribuições de IA em unidades de diferentes perfis epidemiológicos e níveis de criticidade. Também, estudar mecanismos de monitoramento de pacientes por meio da integração entre equipamentos de monitoramento de sinais vitais e sistemas de prontuário eletrônico, sem a intervenção humana na coleta e registro de dados.

REFERÊNCIAS BIBLIOGRÁFICAS

AIASSA, S.; ROS, P. M.; HANITRA, M. I. N.; TUNZI, D.; MARTINA, M.; CARRARA, S.; DEMARCHI, D. Smart Portable Pen for Continuous Monitoring of Anaesthetics in Human Serum With Machine Learning. **IEEE Trans Biomed Circuits Syst.** v. 15(2), p. 294-302. 2021.

ALAM, M. D.; RABIUL, G.; MUNIR, S.; UDDIN, Z.; ALAM, M. S.; DANG, T. N.; HONG, C. S. Edge-of-Things Computing Framework for Cost-Effective Provisioning of Healthcare Data. **Journal of Parallel and Distributed Computing.** v. 123, p. 54–60. 2019.

ALGHATANI, K.; AMMAR, N.; REZGUI, A.; SHABAN-NEJAD, A. Predicting Intensive Care Unit Length of Stay and Mortality Using Patient Vital Signs: Machine Learning Model Development and Validation. **JMIR medical informatics.** v. 9(5), p. 21347. 2021.

AL-MUTAIRI, A.W.; AL-AUBIDY, K.M.; ALHALAIQA, F.N. IoT-Based Real-Time Monitoring System for Epidemic Diseases Patients: Design and Evaluation. **International journal of online and biomedical engineering.** v. 17(1), p. 63-82. 2021.

ALTILIO, R.; ROSSETTI, A.; FANG, Q.; GU, X.; PANELLA, M. A comparison of machine learning classifiers for smartphone-based gait analysis. **Med Biol Eng Comput.** v. 59(3), p. 535-546. 2021.

AL-ZINATI, M.; ALMASRI, T.; ALSMIRAT, M.; JARARWEH, Y. Enabling multiple health security threats detection using mobile edge computing. **Simulation Modelling Practice and Theory.** 101957. 2019.

AMIN, S. U.; HOSSAIN, M. S. Edge Intelligence and Internet of Things in Healthcare: A Survey. **IEEE Access.** v. 9, p. 45-59. 2021.

ASHLEIBTA, A. M.; ABBASI, Q. H.; SHAH, S. A.; ABUALI, N. A.; IMRAN, M. A. Non-Invasive RF Sensing for Detecting Breathing Abnormalities Using Software Defined Radios. **IEEE Sensors Journal.** v. 21(4), p. 5111-5118. 2021.

AUGELLO, A.; INFANTINO, I.; ADRIANO MANFRÉ, G.; PILATO, F. V.; CHELLA, A. Creation and cognition for humanoid live dancing. **Robotics Auton. Syst.** v. 86, p. 128-137. 2016.

AZNAR-GIMENO, R.; ESTEBAN, L. M.; LABATA-LEZAUN, G.; DEL-HOYO-ALONSO, R.; ABADIA-GALLEGRO, D.; PAÑO-PARDO, J. R.; ESQUILLOR-RODRIGO, M. J.; LANAS, Á.; SERRANO, M. T. A Clinical Decision Web to Predict ICU Admission or Death for Patients Hospitalised with COVID-19 Using Machine Learning Algorithms. **International journal of environmental research and public health.** v. 18(16), p. 8677. 2021.

BAUMEISTER, R. F.; LEARY, M. R. Writing Narrative Literature Reviews. **Review of General Psychology.** v. 3, p. 311–20. 1997.

BELBIN, G. M.; CULLINA, S.; WENRIC, S.; SOPER, E. R.; GLICKSBERG, B. S.; TORRE, D.; MOSCATI, A.; WOJCIK, G. L.; SHEMIRANI, R.; BECKMANN, N. D.; COHAIN, A.; SOROKIN, E. P.; PARK, D. S.; AMBITE, J. L.; ELLIS, S.; AUTON, A.; BOTTINGER, E. P.; CHO, J. H.; LOOS, R. J. F.; ABUL-HUSN, N. S.; ZAITLEN, N. A.; GIGNOUX, C. R.; KENNY, E. E. Toward a fine-scale population health monitoring system. **Cell**. v.15;184(8), p. 2068-2083. 2021.

BEN HASSEN, H.; AYARI, N.; HAMDY, B. A home hospitalization system based on the Internet of things, Fog computing and cloud computing. **Informatics in Medicine Unlocked**. v. 20, p, 100368. 2020.

BLOCK, F. E. Why we do not have - and will not have - the integrated and “smart” alarm systems that technology would allow us to have today. **Journal of Electrocardiology**. v. 45(6), p. 592–595. 2012.

BONAKDARI, H.; JAMSHIDI, A.; PELLETIER, J. P.; ABRAM, F.; TARDIF, G.; MARTEL-PELLETIER, J. A warning machine learning algorithm for early knee osteoarthritis structural progressor patient screening. **Ther Adv Musculoskelet Dis**. 2021.

CELESTI, A.; LAY-EKUAKILLE, A.; WAN, J.; FAZIO, M.; CELESTI, F.; ROMANO, A.; VILLARI, M. Information Management in IoT Cloud-Based Tele-Rehabilitation as a Service for Smart Cities: Comparison of NoSQL Approaches. **Measurement**. 107218. 2019.

CHABI, M. L.; DANA, O.; KENNEL, T.; GENGE-BRENEY, A.; SALVATOR, H.; BALLESTER, M. C.; VASSE, M.; BRUN, A. L.; MELLOTT, F.; GRENIER, P. A. Automated AI-Driven CT Quantification of Lung Disease Predicts Adverse Outcomes in Patients Hospitalized for COVID-19 Pneumonia. **Diagnostics**. v. 14;11(5), p. 878. 2021.

CHAO, H.; FANG, X.; ZHANG, J.; HOMAYOUNIEH, F.; ARRU, C. D.; DIGUMARTHY, S. R.; BABAEI, R.; MOBIN, H. K.; MOHSENI, I.; SABA, L.; CARRIERO, A.; FALASCHI, Z.; PASCHE, A.; WANG, G.; KALRA, M. K.; YAN, P. Integrative analysis for COVID-19 patient outcome prediction. **Med Image Anal**. v. 67, p. 101844. 2021.

CHATRATI, S.P.; HOSSAIN, G.; GOYAL, A.; BHAN, A.; BHATTACHARYA, S.; GAURAV, D.; TIWARI, S. Smart home health monitoring system for predicting type 2 diabetes and hypertension. **Computer and Information Sciences**. 2020.
CHEN, J.; SEE, K. C. Artificial Intelligence for COVID-19: Rapid Review. **Journal of Medical Internet Research**. v. 22(10), p. 21476. 2020.

CHICCO, D.; JURMAN, G. An ensemble learning approach for enhanced classification of patients with hepatitis and cirrhosis. **IEEE Access**. v. 9, p. 24485-24498. 2021.

CHICCO, D.; JURMAN, G. Arterial Disease Computational Prediction and Health Record Feature Ranking among Patients Diagnosed with Inflammatory Bowel Disease. **IEEE Access**. v. 9, p. 78648-78657. 2021.

CHOU, C. A.; CAO, Q.; WENG, S. J.; TSAI, C.H. Mixed-integer optimization approach to learning association rules for unplanned ICU transfer. **Artificial Intelligence in Medicine**. v. 103, p. 101806. 2020.

CHURPEK, M. M.; YUEN, T. C.; WINSLOW, C.; MELTZER, D. O.; KATTAN, M. W.; EDELSON, D. P. Multicenter Comparison of Machine Learning Methods and Conventional Regression for Predicting Clinical Deterioration on the Wards. **Crit Care Med**. v. 44(2), p. 368-74. 2016.

COBRE, A. F.; STREMEL, D. P.; NOLETO, G. R.; FACHI, M. M.; SUREK, M.; WIENS, A.; TONIN, F. S.; PONTAROLO, R. Diagnosis and prediction of COVID-19 severity: can biochemical tests and machine learning be used as prognostic indicators? **Comput Biol Med**. v. 134, p. 104531. 2021.

COLIN, T.R.; BELPAEME, T.; CANGELOSI, A.; HEMION, N.J. Hierarchical reinforcement learning as creative problem solving. **Robotics Auton. Syst.** v. 86, p. 196-206. 2016.

COOPER, H.M.; LINDSAY, J.L. Research synthesis and meta-analysis. **Handbook of applied social research methods**. Thousand Oaks, CA: Sage. 1998.

COQUET, J.; BOZKURT, S.; KAN, K. M.; FERRARI, M. K.; BLAYNEY, D. W.; BROOKS, J. D.; HERNANDEZ-BOUSSARD, T. Comparison of orthogonal NLP methods for clinical phenotyping and assessment of bone scan utilization among prostate cancer patients. **Journal of Biomedical Informatics**. v. 94, p. 103184. 2019.

COUSYN, L.; NAVARRO, V.; CHAVEZ, M. Preictal state detection using prodromal symptoms: A machine learning approach. **Epilepsia**. v. 2(2), p. 42-47. 2021.

CRUZ, M. F.; ONO, N.; HUANG, M.; ALTAF-UL-AMIN, M.; KANAYA, S.; CAVALCANTE, C. Kinematics approach with neural networks for early detection of sepsis (KANNEDS). **BMC medical informatics and decision making**. v. 21(1), p. 163. 2021.

DABBAH, M. A.; REED, A. B.; BOOTH, A. T. C. Machine learning approach to dynamic risk modeling of mortality in COVID-19: a UK Biobank study. **Sci Rep**. v. 11(1), p. 16936. 2021.

DAVIS, J.; MENGERSEN, K.; BENNETT, S.; MAZEROLLE, L. Viewing systematic reviews and meta-analysis in social research through different lenses. **SpringerPlus**. v. 3, p. 511. 2014.

DE HOND, A.; RAVEN, W.; SCHINKELSHOEK, L.; GAAKEER, M.; TER AVEST, E.; SIR, O.; LAMEIJER, H.; HESSELS, R. A.; REIJNEN, R.; DE JONGE, E.; STEYERBERG, E. Machine learning for developing a prediction model of hospital admission of emergency department patients: Hype or hope? **International journal of medical informatics**. v. 152, p. 104496. 2021.

DE SOUZA, L. A.; MENDEL, R.; STRASSER, S.; EBIGBO, A.; PROBST, A.; MESSMANN, H.; PAPA, J. P.; PALM, C. Convolutional Neural Networks for the evaluation of cancer in Barrett's esophagus: Explainable AI to lighten up the black-box. **Comput Biol Med.** v. 135, p. 104578. 2021.

DU, H.; FENG, L.; XU, Y.; ZHAN, E.; XU, W. Clinical Influencing Factors of Acute Myocardial Infarction Based on Improved Machine Learning. **J Healthc Eng.** v. 27, p. 5569039. 2021.

EBRAHIMIAN, S.; HOMAYOUNIEH, F.; ROCKENBACH, M. A.; PUTHA, P.; RAJ, T.; DAYAN, I.; BIZZO, B.; BUCH, V.; WU, D.; KIM, K.; LI, Q.; Digumarthy, S.; Kalra, M. Artificial intelligence matches subjective severity assessment of pneumonia for prediction of patient outcome and need for mechanical ventilation: a cohort study. **Scientific Reports.** v. 11. 2021.

EBRAHIMIAN, S.; HOMAYOUNIEH, F.; ROCKENBACH, M.; PUTHA, P.; RAJ, T.; DAYAN, I.; BIZZO, B. C.; BUCH, V.; WU, D.; KIM, K.; LI, Q.; DIGUMARTHY, S. R.; KALRA, M. K. Artificial intelligence matches subjective severity assessment of pneumonia for prediction of patient outcome and need for mechanical ventilation: a cohort study. **Sci Rep.** v. 3;11(1), p. 858. 2021.

EL-HAJJ, C.; KYRIACOU, P. A. A review of machine learning techniques in photoplethysmography for the non-invasive cuff-less measurement of blood pressure. **Biomedical Signal Processing and Control.** v. 58, p. 101870. 2020.

ELWAHSH, H.; EL-SHAFEIY, E.; ALANAZI, S.; TAWFEEK, M. A. A new smart healthcare framework for real-time heart disease detection based on deep and machine learning. **PeerJ Comput Sci.** v. 28(7), p. 646. 2021.

FARAHMAND, S.; SHABESTARI, O.; PAKRAH, M.; HOSSEIN-NEJAD, H.; ARBAB, M.; BAGHERI-HARIRI, S. Artificial Intelligence-Based Triage for Patients with Acute Abdominal Pain in Emergency Department; a Diagnostic Accuracy Study. **Adv J Emerg Med.** v.1(1), p. 5. 2017.

FENG, Y. N.; XU, Z. H.; LIU, J. T.; SUN, X. L.; WANG, D. Q.; YU, Y. Intelligent prediction of RBC demand in trauma patients using decision tree methods. **Military Medical Research.** v. 8(1), p. 33. 2021.

FIROUZI, F. *et al.*; Harnessing the Power of Smart and Connected Health to Tackle COVID-19: IoT, AI, Robotics, and Blockchain for a Better World. **IEEE Internet of Things Journal.** v. 8(16), p. 12826-12846. 2021.

FORKAN, A. R. M.; KHALIL, I. PEACE-Home: Probabilistic estimation of abnormal clinical events using vital sign correlations for reliable home-based monitoring. **Pervasive and Mobile Computing.** v. 38, p. 296–311. 2017.

FORKAN, A. R. M.; KHALIL, I.; ATIQUZZAMAN, M. ViSiBiD: A learning model for early discovery and real-time prediction of severe clinical events using vital signs as big data. **Computer Networks.** v. 113, p. 244–257. 2017.

FORKAN, A. R. M.; KHALIL, I.; TARI, Z.; FOUFOU, S.; BOURAS, A. A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living. **Pattern Recognition**. v. 48(3), p. 628–641. 2015.

FORKAN, A.; KHALIL, I. A clinical decision-making mechanism for context-aware and patient-specific remote monitoring systems using the correlations of multiple vital signs. **Computer methods and programs in biomedicine**. v. 139, p. 1-16. 2017.

GAUTHIER, P.; CARDOT, J. M. Health care digitalization, the straightest pathway to personalization. **Farmacia**. v. 69(2), p. 238-245. 2021.

GREENBAUM, N. R.; JERNITE, Y.; HALPERN, Y.; CALDER, S.; NATHANSON, L. A.; SONTAG, D. A.; HORNG, S. Improving documentation of presenting problems in the emergency department using a domain-specific ontology and machine learning-driven user interfaces. **Int J Med Inform**. v. 132, p. 103981. 2019.

GULTEPE, E.; GREEN, J. P.; NGUYEN, H.; ADAMS, J.; ALBERTSON, T.; TAGKOPOULOS, I. From vital signs to clinical outcomes for patients with sepsis: a machine learning basis for a clinical decision support system. **J Am Med Inform Assoc**. v. 21(2), p. 315-25. 2014.

HAGHAYEGH, S.; KHOSHNEVIS, S.; SMOLENSKY, M. H.; DILLER, K. R.; CASTRIOTTA, R. J. Deep Neural Network Sleep Scoring Using Combined Motion and Heart Rate Variability Data. **Sensors**. v. 23;21(1), p. 25. 2021.

HAHM, C. R.; LEE, Y. K.; OH, D. H.; AHN, M. Y.; CHOI, J. P.; KANG, N. R.; OH, J.; CHOI, H.; KIM, S. Factors Associated with Worsening Oxygenation in Patients with Non-severe COVID-19 Pneumonia. **Tuberc Respir Dis**. v. 84(2), p. 115-124. 2021.

HAN, T. T.; PHAM, H. Y.; NGUYEN, D. S. L.; ISHIBASHI, K.; SUN, G. Machine learning based classification model for screening of infected patients using vital signs. **Informatics in Medicine Unlocked**. v. 24, p. 100592. 2021.

HANITRA, I. N.; CRISCUOLO, F.; CARRARA, S.; DE MICHELI, G. Multi-Ion-Sensing Emulator and Multivariate Calibration Optimization by Machine Learning Models. **IEEE Access**. v. 9, p. 46821-46836. 2021.

HARRER, S.; SHAH, P.; ANTONY, B.; HU, J. Artificial Intelligence for Clinical Trial Design. **Trends in Pharmacological Sciences**. v. 40(8), p. 577–591. 2019.
HAUSKRECHT, M.; BATAL, I.; VALKO, M.; VISWESWARAN, S.; COOPER, G. F.; CLERMONT, G. Outlier detection for patient monitoring and alerting. **Journal of Biomedical Informatics**. v. 46(1), p. 47–55. 2013.

HEILI-FRADES, S.; MINGUEZ, P.; MAHILLO FERNÁNDEZ, I.; JIMÉNEZ HISCOCK, L.; SANTOS, A.; HEILI FRADES, D.; PECES-BARBA ROMERO,

G. Patient Management Assisted by a Neural Network Reduces Mortality in an Intermediate Care Unit. **Archivos de Bronconeumología**. 2020.

HIRANO, Y.; KONDO, Y.; HIFUMI, T.; YOKOBORI, S.; KANDA, J.; SHIMAZAKI, J.; HAYASHIDA, K.; MORIYA, T.; YAGI, M.; TAKAUJI, S.; YAMAGUCHI, J.; OKADA, Y.; OKANO, Y.; KANEKO, H.; KOBAYASHI, T.; FUJITA, M.; YOKOTA, H.; OKAMOTO, K.; TANAKA, H.; YAGUCHI, A. Machine learning-based mortality prediction model for heat-related illness. **Scientific reports**. v. 11(1), p. 9501. 2021.

HOLDSWORTH, L. M.; KLING, S.; SMITH, M.; SAFAEINILI, N.; SHIEH, L.; VILENDRER, S.; GARVERT, D. W.; WINGET, M.; ASCH, S. M.; LI, R. C. Predicting and Responding to Clinical Deterioration in Hospitalized Patients by Using Artificial Intelligence: Protocol for a Mixed Methods, Stepped Wedge Study. **JMIR research protocols**. v.10(7), p. 27532. 2021.

HU, L.; YANG, J.; CHEN, M.; QIAN, Y.; RODRIGUES, J. J. P. C. SCAI-SVSC: Smart clothing for effective interaction with a sustainable vital sign collection. **Future Generation Computer Systems**. v. 86, p. 329–338. 2018.

HUANG, C.-T.; CHANG, R.-C.; TSAI, Y.-L.; WU, C.-L.; LAI, C.-M. Entropy-based time window features extraction for machine learning to predict acute kidney injury in ICU. **Applied Sciences**. v. 11(14), p. 6364. 2021.

HUERTAS CELDRÁN, A.; GIL PÉREZ, M.; GARCÍA CLEMENTE, F. J.; MARTÍNEZ PÉREZ, G. Sustainable securing of Medical Cyber-Physical Systems for the healthcare of the future. **Sustainable Computing: Informatics and Systems**. v. 19, p. 138–146. 2018.

HUSSAIN, T.; NUGENT, C.; MOORE, A.; LIU, J.; BEARD, A. A Risk-Based IoT Decision-Making Framework Based on Literature Review with Human Activity Recognition Case Studies. **Sensors**. v. 30;21(13), p. 4504. 2021.

HWANG, G.; HAN, J-H.; CHANG, T-W. An Integrated Key Performance Measurement for Manufacturing Operations Management. **Sustainability**. v. 12(13), p. 5260. 2020.

IBRAHIM, Z.; BEAN, D.; SEARLE, T.; QIAN, L.; WU, H.; SHEK, A.; KRALJEVIC, Z.; GALLOWAY, J.; NORTON, S.; TEO, J.; DOBSON, R. J. A Knowledge Distillation Ensemble Framework for Predicting Short and Long-term Hospitalisation Outcomes from Electronic Health Records Data. **EEE journal of biomedical and health informatics**. 2021.

IKEMURA, K.; BELLIN, E.; YAGI, Y.; BILLETT, H.; SAADA, M.; SIMONE, K.; STAHL, L.; SZYMANSKI, J.; GOLDSTEIN, D. Y.; REYES GIL, M. Using Automated Machine Learning to Predict the Mortality of Patients With COVID-19: Prediction Model Development Study. **Journal of medical Internet research**. v. 23(2), p. 23458. 2021.

JACQUES, T.; FOURNIER, L.; ZINS, M.; ADAMSBAUM, C.; CHAUMOITRE, K.;

FEYDY, A.; MILLET, I.; MONTAUDON, M.; BEREGI, J. P.; BARTOLI, J. M.; CART, P.; MASSON, J. P.; MEDER, J. F.; BOYER, L.; COTTEN, A. Proposals for the use of artificial intelligence in emergency radiology. **Diagn Interv Imaging**. v. 102(2), p. 63-68. 2021.

JI, N.; XIANG, T.; BONATO, P.; LOVELL, N. H.; OOI, S. Y.; CLIFTON, D. A.; AKAY, M.; DING, X. R.; YAN, B. P.; MOK, V.; FOTIADIS, D. I.; ZHANG, Y. T. Recommendation to Use Wearable-Based mHealth in Closed-Loop Management of Acute Cardiovascular Disease Patients During the COVID-19 Pandemic. **IEEE J Biomed Health Inform**. v. 25(4), p. 903-908. 2021.

JIANG, W.; MAJUMDER, S.; SUBRAMANIAM, S.; LI, X.; KHEDRI, R.; MONDAY, T.; ABOLGHASEMIAN, M.; SATIA, I.; DEEN, M. J. A Wearable Tele-Health System towards Monitoring COVID-19 and Chronic Diseases. **IEEE Rev Biomed Eng**. v. 30. 2021.

JOO, M.-I.; KIM, H.-C. A vital sign analysis system based on algorithm block broker for interoperability between algorithm development tools. **Applied Sciences**. v. 11(4), p. 1-13. 2021.

KAIESKI, N.; COSTA, C.; RIGHI, R.D.; LORA, P.; ESKOFIER, B. Application of artificial intelligence methods in vital signs analysis of hospitalized patients: A systematic literature review. **Appl. Soft Comput**. v. 96, p. 106612. 2020.

KAKAVAS, G.; MALLIAROPOULOS, N.; PRUNA, R.; MAFFULLI, N. Artificial Intelligence A tool for sports trauma prediction. **Injury**. 2019.

KAMOUSHI, B.; KARUNAKARAN, S.; GURURANGAN, K.; MARKERT, M.; DECKER, B.; KHANKHANIAN, P.; MAINARDI, L.; QUINN, J.; WOO, R.; PARVIZI, J. Monitoring the Burden of Seizures and Highly Epileptiform Patterns in Critical Care with a Novel Machine Learning Method. **Neurocrit Care**. v. 34(3), p. 908-917. 2021.

KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**. 2018.

KARLSSON, A.; STASSEN, W.; LOUTFI, A.; WALLGREN, U.; LARSSON, E.; KURLAND, L. Predicting mortality among septic patients presenting to the emergency department-a cross sectional analysis using machine learning. **BMC Emerg Med**. v. 21(1), p. 84. 2021.

KERR, E.; MCGINNITY, T. M.; COLEMAN, S.; SHEPHERD, A. Human vital sign determination using tactile sensing and fuzzy triage system. **Expert Systems with Applications**. v. 175, p. 114781. 2021.

KERR, E.; MCGINNITY, T.; COLEMAN, S. Material recognition using tactile sensing. **Expert Systems with Applications**. v. 94, p. 94-111. 2018.

KHAN, M. B.; REHMAN, M.; MUSTAFA, A.; SHAH, R. A.; YANG, X. Intelligent

non-contact sensing for connected health using software defined radio technology. **Electronics**. v. 10(13), p.1558. 2021.

KHANNA, A. K.; AHUJA, S.; WELLER, R. S.; HARWOOD, T. N. Postoperative ward monitoring - Why and what now? **Best Pract Res Clin Anaesthesiol**. v. 33(2) p. 229-245. 2019.

KIM, B. J.; JANG, S. K.; KIM, Y. H.; LEE, E. J.; CHANG, J. Y.; KWON, S. U.; KIM, J. S.; KANG, D. W. Diagnosis of Acute Central Dizziness With Simple Clinical Information Using Machine Learning. **Frontiers in neurology**. v. 12, p. 691057. 2021.

KIM, T.; KIM, H. A healthcare system as a service in the context of vital signs: Proposing a framework for realizing a model. **Comput. Math. Appl**. v. 64, p. 1324-1332. 2012.

KOBAYASHI, N.; SHIGA, T.; IKUMI, S.; WATANABE, K.; MURAKAMI, H.; YAMAUCHI, M. Semi-automated tracking of pain in critical care patients using artificial intelligence: a retrospective observational study. **Scientific reports**. v. 11(1), p. 5229. 2021.

KRUGER, G. H.; TREMPER, K. K. Advanced integrated real-time clinical displays. **Anesthesiol Clin**. v. 29(3), p. 487-504. 2011.

KRYSKO, K. M.; AKHBARDEH, A.; ARJONA, J.; NOURBAKHS, B.; WAUBANT, E.; GOURRAUD, P.; GRAVES, J.S. Biosensor vital sign detects multiple sclerosis progression. **Ann Clin Transl Neurol**. v. 8(1), p. 4-14. 2021.

KUMAR, V.; RECUPERO, D.R.; RIBONI, D.; HELAOUI, R. Ensembling Classical Machine Learning and Deep Learning Approaches for Morbidity Identification from Clinical Notes. **IEEE Access**. v. 9, p. 7107-7126. 2021.

LAL, A.; PINEVICH, Y.; GAJIC, O.; HERASEVICH, V.; PICKERING, B. Artificial intelligence and computer simulation models in critical illness. **World J Crit Care Med**. v. 5;9(2), p. 13-19. 2020.

LEITNER, J.; HARDING, S.; CHANDRASHEKHARIAH, P.; FRANK, M.; FÖRSTER, A.; TRIESCH, J.; SCHMIDHUBER, J. Learning visual object detection and localisation using icVision. **Biologically Inspired Cognitive Architectures**. v. 5, p. 29–41. 2013.

LEMAIGNAN, S.; WARNIER, M.; SISBOT, E.A.; CLODIC, A.; ALAMI, R. Artificial cognition for social human-robot interaction: An implementation. **Artif. Intell**. v. 247, p. 45-69. 2017.

LI, L.; LEE, C. C.; ZHOU, F. L.; MOLONY, C.; DODER, Z.; ZALMOVER, E.; SHARMA, K.; JUHAERI, J.; WU, C. Performance assessment of different machine learning approaches in predicting diabetic ketoacidosis in adults with type 1 diabetes using electronic health records data. **Pharmacoepidemiology and drug safety**. v. 30(5), p. 610-618. 2021.

LÓPEZ-SASTRE, R. J.; BAPTISTA-RÍOS M, ACEVEDO-RODRÍGUEZ FJ, PACHECO-DA-COSTA S, MALDONADO-BASCÓN S, LAFUENTE-ARROYO S. A Low-Cost Assistive Robot for Children with Neurodevelopmental Disorders to Aid in Daily Living Activities. **Int J Environ Res Public Health**. v. 9;18(8), p. 3974. 2021.

LORETO, M.; LISBOA, T.; MOREIRA, V. P. Early prediction of ICU readmissions using classification algorithms. **Comput Biol Med**. v. 118, p. 103636. 2020.
LOWERY, C. What Is Digital Health and What Do I Need to Know About It? **Obstet Gynecol Clin North Am**. v. 47(2), p. 215-225. 2020.

LU, J. Q.; MUSHEYEV, B.; PENG, Q.; DUONG, T. Q. Neural network analysis of clinical variables predicts escalated care in COVID-19 patients: a retrospective study. **PeerJ**. v. 9, p. 11205. 2021.

LUO, Y.; XU, Q.; JIN, R.; WU, M.; LIU, L. Automatic detection of retinopathy with optical coherence tomography images via a semi-supervised deep learning method. **Biomedical optics express**. v. 12(5), p. 2684-2702. 2021.

LUŠTREK, M.; BOHANEK, M.; CAVERO, C.; CIANCARELLI, M. C.; CLAYS, E.; DAWODU, A. A.; DERBOVEN, J.; SMEDT, D.; DOVGAN, E.; LAMPE, J.; MARINO, F.; MLAKAR, M.; PIOGGIA, G.; PUDDU, P. E.; RODRÍGUEZ, J. M.; SCHIARITI, M.; SLAPNIČAR, G.; SLEGERS, K.; TARTARISCO, G.; VALIČ, J.; VODOPIJA, A. A Personal Health System for Self-Management of Congestive Heart Failure (HeartMan): Development, Technical Evaluation, and Proof-of-Concept Randomized Controlled Trial. **JMIR Med Inform**. v. 5;9(3), p. 24501. 2021.

LYBARGER, K.; OSTENDORF, M.; THOMPSON, M.; YETISGEN, M. Extracting COVID-19 diagnoses and symptoms from clinical text: A new annotated corpus and neural event extraction framework. **Journal of biomedical informatics**. v. 117, p. 103761. 2021.

MA, J.; WANG, Y.; NA, X.; GE, C.; YU, Z.; CHEN, J. Toward data-efficient learning: A benchmark for COVID-19 CT lung and infection segmentation. **Med Phys**. v. 48(3), p. 1197-1210. 2021.

MALYCHA, J.; FARAJIDAVAR, N.; PIMENTEL, M. A. F.; REDFERN, O.; CLIFTON, D. A.; TARASSENKO, L.; MEREDITH, P.; PRYTHERCH, D.; LUDBROOK, G.; YOUNG, J. D.; WATKINSON, P. J. The effect of fractional inspired oxygen concentration on early warning score performance: A database analysis. **Resuscitation**. v. 139, p. 192-199. 2019.

MAO, Y.; ZHANG, L. Optimization of the Medical Service Consultation System Based on the Artificial Intelligence of the Internet of Things. **IEEE Access**. v. 9, p. 98261-98274. 2021.

MARINCOWITZ, C.; PATON, L.; LECKY, F.; TIFFIN, P. Predicting need for

hospital admission in patients with traumatic brain injury or skull fractures identified on CT imaging: a machine learning approach. **Emerg Med J**. v. 8, p. 210776. 2021.

MATHIOUDAKIS, N. N.; ABUSAMAAN, M. S.; SHAKARCHI, A. F.; SOKOLINSKY, S.; FAYZULLIN, S.; MCGREADY, J.; ZILBERMINT, M.; SARIA, S.; GOLDEN, S. H. Development and Validation of a Machine Learning Model to Predict Near-Term Risk of Iatrogenic Hypoglycemia in Hospitalized Patients. **JAMA Netw Open**. v. 4;4(1), p. 2030913. 2021.

MAUER, E.; LEE, J.; CHOI, J.; ZHANG, H.; HOFFMAN, K. L.; EASTHAUSEN, I. J.; RAJAN, M.; WEINER, M. G.; KAUSHAL, R.; SAFFORD, M. M.; STEEL, P.; BANERJEE, S. A predictive model of clinical deterioration among hospitalized COVID-19 patients by harnessing hospital course trajectories. **Journal of biomedical informatics**. v. 118, p. 103794. 2021.

MELIÁ, S.; NASABEH, S.; LUJÁN-MORA, S.; CACHERO, C. MoSloT: Modeling and Simulating IoT Healthcare-Monitoring Systems for People with Disabilities. **Int J Environ Res Public Health**. v. 11;18(12), p. 6357. 2021.

MIGUEL, P. A. C. Estudo de caso na engenharia de produção: estruturação e recomendações para sua condução. **Production**, v. 17(1), p. 216–229. 2007. MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D. G.; Preferred Reporting Items for Systematic Reviews and Meta-Analyses. **The PRISMA Statement, Physical Therapy**, v. 89, p. 873–880. 2009.

MORET-BONILLO, V.; CABRERO-CANOSA, M.; HERNANDEZ-PEREIRA, E. Integration of data, information and knowledge in intelligent patient monitoring. **Expert Systems with Applications**. v. 15(2), p. 155–163. 1998.

MURALITHARAN, S.; NELSON, W.; DI, S.; MCGILLION, M.; DEVEREAUX, P. J.; BARR, N. G.; PETCH, J. Machine Learning-Based Early Warning Systems for Clinical Deterioration: Systematic Scoping Review. **Journal of medical Internet research**. v. 23(2), p. 25187. 2021.

NADEEM, M. W.; GOH, H. G.; KHAN, M. A.; HUSSAIN, M.; MUSHTAQ, M. F. Fusion-based machine learning architecture for heart disease prediction. **Computers, Materials & Continua**. v. 67(20), p. 2481-2496. 2021.

NEVES, A. L.; RODRIGUES, P.; MULLA, A.; GLAMPSON, B.; WILLIS, T.; DARZI, A.; MAYER, E. Using electronic health records to develop and validate a machine-learning tool to predict type 2 diabetes outcomes: a study protocol. **BMJ Open**. v. 30;11(7), p. 046716. 2021.

NG, Q.A.; CHIEW, Y.S.; WANG, X.; DAMANHURI, N.S.; CHASE, J.G. Network Data Acquisition and Monitoring System for Intensive Care Mechanical Ventilation Treatment. **IEEE Access**. v. 9, p. 91859-91873. 2021.

NGUYEN, C. V.; LE QUANG, T.; VU, T. N.; LE THI, H.; VAN, K. N.; TRONG, T. H.; ISHIBASHI, K. A non-contact infection screening system using medical radar

and Linux-embedded FPGA: Implementation and preliminary validation. **Informatics in Medicine Unlocked**. v. 16, p. 100225. 2019.

NIELSEN, A. B.; THORSEN-MEYER, H.-C.; BELLING, K.; NIELSEN, A. P.; THOMAS, C. E.; CHMURA, P. J.; BRUNAK, S. Survival prediction in intensive-care units based on aggregation of long-term disease history and acute physiology: a retrospective study of the Danish National Patient Registry and electronic patient records. **The Lancet Digital Health**. v. 1(2), p. e78–e89. 2019.

NSUGBE, E. A pilot exploration on the use of NIR monitored haemodynamics in gesture recognition for transradial prosthesis control. **Intelligent Systems with Applications**. v. 9, p. 200045. 2021.

OHATA, E. F.; BEZERRA, G. M.; CHAGAS, J. V. S. D.; ALBUQUERQUE, V. H. C. D.; REBOUCAS FILHO, P. P. Automatic detection of COVID-19 infection using chest X-ray images through transfer learning. **IEEE/CAA Journal of Automatica Sinica**. v. 8(1), p. 239-248. 2021.

OIKONOMIDI, T.; RAVAUD, P.; COSSON, E.; MONTORI, V.; TRAN, V. T. Evaluation of Patient Willingness to Adopt Remote Digital Monitoring for Diabetes Management. **JAMA Netw Open**. v. 4;4(1), p. 2033115. 2021.

OLSON, D. M.; DOMBROWSKI, K.; LYNCH, C.; MACE, B.; SINHA, R.; SPAINHOUR, S.; KOLLS, B. J. Comparison of health record vitals and continuously acquired vitals data identifies key differences in clinical impression. **Informatics in Medicine Unlocked**. v. 20, p. 100379. 2020.

PANAGGIO, M. J.; ABRAMS, D. M.; YANG, F.; BANERJEE, T.; SHAH, N. R. Can subjective pain be inferred from objective physiological data? Evidence from patients with sickle cell disease. **PLoS computational biology**. v. 17(3), p. 1008542. 2021.

PARIKH, R. B.; LINN, K. A.; YAN, J.; MACIEJEWSKI, M. L.; ROSLAND, A. M.; VOLPP, K. G.; GROENEVELD, P. W.; & NAVATHE, A. S. A machine learning approach to identify distinct subgroups of veterans at risk for hospitalization or death using administrative and electronic health record data. **PloS one**. v. 16(2), p. 0247203. 2021.

PEGORARO, J. A.; LAVAULT, S.; WATTIEZ, N.; SIMILOWSKI, T.; GONZALEZ-BERMEJO, J.; BIRMELÉ, E. Machine-learning based feature selection for a non-invasive breathing change detection. **BioData Min**. v. 18;14(1), p. 33. 2021.

PÉREZ-SANZ, F.; RIQUELME-PÉREZ, M.; MARTÍNEZ-BARBA E, DE LA PEÑA-MORAL J, SALAZAR NICOLÁS A, CARPES-RUIZ M, ESTEBAN-GIL A, LEGAZ-GARCÍA MDC, PARREÑO-GONZÁLEZ MA, RAMÍREZ P, MARTÍNEZ CM. Efficiency of Machine Learning Algorithms for the Determination of Macrovesicular Steatosis in Frozen Sections Stained with Sudan to Evaluate the Quality of the Graft in Liver Transplantation. **Sensors**. v. 12;21(6), p. 1993. 2021.

PIMENTEL, M.; REDFERN, O. C.; MALYCHA, J.; MEREDITH, P.; PRYTHERCH, D.; BRIGGS, J.; YOUNG, J. D.; CLIFTON, D. A.; TARASSENKO, L.; WATKINSON, P. J. Detecting Deteriorating Patients in the Hospital: Development and Validation of a Novel Scoring System. **American journal of respiratory and critical care medicine**. v. 204(1), p. 44-52. 2021.

PRESEDO, J.; VILA, J.; BARRO, S.; ORTEGA, F.P.; RUÍZ, R.; TADDEI, A.; EMDIN, M. Fuzzy modelling of the expert's knowledge in ECG-based ischaemia detection. **Fuzzy Sets Syst**. v. 77, p. 63-75. 1996.

PURNOMO, A. T.; LIN, D. B.; ADIPRABOWO, T.; HENDRIA, W. F. Non-Contact Monitoring and Classification of Breathing Pattern for the Supervision of People Infected by COVID-19. **Sensors**. v. 21(9), p. 3172. 2021.

QURESHI, M. A.; QURESHI, K. N.; JEON, G.; PICCIALI, F. Deep learning-based ambient assisted living for self-management of cardiovascular conditions. **Neural Computing and Applications**. 2021.

RADHACHANDRAN, A.; GARIKIPATI, A.; IQBAL, Z.; SIEFKAS, A.; BARNES, G.; HOFFMAN, J.; MAO, Q.; DAS, R. A machine learning approach to predicting risk of myelodysplastic syndrome. **Leukemia research**. v. 109, p. 106639. 2021.

RADHACHANDRAN, A.; GARIKIPATI, A.; ZELIN, N. S.; PELLEGRINI, E.; GHANDIAN, S.; CALVERT, J.; HOFFMAN, J.; MAO, Q.; DAS, R. Prediction of short-term mortality in acute heart failure patients using minimal electronic health record data. **BioData mining**. v. 14(1), p. 23. 2021.

RAMESH, J.; ABURUKBA, R.; SAGAHYROON, A. A remote healthcare monitoring framework for diabetes prediction using machine learning. **Healthc Technol Lett**. v. 2;8(3), p. 45-57. 2021.

RAMKUMAR, P. N.; HAEBERLE, H. S.; BLOOMFIELD, M. R.; SCHAFFER, J. L.; KAMATH, A. F.; PATTERSON, B. M.; KREBS, V. E. Artificial Intelligence and Arthroplasty at a Single Institution: Real-World Applications of Machine Learning to Big Data, Value-Based Care, Mobile Health, and Remote Patient Monitoring. **J Arthroplasty**. v. 34(10), p. 2204-2209. 2019.

RATHEE, G.; GARG, S.; KADDOUM, G.; K. JAYAKODY, D. N.; ALAMRI, A. ANN Assisted-IoT Enabled COVID-19 Patient Monitoring. **IEEE Access**. v. 9, p. 42483-42492. 2021.

RAZA, M.; AWAIS, M.; SINGH, N.; IMRAN, M.; HUSSAIN, S. Intelligent IoT Framework for Indoor Healthcare Monitoring of Parkinson's Disease Patient **IEEE Journal on Selected Areas in Communications**. v. 39(2), p. 593-602. 2021.

REZAEI, S.; MOTURU, A.; ZHAO, S.; PRKACHIN, K. M.; HADJISTAVROPOULOS, T.; TAATI, B. Unobtrusive Pain Monitoring in Older Adults With Dementia Using Pairwise and Contrastive Training. **IEEE J Biomed Health Inform**. v. 25(5), p. 1450-1462. 2021.

RICE, D.; BEBERNES, J.; CORMIER, J.; FAYOS, J.; FILLIOE, S.; PETERSON, C. M.; HOUK, M.; AMMENHEUSER, H.; CHAIKEN, J. PV[O]H: Noninvasive Enabling Technology, New Physiological Monitoring, and Big Data. **Mil Med**. v. 25;186, p. 458-464. 2021.

ROHMETRA, H.; RAGHUNATH, N.; NARANG, P.; CHAMOLA, V.; GUIZANI, M.; LAKKANIGA, N. R. AI-enabled remote monitoring of vital signs for COVID-19: methods, prospects and challenges. **Computing**. 2021.

ROY, S.; KIRAL, I.; MIRMOMENI, M.; MUMMERT, T.; BRAZ, A.; TSAY, J.; TANG, J.; ASIF, U.; SCHAFFTER, T.; AHSEN, M. E.; IWAMORI, T.; YANAGISAWA, H.; POONAWALA, H.; MADAN, P.; QIN, Y.; PICONE, J.; OBEID, I.; MARQUES, B. A.; MAETSCHKE, S.; KHALAF, R.; ROSEN-ZVI, M.; STOLOVITZKY, G.; HARRER, S. IBM Epilepsy Consortium. Evaluation of artificial intelligence systems for assisting neurologists with fast and accurate annotations of scalp electroencephalography data. **EBioMedicine**. v. 66, p.103275. 2021.

RYZHIKOVA, E.; RALBOVSKY, N. M.; SIKIRZHYTSKI, V.; KAZAKOV, O.; HALAMKOVA, L.; QUINN, J.; ZIMMERMAN, E. A.; LEDNEV, I. K.; Raman spectroscopy and machine learning for biomedical applications: Alzheimer's disease diagnosis based on the analysis of cerebrospinal fluid. **Spectrochim Acta A Mol Biomol Spectrosc**. v. 5, p. 119188. 2021.

SAHOO, P. K.; MOHAPATRA, S. K.; WU, S.-L. SLA based healthcare big data analysis and computing in cloud network. **Journal of Parallel and Distributed Computing**. v. 119, p. 121–135. 2018.

SAKR, S.; ELGAMMAL, A. Towards a Comprehensive Data Analytics Framework for Smart Healthcare Services. **Big Data Research**. v. 4, p. 44–58. 2016.

SANCHEZ-PINTO, L. N.; VENABLE, L. R.; FAHRENBACH, J.; CHURPEK, M. M. Comparison of variable selection methods for clinical predictive modeling. **International Journal of Medical Informatics**. v. 116, p. 10–17. 2018.

SANG, S.; SUN, R.; COQUET, J.; CARMICHAEL, H.; SETO, T.; & HERNANDEZ-BOUSSARD, T. Learning From Past Respiratory Infections to Predict COVID-19 Outcomes: Retrospective Study. **Journal of medical Internet research**. v. 23(2), p. 23026. 2021.

SCHULTEBRAUCKS, K.; SIJBRANDIJ, M.; GALATZER-LEVY, I.; MOUTHAN, J.; OLFF, M.; VAN ZUIDEN, M. Forecasting individual risk for long-term Posttraumatic Stress Disorder in emergency medical settings using biomedical data: A machine learning multicenter cohort study. **Neurobiology of stress**. v. 14, p. 100297. 2021.

SHAH, S. A.; AHMAD, J.; MASOOD, F.; IMRAN, M. A.; ABBASI, Q. H. Privacy-Preserving Wandering Behavior Sensing in Dementia Patients Using Modified Logistic and Dynamic Newton Leipnik Maps. **IEEE Sensors Journal**. v. 21(3), p. 3669-3679. 2021.

SHAH, S.; YU, C. N.; ZHENG, M.; KIM, H.; EGGLESTON, M. S. Microparticle-Based Biochemical Sensing Using Optical Coherence Tomography and Deep Learning. **ACS nano**. v. 15(6), p. 9764-9774. 2021.

SHAHI, N.; SHAHI, A. K.; PHILLIPS, R.; SHIREK, G.; BENSARD, D.; MOULTON, S. L. Decision-making in pediatric blunt solid organ injury: A deep learning approach to predict massive transfusion, need for operative management, and mortality risk. **J Pediatr Surg**. v. 56(2), p. 379-384. 2021.

SHAIKH, F.; DEHMESKI, J.; BISDAS, S.; ROETTGER-DUPONT, D.; KUBASSOVA, O.; AZIZ, M.; AWAN, O. Artificial Intelligence-Based Clinical Decision Support Systems Using Advanced Medical Imaging and Radiomics. **Current Problems in Diagnostic Radiology**. v. 50(2), p. 262–267. 2021.

SHARKEY, N. E.; ZIEMKE, T. Mechanistic versus phenomenal embodiment: Can robot embodiment lead to strong AI? **Cognitive Systems Research**. v. 2(4), p. 251–262. 2001.

SHEN, H.; HU, Y.; LIU, X.; JIANG, Z.; YE, H. Role of Cardiovascular Color Doppler Imaging Information Technology Under Artificial Intelligence Neural Network in the Diagnosis of Septic Shock Patients. **Neuroscience Letters**. 135199. 2020.

SIGNORONI, A.; SAVARDI, M.; BENINI, S.; ADAMI, N.; LEONARDI, R.; GIBELLINI, P.; VACCHER, F.; RAVANELLI, M.; BORGHESI, A.; MAROLDI, R.; FARINA, D. BS-Net: Learning COVID-19 pneumonia severity on a large chest X-ray dataset. **Med Image Anal**. v. 71, p. 102046. 2021.

SITE, A.; NURMI, J.; LOHAN, E. S. Systematic review on machine-learning algorithms used in wearable-based eHealth data analysis. **IEEE Access**. v. 9, p. 112221-112235. 2021.

SODHI, S. K.; TRIMBOLI, C.; KALAICHANDRAN, S.; PEREIRA, A.; CHOUDHRY, N. A proof of concept study to evaluate the treatment response of aflibercept in wARMd using OCT-A (Canada study). **Int Ophthalmol**. v. 41(5), p. 1697-1708. 2021.

SOGUERO-RUIZ, C.; HINDBERG, K.; MORA-JIMÉNEZ, I.; ROJO-ÁLVAREZ, J. L.; SKRØVSETH, S. O.; GODTLIEBSEN, F.; JENSSEN, R. Predicting colorectal

surgical complications using heterogeneous clinical data and kernel methods. **Journal of Biomedical Informatics**. v. 61, p. 87–96. 2016.

SOLTAN, A. A. S.; KOUCHAKI, S.; ZHU, T.; KIYASSEH, D.; TAYLOR, T.; HUSSAIN, Z. B.; PETO, T.; BRENT, A.J.; EYRE, D. W.; CLIFTON, D. A. Rapid triage for COVID-19 using routine clinical data for patients attending hospital: development and prospective validation of an artificial intelligence screening test. **Lancet Digit Health**. v. 3(2), p. e78-e872021.

SOLTAN, A.; KOUCHAKI, S.; ZHU, T.; KIYASSEH, D.; TAYLOR, T.; HUSSAIN, Z. B.; PETO, T.; BRENT, A. J.; EYRE, D. W.; CLIFTON, D. A. Rapid triage for COVID-19 using routine clinical data for patients attending hospital: development and prospective validation of an artificial intelligence screening test. **The Lancet**. v. 3(2), p. 78-87. 2021.

SONG, X.; LIU, M.; WAITMAN, L. R.; PATEL, A.; SIMPSON, S. Q. Clinical factors associated with rapid treatment of sepsis. **PloS one**. v. 16(5), p. 0250923. 2021.

STOJANOV, G.; TRAJKOVSKI, G.; KULAKOV, A. Interactivism in artificial intelligence (AI) and intelligent robotics. **New Ideas in Psychology**. v. 24, p. 163-185. 2006.

TAKAHASHI, S.; TSUJI, Y.; KASAI, H.; OGAMI, C.; KAWASUJI, H.; YAMAMOTO, Y.; TO, H. Classification Tree Analysis Based On Machine Learning for Predicting Linezolid-Induced Thrombocytopenia. **J Pharm Sci**. v. 110(5), p. 2295-2300. 2021.

TAO, X.; SHAIK, T. B.; HIGGINS, N.; GURURAJAN, R.; & ZHOU, X. Remote Patient Monitoring Using Radio Frequency Identification (RFID) Technology and Machine Learning for Early Detection of Suicidal Behaviour in Mental Health Facilities. **Sensors**. v. 21(3), p. 776. 2021.

TEZZA, F.; LORENZONI, G.; AZZOLINA, D.; BARBAR, S.; LEONE, L.; GREGORI, D. Predicting in-Hospital Mortality of Patients with COVID-19 Using Machine Learning Techniques. **Journal of personalized medicine**. v. 11(5), p. 343. 2021.

The top 10 causes of death. WHO - World Health Organization. 2020. Disponível em <<https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>>. Acesso em: 07 de janeiro de 2021.

TRAN, B. X.; VU, G. T.; há, G. H.; VUONG, Q.H.; HO, M. T.; VUONG, T. T.; LA, V. P.; HO, M.T.; NGHIEM, K. P.; NGUYEN, H. L. T.; LATKIN, C. A.; TAM, W. W. S.; CHEUNG, N. M.; NGUYEN, H. T.; HO, C. S. H.; HO, R. C. M. Global Evolution of Research in Artificial Intelligence in Health and Medicine: A Bibliometric Study. **J Clin Med**. v. 14;8(3), p. 360. 2019. (a)

TRAN, B.; NGHIEM, S.; SAHIN, O.; VU, T.; há, G.; VU, G.; PHAM, H.; DO, H.; LATKIN, C.; TAM, W.; HO, C.; HO, R. Modeling Research Topics for Artificial Intelligence Applications in Medicine: Latent Dirichlet Allocation Application Study.

J Med Internet Res. v. 21(11), p. e15511. 2019. (b)

TRSTENJAK, M.; OPETUK, T.; CAJNER, H.; TOSANOVIC, N. Process Planning in Industry 4.0 - Current State, Potential and Management of Transformation. **Sustainability.** v. 12, p. 5878. 2020.

TSVETKOV, P. O.; EYRAUD, R.; AYACHE, S.; BOUGAEV, A. A.; MALESINSKI, S.; BENAZHA, H.; GOROKHOVA, S.; BUFFAT, C.; DEHAIS, C.; SANSON, M.; BIELLE, F.; FIGARELLA BRANGER, D.; CHINOT, O.; TABOURET, E.; DEVRED, F. An AI-Powered Blood Test to Detect Cancer Using NanoDSF. **Cancers.** v. 15;13(6), p. 1294. 2021.

TUNTHANATHIP, T.; OEARSAKUL, T. Application of machine learning to predict the outcome of pediatric traumatic brain injury. **Chin J Traumatol.** v. 8. 2021.

TYLMAN, W.; WASZYROWSKI, T.; NAPIERALSKI, A.; KAMIŃSKI, M.; TRAFIDŁO, T.; KULESZA, Z.; KOTAS, R.; MARCINIAK, P.; TOMALA, R.; WENERSKI, M. Real-Time Prediction of Acute Cardiovascular Events Using Hardware-Implemented Bayesian Networks. **COMPUT BIOL MED.** v. 1;69. p. 245-53. 2016.

UM, K. C.; WONG, C. K.; LAU, Y. M.; LEE, J. C.; TAM, F.C.; LAI, W. H.; LAU, Y. M.; CHEN, H.; WIBOWO, S.; ZHANG, X.; YAN, M.; WU, E.; CHAN, S. C.; LEE, S. M.; CHOW, A.; TONG, R. C.; MAJMUDAR, M. D. Observational study on wearable biosensors and machine learning-based remote monitoring of COVID-19 patients. **Sci Rep.** v. 23;11(1), p. 4388. 2021.

VACCARI, I.; ORANI, V.; PAGLIALONGA, A.; CAMBIASO, E.; MONGELLI, M. A Generative Adversarial Network (GAN) Technique for Internet of Medical Things Data. **Sensors.** v. 27;21(11), p. 3726. 2021

VAID, A.; CHAN, L.; CHAUDHARY, K.; JALADANKI, S. K.; PARANJPE, I.; RUSSAK, A.; KIA, A.; TIMSINA, P.; LEVIN, M. A.; HE, J. C.; BÖTTINGER, E. P.; CHARNEY, A. W.; FAYAD, Z. A.; COCA, S. G.; GLICKSBERG, B. S. Predictive Approaches for Acute Dialysis Requirement and Death in COVID-19. **Clinical journal of the American Society of Nephrology.** v. 16(8), p. 1158–1168. 2021.

VELARDO, C.; CLIFTON, D.; HAMBLIN, S.; KHAN, R.; TARASSENKO, L.; MACKILLOP, L. Toward a Multivariate Prediction Model of Pharmacological Treatment for Women With Gestational Diabetes Mellitus: Algorithm Development and Validation. **J Med Internet Res.** v. 10;23(3), p. 21435. 2021.

VERMA, N.; HAJI-ABOLHASSANI, I.; GANESH, S.; KULIG, K.; GHOREYSHI, A. A Novel Wearable Device for Continuous Temperature Monitoring Fever Detection. **IEEE Journal of Translational Engineering in Health and Medicine.** v. 9, p. 9490248. 2021.

WANG, Z.; LI, L.; GLICKSBERG, B. S.; ISRAEL, A.; DUDLEY, J. T.; MA'AYAN, A. Predicting age by mining electronic medical records with deep learning characterizes differences between chronological and physiological age. **Journal**

of **Biomedical Informatics**. v. 76, p. 59–68. 2017.

WARDI, G.; CARLILE, M.; HOLDER, A.; SHASHIKUMAR, S.; HAYDEN, S. R.; NEMATI, S. Predicting Progression to Septic Shock in the Emergency Department Using an Externally Generalizable Machine-Learning Algorithm. **Annals of emergency medicine**. v. 77(4), p. 395-406. 2021.

WEI, J.; XIANG, J.; YASIN, Y.; BARSZCZYK, A.; WAH, D.T.O.; YU, M.; HUANG, W.W.; FENG, Z.P.; LEE, K.; LUO, H. Physical Features and Vital Signs Predict Serum Albumin and Globulin Concentrations Using Machine Learning. **Asian Pac J Cancer Prev**. v. 1;22(2), p. 333-340. 2021.

WU, T. T.; LIN, X. Q.; UM, Y.; LI, H.; GUO, Y. S. Machine learning for early prediction of in-hospital cardiac arrest in patients with acute coronary syndromes. **Clin Cardiol**. v. 44(3), p. 349-356. 2021.

YANAMALA, N.; KRISHNA, N. H.; HATHAWAY, Q. A.; RADHAKRISHNAN, A.; SUNKARA, S.; PATEL, H.; FARJO, P.; PATEL, B.; SENGUPTA, P. P. A vital sign-based prediction algorithm for differentiating COVID-19 versus seasonal influenza in hospitalized patients. **NPJ digital medicine**. v. 4(1), p. 95. 2021.

YOUSEFI, S.; GOLDBAUM, M. H.; VARNOUSFADERANI, E. S.; BELGHITH, A.; JUNG, T. P.; MEDEIROS, F. A.; ZANGWILL, L. M.; WEINREB, R. N.; LIEBMANN, J. M.; GIRKIN, C. A.; BOWD, C. Detecting glaucomatous change in visual fields: Analysis with an optimization framework. **Journal of biomedical informatics**. v. 58, p. 96–103. 2015.

YU, L.; HALALAU, A.; DALAL, B.; ABBAS, A. E.; IVASCU, F.; AMIN, M.; NAIR, G. B. Machine learning methods to predict mechanical ventilation and mortality in patients with COVID-19. **PloS one**. v. 16(4), p. 0249285. 2021.

YUAN, K. C.; TSAI, L. W.; LEE, K. H.; CHENG, Y. W.; HSU, S. C.; LO, Y. S.; CHEN, R. J. The development an artificial intelligence algorithm for early sepsis diagnosis in the intensive care unit. **International Journal of Medical Informatics**. v. 141. 2020.

ZHAI, H.; BRADY, P.; LI, Q.; LINGREN, T.; NI, Y.; WHEELER, D. S.; SOLT, I. Developing and evaluating a machine learning based algorithm to predict the need of pediatric intensive care unit transfer for newly hospitalized children. **Resuscitation**. v. 85(8), p. 1065-71. 2014.

ZHU, Y.; ZHANG, J.; WANG, G.; YAO, R.; REN, C.; CHEN, G.; JIN, X.; GUO, J.; LIU, S.; ZHENG, H.; CHEN, Y.; GUO, Q.; LI, L.; DU, B.; XI, X.; LI, W.; HUANG, H.; LI, Y.; YU, Q. Machine Learning Prediction Models for Mechanically Ventilated Patients: Analyses of the MIMIC-III Database. **Frontiers in medicine**. v. 8, p. 662340. 2021.

ZOUKA, H. E.; HOSNI, M. M. Secure IoT communications for smart healthcare monitoring system. **Internet Things**. v. 13, p. 100036. 2021.