



UNIVERSIDADE FEDERAL DO ESTADO DO RIO DE JANEIRO - UNIRIO  
CENTRO DE CIÊNCIAS BIOLÓGICAS E DA SAÚDE - CCBS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENFERMAGEM E BIOCÊNCIAS – PPGENFBIO

CLENYA REJANE BARROS DE LIMA

**APRENDIZADO DE MÁQUINA (*MACHINE LEARNING*) EM CUIDADOS  
INTENSIVOS: ANÁLISE CIENTOMÉTRICA**

RIO DE JANEIRO  
2021

CLENYA REJANE BARROS DE LIMA

**APRENDIZADO DE MÁQUINA (*MACHINE LEARNING*) EM CUIDADOS  
INTENSIVOS: ANÁLISE CIENTOMÉTRICA**

Tese submetida à avaliação da banca do Programa de Pós-Graduação em Enfermagem e Biociências – PPGENFBIO do Centro de Ciências Biológicas e da Saúde da Universidade Federal do Estado do Rio de Janeiro - UNIRIO, como requisito parcial para a obtenção do título de Doutor em Ciências.

Orientador:  
Profº Drº Carlos Roberto Lyra da Silva

RIO DE JANEIRO

2021

Catálogo informatizada pelo(a) autor(a)

L732 Lima, Clenya Rejane Barros de  
Aprendizado de máquina (machine learning) em  
cuidados intensivos: análise cientométrica / Clenya  
Rejane Barros de Lima. -- Rio de Janeiro, 2021.  
156 f.

Orientador: Carlos Roberto Lyra da Silva.  
Tese (Doutorado) - Universidade Federal do  
Estado do Rio de Janeiro, Programa de Pós-Graduação  
em Enfermagem e Biociências, 2021.

1. Inteligência Artificial. 2. Unidade de  
Terapia Intensiva. 3. Produção Científica. 4.  
Aprendizado de Máquina. 5. Cuidados Intensivos. I.  
Silva, Carlos Roberto Lyra da, orient. II. Título.

**APRENDIZADO DE MÁQUINA (*MACHINE LEARNING*) EM CUIDADOS  
INTENSIVOS: ANÁLISE CIENTOMÉTRICA**

CLENYA REJANE BARROS DE LIMA

Tese submetida à avaliação da banca do Programa de Pós-Graduação em Enfermagem e Biociências – PPGENFBIO do Centro de Ciências Biológicas e da Saúde da Universidade Federal do Estado do Rio de Janeiro - UNIRIO, como requisito para a obtenção do título de Doutor em Ciências.

**BANCA EXAMINADORA:**

---

Prof<sup>o</sup> Dr<sup>o</sup> Carlos Roberto Lyra da Silva – UNIRIO  
Presidente

---

Prof<sup>a</sup> Dr<sup>a</sup> Saula Leite Oliveira – IFRR  
1<sup>o</sup> Examinador (Externo)

---

Prof<sup>a</sup> Dr<sup>a</sup> Marcelle Alencar Urquiza – UFRR  
2<sup>o</sup> Examinador (Externo)

---

Prof<sup>o</sup> Dr<sup>o</sup> Roberto Carlos Lyra da Silva – UNIRIO  
3<sup>o</sup> Examinador (Interno)

---

Prof<sup>a</sup> Dr<sup>a</sup> Eva Maria Costa – UNIRIO  
4<sup>o</sup> Examinador (Interno)

---

Prof<sup>a</sup> Dr<sup>a</sup> Land Mary Freitas Peres – UERR  
1<sup>o</sup> Suplente (Externo)

---

Prof<sup>o</sup> Dr<sup>o</sup> Wender Antônio da Silva – UERR  
2<sup>o</sup> Suplente (Externo)

---

Prof<sup>o</sup> Dr<sup>o</sup> Antônio Augusto de Freitas Peregrino – UNIRIO  
3<sup>o</sup> Suplente (Interno)

## **DEDICATÓRIA**

Dedico este trabalho a minha família, pela compreensão durante os meus períodos de ausência, e a todos que, de alguma forma, colaboraram com a construção desta pesquisa, e que torceram por mim.

## **AGRADECIMENTOS**

A todas as pessoas que colaboraram, de forma direta ou indireta, para a realização desta pesquisa.

A Universidade Estadual de Roraima – UERR pelo firmamento do convênio com a UNIRIO para a realização do DINTER em Boa Vista/RR.

A equipe do Programa de Pós-Graduação em Enfermagem e Biociências – PPGENFBIO da UNIRIO pelo acolhimento e orientação nos momentos de dúvida.

Aos membros da banca de qualificação pelas contribuições que muito enriqueceram esta pesquisa: Prof<sup>a</sup> Dr<sup>a</sup> Eva Maria Costa, Prof<sup>a</sup> Dr<sup>a</sup> Land Mary Freitas Peres, Prof<sup>a</sup> Dr<sup>a</sup> Marcelle Alencar Urquiza, Prof<sup>a</sup> Dr<sup>a</sup> Saula Leite Oliveira, Prof<sup>o</sup> Dr<sup>o</sup> Wender Antônio da Silva.

Meu agradecimento especial ao professor Carlos Roberto Lyra da Silva pelo incentivo, compreensão e orientação no decorrer desta tese durante este período. E principalmente, por compartilhar seus primordiais conhecimentos repassados nas aulas e orientações.

A minha família e amigos pelo apoio, compreensão e paciência.

E a Deus pela oportunidade e a vida.

"Toda grande caminhada começa com um pequeno primeiro passo."  
Lao Tsé

"As máquinas podem pensar?"  
Alan Turing

"Não é pequeno o serviço de ajuntar o disperso, abreviar o longo, apartar o seletto."  
Antônio de Souza Macedo

## RESUMO

LIMA, Clenya Rejane Barros de. **Aprendizado de Máquina (*Machine Learning*) em Cuidados Intensivos: Análise cientométrica**. 2021. 156f. Tese (Doutorado em Enfermagem e Biociências) – Centro de Ciências Biológicas e da Saúde, Universidade Federal do Estado do Rio de Janeiro – UNIRIO, Rio de Janeiro, 2021.

A crescente disponibilidade de dados clínicos e a evolução nos estudos de algoritmos de aprendizado de máquina contemplam uma variedade de soluções na área da saúde. As publicações no campo do aprendizado de máquina em cuidados intensivos tiveram sua quantidade aumentada significativamente nos últimos anos, e conhecer essa produção científica contribui para o preenchimento de uma lacuna existente na literatura sobre o assunto, cooperando para um direcionamento de pesquisas. Teve-se como proposição de tese que a produção científica sobre aprendizado de máquina em cuidados intensivos demonstra a emergência do tema para área de Saúde e a sua aproximação com a área de Ciência da Computação. O objetivo geral da pesquisa foi caracterizar a produção científica sobre o uso do aprendizado de máquina em cuidados intensivos no período de 2000 a 2020 na base de dados Scopus. Trata-se de pesquisa com abordagem de métodos mistos, de caráter descritivo e exploratório, e como meios de investigação aplicou-se a análise bibliométrica e cientométrica com a utilização do software RStudio e sua interface web Biblioshiny. Obteve-se como resultados 568 documentos que abordavam sobre o tema. Constatou-se que parcela considerável das pesquisas neste campo tem origem nas áreas de Medicina e Ciência da Computação e foram identificados os periódicos, artigos e autores mais devotados, sendo rastreada as redes de colaboração, cocitação e coocorrência. Também foram apontadas as tendências em pesquisa sobre o tema, fornecendo um direcionamento para futuros estudos. Esta pesquisa evidenciou, ainda, que a produção científica sobre uso do aprendizado de máquina em cuidados intensivos é um tema emergente, identificando o grande potencial de aplicações que proporcionam soluções na manutenção da vida nas unidades de terapia intensiva.

**Palavras-chave:** Inteligência Artificial; Unidade de Terapia Intensiva; Produção Científica.

## ABSTRACT

LIMA, Clenya Rejane Barros de. ***Machine Learning in Intensive Care: Scientometric analysis***. 2021. 156p. Thesis (Doctorate in Nursing and Biosciences) - Center for Biological and Health Sciences, Federal University of the State of Rio de Janeiro - UNIRIO, Rio de Janeiro, 2021.

*The increasing availability of clinical data and the evolution in the studies of machine learning algorithms contemplate a variety of solutions in the health area. Publications in the field of machine learning in intensive care have increased significantly in recent years, and knowing this scientific production contributes to fill a gap in the literature on the subject, cooperating to direct research. It was proposed as a thesis that the scientific production on machine learning in intensive care demonstrates the emergence of the theme for the area of Health and its approximation with the area of Computer Science. The general objective of the research was to characterize the scientific production on the use of machine learning in intensive care in the period from 2000 to 2020 in the Scopus database. This is a research with a mixed method approach, of a descriptive and exploratory character, and as a means of investigation bibliometric and scientometric analysis was applied using the RStudio software and its Biblioshiny web interface. As a result, 568 documents dealing with the topic were obtained. It was found that a considerable part of the research in this field has its origins in the areas of Medicine and Computer Science and the most devoted journals, articles and authors were identified, with the collaboration, co-quotation and co-occurrence networks being tracked. Research trends on the topic were also pointed out, providing guidance for future studies. This research also showed that scientific production on the use of machine learning in intensive care is an emerging theme, identifying the great potential of applications that provide solutions for maintaining life in intensive care units.*

**Keywords:** *Artificial Intelligence; Intensive care unit; Scientific production.*

## LISTA DE FIGURAS

Figura 1: Pipeline de processamento de informações de saúde. ....	30
Figura 2: Os três tipos de aprendizagem. ....	31
Figura 3: Exemplo dos 3 tipos de aprendizado de máquina aplicada a sepse. ....	35
Figura 4: Linha do tempo dos estudos métricos da informação. ....	39
Figura 5: Visão do esquema de documentos cocitados (lado esquerdo) e de documentos acoplados (lado direito). ....	48
Figura 6: Bibliometrix e o fluxo de trabalho de mapeamento científico recomendado. ....	54
Figura 7: Resultado da busca e string de busca obtidos através da base de dados Scopus. ....	60
Figura 8: Tela de exportação em *.CSV dos documentos obtidos. ....	60
Figura 9: Desenho metodológico da pesquisa. ....	63
Figura 10: Nuvem por palavra-chave do autor (10A); Nuvem por palavra-chave plus (10B); Nuvem por palavra em títulos (10C); Nuvem por palavra em resumos (10D). ....	84
Figura 11: Treemap das palavras-chaves definidas pelos autores. ....	86
Figura 12: Rede de coocorrência de palavras-chave definidas pelo autor. ....	88
Figura 13: Mapa temático de palavras-chave definidas pelo autor. ....	89
Figura 14: Evolução temática. ....	90
Figura 15: Análise fatorial pelo método MCA. ....	91
Figura 16: Dendrograma. ....	91
Figura 17: Rede de cocitação. ....	92
Figura 18: Historiógrafo. ....	93
Figura 19: Rede de colaboração de autores. ....	94
Figura 20: Rede de colaboração de instituições. ....	95
Figura 21: Rede de colaboração de países. ....	95
Figura 22: Mapa mundial de colaboração. ....	96

## LISTA DE GRÁFICOS

Gráfico 1: Evolução da quantidade de produção científica na Scopus.....	67
Gráfico 2: Áreas de estudos dos documentos recuperados. ....	67
Gráfico 3: Gráfico dos três campos (dos 10 periódicos, palavras-chaves, países). ..	68
Gráfico 4: Aplicação da Lei de Bradford.....	70
Gráfico 5: Os 13 periódicos mais relevantes sobre o assunto.....	71
Gráfico 6: Dinâmica da evolução de documentos por periódicos por ano (6A) e por acumulado (6B). ....	73
Gráfico 7: Produtividade do autor pela Lei de Lotka.....	75
Gráfico 8: Produção dos autores ao longo do tempo. ....	78
Gráfico 9: Documentos por patrocinador de financiamento. ....	80
Gráfico 10: País correspondente do autor.....	81
Gráfico 11: Dinâmica das 10 palavras-chave mais frequentes ao longo dos anos. ..	86
Gráfico 12: Tendência de tópicos ao longo dos anos.....	87

## LISTA DE QUADROS

Quadro 1: Métodos de aprendizado de máquina usados com frequência em anestesiologia e medicina intensiva. ....	34
Quadro 2: Lista das 16 ferramentas analisadas por de Moreira, Guimarães e Tsunoda (2020). ....	51
Quadro 3: Comparativo entre as 4 ferramentas selecionadas na pesquisa de Moreira, Guimarães e Tsunoda (2020). ....	51
Quadro 4: Conjunto de análises disponíveis no Biblioshiny Autores. ....	54
Quadro 5: Esquema do percurso metodológico. ....	57
Quadro 6: Categorias e indicadores contemplados por esta pesquisa. ....	62
Quadro 7: Principais informações resumidas sobre a coleção de documentos recuperados. ....	65
Quadro 8: Consolidação dos dados aplicados Lei de Bradford. ....	70
Quadro 9: Periódicos mais citados localmente (das listas de referências da coleção de documentos). ....	72
Quadro 10: Impacto (H-Index) dos 10 periódicos. ....	73
Quadro 11: Relação da frequência do número de documentos produzidos por número de autores. ....	74
Quadro 12: Autores mais produtivos. ....	76
Quadro 13: Autores mais citados localmente. ....	77
Quadro 14: H-Índice Impacto do autor. ....	79
Quadro 15: Afiliações mais relevantes. ....	79
Quadro 16: Aplicações aprendizado de máquina em cuidados intensivos. ....	102

## LISTA DE TABELAS

Tabela 1: Comparação das aplicações dos distintos métodos quantitativos.....	40
Tabela 2: Principais funções da bibliometrix associadas a análise bibliométrica e cientométrica.....	55
Tabela 3: Estrutura da relação campo por tipo de dados do Bibliometrix. ....	56
Tabela 4: Lista de elementos de um objeto Bibliometrix e sua descrição. ....	56
Tabela 5: Os 20 documentos mais citados.....	82
Tabela 6: Index H dos artigos de 2011 a 2020.....	83

## LISTA DE ABREVIATURAS E SIGLAS

<b>SIGLA</b>	<b>SIGNIFICADO</b>
AM	Aprendizado de Máquina
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
EUA	Estados Unidos
eICU	Banco de dados de pesquisa colaborativa
IA	Inteligência Artificial
IAM	Inteligência Artificial em Medicina
ILSVRC	<i>ImageNet Large Scale Visual Recognition Challenge</i>
IoT	Internet das Coisas
ISI	<i>Institute for Scientific Information</i>
ITU	União Internacional de Telecomunicações
MCA	Análise de correspondência múltipla
MCTI	Ministério de Ciência, Tecnologia e Inovações
MIMIC III	<i>Medical Information Mart for Intensive Care</i>
N2C2	<i>National NLP Clinical Challenges</i>
OMS	Organização Mundial da Saúde
RL	<i>Reinforcement Learning</i>
RNDS	Rede Nacional Digital em Saúde
TICs	Tecnologias da Informação e Comunicação
UTIs	Unidades de Terapia Intensiva
WoS	<i>Web of Science</i>

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>15</b>
1.1 CONSIDERAÇÕES INICIAIS .....	15
1.2 PROBLEMAS, QUESTÕES E HIPÓTESES .....	18
1.3 OBJETIVOS .....	20
1.4 JUSTIFICATIVA, CONTRIBUIÇÃO E RELEVÂNCIA DO ESTUDO .....	21
1.5 ESTRUTURA DA TESE .....	22
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>23</b>
2.1 INTELIGÊNCIA ARTIFICIAL NA SAÚDE .....	23
2.1.1 Aprendizado de máquina em cuidados intensivos .....	29
2.2 MÉTRICAS DA INFORMAÇÃO CIENTÍFICA .....	38
2.2.1 Bibliometria e Cientometria .....	41
2.2.1.1 Indicadores Bibliométricos e Cientométricos .....	44
2.2.1.2 Leis de Lotka Bradford, Zipf, Elitismo .....	45
2.2.1.3 Citações e redes científicas .....	47
2.3 SOFTWARE PARA AUXÍLIO NAS ANÁLISES .....	50
2.3.1 RStudio, Bibliometrix, Biblioshiny .....	52
<b>3 MATERIAL E MÉTODOS</b> .....	<b>57</b>
3.1 COLETA DE DADOS .....	58
3.1.1 Escolha da base de dados .....	58
3.1.2 String de busca e definição do <i>corpus</i> de análise .....	59
3.2 ANÁLISE DOS DADOS .....	61
3.3 ASPECTOS ÉTICOS DA PESQUISA .....	64
<b>4 RESULTADOS E DISCUSSÃO</b> .....	<b>65</b>
4.1 COLEÇÃO DE DADOS RECUPERADOS .....	65
4.2 ANÁLISE DAS FONTES .....	69
4.3 ANÁLISE DOS AUTORES .....	74
4.4 ANÁLISE DAS AFILIAÇÕES E PAÍSES .....	79
4.5 ANÁLISE DOS DOCUMENTOS .....	81
4.6 ANÁLISE DAS PALAVRAS-CHAVE .....	84
4.7 ANÁLISE DA ESTRUTURA CONCEITUAL .....	87
4.8 ANÁLISE DA ESTRUTURA INTELECTUAL .....	92
4.9 ANÁLISE DA ESTRUTURA SOCIAL .....	93
4.10 DISCUSSÃO DOS RESULTADOS .....	96
<b>5 CONCLUSÃO</b> .....	<b>112</b>
<b>6 REFERÊNCIAS</b> .....	<b>114</b>
<b>APÊNDICES</b> .....	<b>129</b>

## 1 INTRODUÇÃO

### 1.1 CONSIDERAÇÕES INICIAIS

Sabe-se que a humanidade evolui por meio das descobertas e inovações que a ciência proporciona, desfrutando das benesses oferecidas pela geração de conhecimento.

Popper (2007), em seu livro sobre a lógica da pesquisa científica, relata o processo de fazer ciência, defende que deve ser pautada na perspectiva de atender as expectativas da sociedade, sendo produto da coletividade e assim sua visão busca conciliar o desenvolvimento de suas pretensões para a sociedade, o que é conhecido por caráter racional. Tal racionalidade busca incansavelmente a preservação do pensamento científico, por meio do questionamento, do debate, da avaliação, da definição de critérios, que caminham para o progresso e aperfeiçoamento. Para Popper, a ciência não está isenta de influências de valores e concepções do meio em que está inserida, sendo pensada a partir de condicionantes que permeiam a sociedade, tais como: a cultura, a política e a religião. A partir desta visão, estaria sujeita a uma gama de intervenções no seu desenvolver, caracterizando a complexidade do processo do fazer científico. Essa influência externa, sugerida por Popper, gera interferência direta nos rumos do conhecimento científico. Contudo, tal autor enxerga como positiva no sentido de edificar a construção da ciência, pois teorias, experimentos, e outras coisas, estão para serem avaliadas e reavaliadas, e ainda assim, esse processo não garantiria um selo de irrefutabilidade.

Bourdieu (2004) delinea detalhadamente os aspectos sociológicos do fazer científico. Na sociologia estruturalista de Bourdieu, o fazer ciência é caracterizado pelo monopólio da autoridade, ou seja, aqueles que detêm o capital científico exercem a dominação e, conseqüentemente, determinam as diretrizes do método científico. A ciência nesta percepção deixa de ser isenta, não pautando o seu fazer apenas em propostas, teses, argumentos, e etc. Ela sofre forte influência daqueles que exercem o monopólio do capital científico acumulado. É um lugar de tensão, onde os atores duelam pelo poder científico, pela busca incessante da legitimação da produção científica. Para Bourdieu (2004) o capital científico nasce do poder político e do prestígio, sendo o político relacionado a posição do cientista nas academias, cargos,

funções, e etc., e o prestígio a posição dentro do meio científico, a soma desses aspectos gera o poder científico.

Para Chalmers (1993) a ciência tem se constituído ao longo dos séculos como um método genérico dos experimentos físicos, através da coleta de dados, da observação e de experimentos, e derivação de leis e teorias a partir desses métodos, a qual ainda arraigada nesses ditames tem se apresentado como uma espécie de autoestima e religiosidade incontestável e imutável. Chalmers (1993) afirma que na ciência não existe método absolutamente eficaz e que não podem ser desaprovados, tendo em vista que grandes teorias como as de Newton, que não se basearam nos métodos até então vigentes para sua época. Portanto, ele busca o aperfeiçoamento constante, refutando sempre explicações simples como o indutivismo e o relativismo e contrariamente ao pensamento corrente. Chalmers (1993, p.22) grifa que a ciência para ele é “uma busca de descrições ‘verdadeiras’ do que o mundo ‘realmente’ parece.”

Bachelard (2002) enxerga o método científico para além da métrica, existindo na ciência relações mais ocultas e distantes dos métodos tradicionais, e descreve estágios do pensamento científico que permitem a evolução do indivíduo no aspecto cognitivo que o direcionam para o que ele chama de novo espírito científico, e que de maneira dialética, o conhecimento se constrói, desconstrói e se reconstrói, sobretudo a partir dos conhecimentos acumulados, focando na evolução do pensamento, possibilitando a formação do novo espírito científico.

Hessen (2003) estabelece uma relação entre sujeito e objeto, propõe um mergulho no mundo interior do “eu” e no mundo exterior, o próprio objeto a ser estudado, denominado por ele de macrocosmo. Isso faz a teoria do conhecimento proposta por ele um fenômeno peculiar, o qual compreende e interpreta a realidade e produz uma concepção das coisas, isto é, dos objetos em estudo para além de si e do pesquisador. É um processo que relaciona sujeito e objeto que mutuamente se constroem, enriquecendo o processo de conhecimento. Para ele, em tempo nenhum um objeto será conhecido em sua plenitude (HESSEN, 2003).

Observa-se que a forma como se faz ciência não parou de evoluir no decorrer da história. Hey, Tansley e Tolle (2011) afirmam que se vivencia o quarto paradigma da ciência, ao considerar que com o advento da Tecnologia da Informação e Comunicação (TICs), bem como os avanços da Ciência da Computação e sua utilização em apoio às várias áreas e disciplinas, tem influenciado os rumos da

pesquisa científica. Para estes autores, deve-se aproveitar efetivamente a forma multidisciplinar das ferramentas tecnológicas e, conseqüentemente, transformar terabytes de informações em conhecimento científico. Além de considerar os impactos da tecnologia nos diversos ramos, redefinindo o fazer ciência.

Neste paradigma em ascensão, o uso de equipamentos de hardware e software desempenham papel essencial na forma de descoberta do conhecimento, servindo-os de base para os métodos de pesquisa. Infraestrutura de computadores, redes de computadores, banco de dados, dentre outros, contribuem para uma análise e interpretação de dados mais precisos de pesquisas (HEY; TANSLEY; TOLLE, 2011).

Atualmente, tem-se o conceito de eScience para referir-se a utilização de infraestrutura de Tecnologias da Informação e Comunicação (TICs) para auxiliar no processo de estruturar os mais diversos conhecimentos produto da pesquisa científica de maneira colaborativa (FERREIRA, 2018).

O uso de tecnologia da informação e comunicação na área da saúde cresceu, e o que antes era apenas a transição do registro do papel para o computador, agora são produtos e serviços que proporcionam cuidados baseados em volume de dados, históricos e evidências permitindo a geração de diagnósticos baseados em análises de resultados de tempo real, utilizando-se dos mais recentes recursos e ramos da Ciência da Computação para prover soluções que tem como base evidências e resultados, de forma colaborativa e preventiva. De acordo com *Focus Group on Artificial Intelligence for Health* (2020), a informatização da área da saúde e a digitalização de todos os tipos de dados de saúde, bem como o fato dos computadores tornarem-se cada vez mais eficazes de processar e interpretar imagens e textos médicos quase tão precisamente quanto humanos tem possibilitado a aplicação da Inteligência Artificial (IA), e conseqüentemente, o aprendizado de máquina em inúmeras aplicações na área da saúde. Para Ziviani (2017, p. 8), “o aprendizado de máquina permite que os computadores possam ter a capacidade de aprender sem serem explicitamente programados”, ocorrendo uma quebra de paradigma, tornando as máquinas ferramentas extremamente poderosas.

A As unidades de terapia intensiva (UTIs) também evoluíram e são ambientes especializados em recursos materiais e recursos humanos, tendo como finalidade principal, a “restauração da saúde/vida a partir da combinação de tecnologias de ponta (equipamentos e medicamentos), cuidados intensivos de enfermagem e a constante atuação da ‘medicina intensivista’ no atendimento aos clientes” (SILVA; SILVA;

FRANCISCO, 2006, p. 150). As atitudes dos profissionais envolvidos em cuidados intensivos apoiam-se em encontrar na informação e na tecnologia, as contribuições para auxiliar no processo de tomada de decisão quanto ao modo de agir junto ao acompanhamento do paciente. Um exemplo da importância do uso do aprendizado de máquina em cuidados intensivos pode ser verificado na publicação de Cherifa e Pirracchio (2019), que atrai atenção para o que todo intensivista precisa saber sobre o volume de dados e o aprendizado de máquina em unidades de terapia intensiva.

Embora os estudos de bibliometria e cientometria tenham se consolidado inicialmente no campo da Ciência da Informação, a prática de utilização de tais métodos têm sido expandida e aplicada em várias áreas do conhecimento (ARAÚJO, 2006; GUEDES, 2012). Santos (2004) afirma que a cientometria surgiu como sendo o que ele chamou de nova área, tendo como finalidade suscitar informações e discussões que contribuam para a superação dos desafios peculiares da ciência moderna.

A seguir são esclarecidos problemas, questões norteadoras e hipóteses desta pesquisa.

## 1.2 PROBLEMAS, QUESTÕES E HIPÓTESES

A pesquisa e a inovação na aplicação da inteligência artificial nos cuidados da saúde aconteceram tendo em vista a necessidade e a crescente disponibilidade de dados de registros eletrônicos de saúde, bem como o poder computacional cada vez maior (MATHUR; BURNS, 2019).

As unidades de terapia intensiva acompanharam a evolução tecnológica e, conseqüentemente têm em sua estrutura atual responsabilidades e empenho de habilidades específicas por parte da equipe ali alocada. Os profissionais da saúde têm como prática o cuidado para com o paciente. No caso da terapia intensiva, o cuidado carece de ser específico e detalhado. Silva, Silva e Francisco (2006, p. 150), afirmam que “a necessidade de oferecer um atendimento especial faz com que as UTIs tenham equipe especialmente qualificada e com características próprias, além de um aparato tecnológico com fins diagnósticos e terapêuticos.” Para Azevedo (2009, p.1), os recursos utilizados pelos profissionais que trabalham em unidades de terapia intensiva “devem conciliar utilidade com recursos técnicos e científicos avançados e mais

atualizados, bem como equipe multiprofissional devidamente treinada para a obtenção de seu objeto.”

A área de cuidados intensivos tem sido considerada como percussora do uso das técnicas de inteligência artificial avaliando aplicativos em análises preventivas, diagnóstico por imagens, dispositivos inteligentes, dentre outros, e para o futuro vislumbra-se a promessa de soluções ainda mais inovadoras que auxiliam os médicos na tomada de decisões inteligentes em tempo real, na entrega de diagnósticos avançados e na terapêutica de baixo custo, através da colaboração e investigação cuidadosa dos pesquisadores da área (MATHUR; BURNS, 2019).

A crescente disponibilidade de dados clínicos e a evolução nos estudos de aprendizado de máquina contemplam uma variedade de problemas de saúde, como avaliação de risco e previsão em cuidados agudos, crônicos e críticos, por meio dos quais verifica-se que cuidados intensivos é um campo de intenso fluxo de dados, uma vez que o monitoramento contínuo de pacientes que estão na UTI geram grandes quantidades de dados que podem ser aproveitados por algoritmos de aprendizado de máquina (SHEIKHALISHAHI; BALARAMAN; OSMANI, 2020).

A tomada de decisão de admissão em UTIs é um ato complexo da equipe haja vista que se deve considerar as chances de sobrevivência, bem como a qualidade de vida futura. Santos *et al.* (2020, p. 73) em pesquisa que objetivou “desenvolver e comparar o desempenho preditivo de algoritmos de aprendizado de máquina para estimar o risco de ano de vida ajustado pela qualidade (QALY) menor ou igual a 30 dias” a pacientes gravemente enfermos com câncer internados em UTIs, em um estudo de coorte prospectivo, sendo que os preditores foram características coletadas na admissão do paciente na UTI, concluíram que algoritmos de aprendizado de máquina discriminaram bem o risco QALY em 30 dias.

De acordo com Terry e Weaver (2013, p. 23), dentre as competências de um profissional que trabalha com terapia intensiva, destaca-se o da investigação científica, o qual é a “capacidade de questionar e avaliar a prática de forma contínua, usando práticas baseadas em evidências científicas.” Os estudos sobre o uso de tecnologias computacionais, em especial aprendizado de máquina em cuidados intensivos, têm relevância significativa dentro da área de conhecimento da saúde, uma vez que os pacientes se tornaram cada vez mais graves e mais complexos para serem cuidados carecendo de profissionais cada vez mais qualificados (DRAGOSAVAC; ARAÚJO, 2014).

A produção e busca por informações relevantes sobre o uso de aprendizado de máquina em cuidados intensivos, por profissionais que atuam nesta área, em bancos de dados é parte crucial do trabalho de um bom profissional. As publicações científicas na área de aprendizado de máquina em cuidados intensivos tiveram sua quantidade aumentada significativamente nos últimos anos, nos vários ramos de atuação, conforme constata-se no decorrer deste estudo.

Sabe-se que o que move a ciência são as perguntas. Desta forma, a questão norteadora deste estudo é: Como se caracteriza a pesquisa sobre o uso do aprendizado de máquina em cuidados intensivos? As investigações foram além desta questão central, sendo necessários alguns questionamentos complementares, como: Como está dispersa a produção científica sobre este tema? Quais os principais autores, instituições e periódicos que mais publicam sobre este assunto? Quais os núcleos de periódicos mais dedicados ao assunto? É possível identificar a elite produtora da literatura publicada? Qual a tendência das publicações? Existe rede de colaboração consolidada entre os autores, instituições e países?

Empiricamente, apresenta-se as hipóteses desta pesquisa:

1 – A produção científica sobre o uso do aprendizado de máquina em cuidados intensivos, disponível na base de dados Scopus, demonstra a emergência do tema para área de saúde.

2 – Na base de dados Scopus é possível comportar o volume de produção sobre aprendizado de máquina em cuidados intensivos capaz de determinar um grupo de elite de autores que pesquisam sobre o tema.

3 – Devido à emergência do tema não é possível identificar uma rede de colaboração científica consolidada sobre o tema.

Como proposição de tese, tem-se que: A produção científica sobre aprendizado de máquina em cuidados intensivos demonstra a emergência do tema para área de Saúde e a sua aproximação com a área de Ciência da Computação.

A seguir, apresenta-se o objetivo geral e os específicos desta tese.

### 1.3 OBJETIVOS

O objetivo geral desta pesquisa é: Caracterizar a produção científica sobre o uso do aprendizado de máquina em cuidados intensivos identificada no período de 2000 a 2020 na base de dados Scopus.

Para o objetivo geral ser alcançado, objetivos específicos precisaram ser definidos, os quais seguem:

- Identificar os principais autores, periódicos, instituições, países que se dedicam ao tema;
- Rastrear a rede de colaboração científica, cocitação, coautoria e coocorrência;
- Mapear as tendências temáticas das principais patologias/condições específicas em cuidados intensivos em que é usado o aprendizado de máquina;
- Disponibilizar para a comunidade científica estudo panorâmico sobre as pesquisas em aprendizado de máquina em cuidados intensivos.

#### 1.4 JUSTIFICATIVA, CONTRIBUIÇÃO E RELEVÂNCIA DO ESTUDO

Corroborando com Hessen (2003) ao concordar que jamais um objeto será conhecido em sua plenitude, esta pesquisa tem como diferencial a comunicação científica de um assunto em que aplica técnicas de análises bibliométricas e cientométrica, bem como no recorte temporal contemplado.

Esta pesquisa justifica-se ao identificar parâmetros bibliométricos e cientométricos sobre o uso do aprendizado de máquina em cuidados intensivos, no período de 2000 a 2020, contribuindo para uma visão de análise da evolução temática e redes de estrutura conceitual, intelectual e social envolvidas, bem como tendências de pesquisa e ferramentas que admitem explorar outras dimensões desta área de conhecimento.

No campo do conhecimento, compreender a relevância da proposta de realizar um estudo cientométrico sobre a produção científica do uso do aprendizado de máquina em cuidados intensivos, justifica-se uma vez que colabora com a identificação e análise da produção científica disponível sobre o tema, contribui para o preenchimento de uma lacuna existente na literatura sobre o assunto, cooperando para um direcionamento de pesquisas e desenvolvimento de políticas na área.

Além de se ter um panorama sobre este campo de aplicação do conhecimento na área da saúde, evidenciando o uso de algoritmos na identificação de falsos alarmes, na detecção precoce de sepse, previsão de mortalidade, além de soluções de algoritmos de aprendizado de máquina empregadas na pandemia de COVID-19, dentre outros.

## 1.5 ESTRUTURA DA TESE

Esta tese apresenta-se em cinco capítulos, contando com esta introdução.

No Capítulo 2 apresenta-se o referencial teórico contendo a base conceitual sobre o uso da inteligência artificial na saúde, contextualizando a aplicação do aprendizado de máquina em cuidados intensivos. Em seguida, apresenta-se sobre as métricas da informação, abordando os fundamentos da bibliometria e cientometria e seus indicadores, as Leis de Lotka Bradford, Zipf, Elitismo, bem como as citações e o embasamento sobre redes de colaboração científica, e o uso de softwares para auxílio nas análises.

É apresentado no Capítulo 3 o material e os métodos, detalhando a classificação da pesquisa, os procedimentos para a coleta de dados (a escolha da base de dados, a string de busca e definição do *corpus* de análise), e os procedimentos para o processamento, tratamento e apresentação dos resultados. Esclarece, ainda, os aspectos éticos desta pesquisa.

O Capítulo 4 destina-se à apresentação dos resultados organizados por categorias de análise, e sua discussão.

No Capítulo 5 apresenta-se a conclusão da pesquisa realizada, bem como limitações e sugestões de trabalhos futuros.

E por fim, dispõe-se as referências consultadas e utilizadas para a elaboração deste trabalho, e apêndices.

## 2 REFERENCIAL TEÓRICO

Neste capítulo, apresenta-se o embasamento do uso da inteligência artificial na saúde e do aprendizado de máquina em cuidados intensivos. Em seguida, expõe-se sobre as métricas da informação científica, em especial a bibliometria e cientometria elencando os seus conceitos, características, maneiras de aplicação e avaliação que mais se adequam ao escopo do presente estudo. E por fim, uma visão sobre o uso de ferramentas computacionais que auxiliam nos processos das análises.

### 2.1 INTELIGÊNCIA ARTIFICIAL NA SAÚDE

A Inteligência Artificial (IA) é um campo multidisciplinar que emprega técnicas de algoritmos e programas de computadores para fazer com que máquinas solucionem problemas em campos especializados do conhecimento humano (GOLDSCHMIDT, 2010). O conceito e visão do que hoje é a IA foi introduzida por Alan Turing , em 1950, por meio do artigo intitulado *Computing Machinery and Intelligency* (GOLDSCHMIDT, 2010; LOBO, 2018).

Russell e Norvig (2010) assegura que, de modo geral, a Inteligência Artificial divide-se em 06 (seis) subcategorias de abordagem:

- Processamento de linguagem natural;
- Representação de conhecimento;
- Raciocínio automatizado;
- Robótica;
- Visão computacional; e
- Aprendizado de máquina.

Kagerbauer *et al.* (2020, p. 85) afirmam que a “inteligência artificial se tornou uma parte indispensável da medicina moderna.” A Inteligência Artificial em Medicina (IAM), de acordo com Lobo (2018, p. 187) “é o uso de computadores que, analisando um grande volume de dados e seguindo algoritmos definidos por especialistas na matéria, são capazes de propor soluções para problemas médicos.” Neste sentido, os softwares, algoritmos e tecnologias empregadas que de alguma forma contribuem para auxílio e apoio a decisão à equipe médica, baseado em um conjunto de dados que propõem soluções à problemas voltados para saúde é considerado um IAM.

Verifica-se que a nível mundial ocorre um movimento para que seja estruturado e institucionalizado o uso da inteligência artificial na saúde tendo em vista os benefícios que proporciona para a humanidade. O *Telecommunication Standardization Sector* (ITU-T) é uma área da União Internacional de Telecomunicações (ITU), a qual é a agência da Organização das Nações Unidas (ONU) especializada em tecnologias de informação e comunicação, que reúne especialistas de todo o mundo para desenvolver padrões internacionais, coordenando padronizações relacionadas a telecomunicações. Tal organização possui grupos focais que visam reunir especialistas e definir padrões sobre assuntos emergentes. Para melhor contextualizar o assunto desta tese, a criação em julho de 2018 do ITU/WHO *Focus Group on Artificial Intelligence for Health* (FG-AI4H), ou seja, o grupo focal em inteligência artificial para saúde, o qual trabalha em parceria com a Organização Mundial da Saúde para “estabelecer uma estrutura de avaliação padronizada de métodos baseados em IA para saúde, diagnóstico, triagem ou tratamento de decisões” (ITU-T, 2018). Além disto, os grupos focais organizam-se em grupos de tópicos (TGs) que averiguam casos de uso em domínios de saúde específicos com tarefas de inteligência artificial correspondentes.

De acordo com o Ministério da Saúde (2019), a Organização Mundial de Saúde elaborou a Estratégia Global de Saúde Digital, compreendendo que o somatório dos esforços (de cada país) “podem ser potencializados pela colaboração, troca de conhecimento e de experiências entre países, centros de pesquisa, empresas, organizações de saúde e associações de usuários ou cidadãos”, visando proporcionar a saúde de todos em todos os lugares.

É importante esclarecer que o termo Saúde Digital abrange o uso de soluções de Tecnologia de Informação e Comunicação “para produzir e disponibilizar informações confiáveis, sobre o estado de saúde para quem precisa, no momento que precisa”, compreendendo também “os recentes avanços na tecnologia como novos conceitos, aplicações de redes sociais, Internet das Coisas (IoT), Inteligência Artificial, entre outros” (MINISTÉRIO DA SAÚDE, 2019).

Verifica-se que de acordo com o Ministério da Saúde (2020, p. 56) prevê, no documento Estratégia de Saúde Digital para o Brasil 2020-2028, o uso de inteligência artificial e aprendizado de máquina por meio da ação “3.2 Promoção de saúde e prevenção de doenças e agravos”, no item “3.2.2 Oferecer suporte à gestão de saúde populacional”, a inclusão de mecanismos de triagem mediante uso de inteligência e

análise preditivas, bem como a criação “de programas de saúde e estratégias de engajamento adequadas para os diferentes perfis de indivíduos, alinhadas à oferta de um cuidado coordenado.” Ainda neste documento, pretende-se no item “7.2.1 Desenvolver iniciativas em IoT, Big Data e uso secundário dos dados”, o desenvolvimento de redes de colaboração em inovação, a qual funcionará, até o final de 2022, como “catalisador de iniciativas inclusivas dos setores público e privado voltadas à utilização dos dados em saúde e de dispositivos inteligentes, que resultem no desenho e utilização de soluções que apoiem profissionais e gestores de saúde, automatizem processos e, assim, melhorem os serviços de saúde”, visando atrair pesquisadores para compartilhar conhecimento utilizando a Rede Nacional Digital em Saúde (RNDS) (MINISTÉRIO DA SAÚDE, 2020, p. 106).

Al-Mufti *et al.* (2019) afirmam que a IA tem o potencial de reduzir custos de saúde, minimizar atrasos no gerenciamento de pacientes e reduzir erros médicos. Segundo Lobo (2018, p.3) a Inteligência Artificial “reconhece imagens, permite interações computadorizadas em linguagem aberta, escrita e falada, percebe relações e nexos, entende conceitos e não apenas processa dados, segue algoritmos e cria sua própria experiência.” O uso de inteligência artificial na saúde pode ser aplicado em praticamente todas as vertentes de atuação, melhorando o desempenho e a eficiência em termos operacionais, contribuindo com a gestão da saúde da população, bem como melhorando o atendimento ao paciente.

A seguir, elenca-se estudos da aplicação de inteligência artificial na saúde. O uso de inteligência artificial/aprendizado de máquina em cuidados intensivos será abordado, de maneira exclusiva, no item seguinte 2.1.1.

Em pesquisa de realizada por Jie, Zhiying e LI (2021) para avaliar sistematicamente a consistência dos esquemas de tratamento entre o Watson para Oncologia<sup>1</sup> (WFO) e a equipe multidisciplinar (MDT), visando fornecer referências para a aplicação prática do sistema de apoio à decisão clínica de inteligência artificial no tratamento do câncer, concluíram que o uso adequado requer que o WFO esteja na posição de um complemento ao trabalho do médico, integrando-os com recursos

---

<sup>1</sup> Watson for Oncology (WFO) é um sistema de decisão assistente de inteligência artificial, desenvolvido pela IBM Corporation (EUA) com a ajuda dos melhores oncologistas do *Memorial Sloan Kettering Cancer Center* (MSK). Esta IA foi treinada por mais de 4 anos baseado nas diretrizes de tratamento de câncer da rede nacional abrangente de câncer (NCCN) e mais de 100 anos de experiência em tratamento clínico de câncer nos Estados Unidos, e pode recomendar regimes de quimioterapia apropriados para pacientes com câncer específicos (JIE; ZHIYING; LI, 2021, p.1).

tradicionais (como a experiência de colegas e revistas científicas para escolher o método mais eficaz para fornecer esquemas de quimioterapia para pacientes) para fornecer aos pacientes um tratamento mais preciso e eficaz, acelerando e melhorando seus resultados de tratamento.

Shimizu e Nakayama (2020) em artigo de revisão descrevem vários exemplos recentes da aplicação de IA em oncologia, tais como: A classificação bem-sucedida de imagens dermatoscópicas, por meio da qual o algoritmo de IA foi capaz de anotar lesões de pele (incluindo melanoma) com a mesma precisão que os dermatologistas especialistas; Detecção precoce do câncer através do reconhecimento de imagens disponíveis em bases de dados colaborativas, dentre elas, a *ImageNet Large Scale Visual Recognition Challenge*; A IA também alcançou um nível de precisão semelhante ao de médicos especialistas na interpretação de mamografias para rastreamento do câncer de mama; As redes neurais profundas foram capazes de detectar linfonodos aumentados ou pólipos colônicos em imagens de tomografia computadorizada. As autoras concluíram que a IA revolucionará a oncologia na próxima década.

Bi *et al.* (2019) analisaram os desafios clínicos e aplicações da inteligência artificial em imagens de câncer, apresentando que a integração da IA com as imagens contribuem significativamente na avaliação da resposta, no prognóstico e no planejamento do tratamento, o que contribui para a redução da mortalidade, sendo necessário ter cautela, devendo ser enquadrado e analisado no contexto clínico correto.

Pacientes com lesões de queimados exigem cuidados complexos que envolvem ações equilibradas entre reanimação, estabilização e reabilitação, sendo que as lesões “podem variar de queimaduras superficiais, exigindo apenas cuidado local da ferida, até queimaduras mais graves que podem exigir cirurgia e são potencialmente complicadas por insuficiência respiratória ou sepse” (COBB *et al.*, 2018, p.411).

Tran *et al.* (2019) analisaram os cuidados intensivos em queimados, os quais representam uma população de alto impacto que pode se beneficiar da inteligência artificial e do aprendizado de máquina. Treinaram e testaram modelos de aprendizado de máquina com dados de laboratório clínico de 50 pacientes adultos queimados que tinham lipocalina associada a neutrófilos gelatinase (NGAL), débito urinário (UOP), creatinina e peptídeo natriurético tipo B N-terminal (NT-proBNP). Concluíra que os

pacientes queimados apresentam alto risco de lesão renal aguda e o uso do aprendizado de máquina aumenta a classificação preditiva da lesão renal em pacientes gravemente queimados nas primeiras 24 horas de admissão.

Por meio de revisão integrativa da literatura, Schuch e Scherer (2020) ressaltaram recentes evidências científicas relacionadas às tecnologias de inteligência artificial para a avaliação da lesão por queimadura. Identificaram que de uma amostra de 10 estudos que aplicavam técnicas de inteligência artificial, 04 estudos empregaram modelos de aprendizado de máquina supervisionado. E concluíram que algoritmos de inteligência artificial "como assistentes dos profissionais que atendem o queimado é uma ferramenta robusta com excelentes valores de desempenho, e que pode auxiliar na tomada de decisões mais assertivas sobre o tratamento e o plano de cuidados do paciente" (SCHUCH; SCHERER, 2020, p.108).

De acordo com Scott e Coiera (2020) "a inteligência artificial está sendo usada de várias maneiras diferentes para conter a pandemia atual, ao mesmo tempo em que demonstra seu potencial para ser ainda mais eficaz na próxima." Em estudo desenvolvido por estes autores, que objetivou descrever as várias aplicações de inteligência artificial relevantes para COVID-19, destacou os usos em:

- Detecção de surtos, rastreando contatos e moldando respostas de saúde pública por meio do sistema *HealthMap* automatizado por inteligência artificial do Hospital Infantil de Boston, que alertou o mundo sobre o novo coronavírus em 30 de dezembro de 2019, e com um modelo de inteligência artificial canadense *BlueDot*, que emitiu um alerta semelhante um dia depois. Também baseado em algoritmos de IA, pesquisadores alertaram sobre as 20 principais cidades de destino, para as quais a doença podia se espalhar, onde os passageiros de Wuhan haviam chegado;

- Triage para pessoas que podem estar infectadas: Em um estudo pré-clínico com casos hipotéticos, um algoritmo alimentado por inteligência artificial identificou pacientes com COVID-19 com sensibilidade, especificidade e precisão diagnóstica geral de 97%, 96% e 96%, respectivamente;

- Facilitando o diagnóstico precoce: A inteligência artificial foi usada para projetar, em poucas semanas, imunoensaios de ponto de atendimento para detectar antígenos virais em 20 minutos, e esses kits de teste já estão em uso;

- Monitoramento remoto e atendimento virtual: Pacientes com diagnóstico de COVID-19, que não necessitam de hospitalização, tem a possibilidade de ser monitorados em casa, ou seja, de maneira remota utilizando-se de dispositivos

vestíveis que medem temperatura, pressão sanguínea e níveis de oxigênio arterial, transmitindo tais dados para unidades centrais de atendimento virtual (que alerta a equipe sobre uma possível necessidade de atendimento externo), como os que existem em alguns hospitais australianos.

Scott e Coiera (2020) concluem que ainda “é muito cedo para saber até que ponto a IA terá impacto no surto COVID-19. Embora seu papel possa ser limitado durante a atual pandemia, certamente pode ajudar na próxima.”

Al-Mufti *et al.* (2019) abordam sobre o uso da inteligência artificial nos cuidados neurocríticos, o qual combina a complexidade dos estados de doença clínica e cirúrgica com as limitações inerentes à avaliação de pacientes com lesão neurológica, tendo a inteligência artificial apresentado potencial em ajudar os médicos em vários aspectos do atendimento, em especial no monitoramento e controle da pressão intracraniana, convulsões, hemodinâmica e ventilação, realizando análises a partir da vasta quantidade de dados de pacientes que são acumulados na unidade de tratamento neuro crítico, oferecendo aos médicos outra ferramenta de apoio para gerenciar esses pacientes complexos.

O grupo de inteligência artificial da PUCRS (2021) por meio do Guia do Hospital Orientado a Dados, listou como a inteligência artificial pode ser aplicada em relação a eficiência hospitalar, sendo que vários dados podem ser localizados no prontuário eletrônico do paciente, ajudando na detecção de anomalias no atendimento, dentre eles, elenca-se:

- Predição de internação de paciente no pronto atendimento;
- Predição de tipo de acomodação para internação;
- Predição de Alta Hospitalar (para liberação de leito);
- Predição de Reinternação Precoce;
- Mensuração de Custo por Diagnóstico;
- Predição de Agendamento de CTI;
- Predição do DRG (*Diagnosis Related Group*);
- Mensuração de Eficiência de Equipe;
- Busca Ativa de Prontuários; entre outros.

A seguir aborda-se sobre os conceitos de aprendizado de máquina e suas aplicações em cuidados intensivos.

### 2.1.1 Aprendizado de máquina em cuidados intensivos

O aprendizado de máquina (AM) é uma das áreas da inteligência artificial, concentrando-se na especificação de como as máquinas aprendem com os dados (MONARD; BARANAUSKAS, 2003; RUSSELL; NORVIG, 2010).

Os algoritmos de aprendizado de máquina são criados de maneira a resolver uma situação em um determinado cenário, ficando o algoritmo cada vez mais especializado diante do tamanho e estrutura dos dados, e a depender o tipo do algoritmo adquire conhecimento e realiza decisões de maneira automática, dependendo cada vez menos da interferência humana (RUSSELL; NORVIG, 2010; GENNATAS *et al.*, 2020).

O aprendizado de máquina foca na criação de sistemas que são capazes de adquirir conhecimento de maneira automática, ou seja, “um sistema de aprendizado é um programa de computador que toma decisões baseado em experiências acumuladas através da solução bem sucedida de problemas anteriores” (MONARD; BARANAUSKAS, 2003, p.39).

As UTIs acompanharam a evolução tecnológica e, conseqüentemente, têm em sua estrutura atual responsabilidades e empenho de habilidades específicas por parte da equipe médica e de enfermagem, bem como o desenvolvimento sempre atualizado de tecnologias voltadas para seu melhor desempenho que é manter a vida, por meio do reestabelecimento da saúde. A criação da primeira UTI consta de 1926 em Boston pelo Dr. Walter Dandy. A enfermeira britânica Florence Nightingale também merece destaque haja vista que foi a primeira a colocar em prática ideia de classificação dos pacientes, sendo que os mais graves careciam de mais atenção estando a equipe de enfermagem atento à eles (SCHLINZ, 2016). Na década 70, as unidades de terapia intensiva foram implantadas no Brasil através da rápida difusão e produção de equipamentos e fármacos, fortalecendo o setor de saúde como um novo setor industrial (BARRA *et al.*, 2009).

Conforme Resolução Nº 2.271, de 14 de fevereiro de 2020, publicada pelo Conselho Federal de Medicina (2020, p.2), em seu artigo 5º, determina “que cabe ao médico a responsabilidade ética e técnica quanto às decisões concernentes ao diagnóstico e tratamento realizados nos pacientes internados nas UTI/UCI.” As UTIs também se classificam conforme o tipo de paciente, sendo: neonatal, pediátrico ou adulto, uma outra classificação agregada é o nível de atenção ou complexidade. A

UTI é considerada parte do ambiente hospitalar, o qual é considerado o setor de suporte vital de alta complexidade, incluindo monitorização por parte de vários equipamentos e suporte avançados para proporcionar “a vida durante condições clínicas de gravidade extrema e risco de morte por insuficiência orgânica. Essa assistência é prestada de forma contínua, 24 horas por dia, por equipe multidisciplinar especializada” (CONSELHO FEDERAL DE MEDICINA, 2020, p.2).

De acordo com Johnson *et al.* (2016, p. 444), ao pesquisarem sobre uso do aprendizado de máquina em suporte à decisão em cuidados críticos, afirmam que os sistemas de gerenciamento de dados clínicos proporcionam às equipes de profissionais informações primordiais que são derivadas de grandes fontes de dados, e no que na última década, ocorreu um crescimento significativo no interesse no uso dessas fontes de dados, “desde a simples reutilização dos bancos de dados clínicos padrão para previsão de eventos ou suporte à decisão, até a inclusão de informações dinâmicas e específicas do paciente em problemas de monitoramento e previsão clínicos.”

Conforme Kagerbauer *et al.* (2020), o uso do aprendizado da máquina na saúde ajuda a fornecer tratamento de maneira individualizada, evitando complicações, de modo a aumentar a qualidade dos cuidados prestados, sendo baseados em grandes quantidades de dados que atendem a certos requisitos.

Figura 1: Pipeline de processamento de informações de saúde.



Fonte: Adaptado por Schmidt *et al.* (2020, p. 3)

Na Figura 1 verifica-se o pipeline de processamento das informações em saúde, através dela observa-se que o objetivo é explorar padrões que possam ser encontrados ao analisar grandes volumes de dados, por meio dos passos: capturar grandes volumes de dados, armazenar e compartilhar adequadamente os dados, analisar os dados (pré-processamento, seleção de variáveis, aplicação de técnicas de

aprendizado de máquina para gerar conhecimento), procurar por padrões de informações e dar suporte a decisões clínicas (SCHMIDT *et al.*, 2020).

O aprendizado de máquina utiliza-se de padrões nos dados visando realizar classificações baseadas em variáveis para resultados específicos, bem como realizar previsões com base em dados anteriores. Embora o aprendizado de máquina seja considerado uma poderosa tecnologia, não se tem ainda um algoritmo que seja capaz de resolver todos os problemas (MONARD; BARANAUSKAS, 2003). Neste sentido, é fundamental compreender as aplicações e limitações dos diversos algoritmos sabendo analisar os seus conceitos e aplicações.

Os algoritmos em aprendizado de máquina evoluem conforme a lógica, estatística e fórmulas que são definidas, e aprendem conforme o volume de dados que vão sendo capturados. Estes algoritmos classificam-se em: supervisionados, não supervisionados e aprendizagem por reforço. A Figura 2 apresenta as 03 grandes classificações de algoritmos de aprendizado de máquina e suas subclassificações.



Fonte: Clavera (2019, online).

Na aprendizagem supervisionada – *Supervised Learning*, o algoritmo/máquina é programado para observar entrada-saída de exemplo e aprende

uma função que mapeia da entrada para a saída, isto é, o valor de saída é disponível diretamente das percepções da máquina (após o fato), na prática essas distinções nem sempre são tão nítidas (RUSSELL; NORVIG, 2010). Os algoritmos de AM supervisionados trabalham com conjuntos de dados rotulados/identificados, tendo como tarefas comuns a classificação de atividades ou objetos, sendo primordial grandes conjuntos de dados rotulados para que o algoritmo funcione de maneira satisfatória (MONARD; BARANAUSKAS, 2003).

Ashley (2020) afirma que bancos de dados de classificação de imagens para diagnóstico por imagens rotuladas podem ser reutilizadas em qualquer modelo utilizando-se de técnicas de transparência de aprendizagem, como é o caso do *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*, *National NLP Clinical Challenges (N2C2)* e o *Medical Information Mart for Intensive Care (MIMIC III)* (SHEIKHALISHAHI; BALARAMAN; OSMANI, 2020), os quais também proporcionam um conjunto de referência pública para abordar quatro áreas de cuidados intensivos, sendo elas: previsão de mortalidade, estimativa do tempo de internação, fenotipagem do paciente e risco de descompensação. Outro banco de dados é o disponível para pesquisas relatado nos estudos de Pollard *et al.* (2018), o qual é um Banco de Dados de Pesquisa Colaborativa (eICU), um banco de dados de unidade de terapia intensiva, multicêntrico com dados de alta granularidade que possui mais de 200.000 admissões em UTIs monitoradas por Programas da eICU no Estados Unidos. Para Sheikhalishahi, Balaraman e Osmani (2020) a disponibilidade recente de grandes conjuntos de dados clínicos permitiu a possibilidade de estabelecer benchmarks públicos, o que contribui para o progresso nas pesquisas de aprendizado de máquina para cuidados intensivos.

No aprendizado não supervisionado – *Unsupervised Learning*, o algoritmo/máquina aprende padrões na entrada, mesmo que nenhum feedback explícito seja fornecido. O agrupamento (*clustering*) é a tarefa mais comum de aprendizado não supervisionado, nos quais os potenciais grupos são formados a partir dos exemplos de entrada (RUSSELL; NORVIG, 2010). Neste sentido, não se pressupõe que os dados sejam rotulados haja vista que seu objetivo é encontrar semelhanças nos dados e agrupá-los de acordo com as atividades/tarefas semelhantes. Como exemplo, cita-se o mencionado por Ashley (2020), que se treinar um modelo não supervisionado com dados suficientes contendo imagens de atletas realizando ações em diferentes esportes, tal modelo deve ser capaz de prever a qual

grupo ou esporte uma determinada imagem pertence. Este tipo de algoritmo é interessante ser aplicado quando não se tem um conjunto de dados rotulado.

Em decorrência da possibilidade de utilizar um modelo de algoritmo de aprendizado de máquina com alguns rótulos em um conjunto sem rótulo, este modelo é compreendido como sendo semissupervisionado (ASHLEY, 2020). Como exemplo, para facilitar a compreensão, cita-se o mencionado por Russell e Norvig (2010), no qual deve-se imaginar que você recebe alguns dados rotulados e deve fazer o que puder em um grande conjunto de dados não rotulados. Mesmo os próprios rótulos podem não ser as verdades que é esperada. Imagine-se tentando construir um sistema para adivinhar a idade de uma pessoa a partir de uma foto. Então, tira-se algumas fotos e marca a idade delas (aprendizado supervisionado). Porém, algumas pessoas mentiram sobre a idade na foto marcada, momento em que há um ruído nos dados. No entanto, considerando que as imprecisões são sistemáticas e descobri-las é um problema de aprendizagem não supervisionado envolvendo imagens, idades autorrelatadas e idades verdadeiras, é o momento da junção dos dois tipos de aprendizados. Assim, tanto o ruído quanto a falta de rótulos criam um continuum entre o aprendizado supervisionado e o não supervisionado.

A terceira classificação da aprendizagem é por reforço – *Reinforcement Learning*, na qual aplica-se a noção de um agente (algoritmo/máquina) tentando alcançar uma meta e receber recompensas por ações positivas e penalidades por ações negativas, ou seja, aprende-se com uma série de reforços (recompensas ou punições) para os quais são atribuídos pesos (RUSSELL; NORVIG, 2010; ASHLEY, 2020).

Liu *et al.* (2020) realizam uma revisão sistemática da literatura sobre as aplicações da aprendizagem por reforço para apoio à decisão clínica em cuidados intensivos, no qual foram analisados 21 artigos, evidenciando que este tipo de aprendizagem foi empregado para otimizar a escolha de medicamentos, dosagem de medicamentos e tempo de intervenções. Concluíram que a aplicação de aprendizado de máquina por reforço apresenta um poderoso potencial para melhorar a tomada de decisão em cuidados intensivos.

A aprendizagem por reforço foi empregada no estudo de Yu, Liu e Zhao (2019) como proposta para a otimização do desmame da ventilação mecânica e dosagem de sedativos para pacientes em UTIs. Como método aplicaram pesos a variáveis como forma de recompensa. Concluíram que é uma abordagem eficaz para descobrir as

funções de forma que os médicos possam projetar melhores protocolos de tratamento no desmame da ventilação e dosagem de sedativos em UTIs.

Kagerbauer *et al.* (2020) realizaram pesquisa com objetivo de fornecer uma visão geral dos métodos e da aplicação do aprendizado de máquina na área de anestesiologia e medicina intensiva, por meio do qual elencaram os métodos utilizados com mais frequência disposto no Quadro 01.

Quadro 1: Métodos de aprendizado de máquina usados com frequência em anestesiologia e medicina intensiva.

Método	Descrição
Árvore de decisão (Decision tree)	Usada para a classificação automática de objetos. Consiste em nós de raiz, nós internos e folhas. Cada nó representa uma regra lógica, cada folha uma resposta.
Floresta aleatória (Random forest)	Procedimento de classificação que é composto de muitas árvores de decisão diferentes.
Aprendizagem por reforço (Reinforcement learning)	Determina como um programa de computador é capaz de agir diante de recompensas de maneira auto dinâmica para maximizar o comportamento.
Redes bayesianas (Bayesian networks)	Criação de modelos gráficos de variáveis aleatórias e suas dependências condicionais.
Máquina de vetores de suporte (Support Vector Machines)	Usado para classificação e regressão. Usando exemplos de aprendizagem que podem ser classificados em uma das duas categorias predefinidas. Um algoritmo de máquina de vetor de suporte cria um modelo que prevê em qual das categorias um novo exemplo deve ser classificado.
Redes neurais artificiais (Artificial neural networks)	Consistem em neurônios artificiais interconectados que processam informações.
Aprendizagem profunda (Deep learning)	Redes neurais com várias camadas ocultas (camadas profundas) que dão à rede neural uma certa "profundidade" no aprendizado.
Clustering (Clustering)	Resumindo métodos de aprendizagem não supervisionada. Aqui, o sistema não "sabe" o que deve reconhecer e divide as observações em diferentes categorias (clusters).
Métodos de conjunto (Ensemble methods)	Algoritmos de que combinam diferentes métodos de aprendizado de máquina.




Fonte: Kagerbauer *et al.* (2020, p. 88, tradução nossa)

Conforme estudos mencionados até o momento são várias as aplicações de aprendizado de máquina em cuidados intensivos. A seguir são apresentadas pesquisas que aplicaram aprendizado de máquina em sepse.

A Sepse é compreendida como sendo uma disfunção orgânica causada em resposta a um desordenamento do organismo a um processo infeccioso, sendo considerada como um dos maiores causadores de mortalidade e aumentos dos custos em UTIs (MAO *et al.*, 2018).

A Figura 3 apresenta uma análise do emprego dos três tipos de aprendizagem de máquina em sepse.

Figura 3: Exemplo dos 3 tipos de aprendizado de máquina aplicada a sepse.

	Supervised learning	Unsupervised learning	Reinforcement learning
Objective	Learn the mapping between input data and labels	Learn the data structure of identify subgroups	Learn on optimal strategy in a decision process
Model training			
Model use			
Examples of algorithms	<ul style="list-style-type: none"> <li>• Logistic regression</li> <li>• Deep neural network</li> </ul>	<ul style="list-style-type: none"> <li>• Clustering</li> <li>• Dimensionality reduction</li> </ul>	<ul style="list-style-type: none"> <li>• Q learning</li> <li>• Policy iteration</li> </ul>
Examples of applications	<ul style="list-style-type: none"> <li>• Mortality prediction [7]</li> <li>• Prediction of sepsis or deterioration</li> <li>• Classification of dysrhythmias [15]</li> </ul>	<ul style="list-style-type: none"> <li>• Phenotyping of patients with sepsis [9,10] or acute respiratory distress syndrome</li> </ul>	<ul style="list-style-type: none"> <li>• Optimising sepsis resuscitation [13]</li> <li>• Optimising insulin dosing</li> </ul>

Fonte: Komorowski (2019, p.1299).

Pesquisa Calvert *et al.* (2016) que visou desenvolver tecnologia de previsão de sepse precoce de alto desempenho para a população geral de pacientes, por meio da análise retrospectiva (do conjunto de dados MIMIC II) de pacientes adultos em UTIs que não estavam sépticos no momento da admissão, criaram o algoritmo de alerta precoce de sepse, chamado de InSight, e obtiveram como resultado a previsão com exatidão de pelo menos três horas antes do início do primeiro episódio, usando nove sinais vitais comumente disponíveis, concluindo que houve um melhor desempenho do que os métodos da prática padrão empregadas em relação à probabilidade de identificação precoce de pacientes em risco.

Nemati *et al.* (2018) desenvolveram e validaram um algoritmo de aprendizado de máquina para a previsão precoce de sepse. Foram envolvidos na pesquisa mais de 31.000 admissões em UTIs em dois hospitais e mais de 52.000 pacientes de UTI do banco de dados do Medical Information Mart for Intensive Care-III disponível ao público. Usando os dados disponíveis na UTI em tempo real, o algoritmo proposto chamado de Artificial Intelligence Sepsis Expert previu com precisão o início da sepse em paciente da UTI de 4 a 12 horas antes do reconhecimento clínico.

Pimenta, Alvim e Meirelles (2020) descreveram as técnicas de aprendizagem de máquina na identificação de casos de sepse, e concluíram que os algoritmos para

a identificação e predição de sepse estão sendo cada vez mais usados no exercício clínico, aparecendo uma tendência de crescimento e propagação destes modelos, haja vista que serviços de saúde, em sua maioria, ainda identifica a sepse de forma observacional, sem o auxílio desta tecnologia.

Koyner *et al.* (2018) desenvolveram um modelo de predição de risco de lesão renal aguda usando dados de prontuários eletrônicos prontamente disponíveis, podendo ser usados para prever lesão renal aguda iminente antes das alterações na creatinina sérica. Concluíram que o uso do modelo proposto permitiria intervenções precoces para aqueles com alto risco de lesão renal aguda.

Estudos apontam que a utilização de algoritmos em alarmes voltados para equipamentos de amparo ao atendimento de pacientes críticos podem reduzir os falsos alarmes por meio do uso de algoritmos de aprendizado de máquina através da avaliação de qualidade do sinal (LI; CLIFFORD, 2012a; LI; CLIFFORD, 2012b).

Mousavi, Fotoohinasab e Afghah (2020) proporam um modelo de aprendizado profundo que suprime efetivamente os falsos alarmes UTIs sem ignorar os verdadeiros alarmes. O algoritmo atingiu uma sensibilidade de 93,88% e uma especificidade de 92,05% na dos alarmes, considerando três sinais diferentes.

Yu *et al.* (2020) criaram um modelo de aprendizado de máquina que prevê resultados de testes de laboratório, fornecendo uma estratégia de redução de teste de laboratório. Validaram o algoritmo usando um banco de dados de cuidados intensivos, que incluiu 4.570.709 observações de 12 testes laboratoriais padrão, entre 38.773 pacientes em cuidados intensivos. Como resultado obteve-se que o modelo ofereceu uma redução de 20,26% no número de exames laboratoriais, concluindo que auxilia os médicos a determinar quais testes de laboratório podem ser omitidos.

Em relação à atual pandemia da COVID-19, lista-se a seguir artigos que de alguma maneira empregaram algoritmos de aprendizado de máquina para soluções a da COVID-19 em cuidados intensivos.

Schwab *et al.* (2020) desenvolveram e avaliaram modelos preditivos clínicos que estimavam, utilizando aprendizado de máquina e com base em dados clínicos coletados rotineiramente, quais seriam os pacientes que teriam maior probabilidade de receber um teste SARS-CoV-2 positivo ou necessitar de hospitalização ou terapia intensiva. Para avaliar os modelos desenvolvidos, realizaram uma avaliação retrospectiva dos dados demográficos, clínicos e de análise sanguínea de um estudo de coorte de 5.644 pacientes, e determinaram quais características clínicas seriam

preditivas. Concluíram que indicam que os modelos preditivos treinados em dados clínicos coletados rotineiramente podem ser usados para prever caminhos clínicos para COVID-19 e, portanto, ajudar a informar o cuidado e priorizar recursos (SCHWAB *et al.*, 2020).

Pesquisa de Kim *et al.* (2020) evidenciou, por meio o uso do modelo de aprendizado de máquina que compreende características simples, que é possível prever com eficiência a necessidade de cuidados intensivos entre pacientes com COVID-19. Avaliaram dados de 4.787 pacientes incluídos na análise, sendo que baseado nos dados de 460 (9,6%) pacientes que necessitaram de cuidados intensivos.

Izquierdo, Ancochea e Soriano (2020) utilizam-se do aprendizado de máquina e processamento de linguagem natural para descrever características clínicas e determinar os fatores que predizem a admissão à unidade de terapia intensiva (UTI) de pacientes com COVID-19. Analisaram registros eletrônicos de saúde de 10.504 pacientes diagnosticados com COVID-19. Os resultados apresentaram que uma combinação de variáveis clínicas de fácil obtenção (idade, febre e taquipnéia com ou sem estertores respiratórios) prediz se os pacientes com COVID-19 necessitarão de internação na UTI.

Li *et al.* (2020b) em estudo sobre a predição de aprendizagem profunda da probabilidade de admissão à UTI e mortalidade em pacientes com COVID-19 usando variáveis clínicas, que objetivou desenvolver um modelo de aprendizado para prever admissão em unidade de terapia intensiva (UTI) e mortalidade hospitalar em pacientes com COVID-19, concluíram que o aprendizado profundo têm a potencialidade de prover aos médicos da linha de frente bases quantitativas para estratificar os pacientes de forma mais eficaz em circunstâncias sensíveis ao tempo e recursos limitados.

Pan *et al.* (2020) usaram o aprendizado de máquina para construir um modelo de análise de fatores de risco e predição de mortalidade em pacientes internados em UTI com COVID-19. Nesta pesquisa, 123 pacientes com COVID-19 na UTI do Hospital Vulcan Hill foram selecionados retrospectivamente do banco de dados. O modelo definiu 8 fatores que prenuncia bem o risco de morte em pacientes de UTI com COVID-19, demonstrando estabilidade, podendo ser usado efetivamente para prever o prognóstico de COVID-19 em pacientes de UTI.

Ryan *et al.* (2020) desenvolveram e avaliaram um algoritmo baseado em aprendizado de máquina para previsão de mortalidade em COVID-19, pneumonia e pacientes ventilados mecanicamente. Para isto, usaram um conjunto de dados de 53.001 pacientes totais de UTI, incluindo 9.166 pacientes com pneumonia e 25.895 pacientes ventilados mecanicamente. Os autores concluíram que o algoritmo baseado em aprendizado de máquina é um instrumento preditivo útil para prever a mortalidade com precisão para pacientes ventilados mecanicamente, bem como aqueles diagnosticados com pneumonia e COVID-19.

O Grupo de Inteligência Artificial da PUCRS (2021) listou o potencial uso do aprendizado de máquina em alguns processos de segurança do paciente que podem ajudar no aumento da qualidade assistencial e gerenciamento de risco: Detecção de eventos adversos; Detecção de quedas, predição de risco de quedas; Predição de diversos riscos do paciente; Triagem na farmácia clínica; Detecção de prescrição fora do padrão; Escore do paciente crítico; Detecção precoce de sepse; Detecção de procedimento fora do padrão; entre outros.

O uso do aprendizado de máquina proporciona uma maior segurança a equipe na tomada de decisão em relação aos procedimentos frente a um paciente, considerando que a decisão do sistema é tomada baseado no modelo identificado em um conjunto de dados, os quais foram previamente validados por especialistas, auxiliando a encontrar soluções para resolver situações que necessitam de mais assistência.

Conforme visto, o uso do aprendizado de máquina é uma realidade, sendo necessário conhecer sobre como está a produção científica sobre este assunto. Para isto, é essencial conhecer os conceitos que envolvem a bibliometria e a cientometria de forma a melhor compreender o que é proposto nesta tese.

## 2.2 MÉTRICAS DA INFORMAÇÃO CIENTÍFICA

Para Ferreira (2018) o crescimento e desenvolvimento da ciência está relacionada à evolução das ferramentas que possibilitam a efetivação de observações e verificações. O advento das TICs e a disponibilidade das bases de dados eletrônicos de informação científica evoluíram juntamente com o desenvolvimento e popularização dos computadores, a necessidade de avaliar a ciência e a criação de softwares que possibilitam a realização de análises, bem como a análise de redes de


colaboração científica, possibilitaram o estabelecimento de indicadores e de mapas de relacionamento entre autores, instituições, dentre outras variáveis que sejam do interesse das pesquisas (HAYASHI, 2013).

Verifica-se que com o advento do uso de computadores, a indexação da produção científica que antes era realizada em papel e regionalizada passou a ser possível e mais acessível através de bases de dados disponível na rede mundial de computadores, facilitando assim a sua divulgação. Neste sentido, observou-se que a produção científica teve aumento exponencial (GINGRAS, 2016).

Os estudos métricos da informação contribuíram significativamente para a evolução da avaliação da produção científica. Os estudos métricos compreendem a relação de estudos ligados à avaliação da informação, em especial da ciência, nos diversos suportes, fundamentados em recursos quantitativos como artifícios de análise. Tem seu fundamento no campo da Ciência da Informação, da Sociologia da Ciência, Matemática, Estatística e Computação (GINGRAS, 2016).

Quando estes estudos são aplicados para o aumento do conhecimento nas áreas temáticas por meio da proposição de conceitos e indicadores concernentes a área pesquisada são considerados estudos de natureza teórico-conceitual. Também podem ser aplicados de maneira metodológica, com a proposição de dar ratificação às pesquisas teóricas da área na qual serão aplicadas (OLIVEIRA; GRACIO, 2018). A Figura 4 apresenta uma visão linear da evolução dos estudos da informação, apontando que o primeiro estudo aplicando a Bibliometria teve registro em 1917.

Figura 4: Linha do tempo dos estudos métricos da informação.



Fonte: Gabriel Junior (2014, p.31).

Para Vanti (2002), avaliar a produtividade da ciência tem como benefícios, dentre outros, o estabelecimento de políticas para o ensino e pesquisa, bem como o diagnóstico de grupos, instituições, áreas de conhecimento, pesquisadores, países, advertindo que há o questionamento de como fazer tal medição. Para isto, existem técnicas quantitativas de medição, e que são subdivididas em Bibliometria, Cienciometria, Informetria e Webometria. A Tabela 1 apresenta de maneira simples e objetiva o esclarecimento de pontos-chaves que identificam cada um destes subcampos. Devido à popularização da internet, bem como a evolução e utilização desta, novos termos voltados para os estudos métricos da informação surgiram recentemente como a Altmetria e Webmetria, sendo considerados subcampos da Cibermetria (SANTOS; ALBUQUERQUE, 2017).

Tabela 1: Comparação das aplicações dos distintos métodos quantitativos.

Tipologia/ Subcampo	Bibliometria	Cientometria	Informetria	Webometria
Objeto de estudo	Livros, documentos, revistas, artigos, autores, usuários	Disciplinas, assuntos, áreas, campos científicos e tecnológicos, patentes, dissertações e teses	Palavras, documentos, banco de dados, comunicações informais (inclusive em âmbito não científico) e <i>home page</i> na WWW	Sítios na WWW, (URL, título, tipo, domínio, tamanho e <i>links</i> ) motores de busca
Variáveis	Número de empréstimos (circulação) e de citações, frequência de extensão de frases	Fatores que diferenciam as subdisciplinas. Como os cientistas se comunicam	Difere da cientometria no propósito das variáveis, por exemplo, medir a recuperação, relevância, a revocação	Número de páginas por sítio, número de links por sítio, número de links que remetem a um mesmo sítio, número de sítios recuperados
Métodos	<i>Ranking</i> , frequência, distribuição	Análise de conjunto de correspondência, co-ocorrência de termos, expressões, palavras-chave, etc.	Modelo vetor espaço, modelos booleanos de recuperação, modelos probabilísticos; linguagem de processamento, abordagens baseadas conhecimento, tesauros	Fator de Impacto da Web, densidade dos <i>links</i> , "citações", estratégias de busca
Objetivos	Alocar recursos, pessoas, tempo, dinheiro	Identificar domínios de interesse. Onde os assuntos estão concentrados. Compreender como e quanto os cientistas se comunicam	Melhorar a eficiência da recuperação da informação, identificar estruturas e relações dentro dos diversos sistemas de informação	Avaliar o sucesso de determinados sítios, detectar a presença de países, instituições, pesquisadores na rede e melhorar a eficiência dos motores de busca na recuperação das informações

Fonte: Adaptado por Vanti (2002, p. 160).

Considerando o foco e os objetivos propostos, aborda-se somente os conceitos e características das técnicas de Bibliometria e Cientometria.

### **2.2.1 Bibliometria e Cientometria**

A produção científica deve ser transformada em informação acessível, divulgada e compartilhada com a comunidade, sendo a expressão de uma pessoa ou um grupo de pessoas que pesquisam sobre determinado assunto (MACIAS-CHAPULA, 1998). Neste sentido, a avaliação de tais publicações tem se destacado como forma de se verificar o conhecimento. De acordo com Gingras (2016) como resultado do fortalecimento das políticas científicas, a Bibliometria como área de pesquisa acadêmica teve seu impulso no decorrer da década de 70.

Para Gingras (2016, p. 17) a Bibliometria é “método de pesquisa que consiste em utilizar as publicações científicas e suas citações como indicadores da produção científica e de seus usos”, à qual é “essencial para se cartografar de forma global o estado das pesquisas num dado momento e num dado lugar e, assim, ultrapassar as percepções locais e anedóticas”, possibilitando a identificação de “tendências em diversas escalas: regional, nacional e mundial, que de outro modo seria impossível fazer emergir” (GINGRAS, 2016, p.123).

Na visão de Macias-Chapula (1998, p. 134) a Bibliometria “é o estudo dos aspectos quantitativos da produção, disseminação e uso da informação registrada.” Para Spinak (1998, p. 142, tradução nossa) a Bibliometria pode ser melhor definida da seguinte maneira:

- Aplicação de análises estatísticas para estudar as características de uso e criação de documentos.
- Estudo quantitativo da produção de documentos como é refletido nas bibliografias.
- Aplicação de métodos matemáticos e estatísticas para o estudo da utilização que é feita dos livros e outros meios de comunicação social dentro e entre os sistemas de bibliotecas.
- Estudo quantitativo das unidades físicas publicados ou unidades bibliográficas, ou seus substitutos.

A análise bibliométrica pode ser aplicada para diversas finalidades, dentre elas: Mapear a literatura de uma área de conhecimento; Modelar matematicamente aspectos dinâmicos da literatura científica; Identificar áreas de excelência, associações temáticas, interdisciplinaridade, redes de colaboração científica, temas

emergentes e lacunas na produção do conhecimento científico; Produzir indicadores bibliométricos (HAYASHI, 2013).

A aplicação da Bibliometria permite avaliar documentos em diversas escalas, como autores, instituições, países. Em termos de conteúdo é permitido também sua aplicação em uma disciplina e uma especialidade ao documento, sendo possível ter “uma ideia do desenvolvimento relativo de diversos campos de pesquisa entre instituições e os países e ajudam ainda a compreender diversos aspectos da estrutura e da dinâmica das ciências” (GINGRAS, 2016, p. 48).

A análise bibliométrica da produção científica apresenta como vantagens a visão de sua evolução temporal, na escala de país ou de instituição, e por meio da utilização de palavras-chave é possível visualizar tendências de aumento ou diminuição que contemplam certas áreas do conhecimento. “De fato, ninguém poderia ter uma visão global da pesquisa sem esses dados bibliométricos que fornecem indicadores indispensáveis para acompanhar o desenvolvimento da pesquisa” (GINGRAS, 2016, p. 49).

Gingras (2016, p. 23) afirma que os termos Bibliometria e Cientometria “tornaram-se rapidamente intercambiáveis” haja vista que “o uso de dados bibliométricos no estudo da dinâmica das ciências passou a ser rotineiro”, apresentando áreas de aplicação em comum como a política científica, sociologia das ciências, história das ciências, avaliação da pesquisa, economia das ciências e a biblioteconomia e ciência da informação. Gingras (2016, p. 23) esclareceu a Cientometria da Bibliometria:

Cientometria trata da medida quantitativa do conjunto de atividades científicas, válida para todas as disciplinas indistintamente. Seus dados incluem os montantes investidos na pesquisa-desenvolvimento, a formação profissional de ciência e a produção de artigos e certificados. A Bibliometria é um subconjunto da cientometria e limita-se à análise das publicações e de suas propriedades.”

Em 1950, o historiador da ciência que deu mais coerência à Cientometria foi Dereck de Solla Price, o qual propôs considerar a ciência ao objetivar analisar um conjunto dos cientistas ou de suas publicações, no lugar de concentrar-se em um particular, criando assim a “Ciência das Ciências”, o qual tem como essência o fundamento sobre a análise quantitativa de seu desenvolvimento, utilizando a indexação de citações para fazer o uso de maneira sociológica e não apenas como forma bibliográfica (GINGRAS, 2016). Para macias-Chapula, (1998, p. 134) a Cientometria é:

O estudo dos aspectos quantitativos da ciência enquanto uma disciplina ou atividade econômica. A cienciometria é um segmento da sociologia da ciência, sendo aplicada no desenvolvimento de políticas científicas. Envolve estudos quantitativos das atividades científicas, incluindo a publicação e, portanto, sobrepondo-se à bibliometria.

A Cienciometria aplica técnicas de análise bibliométrica voltadas para a ciência (física, natural, sociais), indo além ao analisar a evolução e as políticas de ciência, realizando comparações entre as políticas de pesquisa, bem como entre os países, analisando seus aspectos econômicos, tendo como itens de interesse: o aumento quantitativo da ciência, o desenvolvimento das disciplinas e sub - disciplinas, a relação entre ciência e tecnologia, a obsolescência dos paradigmas cientistas, a estrutura de comunicação entre cientistas, produtividade e criatividade pesquisadores, as relações entre o desenvolvimento científico e o crescimento econômico (SPINAK, 1998).

De acordo com Pelegrini Filho *et al.* (1997) citado por Darosi e Anderle (2014, p. 5), a Cientometria refere-se “a área que trata da análise de aspectos quantitativos referentes à geração, propagação e utilização de informações científicas, com o fim de contribuir para o melhor entendimento do mecanismo de pesquisa científica como uma atividade social.”

De acordo com Santos (2004, p. 35), a Cientometria caracteriza-se como um reducionismo bibliométrico, fundamentando-se como base para a “Ciência da Ciência”, sendo “a razão para este fato a relação direta com os desafios socioeconômicos da era moderna, caracterizada essencialmente, pela reconhecida e certificada importância que a ciência assume junto à sociedade.” Price (1969) citado por Santos (2004, p. 28) definiu a Cientometria como “as pesquisas quantitativas de todas as coisas que dizem respeito à ciência e, aos quais podem ser atribuídos números.”

Para Tague-Sutcliffe (1992) citado por Vanti (2002, p. 154), a Cientometria:

Estuda, por meio de indicadores quantitativos, uma determinada disciplina da ciência. Estes indicadores quantitativos são utilizados dentro de uma área do conhecimento, por exemplo, mediante análise de publicações, com aplicação no desenvolvimento de políticas científicas. Tenta medir os incrementos de produção e produtividade de uma disciplina, de um grupo de pesquisadores de uma área, a fim de delinear o crescimento de determinado ramo do conhecimento.

Destaca-se que seriedade e necessidade de estimativa, ressaltam a importância das análises bibliométricas e cientométricas, tendo em vista que há várias possibilidades de suas aplicações. Spinak (1998, p. 143) especificou as aplicações:

Identificar as tendências e o crescimento do conhecimento nas diferentes disciplinas; Estimar a cobertura das revistas secundárias; Identificar os utilizadores das diferentes disciplinas; Identificar autores e tendências em diferentes disciplinas; Medir a utilidade da disseminação de serviços seletivos de informação; Previsão das tendências de publicação; Identificar os principais periódicos de cada disciplina; Formular políticas de compras ajustadas ao orçamento; Adaptar a política de descarte de publicações; Estudar a dispersão e a obsolescência da ciência da literatura; Normas de projeto para padronização; Desenho de processos de indexação, classificação e preparação de sumarização automática; Prever a produtividade de editores, autores individuais, organizações, países, etc.

Quoniam (1992) citado por Santos (2004) visando não submergir o fundamento da informação, e objetivando garantir a cobertura de maneira ampla e completa é necessário ter uma quantidade de considerável de dados e/ou informação de determinado assunto analisado neste processo de produção dos indicadores.

#### 2.2.1.1 Indicadores Bibliométricos e Cientométricos

A possibilidade de que a produção científica pode ser resgatada, pesquisada e medida a partir de sua literatura ampara o arcabouço teórico para o aproveitamento de métodos que objetivam a criação de indicadores de produção e de desempenho científico, e com o uso da Bibliometria e da Cientometria é plausível levantar indicadores propostos para medir a produção científica de indivíduos, áreas de conhecimento e países. Avaliados com base nos estudos métricos da informação, os indicadores tornaram-se amplamente usados para avaliação de pesquisadores e áreas de conhecimento (SILVA; HAYASHI; HAYASHI, 2011; GREGOLIN *et al.*, 2005).

Os indicadores podem ser classificados em: Indicadores de produção que visam medir a quantidade e impacto das publicações científicas, (em geral empregas as Leis Clássicas da Bibliometria), como por exemplo: autores mais relevantes e produtivos, periódicos mais importantes da área, artigos mais citados, frequência de palavras-chaves, etc. Indicadores de citação que medem a quantidade e impacto das citações. E indicadores de ligação baseiam-se nas citações, mas baseado no aspecto das relações entre a publicação científica, como a análise de citação (relação entre documentos citados e citantes), análise de cocitação (é a verificação da quantidade de referências em comum citadas juntas baseado em documentos anteriores, para

identificar as aproximações teóricas, conceituais e metodológicas sobre determinado assunto), acoplamento bibliográfico (junta documentos que citam o mesmo documento, como referências e/ou atores em comum), análise de coautoria (SPINAK, 1998; MACIAS-CHAPULA, 1998; GREGOLIN *et al.*, 2005).

As pesquisas podem ser efetivadas em nível micro, meso ou macro, podendo medir e analisar: indivíduos, instituições, países, periódicos individuais, grupos temáticos, uma disciplina inteira, área do conhecimento (SPINAK, 1998; VINKLER, 2010).

Os indicadores bibliométricos de produção direcionam para determinados comportamentos baseados em leis bibliométricas, as quais são descritas a seguir.

#### 2.2.1.2 Leis de Lotka Bradford, Zipf, Elitismo

Como forma de realizar as medições em análises bibliométricas três leis clássicas se sobressaem, sendo elas: a lei de medir a produtividade de cientistas de Lotka (1926), a lei de dispersão do conhecimento científico de Bradford (1934) e o modelo de distribuição e frequência de palavras em um texto de Zipf (1949). Tais leis seguem uma padronização em sua distribuição, seguindo a máxima “poucos com muito e muito com poucos” (GUEDES, 2012).

A Lei de Lotka foi proposta em 1926, nos Estados Unidos, pelo matemático Alfred J. Lotka por meio de um estudo que abordou sobre a distribuição de frequências de produtividade científica sobre Chemical Abstracts no período compreendido entre 1909 e 1916, Lotka encontrou que uma grande proporção das publicações científicas sobre o assunto da pesquisa é produzida por um pequeno número de autores, e um grande número de pequenos produtores se iguala, em produção, ao reduzido número de grandes produtores, e considerando tal afirmação definiu a fórmula da lei dos quadrados inversos:  $y_x = \alpha/p^2x^a$ , onde  $y_x$  é a frequência de autores publicando número  $x$  de trabalhos e  $a$  é um valor constante para cada campo científico (ARAÚJO, 2006; URBIZAGASTEGUI, 2008). Em outras palavras esta lei “considera que alguns pesquisadores, supostamente de maior prestígio em uma determinada área do conhecimento, produzem muito e muitos pesquisadores, supostamente de menor prestígio, produzem pouco” (GUEDES; BORSCHIVER, 2005). Ao longo dos anos esta lei tem sido aplicada em várias áreas do conhecimento até os dias atuais.

Em 1934, o químico e bibliotecário britânico Samuel C. Bradford, definiu a Lei de Bradford, também conhecida como Lei da Dispersão da Produção Científica, e tem como objeto o conjunto de periódicos. Ele investigou no recorte temporal de 1931 a 1933, na área da Geofísica, que analisando a coleção de periódicos de um determinado assunto é possível identificar 03 zonas, cada uma contendo 1/3 do total de artigos, sendo a zona 1, com poucos artigos produtivos, a zona 2 contém um número maior de artigos menos produtivos e a zona 3 inclui ainda mais periódicos, e com menos artigos produtivos que a zona anterior. De acordo com (ARAÚJO, 2006, p.14), Bradford ao formular a lei visava “descobrir a extensão na qual artigos de um assunto científico específico apareciam em periódicos destinados a outros assuntos, estudando a distribuição dos artigos em termos de variáveis de proximidade ou de afastamento.” De acordo com (ARAÚJO, 2006, p.15), o enunciado da Lei de Bradford consolida-se assim:

Se dispormos periódicos em ordem decrescente de produtividade de artigos sobre um determinado tema, pode-se distinguir um núcleo de periódicos mais particularmente devotados ao tema e vários grupos ou zonas que incluem o mesmo número de artigos que o núcleo, sempre que o número de periódicos existentes no núcleo e nas zonas sucessivas seja de ordem de 1:  $n$ :  $n^2$ :  $n^3$ ... Assim, os periódicos devem ser listados com o número de artigos de cada um, em ordem decrescente, com soma parcial. O total de artigos deve ser somado e dividido por três; o grupo que tiver mais artigos, até o total de 1/3 dos artigos, é o “core” daquele assunto. O segundo e o terceiro grupo são as extensões. A razão do número de periódicos em qualquer zona pelo número de periódicos na zona precedente é chamada “multiplicador de Bradford” ( $B_m$ ): à medida que o número de zonas for aumentando, o  $B_m$  diminuirá.

Neste sentido, a Lei de Bradford possibilita indicar que os primeiros artigos publicados acerca de um determinado assunto irão ser submetidos a uma pequena seleção serão aceitos por periódicos específicos do assunto. Essas fontes escolhidas logo no começo de determinado assunto consequentemente atrairão mais artigos. No entanto, em paralelo outros periódicos publicam também, logo “se o assunto continua a se desenvolver, emerge eventualmente um núcleo de periódicos mais produtivos, no que se refere à edição de artigos sobre o assunto” (GUEDES, 2012, p.82).

A Lei de Zipf, proposta em 1949 por Ulisses de James Joyce, considera a ocorrência de palavras, isto é, “descreve a relação entre palavras num determinado texto suficientemente grande e a ordem de série destas palavras (contagem de palavras em largas amostragens)” (ARAÚJO, 2006, p.16), concluindo que há um pequeno número de palavras que são mencionadas de maneira recorrente. Considerando a equação:  $r \times f = k$ , onde  $r$  é a posição da palavra,  $f$  é a sua frequência

e  $k$  é a constante, tem que a posição de uma palavra na lista multiplicada por sua frequência é igual a uma constante (GUEDES; BORSCHIVER, 2005), (GUEDES, 2012). No contexto desta lei há o princípio do menor esforço: há uma contenção na utilização de palavras, e “se a tendência é usar o mínimo significa que elas não vão se dispersar, pelo contrário, uma mesma palavra vai ser usada muitas vezes, as palavras mais usadas indicam o assunto do documento” (ARAÚJO, 2006, p.17).

A Lei do Elitismo foi criada por Dereck de Solla Price e visa medir o tamanho da elite de determinada população de autores, tendo como unidade de análise as citações. Seu enunciado é “o número de membros da elite corresponde à raiz quadrada do número total de autores, e a metade do total da produção é considerado o critério para se saber se a elite é produtiva ou não” (ARAÚJO, 2006, p.14), tendo como fórmula: Toda população de tamanho  $N$  tem uma elite efetiva tamanho  $\sqrt{N}$  (GUEDES; BORSCHIVER, 2005).

### 2.2.1.3 Citações e redes científicas

A formação e construção do conhecimento é um processo considerado social por meio do qual são estabelecidas relações e relacionamentos entre os atores envolvidos (MERTON, 1968; BOURDIEU, 2004; SILVA, 2002). A composição social das redes segue uma lógica que auxiliam em sua estruturação, sendo que “redes constituem a nova morfologia social de nossas sociedades, e a difusão da lógica de redes modifica de forma substancial a operação e os resultados dos processos produtivos e de experiência, poder e cultura” (CASTELLS, 1999, p. 565). As pesquisas são resultantes dos trabalhos em equipe, bem como em menções a outros estudos em que está envolvido do assunto.

As citações em documentos são consideradas ferramentas cartográficas que contribuem para a formação da estrutura conceitual das disciplinas e das especialidades científicas, além de possibilitar uma apresentação do seu crescimento, por meio da utilização de indicadores quantitativos de desenvolvimento temporal, utilizando métodos quantitativos, como o acoplamento bibliográfico e as citações de documentos (GINGRAS, 2016). Para Oliveira (2018, p. 58), a citação é um indicador o qual:


Permite a identificação de grupos de cientistas e suas publicações, com a finalidade de evidenciar os pesquisadores de maior impacto de uma área, apontando seus paradigmas, procedimentos metodológicos pertinentes e os pesquisadores de vanguarda que constroem o novo conhecimento na área.

De acordo com Romancini (2010, p. 20), “a rede constituída por citações possui certa arquitetura, capaz de revelar alguns padrões e características de um grupo.” A cocitação é a frequência com que dois outros documentos citados estão juntos em determinado documento.

Para Oliveira (2018, p. 59), “a força da cocitação entre dois autores citados pode ser facilmente determinada a partir do número de vezes que os autores foram citados juntos.” Vanz e Caregnato (2003, 252) citando Garfield (1979) esclarece que a “análise de citações não tem como princípio medir o número de vezes em que um determinado autor está certo ou errado, mas sim, medir o nível de contribuição de um pesquisador ou de uma instituição à ciência.” A cocitação liga documentos, autores ou periódicos segundo a combinação como os escritores os usam, sendo um princípio de agrupamento executado várias vezes por pesquisadores que citam publicações que consideram fundamentais para o estudo (ZUPIC; CATER, 2015).

Grácio (2016, p. 84) esclarece que o acoplamento bibliográfico visa “medir a relação entre dois artigos com base no número de referências em comum citadas pelos dois artigos.” Já a análise de cocitação tem por objetivo mensurar “a relação entre dois artigos com base no número de publicações em que estes aparecem citados concomitantemente.” Na Figura 5, tem-se o esquema gráfico de modo a melhor visualizar o enunciado e fazer a distinção entre acoplamento bibliográfico e cocitação.

Figura 5: Visão do esquema de documentos cocitados (lado esquerdo) e de documentos acoplados (lado direito).



Fonte: Mattos e Dias (2010, p.5) adaptado de Garfield (2001).

Admite-se que o acoplamento bibliográfico e a análise de cocitação podem ser considerados métodos que se complementam, os quais “quando utilizados de

forma conjunta, permitem uma visualização mais ampla, real e precisa da dinâmica da estrutura intelectual, social e cognitiva” (GRÁCIO, 2016, p. 96).

Com o surgimento dos aparatos tecnológicos que se tem nos dias atuais é possível localizar praticamente todas as citações dos autores em seus documentos originais, e com isto realizar análises pertinentes aos estudos que envolvem assuntos específicos. Além de analisar o aspecto quantitativo das produções, as técnicas de análise permitem analisar as relações entre os envolvidos no processo de produção científica, indicando os possíveis relacionamentos entre pesquisadores, instituições diferentes, de países, entre outros. Neste sentido, por meio da utilização de gráficos é recomendável a representação gráfica das redes de colaboração científicas, através dos métodos de análise de redes (GINGRAS, 2016).

Para compreender a análise de redes sociais, alguns conceitos consolidados por Silva (2018, p.18-19) são de importante destaque:

a) Atores - O nó (ou ator) é uma entidade social, que pode ser um único indivíduo, uma corporação, ou um conjunto de unidades sociais, varia de acordo com o que se propõe a analisar. Ou seja, ele permite vários níveis de agregação, o que viabiliza uma adaptação ao problema estudado.

b) Vínculo relacional - estabelece a relação entre pares de nós.

c) Díade (*dyad*) - um par de atores e suas ligações.

d) Tríade (*triad*) - é um subgrafo constituído de três de atores e suas ligações.

e) Subgrupo - é um subconjunto de atores e suas possíveis ligações.

f) Grupo - é o conjunto de todos os atores em que as ligações serão mensuradas.

g) Relação - conjunto de laços relacionais entre membros de um grupo.

h) Grafos - é forma de visualização de dados, que é composto pela relação entre nós e arestas, no caso, as arestas são as linhas que ligam um nó a outro.

As redes sociais também possuem algumas características descritas por medidas ou indicadores, que permitem sua compreensão de mais fácil maneira. Neste sentido, apresenta-se as principais características das redes conforme (MARTELETO; TOMAÉL, 2005, p. 91-92):

a) Coesão social: Pressupõe uma rede densa com a presença de ligações fortes entre um grupo de atores.

b) Densidade da rede: Mede a quantidade de ligações em uma rede, quanto maior o número de ligações entre os atores, mais densa é considerada a rede. É uma

das medidas mais amplas da estrutura de rede social, porque explicita o número de ligações existentes quando a rede é mapeada. Uma rede densa tem considerável comunicação direta entre todos os membros.

c) Transitividade: Mede o grau de flexibilidade e cooperação de uma rede, possibilitando identificar o fluxo da informação entre três atores sem ligações recíprocas.

d) Distância Geodésica: É entendida como a menor distância entre dois pontos, em ARS refere-se ao número de ligações - graus - entre um ator e outro, calculado pelo caminho mais curto, e tem por finalidade otimizar o percurso.

e) Fluxo Máximo: Revela o quanto dois atores estão totalmente conectados na rede. Os atores próximos são os que possibilitam os prováveis e diferentes caminhos para o fluxo de informação de um ator. O propósito do fluxo máximo é levantar os possíveis caminhos de distribuição da informação entre atores, identificando pontos de estrangulamento, isto é, números de caminhos em que a informação não alcança um determinado ator.

f) Centro e Periferia: O centro constitui-se em um grupo coeso de atores, com alta densidade de inter-relacionamentos, o que significa que eles estão fortemente relacionados. E em uma situação inversa à do centro encontra-se a periferia, na qual os atores têm poucos contatos entre si, estando ligados mais aos membros do centro.

Sabe-se que cada análise bibliométrica, cientométrica, e de rede social tem suas especificidades, sendo necessário definir o que se está buscando, o que se está querendo medir e analisar, bem como os resultados que se almeja alcançar a partir dos objetivos definidos. Quanto mais parâmetros de análise for considerado, mais completa será a análise haja vista que não há uma definição pré-definida para tais estudos.

Neste sentido, passa-se a analisar sob o aspecto do software para auxiliar as análises bibliométricas, cientométricas e de rede social.

## 2.3 SOFTWARE PARA AUXÍLIO NAS ANÁLISES

De acordo com Ferreira (2018, p. 13), “a necessidade de medir como forma de comprovação se faz presente na Ciência em muitas áreas do conhecimento e tornou-se prática constante.” A utilização de software e bases de dados revolucionaram a forma como se faz ciência (HEY; TANSLEY; TOLLE, 2011).

Sabe-se que no mercado de software há várias ferramentas voltadas para o auxílio e desenvolvimento de análises bibliométricas e cientométricas. Verifica-se ainda que os ditos mais completos carecem de investimento financeiros para o seu uso, inclusive as próprias bases de dados, como Scopus e Web of Science, também disponibilizam este serviço de maneira paga.

Moreira, Guimarães e Tsunoda (2020) realizaram em 2019 uma pesquisa de comparação entre softwares para apoiar no processo de escolha das ferramentas adequadas para realização de pesquisas bibliométricas. Diante de uma lista 16 ferramentas para esta finalidade (Quadro 2), foram selecionadas quatro ferramentas com base em critérios de exclusão predefinidos pelos autores (Quadro 3), e destas exploraram as funcionalidades em cada delas concluindo que “Biblioshiny apresenta o maior número de possibilidades em análises, embora apresente limitações nos relatórios visuais” (MOREIRA; GUIMARÃES; TSUNODA, 2020, p. 140).

Quadro 2: Lista das 16 ferramentas analisadas por de Moreira, Guimarães e Tsunoda (2020).

Ferramenta	Gratuita	Última Versão	Qualidade da documentação	Interface gráfica?
Bibliometrix/Biblioshiny	Sim	14/03/2019	Alta	Parcial
VOSViewer	Sim	03/04/2019	Alta	Sim
Publish or Perish	Sim	17/04/2019	Alta	Sim
CiteSpace	Sim	31/08/2018	Média	Sim
Metaknowledge	Sim	21/01/2019	Média	Não
Bibexcel	Sim	2017	Baixa	Sim
Network Workbench Tool	Sim	15/09/2009	Baixa	Sim
Science of Science (Sci <sup>2</sup> ) Tool	Sim	31/01/2018	Baixa	Sim
InCites	Não	N/A	Baixa	Sim
SciMAT	Sim	12/07/2016	Média	Sim
IN-SPIRE™	Não	01/02/2019	Média	Sim
VantagePoint	Não	05/02/2019	Média	Sim
SciVal	Não	26/03/2019	Média	Sim
SCImago	Sim	N/A	Média	Sim

Fonte: Moreira, Guimarães e Tsunoda (2020, p. 146).

Quadro 3: Comparativo entre as 4 ferramentas selecionadas na pesquisa de Moreira, Guimarães e Tsunoda (2020).

			Biblioshiny	VOSviewer	Publish or Perish	CiteSpace
Análises básicas	Autores	Autores mais relevantes	X	X	X	X
		Produção ao longo dos anos	X			X
		Lei de Lotka	X			
		Índices de impacto (H-Index, G-Index, M-Index)	X		X	
		Total de citações	X	X	X	X
		Afiliações mais relevantes	X	X		X
		País do autor	X			
		Países mais citados	X	X		
		Produção científica por país	X	X		X
	Fontes	Fontes mais relevantes	X	X		X
Fontes mais citadas		X	X			
Lei de Bradford		X				

		Índices de impacto (H-Index, G-Index, M-Index)	X			
		Total de citações	X	X		
		Source Dynamics	X			
	Documentos	Documentos mais citados	X	X	X	
		Referências mais citadas	X	X		X
		Palavras mais citadas	X	X		
		Keyword Plus	X	X		X
		Word Dynamics	X			
Citação	WordCloud	X	X		X	
	TreeMap	X				
Visualização	Coautoria	Autores	X	X		
		Organizações	X	X		X
		Países	X	X		X
	Coocorrência	Todas as palavras-chave	X	X		X
		Palavras-chave do autor	X	X		X
		Palavras-chave Plus (WoS)	X	X		X
	Citação	Documentos	X	X		X
		Fontes	X	X		X
		Autores	X	X		X
		Organizações	X	X		
		Países	X	X		
	Pares bibliográficos	Documentos	X	X		
		Fontes	X	X		
		Autores	X	X		
		Organizações	X	X		
		Países	X	X		
	Cocitação	Referências citadas	X	X		X
		Fontes citadas	X	X		X
		Autores citados	X	X		X

Fonte: Moreira, Guimarães e Tsunoda (2020, p. 152).

Moral-Muñoz *et al.* (2020) por meio de uma pesquisa de revisão atualizada de ferramentas de software para conduzir análise bibliométrica e cientométrica concluíram que Biblioshiny apresenta uma variedade de técnicas implementadas com uma variedade de análises diferentes, bem como proporciona facilidade de uso de sua interface, e por ser recente incorporou grande parte das análises que constavam em ferramentas anteriores, sendo excelente software para profissionais que atuam utilizando tais análises.

### 2.3.1 RStudio, Bibliometrix, Biblioshiny

Considera-se R como uma linguagem e ambiente para computação estatística e produção de gráficos. O RStudio é um software livre de ambiente de desenvolvimento R e faz parte de um dos projetos com filosofia GNU, ou seja, qualquer pessoa pode ter acesso a seu código-fonte, modificá-lo ou adaptá-lo conforme demanda (Resnizky, 2015).


De acordo com Resnizky (2015) e RStudio (2021), nos dias atuais o software RStudio está conquistando o mercado em face aos softwares comerciais, e tem como coadjuvante a linguagem Python, sendo esta a linguagem mais usada para estatística e ciência de dados. A linguagem R tem como atributos: ser orientada a objetos; poder ser compartilhado e receber melhoramentos no código-fonte, contribuindo para a criação de pacotes/bibliotecas para fins variados; não necessita ser compilado; além de ser facilmente extensível com o acoplamento de pacotes.

O Shiny é um dos vários pacotes disponíveis pelo RStudio, que admite uma interface com boa usabilidade da linguagem R com um navegador da web, sendo possível desenvolver um aplicativo web que tem como entradas em R de modelos estatísticos sendo exibidas saídas de visualização gráfica, o que “o torna incrivelmente fácil construir aplicativos da web interativos com R” (RESNIZKY, 2015, p.51).

Bibliometrix é considerada uma ferramenta de código aberto com a finalidade de ser aplicada em pesquisas quantitativas em cienciometria e bibliometria, a qual contempla todos os principais métodos bibliométricos de análise, fornecendo várias rotinas para importar dados bibliográficos compreendendo as bases de dados SCOPUS, Web of Science, PubMed, Digital Science Dimensions e bancos de dados Cochrane, conseguindo realizar análises bibliométricas e construindo matrizes de dados para citação, acoplamento, análise de colaboração científica e análise de co-palavras (ARIA; CUCCURULLO, 2017; ARIA; CUCCURULLO, 2021a). De acordo com Moral-Muñoz *et al.* (2020, p.12), Bibliometrix “é uma biblioteca poderosa que pode realizar análises bibliométricas e cienciométricas completas.”

Foi com a junção da facilidade do pacote Shiny com as aplicações do Bibliometrix que surgiu o Biblioshiny, criado em 2018, o qual é um aplicativo que apresenta uma interface para que as informações se tornem muito fácil de usar, mesmo para as pessoas que não têm habilidades em programação de computadores. Tem como finalidade auxiliar pesquisadores no uso fácil dos principais recursos do Bibliometrix, tais como: Importação de dados e conversão para coleta de quadro de dados; Coleta de dados usando Dimensions, PubMed e coleta de APIs Scopus; Filtragem de dados; Gráficos e organização de dados para três métricas de nível diferentes: Fontes; Autores; Documentos. Possibilita também a análise sob a visão de três estruturas de conhecimento (estruturas K): Estrutura Conceitual; Estrutura Intelectual; Estrutura Social (ARIA; CUCCURULLO, 2021b). Na Figura 6, segue o fluxo de trabalho proposto para o Bibliometrix:

Figura 6: Bibliometrix e o fluxo de trabalho de mapeamento científico recomendado.



Fonte: Aria e Cuccurullo (2017, p. 963).

Os autores e desenvolvedores do Bibliometrix, Aria e Cuccurullo (2021a), afirmam que inclui todos os principais métodos de análise bibliométrica, sendo utilizado “especialmente para mapeamento científico e não para medir ciência, cientistas ou produtividade científica”, sendo necessário realizar outros procedimentos de análises empregando outros métodos. Apresenta-se no Quadro 4, de maneira resumida o conjunto de análises disponíveis no Biblioshiny.

Quadro 4: Conjunto de análises disponíveis no Biblioshiny Autores.

<b>Autores</b>	Autores: Autores mais relevantes (Produção); Produção ao longo dos anos; Lei de Lotka; Impacto (H-Index; G-Index; M-Index; Total de citações); Afiliação: Afiliações mais relevantes; País: País do autor; Países mais citados; Produção científica por país.
<b>Fontes</b>	Fontes mais relevantes (produção); Fontes mais citadas; Lei de Bradford; Impacto (H-Index; G-Index; M-Index; Total de citações); <i>Source Dynamics</i>
<b>Documentos</b>	Documentos: Documentos mais citados (global) Documentos mais citados (local); Referências: Referências mais citadas; <i>Reference Spectroscopy</i> ; Palavras: Palavras mais citadas (Palavras-chave (autor); <i>Keyword Plus</i> ; Título; Resumo); <i>Word Dynamics</i> ; <i>WordCloud</i> ; <i>TreeMap</i>

Fonte: Moreira, Guimarães e Tsunoda (2020, p. 147).

Abordando de maneira técnica, acredita-se ser interessante, do ponto de vista técnico, elencar informações sobre Bibliometrix, contemplando as principais funções (Tabela 2), relação tipos de dados por campo (Tabela 3) e lista de elementos que um objeto pode assumir (Tabela 4).

Concordando com Araújo (2017, p.18), observa-se que no histórico da pesquisa acadêmica até então não houve tantos softwares e bases de dados tão disponíveis como se tem nos dias atuais, “a opção por se utilizar esses recursos se mostra relevante e desafiadora, uma vez que o campo está em desenvolvimento, exigindo decisões de pesquisa nem sempre claras.”

Tabela 2: Principais funções da bibliometrix associadas a análise bibliométrica e cientométrica.

Fluxo de trabalho assistido pelo software	Função bibliometrix	Descrição	Saída
Carregamento e conversão de dados	readFiles ()	Carrega uma sequência de arquivos de exportação Scopus e Clarivate Analytics WoS para R	Quadro de dados bibliográficos
	Convert2df ()	Cria um quadro de dados bibliográficos	
	retrievalByAuthorID ()	Usa a pesquisa da API Scopus para obter informações em relação a documentos em um conjunto de autores usando Scopus ID	
	biblioAnalysis()	Retorna um objeto de classe bibliometrix	
Análise bibliométrica descritiva	Summary() and plot()	Resume os principais resultados da análise bibliométrica	Tabelas de resultados
	citations()	Identifica as referências ou autores mais citados	
	localCitations()	Identifica os autores locais mais citados	
	dominance()	Calcula a classificação de dominância dos autores	
	index()	Mede a produtividade e o impacto da citação de um acadêmico	
	lotka()	Estima os coeficientes da lei de Lotka para a produtividade científica	
	keywordGrowth()	Calcula ocorrências cumulativas anuais das principais palavras-chave / termos	
Criação de matriz de documento x atributo	keywordAssociation()	Associa palavras-chave de autores a palavras-chave mais	Matriz Documento x Atributo
	metaTagExtraction ()	Extrai outras tags de campo, diferentes da WoS / Scopus codificar padrão	
	termExtraction ()	Extrai e extrai termos de campos textuais (resumo, título, palavras-chave do autor e outros) de um quadro de dados bibliográficos	
Normalização	cocMatrix ()	Calcula uma matriz Documento x Atributo	Matriz de similaridade
	normalizeSimilarity ()	Calcula a força de associação, índice de inclusão, coeficiente de Jaccard e coeficiente de similaridade de Salton entre objetos de uma rede bibliográfica	
Dados Redução	conceptualStructure ()	Cria um mapa da estrutura conceitual de um campo científico usando MCA e Clustering	Matriz de ocorrência de palavras, MCA e resultados de agrupamento
Matriz de rede criação	biblioNetwork ()	Calcula o bibliográfico usado com mais frequência redes de acoplamento, co-citação, colaboração e co-ocorrência	Matriz de rede e matriz de rede histórica
	histNetwork ()	Cria uma rede histórica de co-citação de um quadro de dados bibliográficos.	
	networkPlot ()	Traça uma rede bibliográfica usando a biblioteca R interna ou o software VOSviewer	
Mapeamento	histPlot ()	Traça uma rede histórica de co-citação	Gráfico de rede, formato de Pajek de rede para VOSviewer, Historiograph e mapa semântico
	conceptualStructure ()	Traça o mapa da estrutura conceitual de um campo científico usando MCA e Clustering	

Fonte: Aria e Cuccurullo (2017, p. 964, tradução nossa).

Tabela 3: Estrutura da relação campo por tipo de dados do Bibliometrix.

Tag de campo	Classe	Descrição
UT	CHARACTER	Identificador Único de Artigo
AU	CHARACTER	Autores
TI	CHARACTER	Título do documento
SO	CHARACTER	Nome da publicação (ou fonte)
JI	CHARACTER	Abreviatura da fonte ISO
DT	CHARACTER	tipo de documento
DE	CHARACTER	Palavras-chave dos autores
ID	CHARACTER	Palavras-chave associadas ao banco de dados WoS ou Scopus
AB	LARGE CHARACTER	Resumo
C1	CHARACTER	Endereço do Autor
RP	CHARACTER	Endereço de reimpressão
CR	LARGE CHARACTER	Referências citadas
TC	NUMERIC	Times Cited
PY	NUMERIC	Ano
SC	CHARACTER	Categoria Assunto
DB	CHARACTER	Banco de dados bibliográficos

Fonte: Aria e Cuccurullo (2017, p. 965, tradução nossa).

Tabela 4: Lista de elementos de um objeto Bibliometrix e sua descrição.

Elemento	Descrição
Articles	Número total de documentos
Authors	Distribuição de frequência dos autores
AuthorsFrac	Distribuição de frequência dos autores (fracionada)
FirstAuthors	Primeiro autor de cada documento
nAUpperPaper	Número de autores por documento
Appearances	Número de aparições do autor
nAuthors	Número total de autores
AuMultiAuthoredArt	Número de autores de artigos com vários autores
Years	Ano de publicação de cada documento
FirstAffiliations	Afiliação do primeiro autor para cada documento
Affiliations	Distribuição de frequência de afiliações (de todos os co-autores para cada documento)
Aff_frac	Distribuição de frequência fracionada de afiliações (de todos os co-autores para cada artigo)
CO	País de filiação do primeiro autor
Countries	Distribuição de frequência dos países da afiliação
TotalCitation	Número de vezes que cada documento foi citado
TCperYear	Número médio anual de vezes que cada documento foi citado
Sources	Distribuição de frequência das fontes (periódicos, livros, outros)
DE	Distribuição de frequência das palavras-chave dos autores
ID	Distribuição de frequência de palavras-chave associadas ao documento pelas bases de dados Clarivate Analytics Web of Science e Scopus

Fonte: Aria e Cuccurullo (2017, p. 965, tradução nossa).

### 3 MATERIAL E MÉTODOS

Neste capítulo, apresenta-se o material e os métodos utilizados para a elaboração desta pesquisa.


Em relação ao aspecto da abordagem metodológica da pesquisa, esta caracterizou-se como sendo de métodos mistos. Pesquisas que utilizam-se da aplicação de métodos mistos tem fornecido uma melhor compreensão sobre os problemas de pesquisa, sendo realizadas em vários campos, inclusive nas Ciências da Saúde, por meio das quais tem apresentando grande potencial nos resultados das análises (PINHEIRO; SANTOS; KANTORSKI, 2019; MOLINA-AZORIN, 2012; LORENZINI, 2017).

Quanto aos objetivos esta pesquisa classifica-se como exploratória e descritiva. De acordo Cervo, Bervian e Da Silva (2007), a pesquisa exploratória tem por objetivo conhecer de maneira mais profunda sobre uma situação em questão. Neste sentido, devido ao objetivo de conhecer sobre a produção científica do aprendizado de máquina em cuidados intensivos, coube para esta pesquisa a característica de ser exploratória. Também de caráter descritivo, a pesquisa adota procedimentos de análise cientométrica para coletar dados e analisar informações, bem como desenvolver indicadores que evidenciem as características e a estrutura da temática em questão.

Quanto aos meios de investigação, assume-se a forma predominante de análise bibliométrica e cientométrica.

De maneira resumida, no Quadro 5, a metodologia ficou assim definida:

Quadro 5: Esquema do percurso metodológico.



Fonte: Elaborado pela autora (2021).

### 3.1 COLETA DE DADOS

#### 3.1.1 Escolha da base de dados

Para Gingras (2016, p. 23) “a análise mais ou menos sofisticada das diversas fontes na verdade depende apenas de sua disponibilidade sob a forma de banco de dados.” A facilidade com que as bases de dados online se apresentam possibilitam análises mais elaboradas, sendo possível ser realizadas considerando a sua disponibilidade.

Conforme Archambault *et al.* (2009, p. 1320) por mais de 40 anos, o *Institute for Scientific Information* (ISI), agora parte da *Thomson Reuters*, foi responsável por produzir e cuidar das únicas bases de dados bibliográficas, a partir das quais podiam compilar indicadores bibliométricos em grande escala, agora reagrupados sob a *Web of Science* (WoS). Em 2004 ocorreu o aparecimento da base de dados Scopus, cuja empresa responsável é a Elsevier, na qual as publicações de pesquisas multiplicaram-se até os dias atuais.

Por meio do estudo de Archambault *et al.* (2009, p. 1320) ao comparar a base de dados WoS e Scopus, concluiu que há “evidências de que os indicadores de produção científica e citações em nível de país são estáveis e amplamente independentes do banco de dados” (tradução nossa). Tal afirmação pode ser comprovada através dos estudos Vera-Baceta, Thelwall e Kousha (2019); Aksnes e Sivertsen (2019); Pech e Delgado (2020) ao comparar características das bases de dados Web of Science e Scopus, concluíram que as coberturas são praticamente as mesmas.

Neste sentido, considerando que esta pesquisa se desenvolve baseada em publicações em banco de dados, após a realização de leituras para verificar quais os critérios e motivações para escolher a banco de dados de apoio a este estudo, selecionou-se a base de dados Scopus da Elsevier.

O acesso a base de dados Scopus deu-se via Rede Café da Universidade Federal do Estado do Rio de Janeiro – UNIRIO pelo Portal de Periódico da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), sendo direcionado para a página inicial de pesquisa da base de dados Scopus.

### 3.1.2 String de busca e definição do *corpus* de análise

A busca foi realizada no dia 07 de janeiro de 2021, na base de dados Scopus, com os termos "MACHINE LEARNING" AND ("INTENSIVE CARE" OR "CRITICAL CARE"), pesquisados dentro de títulos de artigos, resumos, palavras-chave (*article title, abstract, keywords*). Ressalta-se que, anteriormente a esta data, foram realizados testes piloto para adequação e validação da string de busca.


As palavras *MACHINE LEARNING* e *INTENSIVE CARE*, foram previamente consultadas e validadas no vocabulário controlado da área da Saúde DeCS e MeSH, como forma de verificar se tais palavras eram as adequadas para descrever o que se pretendia pesquisar como objeto. Constatou-se a necessidade de inclusão da palavra-chave *CRITICAL CARE*, termo também usado como sinônimo para cuidados intensivos.

O resultado da busca na base Scopus retornou 886 documentos, sendo expresso de forma detalhada as quantidades nos parênteses: Artigo (511); Artigo de Conferência (193); Artigos de Revisão (72); Editorial (51); Nota (23); Carta (18); Revisão de Conferência (8); Capítulo de livro (6); Artigo de Dados (2); Errata (1); Pesquisa Curta (1). Verificando-se assim que as publicações advêm de diversos tipos de documentos.

Como critérios de refinamento do resultado, utilizou-se os filtros de busca limitado apenas aos documentos do tipo artigo e artigos de revisão considerando a padronização na estrutura de tais documentos. Quanto ao período, ficou limitado a ser menor que 2021, ou seja, compreendeu de 2000 (ano do primeiro registro encontrado na base de dados Scopus) até 2020, ponderando que a base do ano de 2021 ainda está em seu início. Em relação ao tipo de acesso e à área do estudo, não houve limitação ou exclusão. Quanto a fase da publicação foi considerada os documentos em seu estado final e os artigos em processamento, considerando que em sua maioria (22) são do ano de 2020. Foi incluído todos os autores, fontes (periódicos), palavras-chave, afiliações, patrocinadores de financiamento, país/território, tipo da fonte e língua, ou seja, para esses campos não houve limitação ou exclusão para estas características. Neste sentido, a string final da busca na Scopus ficou assim definida: TITLE-ABS-KEY ("MACHINE LEARNING" AND ("INTENSIVE CARE" OR "CRITICAL CARE")) AND PUBYEAR <2021 AND (LIMIT-TO (DOCTYPE, "ar") OR LIMIT-TO (DOCTYPE, "re"))

Retornando 568 artigos que serviram de *corpus* de análise para esta pesquisa, sendo 497 artigos e 71 artigos de revisão. A Figura 7 demonstra a quantidade de documentos obtidos e a string de busca da Scopus.

Figura 7: Resultado da busca e string de busca obtidos através da base de dados Scopus.




The screenshot shows the Scopus search results page. At the top left is the Scopus logo. Below it, the text "568 document results" is displayed in a large font. Underneath, the search string is shown: "TITLE-ABS-KEY ( "MACHINE LEARNING" AND ( "INTENSIVE CARE" OR "CRITICAL CARE" ) ) AND PUBYEAR < 2021 AND ( LIMIT- TO ( DOCTYPE , "ar" ) OR LIMIT-TO ( DOCTYPE , "re" ) )".

Fonte: Dados da pesquisa (2021).

Em seguida, foi realizada a leitura do resumo para verificar se a seleção/busca realizada era de fato inerente ao assunto. Após tal verificação, foi realizada a exportação dos 568 documentos em formato \*.CSV, com todos os campos/especificações de informação (Figura 8).

Figura 8: Tela de exportação em \*.CSV dos documentos obtidos.



The screenshot shows the "Export document settings" dialog box. It indicates that 566 documents have been chosen for export. The user has selected "CSV" as the export method. The "What information do you want to export?" section is expanded, showing a list of fields with checkboxes. The following table summarizes the fields shown in the screenshot:

Citation information	Bibliographical information	Abstract & keywords	Funding details	Other information
<input checked="" type="checkbox"/> Author(s)	<input checked="" type="checkbox"/> Affiliations	<input checked="" type="checkbox"/> Abstract	<input checked="" type="checkbox"/> Number	<input checked="" type="checkbox"/> Tradenames & manufacturers
<input checked="" type="checkbox"/> Author(s) ID	<input checked="" type="checkbox"/> Serial identifiers (e.g. ISSN)	<input checked="" type="checkbox"/> Author keywords	<input checked="" type="checkbox"/> Acronym	<input checked="" type="checkbox"/> Accession numbers & chemicals
<input checked="" type="checkbox"/> Document title	<input checked="" type="checkbox"/> PubMed ID	<input checked="" type="checkbox"/> Index keywords	<input checked="" type="checkbox"/> Sponsor	<input checked="" type="checkbox"/> Conference information
<input checked="" type="checkbox"/> Year	<input checked="" type="checkbox"/> Publisher		<input checked="" type="checkbox"/> Funding text	<input checked="" type="checkbox"/> Include references
<input checked="" type="checkbox"/> EID	<input checked="" type="checkbox"/> Editor(s)			
<input checked="" type="checkbox"/> Source title	<input checked="" type="checkbox"/> Language of original document			
<input checked="" type="checkbox"/> volume, issue, pages	<input checked="" type="checkbox"/> Correspondence address			
<input checked="" type="checkbox"/> Citation count	<input checked="" type="checkbox"/> Abbreviated source title			
<input checked="" type="checkbox"/> Source & document type				
<input checked="" type="checkbox"/> Publication Stage				
<input checked="" type="checkbox"/> DOI				
<input checked="" type="checkbox"/> Open Access				

Fonte: Dados da pesquisa (2021).

Portanto, constituiu o universo desta pesquisa os documentos disponíveis na base de dados em que nas palavras-chave, título ou resumo constavam os termos

relacionados a aprendizado de máquina e cuidados intensivos, definindo-se como amostra os artigos ou artigos de revisão publicados até o ano 2020, totalizando 568 documentos.

Baseado nos documentos obtidos (artigos), foi realizada uma pesquisa bibliográfica que objetivou evidenciar como a inteligência artificial / aprendizado de máquina tem contribuído com a saúde, em especial nos cuidados intensivos, evidenciando as principais patologias em cuidados intensivos que o aprendizado de máquina tenta resolver. Considerando o volume de documentos, optou-se por adotar os artigos dos periódicos identificados como os mais (Gráfico 5), bem como os artigos mais recentes e adequados ao cerne desta pesquisa.

### 3.2 ANÁLISE DOS DADOS

Em relação a preparação do ambiente para análise dos dados, fez-se o download e instalação do Software R (versão 4.0.3 – Windows 32/64 bits). Em seguida, download e instalação do RStudio (versão 1.3.1093 – Windows). Após a instalação de tais softwares, os mesmos foram iniciados, e para acessar a interface web, proposto em linguagem R para servir de apoio na análise bibliométrica e cientométrica, digitou-se os comandos no console do software RStudio: `library(bibliometrix)`, e em seguida, `biblioshiny()`, para que a interface web Biblioshiny fosse acionada. Após iniciado, o uso do Biblioshiny deu-se por meio do navegador definido como padrão. O arquivo de dados salvo em \*.CSV foi recuperado e carregado para que os dados fossem analisados.

A análise dos dados e interpretação dos resultados foram realizados à luz das teorias que fundamentam a pesquisa de análise bibliométrica e cientométrica, descritas no item 2.2, tendo como objeto o uso do aprendizado de máquina em cuidados intensivos.

Visando a classificação da atividade da produção científica acerca do objeto, com o auxílio da interface web Biblioshiny, foram gerados quadros, tabelas, gráficos, mapas, e com base nestes, análises e interpretações foram realizadas nos parâmetros de comportamentos, analisados com o uso da estatística descritiva. Ao considerar o viés descritivo e exploratório, buscou-se realizar análises que permitem aprender diversos aspectos do objeto como campo científico.

Para facilitar a compreensão das dimensões em análise, optou-se por categorizar em função do propósito pretendido. Os indicadores apresentam um panorama descritivo, trazendo gráficos, quadros, tabelas e classificações, bem como a representação por meio de redes apresentando afinidades entre diversos construtos acerca do objeto.

Esquematiza-se no Quadro 6, as categorias e indicadores contemplados por esta pesquisa.

Quadro 6: Categorias e indicadores contemplados por esta pesquisa.


<b>Coleção de dados recuperados</b>	<ul style="list-style-type: none"> <li>- Principais informações sobre a coleção dos dados recuperados</li> <li>- Produção científica anual</li> <li>- Gráfico dos três campos (autores, palavras-chaves e periódicos)</li> </ul>
<b>Fontes</b>	<ul style="list-style-type: none"> <li>- Lei de Bradford e fontes mais relevantes</li> <li>- Fontes mais citadas localmente</li> <li>- Impacto (<i>H-Index</i>)</li> <li>- Dinâmica da Fonte</li> </ul>
<b>Autores</b>	<ul style="list-style-type: none"> <li>- Lei de Lotka e os autores mais relevantes</li> <li>- Autores mais citados localmente</li> <li>- Produção dos autores ao longo dos anos</li> <li>- Impacto (<i>H-Index</i>)</li> <li>- País do autor</li> </ul>
<b>Afiliações e países</b>	<ul style="list-style-type: none"> <li>- Afiliações mais relevantes</li> <li>- País dos autores</li> </ul>
<b>Documentos</b>	<ul style="list-style-type: none"> <li>- Documentos mais citados globalmente</li> <li>- Média de citações por documento ano</li> </ul>
<b>Palavras-Chave</b>	<ul style="list-style-type: none"> <li>- Palavras mais frequentes (Palavras-chave do autor; Palavras-chave <i>Plus</i>; Título; Resumo)</li> <li>- Nuvem de palavras</li> <li>- TreeMap</li> <li>- Dinâmica de palavra</li> <li>- Tópicos de tendência</li> </ul>
<b>Estrutura Conceitual</b>	<ul style="list-style-type: none"> <li>- Rede de Coocorrência</li> <li>- Mapa Temático</li> <li>- Evolução Temática</li> <li>- Análise Fatorial</li> </ul>
<b>Estrutura Intelectual</b>	<ul style="list-style-type: none"> <li>- Rede de Cocitação</li> <li>- Historiografo</li> </ul>
<b>Estrutura Social</b>	<ul style="list-style-type: none"> <li>- Rede de Colaboração</li> <li>- Mapa do mundo de colaboração</li> </ul>

Fonte: Elaborado pela autora (2021).

Nas análises da estrutura conceitual, intelectual e social, nos mapas os agrupamentos estão identificados por cores distintas e os nós estão representados por retângulos, cuja dimensão (tamanho) refere-se ao número de ocorrências. Neste sentido, quanto maior o tamanho, maior o número de ocorrência.

A Figura 9 contempla o desenho metodológico desta pesquisa.

Figura 9: Desenho metodológico da pesquisa.



Fonte: Elaborado pela autora (2021).

### 3.3 ASPECTOS ÉTICOS DA PESQUISA

Em relação às questões éticas da pesquisa, considerou-se a Resolução Nº Resolução Nº 510, de 7 de abril de 2016 do Conselho Nacional de Saúde (2016) do Ministério da Saúde, na qual em seu artigo 1º regula:

Parágrafo Único. Não serão registradas nem avaliadas pelo sistema CEP/CONEP:

V - Pesquisa com bancos de dados, cujas informações são agregadas, sem possibilidade de identificação individual; e

VI - Pesquisa realizada exclusivamente com textos científicos para revisão da literatura científica;

Portanto, sendo este estudo dispensado de apreciação ética em pesquisa pelo Conselho de Ética em Pesquisa (CEP).

Considerando que se apresentou de maneira detalhada sobre as etapas percorridas para coleta e análise dos dados, bem como os aspectos éticos adotados pela pesquisa, a seguir apresenta-se os resultados e discussão.

## 4 RESULTADOS E DISCUSSÃO

Após a coleta dos dados, identificação e estruturação dos mesmos, procedimentos esses descritos no Capítulo 3, iniciou-se a fase de apresentação dos resultados e discussão. Este capítulo apresenta os resultados obtidos no decorrer desta pesquisa a partir do *corpus* de análise sobre o uso do aprendizado de máquina em cuidados intensivos, cabendo neste momento analisá-los e interpretá-los. Assim, recorreu-se ao referencial teórico para o estabelecimento das categorias de análise e dos relacionamentos entre os dados obtidos.

### 4.1 COLEÇÃO DE DADOS RECUPERADOS

Ter uma visão geral do *corpus* recuperado tem sua importância ao obter um panorama que pode ser visualizado e compreendido de maneira rápida. Os 568 documentos recuperados, e aqui analisados, encontram-se elencados por ordem decrescente de ano no Apêndice A.

O Quadro 7 apresenta dados resumidos do resultado da busca na base de dados Scopus. Verifica-se que o período recuperado pela busca compreende dos anos 2000 até 2020. Foram encontrados 568 documentos, dentre os quais 497 são classificados como sendo do tipo artigos e 71 são artigos de revisão. Tais documentos estão distribuídos em 250 fontes (periódicos). A média de citações por documento ficou em 12,32. E a quantidade de referências mencionadas totalizou 22.456. Ao todo foram especificadas 1.249 palavras-chave pelos autores, e as palavras-chave mais encontradas dos documentos totalizaram 3.910.

Sobre os autores, a coleção selecionada contempla 3.098 pesquisadores, considerando que destes 11 documentos resultam de autoria única, sendo os outros 3.087 documentos com autorias múltiplas, ficando perceptível a colaboração entre os autores. A média de autores por documento ficou em 5,45. O índice de colaboração resultou em 5,54.

Quadro 7: Principais informações resumidas sobre a coleção de documentos recuperados.

<b>PRINCIPAIS INFORMAÇÕES SOBRE OS DADOS RECUPERADOS</b>	
Intervalo de tempo	2000 até 2020
Fontes (periódicos)	250
Documentos	568
Anos médios de publicação	3,12


Média de citações por documentos	12,32
Média de citações por ano por documento	2.519
Referências	22.456
<b>TIPOS DE DOCUMENTOS</b>	
Artigo	497
Artigos de revisão	71
<b>CONTEÚDO DO DOCUMENTO</b>	
Palavras-chave mais encontradas	3.910
Palavras-chave especificadas pelo autor	1.249
<b>AUTORES</b>	
Autores	3.098
Aparições do autor	3.721
Autores de documentos de autoria única	11
Autores de documentos de autoria múltipla	3.087
<b>COLABORAÇÃO DE AUTORES</b>	
Documentos de autoria única	11
Documentos por Autor	0,183
Autores por Documento	5,45
Coautores por documentos	6,55
Índice de Colaboração	5,54

Fonte: Dados da pesquisa (2021).

Apresenta-se no Gráfico 1, a visão geral do crescimento de abordagem do assunto distribuído por quantidade de artigos publicados por ano. Verifica-se que houve crescimento no decorrer dos anos, tendo como início o registro de 04 artigos no ano de 2000. Ao longo dos anos, o ápice de produção ocorreu em 2020 com 223 artigos, representado 39,26% de todo o período analisado. Constata-se ao realizar a leitura dos artigos dos anos de 2020 que tal explosão de publicações buscou investigar, principalmente, o uso do aprendizado de máquina em soluções de amparo ao paciente que necessitam de cuidados intensivos em relação a: identificação antecipada de sepse, previsão de mortalidade, COVID-19, cuidados intensivos neonatais, triagem e admissão em UTIs, resoluções para previsibilidade de lesão renal aguda, abordagens sobre Big Data com dados gerados pelas UTIs, dentre outros. É possível identificar que as publicações se intensificaram desde 2018, o que

corroborar para a importância desta pesquisa e do contexto aqui abordado. O detalhamento dos estudos encontra-se disponível no Quadro 16.

Gráfico 1: Evolução da quantidade de produção científica na Scopus.




Fonte: Dados da pesquisa (2021).

O idioma predominante foi o inglês, presente em 560 publicações (98,60%), seguido de 4 artigos (0,70%) disponíveis em espanhol e 4 artigos (0,70%) em alemão.

Em relação às áreas de estudo dos documentos recuperados, obteve-se o Gráfico 2, no qual observa-se que a área de Medicina é a que mais publica sobre o assunto concentrando 425 documentos. Seguida de Ciência da Computação com 125 documentos. Observou-se que há artigos que foram enquadrados na base de dados em mais de uma área de estudo, significando que o tema desperta interesse em várias áreas do conhecimento.

Gráfico 2: Áreas de estudos dos documentos recuperados.



Fonte: Dados da pesquisa (2021).



## 4.2 ANÁLISE DAS FONTES

De acordo com Toledo e Skalinski Junior (2012, p. 255) as fontes “são produções humanas, portanto, nas suas mais diversas modalidades, são registros das relações entre os homens em um dado momento histórico.”


Na visão de Brito e Lima (2015) os periódicos são considerados fontes de informação, os quais apresentam como características a regularidade, a veracidade dos textos, facilitando a leitura ao reunir vários textos e as apreciações de diversos autores sobre determinado tema. A função de um periódico científico é a divulgação da informação científica para a comunidade, “constituindo fórum privilegiado para anunciar resultados, submeter a produção ao julgamento feito pelos pares e receber contribuições” (BRITO; LIMA, 2015, p. 49).

Na classificação das fontes como categoria de análise, identificou-se os periódicos mais relevantes com a aplicação da Lei de Bradford, os mais citados localmente, posicionou-os por meio do impacto (H-Index), e apresentou-se a dinâmica das fontes no decorrer dos anos.

Utilizou-se da Lei de Bradford, que conforme já explanado no referencial teórico no item 2.2.1.2, para medir a relevância de periódicos em uma determinada área por meio da produção do maior número de artigos sobre determinado assunto, formando assim um núcleo de periódicos, de maneira suposta que os identificados possuem maior qualidade e/ou relevância para a área (GUEDES; BORSCHIVER, 2005).

A visualização gráfica da aplicação da Lei de Bradford sobre os dados da pesquisa é apresentada no Gráfico 4 e no Gráfico 5, através dos quais permitiu-se verificar a produtividade dos periódicos, encontrando o núcleo sobre o assunto aqui abordado, ou seja, as fontes mais relevantes com base em seu número de publicações em um conjunto de periódicos, verificou-se que 13 periódicos compõem o chamado núcleo mais devotado quando se pesquisa sobre o uso do aprendizado de máquina em cuidados intensivos indexadas na base de dados Scopus, identificando as principais fontes onde se pode buscar informações sobre o tema. Isso sugere que se deve ponderar sobretudo em relação ao número limitado de fontes a serem atualizadas sobre este tema.

Gráfico 4: Aplicação da Lei de Bradford



Fonte: Elaborado pela autora (2021). (Suporta zoom de alta qualidade).

O Quadro 8 consolida os dados e as informações que serviram de base para a elaboração do Gráfico 4. A dispersão é identificada a partir da definição do núcleo de periódicos que concentram sobre o tema, que é composto por poucos periódicos com número considerável de artigos de interesse.

Quadro 8: Consolidação dos dados aplicados Lei de Bradford.


Contagem de Periódicos	Contagem de Artigos	Nº de Periódicos	Nº de Artigos	Nº de Periódicos * Nº de Artigos	Zona	Multiplificador de Bradford	Nº de Periódicos	Quantidade de artigo encontrado efetivamente em cada zona
1	21	1	21	21	Zona 1 (Núcleo)	-	13	183 efetivo (esperado 189)
1	20	2	20	41				
1	16	3	16	57				
1	15	4	15	72				
5	13	9	65	137				
2	12	11	24	161				
2	11	13	22	183				
3	10	16	30	213	Zona 2	5,23	68	216 efetivo (399 acumulado efetivo) (378 acumulado esperado)
1	8	17	8	221				
1	7	18	7	228				
4	6	22	24	252				
1	5	23	5	257				
6	4	29	24	281				
14	3	43	42	323				
38	2	81	76	399				
169	1	250	169	568	Zona 3	2,48	169	169 efetivo (568 acumulado efetivo e esperado)

Fonte: Elaborado pela autora (2021).

Verifica-se no Quadro 8 a organização pela aplicação da Lei de Bradford, no qual é possível identificar os agrupamentos de artigos e periódicos por zonas. Foram definidas 3 zonas, a partir das quais pode-se determinar a quantidade de artigos esperado de 189,33 ( $568/3=189,33$ ). Pode-se observar que a Zona 1, a qual é considerada o núcleo, é a zona produtiva. As zonas 2 e 3, concentram mais periódicos, caracterizando que o número aumentou ao passo que a produtividade do periódico sobre o assunto diminui. Pode-se observar também que a quantidade de artigos efetivamente encontrada em cada zona ficou próximo da quantidade esperada que era de 189.

Após a aplicação da Lei de Bradford, obteve-se a identificação dos periódicos mais relevantes baseado na quantidade de documentos publicados sobre o assunto, ou seja, os que se encontravam na Zona 1 são os mais relevantes (devotados) sobre aprendizado de máquina em cuidados intensivos, os quais são apresentados no Gráfico 5.

Gráfico 5: Os 13 periódicos mais relevantes sobre o assunto.



Fonte: Dados da pesquisa (2021).

Foram identificadas 250 entradas de fontes (periódicos), e destes 13 são os mais relevantes. Verificou-se, através de cálculos estatísticos realizados, que este núcleo de periódicos concentrou 32,22% de toda a produção de artigos científicos recuperados. O periódico *Plos One* concentrou 21 artigos, representando uma

porcentagem de 3,70%, acompanhado de *Critical Care Medicine*, com 20 artigos, com 3,52%, e em seguida o periódico *Artificial Intelligence In Medicine*, com 16, e 2,82%.

O Gráfico 5 apresentou as fontes mais citadas globalmente (citações globais), isto significa dizer que do total de fontes (periódicos) citadas conta-se os selecionados “em todo o mundo.”

As fontes mais citadas localmente (baseado nas referências citadas no *corpus* analisado – coleção de documentos), ou seja, neste caso trata-se da inclusão de citações locais (são as citações recebidas por um artigo de referência "internamente à sua coleção).

No Quadro 9 é apresentado lista dos 10 periódicos com maiores quantidades de citações locais. Tal lista foi extraída com base na quantidade de referências catalogas no *corpus* da pesquisa. Do total de referências (6.624 referências localizadas na coleção de documentos) mencionados nos documentos, verificou-se que os artigos mais referenciados são os que advém do periódico *Critical Care Medicine* que possui 1000 citações de referências, fato este que o põe como alusão em termos de periódicos.

Quadro 9: Periódicos mais citados localmente (das listas de referências da coleção de documentos).

<b>Rank</b>	<b>Fontes</b>	<b>Quantidade de citações em artigos por periódico</b>
1	<i>Critical Care Medicine</i>	1000
2	<i>JAMA</i>	393
3	<i>Intensive Care Medicine</i>	380
4	<i>Critical Care</i>	292
5	<i>New England Journal of Medicine</i>	265
6	<i>Plos One</i>	221
7	<i>Lancet</i>	195
8	<i>Chest</i>	180
9	<i>Resuscitation</i>	159
10	<i>IEEE Trans Biomed Eng</i>	152

Fonte: Dados da pesquisa (2021).

O índice H (*H-Index*) é um indicador de desempenho, que apresenta um número dinâmico, e tem como finalidade indicar um balanceamento entre a produtividade (produção científica) e impacto de citação (contagem de citações) de publicações, neste caso dos periódicos (SCIMAGO, 2016). O índice H é um número dinâmico haja vista que ao longo dos anos o periódico pode continuar recebendo citações nos seus artigos. O Quadro 10 indica, por exemplo, que o periódico *Critical Care Medicine* apresenta índice h de 12, significa que, no conjunto de dados, 12

artigos foram citados pelo menos 12 vezes cada um. Identificando assim, a produtividade e a relevância do trabalho de um determinado periódico individualmente.


Quadro 10: Impacto (H-Index) dos 10 periódicos.

Rank	Fonte	H-index
1	<i>Critical Care Medicine</i>	12
2	<i>Artificial Intelligence in Medicine</i>	10
3	<i>Journal of Biomedical Informatics</i>	9
4	<i>Physiological Measurement</i>	9
5	<i>Plos One</i>	7
6	<i>International Journal of Medical Informatics</i>	7
7	<i>Critical Care</i>	6
8	<i>Journal of Clinical Monitoring and Computing</i>	6
9	<i>Computers in Biology and Medicine</i>	6
10	<i>BMC Medical Informatics and Decision Making</i>	5


Fonte: Dados da pesquisa (2021).

O Gráfico 6, da dinâmica da fonte, apresenta a evolução/crescimento de 2000 a 2020 das publicações dos dez principais periódicos, sendo visualizados os quantitativos de ocorrências por ano (6A) e por acumulado (6B).

Gráfico 6: Dinâmica da evolução de documentos por periódicos por ano (6A) e por acumulado (6B).



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).



Após identificado as classificações para a categoria de análise das fontes (periódicos), analisou-se a categoria de análise dos autores (pesquisadores).

#### 4.3 ANÁLISE DOS AUTORES

Conforme item 2.2.1.2 que descreve sobre a Lei de Lotka, verifica-se que o número de artigos publicados por autor aumenta à medida que a produção dos autores com mais publicações se torna menos frequente. Por meio da aplicação da Lei de Lotka foi possível obter a classificação dos autores mais produtivos sobre o assunto. No *corpus* desta pesquisa foram encontrados 3.098 autores que abordaram sobre aprendizado de máquina em cuidados intensivos. Em meio a estes, 11 autores de documentos de autoria única e 3.087 autores de artigos de autoria múltipla. O Quadro 11 apresenta os resultados da produtividade por autor (observado e esperado).

Quadro 11: Relação da frequência do número de documentos produzidos por número de autores.

Nº de documentos	Nº de autores	Nº de autores esperados	% observado	% esperado
1	2713	2697	87,57%	83,17%
2	269	248	8,68%	7,66%


3	57	110	1,84%	3,40%
4	29	62	0,94%	1,91%
5	16	40	0,52%	1,22%
6	5	28	0,16%	0,85%
7	3	20	0,10%	0,62%
8	3	16	0,10%	0,48%
9	2	12	0,06%	0,38%
10	1	10	0,03%	0,31%
Total	3.098	3.243	100%	100,00%

Fonte: Elaborado pela autora (2021).

Conforme o Quadro 11, esperava-se que 2.697 autores publicassem 1 artigo. Esperava-se que 248 autores publicassem 2 artigos, e foi identificado que 269 publicaram, estando acima do que era esperado de acordo com a Lei de Lotka. Esperava-se que 110 autores publicassem 3 artigos, mas apenas 57 autores realizaram a publicação de 3 documentos. Para os autores mais produtivos pela quantidade de documentos, pela Lei de Lotka esperava-se que aproximadamente 10 autores publicassem 10 artigos, no entanto apenas 1 autor chegou a publicar 10 artigos, sendo verificadas divergências em relação às quantidades observadas e esperadas.

O Gráfico 7, baseado nos dados do Quadro 11, apresenta aplicação da Lei de Lotka, obtendo-se a produtividade do autor.

Gráfico 7: Produtividade do autor pela Lei de Lotka.



Fonte: Elaborado pela autora (2021).

Aplicando-se a Lei do Elitismo de Price, de um total de 3.098 autores detectados, a raiz quadrada identifica a elite de autores, e para ser confirmada necessita-se verificar se a produção deles compreende em torno de 50%. A raiz quadrada de 3.098 resulta em 56 autores mais produtivos, identificados no Quadro 12. Verifica-se que autor que mais produziu foi CLERMONT G com 10 artigos, concentrando 1,76% da produção total. Analisou-se também que a produção dos autores, que produziram pelo menos 4 artigos, concentra 50,53% do total de artigos produzidos no período analisado que compreende de 2000 até 2020.

Quadro 12: Autores mais produtivos.

	<b>Autores</b>	<b>Artigos</b>	<b>Porcentagem %</b>				
1	CLERMONT G	10	1,76%	29	VISWESWARAN S	5	0,88%
2	DAS R	9	1,58%	30	ZHANG Z	5	0,88%
3	MEYFROIDT G	9	1,58%	31	AGARWAL S	4	0,70%
4	CELI LA	8	1,41%	32	BARTON C	4	0,70%
5	CLIFFORD GD	8	1,41%	33	CAMARGO CA	4	0,70%
6	JR	8	1,41%	34	CAREY KA	4	0,70%
7	LI Q	7	1,23%	35	CHA WC	4	0,70%
8	LI X	7	1,23%	36	CHEN L	4	0,70%
9	LI Y	7	1,23%	37	CHEN Y	4	0,70%
10	CALVERT J	6	1,06%	38	CLAASSEN J	4	0,70%
11	PARK S	6	1,06%	39	CLIFTON DA	4	0,70%
12	PINSKY MR	6	1,06%	40	DE TURCK F	4	0,70%
13	PIRRACCHIO R	6	1,06%	41	DHAENE T	4	0,70%
14	WANG Y	6	1,06%	42	DING Y	4	0,70%
15	CHURPEK MM	5	0,88%	43	EDELSON DP	4	0,70%
16	COOPER GF	5	0,88%	44	GREEN-SAXENA A	4	0,70%
17	DECRUYENAERE	5	0,88%	45	HASEGAWA K	4	0,70%
18	DUBRAWSKI A	5	0,88%	46	HAUSKRECHT M	4	0,70%
19	ERCOLE A	5	0,88%	47	HOFFMAN J	4	0,70%
20	GúIZA F	5	0,88%	48	HRAVNAK M	4	0,70%
21	HOCHHEISER H	5	0,88%	49	JOHNSON AEW	4	0,70%
22	LIU Y	5	0,88%	50	KING AJ	4	0,70%
23	LUO Y	5	0,88%	51	LEE S	4	0,70%
24	MEGJHANI M	5	0,88%	52	LIGHTBODY G	4	0,70%
25	NAJARIAN K	5	0,88%	53	MARK RG	4	0,70%
26	NEMATI S	5	0,88%	54	ONGENAE F	4	0,70%
27	SANCHEZ-PINTO I	5	0,88%	55	PELLEGRINI E	4	0,70%
28	VAN DEN BERGHE	5	0,88%	56	SALINAS J	4	0,70%
				Total		287	50,53%

Fonte: Dados da pesquisa (2021).

Os autores mais citados localmente, ou seja, dentre a coleção de documentos os autores que mais foram mencionados foram: Mark R G com 178

citações distribuídos em seus 4 artigos publicados; Clifford G D com 177 citações disseminados em 8 artigos; e Vincent J L com 120 citações.

Quadro 13: Autores mais citados localmente.

	<b>Autores</b>	<b>Citações</b>
1	MARK R G	178
2	CLIFFORD G D	177
3	VINCENT J L	120
4	CELI L A	116
5	GHASSEMI M	113
6	POLLARD T J	113
7	ZIMMERMAN J E	105
8	JOHNSON A E W	91
9	KNAUS W A	91
10	LEMESHOW S	88
11	NEMATI S	87
12	SHEN L	87
13	BREIMAN L	84
14	CHURPEK M M	84
15	ANGUS D C	83
16	WANG Y	83
17	BENGIO Y	81
18	JOHNSON A E	80
19	DOI	79
20	FENG M	79

Fonte: Dados da pesquisa (2021).

Para contextualizar e complementar as informações contidas nos Quadros 12 e 13, no Gráfico 8 apresenta-se a quantidade de publicações por ano e a quantidade de citações por artigo. O gráfico de bolhas foi utilizado com a finalidade de identificar as várias dimensões de análise. Neste sentido, o tamanho da bolha é eficaz para indicar valores característicos e comparações em análise. Quanto maior a bolha maior é a quantidade de publicações pelo autor (eixo y) no ano (eixo x). Da mesma forma, quanto mais escura a bolha, maior o número de citações. Observa-se que não é sempre que a publicação mais citada é a mais relevante. No entanto, por ter sido a mais mencionada evidencia que a publicação aderiu como referência de várias outras pesquisas, sendo considerada significativa para referência sobre o assunto.


O artigo mais citado foi o de Churpek MM (produziu 04 artigos em 2018) com média de citação de 37,5 citações por ano. Seguidos dos artigos de Clifford G D (produziu 3 artigos em 2012) e Li Q (produziu 3 artigos em 2012) com média de 34,01 citações por ano.

Os 04 artigos produzidos por Churpek MM em 2018 versaram sobre o uso de modelos de predição em aprendizado de máquina, sendo um deles baseado em dados de registro eletrônico de saúde, outro baseado em ligações da equipe de resposta rápida, outro artigo versou sobre o desenvolvimento para prever lesão renal aguda, em outro artigo deste autor abordou sobre Big Data e Ciência de Dados em cuidados intensivos.

Em 2012, 3 artigos foram escritos em parceria de Clifford G D e Li Q, e foram voltados para a análise da qualidade dos sinais, utilizando-se o aprendizado de máquina visando a redução de alarmes falsos em UTIs.

Analisando ainda o Gráfico 8, verifica-se que o autor JR foi o que mais produziu no ano de 2020, no entanto não obteve tantas citações, situação esta que se caracteriza pelo curto período de tempo não suficiente para evidenciar a citação de artigos por outros autores.

Gráfico 8: Produção dos autores ao longo do tempo.



Conforme já mencionado, o H-Índice é um indicador que também serve para aferir o impacto dos autores. Os pontos atribuídos a este indicador mensuram a produção científica individual de cada pesquisador, relacionando artigos e citações. Neste sentido, quanto maior a pontuação do H-Índice, mais expressivo é o impacto do

autor (SCIMAGO, 2016). O Quadro 14 apresenta os 20 primeiros autores com maior impacto pelo H-Índice.

Quadro 14: H-Índice Impacto do autor.

	<b>Autor</b>	<b>H-Índice</b>
1	CLIFFORD GD	8
2	MEYFROIDT G	6
3	LI Q	6
4	CLERMONT G	5
5	DAS R	5
6	CELI LA	5
7	JR	5
8	WANG Y	5
9	CHURPEK MM	5
10	GüIZA F	5
11	VAN DEN BERGHE G	5
12	CALVERT J	4
13	PINSKY MR	4
14	PIRRACCHIO R	4
15	DECRUYENAERE J	4
16	ERCOLE A	4
17	LIU Y	4
18	NAJARIAN K	4
19	NEMATI S	4
20	CAREY KA	4

Fonte: Dados da pesquisa (2021).

A seguir será analisada a categoria de análise das afiliações e países.

#### 4.4 ANÁLISE DAS AFILIAÇÕES E PAÍSES

Para identificar as instituições (afiliações) mais relevantes que abordam sobre o tema em questão, utilizou-se da contagem da quantidade de artigos publicados. Observa-se no Quadro 15 que de um total de 883 ocorrências de instituições, destaca-se as 20 primeiras. Foi aplicado o filtro de desambiguação de nome de afiliação.

Quadro 15: Afiliações mais relevantes.


	<b>Afiliações</b>	<b>Artigos</b>
1	Columbia University	63
2	University of Pennsylvania	54
3	University of California	48
4	Harvard Medical School	47
5	University of Michigan	47
6	University of Pittsburgh	45
7	University of Florida	30
8	University of Oxford	29

9	University College Cork	25
10	Stanford University	21
11	Stanford University School of Medicine	20
12	University of Cambridge	18
13	Johns Hopkins University	17
14	Massachusetts Institute of Technology	17
15	Seoul National University College of Medicine	17
16	University of California San Francisco	17
17	University of Copenhagen	17
18	McMaster University	16
19	University College London	16
20	Carnegie Mellon University	15

Fonte: Dados da pesquisa (2021).

Por meio do Gráfico 9 foi possível identificar a relação das principais instituições financiadoras por número de documentos. Observou-se que são renomadas instituições de pesquisa, sendo em sua maioria localizada no Estados Unidos, o que o consolida como o país que mais pesquisa sobre o assunto aqui abordado.

Gráfico 9: Documentos por patrocinador de financiamento.




Fonte: Dados da pesquisa (2021).

O Gráfico 10 apresenta a relação de países por número de documentos publicados, adotando o *Multiple Country Publications* (MCP) que indica, para cada

país, o número de documentos em que há pelo menos um coautor de um país diferente, medindo a colaboração internacional, representando a colaboração com autores de outros países e o *Single Country Publications* (SCP) que é a identificação de coautores do mesmo país, representando colaboração com autores do mesmo país. De um total de 40 países, segue a informação dos 20 primeiros. Verifica-se que o Estados Unidos se encontra grande parte dos autores, seguido de China e Reino Unido. A quantidade de pesquisadores no gráfico demonstra a colaboração intra-país e entre países.

Gráfico 10: País correspondente do autor.



Fonte: Dados da pesquisa (2021).

No tópico a seguir será abordado indicadores relacionados aos documentos.

#### 4.5 ANÁLISE DOS DOCUMENTOS

Na Tabela 5, os 20 documentos mais citados globalmente dentre os 568 documentos recuperados, considerados os mais relevantes pela comunidade. A base de dados Scopus fornece uma visualização do H-Índice dos artigos do período de 2011 a 2020. Observa-se na Tabela 6 que os artigos permanecem os mesmos em ambas as classificações.

Tabela 5: Os 20 documentos mais citados.

	<b>Autor</b>	<b>Título</b>	<b>Ano</b>	<b>Fonte</b>	<b>Total de Citações</b>
1	TEMKO A; THOMAS E; MARNANE W; LIGHTBODY G; BOYLAN G	Detecção de ataque neonatal baseada em EEG com máquinas vetoriais de suporte	2011	Clinical Neurophysiology	197
2	NEMATI S; HOLDER A; RAZMI F; STANLEY MD; CLIFFORD GD; BUCHMAN TG	Um modelo de aprendizagem da máquina interpretável para a previsão precisa de Sepsis na UTI	2018	Critical Care Medicine	145
3	CLIFFORD GD; BEHAR J; LI Q; REZEK I	Índices de qualidade de sinal e fusão de dados para determinar a aceitabilidade clínica de eletrocardiogramas	2012	Physiological Measurement	136
4	LI Q; CLIFFORD GD	Temporizador dinâmico e aprendizagem da máquina para avaliação da qualidade do sinal de sinais pulsáveis	2012	Physiological Measurement	131
5	PIRRACCHIO R; PETERSEN ML; CARONE M; RIGON MF CHEVRET S; VAN DER LAA MJ	Predição de mortalidade em unidades de terapia intensiva com o algoritmo do aprendiz super UTI (SICULA): um estudo de base populacional	2015	The Lancet Respiratory Medicine	117
6	JOHNSON AEW; GHASSEMI MM; NEMATI S; NIEHAUS KE; CLIFTON D; CLIFFORD GD	Aprendizagem da máquina e suporte à decisão no cuidado crítico	2016	Proceedings of the IEEE	116
7	SCICLUNA BP; VAN VUGHT LA; ZWINDERMAN AH; WIEWEL MA; DAVENPORT EE; BURNHAM KL; NÄRNBERG P; SCHULTZ MJ; HORN J; CREMER OL; BONTEN MJ; HINDS CJ; WONG HR; KNIGHT JC	Classificação de pacientes com Sepsis de acordo com endótipo genômico de sangue: um estudo de coorte prospectivo	2017	The Lancet Respiratory Medicine	108
8	SARIA S; RAJANI AK; GOULD J; KOLLER D; PENN AA	A integração de respostas fisiológicas precoce predita mais gravidade de doença em bebês prematuros	2010	Science Translational Medicine	107
9	CHE Z; PURUSHOTHAM S; KHEMANI R; LIU Y	Modelos profundos interpretáveis para previsão de resultados UTI	2016	Amia ... Annual symposium proceedings. Amia symposium	102
10	HATIB F; JIAN Z; BUDDI S; LEE C; SETTELS J; SIBERT K; RINEHART J; CANNESSON M	Algoritmo de aprendizagem da máquina para prever hipotensão com base na análise da forma de onda da pressão arterial de alta fidelidade	2018	Anesthesiology	92
11	PREVEDELLO LM; ERDAL BS; RYU JL; LITTLE KJ; DEMIRER M; QIAN S; WHITE RD	Identificação de achados de teste críticos automatizados e sistema de notificação online usando inteligência artificial na imagem	2017	Radiology	88
12	POLLARD TJ; JOHNSON AEW; RAFFA JD; CELI LA; MARK RG; BADAWI O	A EICU collaborative research database, uma base de dados multi-central livremente disponível para pesquisa em cuidados críticos	2018	Scientific Data	86

13	SUTHERLAND A; THOMAS M; BRANDON RA; BRANDON RB; LIPMAN J; TANG B; MCLEAN A; PASCOE R; PRICE G; NGUYEN T; STONE G; VENTER D	Desenvolvimento e validação de um novo teste de diagnóstico em biomarcador molecular para a detecção precoce de Sepsis	2011	Critical Care	84
14	PEROTTE A; PIVOVAROV R; NATARAJAN K; WEISKOPF N; WOOD F; ELHADAD N	Atribuição do código de diagnóstico: modelos e métricas de avaliação	2014	Journal of the American Medical Informatics Association	81
15	MAO Q; JAY M; HOFFMAN JL; CALVERT J; BARTON C; SHIMABUKURO D; SHIEH L; CHETTIPALLY U; FLETCHER G; KEREM Y; ZHOU Y; DAS R	Validação multicentro de um algoritmo de previsão de Sepsis usando apenas dados de sinal vital no departamento de emergência, UTI geral e UTI	2018	Bmj Open	79
16	CALVERT JS; PRICE DA; CHETTIPALLY UK; BARTON CW; FELDMAN MD; HOFFMAN JL; JAY M; DAS R	Uma abordagem computacional para a detecção de Sepsis precoce	2016	Computers in Biology and Medicine	79
17	LI Q; CLIFFORD GD	Qualidade de sinal e fusão de dados para redução de alarme falso na unidade de terapia intensiva	2012	Journal of Electrocardiology	74
18	LUCAS P	Análise Bayesian, Análise de Padrão e Mineração de Dados em cuidados de saúde	2004	Current Opinion in Critical Care	74
19	MANI S; OZDAS A; ALIFERIS C; VAROL HA; CHEN Q; CARNEVALE R; CHEN Y; ROMANO-KEELER J; NIAN H; WEITKAMP J-H	Suporte à decisão médica usando a aprendizagem da máquina para a detecção precoce de Sepsis neonatal de início tardio	2014	Journal of the American Medical Informatics Association	71
20	TEMKO A; THOMAS E; MARNANE W; LIGHTBODY G; BOYLAN GB	Avaliação de desempenho para detectores de conversão neonatal baseados em EEG	2011	Clinical Neurophysiology	69

Fonte: Dados da pesquisa (2021).

Tabela 6: Index H dos artigos de 2011 a 2020.

Documents	Citations	<2011	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	Subtotal	>2020	Total
	Total	188	64	115	129	182	198	296	376	710	1437	2652	6159	549	6896
1	EEG-based neonatal seizure detection with Support Vector Mac...	2011	10	20	12	22	18	21	23	23	18	22	189	2	191
2	An Interpretable Machine Learning Model for Accurate Predict...	2018								5	63	63	131	14	145
3	Signal quality indices and data fusion for determining clini...	2012		1	4	15	11	18	16	30	15	18	128	3	131
4	Dynamic time warping and machine learning for signal quality...	2012		5	5	7	14	22	17	19	18	20	127	1	128
5	Mortality prediction in intensive care units with the Super ...	2015					3	9	10	23	30	32	107	8	115
6	Machine Learning and Decision Support in Critical Care	2016						5	11	31	26	37	110	2	112
7	Classification of patients with sepsis according to blood ge...	2017							2	19	39	37	97	5	102
8	Interpretable Deep Models for ICU Outcome Prediction	2016							3	22	32	34	91	9	100
9	Integration of early physiological responses predicts later ...	2010	1	12	5	10	10	10	11	18	8	11	96	1	97
10	Machine-learning Algorithm to Predict Hypotension Based on H...	2018								2	31	51	84	8	92

Fonte: Dados da pesquisa (2021).

#### 4.6 ANÁLISE DAS PALAVRAS-CHAVE

Palavra-chave é o termo simples ou compostos que sintetiza do que se trata um documento (artigo/conteúdo), e constitui-se como importante indicador de conteúdo, sendo possível identificar principais temas abordados, bem como indica tendências de pesquisa. Dos 568 documentos foram extraídas 1.249 palavras-chave definidas pelos autores.


A visualização destas ocorrências confirma a alta aderência do *corpus* recuperado, o que também valida a utilização no processo de busca. Baseado no levantamento de palavras-chave, organizou-se a nuvem de palavras (Figuras 10A, 10B, 10C e 10D), apresentando-se as 50 palavras-chave /palavras com maior ocorrência.

Figura 10: Nuvem por palavra-chave do autor (10A); Nuvem por palavra-chave plus (10B); Nuvem por palavra em títulos (10C); Nuvem por palavra em resumos (10D).






Figura 11: Treemap das palavras-chave definidas pelos autores.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).


Observa-se que os Gráficos 11 e 12 são complementares ao entendimento da dinâmica da tendência de pesquisas por palavras-chave.

Gráfico 11: Dinâmica das 10 palavras-chave mais frequentes ao longo dos anos.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).

O Gráfico 12 apresenta a tendência de tópicos abordados ao longo dos anos. Em 2018, o uso de machine learning e em 2019 a especificação mais detalhada como *prediction* e *deep learning*, as quais são subclassificações de aprendizado de máquina, inferindo que os artigos estão sendo mais específicos em relação a quais algoritmos utilizar.



Fonte: Dados da pesquisa (2021).

No tópico a seguir será apresentado a análise da estrutura conceitual.

#### 4.7 ANÁLISE DA ESTRUTURA CONCEITUAL

A estrutura conceitual é frequentemente usada para entender os tópicos abordados pelos estudiosos (a chamada frente de pesquisa) e identificar quais são os assuntos mais importantes e os mais recentes (ARIA; CUCCURULLO, 2021b). Análise da estrutura conceitual compreende a visualização da Rede de Coocorrência, Mapa Temático, Evolução Temática e Análise Fatorial.


Redes de coocorrência mostram a estrutura conceitual, as quais revelam ligações entre conceitos por meio de coocorrência de palavras-chave do autor.



Na análise das palavras-chave por meio do mapa temático, verifica-se que a centralidade e a densidade podem ser usadas na classificação dos temas e no mapeamento em um plano bidimensional, sendo analisado de acordo com o quadrante em que estão inseridos: (1) quadrante superior direito: temas motores; (2) quadrante inferior direito: temas básicos; (3) quadrante inferior esquerdo: temas emergentes ou em declínio; (4) quadrante superior esquerdo: temas muito especializados / de nicho (ARIA; CUCCURULLO, 2021b).

Para a elaboração da Figura 13 foi definido como parâmetros: 250 como número de palavra, frequência mínima de 5 (por mil documentos), 1 rótulo (para cada cluster), todos os outros argumentos assumiram os valores padrão. Os agrupamentos são caracterizados por dois parâmetros: densidade e centralidade.


Figura 13: Mapa temático de palavras-chave definidas pelo autor.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).

A evolução temática pode ser visualizada na Figura 14, no qual todos argumentos assumiram os valores padrão oferecido pela ferramenta de análise.

Figura 14: Evolução temática.




Fonte: Dados da pesquisa (2021).

Análise de Correspondência Múltipla (MCA) é uma técnica exploratória para a análise gráfica e numérica de dados por categorias multivariadas, realizando uma análise de homogeneidade de uma matriz de indicador para obter uma representação euclidiana de baixa dimensão dos dados originais. Os resultados são analisados com base nas posições relativas dos pontos e sua distribuição ao longo das dimensões (ARIA; CUCCURULLO, 2021b).

A Figura 15 apresenta o mapa de análise fatorial de palavras-chave, usando uma abordagem de escala multidimensional entre as principais 50 palavras-chave e um mínimo de 5 documentos. O agrupamento direito (azul) é uma combinação de 04 palavras-chave relacionadas à pesquisas voltadas para a redução de falsos alarmes. O agrupamento esquerdo (vermelho) composto por 26 palavras que fazem parte do agrupamento geral, estão principalmente relacionadas a pesquisas de aprendizado de máquina em cuidados intensivos. Destaca-se a ponta superior do cluster vermelho, por meio do qual pode-se observar que já ocorrem os termos relacionados a SARS-COV-2 e COVID-19, representando tendências de pesquisa.


A Figura 16 apresenta o dendrograma, o qual é um diagrama hierárquico que expõe os grupos formados por agrupamento de observações em cada nível e em suas similaridades em termos de palavras-chave.

Figura 15: Análise fatorial pelo método MCA.



Fonte: Dados da pesquisa (2021).

Figura 16: Dendrograma.




Fonte: Dados da pesquisa (2021).

#### 4.8 ANÁLISE DA ESTRUTURA INTELECTUAL

A estrutura intelectual se aplica aos documentos (artigos), aos autores e às fontes compreendendo a rede de cocitação e historiografia. A cocitação é o ponto focal de análise. De acordo com Oliveira e Gracio (2018, p. 59) entende-se por cocitação “como a frequência com que dois documentos citados estão juntos em um artigo. A força da cocitação entre dois autores citados pode ser facilmente determinada a partir do número de vezes que os autores foram citados juntos.” Neste tipo de análise tem-se como evidência a estrutura do conhecimento percebida pelos pesquisadores da área, sendo considerado a visão intelectual do *corpus* pesquisado.

A Figura 17 apresenta a rede de cocitação que envolve o assunto de aprendizado de máquina em cuidados intensivos.

Figura 17: Rede de cocitação.




Fonte: Dados da pesquisa (2021).

A Figura 17 representa a rede de cocitações de autores, ou seja, autores que citam uns aos outros, tendo alguns autores como principais destacados na imagem da rede. Verificou-se a separação de quatro agrupamentos, separados por cor, sendo que em cada agrupamento os principais autores estão indicados com tamanho de letra maior.

A Figura 18 demonstra a rede histórica de citações, que mapeia no tempo a origem de artigos mais citados recentes. As linhas que ligam os artigos, representam as conexões deles, os artigos que seguiram a mesmas linhas de antecessores. É uma maneira de identificar de maneira rápida os artigos mais significativos sobre o assunto pesquisado e realizar o rastreamento de seu desenvolvimento histórico no tempo.

Figura 18: Historiôgrafo.



Fonte: Dados da pesquisa (2021).


#### 4.9 ANÁLISE DA ESTRUTURA SOCIAL

A análise da estrutura social visa identificar as estruturas formais do domínio de determinado assunto, identificando a chamada divisão social, ou seja, as comunidades que se criaram ao pesquisarem sobre o assunto, relacionando-as com o conhecimento em uma dimensão sociológica (GHENO, 2017).

As redes de colaboração visam demonstrar a interação de como os autores, as afiliações/instituições e países se relacionam com outros em um campo específico

de pesquisa, possibilitando revelar os autores, instituições e países com regularidade de pesquisa. As Figura 19, 20 e 21 apresentam, respectivamente, a rede de colaboração dos autores, instituições e países analisados no *corpus* do tema abordado.


Figura 19: Rede de colaboração de autores.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).


Observa-se na Figura 19 que há 6 grupos de pesquisadores que se destacam com 3 ou mais nós (autores). Isto significa que há poucos grupos consolidados de pesquisa sobre aprendizado de máquina em cuidados intensivos.

Figura 20: Rede de colaboração de instituições.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).


Figura 21: Rede de colaboração de países.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).

Na Figura 22 visualiza-se o mapa mundial de colaboração. Verifica-se que os Estados Unidos é o nó central das colaborações.

Figura 22: Mapa mundial de colaboração.



Fonte: Dados da pesquisa (2021). (Suporta zoom de alta qualidade).

A seguir, discute-se os resultados obtidos.

#### 4.10 DISCUSSÃO DOS RESULTADOS

A recuperação e análise dos 568 documentos da base de dados Scopus sobre aprendizado de máquina em cuidados intensivos revelou informações importantes sobre a aplicação desta temática que está em constante crescimento e é de fundamental relevância para a manutenção da saúde, servindo no apoio a tomada de decisão dos profissionais da saúde.

Verificou-se que a consolidação dos dados no Quadro 7 possibilitou a visão e rápida compreensão sobre a coleção de dados.

Conforme Gráfico 1, houve um crescimento das publicações sobre o tema, significando que é um tema em ascensão, bem como se pode verificar na análise da categoria de palavras-chave. O idioma predominante é o inglês, e os artigos são publicados principalmente em periódicos da área de Medicina, seguido de Ciência da Computação. Em relação ao crescimento das publicações sobre o assunto, Mathur e Burns (2019) em pesquisa de levantamento sobre aplicações de inteligência artificial

em cuidados intensivos, apontaram que o interesse da comunidade científica cresceu nesta área, sendo evidenciada pelo fato de que o número de publicações evoluiu em um ritmo constante desde o ano de 2000 e triplicou nos últimos anos.

Em relação às fontes, a dispersão é identificada a partir da definição do núcleo de periódicos que concentram sobre o tema, que é composto por poucos periódicos com número considerável de artigos de interesse. Por meio da aplicação da Lei de Bradford identificou-se que são 13 os periódicos mais relevantes / devotados sobre o assunto. Os outros periódicos menos produtivos foram ordenados em zonas de produtividade decrescente de artigos sobre o mesmo assunto, e o número de periódicos em cada zona aumenta à medida em que sua produtividade individual diminui. O número de artigos em cada zona, no entanto, permanece em aproximação constante. Elenca-se os 13 periódicos mais relevantes: *Plos One*, *Critical Care Medicine*, *Artificial Intelligence in Medicine*, *Journal of Biomedical Informatics*, *BMC Medical Informatics and Decision Making*, *Critical Care*, *IEEE Journal of Biomedical and Health Informatics*, *International Journal of Medical Informatics*, *Journal of Medical Internet Research*, *Journal of Clinical Monitoring and Computing*, *Physiological Measurement*, *AMIA Annual Symposium Proceedings*, *IEEE Access*.

O periódico *Plos One* concentrou estudos com a finalidade de criação de algoritmos de aprendizado de máquina para previsão de mortalidade em cuidados intensivos (CHANG JUNIOR *et al.*, 2020; APERSTEIN *et al.*, 2019; MAYAMPURATH *et al.*, 2019; MEIRING *et al.*, 2018; AUSHEV *et al.*, 2018). Também publicou artigos sobre o uso de modelos de aprendizado de máquina para previsão de admissão de pacientes em UTI (FERNANDES *et al.*, 2020), redução de falsos alarmes (MOUSAVI; FOTOOHINASAB; AFGHAH, 2020), previsão de síndrome respiratória aguda (ZEIBERG *et al.*, 2019), previsão de sepse (MASINO *et al.*, 2019), .previsão de lesão renal aguda (PARK *et al.*, 2018).

A fonte *Critical Care Medicine* publicou sobre modelo de aprendizado de máquina para previsão de sepse (LI *et al.*, 2020a; NEMATI *et al.*, 2018; SWEENEY *et al.*, 2018), lesão renal aguda (KOYNER *et al.*, 2018).

Dentre os periódicos mais devotados, o *Journal of Medical Internet Research* foi que mais publicou pesquisas voltadas para COVID-19, elencando-se os trabalhos de (KIM *et al.*, 2020; PAN *et al.*, 2020; IZQUIERDO; ANCOCHEA; SORIANO, 2020).

Ainda em relação as fontes sobre a importância da identificação da dispersão dos artigos, que abordam sobre o uso do aprendizado de máquina em cuidados

intensivos, em periódicos de diversas áreas pode ser explicada pela Lei de Bradford, que assegura: “a necessidade de se identificar a dispersão dos artigos sobre determinado assunto publicados em periódicos de outras especialidades, já que as áreas científicas se interrelacionam, para que o maior número de artigos relevantes possa ser recuperado, além daqueles publicados em periódicos dedicados especificamente à área de interesse” (COUTINHO, 1988, p. 218).

Sobre a categoria de análise de autores, verificou-se que 11 autores de documentos de autoria única e 3.087 autores de artigos de autoria múltipla. Através da constatação evidenciada no Quadro 11, pode-se afirmar que distribuição da produção científica dos autores da literatura sobre o uso do aprendizado de máquina em cuidados intensivos, quando relacionada pelos resultados obtidos e esperados, não se ajusta à Lei de Lotka, haja vista que os resultados remetem à rejeição da semelhança da distribuição.

Pela aplicação da Lei do Elitismo obteve-se que 56 são os que compõem a elite de autores, os quais produziram 50,53% dos artigos. Identificou-se o efeito Mateus, o qual “consiste na acumulação de maiores incrementos de reconhecimento por contribuições científicas particulares para cientistas de reputação considerável e a retenção de tal reconhecimento para cientistas que ainda não deixaram sua marca” (MERTON, 1968; CAMARGO JR, 2015). Em suma, o efeito Mateus afirma que muitos autores produzem pouco, e poucos autores produzem muito.

Embora pela Lei de Lotka tenha sido verificado uma variação entre o observado e o esperado, foi possível identificar os autores mais relevantes sobre o tema em questão. Os 10 mais produtivos foram: Clermont G, Das R, Meyfroidt G, Celi La, Clifford GD, JR, Li Q, Li X, Li Y, Calvert J.

Clermont G teve seus estudos publicados em parceria com outros autores, e de 2018 a 2020, aplicando o aprendizado de máquina em cuidados intensivos para: Predição de eventos de hipotensão com assinaturas fisiológicas de sinal vital na unidade de terapia intensiva; Destacar seletivamente as informações do paciente; Prever taquicardia como superfície de instabilidade na UTI; Prever o comportamento de busca de informações de clínicos usando um sistema de registro médico eletrônico; Prever risco dinâmico e personalizado, e suas implicações para paradigmas de monitoramento.

O autor Das R também escreveu em parceria com outros autores, e no período de 2018 a 2020, publicou artigos sobre: Aprendizagem supervisionada da

máquina para a previsão precoce da síndrome do desconforto respiratório agudo; Validação de um algoritmo de aprendizagem de máquina para previsão de sepsis precoce grave com 48h de antecedência; Propôs modelo de previsão de mortalidade para o triagem de COVID-19, pneumonia e pacientes de UTI mecanicamente ventilados; Prever lesão renal aguda com algoritmo de aprendizagem da máquina usando dados de registro de saúde eletrônica; Validação multicentro de um algoritmo de previsão de sepsis usando apenas dados de sinal vital na UTI.

Identificou-se que Estados Unidos é o país com maior produção de artigos, e a partir do qual os autores estão vinculados por meio das principais instituições que publicam sobre o tema, sendo as 10 mais produtoras listadas a seguir: *Columbia University, University of Pennsylvania, University of California, Harvard Medical School, University of Michigan, University of Pittsburgh, University of Florida, University of Oxford, University College Cork, Stanford University.*

Também foi possível identificar os artigos mais citados pela comunidade científica. O artigo mais citado foi o de Temko *et al.* (2011) cujo objetivo foi a detecção de ataque neonatal baseada em EEG com máquinas vetoriais de suporte, obtendo até o momento 197 citações. Seguido de Nemat *et al.* (2018), no qual artigo propôs um modelo de aprendizagem da máquina interpretável para a previsão precisa de Sepsis na UTI, tendo 145 citações.

Na análise das palavras-chaves identificou-se as tendências de pesquisa, as palavras-chaves e palavras que mais ocorreram na coleção de documentos analisados. Com a utilização dos recursos disponíveis pela ferramenta Biblioshiny foi possível apresentar as nuvens de palavras, *treemap*, a evolução da utilização das palavras, bem como as tendências temáticas observando-as de maneira gráfica. É possível que a identificação das palavras-chave utilizadas tenha tido interferência pela metodologia empregada neste estudo haja vista que foram usados nos termos de busca na base Scopus. Entretanto, foi admissível observar crescimento na produção de documentos e da evolução temática.

Através da visualização do Gráfico 12 foi possível identificar a tendência de tópicos ao longo dos anos. Em relação ao aprendizado de máquina percebe-se a evolução das técnicas empregadas, sendo que em 2011 utilizava-se máquina de vetores de suporte (*support vector machines*). E em 2018, os estudos que pesquisaram sobre o desenvolvimento de modelos que se utilizaram das técnicas de floresta aleatória (*random forest*) e redes neurais artificiais (*artificial neural networks*).

E como técnica mais recente (2020), evidencia-se a aprendizagem profunda (*Deep learning*). A aprendizagem profunda é uma das técnicas mais promissoras quando se aborda sobre predição de eventos em pacientes em unidades de terapia intensiva (YU et al., 2020), (YE et al., 2020), (SCOTT; COIERA, 2020), (PAN et al., 2020).

Em relação as patologias e/ou condições específicas que se queria solucionar com o aprendizado de máquina nas UTIs, obteve-se uma tendência à pesquisas de:

- Sepsis: LAURITSEN *et al.*, 2020; YUAN *et al.*, 2020; LI *et al.*, 2020a; BURDICK *et al.*, 2020; KONG; LIN; HU, 2020; YUAN *et al.*, 2020; MASINO *et al.*, 2019; NEMATI *et al.*, 2018; SWEENEY *et al.*, 2018;

- Previsão de mortalidade: CHANG JUNIOR *et al.*, 2020; EL-RASHIDY *et al.*, 2020; PAN *et al.*, 2020; KONG; LIN; HU, 2020; KANG *et al.*, 2020; KLINE *et al.*, 2020); YE *et al.*, 2020; APERSTEIN *et al.*, 2019; MAYAMPURATH *et al.*, 2019; HUANG *et al.*, 2019; CAICEDO-TORRES; GUTIERREZ, 2019; KIM *et al.*, 2019; DELIBERATO *et al.*, 2019; MEIRING *et al.*, 2018; AUSHEV *et al.*, 2018; DELAHANTY; KAUFMAN; JONES, 2018.

Por meio das estruturas conceitual, intelectual e social, que refletem uma visão em rede através de nós e ligações, revelaram a cadeia de produção dos autores, periódicos, palavras-chave conforme especificação do objeto em análise.

Em relação à estrutura conceitual verifica-se que, baseado nas palavras-chaves, é possível identificar que há uma tendência crescente de tópicos de interesse para a elaboração de novas pesquisas na área. As Figuras 12, 15 e 16 revelaram o agrupamento de palavras-chaves conceituais que se interrelacionam evidenciando algumas afinidades de temáticas pesquisadas. Foi possível apontar grupos com temáticas e técnicas de pesquisa consolidadas, bem como as que estão emergindo. O agrupamento com tendência recente e crescente de evolução é o SARS-CoV-2/COVID-19, para o qual foram empregados modelos preditivos, com decisões baseadas em dados clínicos e memória de dados de longo prazo. Para as patologias de lesão renal aguda usa-se modelos de predição por meio de algoritmos de aprendizado supervisionado. Há um outro grupo conceitual que se concentra na predição de sepsis e choque séptico baseando-se em sistemas de apoio das decisões clínicas e informática médica.

No que se refere à estrutura intelectual, foi possível a identificação da rede de citação, bem como o historiográfico dos artigos mais citados nos últimos anos.

A respeito da estrutura social, foi possível conhecer as redes de colaboração, verificou-se que há agrupamentos de autores, instituições e países que trabalham em parcerias. No entanto, em suma, os autores, instituições e países pesquisam sobre o tema de maneira isolada. Não representando uma rede de colaboração consolidada nesta área.

Verificou-se através dos artigos lidos, que o uso das técnicas de aprendizado de máquina nos cuidados da saúde é recente, com muitas iniciativas resultando soluções que carecem de validações definitivas para ampliar o seu uso na saúde, e assim torná-lo consolidado e acessível a todos. Tran *et al.* (2019) afirma que o uso de ferramentas de “inteligência artificial / aprendizado de máquina em disciplinas de cuidados de saúde permanece embrionário, com esforços iniciais resultando em mais perguntas do que soluções definitivas para melhorar os resultados de saúde.”

Gennatas *et al.* (2020) afirmam que um dos maiores desafios do aprendizado de máquina em aplicativos voltados para de alto risco, como é o caso dos cuidados intensivos, é retirar e agrupar o conhecimento prévio que possibilita que os algoritmos se generalizem para novos casos e aprendam com menos dados, sendo este o foco de vários estudos voltados para o grande volume de dados gerados ou sendo utilizados por aprendizado de máquina.

Em relação à ferramenta Biblioshiny pode-se comprovar na prática a sua aplicação, realizando uma validação dela em termos de apresentar funcionalidades de maneira adequada ao que se propõe a fazer, sendo de fundamental importância para auxiliar no apoio e desenvolvimento de estudos pelos pesquisadores. A interface web Biblioshiny apresentou-se como uma poderosa ferramenta para apoio na elaboração das análises bibliométricas e cientométricas, facilitando para o pesquisador, no qual passará a maior parte de seu tempo agora focando nas análises e interpretações, e não mais na organização do *corpus* e meios de analisá-los.

Também como contribuição da tese, no Quadro 16 elenca-se pesquisas identificadas nos periódicos mais devotados e recentes sobre o tema, categorizados por patologias/condições específicas em unidades de terapia intensiva que se utilizaram de algoritmos de aprendizado de máquina como forma de apoio para sua resolução.

Quadro 16: Aplicações aprendizado de máquina em cuidados intensivos.

PATOLOGIA/ CONDIÇÕES ESPECÍFICAS	TÍTULO	OBJETIVO	RESULTADOS/CONCLUSÃO	AUTORES
COVID-19	Um modelo de aprendizado de máquina fácil de usar para prever o prognóstico de pacientes com COVID-19: estudo de coorte retrospectivo	Desenvolver um modelo de aprendizado de máquina que prevê a necessidade de tratamento intensivo para pacientes com COVID-19 usando características facilmente obtidas - dados demográficos de linha de base, comorbidades e sintomas.	Desenvolveu um modelo de aprendizado de máquina que compreende características simples fornecidas pelo paciente, que podem prever com eficiência a necessidade de cuidados intensivos entre pacientes com COVID-19.	(KIM <i>et al.</i> , 2020)
COVID-19	Avaliação Prognóstica do COVID-19 em Unidade de Terapia Intensiva por Métodos de Aprendizagem de Máquina: Desenvolvimento e Validação de Modelo	Usar o aprendizado de máquina para construir um modelo de análise de fatores de risco e predição de mortalidade em pacientes internados em UTI com COVID-19.	O modelo de 8 fatores prediz bem o risco de morte em pacientes de UTI com COVID-19; inicialmente demonstra estabilidade e pode ser usado efetivamente para prever o prognóstico de COVID-19 em pacientes de UTI.	(PAN <i>et al.</i> , 2020)
COVID-19	Características clínicas e fatores prognósticos para admissão em unidade de terapia intensiva de pacientes com COVID-19: estudo retrospectivo usando aprendizado de máquina e processamento de linguagem natural	Descrever as características clínicas e determinar os fatores que predizem a admissão à unidade de terapia intensiva (UTI) de pacientes com COVID-19. A determinação desses fatores usando uma população bem definida pode aumentar nossa compreensão da epidemiologia da doença no mundo real.	Mostrou que uma combinação de variáveis clínicas de fácil obtenção (idade, febre e taquipnéia com ou sem estertores respiratórios) prediz se os pacientes com COVID-19 necessitarão de internação na UTI.	(IZQUIERDO; ANCOCHEA; SORIANO, 2020)
PREVISÃO DE MORTALIDADE	Melhorando a previsão pré-operatória do risco de morte em cardiopatias congênitas em cirurgia usando modelo de inteligência artificial: um estudo piloto	Gerar um modelo preditivo de calculadora adaptado à realidade regional com foco na predição de mortalidade individual em pacientes com cardiopatia congênita submetidos à cirurgia cardíaca.	As áreas de melhor desempenho sob a curva foram obtidas usando Random Forest (0,902). Os preditores mais influentes incluíram admissão prévia à UTI, grupo diagnóstico, altura do paciente, síndrome do coração esquerdo hipoplásico, massa corporal, saturação arterial de oxigênio e atresia pulmonar. Essas variáveis preditoras combinadas representam 67,8% de importância para o risco de mortalidade no algoritmo Random Forest.	(CHANG JUNIOR <i>et al.</i> , 2020)
PREVISÃO DE MORTALIDADE	Previsão de mortalidade em pacientes gravemente enfermos com diabetes	Utilizar recursos do Sistema de Linguagem Médica Unificada (UMLS), envolvendo abordagens de	Os recursos UMLS e as notas clínicas são ferramentas poderosas e importantes para prever a mortalidade em pacientes diabéticos no ambiente de cuidados intensivos.	(YE <i>et al.</i> , 2020)

	usando aprendizado de máquina e notas clínicas	aprendizado de máquina e processamento de linguagem natural (PNL) para prever o risco de mortalidade.	O modelo CNN orientado por conhecimento é eficaz (AUC = 0,97) para aprender recursos ocultos.	
PREVISÃO DE MORTALIDADE	Usando a teoria de resposta ao item para aprendizado de máquina explicável na previsão de mortalidade em unidade de terapia intensiva: abordagem baseada em casos	demonstrar como a teoria de resposta ao item (TRI) pode ser usada para estratificar os dados com base na dificuldade de classificação de cada caso, independentemente da medida de resultado de interesse (por exemplo, precisão). Essa estratificação permite que a avaliação dos classificadores de ML assumam a forma de uma distribuição em vez de um único valor escalar.	Mostrou que usar o IRT é um método viável para compreender os dados fornecidos aos algoritmos de aprendizado de máquina, independentemente das medidas de resultado, e destaca como os classificadores diferenciam bem os casos de dificuldade variável. Este método explica quais recursos são indicativos de estados saudáveis e por quê. Ele permite que os usuários finais ajustem o classificador adequado ao nível de dificuldade do paciente para a medicina personalizada.	(KLINE <i>et al.</i> , 2020)
PREVISÃO DE MORTALIDADE	Predição de mortalidade em unidade de terapia intensiva: um modelo aprimorado de conjunto de empilhamento específico do paciente	Propõe uma nova abordagem de conjunto de empilhamento para prever a mortalidade de pacientes de UTI.	Os resultados indicam que o modelo superou as abordagens de última geração em termos de precisão (94,4%), pontuação F1 (93,7%), precisão (96,4%), recall (91,1%) e área sob o operador do receptor curva característica (ROC) (93,3%). Esses resultados demonstram a capacidade e eficiência	(EL-RASHIDY <i>et al.</i> , 2020)
PREVISÃO DE MORTALIDADE	Algoritmo de aprendizado de máquina para prever mortalidade em pacientes submetidos à terapia de substituição renal contínua	Aplicar algoritmos de aprendizado de máquina para melhorar a precisão da predição para esse subconjunto de pacientes.	Os algoritmos de aprendizado de máquina aumentam a precisão da previsão de mortalidade para pacientes submetidos a terapia de substituição renal contínua (CRRT) para lesão renal aguda em comparação com modelos de pontuação anteriores.	(KANG <i>et al.</i> , 2020)
PREVISÃO DE MORTALIDADE	Um modelo de aprendizagem profunda para previsão de mortalidade em tempo real em crianças gravemente doentes	Desenvolver e validamos um modelo baseado em aprendizado de máquina, a Ferramenta de Predição de Risco Pediátrico de Mortalidade (PROMPT), para predição em tempo real de mortalidade por todas as causas em unidades de terapia intensiva pediátrica.	PROMPT é uma ferramenta de pontuação de alerta precoce baseada em modelos e baseada em dados que pode prever a mortalidade em crianças gravemente doentes e pode ser útil para a identificação oportuna de pacientes em deterioração.	(KIM <i>et al.</i> , 2019)
PREVISÃO DE MORTALIDADE	SEVERITAS: Uma previsão de mortalidade validada externamente para pacientes gravemente	Criar um novo modelo de prognóstico de gravidade usando menos variáveis que são mais fáceis de coletar em países de baixa e média renda (LMIC)	Criou um novo modelo de previsão de mortalidade em UTI usando regressão logística simples em um pequeno conjunto de variáveis facilmente coletadas pode ser mais adequado do que os modelos disponíveis atualmente para uso em países de baixa e média renda.	(DELIBERATO <i>et al.</i> , 2019)

	enfermos em países de baixa e média renda			
PREVISÃO DE MORTALIDADE	Melhoria da previsão de mortalidade na UTI com base nos escores SOFA e parâmetros gastrointestinais	Construir um modelo computacional para prever a mortalidade com base em uma série de escores Sequential Organ Failure Assessment (SOFA). E E examinar possibilidade de melhorar a previsão com a incorporação de um novo componente projetado para medir o desempenho do sistema gastrointestinal, adicionado aos outros seis componentes.	Resultados indicam que os parâmetros gastrointestinais carregam informações significativas como um preditor de mortalidade, além do escore SOFA convencional. Essas informações aumentam o poder preditivo dos modelos de aprendizado de máquina, estendendo o SOFA para incluir informações relacionadas ao sistema de órgãos gastrointestinais. O método descrito melhora a previsão de mortalidade, considerando a dinâmica do escore SOFA estendido. Embora testado em um conjunto de dados limitado, a estabilidade dos resultados em diferentes modelos sugere robustez no uso em tempo real.	(APERSTEIN <i>et al.</i> , 2019)
PREVISÃO DE MORTALIDADE	Combinando cronogramas visuais do paciente com aprendizado profundo para prever mortalidade	Desenvolver uma estrutura que primeiro transforma os dados longitudinais do paciente em linhas do tempo visuais e, em seguida, utiliza o aprendizado profundo para prever a mortalidade intra-hospitalar.	Desenvolveram uma estrutura que representa de forma exclusiva os dados clínicos de paciente em um formato visual e usa um modelo de rede neural de aprendizado profundo para prever a mortalidade intra-hospitalar usando informações das primeiras 48 horas de internação.	(MAYAMPURA TH <i>et al.</i> , 2019)
PREVISÃO DE MORTALIDADE	O agrupamento de pacientes melhora a eficiência do aprendizado de máquina federado para prever mortalidade e tempo de internação hospitalar usando registros médicos eletrônicos distribuídos	Desenvolver algoritmo que agrupe os dados distribuídos em comunidades clinicamente significativas que capturaram diagnósticos e localizações geográficas semelhantes e aprenderam um modelo para cada comunidade	Criaram um método que agrupou pacientes sem violação de privacidade e uma estratégia de aprendizagem que treinou vários modelos de comunidade para aproveitar os dados agrupados.	(HUANG <i>et al.</i> , 2019)
PREVISÃO DE MORTALIDADE	ISeeU: Aprendizagem profunda visualmente interpretável para previsão de mortalidade dentro da UTI	Propõe uma arquitetura convolucional multi-escala profunda treinada no Medical Information Mart for Intensive Care III (MIMIC-III) para predição de mortalidade, e o uso de conceitos da teoria dos jogos de coalizão para construir explicações visuais destinadas a mostrar o quão importante essas entradas são consideradas pela rede.	Mostrou que o modelo oferece desempenho de ponta, ao mesmo tempo em que oferece explicações visuais baseadas em um conceito da teoria dos jogos de coalizão, que mostram a importância dos recursos de entrada para a saída do modelo.	(CAICEDO-TORRES; GUTIERREZ, 2019)

PREVISÃO DE MORTALIDADE	Previsão ideal de resultados em terapia intensiva ao longo do tempo usando aprendizado de máquina	Empregar o aprendizado e máquina para avaliar a previsibilidade da mortalidade na UTI em função do tempo	Apresentou implicações para a tomada de decisão em terapia intensiva e fornece uma justificativa para estudos com tempo limitado de terapia em UTI; a avaliação do prognóstico ao longo de mais de um dia pode ser uma estratégia valiosa, pois novas informações no segundo dia ajudam a diferenciar os resultados. Novos modelos de aprendizado de máquina baseados em dados de tendência além do primeiro dia podem melhorar muito as ferramentas atuais de estratificação de risco.	(MEIRING <i>et al.</i> , 2018)
PREVISÃO DE MORTALIDADE	Seleção de recursos para a previsão precisa de mortalidade por choque séptico e cardiogênico na UTI na fase aguda	Encontrar assinaturas de choque 'ômicas' e incluiu dois tipos de choque: séptico e cardiogênico.	É possível prever o risco de morte na fase aguda do choque séptico e cardiogênico com resultados bastante aceitáveis, levando-se em consideração os atributos medidos rotineiramente pela ecocardiografia em UTI. A utilização desses dados para avaliação do prognóstico dos pacientes é considerada valiosa para o manejo clínico de pacientes com choque na UTI na admissão à UTI ou durante o primeiro dia de evolução.	(AUSHEV <i>et al.</i> , 2018)
SEPSE	Um modelo de aprendizado de máquina em fase de tempo para previsão em tempo real de sepse em cuidados intensivos	Desenvolver e validar um algoritmo de aprendizado de máquina com alto desempenho de previsão e interpretabilidade clínica para previsão de início de sepse durante cuidados intensivos em tempo real	O modelo de aprendizado de máquina proposto por Time-phAsed para o modelo de previsão de sepse é preciso e interpretável para previsão em tempo real do início da sepse em cuidados intensivos, o que tem grande potencial para avaliação posterior em estudos prospectivos.	(LI <i>et al.</i> , 2020a)
SEPSE	Detecção precoce de sepse utilizando aprendizado profundo em sequências de eventos de registros eletrônicos de saúde	Avaliação de detecção de sepse	Apresentou um sistema de aprendizado profundo para detecção precoce de sepse que pode aprender as características dos principais fatores e interações dos próprios dados de sequência de eventos brutos, sem depender de um trabalho intensivo de extração de recursos. O sistema supera os modelos de linha de base, como aumento de gradiente, que dependem de elementos de dados específicos e, portanto, sofrem de muitos valores ausentes no conjunto de dados.	(LAURITSEN <i>et al.</i> , 2020)
SEPSE	Validação de um algoritmo de aprendizado de máquina para previsão de sepse grave precoce: um estudo retrospectivo prevendo sepse grave com até 48 horas de	Desenvolver e validar um algoritmo de aprendizado de máquina (MLA) para a previsão de sepse grave até 48 horas antes do início, usando um conjunto de dados de pacientes diversificado.	O MLA prevê com precisão o início da sepse grave com até 48 horas de antecedência, usando apenas sinais vitais prontamente disponíveis extraídos dos registros eletrônicos de saúde existentes do paciente. Implicações relevantes para a prática clínica incluem melhores resultados para os pacientes a partir da detecção e tratamento precoce da sepse grave.	(BURDICK <i>et al.</i> , 2020)

	antecedência usando um conjunto de dados diverso de 461 hospitais dos EUA			
SEPSE	Uso de métodos de aprendizado de máquina para prever mortalidade hospitalar de pacientes com sepse na UTI	Desenvolver ferramentas baseadas em aprendizado de máquina para prever o risco de morte hospitalar de pacientes com sepse em UTI.	Os modelos baseados em aprendizado de máquina desenvolvidos no estudo tiveram bom desempenho de previsão. Dentre eles, o modelo GBM apresentou o melhor desempenho na predição do risco de óbito hospitalar. Ele tem o potencial de ajudar os médicos na UTI a realizar intervenções clínicas adequadas para pacientes com sepse criticamente enfermos e, portanto, pode ajudar a melhorar o prognóstico dos pacientes com sepse na UTI.	(KONG; LIN; HU, 2020)
SEPSE	O desenvolvimento de um algoritmo de inteligência artificial para o diagnóstico precoce de sepse em unidade de terapia intensiva	Desenvolver de um algoritmo de IA projetado para o diagnóstico de sepse usando recursos pré-selecionados	Usando dados em tempo real, coletados por prontuário eletrônico (EMR), da prática diária da UTI, o algoritmo de IA estabelecido com recursos pré-selecionados e XGBoost pode fornecer um diagnóstico oportuno de sepse com uma precisão superior a 80%. O algoritmo de IA também supera o escore SOFA no diagnóstico de sepse e exibe praticidade, pois os médicos podem implantar o tratamento apropriado mais cedo. A resposta precoce e precisa desse algoritmo de IA resultará em redução de custos, melhoria de resultados e benefícios para os sistemas de saúde, equipe médica e pacientes também.	(YUAN <i>et al.</i> , 2020)
SEPSE	Modelos de aprendizado de máquina para reconhecimento de sepse precoce na unidade de terapia intensiva neonatal usando dados de prontuários eletrônicos prontamente disponíveis	Desenvolver um modelo usando dados prontamente disponíveis do prontuário eletrônico (EHR) capaz de reconhecer a sepse infantil pelo menos 4 horas antes do reconhecimento clínico.	Os modelos de aprendizado de máquina podem identificar bebês com sepse nas horas da UTI Neonatal antes do reconhecimento clínico. As curvas de aprendizagem indicam que a melhoria do modelo pode ser alcançada com exemplos de treinamento adicionais. Recursos de entrada adicionais também podem melhorar o desempenho. Mais pesquisas são necessárias para avaliar melhorias potenciais de desempenho e eficácia clínica em um estudo prospectivo.	(MASINO <i>et al.</i> , 2019)
SEPSE BACTERIANA	A análise não supervisionada da transcriptômica na sepse bacteriana em vários conjuntos de dados revela	Localizar e validar subtipos de sepse generalizáveis usando clustering orientado a dados.	Os três subtipos de sepse podem representar uma estrutura unificadora para a compreensão da heterogeneidade molecular da síndrome da sepse. Um estudo adicional poderia permitir uma abordagem de medicina de precisão de combinar novas terapias	(SWEENEY <i>et al.</i> , 2018)

	três agrupamentos robustos		imunomoduladoras com pacientes sépticos com maior probabilidade de se beneficiar.	
SEPSE	Um modelo de aprendizado de máquina interpretável para previsão precisa de sepse na UTI	Desenvolver e validar um algoritmo Artificial Intelligence Sepsis Expert para a previsão precoce de sepse	Usando os dados disponíveis na UTI em tempo real, o Artificial Intelligence Sepsis Expert pode prever com precisão o início da sepse em um paciente da UTI 4–12 horas antes do reconhecimento clínico. Um estudo prospectivo é necessário para determinar a utilidade clínica do modelo de previsão de sepse proposto .	(NEMATI <i>et al.</i> , 2018)
LESÃO RENAL AGUDA	Aprendizado de máquina para a previsão de responsividade a volume em pacientes com lesão renal aguda oligúrica em cuidados intensivos	Desenvolver um modelo de predição que pode ser usado para diferenciar entre LRA responsiva a volume (VR) e LRA não responsiva a volume (VU).	O modelo foi capaz de diferenciar os pacientes que iriam e não iriam responder à ingestão de fluidos na produção de urina melhor do que um modelo de regressão logística tradicional. Esse resultado sugere que as técnicas de aprendizado de máquina têm potencial para melhorar o desenvolvimento e a validação de modelagem preditiva em pesquisas em cuidados intensivos.	(ZHANG <i>et al.</i> 2019)
LESÃO RENAL AGUDA	Previsão precoce de lesão renal aguda após admissão na UTI usando um painel multivariado de medições fisiológicas	Desenvolver e validar um modelo preditivo clínico multivariável baseado em dados para a detecção precoce de lesão renal aguda (IRA) entre uma grande coorte de pacientes adultos em cuidados intensivos.	Os resultados experimentais sugerem que o modelo tem o potencial de auxiliar os médicos na identificação de pacientes com maior risco de novo início de IRA em ambiente de cuidados intensivos. Ensaios prospectivos com treinamento de modelo independente e coortes de validação externa são necessários para avaliar ainda mais a utilidade clínica desta abordagem e potencialmente instituir intervenções para diminuir a probabilidade de desenvolver IRA.	(ZIMMERMAN <i>et al.</i> , 2019)
LESÃO RENAL AGUDA	Desenvolvimento de um Modelo de Predição de Lesão Renal Aguda em Paciente Interno de Aprendizado de Máquina	Desenvolver um modelo de predição de risco de lesão renal aguda usando dados de prontuários eletrônicos para uso longitudinal em pacientes hospitalizados	Os dados do prontuário eletrônico prontamente disponíveis podem ser usados para prever lesão renal aguda iminente antes das alterações na creatinina sérica com excelente precisão em diferentes localizações de pacientes e creatinina sérica de admissão. O uso em tempo real deste modelo permitiria intervenções precoces para aqueles com alto risco de lesão renal aguda.	(KOYNER <i>et al.</i> , 2018)
LESÃO RENAL AGUDA	Previsão de lesão renal aguda em pacientes com câncer usando dados heterogêneos e irregulares	Prever a ocorrência de lesão renal aguda (LRA) em pacientes com câncer com base no aprendizado de máquina com dados de creatinina sérica	Apresentou como resultado: o método para prever doença renal aguda (LRA) a partir de dados clínicos irregulares e heterogêneos; um modelo para predição que relaxa as restrições dos modelos de predição existentes; fornecimento de extensas evidências empíricas para o desempenho de nossa abordagem usando o conjunto de dados de 21.022 pacientes com câncer.	(PARK <i>et al.</i> , 2018)

ADMISSÃO EM UTI	Previsão de admissão à Unidade de Terapia Intensiva entre pacientes que se apresentam ao departamento de emergência usando aprendizado de máquina e processamento de linguagem natural	Apresentar uma nova abordagem para auxiliar os profissionais de saúde na triagem na estratificação dos pacientes e na identificação daqueles com maior risco de admissão na UTI	Como a atribuição da prioridade de triagem é subjetiva e pode ser variável entre as instituições, os modelos finais foram desenvolvidos usando todas as variáveis clínicas e a queixa principal, com exceção da prioridade de triagem. Para ambos os hospitais, a frequência cardíaca, oximetria de pulso, frequência respiratória e pressão arterial sistólica tiveram alta classificação para a previsão de admissão na UTI	(FERNANDES <i>et al.</i> , 2020)
REDUÇÃO DE FALSOS ALARMES	Redução do alarme de arritmia falsa monomodal e multimodal usando redes neurais recorrentes e convolucionais baseadas na atenção	Propõe um modelo de aprendizado profundo que suprime efetivamente os falsos alarmes nas unidades de terapia intensiva (UTIs) sem ignorar os verdadeiros alarmes usando biossinais monomodais e multimodais	Os resultados da avaliação demonstram que o método proposto obtém melhores resultados em comparação com outros algoritmos existentes para a tarefa de redução de falsos alarmes em UTIs. O método proposto atinge uma sensibilidade de 93,88% e uma especificidade de 92,05% para a classificação de alarmes, considerando três sinais diferentes. Além disso, os experimentos para 5 tipos de alarme separados levam a resultados significativos, onde apenas consideramos um ECG de derivação única	(MOUSAVI; FOTOOHINAS AB; AFGHAH, 2020)
FALSOS ALARMES	Aprendizado de máquina aplicado a informações de multissensores para reduzir a taxa de falsos alarmes na UTI	Desenvolver ferramentas automatizadas de suporte a decisões baseadas em dados, utilizando metodologias de aprendizado de máquina, com o objetivo principal de minimizar a taxa de falsos alarmes (FAR) de monitores de sinais vitais em UTI	Apresentou uma abordagem para redução de FAR que melhora a segurança do paciente, criando um ambiente de UTI mais silencioso e confiável. Essa abordagem também cria um ambiente de trabalho mais adequado para profissionais de saúde e minimiza o efeito negativo da fadiga do alarme.	(HEVER <i>et al.</i> , 2020)
SÍNDROME RESPIRATÓRIA AGUDA	Aprendizado de máquina para estratificação de risco do paciente para síndrome da dificuldade respiratória aguda	desenvolver uma abordagem de aprendizado de máquina para a previsão de ARDS que (a) aproveite os dados do registro eletrônico de saúde (EHR), (b) seja totalmente automatizado e (c) possa ser aplicado em pontos de tempo clinicamente relevantes durante a internação de um paciente.	Os resultados demonstram a viabilidade de uma abordagem de aprendizado de máquina para estratificar o risco de pacientes para SDRA apenas a partir de dados extraídos automaticamente do EHR.	(ZEIBERG <i>et al.</i> , 2019)
VENTILAÇÃO	Usando modelos de aprendizado de máquina para prever a saturação de	O objetivo deste estudo foi determinar se uma máquina de aprendizagem modelo preditivo pode ser treinado	Este estudo piloto de centro único usando modelo preditivo de aprendizado de máquina resultou em um algoritmo com baixa precisão. A comparação de modelos	(GHAZAL <i>et al.</i> , 2019)

	oxigênio após o ajuste do suporte do ventilador em crianças gravemente enfermas: Um estudo piloto de centro único	num conjunto de dados clínicos e usado para prever a saturação de oxigênio de hemoglobina transcutânea 5 min (5 min a SpO <sub>2</sub> ) depois de uma alteração de configuração ventilador.	de aprendizado de máquina mostrou que árvores complexas ensacadas eram uma abordagem promissora. No entanto, é necessário aprimorar esses modelos antes de incorporá-los a sistemas de suporte à decisão clínica. Uma solução potencial para melhorar o modelo preditivo seria aumentar a quantidade de dados disponíveis para limitar o sobre ajuste, que é potencialmente uma das causas de desempenho de classificação ruim para 2 dos três rótulos de classe.	
VENTILAÇÃO	Aprendizagem por reforço inverso para ventilação mecânica inteligente e dosagem de sedativos em unidades de terapia intensiva	Inferir as funções de recompensa que os médicos têm em mente durante suas decisões sobre o desmame da ventilação mecânica e dosagem de sedativos em Unidades de Terapia Intensiva (UTIs).	Conclui que é uma abordagem eficaz para descobrir as funções subjacentes de recompensa dos médicos para projetar melhores protocolos de tratamento no desmame da ventilação e dosagem de sedativos em futuras UTIs.	(YU; LIU; ZHAO, 2019)
PREVISÃO DE HIPERCLOREMIA	Hipercloremia em pacientes gravemente enfermos: associação com desfechos e previsão usando dados de prontuários eletrônicos	Propor um modelo de aprendizado supervisionado para a previsão de hipercloremia em pacientes de UTI.	Os resultados apóiam o uso de modelos preditivos para auxiliar os médicos no monitoramento e prevenção da hipercloremia em pacientes de alto risco e oferece uma oportunidade para melhorar os resultados dos pacientes.	(YEH <i>et al.</i> , 2020)
EVENTOS DE HIPERTENSÃO	Previsão de eventos de hipotensão com assinaturas de sinais vitais fisiológicos na unidade de terapia intensiva	Desenvolver um modelo de aprendizado de máquina para prever o evento inicial de hipotensão entre pacientes de unidade de terapia intensiva (UTI) e projetamos um sistema de alerta para implementação à beira do leito.	Eventos de hipotensão clinicamente significativos na UTI podem ser previstos pelo menos 1 hora antes do episódio inicial de hipotensão. Com um sistema de alerta prático altamente sensível e confiável, uma grande maioria da hipotensão futura pode ser capturada, sugerindo uma utilidade potencial na vida real.	(YOON <i>et al.</i> , 2020)
FENÓTIPOS	Fenótipos cognitivos 1 mês após a alta da UTI em pacientes ventilados mecanicamente: um estudo de coorte observacional prospectivo	Identificar fenótipos cognitivos em sobreviventes gravemente enfermos 1 mês após a alta da UTI usando um método de aprendizado de máquina não supervisionado e contrastá-los com a abordagem clássica de avaliação do comprometimento cognitivo.	Um mês após a alta da UTI, três grupos de pacientes com diferentes fenótipos cognitivos foram identificados por meio de um método de aprendizado de máquina não supervisionado. Essa nova abordagem melhorou a classificação clássica de comprometimento cognitivo em sobreviventes de UTI. Na análise exploratória, sexo, idade e nível de reserva cognitiva surgiram como fatores predisponentes relevantes para o comprometimento cognitivo em pacientes internados em UTI.	(FERNÁNDEZ-GONZALO <i>et al.</i> , 2020)
PARADA CARDÍACA	As redes neurais artificiais melhoram a predição inicial	criar um modelo para previsão precoce de resultados por redes	Um modelo de aprendizado de máquina supervisionado usando RNA previu recuperação neurológica, incluindo	(JOHNSSON <i>et al.</i> , 2020)

	de resultados e a classificação de risco em pacientes com parada cardíaca fora do hospital admitidos em terapia intensiva	neurais artificiais (RNA) e usar esse modelo para investigar os efeitos da intervenção nas classes de gravidade da doença em pacientes com parada cardíaca tratados com gerenciamento de temperatura direcionado (TTM).	sobrevivência de forma excelente, e superou um modelo convencional baseado em regressão logística. Dentre os dados disponíveis no momento da internação, os fatores relacionados ao ambiente pré-hospitalar foram os que mais informaram. A RNA pode ser usada para estratificar uma população de ensaio heterogênea em classes de risco e ajudar a determinar os efeitos da intervenção em subgrupos.	
REDUÇÃO DE EXAMES LABORATORIAIS	Uma solução de aprendizado profundo para recomendar estratégias de redução laboratorial em UTI	Construir um modelo de aprendizado de máquina que prevê resultados de testes de laboratório e fornece uma estratégia de redução de teste de laboratório promissora, usando correlações espaço-temporais.	Demonstrou um modelo de aprendizado de máquina que auxilia os médicos a determinar quais testes de laboratório podem ser omitidos.	(YU <i>et al.</i> , 2020)
DOENÇA FALCIFORME	Uso do aprendizado de máquina para prever a insuficiência orgânica aguda de início precoce em pacientes com doença falciforme em unidades de terapia intensiva em estado crítico: estudo retrospectivo	Testar a hipótese de que fisiomarcadores de aprendizado de máquina podem prever o desenvolvimento de disfunção orgânica em uma amostra de pacientes adultos com DF internados em unidades de terapia intensiva (UTIs).	Demonstrou a viabilidade do uso do aprendizado de máquina para prever a falência aguda de órgãos em adultos hospitalizados com DF. A descoberta de fisiomarcadores salientes por meio de técnicas de aprendizado de máquina tem o potencial de acelerar ainda mais o desenvolvimento e a implementação de protocolos e estratégias de prestação de cuidados inovadores para pacientes clinicamente vulneráveis.	(MOHAMMED <i>et al.</i> , 2020)
PREVISÃO PARADA CARDÍACA	Estrutura baseada em aprendizado de máquina para prever paradas cardíacas em uma unidade de terapia intensiva pediátrica	Explorar os padrões de mudança causalmente relacionados em sinais como frequência cardíaca, frequência respiratória, pressão arterial sistólica e saturação cutânea de oxigênio periférica para avaliar a previsibilidade de paradas cardíacas em pacientes pediátricos gravemente enfermos em terapia intensiva.	Os resultados preliminares obtidos da análise de séries temporais biomédicas multivariadas resultaram em um sistema de alerta precoce baseado em computador eficiente. Das 69 paradas cardíacas, apenas 4 (6%) foram classificadas como previsíveis pelos médicos na revisão pós-evento dos sinais vitais. Portanto, em comparação, uma taxa de predição de 91% obtida pelo método é significativa	(MATAM; DUNCAN; LOWE, 2019)
NEURO CRÍTICOS	Aviso prévio de eventos hipotensivos usando uma rede neural artificial Bayesiana no atendimento neurócritico	Obter uma prova do conceito de que técnicas estatísticas avançadas (aprendizado de máquina) são métodos capazes de fornecer um alerta precoce de eventos hipotensivos iminentes antes que eles ocorram durante o tratamento neuro-crítico.	Mostrou, usando técnicas avançadas de aprendizado de máquina em um ambiente de cuidado neuro-crítico, que seria possível dar às equipes neurointensivas um aviso prévio de eventos hipotensivos em potencial antes que eles surjam, permitindo um monitoramento mais próximo e uma avaliação clínica precoce na tentativa de prevenir o início da hipotensão.	(DONALD <i>et al.</i> , 2019)

DELÍRIO	Predição e detecção precoce de delirium na unidade de terapia intensiva por meio da variabilidade da frequência cardíaca e aprendizado de máquina	Investigar se pacientes delirantes podem ser distinguidos com sucesso de pacientes não delirantes usando a variabilidade da frequência cardíaca (VFC) e aprendizado de máquina.	Mostrou que as alterações autonômicas podem ser uma característica significativa dos pacientes com delirium na UTI, sugerindo o potencial para a predição automática e detecção precoce do delirium com base na VFC com aprendizado de máquina.	(OH <i>et al.</i> , 2018)
PREVISÃO DE CONVULSÕES	Análise de aprendizado de máquina da variabilidade da frequência cardíaca para a detecção de convulsões em sobreviventes de parada cardíaca por coma	Desenvolver um sistema de aquisição de dados de sinais médicos fisiológicos contínuos em tempo real na detecção de convulsões em unidade de terapia intensiva (UTI).	O sistema desenvolvido pode ser usado para identificar eventos de convulsão. Significância: o estudo atual alcançou a detecção de crises em tempo real e superou as limitações anteriores de continuidade e acessibilidade.	(SUNG <i>et al.</i> , 2020)

Fonte: Dados da pesquisa (2021).

## 5 CONCLUSÃO

A produção científica sobre uso do aprendizado de máquina em cuidados intensivos é um tema emergente que enfatiza o grande potencial de aplicações que proporcionam soluções na manutenção da vida nas unidades de terapia intensiva.

Verificou-se através desta pesquisa que o uso do aprendizado de máquina em cuidados intensivos está em crescimento, sendo uma área de pesquisa promissora. O emprego do aprendizado de máquina não substituirá atuação da equipe multiprofissional, e sim servirá como um aliado na decisão destes visando a salvaguarda de vidas.

A originalidade desta pesquisa centrou-se na busca de estudos que abordaram sobre o uso do aprendizado de máquina em cuidados intensivos, bem como no uso da análise bibliométrica e cientométrica para encontrar informações relevantes que contribuem para um direcionamento de pesquisas sobre o tema.

No que se refere aos objetivos desta pesquisa, considera-se que o objetivo geral de caracterizar a produção científica sobre o uso do aprendizado de máquina em cuidados intensivos foi atingido, uma vez que evidenciou o seu uso em várias patologias e/ou condições específicas em unidades de terapia intensiva, bem como a identificação, através de indicadores bibliométricos, dos principais autores, periódicos, instituições, idiomas, países que se dedicam a pesquisar este tema que apresentou considerável crescimento. Também se identificou as redes de colaboração de autores, países e instituições, e foi possível rastrear as tendências temáticas das publicações sobre aprendizado de máquina em cuidados intensivos, e as redes de colaboração científica.

Por meio da referencial teórico, ressalta-se os esforços com as ações do projeto Saúde Digital, a nível mundial, visando a estruturação dos dados gerados e da infraestrutura de tecnologias computacionais, isto colabora para um ganho significativo do armazenamento de dados, o que colabora positivamente para que as máquinas aprendam mais, formando bases de dados compartilhadas, possibilitando decisões mais precisas.

Conforme os resultados obtidos, a produção científica sobre aprendizado de máquina em cuidados intensivos demonstra a emergência do tema, principalmente

nas áreas de Saúde, e que seu desenvolvimento será com o apoio da área de Ciência da Computação, confirmando assim a proposição da tese.

Este estudo apresenta limitações no que se refere à análise da realidade de um grupo de pesquisa específico, bem como de instituições e países específicos.

Sugere-se pesquisas para ampliar a produção científica acerca do tema, bem como para disseminar evidências científicas no contexto do aprendizado de máquina em cuidados intensivos. Indica-se, também, a investigação sobre o que fazer com o grande volume de dados gerados pelos equipamentos que se encontram nas UTIs, bem como os dilemas éticos de uso da inteligência artificial em decisões sobre a vida em cuidados intensivos.

## 6 REFERÊNCIAS

- AKSNES, Dag W.; SIVERTSEN, Gunnar. A criteria-based assessment of the coverage of scopus and web of science. **Journal of Data and Information Science**, [S. l.], v. 4, n. 1, p. 1–21, 2019. DOI: 10.2478/jdis-2019-0001. Disponível em: <http://www.jdis.orghttps://www.degruyter.com/view/j/jdis>. Acesso em: 28 jan. 2021.
- AL-MUFTI, Fawaz et al. **Machine Learning and Artificial Intelligence in Neurocritical Care: a Specialty-Wide Disruptive Transformation or a Strategy for Success****Current Neurology and Neuroscience Reports**Current Medicine Group LLC 1, , 2019. DOI: 10.1007/s11910-019-0998-8. Disponível em: <https://link-springer-com.ez39.periodicos.capes.gov.br/article/10.1007/s11910-019-0998-8>. Acesso em: 20 mar. 2021.
- APERSTEIN, Yehudit; COHEN, Lidor; BENDAVID, Itai; COHEN, Jonathan; GROZOVSKY, Elad; ROTEM, Tammy; SINGER, Pierre. Improved ICU mortality prediction based on SOFA scores and gastrointestinal parameters. **PLOS ONE**, [S. l.], v. 14, n. 9, p. e0222599, 2019. DOI: 10.1371/journal.pone.0222599. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0222599>. Acesso em: 22 mar. 2021.
- ARAÚJO, Carlos Alberto. Bibliometria: evolução histórica e questões atuais. **Em Questão**, Porto Alegre, p. 11–32, 2006. Disponível em: <https://seer.ufrgs.br/EmQuestao/article/view/16/5>. Acesso em: 20 fev. 2021.
- ARAÚJO, Gabriel Aguiar De. **Evolução e distribuição do conhecimento sobre responsabilidade social corporativa: análise cientométrica**. 2017. Universidade do Grande Rio, [S. l.], 2017. Disponível em: <http://localhost:8080//handle/tede/194>. Acesso em: 11 jan. 2021.
- ARCHAMBAULT, Éric; CAMPBELL, David; GINGRAS, Yves; LARIVIÈRE, Vincent. Comparing bibliometric statistics obtained from the web of science and Scopus. **Journal of the American Society for Information Science and Technology**, [S. l.], v. 60, n. 7, p. 1320–1326, 2009. DOI: 10.1002/asi.21062. Disponível em: <http://doi.wiley.com/10.1002/asi.21062>. Acesso em: 21 jan. 2021.
- ARIA, Massimo; CUCCURULLO, Corrado. bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, [S. l.], v. 11, n. 4, p. 959–975, 2017. DOI: 10.1016/j.joi.2017.08.007.
- ARIA, Massimo; CUCCURULLO, Corrado. **Pacote Bibliometrix R**. 2021a. Disponível em: <http://www.bibliometrix.org/>. Acesso em: 30 jan. 2021.
- ARIA, Massimo; CUCCURULLO, Corrado. **Biblioshiny**. 2021b. Disponível em: <http://www.bibliometrix.org/Biblioshiny.html>. Acesso em: 30 jan. 2021.
- ASHLEY, Kevin. **Applied Machine Learning For Health And Fitness - A Practical Guide to Machine Learning with Deep Vision, Sensors and IOT**. Belmont.
- AUSHEV, Alexander et al. Feature selection for the accurate prediction of septic and cardiogenic shock ICU mortality in the acute phase. **PLOS ONE**, [S. l.], v. 13, n. 11, p. e0199089, 2018. DOI: 10.1371/journal.pone.0199089. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0199089>. Acesso em: 22 mar. 2021.
- AZEVEDO, Edjane Guerra De. **Enfermagem em Unidade de Terapia Intensiva**. [s.l.] : AB, 2009.
- BACHELARD, Gaston. **O novo espírito científico**. Rio de Janeiro: Contraponto,

2002.

BI, Wenya Linda et al. Artificial intelligence in cancer imaging: Clinical challenges and applications. **CA: A Cancer Journal for Clinicians**, [S. l.], v. 69, n. 2, p. caac.21552, 2019. DOI: 10.3322/caac.21552. Disponível em:

<https://onlinelibrary.wiley.com/doi/abs/10.3322/caac.21552>. Acesso em: 15 fev. 2021.

BOURDIEU, Pierre. **Os usos sociais da ciência: por uma sociologia clínica do campo científico**. São Paulo: UNESP, 2004.

BRITO, Gislaine do Nascimento; LIMA, Izabel França De. Periódicos Científicos como Fonte de Informação: um estudo na Informação & Sociedade e na Biblionline.

**Folha de Rosto em Biblioteconomia e Ciência da Informação**, [S. l.], v. 1, n. 2, p. 49–60, 2015. Disponível em:

[https://periodicos.ufca.edu.br/ojs/index.php/folhaderosto/article/download/42/55/#:~:text=O periódico é uma fonte,vários autores sobre determinado tema.](https://periodicos.ufca.edu.br/ojs/index.php/folhaderosto/article/download/42/55/#:~:text=O%20peri%C3%B3dico%20%C3%A9%20uma%20fonte,v%C3%A1rios%20autores%20sobre%20determinado%20tema.)

BURDICK, Hoyt et al. Validation of a machine learning algorithm for early severe sepsis prediction: a retrospective study predicting severe sepsis up to 48 h in advance using a diverse dataset from 461 US hospitals. **BMC Medical Informatics and Decision Making**, [S. l.], v. 20, n. 1, p. 276, 2020. DOI: 10.1186/s12911-020-01284-x. Disponível em:

<https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-020-01284-x>. Acesso em: 22 mar. 2021.

CAICEDO-TORRES, William; GUTIERREZ, Jairo. ISeeU: Visually interpretable deep learning for mortality prediction inside the ICU. **Journal of Biomedical Informatics**, [S. l.], v. 98, p. 103269, 2019. DOI: 10.1016/j.jbi.2019.103269.

CALVERT, Jacob S.; PRICE, Daniel A.; CHETTIPALLY, Uli K.; BARTON, Christopher W.; FELDMAN, Mitchell D.; HOFFMAN, Jana L.; JAY, Melissa; DAS, Ritankar. A computational approach to early sepsis detection. **Computers in Biology and Medicine**, [S. l.], v. 74, p. 69–73, 2016. DOI: 10.1016/j.compbimed.2016.05.003.

CAMARGO JR, Kenneth R. De. Editorial Ao vencedor, as batatas? **Physis Revista de Saúde Coletiva**, [S. l.], v. 25, n. 1, p. 9–12, 2015. DOI: 10.1590/S0103-73312014000400001. Disponível em: <http://dx.doi.org/10.1590/S0103-73312014000400001>. Acesso em: 22 mar. 2021.

CARVALHO BARRA, Daniela Couto; PEREIRA DO NASCIMENTO, Eliane Regina; MARTINS, Josiane De Jesus; ALBUQUERQUE, Gelson Luiz; ERDMANN, Alacoque Lorenzini. Evolução histórica e impacto da tecnologia na área da saúde e da enfermagem. **Revista Eletrônica de Enfermagem**, [S. l.], v. 8, n. 3, p. 422–430, 2009. DOI: 10.5216/ree.v8i3.7081. Disponível em:

[http://www.fen.ufg.br/revista/revista8\\_3/v8n3a13.htm](http://www.fen.ufg.br/revista/revista8_3/v8n3a13.htm). Acesso em: 13 jan. 2021.

CASTELLS, Manuel. **A sociedade em rede. A era da informação : economia, sociedade e cultura**. 6. ed. São Paulo.

CERVO, Amado Luiz; BERVIAN, Pedro Alcino; DA SILVA, Roberto. **Metodologia Científica**. 6. ed. São Paulo: Pearson Prentice Hall, 2007.

CHALMERS, Alan F. **O que é Ciência afinal?** São Paulo: Brasiliense, 1993.

CHANG JUNIOR, João et al. Improving preoperative risk-of-death prediction in surgery congenital heart defects using artificial intelligence model: A pilot study.

**PLOS ONE**, [S. l.], v. 15, n. 9, p. e0238199, 2020. DOI:

10.1371/journal.pone.0238199. Disponível em:

<https://dx.plos.org/10.1371/journal.pone.0238199>. Acesso em: 22 mar. 2021.

CHERIFA, Ményssa; PIRRACCHIO, Romain. What every intensivists should know about Big Data and targeted machine learning in the intensive care unit. **Revista Brasileira de Terapia Intensiva**, [S. l.], v. 31, n. 4, p. 444–446, 2019. DOI:

10.5935/0103-507X.20190069. Disponível em:

<http://www.gnresearch.org/doi/10.5935/0103-507X.20190069>. Acesso em: 13 jan. 2021.

CLAVERA, Walter V. **Aprendizado de Máquina (Machine Learning)**. 2019.

Disponível em: <http://www.redesdesaude.com.br/?p=1757>. Acesso em: 23 fev. 2021.

COBB, Adrienne N.; DAUNGJAIBOON, Witawat; BROWNLEE, Sarah A.; BALDEA, Anthony J.; SANFORD, Arthur P.; MOSIER, Michael M.; KUO, Paul C. Seeing the forest beyond the trees: Predicting survival in burn patients with machine learning.

**American Journal of Surgery**, [S. l.], v. 215, n. 3, p. 411–416, 2018. DOI:

10.1016/j.amjsurg.2017.10.027.

CONSELHO FEDERAL DE MEDICINA. **Resolução N° 2.271, de 14 de fevereiro de 2020. Define as unidades de terapia intensiva e unidades de cuidado intermediário conforme sua complexidade e nível de cuidado, determinando a responsabilidade técnica médica, as responsabilidades éticas, habilita.**

BRASÍLIA/DF. Disponível em:

[https://sistemas.cfm.org.br/normas/arquivos/resolucoes/BR/2020/2271\\_2020.pdf](https://sistemas.cfm.org.br/normas/arquivos/resolucoes/BR/2020/2271_2020.pdf).

Acesso em: 13 jan. 2021.

CONSELHO NACIONAL DE SAÚDE. RESOLUÇÃO N° 510, DE 07 DE ABRIL DE 2016. . 7 abr. 2016.

DAROSI, Gilberto Carlos Monteiro; ANDERLE, Daniel Fernando. Mapeamento da Produção Científica Internacional sobre Inteligência de Estado. **Revista ESPACIOS | Vol. 35 (N° 5) Año 2014**, [S. l.], 2014.

DELAHANTY, Ryan J.; KAUFMAN, David; JONES, Spencer S. Development and Evaluation of an Automated Machine Learning Algorithm for In-Hospital Mortality Risk Adjustment Among Critical Care Patients\*. **Critical Care Medicine**, [S. l.], v. 46, n. 6, p. e481–e488, 2018. DOI: 10.1097/CCM.0000000000003011. Disponível em:

<http://journals.lww.com/00003246-201806000-00042>. Acesso em: 22 mar. 2021.

DELIBERATO, Rodrigo Octávio et al. SEVERITAS: An externally validated mortality prediction for critically ill patients in low and middle-income countries. **International Journal of Medical Informatics**, [S. l.], v. 131, p. 103959, 2019. DOI:

10.1016/j.ijmedinf.2019.103959.

DONALD, Rob et al. Forewarning of hypotensive events using a Bayesian artificial neural network in neurocritical care. **Journal of Clinical Monitoring and Computing**, [S. l.], v. 33, n. 1, p. 39–51, 2019. DOI: 10.1007/s10877-018-0139-y.

Disponível em: <https://doi.org/10.1007/s10877-018-0139-y>. Acesso em: 22 mar. 2021.

DRAGOSAVAC, Desanka; ARAÚJO, Sebastião. **Protocolos de Condutas em Terapia Intensiva**. São Paulo: Atheneu, 2014.

EL-RASHIDY, Nora; EL-SAPPAGH, Shaker; ABUHMED, Tamer; ABDELRAZEK,

Samir; EL-BAKRY, Hazem M. Intensive Care Unit Mortality Prediction: An Improved Patient-Specific Stacking Ensemble Model. **IEEE Access**, [S. l.], v. 8, p. 133541–133564, 2020. DOI: 10.1109/ACCESS.2020.3010556.

FERNANDES, Marta; MENDES, Rúben; VIEIRA, Susana M.; LEITE, Francisca; PALOS, Carlos; JOHNSON, Alistair; FINKELSTEIN, Stan; HORNG, Steven; CELL, Leo Anthony. Predicting Intensive Care Unit admission among patients presenting to the emergency department using machine learning and natural language processing. **PLOS ONE**, [S. l.], v. 15, n. 3, p. e0229331, 2020. DOI: 10.1371/journal.pone.0229331. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0229331>. Acesso em: 22 mar. 2021.

FERNÁNDEZ-GONZALO, Sol et al. Cognitive phenotypes 1 month after ICU discharge in mechanically ventilated patients: a prospective observational cohort study. **Critical Care**, [S. l.], v. 24, n. 1, p. 618, 2020. DOI: 10.1186/s13054-020-03334-2. Disponível em: <https://ccforum.biomedcentral.com/articles/10.1186/s13054-020-03334-2>. Acesso em: 22 mar. 2021.

FERREIRA, Valdinéia Barreto. E-science. In: **E-science e políticas públicas para ciência, tecnologia e inovação no Brasil [online]**. Salvador: EDUFBA, 2018. p. 13–30. DOI: 10.7476/9788523218652.0003. Disponível em: <https://doi.org/10.7476/9788523218652.0003>. Acesso em: 30 jan. 2021.

FIRMINO, Daniel Alvarez. **Diagrama de Sankey: o que é, e como fazer no Excel**. 2020. Disponível em: <https://www.opuspesquisa.com/blog/tecnicas/diagrama-sankey/>. Acesso em: 25 fev. 2021.

FOCUS GROUP ON ARTIFICIAL INTELLIGENCE FOR HEALTH, FG-AI4H. **Whitepaper for the ITU/WHO Focus Group on Artificial Intelligence for Health**. 2020. Disponível em: [https://www.itu.int/en/ITU-T/focusgroups/ai4h/Documents/FG-AI4H\\_Whitepaper.pdf](https://www.itu.int/en/ITU-T/focusgroups/ai4h/Documents/FG-AI4H_Whitepaper.pdf). Acesso em: 26 jan. 2021.

GABRIEL JUNIOR, Rene Faustino. **Geração de indicadores de produção e citação científica em revistas de Ciência da Informação: estudo aplicado à base de dados BRAPCI**. 2014. Universidade Estadual Paulista “Julio de Mesquita Filho”, Marília/SP, 2014. Disponível em: <https://repositorio.unesp.br/handle/11449/123338>. Acesso em: 20 fev. 2021.

GENNATAS, Efstathios D. et al. Expert-augmented machine learning. **PNAS - Proceedings of the National Academy of Sciences of the United States of America**, [S. l.], v. 117, n. 9, p. 4571–4577, 2020. DOI: 10.1073/pnas.1906831117/-/DCSupplemental. Disponível em: [www.pnas.org/cgi/doi/10.1073/pnas.1906831117](http://www.pnas.org/cgi/doi/10.1073/pnas.1906831117). Acesso em: 17 mar. 2021.

GHAZAL, Sam; SAUTHIER, Michael; BROSSIER, David; BOUACHIR, Wassim; JOUVET, Philippe A.; NOUMEIR, Rita. Using machine learning models to predict oxygen saturation following ventilator support adjustment in critically ill children: A single center pilot study. **PLOS ONE**, [S. l.], v. 14, n. 2, p. e0198921, 2019. DOI: 10.1371/journal.pone.0198921. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0198921>. Acesso em: 22 mar. 2021.

GHENO, Tatiane Cristina. **Análise de domínio: um estudo das publicações científicas brasileiras**. 2017. Universidade Federal de Santa Catarina, Florianópolis, 2017. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/179000/348756.pdf?sequence>

=1&isAllowed=y. Acesso em: 4 mar. 2021.

GINGRAS, Yves. **Os desvios da avaliação da pesquisa: o bom uso da bibliometria**. Tradução de Carlos Deanne. Rio de Janeiro: Editora da UFRJ, 2016.

GOLDSCHMIDT, Ronaldo Ribeiro. **Inteligência Computacional**. 1. ed. Rio de Janeiro: IST-Rio, 2010.

GRÁCIO, Maria Cláudia Cabrini. Acoplamento bibliográfico e análise de cocitação: revisão teórico-conceitual. **Encontros Bibli: revista eletrônica de biblioteconomia e ciência da informação**, [S. l.], v. 21, n. 47, p. 82–99, 2016. DOI: <https://doi.org/10.5007/1518-2924.2016v21n47p82>. Disponível em: <https://periodicos.ufsc.br/index.php/eb/article/view/1518-2924.2016v21n47p82/32343>. Acesso em: 21 fev. 2021.

GREGOLIN, José Ângelo Rodrigues; HOFFMANN, Wanda Aparecida Machado; FARIA, Leandro Innocentini Lopes De; QUONIAM, Luc; QUEYRAS, Joachim. Análise da produção científica a partir de indicadores bibliométricos. *In*: **INDICADORES DE CIÊNCIA, TECNOLOGIA E INOVAÇÃO EM SÃO PAULO-2004**. São Paulo: FAPESP, 2005. v. 1p. 1–44.

GRUPO DE INTELIGÊNCIA ARTIFICIAL DA PUCRS. **Guia do Hospital Orientado a Dados – Grupo de Inteligência Artificial na Saúde**. 2021. Disponível em: <https://www.inf.pucrs.br/ia-saude/guia-do-hospital-orientado-a-dados/>. Acesso em: 27 jan. 2021.

GUEDES, Vânia L. S.; BORSCHIVER, Suzana. Bibliometria: uma ferramenta estatística para a gestão da informação e do conhecimento em sistemas de informação, de comunicação e de avaliação científica e tecnológica. *In*: ENCONTRO NACIONAL DE CIÊNCIA DA INFORMAÇÃO 2005, Salvador. **Anais [...]**. Salvador p. 1–18. Disponível em: [http://www.cinform-antiores.ufba.br/vi\\_anais/docs/VaniaLSGuedes.pdf](http://www.cinform-antiores.ufba.br/vi_anais/docs/VaniaLSGuedes.pdf). Acesso em: 20 fev. 2021.

GUEDES, Vania Lisboa da Silveira. A Bibliometria e a Gestão da Informação e do Conhecimento Científico e Tecnológico: uma revisão da literatura. **Ponto de Acesso**, [S. l.], v. 6, n. 2, p. 74–109, 2012. Disponível em: <https://periodicos.ufba.br/index.php/revistaici/article/view/5695/4591>. Acesso em: 20 fev. 2021.

HAYASHI, Carlos Roberto Massao. Apontamentos sobre a coleta de dados em estudos bibliométricos e cientométricos. **Filosofia e Educação**, [S. l.], v. 5, n. 2, p. 89–102, 2013. DOI: 10.20396/rfe.v5i2.8635396. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/rfe/article/view/8635396>. Acesso em: 21 jan. 2021.

HESSEN, Johannes. **Teoria do conhecimento**. 2. ed. São Paulo: Martins Fontes, 2003.

HEVER, Gal; COHEN, Liel; O'CONNOR, Michael F.; MATOT, Idit; LERNER, Boaz; BITAN, Yuval. Machine learning applied to multi-sensor information to reduce false alarm rate in the ICU. **Journal of Clinical Monitoring and Computing**, [S. l.], v. 34, n. 2, p. 339–352, 2020. DOI: 10.1007/s10877-019-00307-x. Disponível em: <https://doi.org/10.1007/s10877-019-00307-x>. Acesso em: 22 mar. 2021.

HEY, Tony; TANSLEY, Stewart; TOLLE, Kristin. **O Quarto Paradigma: descobertas científicas na era da eScience**. São Paulo: Oficina de Textos, 2011.

HUANG, Li; SHEA, Andrew L.; QIAN, Huining; MASURKAR, Aditya; DENG, Hao; LIU, Dianbo. Patient clustering improves efficiency of federated machine learning to predict mortality and hospital stay time using distributed electronic medical records. **Journal of Biomedical Informatics**, [S. l.], v. 99, p. 103291, 2019. DOI: 10.1016/j.jbi.2019.103291.

ITU-T. **Grupo de foco em “Inteligência Artificial para a Saúde”**. 2018. Disponível em: <https://www.itu.int/en/ITU-T/focusgroups/ai4h/Pages/default.aspx>. Acesso em: 26 jan. 2021.

IZQUIERDO, Jose Luis; ANCOCHEA, Julio; SORIANO, Joan B. Clinical Characteristics and Prognostic Factors for Intensive Care Unit Admission of Patients with COVID-19: Retrospective Study Using Machine Learning and Natural Language Processing. **Journal of Medical Internet Research**, [S. l.], v. 22, n. 10, p. e21801, 2020. DOI: 10.2196/21801. Disponível em: <https://www.jmir.org/2020/10/e21801>. Acesso em: 22 mar. 2021.

JIE, Zhou; ZHIYING, Zeng; LI, Li. A meta-analysis of Watson for Oncology in clinical application. **Scientific Reports**, [S. l.], v. 11, n. 1, p. 5792, 2021. DOI: 10.1038/s41598-021-84973-5. Disponível em: <http://www.nature.com/articles/s41598-021-84973-5>. Acesso em: 21 mar. 2021.

JOHNSON, Alistair E. W.; GHASSEMI, Mohammad M.; NEMATI, Shamim; NIEHAUS, Katherine E.; CLIFTON, David; CLIFFORD, Gari D. Machine Learning and Decision Support in Critical Care. **Proceedings of the IEEE**, [S. l.], v. 104, n. 2, p. 444–466, 2016. DOI: 10.1109/JPROC.2015.2501978.

JOHNSSON, Jesper et al. Artificial neural networks improve early outcome prediction and risk classification in out-of-hospital cardiac arrest patients admitted to intensive care. **Critical Care**, [S. l.], v. 24, n. 1, p. 474, 2020. DOI: 10.1186/s13054-020-03103-1. Disponível em: <https://ccforum.biomedcentral.com/articles/10.1186/s13054-020-03103-1>. Acesso em: 22 mar. 2021.

KAGERBAUER, S.; BLOBNER, M.; ULM, B.; JUNGWIRTH, B. Tomorrow is already here [1] How machine learning is influencing anaesthesiology and intensive care medicine. **Anesthesiologie und Intensivmedizin**, [S. l.], v. 61, n. 3, p. 85–96, 2020. DOI: 10.19224/ai2020.085.

KANG, Min Woo; KIM, Jayoun; KIM, Dong Ki; OH, Kook Hwan; JOO, Kwon Wook; KIM, Yon Su; HAN, Seung Seok. Machine learning algorithm to predict mortality in patients undergoing continuous renal replacement therapy. **Critical Care**, [S. l.], v. 24, n. 1, p. 42, 2020. DOI: 10.1186/s13054-020-2752-7. Disponível em: <https://ccforum.biomedcentral.com/articles/10.1186/s13054-020-2752-7>. Acesso em: 22 mar. 2021.

KIM, Hyung Jun et al. An easy-to-use machine learning model to predict the prognosis of patients with COVID-19: Retrospective cohort study. **Journal of Medical Internet Research**, [S. l.], v. 22, n. 11, p. e24225, 2020. DOI: 10.2196/24225. Disponível em: <https://www.jmir.org/2020/11/e24225>. Acesso em: 22 mar. 2021.

KIM, Soo Yeon et al. A deep learning model for real-time mortality prediction in critically ill children. **Critical Care**, [S. l.], v. 23, n. 1, p. 279, 2019. DOI: 10.1186/s13054-019-2561-z. Disponível em: <https://ccforum.biomedcentral.com/articles/10.1186/s13054-019-2561-z>. Acesso em:

22 mar. 2021.

KLINE, Adrienne; KLINE, Theresa; ABAD, Zahra Shakeri Hossein; LEE, Joon. Using item response theory for explainable machine learning in predicting mortality in the intensive care unit: Case-based approach. **Journal of Medical Internet Research**, [S. l.], v. 22, n. 9, p. e20268, 2020. DOI: 10.2196/20268. Disponível em: <https://www.jmir.org/2020/9/e20268>. Acesso em: 22 mar. 2021.

KOMOROWSKI, Matthieu. Artificial intelligence in intensive care: are we there yet? **Intensive Care Medicine**, [S. l.], v. 45, n. 9, p. 1298–1300, 2019. DOI: 10.1007/s00134-019-05662-6. Disponível em: <https://doi.org/10.1007/s00134-019-05662-6>. Acesso em: 28 jan. 2021.

KONG, Guilan; LIN, Ke; HU, Yonghua. Using machine learning methods to predict in-hospital mortality of sepsis patients in the ICU. **BMC Medical Informatics and Decision Making**, [S. l.], v. 20, n. 1, p. 251, 2020. DOI: 10.1186/s12911-020-01271-2. Disponível em: <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-020-01271-2>. Acesso em: 22 mar. 2021.

KOYNER, Jay L.; CAREY, Kyle A.; EDELSON, Dana P.; CHURPEK, Matthew M. The Development of a Machine Learning Inpatient Acute Kidney Injury Prediction Model\*. **Critical Care Medicine**, [S. l.], v. 46, n. 7, p. 1070–1077, 2018. DOI: 10.1097/CCM.0000000000003123. Disponível em: <http://journals.lww.com/00003246-201807000-00005>. Acesso em: 22 mar. 2021.

LAURITSEN, Simon Meyer; KALØR, Mads Ellersgaard; KONGSGAARD, Emil Lund; LAURITSEN, Katrine Meyer; JØRGENSEN, Marianne Johansson; LANGE, Jeppe; THIESSON, Bo. Early detection of sepsis utilizing deep learning on electronic health record event sequences. **Artificial Intelligence in Medicine**, [S. l.], v. 104, p. 101820, 2020. DOI: 10.1016/j.artmed.2020.101820.

LI, Q.; CLIFFORD, G. D. Dynamic time warping and machine learning for signal quality assessment of pulsatile signals. **Physiological Measurement**, [S. l.], v. 33, n. 9, p. 1491–1501, 2012. a. DOI: 10.1088/0967-3334/33/9/1491. Disponível em: <https://iopscience.iop.org/article/10.1088/0967-3334/33/9/1491>. Acesso em: 18 jan. 2021.

LI, Qiao; CLIFFORD, Gari D. Signal quality and data fusion for false alarm reduction in the intensive care unit. **Journal of Electrocardiology**, [S. l.], v. 45, n. 6, p. 596–603, 2012. b. DOI: 10.1016/j.jelectrocard.2012.07.015.

LI, Xiang et al. A Time-Phased Machine Learning Model for Real-Time Prediction of Sepsis in Critical Care. **Critical Care Medicine**, [S. l.], v. 48, n. 10, p. e884–e888, 2020. a. DOI: 10.1097/CCM.0000000000004494. Disponível em: <https://journals.lww.com/10.1097/CCM.0000000000004494>. Acesso em: 22 mar. 2021.

LI, Xiaoran; GE, Peilin; ZHU, Jocelyn; LI, Haifang; GRAHAM, James; SINGER, Adam; RICHMAN, Paul S.; DUONG, Tim Q. Deep learning prediction of likelihood of ICU admission and mortality in COVID-19 patients using clinical variables. **PeerJ**, [S. l.], v. 8, p. e10337, 2020. b. DOI: 10.7717/peerj.10337. Disponível em: <https://peerj.com/articles/10337>. Acesso em: 22 mar. 2021.

LIU, Siqi; SEE, Kay Choong; NGIAM, Kee Yuan; CELI, Leo Anthony; SUN, Xingzhi; FENG, Mengling. Reinforcement learning for clinical decision support in critical care:

Comprehensive review. **Journal of Medical Internet Research**, [S. l.], v. 22, n. 7, 2020. DOI: 10.2196/18477. Disponível em: <https://www.jmir.org/2020/7/e18477>. Acesso em: 17 mar. 2021.

LOBO, Luiz Carlos. Inteligência artificial, o Futuro da Medicina e a Educação Médica. **Revista Brasileira de Educação Médica**, [S. l.], v. 42, n. 3, p. 3–8, 2018. DOI: 10.1590/1981-52712015v42n3rb20180115editorial1. Disponível em: <http://dx.doi.org/10.1590/1981-52712015v42n3RB20180115EDITORIAL1>. Acesso em: 17 jan. 2021.

LORENZINI, Elisiane. Pesquisa de métodos mistos nas ciências da saúde. **Revista CUIDARTE**, [S. l.], v. 8, n. 2, p. 1549, 2017. DOI: 10.15649/cuidarte.v8i2.406. Disponível em: [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S2216-09732017000201549&lng=en&nrm=iso&tlng=pt](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S2216-09732017000201549&lng=en&nrm=iso&tlng=pt). Acesso em: 15 mar. 2021.

MACIAS-CHAPULA, Cesar A. O papel da informetria e da cienciometria e sua perspectiva nacional e internacional \*. **Ci. Inf.**, [S. l.], v. 27, n. 2, p. 134–140, 1998. DOI: <https://doi.org/10.1590/S0100-19651998000200005>.

MAO, Qingqing et al. Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU. **BMJ Open**, [S. l.], v. 8, n. 1, p. 17833, 2018. DOI: 10.1136/bmjopen-2017-017833. Disponível em: <http://bmjopen.bmj.com/>. Acesso em: 18 jan. 2021.

MARTELETO, Regina Maria; TOMAÉL, Maria Inês. Metodologia de Análise de Redes Sociais (ARS). In: **Métodos qualitativos de pesquisa em Ciência da Informação**. São Paulo: Polis, 2005.

MASINO, Aaron J.; HARRIS, Mary Catherine; FORSYTH, Daniel; OSTAPENKO, Svetlana; SRINIVASAN, Lakshmi; BONAFIDE, Christopher P.; BALAMUTH, Fran; SCHMATZ, Melissa; GRUNDMEIER, Robert W. Machine learning models for early sepsis recognition in the neonatal intensive care unit using readily available electronic health record data. **PLOS ONE**, [S. l.], v. 14, n. 2, p. e0212665, 2019. DOI: 10.1371/journal.pone.0212665. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0212665>. Acesso em: 22 mar. 2021.

MATAM, B. R.; DUNCAN, Heather; LOWE, David. Machine learning based framework to predict cardiac arrests in a paediatric intensive care unit: Prediction of cardiac arrests. **Journal of Clinical Monitoring and Computing**, [S. l.], v. 33, n. 4, p. 713–724, 2019. DOI: 10.1007/s10877-018-0198-0. Disponível em: <https://doi.org/10.1007/s10877-018-0198-0>. Acesso em: 22 mar. 2021.

MATHUR, Piyush; BURNS, Michael L. Artificial Intelligence in Critical Care. **International Anesthesiology Clinics**, [S. l.], v. 57, n. 2, p. 89–102, 2019. DOI: 10.1097/AIA.000000000000221. Disponível em: <https://journals.lww.com/00004311-201905720-00008>. Acesso em: 21 mar. 2021.

MATTOS, Ana Maria; DIAS, Eduardo Wense. Análise de cocitação de autores: Questões metodológicas. **Brapci - Base de Dados em Ciência da Informação**, [S. l.], v. 11, 2010. Disponível em: <https://www.brapci.inf.br/index.php/article/view/0000010589/61b12f45382ea8d227377501e6c62a94>. Acesso em: 21 fev. 2021.

MAYAMPURATH, Anoop; SANCHEZ-PINTO, L. Nelson; CAREY, Kyle A.; VENABLE, Laura-Ruth; CHURPEK, Matthew. Combining patient visual timelines with deep learning to predict mortality. **PLOS ONE**, [S. l.], v. 14, n. 7, p. e0220640, 2019.

DOI: 10.1371/journal.pone.0220640. Disponível em:

<https://dx.plos.org/10.1371/journal.pone.0220640>. Acesso em: 22 mar. 2021.

MEIRING, Christopher et al. Optimal intensive care outcome prediction over time using machine learning. **PLOS ONE**, [S. l.], v. 13, n. 11, p. e0206862, 2018. DOI: 10.1371/journal.pone.0206862. Disponível em:

<https://dx.plos.org/10.1371/journal.pone.0206862>. Acesso em: 22 mar. 2021.

MERTON, Robert K. **Social Theory and Social Structure**. New York.

MINISTÉRIO DA SAÚDE. **O que é a Saúde Digital?** 2019. Disponível em:

<https://saudedigital.saude.gov.br/>. Acesso em: 26 jan. 2021.

MINISTÉRIO DA SAÚDE. **Estratégia de Saúde Digital para o Brasil 2020-2028**. 2020. Disponível em:

[http://bvsmms.saude.gov.br/bvs/publicacoes/estrategia\\_saude\\_digital\\_Brasil.pdf](http://bvsmms.saude.gov.br/bvs/publicacoes/estrategia_saude_digital_Brasil.pdf). Acesso em: 26 jan. 2021.

MOHAMMED, Akram; PODILA, Pradeep S. B.; DAVIS, Robert L.; ATAGA, Kenneth I.; HANKINS, Jane S.; KAMALESWARAN, Rishikesan. Using machine learning to predict early onset acute organ failure in critically ill intensive care unit patients with sickle cell disease: Retrospective study. **Journal of Medical Internet Research**, [S. l.], v. 22, n. 5, p. e14693, 2020. DOI: 10.2196/14693. Disponível em:

<https://www.jmir.org/2020/5/e14693>. Acesso em: 22 mar. 2021.

MOLINA-AZORIN, Jose F. Mixed Methods Research in Strategic Management.

**Organizational Research Methods**, [S. l.], v. 15, n. 1, p. 33–56, 2012. DOI: 10.1177/1094428110393023. Disponível em:

<http://journals.sagepub.com/doi/10.1177/1094428110393023>. Acesso em: 15 mar. 2021.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos Sobre Aprendizado de Máquina. In: **Sistemas Inteligentes Fundamentos e Aplicações**.

1. ed. Barueri-SP: Manole Ltda, 2003. p. 89–114. Disponível em:

<http://dcm.ffclrp.usp.br/~augusto/publications/2003-sistemas-inteligentes-cap4.pdf>.

MORAL-MUÑOZ, José A.; HERRERA-VIDEVA, Enrique; SANTISTEBAN-ESPEJO, Antonio; COBO, Manuel J. **Software tools for conducting bibliometric analysis in science: An up-to-date review** *Profesional de la Informacion* El Profesional de la Informacion, , 2020. DOI: 10.3145/epi.2020.ene.03. Disponível em:

<https://doi.org/10.3145/epi.2020.ene.03><https://orcid.org/0000-0002-6465-982X>

<https://orcid.org/0000-0002-7922-4984><https://orcid.org/0000-0001-6575-803X>.

Acesso em: 30 jan. 2021.

MOREIRA, Paulo Sergio da Conceição; GUIMARÃES, André José Ribeiro;

TSUNODA, Denise Fukumi. Qual ferramenta bibliométrica escolher? um estudo comparativo entre softwares. **P2P E INOVAÇÃO**, [S. l.], v. 6, p. 140–158, 2020. DOI: 10.21721/p2p.2020v6n2.p140-158. Disponível em:

<https://doi.org/10.21721/p2p.2020v6n2.p140-158>. Acesso em: 30 jan. 2021.

MOUSAVI, Sajad; FOTOOHINASAB, Atiyeh; AFGHAH, Fatemeh. Single-modal and multi-modal false arrhythmia alarm reduction using attention-based convolutional and recurrent neural networks. **PLOS ONE**, [S. l.], v. 15, n. 1, p. e0226990, 2020. DOI: 10.1371/journal.pone.0226990. Disponível em:

<https://dx.plos.org/10.1371/journal.pone.0226990>. Acesso em: 22 mar. 2021.

NEMATI, Shamim; HOLDER, Andre; RAZMI, Fereshteh; STANLEY, Matthew D.; CLIFFORD, Gari D.; BUCHMAN, Timothy G. An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU. **Critical Care Medicine**, [S. l.], v. 46, n. 4, p. 547–553, 2018. DOI: 10.1097/CCM.0000000000002936. Disponível em: <http://journals.lww.com/00003246-201804000-00010>. Acesso em: 18 jan. 2021.

OH, Jooyoung et al. Prediction and early detection of delirium in the intensive care unit by using heart rate variability and machine learning. **Physiological Measurement**, [S. l.], v. 39, n. 3, p. 35004, 2018. DOI: 10.1088/1361-6579/aaab07. Disponível em: <https://doi.org/10.1088/1361-6579/aaab07>. Acesso em: 22 mar. 2021.

OLIVEIRA, Ely Francina Tannuri De. **Estudos métricos da informação no Brasil : indicadores de produção, colaboração, impacto e visibilidade**. Marília: Oficina Universitária, 2018. Disponível em: <https://www.marilia.unesp.br/Home/Publicacoes/estudos-metricos-da-informacao-no-brasil---e-book.pdf>. Acesso em: 21 fev. 2021.

OLIVEIRA, Ely Francina Tannuri; GRACIO, Maria Claudia Cabrini. **Questões métricas em organização da informação**. Marília.

PAN, Pan et al. Prognostic assessment of COVID-19 in the intensive care unit by machine learning methods: Model development and validation. **Journal of Medical Internet Research**, [S. l.], v. 22, n. 11, p. e23128, 2020. DOI: 10.2196/23128. Disponível em: <https://www.jmir.org/2020/11/e23128>. Acesso em: 22 mar. 2021.

PARK, Namyong; KANG, Eunjeong; PARK, Minsu; LEE, Hajeong; KANG, Hee-Gyung; YOON, Hyung-Jin; KANG, U. Predicting acute kidney injury in cancer patients using heterogeneous and irregular data. **PLOS ONE**, [S. l.], v. 13, n. 7, p. e0199839, 2018. DOI: 10.1371/journal.pone.0199839. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0199839>. Acesso em: 22 mar. 2021.

PECH, Gerson; DELGADO, Catarina. Assessing the publication impact using citation data from both Scopus and WoS databases: an approach validated in 15 research fields. **Scientometrics**, [S. l.], v. 125, n. 2, p. 909–924, 2020. DOI: 10.1007/s11192-020-03660-w. Disponível em: <https://doi.org/10.1007/s11192-020-03660-w>. Acesso em: 28 jan. 2021.

PIMENTA, Fabiana Guerra; ALVIM, André Luiz; MEIRELLES, Paulo. Técnicas de aprendizagem de máquina aplicadas à identificação de pacientes com sepse. **Journal Infection Control - Official Journal of the Brazilian Association of Infection Control and Hospital Epidemiology Professionals**, [S. l.], v. 9, n. 1, p. 32–36, 2020. Disponível em: [https://jic-abih.com.br/index.php/jic/issue/viewFile/43/pdf\\_4](https://jic-abih.com.br/index.php/jic/issue/viewFile/43/pdf_4). Acesso em: 23 fev. 2021.

PINHEIRO, Guilherme Emanuel Weiss; SANTOS, Angela Maria Pereira Dos; KANTORSKI, Luciane Prado. Análise da produção de estudos com métodos mistos na avaliação de serviços de saúde mental. **Revista de Enfermagem da UFSM**, [S. l.], v. 9, p. e3, 2019. DOI: 10.5902/2179769238739.

POLLARD, Tom J.; JOHNSON, Alistair E. W.; RAFFA, Jesse D.; CELI, Leo A.; MARK, Roger G.; BADAWI, Omar. The eICU collaborative research database, a freely available multi-center database for critical care research. **Scientific Data**, [S. l.], v. 5, n. 1, p. 1–13, 2018. DOI: 10.1038/sdata.2018.178. Disponível em: <https://www.nature.com/articles/sdata2018178>. Acesso em: 18 jan. 2021.

POPPER, Karl. **A Lógica da Pesquisa Científica**. São Paulo.

RESNIZKY, Hernan G. **Learning Shiny: Make the most of R's dynamic capabilities and create web applications with Shiny**. 1. ed. Birmingham: Packt Publishing, 2015.

ROMANCINI, Richard. O QUE É UMA CITAÇÃO? A análise de citações na ciência 1. **Intexto**, [S. l.], v. 0, n. 23, p. 5–17, 2010. Disponível em: <https://seer.ufrgs.br/intexto/article/view/15885>. Acesso em: 21 fev. 2021.

RSTUDIO. **R & Python: A Love Story - RStudio**. 2021. Disponível em: <https://rstudio.com/solutions/r-and-python/>. Acesso em: 30 jan. 2021.

RUSSELL, Stuart; NORVIG, Peter. **Artificial Intelligence A Modern Approach Third Edition**. 3. ed. New Jersey: Pearson Education, 2010.

RYAN, Logan et al. Mortality prediction model for the triage of COVID-19, pneumonia, and mechanically ventilated ICU patients: A retrospective study. **Annals of Medicine and Surgery**, [S. l.], v. 59, p. 207–216, 2020. DOI: 10.1016/j.amsu.2020.09.044.

SANTOS, Hellen Geremias Dos; ZAMPIERI, Fernando Godinho; NORMILIO-SILVA, Karina; SILVA, Gisela Tunes Da; LIMA, Antonio Carlos Pedrosa De; CAVALCANTI, Alexandre Biasi; CHIAVEGATTO FILHO, Alexandre Dias Porto. Machine learning to predict 30-day quality-adjusted survival in critically ill patients with cancer. **Journal of Critical Care**, [S. l.], v. 55, p. 73–78, 2020. DOI: 10.1016/j.jcrc.2019.10.015.

SANTOS, Paula Wivianne Quirino Dos; ALBUQUERQUE, João Pedro Silva De. Almetria: Uma nova lente para os estudos métricos da informação. **Biblionline**, [S. l.], v. 13, n. 3, p. 3–12, 2017. Disponível em: <https://periodicos.ufpb.br/ojs2/index.php/biblio/article/view/35874/19240>. Acesso em: 20 fev. 2021.

SANTOS, Raimundo Nonato Macedo Dos. Produção científica: por que medir? o que medir? **RDBCI: Revista Digital de Biblioteconomia e Ciência da Informação**, [S. l.], v. 1, n. 1, p. 22, 2004. DOI: 10.20396/rdbci.v1i1.2087. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/rdbci/article/view/2087>. Acesso em: 21 jan. 2021.

SCHLINZ, Marcos. **O que é UTI (Unidade de Terapia Intensiva)?** 2016. Disponível em: <https://www.iespe.com.br/blog/o-que-e-unidade-de-terapia-intensiva/>. Acesso em: 15 fev. 2021.

SCHMIDT, Diogo; DA SILVA, Denise Bandeira; DA COSTA, Cristiano André; RIGHI, Rodrigo da Rosa. Um Modelo de Predição de Mortalidade em Unidades de Terapia Intensiva Baseado em Deep Learning. *In*: ANAIS DO XVIII SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS) 2020, **Anais [...]**. : Sociedade Brasileira de Computacao - SB, 2020. DOI: 10.5753/sbcas.2018.3677. Disponível em: <https://sol.sbc.org.br/index.php/sbcas/article/view/3677>. Acesso em: 21 mar. 2021.

SCHUCH, Cintia Renata; SCHERER, Juliane de Souza. Uso de Inteligência Artificial na avaliação de queimaduras em pele humana. *In*: ANAIS DO VIII CBED - CONGRESSO BRASILEIRO DE ENFERMAGEM EM DERMATOLOGIA - ONLINE 2020 2020, Online. **Anais [...]**. Online p. 105–108. Disponível em: [http://www.revistapellesana.com.br/Revistas/Anais\\_CBED\\_2020.pdf](http://www.revistapellesana.com.br/Revistas/Anais_CBED_2020.pdf). Acesso em: 23 fev. 2021.

SCHWAB, Patrick; SCHÜTTE, August Du Mont; DIETZ, Benedikt; BAUER, Stefan. **Clinical Predictive Models for COVID-19: Systematic Study** *Journal of Medical Internet Research* Xiv, , 2020. DOI: 10.2196/21439. Disponível em: <https://www.jmir.org/2020/10/e21439>. Acesso em: 22 mar. 2021.

SCIMAGO, Grupo. El índice h de Hirsch: su aplicación a algunos de los científicos españoles más destacados. **El Profesional de la Información**, [S. l.], v. 16, n. 1, p. 47, 2016. DOI: 10.3145/epi.2007.ene.05. Disponível em: <http://dx.doi.org/10.3145/epi.2007.ene.05>. Acesso em: 3 mar. 2021.

SCOTT, Ian A.; COIERA, Enrico W. Can AI help in the fight against COVID-19? **Medical Journal of Australia**, [S. l.], v. 213, n. 10, p. 439- 441.e2, 2020. DOI: 10.5694/mja2.50821.

SHEIKHALISHAHI, Seyedmostafa; BALARAMAN, Vevake; OSMANI, Venet. Benchmarking machine learning models on multi-centre eICU critical care dataset. **PLOS ONE**, [S. l.], v. 15, n. 7, p. e0235424, 2020. DOI: 10.1371/journal.pone.0235424. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0235424>. Acesso em: 17 mar. 2021.

SHIMIZU, Hideyuki; NAKAYAMA, Keiichi I. Artificial intelligence in oncology. **Cancer Science**, [S. l.], v. 111, n. 5, p. 1452–1460, 2020. DOI: 10.1111/cas.14377. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/cas.14377>. Acesso em: 21 mar. 2021.

SILVA, Carlos Roberto Lyra Da; SILVA, Roberto Carlos Lyra Da; FRANCISCO, Márcio Tadeu Ribeiro. Unidades de Cuidados Intensivos. *In: Fundamentos do uso de Tecnologias na Enfermagem*. 1. ed. São Caetano do Sul - SP: Yendis, 2006. p. 149–252.

SILVA, Edna Lúcia Da. Rede científica e a construção do conhecimento. **Brapci - Base de Dados em Ciência da Informação | Informação e Sociedade: Estudos**, Rio Grande do Sul, v. 12, n. 1, p. 120–148, 2002. Disponível em: <https://brapci.inf.br/index.php/article/view/0000001064/7d917fcbb7a27d50fbd33c87af22f60/>. Acesso em: 21 fev. 2021.

SILVA, Fernanda Ferreira Da. **Redes de colaboração científica nos cursos de graduação em Biblioteconomia no Estado de São Paulo: interseções entre graduação e pós-graduação**. 2018. Universidade de São Paulo | Escola de Comunicações e Artes, São Paulo, 2018. Disponível em: <https://www.teses.usp.br/teses/disponiveis/27/27151/tde-27022019-150805/publico/FernandaFerreiradaSilvaVC.pdf>. Acesso em: 21 fev. 2021.

SILVA, Márcia Regina Da; HAYASHI, Carlos Roberto Massao; HAYASHI, Maria Cristina Piumbato Innocentini. Análise bibliométrica e cientométrica: desafios para especialistas que atuam no campo. **InCID: Revista de Ciência da Informação e Documentação**, [S. l.], v. 2, n. 1, p. 110–129, 2011. DOI: 10.11606/issn.2178-2075.v2i1p110-129. Disponível em: <https://www.revistas.usp.br/incid/article/view/42337>. Acesso em: 21 jan. 2021.

SPINAK, Ernesto. Indicadores cientométricos. **Ci. Inf.**, Brasília, v. 27, n. 2, p. 141–148, 1998. Disponível em: <https://www.scielo.br/pdf/ci/v27n2/spinak.pdf>. Acesso em: 8 fev. 2021.

SUNG, Chih Wei et al. Machine Learning Analysis of Heart Rate Variability for the Detection of Seizures in Comatose Cardiac Arrest Survivors. **IEEE Access**, [S. l.], v.

8, p. 160515–160525, 2020. DOI: 10.1109/ACCESS.2020.3020742. Disponível em: <https://ieeexplore.ieee.org/document/9181556/>. Acesso em: 22 mar. 2021.

SWEENEY, Timothy E. et al. Unsupervised Analysis of Transcriptomics in Bacterial Sepsis Across Multiple Datasets Reveals Three Robust Clusters. **Critical Care Medicine**, [S. l.], v. 46, n. 6, p. 915–925, 2018. DOI: 10.1097/CCM.0000000000003084. Disponível em: <http://journals.lww.com/00003246-201806000-00011>. Acesso em: 22 mar. 2021.

TEMKO, A.; THOMAS, E.; MARNANE, W.; LIGHTBODY, G.; BOYLAN, G. EEG-based neonatal seizure detection with Support Vector Machines. **Clinical Neurophysiology**, [S. l.], v. 122, n. 3, p. 464–473, 2011. DOI: 10.1016/j.clinph.2010.06.034.

TERRY, Cynthia L.; WEAVER, Aurora. **Enfermagem em terapia intensiva desmistificada – um guia de aprendizado**. Porto Alegre: AMGH, 2013.

TOLEDO, César de Alencar Arnaut De; SKALINSKI JUNIOR, Oriomar. A IMPRENSA PERIÓDICA COMO FONTE PARA A HISTÓRIA DA EDUCAÇÃO: TEORIA E MÉTODO. **Revista HISTEDBR On-line**, [S. l.], n. 48, p. 255–268, 2012. Disponível em: <https://webcache.googleusercontent.com/search?q=cache:PpqnQztLd-EJ:https://periodicos.sbu.unicamp.br/ojs/index.php/histedbr/article/download/864002/07580/0+&cd=13&hl=pt-BR&ct=clnk&gl=br>. Acesso em: 25 fev. 2021.

TRAN, Nam K.; SEN, Soman; PALMIERI, Tina L.; LIMA, Kelly; FALWELL, Stephanie; WAJDA, Jeffery; RASHIDI, Hooman H. Artificial intelligence and machine learning for predicting acute kidney injury in severely burned patients: A proof of concept. **Burns**, [S. l.], v. 45, n. 6, p. 1350–1358, 2019. DOI: 10.1016/j.burns.2019.03.021.

URBIZAGASTEGUI, Ruben. A produtividade dos autores sobre a Lei de Lotka. **Ci. Inf**, [S. l.], v. 37, n. 2, p. 87–102, 2008. Disponível em: <https://www.scielo.br/pdf/ci/v37n2/a07v37n2.pdf>. Acesso em: 20 fev. 2021.

VANTI, Nadia Aurora Peres. Da bibliometria à webometria: uma exploração conceitual dos mecanismos utilizados para medir o registro da informação e a difusão do conhecimento. **Ciência da Informação**, [S. l.], v. 31, n. 2, p. 369–379, 2002. DOI: 10.1590/s0100-19652002000200016. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0100-19652002000200016&lng=en&nrm=iso&tlng=pt](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-19652002000200016&lng=en&nrm=iso&tlng=pt). Acesso em: 22 jan. 2021.

VANZ, Samile Andréa de Souza; CAREGNATO, Sônia Elisa. Estudos de Citação: uma ferramenta para entender a comunicação científica. **Em Questão**, [S. l.], v. 9, n. 2, p. 295–307, 2003. Disponível em: <https://seer.ufrgs.br/EmQuestao/article/view/75/35>. Acesso em: 21 fev. 2021.

VERA-BACETA, Miguel Angel; THELWALL, Michael; KOUSHA, Kayvan. **Web of Science and Scopus language coverage Scientometrics** Springer Netherlands, , 2019. DOI: 10.1007/s11192-019-03264-z. Disponível em: <https://doi.org/10.1007/s11192-019-03264-z>. Acesso em: 28 jan. 2021.

VINKLER, Péter. **The Evaluation of Research by Scientometric Indicators**. [s.l.] : Elsevier, 2010. Disponível em: <https://www.sciencedirect.com/book/9781843345725/the-evaluation-of-research-by-scientometric-indicators>. Acesso em: 28 jan. 2021.

YE, Jiancheng; YAO, Liang; SHEN, Jiahong; JANARTHANAM, Rethavathi; LUO, Yuan. Predicting mortality in critically ill patients with diabetes using machine learning and clinical notes. **BMC Medical Informatics and Decision Making**, [S. l.], v. 20, n. S11, p. 295, 2020. DOI: 10.1186/s12911-020-01318-4. Disponível em: <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-020-01318-4>. Acesso em: 22 mar. 2021.

YEH, Pete; PAN, Yiheng; SANCHEZ-PINTO, L. Nelson; LUO, Yuan. Hyperchloremia in critically ill patients: association with outcomes and prediction using electronic health record data. **BMC Medical Informatics and Decision Making**, [S. l.], v. 20, n. S14, p. 302, 2020. DOI: 10.1186/s12911-020-01326-4. Disponível em: <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-020-01326-4>. Acesso em: 22 mar. 2021.

YOON, Joo Heung; JEANSELME, Vincent; DUBRAWSKI, Artur; HRVNAK, Marilyn; PINSKY, Michael R.; CLERMONT, Gilles. Prediction of hypotension events with physiologic vital sign signatures in the intensive care unit. **Critical Care**, [S. l.], v. 24, n. 1, p. 661, 2020. DOI: 10.1186/s13054-020-03379-3. Disponível em: <https://ccforum.biomedcentral.com/articles/10.1186/s13054-020-03379-3>. Acesso em: 22 mar. 2021.

YU, Chao; LIU, Jiming; ZHAO, Hongyi. Inverse reinforcement learning for intelligent mechanical ventilation and sedative dosing in intensive care units. **BMC Medical Informatics and Decision Making**, [S. l.], v. 19, n. S2, p. 57, 2019. DOI: 10.1186/s12911-019-0763-6. Disponível em: <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-019-0763-6>. Acesso em: 21 mar. 2021.

YU, Lishan; LI, Linda; BERNSTAM, Elmer; JIANG, Xiaoqian. A deep learning solution to recommend laboratory reduction strategies in ICU. **International Journal of Medical Informatics**, [S. l.], v. 144, p. 104282, 2020. DOI: 10.1016/j.ijmedinf.2020.104282.

YUAN, Kuo Ching; TSAI, Lung Wen; LEE, Ko Han; CHENG, Yi Wei; HSU, Shou Chieh; LO, Yu Sheng; CHEN, Ray Jade. The development an artificial intelligence algorithm for early sepsis diagnosis in the intensive care unit. **International Journal of Medical Informatics**, [S. l.], v. 141, p. 104176, 2020. DOI: 10.1016/j.ijmedinf.2020.104176.

ZEIBERG, Daniel; PRAHLAD, Tejas; NALLAMOTHU, Brahmajee K.; IWASHYNA, Theodore J.; WIENS, Jenna; SJODING, Michael W. Machine learning for patient risk stratification for acute respiratory distress syndrome. **PLOS ONE**, [S. l.], v. 14, n. 3, p. e0214465, 2019. DOI: 10.1371/journal.pone.0214465. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0214465>. Acesso em: 22 mar. 2021.

ZIMMERMAN, Lindsay P.; REYFMAN, Paul A.; SMITH, Angela D. R.; ZENG, Zexian; KHO, Abel; SANCHEZ-PINTO, L. Nelson; LUO, Yuan. Early prediction of acute kidney injury following ICU admission using a multivariate panel of physiological measurements. **BMC Medical Informatics and Decision Making**, [S. l.], v. 19, n. S1, p. 16, 2019. DOI: 10.1186/s12911-019-0733-z. Disponível em: <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-019-0733-z>. Acesso em: 22 mar. 2021.

ZIVIANI, Nivio. A quarta revolução tecnológica. [S. l.], 2017. Disponível em: [https://www.prodemge.gov.br/images/com\\_arismartbook/download/19/revista\\_17.pdf](https://www.prodemge.gov.br/images/com_arismartbook/download/19/revista_17.pdf)

. Acesso em: 26 jan. 2021.

ZUPIC, Ivan; ČATER, Tomaz. Bibliometric Methods in Management and Organization. **Organizational Research Methods**, [S. l.], v. 18, n. 3, p. 429–472, 2015. DOI: 10.1177/1094428114562629. Disponível em: <http://journals.sagepub.com/doi/10.1177/1094428114562629>. Acesso em: 20 fev. 2021.

## APÊNDICES

### APÊNDICE A – IDENTIFICAÇÃO DO *CORPUS* ANALISADO CONTENDO 568 DOCUMENTOS

Nº sequencia) Autores., Título do documento (ano) Fonte, . DOI, organizados de maneira decrescente por ano.

- 1) Liu, K.D., Goldstein, S.L., Vijayan, A., Parikh, C.R., Kashani, K., Okusa, M.D., Agarwal, A., Cerdá, J., AkiNow initiative: Recommendations for awareness, recognition, and management of aki (2020) Clinical Journal of the American Society of Nephrology, . DOI: 10.2215/CJN.15611219
- 2) Zhang, S., Wu, Z., Chang, W., Liu, F., Xie, J., Yang, Y., Qiu, H. Classification of Patients With Sepsis According to Immune Cell Characteristics: A Bioinformatic Analysis of Two Cohort Studies (2020) Frontiers in Medicine, . DOI: 10.3389/fmed.2020.598652
- 3) Bi, S., Zhang, L., Chen, J., Huang, L., Zeng, S., Jia, J., Wen, S., Cao, Y., Wang, S., Xu, X., Ling, F., Zhao, X., Zhao, Y., Zhu, Q., Qi, H., Zhang, L., Li, H., Du, L., Wang, Z., Chen, D. Development and validation of predictive models for vaginal birth after cesarean delivery in china (2020) Medical Science Monitor, . DOI: 10.12659/MSM.927681
- 4) Bulgarelli, L., Deliberato, R.O., Johnson, A.E.W. Prediction on critically ill patients: The role of “big data” (2020) Journal of Critical Care, . DOI: 10.1016/j.jc.2020.07.017
- 5) Siu, B.M.K., Kwak, G.H., Ling, L., Hui, P. Predicting the need for intubation in the first 24 h after critical care admission using machine learning approaches (2020) Scientific Reports, . DOI: 10.1038/s41598-020-77893-3
- 6) Raita, Y., Camargo, C.A., Jr., Macias, C.G., Mansbach, J.M., Piedra, P.A., Porter, S.C., Teach, S.J., Hasegawa, K. Machine learning-based prediction of acute severity in infants hospitalized for bronchiolitis: a multicenter prospective study (2020) Scientific Reports, . DOI: 10.1038/s41598-020-67629-8
- 7) Chiew, C.J., Liu, N., Wong, T.H., Sim, Y.E., Abdullah, H.R. Utilizing Machine Learning Methods for Preoperative Prediction of Postsurgical Mortality and Intensive Care Unit Admission (2020) Annals of surgery, . DOI: 10.1097/SLA.0000000000003297
- 8) Yu, L., Li, L., Bernstam, E., Jiang, X. A deep learning solution to recommend laboratory reduction strategies in ICU (2020) International Journal of Medical Informatics, . DOI: 10.1016/j.ijmedinf.2020.104282
- 9) Zhai, Q., Lin, Z., Ge, H., Liang, Y., Li, N., Ma, Q., Ye, C. Using machine learning tools to predict outcomes for emergency department intensive care unit patients (2020) Scientific Reports, . DOI: 10.1038/s41598-020-77548-
- 10) Ye, J., Yao, L., Shen, J., Janarthanam, R., Luo, Y. Predicting mortality in critically ill patients with diabetes using machine learning and clinical notes (2020) BMC Medical Informatics and Decision Making, . DOI: 10.1186/s12911-020-01318-4
- 11) Le, S., Pellegrini, E., Green-Saxena, A., Summers, C., Hoffman, J., Calvert, J., Das, R. Supervised machine learning for the early prediction of acute respiratory distress syndrome (ARDS) (2020) Journal of Critical Care, .DOI: 10.1016/j.jc.2020.07.019
- 12) Su, L., Zhang, Z., Zheng, F., Pan, P., Hong, N., Liu, C., He, J., Zhu, W., Long, Y., Liu, D. Five novel clinical phenotypes for critically ill patients with mechanical ventilation in intensive care units: a retrospective and multi database study (2020) Respiratory Research, . DOI: 10.1186/s12931-020-01588-6
- 13) Yoon, J.H., Jeanselme, V., Dubrawski, A., Hravnak, M., Pinsky, M.R., Clermont, G. Prediction of hypotension events with physiologic vital sign signatures in the intensive care unit (2020) Critical Care, . DOI: 10.1186/s13054-020-03379-3
- 14) De Vlieger, G., Kashani, K., Meyfroidt, G. Artificial intelligence to guide management of acute kidney injury in the ICU: a narrative review (2020) Current opinion in critical care, .DOI: 10.1097/MCC.0000000000000775
- 15) Fernández-Gonzalo, S., Navarra-Ventura, G., Bacardit, N., Gomà Fernández, G., de Haro, C., Subirà, C., López-Aguilar, J., Magrans, R., Sarlabous, L., Aquino Esperanza, J., Jodar, M., Rué, M., Ochagavía, A., Palao, D.J., Fernández, R., Blanch, L. Cognitive phenotypes 1 month after ICU discharge in mechanically ventilated patients: a prospective observational cohort study (2020) Critical Care, . DOI: 10.1186/s13054-020-03334-2
- 16) Goldsmith, M.P., Schwartz, E.J., Hehir, D.A. Data analytics in pediatric cardiac intensive care: How and what can we learn to improve care (2020) Progress in Pediatric Cardiology, .DOI: 10.1016/j.ppedcard.2020.101317
- 17) Zhang, Y., Zhu, S., Yuan, Z., Li, Q., Ding, R., Bao, X., Zhen, T., Fu, Z., Fu, H., Xing, K., Yuan, H., Chen, T. Risk factors and socio-economic burden in pancreatic ductal adenocarcinoma operation: a machine learning based analysis(2020) BMC Cancer, . DOI: 10.1186/s12885-020-07626-2

- 18) Burdick, H., Pino, E., Gabel-Comeau, D., Gu, C., Roberts, J., Le, S., Slote, J., Saber, N., Pellegrini, E., Green-Saxena, A., Hoffman, J., Das, R. Validation of a machine learning algorithm for early severe sepsis prediction: a retrospective study predicting severe sepsis up to 48 h in advance using a diverse dataset from 461 US hospitals (2020) BMC Medical Informatics and Decision Making, . DOI: 10.1186/s12911-020-01284-x
- 19) Langer, T., Favarato, M., Giudici, R., Bassi, G., Garberi, R., Villa, F., Gay, H., Zeduri, A., Bragagnolo, S., Molteni, A., Beretta, A., Corradin, M., Moreno, M., Vismara, C., Perno, C.F., Buscema, M., Grossi, E., Fumagalli, R. Development of machine learning models to predict RT-PCR results for severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) in patients with influenza-like symptoms using only basic clinical data (2020) Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine, . DOI: 10.1186/s13049-020-00808-8
- 20) Zhang, D., Yin, C., Zeng, J., Yuan, X., Zhang, P. Combining structured and unstructured data for predictive models: a deep learning approach (2020) BMC Medical Informatics and Decision Making, . DOI: 10.1186/s12911-020-01297-6
- 21) Carra, G., Salluh, J.I.F., da Silva Ramos, F.J., Meyfroidt, G. Data-driven ICU management: Using Big Data and algorithms to improve outcomes (2020) Journal of Critical Care, . DOI: 10.1016/j.jcrc.2020.09.002
- 22) Serviá, L., Montserrat, N., Badia, M., Llopart-Pou, J.A., Barea-Mendoza, J.A., Chico-Fernández, M., Sánchez-Casado, M., Jiménez, J.M., Mayor, D.M., Trujillano, J. Machine learning techniques for mortality prediction in critical traumatic patients: anatomic and physiologic variables from the RETRAUCI study (2020) BMC Medical Research Methodology, . DOI: 10.1186/s12874-020-01151-3
- 23) Yeh, P., Pan, Y., Sanchez-Pinto, L.N., Luo, Y. Hyperchloremia in critically ill patients: association with outcomes and prediction using electronic health record data (2020) BMC Medical Informatics and Decision Making, . DOI: 10.1186/s12911-020-01326-4
- 24) Koshimizu, H., Kojima, R., Okuno, Y. Future possibilities for artificial intelligence in the practical management of hypertension (2020) Hypertension Research, .DOI: 10.1038/s41440-020-0498-x
- 25) Tran, A., Walsh, C.J., Batt, J., dos Santos, C.C., Hu, P.A machine learning-based clinical tool for diagnosing myopathy using multi-cohort microarray expression profiles (2020) Journal of Translational Medicine, . DOI: 10.1186/s12967-020-02630-3
- 26) Duncan, H.P., Fule, B., Rice, I., Sitch, A.J., Lowe, D. Wireless monitoring and real-time adaptive predictive indicator of deterioration (2020) Scientific Reports, .DOI: 10.1038/s41598-020-67835-4
- 27) Tang, S., Davarmanesh, P., Song, Y., Koutra, D., Sjoding, M.W., Wiens, J. Democratizing EHR analyses with FIDDLE: A flexible data-driven preprocessing pipeline for structured clinical data (2020) Journal of the American Medical Informatics Association, .DOI: 10.1093/jamia/ocaa139
- 28) Pirracchio, R., Hubbard, A., Sprung, C.L., Chevret, S., Annane, D., Rapid Recognition of Corticosteroid Resistant or Sensitive Sepsis (RECORDS) Collaborators Assessment of Machine Learning to Estimate the Individual Treatment Effect of Corticosteroids in Septic Shock (2020) JAMA network open, . DOI: 10.1001/jamanetworkopen.2020.29050
- 29) Moffet, E.W., Subramaniam, T., Hirsch, L.J., Gilmore, E.J., Lee, J.W., Rodriguez-Ruiz, A.A., Haider, H.A., Dhakar, M.B., Jadeja, N., Osman, G., Gaspard, N., Struck, A.F. Validation of the 2HELPS2B Seizure Risk Score in Acute Brain Injury Patients (2020) Neurocritical Care, . DOI: 10.1007/s12028-020-00939-x
- 30) Ducharme, J., Self, W.H., Osborn, T.M., Ledebor, N.A., Romanowsky, J., Sweeney, T.E., Liesenfeld, O., Rothman, R.E. A multi-mrna host-response molecular blood test for the diagnosis and prognosis of acute infections and sepsis: Proceedings from a clinical advisory panel (2020) Journal of Personalized Medicine, .DOI: 10.3390/jpm10040266
- 31) Hawkins, B.E., Huie, J.R., Almeida, C., Chen, J., Ferguson, A.R. Data Dissemination: Shortening the Long Tail of Traumatic Brain Injury Dark Data(2020) Journal of Neurotrauma, . DOI: 10.1089/neu.2018.6192
- 32) Li, X., Ge, P., Zhu, J., Li, H., Graham, J., Singer, A., Richman, P.S., Duong, T.Q. Deep learning prediction of likelihood of ICU admission and mortality in COVID-19 patients using clinical variables (2020) PeerJ, . DOI: 10.7717/peerj.10337
- 33) Kim, H.-J., Han, D., Kim, J.-H., Kim, D., Ha, B., Seog, W., Lee, Y.-K., Lim, D., Hong, S.O., Park, M.-J., Heo, J.N. An easy-to-use machine learning model to predict the prognosis of patients with COVID-19: Retrospective cohort study (2020) Journal of Medical Internet Research, . DOI: 10.2196/24225
- 34) Hagan, R., Gillan, C.J., Spence, I., McAuley, D., Shyamsundar, M. Comparing regression and neural network techniques for personalized predictive analytics to promote lung protective ventilation in Intensive Care Units (2020) Computers in Biology and Medicine, . DOI: 10.1016/j.combiomed.2020.104030
- 35) Pan, P., Li, Y., Xiao, Y., Han, B., Su, L., Su, M., Li, Y., Zhang, S., Jiang, D., Chen, X., Zhou, F., Ma, L., Bao, P., Xie, L. Prognostic assessment of COVID-19 in the intensive care unit by machine learning methods: Model development and validation (2020) Journal of Medical Internet Research, . DOI: 10.2196/23128
- 36) Choi, B.K., Kim, M.S., Kim, S.H. Risk prediction models for the development of oral-mucosal pressure injuries in intubated patients in intensive care units: A prospective observational study (2020) Journal of Tissue Viability, . DOI: 10.1016/j.jtv.2020.06.002
- 37) Scott, I.A., Coiera, E.W. Can AI help in the fight against COVID-19? (2020) Medical Journal of Australia, . DOI: 10.5694/mja2.50821

- 38) Chen, P.-H., Lien, C.-W., Wu, W.-C., Lee, L.-S., Shaw, J.-S. Artificial intelligence of neuropsychological tests for the prediction and verification of decline in gait parameters in patients with mild cognitive impairment (2020) *International Journal of Gerontology*, . DOI: 10.6890/IJGE.202011\_14(4).0005
- 39) Bashar, S.K., Hossain, M.B., Ding, E., Walkey, A.J., McManus, D.D., Chon, K.H. Atrial Fibrillation Detection during Sepsis: Study on MIMIC III ICU Data (2020) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2020.2995139
- 40) Fanelli, U., Pappalardo, M., Chinè, V., Gismondi, P., Neglia, C., Argentiero, A., Calderaro, A., Prati, A., Esposito, S. Role of artificial intelligence in fighting antimicrobial resistance in pediatrics (2020) *Antibiotics*, .DOI: 10.3390/antibiotics9110767
- 41) Ryan, L., Lam, C., Mataraso, S., Allen, A., Green-Saxena, A., Pellegrini, E., Hoffman, J., Barton, C., McCoy, A., Das, R. Mortality prediction model for the triage of COVID-19, pneumonia, and mechanically ventilated ICU patients: A retrospective study (2020) *Annals of Medicine and Surgery*, .DOI: 10.1016/j.amsu.2020.09.044
- 42) Ornek, A.H., Ervural, S., Ceylan, M., Konak, M., Soylu, H., Savasci, D. Classification of medical thermograms belonging neonates by using segmentation, feature engineering and machine learning algorithms(2020) *Traitement du Signal*, .DOI: 10.18280/TS.370409
- 43) Chaudhry, F., Hunt, R.J., Hariharan, P., Anand, S.K., Sanjay, S., Kjoller, E.E., Bartlett, C.M., Johnson, K.W., Levy, P.D., Noushmehr, H., Lee, I.Y. Machine Learning Applications in the Neuro ICU: A Solution to Big Data Mayhem? (2020) *Frontiers in Neurology*, . DOI: 10.3389/fneur.2020.554633
- 44) Barda, A.J., Horvat, C.M., Hochheiser, H. A qualitative research framework for the design of user-centered displays of explanations for machine learning model predictions in healthcare (2020) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/s12911-020-01276-x
- 45) Hunter, R.B., Jiang, S., Nishisaki, A., Nickel, A.J., Napolitano, N., Shinozaki, K., Li, T., Saeki, K., Becker, L.B., Nadkarni, V.M., Masino, A.J. Supervised Machine Learning Applied to Automate Flash and Prolonged Capillary Refill Detection by Pulse Oximetry (2020) *Frontiers in Physiology*, .DOI: 10.3389/fphys.2020.564589
- 46) Kong, G., Lin, K., Hu, Y. Using machine learning methods to predict in-hospital mortality of sepsis patients in the ICU (2020) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/s12911-020-01271-2
- 47) Hyun, S., Kaewprag, P., Cooper, C., Hixon, B., Moffatt-Bruce, S. Exploration of critical care data by using unsupervised machine learning (2020) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2020.105507
- 48) Ahmed, F.S., Ali, L., Joseph, B.A., Ikram, A., Ul Mustafa, R., Bukhari, S.A.C. A statistically rigorous deep neural network approach to predict mortality in trauma patients admitted to the intensive care unit (2020) *Journal of Trauma and Acute Care Surgery*, . DOI: 10.1097/TA.0000000000002888
- 49) Levenson, A.R., Morales-Nebreda, L., Alexander, M.J., Schroedl, C.J. Harnessing Machine Learning to Improve Patient Outcomes in Pulmonary and Critical Care Medicine (2020) *American Journal of Respiratory and Critical Care Medicine*, . DOI: 10.1164/rccm.201912-2486RR
- 50) Schwab, P., Schütte, A.D., Dietz, B., Bauer, S. Clinical predictive models for COVID-19: Systematic study (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/21439
- 51) Deshmukh, F., Merchant, S.S. Explainable Machine Learning Model for Predicting GI Bleed Mortality in the Intensive Care Unit (2020) *The American journal of gastroenterology*, . DOI: 10.14309/ajg.0000000000000632
- 52) Montagna, S., Mariani, S., Gamberini, E., Ricci, A., Zambonelli, F. Complementing Agents with Cognitive Services: A Case Study in Healthcare (2020) *Journal of Medical Systems*, . DOI: 10.1007/s10916-020-01621-7
- 53) Allen, A., Mataraso, S., Siefkas, A., Burdick, H., Braden, G., Dellinger, R.P., McCoy, A., Pellegrini, E., Hoffman, J., Green-Saxena, A., Barnes, G., Calvert, J., Das, R. A racially unbiased, machine learning approach to prediction of mortality: Algorithm development study (2020) *JMIR Public Health and Surveillance*, .DOI: 10.2196/22400
- 54) Izquierdo, J.L., Ancochea, J., Soriano, J.B., Savana COVID-19 Research Group. Clinical Characteristics and Prognostic Factors for Intensive Care Unit Admission of Patients with COVID-19: Retrospective Study Using Machine Learning and Natural Language Processing (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/21801
- 55) Tissot, H.C., Shah, A.D., Brealey, D., Harris, S., Agbakoba, R., Folarin, A., Romao, L., Roguski, L., Dobson, R., Asselbergs, F.W. Natural Language Processing for Mimicking Clinical Trial Recruitment in Critical Care: A Semi-Automated Simulation Based on the LeoPARDS Trial (2020) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2020.2977925
- 56) Dixon, A., Underwood, S., Schreiber, M. Implementing thrombelastography: Experiences from a level I trauma institution (2020) *Transfusion*, . DOI: 10.1111/trf.16070
- 57) Datta, S., Loftus, T.J., Ruppert, M.M., Giordano, C., Upchurch, G.R., Jr., Rashidi, P., Ozrazgat-Baslanti, T., Bihorac, A. Added Value of Intraoperative Data for Predicting Postoperative Complications: The MySurgeryRisk PostOp Extension (2020) *Journal of Surgical Research*, . DOI: 10.1016/j.jss.2020.05.007
- 58) Farzaneh, N., Williamson, C.A., Jiang, C., Srinivasan, A., Bapuraj, J.R., Gryak, J., Najarian, K., Reza Soroushmehr, S.M. Automated segmentation and severity analysis of subdural hematoma for patients with traumatic brain injuries (2020) *Diagnostics*, .DOI: 10.3390/diagnostics10100773

- 59) Gillies, C.E., Taylor, D.F., Cummings, B.C., Ansari, S., Islim, F., Kronick, S.L., Medlin, R.P., Jr., Ward, K.R. Demonstrating the consequences of learning missingness patterns in early warning systems for preventative health care: A novel simulation and solution (2020) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2020.103528
- 60) Pavel, A.M., Rennie, J.M., de Vries, L.S., Blennow, M., Foran, A., Shah, D.K., Pressler, R.M., Kapellou, O., Dempsey, E.M., Mathieson, S.R., Pavlidis, E., van Huffelen, A.C., Livingstone, V., Toet, M.C., Weeke, L.C., Finder, M., Mitra, S., Murray, D.M., Marnane, W.P., Boylan, G.B. A machine-learning algorithm for neonatal seizure recognition: a multicentre, randomised, controlled trial (2020) *The Lancet Child and Adolescent Health*, . DOI: 10.1016/S2352-4642(20)30239-X
- 61) Xie, F., Chakraborty, B., Hock Ong, M.E., Goldstein, B.A., Liu, N. AutoScore: A machine learning–based automatic clinical score generator and its application to mortality prediction using electronic health records (2020) *JMIR Medical Informatics*, . DOI: 10.2196/21798
- 62) Li, Y.-H., Harfiya, L.N., Purwandari, K., Lin, Y.-D. Real-time cuffless continuous blood pressure estimation using deep learning model (2020) *Sensors (Switzerland)*, . DOI: 10.3390/s20195606
- 63) Lee, G.H., Shin, S.-Y. Federated Learning on Clinical Benchmark Data: Performance Assessment (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/20891
- 64) Aggarwal, T., Eskandari, A., Priya, S., Mullan, A., Garg, I., Siembida, J., Mullan, B., Nagpal, P. Pulmonary embolism rule out: Positivity and factors affecting the yield of CT angiography (2020) *Postgraduate Medical Journal*, . DOI: 10.1136/postgradmedj-2019-137031
- 65) Chiera, M., Cerritelli, F., Casini, A., Barsotti, N., Boschiero, D., Caviglioli, F., Corti, C.G., Manzotti, A. Heart Rate Variability in the Perinatal Period: A Critical and Conceptual Review (2020) *Frontiers in Neuroscience*, . DOI: 10.3389/fnins.2020.561186
- 66) Wang, Y., Wei, Y., Yang, H., Li, J., Zhou, Y., Wu, Q. Utilizing imbalanced electronic health records to predict acute kidney injury by ensemble learning and time series model (2020) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/s12911-020-01245-4
- 67) Lim, K., Jiang, H., Marshall, A.P., Salmon, B., Gale, T.J., Dargaville, P.A. Predicting Apnoeic Events in Preterm Infants (2020) *Frontiers in Pediatrics*, . DOI: 10.3389/fped.2020.00570
- 68) Haque, A., Milstein, A., Fei-Fei, L. Illuminating the dark spaces of healthcare with ambient intelligence (2020) *Nature*, . DOI: 10.1038/s41586-020-2669-y
- 69) Van Laere, D., Meeus, M., Beirnaert, C., Sonck, V., Laukens, K., Mahieu, L., Mulder, A. Machine Learning to Support Hemodynamic Intervention in the Neonatal Intensive Care Unit (2020) *Clinics in Perinatology*, . DOI: 10.1016/j.clp.2020.05.002
- 70) Peine, A., Lütge, C., Poszler, F., Celi, L., Schöffski, O., Marx, G., Martin, L. Artificial intelligence and machine learning in intensive care research and clinical application [Künstliche Intelligenz und maschinelles Lernen in der intensivmedizinischen Forschung und klinischen Anwendung] (2020) *Anesthesiologie und Intensivmedizin*, . DOI: 10.19224/ai2020.372
- 71) Alexander, J.C., Romito, B.T., Çobanoğlu, M.C. The present and future role of artificial intelligence and machine learning in anesthesiology (2020) *International Anesthesiology Clinics*, . DOI: 10.1097/AIA.0000000000000294
- 72) Groves, A. The Future of Cardiac Ultrasound in the Neonatal Intensive Care Unit (2020) *Clinics in Perinatology*, . DOI: 10.1016/j.clp.2020.05.004
- 73) Castiñeira, D., Schlosser, K.R., Geva, A., Rahmani, A.R., Fiore, G., Walsh, B.K., Smallwood, C.D., Arnold, J.H., Santillana, M. Adding continuous vital sign information to static clinical data improves the prediction of length of stay after intubation: A data-driven machine learning approach (2020) *Respiratory Care*, . DOI: 10.4187/respcare.07561
- 74) Eickelberg, G., Sanchez-Pinto, L.N., Luo, Y. Predictive modeling of bacterial infections and antibiotic therapy needs in critically ill adults (2020) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2020.103540
- 75) Agieb, R.S. Machine learning models for the prediction the necessity of resorting to icu of covid-19 patients (2020) *International Journal of Advanced Trends in Computer Science and Engineering*, . DOI: 10.30534/ijatcse/2020/15952020
- 76) Kang, S.Y., Cha, W.C., Yoo, J., Kim, T., Park, J.H., Yoon, H., Hwang, S.Y., Sim, M.S., Jo, I.J., Shin, T.G. Predicting 30-day mortality of patients with pneumonia in an emergency department setting using machine-learning models (2020) *Clinical and Experimental Emergency Medicine*, .DOI: 10.15441/ceem.19.052
- 77) Kline, A., Kline, T., Abad, Z.S.H., Lee, J. Using item response theory for explainable machine learning in predicting mortality in the intensive care unit: Case-based approach (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/20268
- 78) 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 (2020) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2020.104176
- 79) Lee, S.-Y., Chinnam, R.B., Dalkiran, E., Krupp, S., Nauss, M. Prediction of emergency department patient disposition decision for proactive resource allocation for admission (2020) *Health Care Management Science*, . DOI: 10.1007/s10729-019-09496-y
- 80) Barnes, S.L., Myers, M., Rock, C., Morgan, D.J., Pineles, L., Thom, K.A., Harris, A.D. Evaluating a prediction-driven targeting strategy for reducing the transmission of multidrug-resistant organisms (2020) *INFORMS Journal on Computing*, . DOI: 10.1287/ijoc.2019.0916

- 81) Deffland, M., Spies, C., Weiss, B., Keller, N., Jenny, M., Kruppa, J., Balzer, F. Effects of pain, sedation and delirium monitoring on clinical and economic outcome: A retrospective study (2020) PLoS ONE, . DOI: 10.1371/journal.pone.0234801
- 82) Guedalia, J., Lipschuetz, M., Novoselsky-Persky, M., Cohen, S.M., Rottenstreich, A., Levin, G., Yagel, S., Unger, R., Sompolinsky, Y. Real-time data analysis using a machine learning model significantly improves prediction of successful vaginal deliveries (2020) American Journal of Obstetrics and Gynecology, . DOI: 10.1016/j.ajog.2020.05.025
- 83) Chen, W., Long, G., Yao, L., Sheng, Q.Z. AMRNN: attended multi-task recurrent neural networks for dynamic illness severity prediction (2020) World Wide Web, . DOI: 10.1007/s11280-019-00720-x
- 84) Jazayeri, A., Liang, O.S., Yang, C.C. Imputation of Missing Data in Electronic Health Records Based on Patients' Similarities (2020) Journal of Healthcare Informatics Research, . DOI: 10.1007/s41666-020-00073-5
- 85) Heili-Frades, S., Minguez, P., Mahillo Fernández, I., Jiménez Hiscock, L., Santos, A., Heili Frades, D., Carballosa de Miguel, M.D.P., Fernández Ormaechea, I., Álvarez Suárez, L., Naya Prieto, A., González Mangado, N., Peces-Barba Romero, G. Patient Management Assisted by a Neural Network Reduces Mortality in an Intermediate Care Unit [El manejo del paciente asistido por una red neuronal disminuye la mortalidad en una unidad de cuidados intermedios] (2020) Archivos de Bronconeumología, . DOI: 10.1016/j.arbres.2019.11.019
- 86) Junior, J.C., Binuesa, F., Caneo, L.F., Ribeiro Turquetto, A.L., Calvo Arita, E.C.T., Barbosa, A.C., da Silva Fernandes, A.M., Trindade, E.M., Jatene, F.B., Dossou, P.-E., Jatene, M.B. Improving preoperative risk-of-death prediction in surgery congenital heart defects using artificial intelligence model: A pilot study (2020) PLoS ONE, . DOI: 10.1371/journal.pone.0238199
- 87) Yao, R.-Q., Jin, X., Wang, G.-W., Yu, Y., Wu, G.-S., Zhu, Y.-B., Li, L., Li, Y.-X., Zhao, P.-Y., Zhu, S.-Y., Xia, Z.-F., Ren, C., Yao, Y.-M. A Machine Learning-Based Prediction of Hospital Mortality in Patients With Postoperative Sepsis (2020) Frontiers in Medicine, . DOI: 10.3389/fmed.2020.00445
- 88) Decruyenaere, A., Steen, J., Colpaert, K., Benoit, D.D., Decruyenaere, J., Vansteelandt, S. The obesity paradox in critically ill patients: a causal learning approach to a casual finding (2020) Critical Care, . DOI: 10.1186/s13054-020-03199-5
- 89) Essay, P., Balkan, B., Subbian, V. Decompensation in critical care: Early prediction of acute heart failure onset (2020) JMIR Medical Informatics, . DOI: 10.2196/19892
- 90) Maheshwari, S., Agarwal, A., Shukla, A., Tiwari, R. A comprehensive evaluation for the prediction of mortality in intensive care units with LSTM networks: Patients with cardiovascular disease (2020) Biomedizinische Technik, . DOI: 10.1515/bmt-2018-0206
- 91) Alzghoul, B.N., Reddy, R., Chizinga, M., Innabi, A., Zou, B., Papierniak, E.S., Faruqi, I. Pulmonary Embolism in Acute Asthma Exacerbation: Clinical Characteristics, Prediction Model and Hospital Outcomes (2020) Lung, . DOI: 10.1007/s00408-020-00363-0
- 92) Baldassano, S.N., Roberson, S.W., Balu, R., Scheid, B., Bernabei, J.M., Pathmanathan, J., Oommen, B., Leri, D., Echaz, J., Gelfand, M., Bhalla, P.K., Hill, C.E., Christini, A., Wagenaar, J.B., Litt, B. IRIS: A modular platform for continuous monitoring and caretaker notification in the intensive care unit (2020) IEEE Journal of Biomedical and Health Informatics, . DOI: 10.1109/JBHI.2020.2965858
- 93) Rao, V.L., Gupta, N., Swei, E., Wagner, T., Aronsohn, A., Reddy, K.G., Sengupta, N. Predictors of mortality and endoscopic intervention in patients with upper gastrointestinal bleeding in the intensive care unit (2020) Gastroenterology Report, . DOI: 10.1093/gastro/goaa009
- 94) Gordon, S.M., Srinivasan, L., Taylor, D.M., Master, S.R., Tremoglie, M.A., Hankeova, A., Flannery, D.D., Abbasi, S., Fitzgerald, J.C., Harris, M.C. Derivation of a metabolic signature associated with bacterial meningitis in infants (2020) Pediatric Research, . DOI: 10.1038/s41390-020-0816-7
- 95) Peran, P., Malagurski, B., Nemmi, F., Sarton, B., Vinour, H., Ferre, F., Bounes, F., Rousset, D., Mrozeck, S., Seguin, T., Riu, B., Minville, V., Geeraerts, T., Lotterie, J.A., Deboissezon, X., Albuher, J.F., Fourcade, O., Olivot, J.M., Naccache, L., Silva, S. Functional and Structural Integrity of Frontoparietal Connectivity in Traumatic and Anoxic Coma (2020) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000004406
- 96) Keim-Malpass, J., Clark, M.T., Lake, D.E., Moorman, J.R. Towards development of alert thresholds for clinical deterioration using continuous predictive analytics monitoring (2020) Journal of Clinical Monitoring and Computing, . DOI: 10.1007/s10877-019-00361-5
- 97) Wang, T., Tian, Y., Qiu, R.G. Long short-term memory recurrent neural networks for multiple diseases risk prediction by leveraging longitudinal medical records (2020) IEEE Journal of Biomedical and Health Informatics, .DOI: 10.1109/JBHI.2019.2962366
- 98) Johnsson, J., Björnsson, O., Andersson, P., Jakobsson, A., Cronberg, T., Lilja, G., Friberg, H., Hassager, C., Kjaergard, J., Wise, M., Nielsen, N., Frigyesi, A. Artificial neural networks improve early outcome prediction and risk classification in out-of-hospital cardiac arrest patients admitted to intensive care (2020) Critical Care, . DOI: 10.1186/s13054-020-03103-1
- 99) Shi, P., Hou, F., Zheng, X., Yuan, F. Analysis of electronic health records based on long short-term memory (2020) Concurrency Computation, . DOI: 10.1002/cpe.5684

- 100) Liu, S., See, K.C., Ngiam, K.Y., Celi, L.A., Sun, X., Feng, M. Reinforcement learning for clinical decision support in critical care: Comprehensive review (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/18477
- 101) Sheikhalishahi, S., Balaraman, V., Osmani, V. Benchmarking machine learning models on multi-centre eICU critical care dataset (2020) *PLoS ONE*, .DOI: 10.1371/journal.pone.0235424
- 102) Rehm, G.B., Woo, S.H., Chen, X.L., Kuhn, B.T., Cortes-Puch, I., Anderson, N.R., Adams, J.Y., Chuah, C.-N. Leveraging IoTs and Machine Learning for Patient Diagnosis and Ventilation Management in the Intensive Care Unit (2020) *IEEE Pervasive Computing*, . DOI: 10.1109/MPRV.2020.2986767
- 103) Ladios-Martín, M., Fernández-De-maya, J., Ballesta-López, F.-J., Belso-Garzas, A., Mas-Asencio, M., Cabañero-Martínez, M.J. Predictive modeling of pressure injury risk in patients admitted to an intensive care unit (2020) *American Journal of Critical Care*, . DOI: 10.4037/ajcc2020237
- 104) Abromavičius, V., Plonis, D., Tarasevičius, D., Serackis, A. Two-stage monitoring of patients in intensive care unit for sepsis prediction using non-overfitted machine learning models (2020) *Electronics (Switzerland)*, . DOI: 10.3390/electronics9071133
- 105) Song, W., Jung, S.Y., Baek, H., Choi, C.W., Jung, Y.H., Yoo, S. A predictive model based on machine learning for the early detection of late-onset neonatal sepsis: Development and observational study (2020) *JMIR Medical Informatics*, . DOI: 10.2196/15965
- 106) Monteiro, F., Meloni, F., Baranauskas, J.A., Macedo, A.A. Prediction of mortality in Intensive Care Units: a multivariate feature selection (2020) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2020.103456
- 107) Sonabend W, A., Cai, W., Ahuja, Y., Ananthkrishnan, A., Xia, Z., Yu, S., Hong, C. Automated ICD coding via unsupervised knowledge integration (UNITE) (2020) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2020.104135
- 108) Lee, D.H., Yetisgen, M., Vanderwende, L., Horvitz, E. Predicting severe clinical events by learning about life-saving actions and outcomes using distant supervision (2020) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2020.103425
- 109) Thambiraj, G., Gandhi, U., Mangalanathan, U., Jose, V.J.M., Anand, M. Investigation on the effect of Womersley number, ECG and PPG features for cuff less blood pressure estimation using machine learning (2020) *Biomedical Signal Processing and Control*, . DOI: 10.1016/j.bspc.2020.101942
- 110) Ueno, R., Xu, L., Uegami, W., Matsui, H., Okui, J., Hayashi, H., Miyajima, T., Hayashi, Y., Pilcher, D., Jones, D. Value of laboratory results in addition to vital signs in a machine learning algorithm to predict in-hospital cardiac arrest: A singlecenter retrospective cohort study (2020) *PLoS ONE*, . DOI: 10.1371/journal.pone.0235835
- 111) Tadesse, G.A., Javed, H., Thanh, N.L.N., Thi, H.D.H., Tan, L.V., Thwaites, L., Clifton, D.A., Zhu, T. Multi-Modal Diagnosis of Infectious Diseases in the Developing World (2020) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2019.2959839
- 112) Santos, J., Brierley, S., Gandhi, M.J., Cohen, M.A., Moschella, P.C., Declan, A.B.L. Repurposing therapeutics for potential treatment of SARS-CoV-2: A review (2020) *Viruses*, . DOI: 10.3390/v12070705
- 113) McRae, M.P., Simmons, G.W., Christodoulides, N.J., Lu, Z., Kang, S.K., Fenyo, D., Alcorn, T., Dapkins, I.P., Sharif, I., Vurmaz, D., Modak, S.S., Srinivasan, K., Warhadpande, S., Shrivastav, R., McDevitt, J.T. Clinical decision support tool and rapid point-of-care platform for determining disease severity in patients with COVID-19 (2020) *Lab on a Chip*, . DOI: 10.1039/d0lc00373e
- 114) Fang, A.H.S., Lim, W.T., Balakrishnan, T. Early warning score validation methodologies and performance metrics: a systematic review (2020) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/s12911-020-01144-8
- 115) McKenzie, C.A., Page, V.J., Strain, W.D., Blackwood, B., Ostermann, M., Taylor, D., Spronk, P.E., McAuley, D.F. Parenteral thiamine for prevention and treatment of delirium in critically ill adults: A systematic review protocol (2020) *Systematic Reviews*, . DOI: 10.1186/s13643-020-01380-z
- 116) Görges, M., Ansermino, J.M. Augmented intelligence in pediatric anesthesia and pediatric critical care (2020) *Current Opinion in Anaesthesiology*, . DOI: 10.1097/ACO.0000000000000845
- 117) Su, L., Liu, C., Li, D., He, J., Zheng, F., Jiang, H., Wang, H., Gong, M., Hong, N., Zhu, W., Long, Y. Toward optimal heparin dosing by comparing multiple machine learning methods: Retrospective study (2020) *JMIR Medical Informatics*, . DOI: 10.2196/17648
- 118) Smallwood, C.D. Monitoring big data during mechanical ventilation in the icu (2020) *Respiratory Care*, . DOI: 10.4187/respcare.07500
- 119) Awad, A., Bader-El-Den, M., McNicholas, J., Briggs, J., El-Sonbaty, Y. Predicting hospital mortality for intensive care unit patients: Time-series analysis (2020) *Health Informatics Journal*, . DOI: 10.1177/1460458219850323
- 120) Peng, L.-N., Hsiao, F.-Y., Lee, W.-J., Huang, S.-T., Chen, L.-K. Comparisons between hypothesis- And data-driven approaches for multimorbidity frailty index: a machine learning approach (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/16213

- 121) Rocha, T.A.H., Elahi, C., Da Silva, N.C., Sakita, F.M., Fuller, A., Mmbaga, B.T., Green, E.P., Haglund, M.M., Staton, C.A., Vissoci, J.R.N. A traumatic brain injury prognostic model to support in-hospital triage in a low-income country: A machine learning-based approach (2020) *Journal of Neurosurgery*, . DOI: 10.3171/2019.2.JNS182098
- 122) Zhu, K., Song, H., Zhang, Z., Ma, B., Bao, X., Zhang, Q., Jin, J. Acute kidney injury in solitary kidney patients after partial nephrectomy: Incidence, risk factors and prediction (2020) *Translational Andrology and Urology*, . DOI: 10.21037/tau.2020.03.45
- 123) Daberdaku, S., Tavazzi, E., Di Camillo, B. A Combined Interpolation and Weighted K-Nearest Neighbours Approach for the Imputation of Longitudinal ICU Laboratory Data (2020) *Journal of Healthcare Informatics Research*, . DOI: 10.1007/s41666-020-00069-1
- 124) Lamberti, J.P. Respiratory monitoring in general care units (2020) *Respiratory Care*, . DOI: 10.4187/respcare.07405
- 125) Braun, D., Braun, E., Chiu, V., Burgos, A.E., Gupta, M., Volodarskiy, M., Getahun, D. Trends in Neonatal Intensive Care Unit Utilization in a Large Integrated Health Care System (2020) *JAMA network open*, . DOI: 10.1001/jamanetworkopen.2020.5239
- 126) Guo, R., Fujiwara, T., Li, Y., Lima, K.M., Sen, S., Tran, N.K., Ma, K.-L. Comparative visual analytics for assessing medical records with sequence embedding (2020) *Visual Informatics*, . DOI: 10.1016/j.visinf.2020.04.001
- 127) Raj, V., Jagdish, J. Computed tomography (CT) chest imaging in diagnosis and management of patients with COVID-19 (2020) *Journal of the Indian Medical Association*, .
- 128) Milstein, A., Topol, E.J. Computer vision's potential to improve health care (2020) *The Lancet*, . DOI: 10.1016/S0140-6736(20)31090-4
- 129) Mohammed, A., Podila, P.S.B., Davis, R.L., Ataga, K.I., Hankins, J.S., Kamaleswaran, R. Using machine learning to predict early onset acute organ failure in critically ill intensive care unit patients with sickle cell disease: Retrospective study (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/14693
- 130) Pappada, S.M., Owais, M.H., Cameron, B.D., Jaime, J.C., Mavarez-Martinez, A., Tripathi, R.S., Papadimos, T.J. An Artificial Neural Network-based Predictive Model to Support Optimization of Inpatient Glycemic Control (2020) *Diabetes Technology and Therapeutics*, . DOI: 10.1089/dia.2019.0252
- 131) Peiffer-Smadja, N., Rawson, T.M., Ahmad, R., Buchard, A., Pantelis, G., Lescure, F.-X., Birgand, G., Holmes, A.H. Machine learning for clinical decision support in infectious diseases: a narrative review of current applications (2020) *Clinical Microbiology and Infection*, . DOI: 10.1016/j.cmi.2019.09.009
- 132) Alkhachroum, A., Terilli, K., Megjhani, M., Park, S. Harnessing Big Data in Neurocritical Care in the Era of Precision Medicine (2020) *Current Treatment Options in Neurology*, . DOI: 10.1007/s11940-020-00622-8
- 133) Hopkins, B.S., Mazmudar, A., Driscoll, C., Svet, M., Goergen, J., Kelsten, M., Shlobin, N.A., Kesavabhotla, K., Smith, Z.A., Dahdaleh, N.S. Using artificial intelligence (AI) to predict postoperative surgical site infection: A retrospective cohort of 4046 posterior spinal fusions (2020) *Clinical Neurology and Neurosurgery*, . DOI: 10.1016/j.clineuro.2020.105718
- 134) Teng, A.K., Ms, Wilcox, A.B. A Review of Predictive Analytics Solutions for Sepsis Patients (2020) *Applied Clinical Informatics*, . DOI: 10.1055/s-0040-1710525
- 135) Mapder, T., Aaskov, J., Burrage, K. Administration of defective virus inhibits dengue transmission into mosquitoes (2020) *Viruses*, . DOI: 10.3390/v12050558
- 136) Chen, D., Zhang, R., Qiu, R.G. Leveraging Semantics in WordNet to Facilitate the Computer-Assisted Coding of ICD-11 (2020) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2019.2949567
- 137) Balachander, T., Sharma, S., Srivastava, A. Detection of sepsis using machine learning approach (2020) *International Journal of Advanced Science and Technology*, .
- 138) Falini, S., Angelotti, G., Cecconi, M. ICU management based on big data (2020) *Current opinion in anaesthesiology*, . DOI: 10.1097/ACO.0000000000000834
- 139) Huang, L., Yin, Y., Fu, Z., Zhang, S., Deng, H., Liu, D. LoadaBoost: Loss-based AdaBoost federated machine learning with reduced computational complexity on IID and non-IID intensive care data (2020) *PLoS ONE*, . DOI: 10.1371/journal.pone.0230706
- 140) King, A.J., Cooper, G.F., Clermont, G., Hochheiser, H., Hauskrecht, M., Sittig, D.F., Visweswaran, S. Leveraging Eye Tracking to Prioritize Relevant Medical Record Data: Comparative Machine Learning Study (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/15876
- 141) Hever, G., Cohen, L., O'Connor, M.F., Matot, I., Lerner, B., Bitan, Y. Machine learning applied to multi-sensor information to reduce false alarm rate in the ICU (2020) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-019-00307-x
- 142) Tawfik, D.S., Profit, J., Lake, E.T., Liu, J.B., Sanders, L.M., Phibbs, C.S. Development and use of an adjusted nurse staffing metric in the neonatal intensive care unit (2020) *Health Services Research*, . DOI: 10.1111/1475-6773.13249
- 143) Lauritsen, S.M., Kalør, M.E., Kongsgaard, E.L., Lauritsen, K.M., Jørgensen, M.J., Lange, J., Thiesson, B. Early detection of sepsis utilizing deep learning on electronic health record event sequences (2020) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2020.101820

- 144) García-Gallo, J.E., Fonseca-Ruiz, N.J., Celi, L.A., Duitama-Muñoz, J.F. A machine learning-based model for 1-year mortality prediction in patients admitted to an Intensive Care Unit with a diagnosis of sepsis [Modelo para la predicción de la mortalidad a un año en pacientes ingresados en una unidad de cuidados intensivos con diagnóstico de sepsis] (2020) *Medicina Intensiva*, . DOI: 10.1016/j.medin.2018.07.016
- 145) Thorsen-Meyer, H.-C., Nielsen, A.B., Nielsen, A.P., Kaas-Hansen, B.S., Toft, P., Schierbeck, J., Strøm, T., Chmura, P.J., Heimann, M., Dybdahl, L., Spangsege, L., Hulsen, P., Belling, K., Brunak, S., Perner, A. Dynamic and explainable machine learning prediction of mortality in patients in the intensive care unit: a retrospective study of high-frequency data in electronic patient records (2020) *The Lancet Digital Health*, . DOI: 10.1016/S2589-7500(20)30018-2
- 146) Chatburn, R.L., Mireles-Cabodevila, E. 2019 year in review: Patient-ventilator synchrony (2020) *Respiratory Care*, . DOI: 10.4187/respcare.07635
- 147) Ma, X., Si, Y., Wang, Z., Wang, Y. Length of stay prediction for ICU patients using individualized single classification algorithm (2020) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2019.105224
- 148) Acosta, J.N., Brown, S.C., Falcone, G.J. Genetic Variation and Response to Neurocritical Illness: a Powerful Approach to Identify Novel Pathophysiological Mechanisms and Therapeutic Targets (2020) *Neurotherapeutics*, . DOI: 10.1007/s13311-020-00837-2
- 149) Goodwin, T.R., Demner-Fushman, D. A customizable deep learning model for nosocomial risk prediction from critical care notes with indirect supervision (2020) *Journal of the American Medical Informatics Association : JAMIA*, . DOI: 10.1093/jamia/ocaa004
- 150) Gennatas, E.D., Friedman, J.H., Ungar, L.H., Pirracchio, R., Eaton, E., Reichmann, L.G., Interian, Y., Luna, J.M., Simone, C.B., II, Auerbach, A., Delgado, E., van der Laan, M.J., Solberg, T.D., Valdes, G. Expert-augmented machine learning (2020) *Proceedings of the National Academy of Sciences of the United States of America*, . DOI: 10.1073/pnas.1906831117
- 151) Chou, C.-A., Cao, Q., Weng, S.-J., Tsai, C.-H. Mixed-integer optimization approach to learning association rules for unplanned ICU transfer (2020) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2020.101806
- 152) Hyland, S.L., Faltys, M., Hüser, M., Lyu, X., Gumbsch, T., Esteban, C., Bock, C., Horn, M., Moor, M., Rieck, B., Zimmermann, M., Bodenham, D., Borgwardt, K., Rätsch, G., Merz, T.M. Early prediction of circulatory failure in the intensive care unit using machine learning (2020) *Nature Medicine*, . DOI: 10.1038/s41591-020-0789-4
- 153) Catling, F.J.R., Wolff, A.H. Temporal convolutional networks allow early prediction of events in critical care (2020) *Journal of the American Medical Informatics Association*, . DOI: 10.1093/jamia/oc2205
- 154) Morid, M.A., Sheng, O.R.L., Fiol, G.D., Facelli, J.C., Bray, B.E., Abdelrahman, S. Temporal pattern detection to predict adverse events in critical care: Case study with acute kidney injury (2020) *Journal of Medical Internet Research*, .DOI: 10.2196/14272
- 155) Ibrahim, Z.M., Wu, H., Hamoud, A., Stappen, L., Dobson, R.J.B., Agarossi, A. On classifying sepsis heterogeneity in the ICU: Insight using machine learning (2020) *Journal of the American Medical Informatics Association*, . DOI: 10.1093/jamia/oc2211
- 156) Moghadam, M.C., Abad, E.M.K., Bagherzadeh, N., Ramsingh, D., Li, G.-P., Kain, Z.N. A machine-learning approach to predicting hypotensive events in ICU settings (2020) *Computers in Biology and Medicine*, . DOI: 10.1016/j.combiomed.2020.103626
- 157) Fleuren, L.M., Klausch, T.L.T., Zwager, C.L., Schoonmade, L.J., Guo, T., Roggeveen, L.F., Swart, E.L., Girbes, A.R.J., Thorat, P., Ercole, A., Hoogendoorn, M., Elbers, P.W.G. Machine learning for the prediction of sepsis: a systematic review and meta-analysis of diagnostic test accuracy (2020) *Intensive Care Medicine*, . DOI: 10.1007/s00134-019-05872-y
- 158) Pereira, T., Gadhoumi, K., Ma, M., Liu, X., Xiao, R., Colorado, R.A., Keenan, K.J., Meisel, K., Hu, X. A Supervised Approach to Robust Photoplethysmography Quality Assessment (2020) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2019.2909065
- 159) Roimi, M., Neuberger, A., Shrot, A., Paul, M., Geffen, Y., Bar-Lavie, Y. Early diagnosis of bloodstream infections in the intensive care unit using machine-learning algorithms (2020) *Intensive Care Medicine*, . DOI: 10.1007/s00134-019-05876-8
- 160) Rongali, S., Rose, A.J., McManus, D.D., Bajracharya, A.S., Kapoor, A., Granillo, E., Yu, H. Learning latent space representations to predict patient outcomes: Model development and validation (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/16374
- 161) Sahu, S., Ghosh, S.K., Kalita, J.M., Ginjupalli, M.C., K, K.R. Discovery of potential 1,3,5-Triazine compounds against strains of *Plasmodium falciparum* using supervised machine learning models (2020) *European Journal of Pharmaceutical Sciences*, . DOI: 10.1016/j.ejps.2019.105208
- 162) Lee, S., Hong, S., Cha, W.C., Kim, K. Predicting adverse outcomes for febrile patients in the emergency department using sparse laboratory data: Development of a time adaptive model (2020) *Journal of Medical Internet Research*, . DOI: 10.2196/16117
- 163) Osterhoff, G., Pffröninger, D., Scherer, J., Juhra, C., Maerdian, S., Back, D.A., Arbeitsgruppe Digitalisierung der Deutschen Gesellschaft für Orthopädie und Unfallchirurgie Computer-assisted decision-making for trauma patients [Computerassistierte Entscheidungsfindung beim Traumapatienten] (2020) *Unfallchirurg*, . DOI: 10.1007/s00113-019-0676-y
- 164) Morid, M.A., Liu Sheng, O.R., Del Fiol, G., Facelli, J.C., Bray, B.E., Abdelrahman, S. Temporal pattern detection to predict adverse events in critical care: Case study with acute kidney injury (2020) *JMIR Medical Informatics*, . DOI: 10.2196/14272

- 165) Zhao, C., Wei, Y., Chen, D., Jin, J., Chen, H. Prognostic value of an inflammatory biomarker-based clinical algorithm in septic patients in the emergency department: An observational study (2020) *International Immunopharmacology*, . DOI: 10.1016/j.intimp.2019.106145
- 166) Loreto, M., Lisboa, T., Moreira, V.P. Early prediction of ICU readmissions using classification algorithms (2020) *Computers in Biology and Medicine*, . DOI: 10.1016/j.combiomed.2020.103636
- 167) Lee, S., Hong, S., Cha, W.C., Kim, K. Predicting adverse outcomes for febrile patients in the emergency department using sparse laboratory data: Development of a time adaptive model (2020) *JMIR Medical Informatics*, . DOI: 10.2196/16117
- 168) Goodwin, A.J., Eytan, D., Greer, R.W., Mazwi, M., Thommandram, A., Goodfellow, S.D., Assadi, A., Jegatheeswaran, A., Laussen, P.C. A practical approach to storage and retrieval of high-frequency physiological signals (2020) *Physiological Measurement*, . DOI: 10.1088/1361-6579/ab7cb5
- 169) Mohebbian, M.R., Dinh, A., Wahid, K., Alam, M.S. Blind, Cuff-less, Calibration-Free and Continuous Blood Pressure Estimation using Optimized Inductive Group Method of Data Handling (2020) *Biomedical Signal Processing and Control*, . DOI: 10.1016/j.bspc.2019.101682
- 170) Hu, C.-A., Chen, C.-M., Fang, Y.-C., Liang, S.-J., Wang, H.-C., Fang, W.-F., Sheu, C.-C., Perng, W.-C., Yang, K.-Y., Kao, K.-C., Wu, C.-L., Tsai, C.-S., Lin, M.-Y., Chao, W.-C. Using a machine learning approach to predict mortality in critically ill influenza patients: A cross-sectional retrospective multicentre study in Taiwan (2020) *BMJ Open*, . DOI: 10.1136/bmjopen-2019-033898
- 171) Zhang, Z., Ho, K.M., Gu, H., Hong, Y., Yu, Y. Defining persistent critical illness based on growth trajectories in patients with sepsis (2020) *Critical Care*, . DOI: 10.1186/s13054-020-2768-z
- 172) Chen, C.-Y., Lin, W.-C., Yang, H.-Y. Diagnosis of ventilator-associated pneumonia using electronic nose sensor array signals: Solutions to improve the application of machine learning in respiratory research (2020) *Respiratory Research*, . DOI: 10.1186/s12931-020-1285-6
- 173) Kang, M.W., Kim, J., Kim, D.K., Oh, K.-H., Joo, K.W., Kim, Y.S., Han, S.S. Machine learning algorithm to predict mortality in patients undergoing continuous renal replacement therapy (2020) *Critical Care*, . DOI: 10.1186/s13054-020-2752-7
- 174) Grogan, K.L., Goldsmith, M.P., Masino, A.J., Nelson, O., Tsui, F.-C., Simpao, A.F. A Narrative Review of Analytics in Pediatric Cardiac Anesthesia and Critical Care Medicine (2020) *Journal of Cardiothoracic and Vascular Anesthesia*, . DOI: 10.1053/j.jvca.2019.06.009
- 175) Feretzakis, G., Loupelis, E., Sakagianni, A., Kalles, D., Martsoukou, M., Lada, M., Skarmoutsou, N., Christopoulos, C., Valakis, K., Velentza, A., Petropoulou, S., Michelidou, S., Alexiou, K. Using machine learning techniques to aid empirical antibiotic therapy decisions in the intensive care unit of a general hospital in Greece (2020) *Antibiotics*, . DOI: 10.3390/antibiotics9020050
- 176) Santos, H.G.D., Zampieri, F.G., Normilio-Silva, K., Silva, G.T.D., Lima, A.C.P.D., Cavalcanti, A.B., Chiavegatto Filho, A.D.P. Machine learning to predict 30-day quality-adjusted survival in critically ill patients with cancer (2020) *Journal of Critical Care*, . DOI: 10.1016/j.jcrc.2019.10.015
- 177) Shabaan, A.R., Sharawi, A.A. Machine learning for blood pressure classification using only the ecg signal (2020) *Journal of Engineering and Applied Science*, .
- 178) Ghodratioghar, M., Ghanadian, H., Al Osman, H. A Remote Respiration Rate Measurement Method for Non-Stationary Subjects Using CEEMDAN and Machine Learning (2020) *IEEE Sensors Journal*, .DOI: 10.1109/JSEN.2019.2946132
- 179) Abbasi, H., Unsworth, C. Applications of advanced signal processing and machine learning in the neonatal hypoxic-ischemic electroencephalogram (2020) *Neural Regeneration Research*, . DOI: 10.4103/1673-5374.265542
- 180) Shamout, F.E., Zhu, T., Sharma, P., Watkinson, P.J., Clifton, D.A. Deep Interpretable Early Warning System for the Detection of Clinical Deterioration (2020) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2019.2937803
- 181) Liang, Z., Shao, S., Lv, Z., Li, D., Sleigh, J.W., Li, X., Zhang, C., He, J. Constructing a Consciousness Meter Based on the Combination of Non-Linear Measurements and Genetic Algorithm-Based Support Vector Machine (2020) *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, . DOI: 10.1109/TNSRE.2020.2964819
- 182) Amorim, R.L., Oliveira, L.M., Malbouisson, L.M., Nagumo, M.M., Simoes, M., Miranda, L., Bor-Seng-Shu, E., Beer-Furlan, A., De Andrade, A.F., Rubiano, A.M., Teixeira, M.J., Koliass, A.G., Paiva, W.S. Prediction of Early TBI Mortality Using a Machine Learning Approach in a LMIC Population (2020) *Frontiers in Neurology*, . DOI: 10.3389/fneur.2019.01366
- 183) Hamilton, E.F., Dyachenko, A., Ciampi, A., Maurel, K., Warrick, P.A., Garite, T.J. Estimating risk of severe neonatal morbidity in preterm births under 32 weeks of gestation (2020) *Journal of Maternal-Fetal and Neonatal Medicine*, . DOI: 10.1080/14767058.2018.1487395
- 184) Khurram, M., Asmar, S., Joseph, B. Telemedicine in the ICU: Innovation in the Critical Care Process (2020) *Journal of Intensive Care Medicine*, . DOI: 10.1177/0885066620968518
- 185) Kagerbauer, S., Blobner, M., Ulm, B., Jungwirth, B. Tomorrow is already here [1] How machine learning is influencing anaesthesiology and intensive care medicine [Die Zukunft hat schon begonnen [1] Wie maschinelles Lernen Anästhesie und Intensivmedizin prägt] (2020) *Anesthesiologie und Intensivmedizin*, . DOI: 10.19224/ai2020.085

- 186) Soussi, S., Collins, G.S., Jüni, P., Mebazaa, A., Gayat, E., Le Manach, Y. Evaluation of Biomarkers in Critical Care and Perioperative Medicine: A Clinician's Overview of Traditional Statistical Methods and Machine Learning Algorithms (2020) *Anesthesiology*, . DOI: 10.1097/ALN.0000000000003600
- 187) Fabregat, A., Magret, M., Ferré, J.A., Vernet, A., Guasch, N., Rodríguez, A., Gómez, J., Bodí, M. A Machine Learning decision-making tool for extubation in Intensive Care Unit patients (2020) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2020.105869
- 188) Rahmatizadeh, S., Valizadeh-Haghi, S., Dabbagh, A. The role of artificial intelligence in management of critical COVID-19 patients (2020) *Journal of Cellular and Molecular Anesthesia*, . DOI: 10.22037/jcma.v5i1.29752
- 189) Li, X., Xu, X., Xie, F., Xu, X., Sun, Y., Liu, X., Jia, X., Kang, Y., Xie, L., Wang, F., Xie, G. A time-phased machine learning model for real-time prediction of sepsis in critical care (2020) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000004494
- 190) Jaskari, J., Myllarinen, J., Leskinen, M., Rad, A.B., Hollmen, J., Andersson, S., Sarkka, S. Machine Learning Methods for Neonatal Mortality and Morbidity Classification (2020) *IEEE Access*, . DOI: 10.1109/ACCESS.2020.3006710
- 191) El-Rashidy, N., El-Sappagh, S., Abuhmed, T., Abdelrazek, S., El-Bakry, H.M. Intensive Care Unit Mortality Prediction: An Improved Patient-Specific Stacking Ensemble Model (2020) *IEEE Access*, . DOI: 10.1109/ACCESS.2020.3010556
- 192) Parker, F., Brodsky, M.B., Akst, L.M., Ali, H. Machine Learning in Laryngoscopy Analysis: A Proof of Concept Observational Study for the Identification of Post-Extubation Ulcerations and Granulomas (2020) *Annals of Otolaryngology, Rhinology and Laryngology*, . DOI: 10.1177/0003489420950364
- 193) Nguyen, T.-P., Nguyen, S., Alahakoon, D., Huynh, V.-N. GSIC: A New Interpretable System for Knowledge Exploration and Classification (2020) *IEEE Access*, . DOI: 10.1109/ACCESS.2020.3001428
- 194) Lee, S., Son, C.-H., Albertini, M.K., Fernandes, H.C. Multi-Phases and Various Feature Extraction and Selection Methodology for Ensemble Gradient Boosting in Estimating Respiratory Rate (2020) *IEEE Access*, . DOI: 10.1109/ACCESS.2020.3007524
- 195) Ghorbani, R., Ghousi, R., Makui, A., Atashi, A. A New Hybrid Predictive Model to Predict the Early Mortality Risk in Intensive Care Units on a Highly Imbalanced Dataset (2020) *IEEE Access*, . DOI: 10.1109/ACCESS.2020.3013320
- 196) Al-Mamun, M.A., Brothers, T., Newsome, A.S. Development of Machine Learning Models to Validate a Medication Regimen Complexity Scoring Tool for Critically Ill Patients (2020) *Annals of Pharmacotherapy*, . DOI: 10.1177/1060028020959042
- 197) Cherifa, M., Blet, A., Chambaz, A., Gayat, E., Resche-Rigon, M., Pirracchio, R. Prediction of an acute hypotensive episode during an ICU hospitalization with a super learner machine-learning algorithm (2020) *Anesthesia and Analgesia*, . DOI: 10.1213/ANE.0000000000004539
- 198) Wanyan, T., Vaid, A., De Freitas, J.K., Somani, S., Miotto, R., Nadkarni, G.N., Azad, A., Ding, Y., Glicksberg, B.S. Relational Learning Improves Prediction of Mortality in COVID-19 in the Intensive Care Unit (2020) *IEEE Transactions on Big Data*, . DOI: 10.1109/TBDATA.2020.3048644
- 199) Qiu, Y., Ding, S., Yao, N., Gu, D., Li, X. HFS-LightGBM: A machine learning model based on hybrid feature selection for classifying ICU patient readmissions (2020) *Expert Systems*, . DOI: 10.1111/exsy.12658
- 200) Liao, Y.-H., Shih, C.-H., Abbod, M.F., Shieh, J.-S., Hsiao, Y.-J. Development of an E-nose system using machine learning methods to predict ventilator-associated pneumonia (2020) *Microsystem Technologies*, . DOI: 10.1007/s00542-020-04782-0
- 201) Zhang, G., Yuan, J., Yu, M., Wu, T., Luo, X., Chen, F. A machine learning method for acute hypotensive episodes prediction using only non-invasive parameters (2020) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2020.105845
- 202) Yu, J.Y., Jeong, G.Y., Jeong, O.S., Chang, D.K., Cha, W.C. Machine learning and initial nursing assessment-based triage system for emergency department (2020) *Healthcare Informatics Research*, . DOI: 10.4258/hir.2020.26.1.13
- 203) Dziorny, A.C., Lindell, R.B., Bennett, T.D., Bailey, L.C. Joining datasets without identifiers: Probabilistic linkage of virtual pediatric systems and PEDSnet (2020) *Pediatric Critical Care Medicine*, . DOI: 10.1097/PCC.0000000000002380
- 204) Fernandes, M., Vieira, S.M., Leite, F., Palos, C., Finkelstein, S., Sousa, J.M.C. Clinical Decision Support Systems for Triage in the Emergency Department using Intelligent Systems: a Review (2020) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2019.101762
- 205) Fernandes, M., Mendes, R., Vieira, S.M., Leite, F., Palos, C., Johnson, A., Finkelstein, S., Horng, S., Celi, L.A. Predicting intensive care unit admission among patients presenting to the emergency department using machine learning and natural language processing (2020) *PLoS ONE*, . DOI: 10.1371/journal.pone.0229331
- 206) Mousavi, S., Fotoohinasab, A., Afghah, F. Single-modal and multi-modal false arrhythmia alarm reduction using attentionbased convolutional and recurrent neural networks (2020) *PLoS ONE*, . DOI: 10.1371/journal.pone.0226990
- 207) Hashimoto, D.A., Witkowski, E., Gao, L., Meireles, O., Rosman, G. Artificial intelligence in anesthesiology: Current techniques, clinical applications, and limitations (2020) *Anesthesiology*, . DOI: 10.1097/ALN.0000000000002960

- 208) Sung, C.-W., Shieh, J.-S., Chang, W.-T., Lee, Y.-W., Lyu, J.-H., Ong, H.-N., Chen, W.-T., Huang, C.-H., Chen, W.-J., Jaw, F.-S. Machine Learning Analysis of Heart Rate Variability for the Detection of Seizures in Comatose Cardiac Arrest Survivors (2020) IEEE Access, . DOI: 10.1109/ACCESS.2020.3020742
- 209) Grupo de Trabajo Gripe A Grave (GETGAG) de la Sociedad Espanola de Medicina Intensiva Critica y Unidades Coronarias (SEMICYUC) Spanish Influenza Score (SIS): Usefulness of machine learning in the development of an early mortality prediction score in severe influenza [Spanish Influenza Score (SIS): utilidad del Machine Learning en el desarrollo de una escala temprana de predicción de mortalidad en la gripe grave] (2020) Medicina Intensiva, . DOI: 10.1016/j.medin.2020.05.017
- 210) Choi, J., Bessoif, K., Bromley-Dulfano, R., Li, Z., Gupta, A., Taylor, K., Wadhwa, H., Seltzer, R., Spain, D.A., Knowlton, L.M. Prospectively Assigned AAST Grade versus Modified Hinchey Class and Acute Diverticulitis Outcomes (2020) Journal of Surgical Research, . DOI: 10.1016/j.jss.2020.10.016
- 211) Zhang, Z., Han, J., Qian, K., Janott, C., Guo, Y., Schuller, B. Snore-GANs: Improving Automatic Snore Sound Classification with Synthesized Data (2020) IEEE Journal of Biomedical and Health Informatics, . DOI: 10.1109/JBHI.2019.2907286
- 212) Kamousi, 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 (2020) Neurocritical Care, . DOI: 10.1007/s12028-020-01120-0
- 213) Wu, Y., Zeng, M., Fei, Z., Yu, Y., Wu, F.-X., Li, M. KAICD: A knowledge attention-based deep learning framework for automatic ICD coding (2020) Neurocomputing, . DOI: 10.1016/j.neucom.2020.05.115
- 214) Røst, T.B., Tvedt, C.R., Husby, H., Berg, I.A., Nytrø, Ø. Identifying catheter-related events through sentence classification (2020) International Journal of Data Mining and Bioinformatics, . DOI: 10.1504/IJDMB.2020.107877
- 215) Gajowniczek, K., Grzegorzczak, I., Ząbkowski, T., Bajaj, C. Weighted random forests to improve arrhythmia classification (2020) Electronics (Switzerland), . DOI: 10.3390/electronics9010099
- 216) Olson, D.M., Dombrowski, K., Lynch, C., Mace, B., Sinha, R., Spainhour, S., Naglich, M., Riemen, K., Kolls, B.J. Comparison of health record vitals and continuously acquired vitals data identifies key differences in clinical impression (2020) Informatics in Medicine Unlocked, . DOI: 10.1016/j.imu.2020.100379
- 217) Hüser, M., Kündig, A., Karlen, W., De Luca, V., Jaggi, M. Forecasting intracranial hypertension using multi-scale waveform metrics (2020) Physiological Measurement, . DOI: 10.1088/1361-6579/ab6360
- 218) Baniasadi, A., Rezaeirad, S., Zare, H., Ghassemi, M.M. Two-Step Imputation and AdaBoost-Based Classification for Early Prediction of Sepsis on Imbalanced Clinical Data (2020) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000004705
- 219) Li, K., Wu, H., Pan, F., Chen, L., Feng, C., Liu, Y., Hui, H., Cai, X., Che, H., Ma, Y., Li, T. A Machine Learning-Based Model to Predict Acute Traumatic Coagulopathy in Trauma Patients Upon Emergency Hospitalization (2020) Clinical and Applied Thrombosis/Hemostasis, . DOI: 10.1177/1076029619897827
- 220) Kline, J.E., Sita Priyanka Illapani, V., He, L., Parikh, N.A. Automated brain morphometric biomarkers from MRI at term predict motor development in very preterm infants (2020) NeuroImage: Clinical, . DOI: 10.1016/j.nicl.2020.102475
- 221) Gonzalez, H.A., Muzaffar, S., Yoo, J., Elfadel, I.M. BioCNN: A Hardware Inference Engine for EEG-Based Emotion Detection (2020) IEEE Access, . DOI: 10.1109/ACCESS.2020.3012900
- 222) Miao, F., Liu, Z.-D., Liu, J.-K., Wen, B., He, Q.-Y., Li, Y. Multi-Sensor Fusion Approach for Cuff-Less Blood Pressure Measurement (2020) IEEE Journal of Biomedical and Health Informatics, . DOI: 10.1109/JBHI.2019.2901724
- 223) Dieterle, M.G., Putler, R., Perry, D.A., Menon, A., Abernathy-Close, L., Perlman, N.S., Penkevich, A., Standke, A., Keidan, M., Vendrov, K.C., Bergin, I.L., Young, V.B., Rao, K. Systemic inflammatory mediators are effective biomarkers for predicting adverse outcomes in clostridioides difficile infection (2020) mBio, . DOI: 10.1128/mBio.00180-20
- 224) Cannesson, M., Hofer, I., Rinehart, J., Lee, C., Subramaniam, K., Baldi, P., Dubrawski, A., Pinsky, M.R. Machine learning of physiological waveforms and electronic health record data to predict, diagnose and treat haemodynamic instability in surgical patients: Protocol for a retrospective study (2019) BMJ Open, . DOI: 10.1136/bmjopen-2019-031988
- 225) King, A.J., Cooper, G.F., Clermont, G., Hochheiser, H., Hauskrecht, M., Sittig, D.F., Visweswaran, S. Using machine learning to selectively highlight patient information (2019) Journal of Biomedical Informatics, . DOI: 10.1016/j.jbi.2019.103327
- 226) Spangler, D., Hermansson, T., Smekal, D., Blomberg, H. A validation of machine learning-based risk scores in the prehospital setting (2019) PLoS ONE, . DOI: 10.1371/journal.pone.0226518
- 227) Yoon, J.H., Mu, L., Chen, L., Dubrawski, A., Hravnak, M., Pinsky, M.R., Clermont, G. Predicting tachycardia as a surrogate for instability in the intensive care unit (2019) Journal of Clinical Monitoring and Computing, . DOI: 10.1007/s10877-019-00277-0
- 228) Raj, R., Luostarinen, T., Pursiainen, E., Posti, J.P., Takala, R.S.K., Bendel, S., Konttila, T., Korja, M. Machine learning-based dynamic mortality prediction after traumatic brain injury (2019) Scientific Reports, . DOI: 10.1038/s41598-019-53889-6

- 229) Harutyunyan, H., Khachatryan, H., Kale, D.C., Ver Steeg, G., Galstyan, A. Multitask learning and benchmarking with clinical time series data (2019) *Scientific Data*, . DOI: 10.1038/s41597-019-0103-9
- 230) Liu, R., Greenstein, J.L., Granite, S.J., Fackler, J.C., Bembea, M.M., Sarma, S.V., Winslow, R.L. Data-driven discovery of a novel sepsis pre-shock state predicts impending septic shock in the ICU (2019) *Scientific Reports*, . DOI: 10.1038/s41598-019-42637-5
- 231) Nagori, A., Dhingra, L.S., Bhatnagar, A., Lodha, R., Sethi, T. Predicting Hemodynamic Shock from Thermal Images using Machine Learning (2019) *Scientific Reports*, . DOI: 10.1038/s41598-018-36586-8
- 232) Fagerström, J., Bång, M., Wilhelms, D., Chew, M.S. LiSep LSTM: A Machine Learning Algorithm for Early Detection of Septic Shock (2019) *Scientific Reports*, . DOI: 10.1038/s41598-019-51219-4
- 233) Gasparrini, A.J., Wang, B., Sun, X., Kennedy, E.A., Hernandez-Leyva, A., Ndao, I.M., Tarr, P.I., Warner, B.B., Dantas, G. Persistent metagenomic signatures of early-life hospitalization and antibiotic treatment in the infant gut microbiota and resistome (2019) *Nature Microbiology*, . DOI: 10.1038/s41564-019-0550-2
- 234) Kwizera, A., Kisson, N., Musa, N., Urayeneza, O., Mujiyugamba, P., Patterson, A.J., Harmon, L., Farmer, J.C., Dünser, M.W., Meier, J. A Machine Learning-Based Triage Tool for Children with Acute Infection in a Low Resource Setting (2019) *Pediatric Critical Care Medicine*, . DOI: 10.1097/PCC.0000000000002121
- 235) Sánchez-Hernández, F., Ballesteros-Herráez, J.C., Kraiem, M.S., Sánchez-Barba, M., Moreno-García, N. Predictive modeling of ICU healthcare-associated infections from imbalanced data. Using ensembles and a clustering-based undersampling approach (2019) *Applied Sciences (Switzerland)*, . DOI: 10.3390/app9245287
- 236) Rohaut, B., Doyle, K.W., Reynolds, A.S., Igwe, K., Couch, C., Matory, A., Rizvi, B., Roh, D., Velazquez, A., Meghani, M., Park, S., Agarwal, S., Mauro, C.M., Li, G., Eliseyev, A., Perlberg, V., Connolly, S., Brickman, A.M., Claassen, J. Deep structural brain lesions associated with consciousness impairment early after hemorrhagic stroke (2019) *Scientific Reports*, . DOI: 10.1038/s41598-019-41042-2
- 237) Dai, L., Mick, S.L., McCrae, K.R., Houghtaling, P.L., Blackstone, E.H., Koch, C.G. Prognostic Value of Preoperative Red Cell Distribution Width: Fine-Tuning by Mean Corpuscular Volume (2019) *Annals of Thoracic Surgery*, . DOI: 10.1016/j.athoracsur.2019.04.072
- 238) Mandalapu, V., Ghaemmaghami, B., Mitchell, R., Gong, J. Understanding the relationship between healthcare processes and in-hospital weekend mortality using MIMIC III (2019) *Smart Health*, . DOI: 10.1016/j.smhl.2019.100084
- 239) König, R., Cao, X., Oswald, M., Forstner, C., Rohde, G., Rupp, J., Witzernath, M., Welte, T., Kolditz, M., Pletz, M., for the CAPNETZ study group Macrolide combination therapy for patients hospitalised with community-acquired pneumonia? An individualised approach supported by machine learning (2019) *European Respiratory Journal*, . DOI: 10.1183/13993003.00824-2019
- 240) Massaad, E., Fatima, N., Hadzipasic, M., Alvarez-Breckenridge, C., Shankar, G.M., Shin, J.H. Predictive analytics in spine oncology research: First steps, limitations, and future directions (2019) *Neurospine*, . DOI: 10.14245/ns.1938402.201
- 241) Menin, D., Costabile, A., Tenuta, F., Oster, H., Dondi, M. Identifying fetal yawns based on temporal dynamics of mouth openings: A preterm neonate model using support vector machines (SVMs) (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0226921
- 242) Churpek, M.M., Carey, K.A., Dela Merced, N., Prister, J., Brofman, J., Edelson, D.P. Validation of Early Warning Scores at Two Long-Term Acute Care Hospitals (2019) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000004026
- 243) Al-Mufti, F., Kim, M., Dodson, V., Sursal, T., Bowers, C., Cole, C., Scurlock, C., Becker, C., Gandhi, C., Mayer, S.A. Machine Learning and Artificial Intelligence in Neurocritical Care: a Specialty-Wide Disruptive Transformation or a Strategy for Success (2019) *Current Neurology and Neuroscience Reports*, . DOI: 10.1007/s11910-019-0998-8
- 244) Huang, L., Shea, A.L., Qian, H., Masurkar, A., Deng, H., Liu, D. Patient clustering improves efficiency of federated machine learning to predict mortality and hospital stay time using distributed electronic medical records (2019) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2019.103291
- 245) Park, S., Lee, H. Acute kidney injury prediction models: Current concepts and future strategies (2019) *Current Opinion in Nephrology and Hypertension*, . DOI: 10.1097/MNH.0000000000000536
- 246) Deliberato, R.O., Escudero, G.G., Bulgarelli, L., Neto, A.S., Ko, S.Q., Campos, N.S., Saat, B., Amaro, E., Júnior, Lopes, F.S., Johnson, A.E. SEVERITAS: An externally validated mortality prediction for critically ill patients in low and middle-income countries (2019) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2019.103959
- 247) Kim, H.-J., Min, H.-J., Lee, D.-S., Choi, Y.-Y., Yoon, M., Lee, D.-Y., Song, I.-A., Cho, J.-Y., Park, J.S., Cho, Y.-J., Jo, Y.-H., Yoon, H.I., Lee, J.H., Lee, C.-T., Lee, Y.J. Performance of patient acuity rating by rapid response team nurses for predicting short-term prognosis (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0225229
- 248) Kayhanian, S., Young, A.M.H., Mangla, C., Jalloh, I., Fernandes, H.M., Garnett, M.R., Hutchinson, P.J., Agrawal, S. Modelling outcomes after paediatric brain injury with admission laboratory values: a machine-learning approach (2019) *Pediatric Research*, . DOI: 10.1038/s41390-019-0510-9

- 249) Zampieri, F.G., Salluh, J.I.F., Azevedo, L.C.P., Kahn, J.M., Damiani, L.P., Borges, L.P., Viana, W.N., Costa, R., Corrêa, T.D., Araya, D.E.S., Maia, M.O., Ferez, M.A., Carvalho, A.G.R., Knibel, M.F., Melo, U.O., Santino, M.S., Lisboa, T., Caser, E.B., Besen, B.A.M.P., Bozza, F.A., Angus, D.C., Soares, M., the ORCHESTRA Study Investigators ICU staffing feature phenotypes and their relationship with patients' outcomes: an unsupervised machine learning analysis (2019) *Intensive Care Medicine*, . DOI: 10.1007/s00134-019-05790-z
- 250) Asgari, S., Adams, H., Kasproicz, M., Czosnyka, M., Smielewski, P., Ercole, A. Feasibility of hidden Markov models for the description of time-varying physiologic state after severe traumatic brain injury (2019) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000003966
- 251) Rush, B., Celi, L.A., Stone, D.J. Applying machine learning to continuously monitored physiological data (2019) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-018-0219-z
- 252) Núñez Reiz, A., Armengol de la Hoz, M.A., Sánchez García, M. Big Data Analysis and Machine Learning in Intensive Care Units [Big Data Analysis y Machine Learning en medicina intensiva] (2019) *Medicina Intensiva*, . DOI: 10.1016/j.medin.2018.10.007
- 253) Caicedo-Torres, W., Gutierrez, J. ISeeU: Visually interpretable deep learning for mortality prediction inside the ICU (2019) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2019.103269
- 254) Ding, X.-F., Li, J.-B., Liang, H.-Y., Wang, Z.-Y., Jiao, T.-T., Liu, Z., Yi, L., Bian, W.-S., Wang, S.-P., Zhu, X., Sun, T.-W. Predictive model for acute respiratory distress syndrome events in ICU patients in China using machine learning algorithms: A secondary analysis of a cohort study (2019) *Journal of Translational Medicine*, . DOI: 10.1186/s12967-019-2075-0
- 255) Chandar, V.R.K., Thangamani, M. Suppression of noises using fast independent component analysis (FICA) and signal saturation using fuzzy adaptive histogram equalization (FAHE) for intensive care unit false alarms (2019) *Measurement: Journal of the International Measurement Confederation*, . DOI: 10.1016/j.measurement.2019.02.007
- 256) Scherpf, M., Gräßler, F., Malberg, H., Zaunseder, S. Predicting sepsis with a recurrent neural network using the MIMIC III database (2019) *Computers in Biology and Medicine*, . DOI: 10.1016/j.compbiomed.2019.103395
- 257) Koutsiana, E., Chytas, A., Vaporidi, K., Chouvarda, I. Smart alarms towards optimizing patient ventilation in intensive care: The driving pressure case (2019) *Physiological Measurement*, . DOI: 10.1088/1361-6579/ab4119
- 258) Komorowski, M. Artificial intelligence in intensive care: are we there yet? (2019) *Intensive Care Medicine*, . DOI: 10.1007/s00134-019-05662-6
- 259) Schamoni, S., Lindner, H.A., Schneider-Lindner, V., Thiel, M., Riezler, S. Leveraging implicit expert knowledge for non-circular machine learning in sepsis prediction (2019) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2019.101725
- 260) Khan, F.H., Fazal, M. Artificial intelligence--- Future of Anaesthesiology!! (2019) *Anaesthesia, Pain and Intensive Care*, . DOI: 10.35975/apic.v23i3.1130
- 261) Layeghian Javan, S., Sepehri, M.M., Layeghian Javan, M., Khatibi, T. An intelligent warning model for early prediction of cardiac arrest in sepsis patients (2019) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2019.06.010
- 262) Aperia, Y., Cohen, L., Bendavid, I., Cohen, J., Grozovsky, E., Rotem, T., Singer, P. Improved ICU mortality prediction based on SOFA scores and gastrointestinal parameters (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0222599
- 263) Tran, N.K., Sen, S., Palmieri, T.L., Lima, K., Falwell, S., Wajda, J., Rashidi, H.H. Artificial intelligence and machine learning for predicting acute kidney injury in severely burned patients: A proof of concept (2019) *Burns*, . DOI: 10.1016/j.burns.2019.03.021
- 264) Suresh, M.R., Chung, K.K., Schiller, A.M., Holley, A.B., Howard, J.T., Convertino, V.A. Unmasking the Hypovolemic Shock Continuum: The Compensatory Reserve (2019) *Journal of Intensive Care Medicine*, . DOI: 10.1177/0885066618790537
- 265) Shillan, D., Sterne, J.A.C., Champneys, A., Gibbison, B. Use of machine learning to analyse routinely collected intensive care unit data: A systematic review (2019) *Critical Care*, . DOI: 10.1186/s13054-019-2564-9
- 266) Holmgren, G., Andersson, P., Jakobsson, A., Frigyesi, A. Artificial neural networks improve and simplify intensive care mortality prognostication: A national cohort study of 217,289 first-time intensive care unit admissions (2019) *Journal of Intensive Care*, . DOI: 10.1186/s40560-019-0393-1
- 267) Flechet, M., Falini, S., Bonetti, C., Güiza, F., Schetz, M., Van Den Berghe, G., Meyfroidt, G. Machine learning versus physicians' prediction of acute kidney injury in critically ill adults: A prospective evaluation of the AKIpredictor (2019) *Critical Care*, . DOI: 10.1186/s13054-019-2563-x
- 268) Matam, B.R., Duncan, H., Lowe, D. Machine learning based framework to predict cardiac arrests in a paediatric intensive care unit: Prediction of cardiac arrests (2019) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-018-0198-0
- 269) Kim, S.Y., Kim, S., Cho, J., Kim, Y.S., Sol, I.S., Sung, Y., Cho, I., Park, M., Jang, H., Kim, Y.H., Kim, K.W., Sohn, M.H. A deep learning model for real-time mortality prediction in critically ill children (2019) *Critical Care*, . DOI: 10.1186/s13054-019-2561-z

- 270) Lin, P.-C., Huang, H.-C., Komorowski, M., Lin, W.-K., Chang, C.-M., Chen, K.-T., Li, Y.-C., Lin, M.-C. A machine learning approach for predicting urine output after fluid administration (2019) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2019.05.009
- 271) Huang, J., Osorio, C., Sy, L.W. An empirical evaluation of deep learning for ICD-9 code assignment using MIMIC-III clinical notes (2019) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2019.05.024
- 272) Pirracchio, R., Cohen, M.J., Malenica, I., Cohen, J., Chambaz, A., Cannesson, M., Lee, C., Resche-Rigon, M., Hubbard, A., the ACTERREA Research Group Big data and targeted machine learning in action to assist medical decision in the ICU (2019) *Anaesthesia Critical Care and Pain Medicine*, . DOI: 10.1016/j.accpm.2018.09.008
- 273) Messinger, A.I., Bui, N., Wagner, B.D., Szeffler, S.J., Vu, T., Deterding, R.R. Novel pediatric-automated respiratory score using physiologic data and machine learning in asthma (2019) *Pediatric Pulmonology*, . DOI: 10.1002/ppul.24342
- 274) Si, Y., Wang, J., Xu, H., Roberts, K. Enhancing clinical concept extraction with contextual embeddings (2019) *Journal of the American Medical Informatics Association*, . DOI: 10.1093/jamia/ocz096
- 275) Zador, Z., Landry, A., Cusimano, M.D., Geifman, N. Mltimorbidity states associated with higher mortality rates in organ dysfunction and sepsis: A data-driven analysis in critical care (2019) *Critical Care*, . DOI: 10.1186/s13054-019-2486-6
- 276) Ofman, G., Caballero, M.T., Alvarez Paggi, D., Marzec, J., Nowogrodzki, F., Cho, H.-Y., Sorgetti, M., Colantonio, G., Bianchi, A., Prudent, L.M., Vain, N., Mariani, G., Digregorio, J., Turconi, E.L., Osio, C., Galletti, F., Quiros, M., Brum, A., Lopez Garcia, S., Garcia, S., Bell, D., Jones, M.H., Tipple, T.E., Kleeberger, S.R., Polack, F.P. The discovery BPD (D-BPD) program: Study protocol of a prospective translational multicenter collaborative study to investigate determinants of chronic lung disease in very low birth weight infants (2019) *BMC Pediatrics*, . DOI: 10.1186/s12887-019-1610-8
- 277) Bender, W., Hiddleston, C.A., Buchman, T.G. Intensive Care Unit Telemedicine: Innovations and Limitations (2019) *Critical Care Clinics*, . DOI: 10.1016/j.ccc.2019.02.011
- 278) Kindle, R.D., Badawi, O., Celi, L.A., Sturland, S. Intensive Care Unit Telemedicine in the Era of Big Data, Artificial Intelligence, and Computer Clinical Decision Support Systems (2019) *Critical Care Clinics*, . DOI: 10.1016/j.ccc.2019.02.005
- 279) Lin, Y.-W., Zhou, Y., Faghri, F., Shaw, M.J., Campbell, R.H. Analysis and prediction of unplanned intensive care unit readmission using recurrent neural networks with long shortterm memory (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0218942
- 280) Struck, A.F., Rodriguez-Ruiz, A.A., Osman, G., Gilmore, E.J., Haider, H.A., Dhakar, M.B., Schrettner, M., Lee, J.W., Gaspard, N., Hirsch, L.J., Westover, M.B., Critical Care EEG Monitoring Research Consortium (CCERMRC) Comparison of machine learning models for seizure prediction in hospitalized patients (2019) *Annals of Clinical and Translational Neurology*, . DOI: 10.1002/acn3.50817
- 281) Manna, T., Swetapadma, A., Abdar, M. Decision Tree Predictive Learner-Based Approach for False Alarm Detection in ICU (2019) *Journal of Medical Systems*, . DOI: 10.1007/s10916-019-1337-y
- 282) Ruiz, V.M., Saenz, L., Lopez-Magallon, A., Shields, A., Ogoe, H.A., Suresh, S., Munoz, R., Tsui, F.R. Early prediction of critical events for infants with single-ventricle physiology in critical care using routinely collected data (2019) *Journal of Thoracic and Cardiovascular Surgery*, . DOI: 10.1016/j.jtcvs.2019.01.130
- 283) S. Krishnan, G., S., S.K. A novel GA-ELM model for patient-specific mortality prediction over large-scale lab event data (2019) *Applied Soft Computing Journal*, . DOI: 10.1016/j.asoc.2019.04.019
- 284) Radhakrishnan, S., Nair, S.G., Isaac, J. Analysis of parameters affecting blood oxygen saturation and modeling of fuzzy logic system for inspired oxygen prediction (2019) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2019.04.014
- 285) Bahado-Singh, R.O., Sonek, J., McKenna, D., Cool, D., Aydas, B., Turkoglu, O., Bjorndahl, T., Mandal, R., Wishart, D., Friedman, P., Graham, S.F., Yilmaz, A. Artificial intelligence and amniotic fluid multiomics: prediction of perinatal outcome in asymptomatic women with short cervix (2019) *Ultrasound in Obstetrics and Gynecology*, . DOI: 10.1002/uog.20168
- 286) Shirwaikar, R.D., Acharya U, D., Makkithaya, K., M, S., Srivastava, S., Lewis U, L.E.S. Optimizing neural networks for medical data sets: A case study on neonatal apnea prediction (2019) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2019.07.008
- 287) Kramer, A.A., Sebat, F., Lissauer, M. A review of early warning systems for prompt detection of patients at risk for clinical decline (2019) *The journal of trauma and acute care surgery*, . DOI: 10.1097/TA.0000000000002197
- 288) Mayampurath, A., Sanchez-Pinto, L.N., Carey, K.A., Venable, L.-R., Churpek, M. Combining patient visual timelines with deep learning to predict mortality (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0220640
- 289) Claassen, J., Doyle, K., Matory, A., Couch, C., Burger, K.M., Velazquez, A., Okonkwo, J.U., King, J.-R., Park, S., Agarwal, S., Roh, D., Megjhani, M., Elisseyev, A., Sander Connolly, E., Rohaut, B. Detection of brain activation in unresponsive patients with acute brain injury (2019) *New England Journal of Medicine*, .DOI: 10.1056/NEJMoa1812757

- 290) Saugel, B., Kouz, K., Hoppe, P., Maheshwari, K., Scheeren, T.W.L. Predicting hypotension in perioperative and intensive care medicine (2019) *Best Practice and Research: Clinical Anaesthesiology*, . DOI: 10.1016/j.bpa.2019.04.001
- 291) Martínez-Agüero, S., Mora-Jiménez, I., Lérída-García, J., Álvarez-Rodríguez, J., Soguero-Ruiz, C. Machine learning techniques to identify antimicrobial resistance in the intensive care unit (2019) *Entropy*, . DOI: 10.3390/e21060603
- 292) 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 (2019) *Resuscitation*, . DOI: 10.1016/j.resuscitation.2019.04.002
- 293) López-Martínez, F., Núñez-Valdez, E.R., Lorduy Gomez, J., García-Díaz, V. A neural network approach to predict early neonatal sepsis (2019) *Computers and Electrical Engineering*, . DOI: 10.1016/j.compeleceng.2019.04.015
- 294) Van Steenkiste, T., Ruyssinck, J., De Baets, L., Decruyenaere, J., De Turck, F., Ongenaes, F., Dhaene, T. Accurate prediction of blood culture outcome in the intensive care unit using long short-term memory neural networks (2019) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2018.10.008
- 295) Barton, C., Chettipally, U., Zhou, Y., Jiang, Z., Lynn-Palevsky, A., Le, S., Calvert, J., Das, R. Evaluation of a machine learning algorithm for up to 48-hour advance prediction of sepsis using six vital signs (2019) *Computers in Biology and Medicine*, . DOI: 10.1016/j.combiomed.2019.04.027
- 296) Khanna, A.K., Ahuja, S., Weller, R.S., Harwood, T.N. Postoperative ward monitoring – Why and what now? (2019) *Best Practice and Research: Clinical Anaesthesiology*, . DOI: 10.1016/j.bpa.2019.06.005
- 297) Nielsen, A.B., Thorsen-Meyer, H.-C., Belling, K., Nielsen, A.P., Thomas, C.E., Chmura, P.J., Lademann, M., Moseley, P.L., Heimann, M., Dybdahl, L., Spangsege, L., Hulsen, P., Perner, A., 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 (2019) *The Lancet Digital Health*, . DOI: 10.1016/S2589-7500(19)30024-X
- 298) Junqueira, A.R.B., Mirza, F., Baig, M.M. A machine learning model for predicting ICU readmissions and key risk factors: analysis from a longitudinal health records (2019) *Health and Technology*, . DOI: 10.1007/s12553-019-00329-0
- 299) Lee, S., Zhao, X., Davis, K.A., Topjian, A.A., Litt, B., Abend, N.S. Quantitative EEG predicts outcomes in children after cardiac arrest (2019) *Neurology*, . DOI: 10.1212/WNL.0000000000007504
- 300) Lin, K., Hu, Y., Kong, G. Predicting in-hospital mortality of patients with acute kidney injury in the ICU using random forest model (2019) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2019.02.002
- 301) Li, B.Y., Oh, J., Young, V.B., Rao, K., Wiens, J. Using Machine learning and the electronic health record to predict complicated clostridium difficile infection (2019) *Open Forum Infectious Diseases*, . DOI: 10.1093/ofid/ofz186
- 302) Goodman, K.E., Simner, P.J., Klein, E.Y., Kazmi, A.Q., Gadala, A., Toerper, M.F., Levin, S., Tamma, P.D., Rock, C., Cosgrove, S.E., Maragakis, L.L., Milstone, A.M. Predicting probability of perirectal colonization with carbapenem-resistant Enterobacteriaceae (CRE) and other carbapenem-resistant organisms (CROs) at hospital unit admission (2019) *Infection Control and Hospital Epidemiology*, . DOI: 10.1017/ice.2019.42
- 303) Brennan, M., Puri, S., Ozrazgat-Baslanti, T., Feng, Z., Ruppert, M., Hashemighouchani, H., Momcilovic, P., Li, X., Wang, D.Z., Bihorac, A. Comparing clinical judgment with the MySurgeryRisk algorithm for preoperative risk assessment: A pilot usability study (2019) *Surgery (United States)*, . DOI: 10.1016/j.surg.2019.01.002
- 304) Muñoz, I.C., Hernández, A.M., Mañanas, M.Á. Estimation of work of breathing from respiratory muscle activity in spontaneous ventilation: A pilot study (2019) *Applied Sciences (Switzerland)*, . DOI: 10.3390/app9102007
- 305) Yu, C., Liu, J., Zhao, H. Inverse reinforcement learning for intelligent mechanical ventilation and sedative dosing in intensive care units (2019) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/s12911-019-0763-6
- 306) Zhang, Z., Ho, K.M., Hong, Y. Machine learning for the prediction of volume responsiveness in patients with oliguric acute kidney injury in critical care (2019) *Critical Care*, . DOI: 10.1186/s13054-019-2411-z
- 307) Liao, Y.-H., Wang, Z.-C., Zhang, F.-G., Abbod, M.F., Shih, C.-H., Shieh, J.-S. Machine learning methods applied to predict ventilator-associated pneumonia with pseudomonas aeruginosa infection via sensor array of electronic nose in intensive care unit (2019) *Sensors (Switzerland)*, . DOI: 10.3390/s19081866
- 308) Muller, E., Shock, J.P., Bender, A., Kleeberger, J., Högen, T., Rosenfelder, M., Bah, B., Lopez-Rolon, A. Zutcome prediction with serial neuron-specific enolase and machine learning in anoxic-ischaemic disorders of consciousness (2019) *Computers in Biology and Medicine*, . DOI: 10.1016/j.combiomed.2019.02.006
- 309) Yang, Z., Tan, E.H., Li, Y., Lim, B., Metz, M.P., Loh, T.P. Relative criticalness of common laboratory tests for critical value reporting (2019) *Journal of Clinical Pathology*, . DOI: 10.1136/jclinpath-2018-205549

- 310) Vauchel, T., Pirracchio, R., Chaussard, M., Lafaurie, M., Rouveau, M., Rousseau, C., Benyamina, M., Soussi, S., Dépret, F., Ferry, A., Oueslati, H., Chaouat, M., Mimoun, M., Jarlier, V., Moreno, N., Mebazaa, A., Legrand, M. Impact of an *Acinetobacter baumannii* outbreak on kidney events in a burn unit: A targeted machine learning analysis (2019) *American Journal of Infection Control*, . DOI: 10.1016/j.ajic.2018.09.010
- 311) Bihorac, A., Ozrazgat-Baslanti, T., Ebadi, A., Motaei, A., Madkour, M., Pardalos, P.M., Lipori, G., Hogan, W.R., Efron, P.A., Moore, F., Moldawer, L.L., Wang, D.Z., Hobson, C.E., Rashidi, P., Li, X., Momcilovic, P. MySurgeryRisk: Development and Validation of a Machine-learning Risk Algorithm for Major Complications and Death After Surgery (2019) *Annals of surgery*, . DOI: 10.1097/SLA.0000000000002706
- 312) Gajowniczek, K., Grzegorzczak, I., Ząbkowski, T. Reducing false arrhythmia alarms using different methods of probability and class assignment in random forest learning methods (2019) *Sensors (Switzerland)*, . DOI: 10.3390/s19071588
- 313) Kasparick, M., Andersen, B., Franke, S., Rockstroh, M., Golatowski, F., Timmermann, D., Ingenerf, J., Neumuth, T. Enabling artificial intelligence in high acuity medical environments (2019) *Minimally Invasive Therapy and Allied Technologies*, . DOI: 10.1080/13645706.2019.1599957
- 314) Mathur, P., Md, Fccm, Burns, M.L., Md, PhD Artificial Intelligence in Critical Care (2019) *International Anesthesiology Clinics*, . DOI: 10.1097/AIA.0000000000000221
- 315) McWilliams, C.J., Lawson, D.J., Santos-Rodriguez, R., Gilchrist, I.D., Champneys, A., Gould, T.H., Thomas, M.J., Bourdeaux, C.P. Towards a decision support tool for intensive care discharge: Machine learning algorithm development using electronic healthcare data from MIMIC-III and Bristol, UK (2019) *BMJ Open*, . DOI: 10.1136/bmjopen-2018-025925
- 316) Kwong, M.T., Colopy, G.W., Weber, A.M., Ercole, A., Bergmann, J.H.M. The efficacy and effectiveness of machine learning for weaning in mechanically ventilated patients at the intensive care unit: a systematic review (2019) *Bio-Design and Manufacturing*, . DOI: 10.1007/s42242-018-0030-1
- 317) Padmanabhan, R., Meskin, N., Haddad, W.M. Optimal adaptive control of drug dosing using integral reinforcement learning (2019) *Mathematical Biosciences*, . DOI: 10.1016/j.mbs.2019.01.012
- 318) Linnen, D.T., Escobar, G.J., Hu, X., Scruth, E., Liu, V., Stephens, C. Statistical modeling and aggregate-weighted scoring systems in prediction of mortality and ICU transfer: A systematic review (2019) *Journal of Hospital Medicine*, . DOI: 10.12788/jhm.3151
- 319) Zeiberg, D., Prahlad, T., Nallamothu, B.K., Iwashyna, T.J., Wiens, J., Sjoding, M.W. Machine learning for patient risk stratification for acute respiratory distress syndrome (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0214465
- 320) Raita, Y., Goto, T., Faridi, M.K., Brown, D.F.M., Camargo, C.A., Jr., Hasegawa, K. Emergency department triage prediction of clinical outcomes using machine learning models (2019) *Critical Care*, . DOI: 10.1186/s13054-019-2351-7
- 321) Lopansri, B.K., Miller, R.R., III, Burke, J.P., Levy, M., Opal, S., Rothman, R.E., D'Alessio, F.R., Sidhaye, V.K., Balk, R., Greenberg, J.A., Yoder, M., Patel, G.P., Gilbert, E., Afshar, M., Parada, J.P., Martin, G.S., Esper, A.M., Kempker, J.A., Narasimhan, M., Tsegaye, A., Hahn, S., Mayo, P., McHugh, L., Rapisarda, A., Sampson, D., Brandon, R.A., Seldon, T.A., Yager, T.D., Brandon, R.B. Physician agreement on the diagnosis of sepsis in the intensive care unit: Estimation of concordance and analysis of underlying factors in a multicenter cohort (2019) *Journal of Intensive Care*, . DOI: 10.1186/s40560-019-0368-2
- 322) Donald, R., Howells, T., Piper, I., Enblad, P., Nilsson, P., Chambers, I., Gregson, B.A., Citerio, G., Kiening, K., Neumann, J., Ragauskas, A., Sahuquillo, J., Sinnott, R., Stell, A., Pickard, J., Whittle, I., Dunn, Rydenhag, B., Iencean, S., Pavalkis, Meixensberger, Goffin, J., Vajkoczy, P., Stocchetti, N., Corte, D., Hell, Mascia, L., Jarzemaskas, Stocker, R., Mattern, J., Yau, Y.H., Wyper, D., Kiefer, M., de Jong, D., Gjerris, F., Hill, S., Cruickshank, G., Watkins, L., the BrainIT Group Forewarning of hypotensive events using a Bayesian artificial neural network in neurocritical care (2019) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-018-0139-y
- 323) Park, S., Megjhani, M., Frey, H.-P., Grave, E., Wiggins, C., Terilli, K.L., Roh, D.J., Velazquez, A., Agarwal, S., Connolly, E.S., Jr., Schmidt, J.M., Claassen, J., Elhadad, N. Predicting delayed cerebral ischemia after subarachnoid hemorrhage using physiological time series data (2019) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-018-0132-5
- 324) Masino, A.J., Harris, M.C., Forsyth, D., Ostapenko, S., Srinivasan, L., Bonafide, C.P., Balamuth, F., Schmatz, M., Grundmeier, R.W. Machine learning models for early sepsis recognition in the neonatal intensive care unit using readily available electronic health record data (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0212665
- 325) Chan, A., Chien, I., Moseley, E., Salman, S., Kaminer Bourland, S., Lamas, D., Walling, A.M., Tulsy, J.A., Lindvall, C. Deep learning algorithms to identify documentation of serious illness conversations during intensive care unit admissions (2019) *Palliative Medicine*, . DOI: 10.1177/0269216318810421
- 326) Chen, I.Y., Szolovits, P., Ghassemi, M. Can AI help reduce disparities in general medical and mental health care? (2019) *AMA Journal of Ethics*, . DOI: 10.1001/amajethics.2019.167
- 327) Ghazal, S., Sauthier, M., Brossier, D., Bouachir, W., Jouvet, P.A., Noumeir, R. Using machine learning models to predict oxygen saturation following ventilator support adjustment in critically ill children: A single center pilot study (2019) *PLoS ONE*, . DOI: 10.1371/journal.pone.0198921
- 328) van Wyk, F., Khojandi, A., Mohammed, A., Begoli, E., Davis, R.L., Kamaleswaran, R. A minimal set of physiometers in continuous high frequency data streams predict adult sepsis onset earlier (2019) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2018.12.002

- 329) Lazaridis, C., Rusin, C.G., Robertson, C.S. Secondary brain injury: Predicting and preventing insults (2019) *Neuropharmacology*, . DOI: 10.1016/j.neuropharm.2018.06.005
- 330) Golmohammadi, M., Harati Nejad Torbati, A.H., Lopez de Diego, S., Obeid, I., Picone, J. Automatic analysis of EEGs using big data and hybrid deep learning architectures (2019) *Frontiers in Human Neuroscience*, . DOI: 10.3389/fnhum.2019.00076
- 331) Nunez Lopez, Y.O., Retnakaran, R., Zinman, B., Pratley, R.E., Seyhan, A.A. Predicting and understanding the response to short-term intensive insulin therapy in people with early type 2 diabetes (2019) *Molecular Metabolism*, . DOI: 10.1016/j.molmet.2018.11.003
- 332) Zimmerman, L.P., Reyfman, P.A., Smith, A.D.R., Zeng, Z., Kho, A., Sanchez-Pinto, L.N., Luo, Y. Early prediction of acute kidney injury following ICU admission using a multivariate panel of physiological measurements (2019) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/s12911-019-0733-z
- 333) Garmendia, A., Rios, S.A., Lopez-Guede, J.M., Graña, M. Triage prediction in pediatric patients with respiratory problems (2019) *Neurocomputing*, . DOI: 10.1016/j.neucom.2017.01.122
- 334) Goto, T., Camargo, C.A., Jr, Faridi, M.K., Freishtat, R.J., Hasegawa, K. Machine Learning-Based Prediction of Clinical Outcomes for Children During Emergency Department Triage (2019) *JAMA network open*, . DOI: 10.1001/jamanetworkopen.2018.6937
- 335) Kennedy, E.H., Harris, S., Keele, L.J. Survivor-Complier Effects in the Presence of Selection on Treatment, With Application to a Study of Prompt ICU Admission (2019) *Journal of the American Statistical Association*, . DOI: 10.1080/01621459.2018.1469990
- 336) Reiz, A.N., Sagasti, F.M., González, M.Á., Malpica, A.B., Benítez, J.C.M., Cabrera, M.N., Ramírez, Á.P., Perdomo, J.M.G., Alonso, J.P., Celi, L.A., de la Hoz, M.Á.A., Deliberato, R., Paik, K., Pollard, T., Raffa, J., Torres, F., Mayol, J., Chafer, J., Ferrer, A.G., Rey, Á., Luengo, H.G., Fico, G., Lombroni, I., Hernandez, L., López, L., Merino, B., Cabrera, M.F., Arredondo, M.T., Bodí, M., Gómez, J., Rodríguez, A., Sánchez García, M., Organizing Committee of the Madrid 2017 Critical Care Datathon Big data and machine learning in critical care: Opportunities for collaborative research [Big data y machine learning en medicina intensiva: oportunidades del trabajo colaborativo] (2019) *Medicina Intensiva*, . DOI: 10.1016/j.medin.2018.06.002
- 337) Sanz-García, A., Pérez-Romero, M., Pastor, J., Sola, R.G., Vega-Zelaya, L., Vega, G., Monasterio, F., Torrecilla, C., Pulido, P., Ortega, G.J. Potential EEG biomarkers of sedation doses in intensive care patients unveiled by using a machine learning approach (2019) *Journal of Neural Engineering*, . DOI: 10.1088/1741-2552/ab039f
- 338) Medic, G., Kließ, M.K., Atallah, L., Weichert, J., Panda, S., Postma, M., El-Kerdi, A. Evidence-based clinical decision support systems for the prediction and detection of three disease states in critical care: A systematic literature review (2019) *F1000Research*, . DOI: 10.12688/f1000research.20498.1
- 339) Kefi, Z., Aloui, K., Naceur, M.S. New approach based on machine learning for short-term mortality prediction in neonatal intensive care unit (2019) *International Journal of Advanced Computer Science and Applications*, . DOI: 10.14569/ijacsa.2019.0100778
- 340) Bloch, E., Rotem, T., Cohen, J., Singer, P., Aperstein, Y. Machine Learning Models for Analysis of Vital Signs Dynamics: A Case for Sepsis Onset Prediction (2019) *Journal of Healthcare Engineering*, . DOI: 10.1155/2019/5930379
- 341) Joshi, R., Peng, Z., Long, X., Feijs, L., Andriessen, P., Van Pul, C. Predictive Monitoring of Critical Cardiorespiratory Alarms in Neonates under Intensive Care (2019) *IEEE Journal of Translational Engineering in Health and Medicine*, . DOI: 10.1109/JTEHM.2019.2953520
- 342) Chen, T., Xu, J., Ying, H., Chen, X., Feng, R., Fang, X., Gao, H., Wu, J. Prediction of Extubation Failure for Intensive Care Unit Patients Using Light Gradient Boosting Machine (2019) *IEEE Access*, . DOI: 10.1109/ACCESS.2019.2946980
- 343) Beutel, G., Kiehl, M., Stemmler, J., Shimabukuro-Vornhagen, A., Staudinger, T. Caring for the Critically Ill Cancer Patient in 2019 [Intensivmedizinische Versorgung des kritisch kranken Tumorpatienten - Status Quo 2019] (2019) *Deutsche Medizinische Wochenschrift*, . DOI: 10.1055/a-0853-4804
- 344) Vanden Berghe, T., Hoste, E. Paving the way for precision medicine v2.0 in intensive care by profiling necroinflammation in biofluids (2019) *Cell Death and Differentiation*, . DOI: 10.1038/s41418-018-0196-2
- 345) Parreco, J., Soe-Lin, H., Parks, J.J., Byerly, S., Chatoor, M., Buicko, J.L., Namias, N., Rattan, R. Comparing machine learning algorithms for predicting acute kidney injury (2019) *American Surgeon*, .
- 346) Gao, F., Lin, M.-T., Yang, X.-Y., Cai, M.-X., Hao-Nan, Xie, W., Huang, Z.-M. Metabolic acidosis in critically ill patients with cirrhosis: Epidemiology and short-term mortality risk factors (2019) *Turkish Journal of Gastroenterology*, . DOI: 10.5152/tjg.2019.18813
- 347) Liao, C., Rosner, A.O., Maron, J.L., Song, D., Barlow, S.M. Automatic Nonnutritive Suck Waveform Discrimination and Feature Extraction in Preterm Infants (2019) *Computational and Mathematical Methods in Medicine*, . DOI: 10.1155/2019/7496591
- 348) Lucas, A., Hermiz, J., Labuzetta, J., Arabadzhi, Y., Karanjia, N., Gilja, V. Use of Accelerometry for Long Term Monitoring of Stroke Patients (2019) *IEEE Journal of Translational Engineering in Health and Medicine*, . DOI: 10.1109/JTEHM.2019.2897306
- 349) Chen, R., Paschalidis, I.C., Hatabu, H., Valtchinov, V.I., Siegelman, J. Detection of unwarranted CT radiation exposure from patient and imaging protocol meta-data using regularized regression (2019) *European Journal of Radiology Open*, . DOI: 10.1016/j.ejro.2019.04.007

- 350) Wulff, A., Montag, S., Marschollek, M., Jack, T. Clinical Decision-Support Systems for Detection of Systemic Inflammatory Response Syndrome, Sepsis, and Septic Shock in Critically Ill Patients: A Systematic Review (2019) *Methods of Information in Medicine*, . DOI: 10.1055/s-0039-1695717
- 351) Rajkomar, A., Hardt, M., Howell, M.D., Corrado, G., Chin, M.H. Ensuring fairness in machine learning to advance health equity (2018) *Annals of Internal Medicine*, . DOI: 10.7326/M18-1990
- 352) Marafino, B.J., Park, M., Davies, J.M., Thombley, R., Luft, H.S., Sing, D.C., Kazi, D.S., DeJong, C., Boscardin, W.J., Dean, M.L., Dudley, R.A. Validation of Prediction Models for Critical Care Outcomes Using Natural Language Processing of Electronic Health Record Data (2018) *JAMA network open*, . DOI: 10.1001/jamanetworkopen.2018.5097
- 353) Textoris, J., Taccone, F.S., Zafrani, L., Guillon, A., Gibot, S., Uhel, F., Azabou, E., Monneret, G., Pène, F., de Prost, N., Silva, S., the Translational Research Committee of the French Intensive Care Society (Societe de Reanimation de Langue Francaise, SRLF) Data-driving methods: More than merely trendy buzzwords? (2018) *Annals of Intensive Care*, . DOI: 10.1186/s13613-018-0405-7
- 354) Salluh, J.I.F., Chiche, J.D., Reis, C.E., Soares, M. New perspectives to improve critical care benchmarking (2018) *Annals of Intensive Care*, . DOI: 10.1186/s13613-018-0363-0
- 355) Meyer, A., Zverinski, D., Pfahringer, B., Kempfert, J., Kuehne, T., Sündermann, S.H., Stamm, C., Hofmann, T., Falk, V., Eickhoff, C. Machine learning for real-time prediction of complications in critical care: a retrospective study (2018) *The Lancet Respiratory Medicine*, . DOI: 10.1016/S2213-2600(18)30300-X
- 356) Hsieh, M.H., Hsieh, M.J., Chen, C.-M., Hsieh, C.-C., Chao, C.-M., Lai, C.-C. Comparison of machine learning models for the prediction of mortality of patients with unplanned extubation in intensive care units (2018) *Scientific Reports*, . DOI: 10.1038/s41598-018-35582-2
- 357) Carlin, C.S., Ho, L.V., Ledbetter, D.R., Aczon, M.D., Wetzell, R.C. Predicting individual physiologically acceptable states at discharge from a pediatric intensive care unit (2018) *Journal of the American Medical Informatics Association*, . DOI: 10.1093/jamia/ocy122
- 358) Bose, S., Talmor, D. Who is a high-risk surgical patient? (2018) *Current opinion in critical care*, . DOI: 10.1097/MCC.0000000000000556
- 359) Rubbert, C., Patil, K.R., Beseoglu, K., Mathys, C., May, R., Kaschner, M.G., Sigl, B., Teichert, N.A., Boos, J., Turowski, B., Caspers, J. Prediction of outcome after aneurysmal subarachnoid haemorrhage using data from patient admission (2018) *European Radiology*, . DOI: 10.1007/s00330-018-5505-0
- 360) Catling, F., Spithourakis, G.P., Riedel, S. Towards automated clinical coding (2018) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2018.09.021
- 361) Vellido, A., Ribas, V., Morales, C., Ruiz Sanmartín, A., Ruiz Rodríguez, J.C. Machine learning in critical care: State-of-the-art and a sepsis case study (2018) *BioMedical Engineering Online*, . DOI: 10.1186/s12938-018-0569-2
- 362) Alderden, J., Pepper, G.A., Wilson, A., Whitney, J.D., Richardson, S., Butcher, R., Jo, Y., Cummins, M.R. Predicting pressure injury in critical care patients: A machinelearning model (2018) *American Journal of Critical Care*, . DOI: 10.4037/ajcc2018525
- 363) Meiring, C., Dixit, A., Harris, S., MacCallum, N.S., Brealey, D.A., Watkinson, P.J., Jones, A., Ashworth, S., Beale, R., Brett, S.J., Singer, M., Ercole, A. Optimal intensive care outcome prediction over time using machine learning (2018) *PLoS ONE*, . DOI: 10.1371/journal.pone.0206862
- 364) Sanchez-Pinto, L.N., Luo, Y., Churpek, M.M. Big Data and Data Science in Critical Care (2018) *Chest*, . DOI: 10.1016/j.chest.2018.04.037
- 365) Aushev, A., Ripoll, V.R., Vellido, A., Aletti, F., Pinto, B.B., Herpain, A., Post, E.H., Medina, E.R., Ferrer, R., Baselli, G., Bendjelid, K. Feature selection for the accurate prediction of septic and cardiogenic shock ICU mortality in the acute phase (2018) *PLoS ONE*, . DOI: 10.1371/journal.pone.0199089
- 366) Nanayakkara, S., Fogarty, S., Tremeer, M., Ross, K., Richards, B., Bergmeir, C., Xu, S., Stub, D., Smith, K., Tacey, M., Liew, D., Pilcher, D., Kaye, D.M. Characterising risk of in-hospital mortality following cardiac arrest using machine learning: A retrospective international registry study (2018) *PLoS Medicine*, . DOI: 10.1371/journal.pmed.1002709
- 367) Taggart, M., Chapman, W.W., Steinberg, B.A., Ruckel, S., Pregenzer-Wenzler, A., Du, Y., Ferraro, J., Bucher, B.T., Lloyd-Jones, D.M., Rondina, M.T., Shah, R.U. Comparison of 2 Natural Language Processing Methods for Identification of Bleeding Among Critically Ill Patients (2018) *JAMA network open*, . DOI: 10.1001/jamanetworkopen.2018.3451
- 368) Pollard, T.J., Johnson, A.E.W., Raffa, J.D., Celi, L.A., Mark, R.G., Badawi, O. The eICU collaborative research database, a freely available multi-center database for critical care research (2018) *Scientific Data*, . DOI: 10.1038/sdata.2018.178
- 369) Bailly, S., Meyfroidt, G., Timsit, J.-F. What's new in ICU in 2050: big data and machine learning (2018) *Intensive Care Medicine*, . DOI: 10.1007/s00134-017-5034-3
- 370) Goto, T., Camargo, C.A., Jr., Faridi, M.K., Yun, B.J., Hasegawa, K. Machine learning approaches for predicting disposition of asthma and COPD exacerbations in the ED (2018) *American Journal of Emergency Medicine*, . DOI: 10.1016/j.ajem.2018.06.062
- 371) Jeffery, A.D., Dietrich, M.S., Fabbri, D., Kennedy, B., Novak, L.L., Coco, J., Mion, L.C. Advancing in-hospital clinical deterioration prediction models (2018) *American Journal of Critical Care*, . DOI: 10.4037/ajcc2018957

- 372) Chen, Z., Bird, V.Y., Ruchi, R., Segal, M.S., Bian, J., Khan, S.R., Elie, M.-C., Prosperi, M. Development of a personalized diagnostic model for kidney stone disease tailored to acute care by integrating large clinical, demographics and laboratory data: The diagnostic acute care algorithm - Kidney stones (DACA-KS) (2018) BMC Medical Informatics and Decision Making, . DOI: 10.1186/s12911-018-0652-4
- 373) Wong, A., Young, A.T., Liang, A.S., Gonzales, R., Douglas, V.C., Hadley, D. Development and Validation of an Electronic Health Record-Based Machine Learning Model to Estimate Delirium Risk in Newly Hospitalized Patients Without Known Cognitive Impairment (2018) JAMA network open, . DOI: 10.1001/jamanetworkopen.2018.1018
- 374) Parreco, J., Hidalgo, A., Parks, J.J., Kozol, R., Rattan, R. Using artificial intelligence to predict prolonged mechanical ventilation and tracheostomy placement (2018) Journal of Surgical Research, . DOI: 10.11016/j.jss.2018.03.028
- 375) Tomaselli Muensterman, E., Tisdale, J.E. Predictive Analytics for Identification of Patients at Risk for QT Interval Prolongation: A Systematic Review (2018) Pharmacotherapy, . DOI: 10.1002/phar.2146
- 376) Reyes-Garcia, J., Galeana-Zapien, H., Galaviz-Mosqueda, A., Torres-Huitzil, C. Evaluation of the Impact of Data Uncertainty on the Prediction of Physiological Patient Deterioration (2018) IEEE Access, . DOI: 10.1109/ACCESS.2018.2853701
- 377) Williams, J.B., Ghosh, D., Wetzel, R.C. Applying machine learning to pediatric critical care data\* (2018) Pediatric Critical Care Medicine, . DOI: 10.1097/PCC.0000000000001567
- 378) Sánchez Fernández, I., Sansevere, A.J., Gaínza-Lein, M., Kapur, K., Loddenkemper, T. Machine Learning for Outcome Prediction in Electroencephalograph (EEG)-Monitored Children in the Intensive Care Unit (2018) Journal of Child Neurology, . DOI: 10.1177/0883073818773230
- 379) Rojas, J.C., Carey, K.A., Edelson, D.P., Venable, L.R., Howell, M.D., Churpek, M.M. Predicting intensive care unit readmission with machine learning using electronic health record data (2018) Annals of the American Thoracic Society, . DOI: 10.1513/AnnalsATS.201710-787OC
- 380) Purushotham, S., Meng, C., Che, Z., Liu, Y. Benchmarking deep learning models on large healthcare datasets (2018) Journal of Biomedical Informatics, . DOI: 10.1016/j.jbi.2018.04.007
- 381) Park, N., Kang, E., Park, M., Lee, H., Kang, H.-G., Yoon, H.-J., Kang, U. Predicting acute kidney injury in cancer patients using heterogeneous and irregular data (2018) PLoS ONE, .DOI: 10.1371/journal.pone.0199839
- 382) McGillion, M.H., Duceppe, E., Allan, K., Marcucci, M., Yang, S., Johnson, A.P., Ross-Howe, S., Peter, E., Scott, T., Ouellette, C., Henry, S., Le Manach, Y., Paré, G., Downey, B., Carroll, S.L., Mills, J., Turner, A., Clyne, W., Dvirnik, N., Mierdel, S., Poole, L., Nelson, M., Harvey, V., Good, A., Pettit, S., Sanchez, K., Harsha, P., Mohajer, D., Ponnambalam, S., Bhavnani, S., Lamy, A., Whitlock, R., Devereaux, P.J., PROTECT Network Investigators Postoperative Remote Automated Monitoring: Need for and State of the Science (2018) Canadian Journal of Cardiology, . DOI: 10.1016/j.cjca.2018.04.021
- 383) Brooks, B., Olm, M.R., Firek, B.A., Baker, R., Geller-McGrath, D., Reimer, S.R., Soenjoyo, K.R., Yip, J.S., Dahan, D., Thomas, B.C., Morowitz, M.J., Banfield, J.F. The developing premature infant gut microbiome is a major factor shaping the microbiome of neonatal intensive care unit rooms (2018) Microbiome, . DOI: 10.1186/s40168-018-0493-5
- 384) Wollborn, J., Hermann, C., Goebel, U., Merget, B., Wunder, C., Maier, S., Schäfer, T., Heuler, D., Müller-Buschbaum, K., Buerkle, H., Meinel, L., Schick, M.A., Steiger, C. Overcoming safety challenges in CO therapy – Extracorporeal CO delivery under precise feedback control of systemic carboxyhemoglobin levels (2018) Journal of Controlled Release, . DOI: 10.1016/j.jconrel.2018.04.017
- 385) Mohamadlou, H., Lynn-Palevsky, A., Barton, C., Chettipally, U., Shieh, L., Calvert, J., Saber, N.R., Das, R. Prediction of Acute Kidney Injury With a Machine Learning Algorithm Using Electronic Health Record Data (2018) Canadian Journal of Kidney Health and Disease, . DOI: 10.1177/2054358118776326
- 386) Gholami, B., Phan, T.S., Haddad, W.M., Cason, A., Mullis, J., Price, L., Bailey, J.M. Replicating human expertise of mechanical ventilation waveform analysis in detecting patient-ventilator cycling asynchrony using machine learning (2018) Computers in Biology and Medicine, . DOI: 10.1016/j.combiomed.2018.04.016
- 387) Parreco, J.P., Hidalgo, A.E., Badilla, A.D., Ilyas, O., Rattan, R. Predicting central line-associated bloodstream infections and mortality using supervised machine learning (2018) Journal of Critical Care, . DOI: 10.1016/j.jcrc.2018.02.010
- 388) Matam, B.R., Duncan, H. Technical challenges related to implementation of a formula one real time data acquisition and analysis system in a paediatric intensive care unit (2018) Journal of Clinical Monitoring and Computing, . DOI: 10.1007/s10877-017-0047-6
- 389) Savin, I., Ershova, K., Kurdyumova, N., Ershova, O., Khomenko, O., Danilov, G., Shifrin, M., Zelman, V. Healthcare-associated ventriculitis and meningitis in a neuro-ICU: Incidence and risk factors selected by machine learning approach (2018) Journal of Critical Care, . DOI: 10.1016/j.jcrc.2018.01.022
- 390) Delahanty, R.J., Kaufman, D., Jones, S.S. Development and Evaluation of an Automated Machine Learning Algorithm for In-Hospital Mortality Risk Adjustment Among Critical Care Patients (2018) Critical care medicine, . DOI: 10.1097/CCM.0000000000003011
- 391) Liu, J., Chen, X.X., Fang, L., Li, J.X., Yang, T., Zhan, Q., Tong, K., Fang, Z. Mortality prediction based on imbalanced high-dimensional ICU big data (2018) Computers in Industry, . DOI: 10.1016/j.compind.2018.01.017

- 392) Feng, J., Huang, Z., Zhou, C., Ye, X. Study of continuous blood pressure estimation based on pulse transit time, heart rate and photoplethysmography- derived hemodynamic covariates (2018) *Australasian Physical and Engineering Sciences in Medicine*, . DOI: 10.1007/s13246-018-0637-8
- 393) Lebet, R.M., Asaro, L.A., Zuppa, A.F., Curley, M.A.Q. Face and content validity of variables associated with the difficult-to-sedate child in the paediatric intensive care unit: A survey of paediatric critical care clinicians (2018) *Australian Critical Care*, . DOI: 10.1016/j.aucc.2017.12.091
- 394) Levin, S., Toerper, M., Hamrock, E., Hinson, J.S., Barnes, S., Gardner, H., Dugas, A., Linton, B., Kirsch, T., Kelen, G. Machine-Learning-Based Electronic Triage More Accurately Differentiates Patients With Respect to Clinical Outcomes Compared With the Emergency Severity Index (2018) *Annals of Emergency Medicine*, . DOI: 10.1016/j.annemergmed.2017.08.005
- 395) Yeung, S., Lance Downing, N., Fei-Fei, L., Milstein, A. Bedside computer vision — Moving artificial intelligence from driver assistance to patient safety (2018) *New England Journal of Medicine*, . DOI: 10.1056/NEJMp1716891
- 396) Olive, M.K., Owens, G.E. Current monitoring and innovative predictive modeling to improve care in the pediatric cardiac intensive care unit (2018) *Translational Pediatrics*, . DOI: 10.21037/tp.2018.04.03
- 397) Rubin, J., Potes, C., Xu-Wilson, M., Dong, J., Rahman, A., Nguyen, H., Moromisato, D. An ensemble boosting model for predicting transfer to the pediatric intensive care unit (2018) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2018.01.001
- 398) Nemati, S., Holder, A., Razmi, F., Stanley, M.D., Clifford, G.D., Buchman, T.G. An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU (2018) *Critical care medicine*, .DOI: 10.1097/CCM.0000000000002936
- 399) Fritz, B.A., Chen, Y., Murray-Torres, T.M., Gregory, S., Ben Abdallah, A., Kronzer, A., McKinnon, S.L., Budelier, T., Helsten, D.L., Wildes, T.S., Sharma, A., Avidan, M.S. Using machine learning techniques to develop forecasting algorithms for postoperative complications: Protocol for a retrospective study (2018) *BMJ Open*, . DOI: 10.1136/bmjopen-2017-020124
- 400) Ding, Y., Wang, Y., Zhou, D. Mortality prediction for ICU patients combining just-in-time learning and extreme learning machine (2018) *Neurocomputing*, .DOI: 10.1016/j.neucom.2017.10.044
- 401) Lamping, F., Jack, T., Rüksamen, N., Sasse, M., Beerbaum, P., Mikolajczyk, R.T., Boehne, M., Karch, A. Development and validation of a diagnostic model for early differentiation of sepsis and non-infectious SIRS in critically ill children - A data-driven approach using machine-learning algorithms (2018) *BMC Pediatrics*, . DOI: 10.1186/s12887-018-1082-2
- 402) Megjhani, M., Terilli, K., Frey, H.-P., Velazquez, A.G., Doyle, K.W., Connolly, E.S., Roh, D.J., Agarwal, S., Claassen, J., Elhadad, N., Park, S. Incorporating high-frequency physiologic data using computational dictionary learning improves prediction of delayed cerebral ischemia compared to existing methods (2018) *Frontiers in Neurology*, . DOI: 10.3389/fneur.2018.00122
- 403) Ding, Y., Ma, X., Wang, Y. Health status monitoring for ICU patients based on locally weighted principal component analysis (2018) *Computer Methods and Programs in Biomedicine*, . DOI: 10.1016/j.cmpb.2017.12.019
- 404) Afghah, F., Razi, A., Soroushmehr, R., Ghanbari, H., Najarian, K. Game theoretic approach for systematic feature selection; Application in false alarm detection in Intensive Care Units (2018) *Entropy*, . DOI: 10.3390/e20030190
- 405) Cobb, A.N., Daungjaiboon, W., Brownlee, S.A., Baldea, A.J., Sanford, A.P., Mosier, M.M., Kuo, P.C. Seeing the forest beyond the trees: Predicting survival in burn patients with machine learning (2018) *American Journal of Surgery*, . DOI: 10.1016/j.amjsurg.2017.10.027
- 406) Hillman, K.M., Takala, J. Intensive care medicine in 2050: expanding care beyond the intensive care unit (2018) *Intensive Care Medicine*, . DOI: 10.1007/s00134-017-4806-0
- 407) Oh, J., Cho, D., Park, J., Na, S.H., Kim, J., Heo, J., Shin, C.S., Kim, J.-J., Park, J.Y., Lee, B. Prediction and early detection of delirium in the intensive care unit by using heart rate variability and machine learning (2018) *Physiological Measurement*, . DOI: 10.1088/1361-6579/aaab07
- 408) Wulff, A., Marschollek, M. Learning Healthcare Systems in Pediatrics: Cross-Institutional and Data-Driven Decision-Support for Intensive Care Environments (CADDIE) (2018) *Studies in Health Technology and Informatics*, . DOI: 10.3233/978-1-61499-880-8-109
- 409) Shirwaikar, R.D., Dinesh Acharya, U., Makkithaya, K., Mallayaswamy, S., Lewis, L.E.S. Estimation of caffeine regimens: A machine learning approach for enhanced clinical decision making at a neonatal intensive care unit (NICU) (2018) *Critical Reviews in Biomedical Engineering*, . DOI: 10.1615/CritRevBiomedEng.2018025933
- 410) Ge, W., Huh, J.-W., Park, Y.R., Lee, J.-H., Kim, Y.-H., Turchin, A. An Interpretable ICU Mortality Prediction Model Based on Logistic Regression and Recurrent Neural Networks with LSTM units (2018) *AMIA ... Annual Symposium proceedings. AMIA Symposium*, .
- 411) Weissman, G.E., Hubbard, R.A., Ungar, L.H., Harhay, M.O., Greene, C.S., Himes, B.E., Halpern, S.D. Inclusion of unstructured clinical text improves early prediction of death or prolonged ICU stay (2018) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000003148

- 412) King, A.J., Cooper, G.F., Hochheiser, H., Clermont, G., Hauskrecht, M., Visweswaran, S. Using Machine Learning to Predict the Information Seeking Behavior of Clinicians Using an Electronic Medical Record System (2018) AMIA ... Annual Symposium proceedings. AMIA Symposium, .
- 413) Peng, X., Ding, Y., Wihl, D., Gottesman, O., Komorowski, M., Lehman, L.-W.H., Ross, A., Faisal, A., Doshi-Velez, F. Improving Sepsis Treatment Strategies by Combining Deep and Kernel-Based Reinforcement Learning (2018) AMIA ... Annual Symposium proceedings. AMIA Symposium, .
- 414) Rehm, G.B., Han, J., Kuhn, B.T., Delplanque, J.-P., Anderson, N.R., Adams, J.Y., Chuah, C.-N. Creation of a Robust and Generalizable Machine Learning Classifier for Patient Ventilator Asynchrony (2018) Methods of Information in Medicine, . DOI: 10.3414/ME17-02-0012
- 415) Mao, Q., Jay, M., Hoffman, J.L., Calvert, J., Barton, C., Shimabukuro, D., Shieh, L., Chettipally, U., Fletcher, G., Kerem, Y., Zhou, Y., Das, R. Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU (2018) BMJ Open, . DOI: 10.1136/bmjopen-2017-017833
- 416) Lakshmi, C., Bojewar, S. Performance evaluation Of SVM and ANN for cancer classification and designing algorithm for arrhythmia prediction in cancer patient (2018) International Journal of Engineering and Technology(UAE), . DOI: 10.14419/ijet.v7i3.3.14496
- 417) Wang, L., Lakin, J., Riley, C., Korach, Z., Frain, L.N., Zhou, L. Disease Trajectories and End-of-Life Care for Dementias: Latent Topic Modeling and Trend Analysis Using Clinical Notes (2018) AMIA ... Annual Symposium proceedings. AMIA Symposium, .
- 418) Kamaleswaran, R., Akbilgic, O., Hallman, M.A., West, A.N., Davis, R.L., Shah, S.H. Applying artificial intelligence to identify physiometers predicting severe sepsis in the PICU (2018) Pediatric Critical Care Medicine, . DOI: 10.1097/PCC.0000000000001666
- 419) Lehman, L.-W.H., Mark, R.G., Nemati, S. A Model-Based Machine Learning Approach to Probing Autonomic Regulation from Nonstationary Vital-Sign Time Series (2018) IEEE Journal of Biomedical and Health Informatics, . DOI: 10.1109/JBHI.2016.2636808
- 420) Jain, S.S., Sarkar, I.N., Stey, P.C., Anand, R.S., Biron, D.R., Chen, E.S. Using Demographic Factors and Comorbidities to Develop a Predictive Model for ICU Mortality in Patients with Acute Exacerbation COPD (2018) AMIA ... Annual Symposium proceedings. AMIA Symposium, .
- 421) Hatib, F., Jian, Z., Buddi, S., Lee, C., Settels, J., Sibert, K., Rinehart, J., Cannesson, M. Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis (2018) Anesthesiology, . DOI: 10.1097/ALN.0000000000002300
- 422) Lee, Y., Kwon, J.-M., Lee, Y., Park, H., Cho, H., Park, J. Deep learning in the medical domain: Predicting cardiac arrest using deep learning (2018) Acute and Critical Care, . DOI: 10.4266/acc.2018.00290
- 423) Shappell, C., Snyder, A., Edelson, D.P., Churpek, M.M. Predictors of in-hospital mortality after rapid response team calls in a 274 hospital nationwide sample (2018) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000002926
- 424) Koyner, J.L., Carey, K.A., Edelson, D.P., Churpek, M.M. The development of a machine learning inpatient acute kidney injury prediction model (2018) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000003123
- 425) Manimaran, J., Velmurugan, T. Evaluation of Named Entity Recognition algorithms using clinical text data (2018) International Journal of Engineering and Technology(UAE), .
- 426) Manimaran, J., Velmurugan, T. Evaluation of Named Entity Recognition algorithms using clinical text data (2018) International Journal of Engineering and Technology(UAE), . DOI: 10.14419/ijet.v7i4.5.20093
- 427) Patel, P., Nigam, N., Sengupta, N. Resumption of Warfarin after Hospitalization for Lower Gastrointestinal Bleeding and Mortality Benefits (2018) Journal of Clinical Gastroenterology, . DOI: 10.1097/MCG.0000000000000821
- 428) Sweeney, T.E., Azad, T.D., Donato, M., Haynes, W.A., Perumal, T.M., Henao, R., Bermejo-Martin, J.F., Almansa, R., Tamayo, E., Howrylak, J.A., Choi, A., Parnell, G.P., Tang, B., Nichols, M., Woods, C.W., Ginsburg, G.S., Kingsmore, S.F., Omberg, L., Mangravite, L.M., Wong, H.R., Tsalik, E.L., Langley, R.J., Khatri, P. Unsupervised analysis of transcriptomics in bacterial sepsis across multiple datasets reveals three robust clusters (2018) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000003084
- 429) Kreif, N., Tran, L., Grieve, R., De Stavola, B., Tasker, R.C., Petersen, M. Estimating the comparative effectiveness of feeding interventions in the pediatric intensive care unit: A demonstration of longitudinal targeted maximum likelihood estimation (2017) American Journal of Epidemiology, . DOI: 10.1093/aje/kwx213
- 430) Golden, J.A. Deep learning algorithms for detection of lymph node metastases from breast cancer helping artificial intelligence be seen (2017) JAMA - Journal of the American Medical Association, . DOI: 10.1001/jama.2017.14580
- 431) Awad, A., Bader-EI-Den, M., McNicholas, J., Briggs, J. Early hospital mortality prediction of intensive care unit patients using an ensemble learning approach (2017) International Journal of Medical Informatics, . DOI: 10.1016/j.ijmedinf.2017.10.002
- 432) Vandendriessche, B., Abas, M., Dick, T.E., Loparo, K.A., Jacono, F.J. A Framework for Patient State Tracking by Classifying Multiscalar Physiologic Waveform Features (2017) IEEE Transactions on Biomedical Engineering, . DOI: 10.1109/TBME.2017.2684244

- 433) Prevedello, L.M., Erdal, B.S., Ryu, J.L., Little, K.J., Demirel, M., Qian, S., White, R.D. Automated critical test findings identification and online notification system using artificial intelligence in imaging (2017) *Radiology*, . DOI: 10.1148/radiol.2017162664
- 434) Struck, A.F., Ustun, B., Ruiz, A.R., Lee, J.W., LaRoche, S.M., Hirsch, L.J., Gilmore, E., Vlachy, J., Haider, H.A., Rudin, C., Westover, M.B. Association of an electroencephalography-based risk score with seizure probability in hospitalized patients (2017) *JAMA Neurology*, . DOI: 10.1001/jamaneurol.2017.2459
- 435) Shashikumar, S.P., Stanley, M.D., Sadiq, I., Li, Q., Holder, A., Clifford, G.D., Nemati, S. Early sepsis detection in critical care patients using multiscale blood pressure and heart rate dynamics (2017) *Journal of Electrocardiology*, . DOI: 10.1016/j.jelectrocard.2017.08.013
- 436) Vranas, K.C., Jopling, J.K., Sweeney, T.E., Ramsey, M.C., Milstein, A.S., Slatore, C.G., Escobar, G.J., Liu, V.X. Identifying distinct subgroups of ICU patients: A machine learning approach (2017) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000002548
- 437) Moskowitz, A., Chen, K.P., Cooper, A.Z., Chahin, A., Ghassemi, M.M., Celi, L.A. Management of atrial fibrillation with rapid ventricular response in the intensive care unit: A secondary analysis of electronic health record data (2017) *Shock*, . DOI: 10.1097/SHK.0000000000000869
- 438) Avram, M.J., Kharasch, E.D., Kheterpal, S., Rathmell, J.P., Sessler, D.I. Journal-related Activities and Other Special Activities at the 2017 American Society of Anesthesiologists Meeting (2017) *Anesthesiology*, . DOI: 10.1097/ALN.0000000000001832
- 439) Kam, H.J., Kim, H.Y. Learning representations for the early detection of sepsis with deep neural networks (2017) *Computers in Biology and Medicine*, . DOI: 10.1016/j.compbiomed.2017.08.015
- 440) Scicluna, B.P., van Vught, L.A., Zwinderman, A.H., Wiewel, M.A., Davenport, E.E., Burnham, K.L., Nürnberg, P., Schultz, M.J., Horn, J., Cremer, O.L., Bonten, M.J., Hinds, C.J., Wong, H.R., Knight, J.C., van der Poll, T., de Beer, F.M., Bos, L.D.J., Frencken, J.F., Koster-Brouwer, M.E., van de Groep, K., Verboom, D.M., Glas, G.J., van Hooijdonk, R.T.M., Hoogendijk, A.J., Huson, M.A., Klouwenberg, P.M.K., Ong, D.S.Y., Schouten, L.R.A., Straat, M., Witteveen, E., Wieske, L. Classification of patients with sepsis according to blood genomic endotype: a prospective cohort study (2017) *The Lancet Respiratory Medicine*, . DOI: 10.1016/S2213-2600(17)30294-1
- 441) Escobar, G.J., Baker, J.M., Kipnis, P., Greene, J.D., Mast, T.C., Gupta, S.B., Cossrow, N., Mehta, V., Liu, V., Dubberke, E.R. Prediction of recurrent clostridium difficile infection using comprehensive electronic medical records in an integrated healthcare delivery system (2017) *Infection Control and Hospital Epidemiology*, . DOI: 10.1017/ice.2017.176
- 442) Perner, A., Gordon, A.C., Angus, D.C., Lamontagne, F., Machado, F., Russell, J.A., Timsit, J.-F., Marshall, J.C., Myburgh, J., Shankar-Hari, M., Singer, M. The intensive care medicine research agenda on septic shock (2017) *Intensive Care Medicine*, . DOI: 10.1007/s00134-017-4821-1
- 443) Desautels, T., Das, R., Calvert, J., Trivedi, M., Summers, C., Wales, D.J., Ercole, A. Prediction of early unplanned intensive care unit readmission in a UK tertiary care hospital: A cross-sectional machine learning approach (2017) *BMJ Open*, . DOI: 10.1136/bmjopen-2017-017199
- 444) Singh, H., Yadav, G., Mallaiyah, R., Joshi, P., Joshi, V., Kaur, R., Bansal, S., Brahmachari, S.K. iNICU – Integrated Neonatal Care Unit: Capturing Neonatal Journey in an Intelligent Data Way (2017) *Journal of Medical Systems*, . DOI: 10.1007/s10916-017-0774-8
- 445) Silva, S., Peran, P., Kerhuel, L., Malagurski, B., Chauveau, N., Bataille, B., Lotterie, J.A., Celsis, P., Aubry, F., Citerio, G., Jean, B., Chabanne, R., Perlberg, V., Velly, L., Galanaud, D., Vanhauzenhuyse, A., Fourcade, O., Laureys, S., Puybasset, L. Brain gray matter MRI morphometry for neuroprognostication after cardiac arrest (2017) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000002379
- 446) Shalish, W., Kanbar, L.J., Rao, S., Robles-Rubio, C.A., Kovacs, L., Chawla, S., Keszler, M., Precup, D., Brown, K., Kearney, R.E., Sant'Anna, G.M. Prediction of Extubation readiness in extremely preterm infants by the automated analysis of cardiorespiratory behavior: Study protocol (2017) *BMC Pediatrics*, . DOI: 10.1186/s12887-017-0911-z
- 447) Nagaraj, S.B., Biswal, S., Boyle, E.J., Zhou, D.W., McClain, L.M., Bajwa, E.K., Quraishi, S.A., Akeju, O., Barbieri, R., Purdon, P.L., Brandon Westover, M. Patient-Specific Classification of ICU Sedation Levels from Heart Rate Variability (2017) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000002364
- 448) Awad, A., Bader–El–Den, M., McNicholas, J. Patient length of stay and mortality prediction: A survey (2017) *Health Services Management Research*, . DOI: 10.1177/0951484817696212
- 449) Waghmare, A., Hemalatha, S. Predictive analytics of health-care data (2017) *Asian Journal of Pharmaceutical and Clinical Research*, . DOI: 10.22159/ajpcr.2017.v10s1.19750
- 450) Ma, A.J., Rawat, N., Reiter, A., Shrock, C., Zhan, A., Stone, A., Rabiee, A., Griffin, S., Needham, D.M., Saria, S. Measuring Patient Mobility in the ICU Using a Novel Noninvasive Sensor (2017) *Critical Care Medicine*, . DOI: 10.1097/CCM.0000000000002265
- 451) Chen, L., Ogundele, O., Clermont, G., Hravnak, M., Pinsky, M.R., Dubrawski, A.W. Dynamic and personalized risk forecast in step-down units: Implications for monitoring paradigms (2017) *Annals of the American Thoracic Society*, . DOI: 10.1513/AnnalsATS.201611-905OC
- 452) Ghosh, S., Li, J., Cao, L., Ramamohanarao, K. Septic shock prediction for ICU patients via coupled HMM walking on sequential contrast patterns (2017) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2016.12.010

- 453) Ho, L.V., Ledbetter, D., Aczon, M., Wetzell, R. The Dependence of Machine Learning on Electronic Medical Record Quality (2017) AMIA ... Annual Symposium proceedings. AMIA Symposium, .
- 454) Lameski, P., Zdravevski, E., Koceski, S., Kulakov, A., Trajkovik, V. Suppression of Intensive Care Unit False Alarms Based on the Arterial Blood Pressure Signal (2017) IEEE Access, . DOI: 10.1109/ACCESS.2017.2690380
- 455) Belderrain, A., Hazzab, A. Hierarchical genetic algorithm and fuzzy radial basis function networks for factors influencing hospital length of stay outliers (2017) Healthcare Informatics Research, . DOI: 10.4258/hir.2017.23.3.226
- 456) Xu, H., Wu, W., Nemat, S., Zha, H. Patient Flow Prediction via Discriminative Learning of Mutually-Correcting Processes (2017) IEEE Transactions on Knowledge and Data Engineering, . DOI: 10.1109/TKDE.2016.2618925
- 457) Li, X., Wang, Y. Adaptive online monitoring for ICU patients by combining just-in-time learning and principal component analysis (2016) Journal of Clinical Monitoring and Computing, . DOI: 10.1007/s10877-015-9778-4
- 458) Hauskrecht, M., Batal, I., Hong, C., Nguyen, Q., Cooper, G.F., Visweswaran, S., Clermont, G. Outlier-based detection of unusual patient-management actions: An ICU study (2016) Journal of Biomedical Informatics, . DOI: 10.1016/j.jbi.2016.10.002
- 459) Nemeth, C., Blomberg, J., Argenta, C., Serio-Melvin, M.L., Salinas, J., Pamplin, J. Revealing ICU Cognitive Work Through Naturalistic Decision-Making Methods (2016) Journal of Cognitive Engineering and Decision Making, . DOI: 10.1177/1555343416664845
- 460) Ordoñez, P., Schwarz, N., Figueroa-Jiménez, A., Garcia-Lebron, L.A., Roche-Lima, A. Learning stochastic finite-state transducer to predict individual patient outcomes (2016) Health and Technology, . DOI: 10.1007/s12553-016-0146-2
- 461) Ding, X.-R., Zhao, N., Yang, G.-Z., Pettigrew, R.I., Lo, B., Miao, F., Li, Y., Liu, J., Zhang, Y.-T. Continuous Blood Pressure Measurement From Invasive to Unobtrusive: Celebration of 200th Birth Anniversary of Carl Ludwig (2016) IEEE Journal of Biomedical and Health Informatics, . DOI: 10.1109/JBHI.2016.2620995
- 462) Temko, A., Lightbody, G. Detecting neonatal seizures with computer algorithms (2016) Journal of Clinical Neurophysiology, . DOI: 10.1097/WNP.0000000000000295
- 463) Seely, A.J.E. Prediction Is Difficult, Especially about Future Unexpected Deterioration\* (2016) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000001800
- 464) Nagaraj, S.B., McClain, L.M., Zhou, D.W., Biswal, S., Rosenthal, E.S., Purdon, P.L., Westover, M.B. Automatic Classification of Sedation Levels in ICU Patients Using Heart Rate Variability (2016) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000001708
- 465) Sobrie, O., Lazouni, M.E.A., Mahmoudi, S., Mousseau, V., Pirlot, M. A new decision support model for preanesthetic evaluation (2016) Computer Methods and Programs in Biomedicine, . DOI: 10.1016/j.cmpb.2016.05.021
- 466) Hu, S.B., Wong, D.J.L., Correa, A., Li, N., Deng, J.C. Prediction of clinical deterioration in hospitalized adult patients with hematologic malignancies using a neural network model (2016) PLoS ONE, . DOI: 10.1371/journal.pone.0161401
- 467) Plesinger, F., Klimes, P., Halamek, J., Jurak, P. Taming of the monitors: Reducing false alarms in intensive care units (2016) Physiological Measurement, . DOI: 10.1088/0967-3334/37/8/1313
- 468) Ansari, S., Belle, A., Ghanbari, H., Salamango, M., Najarian, K. Suppression of false arrhythmia alarms in the ICU: A machine learning approach (2016) Physiological Measurement, . DOI: 10.1088/0967-3334/37/8/1186
- 469) Eerikainen, L.M., Vanschoren, J., Rooijackers, M.J., Vullings, R., Aarts, R.M. Reduction of false arrhythmia alarms using signal selection and machine learning (2016) Physiological Measurement, . DOI: 10.1088/0967-3334/37/8/1204
- 470) Antink, C.H., Leonhardt, S., Walter, M. Reducing false alarms in the ICU by quantifying self-similarity of multimodal biosignals (2016) Physiological Measurement, . DOI: 10.1088/0967-3334/37/8/1233
- 471) Kalidas, V., Tamil, L.S. Cardiac arrhythmia classification using multi-modal signal analysis (2016) Physiological Measurement, . DOI: 10.1088/0967-3334/37/8/1253
- 472) Calvert, J.S., Price, D.A., Chettipally, U.K., Barton, C.W., Feldman, M.D., Hoffman, J.L., Jay, M., Das, R. A computational approach to early sepsis detection (2016) Computers in Biology and Medicine, . DOI: 10.1016/j.combiomed.2016.05.003
- 473) Chen, L., Dubrawski, A., Wang, D., Fiterau, M., Guillame-Bert, M., Bose, E., Kaynar, A.M., Wallace, D.J., Guttendorf, J., Clermont, G., Pinsky, M.R., Hravnak, M. Using supervised machine learning to classify real alerts and artifact in online multisignal vital sign monitoring data (2016) Critical Care Medicine, . DOI: 10.1097/CCM.0000000000001660
- 474) Harrison, A.M., Gajic, O., Pickering, B.W., Herasevich, V. Development and Implementation of Sepsis Alert Systems (2016) Clinics in Chest Medicine, . DOI: 10.1016/j.ccm.2016.01.004
- 475) Goldstein, A., Shahar, Y. An automated knowledge-based textual summarization system for longitudinal, multivariate clinical data (2016) Journal of Biomedical Informatics, . DOI: 10.1016/j.jbi.2016.03.022

- 476) Nemeth, C., Anders, S., Strouse, R., Grome, A., Crandall, B., Pamplin, J., Salinas, J., Mann-Salinas, E. Developing a cognitive and communications tool for burn intensive care unit clinicians (2016) *Military Medicine*, . DOI: 10.7205/MILMED-D-15-00173
- 477) Temple, M.W., Lehmann, C.U., Fabbri, D. Natural language processing for cohort discovery in a discharge prediction model for the neonatal ICU (2016) *Applied Clinical Informatics*, . DOI: 10.4338/ACI-2015-09-RA-0114
- 478) Johnson, A.E.W., Ghassemi, M.M., Nemat, S., Niehaus, K.E., Clifton, D., Clifford, G.D. Machine Learning and Decision Support in Critical Care (2016) *Proceedings of the IEEE*, . DOI: 10.1109/JPROC.2015.2501978
- 479) Ruysinck, J., Van Der Herten, J., Houthoofd, R., Ongenaes, F., Couckuyt, I., Gadeyne, B., Colpaert, K., Decruyenaere, J., De Turck, F., Dhaene, T. Random Survival Forests for Predicting the Bed Occupancy in the Intensive Care Unit (2016) *Computational and Mathematical Methods in Medicine*, . DOI: 10.1155/2016/7087053
- 480) Clifford, G.D., Silva, I., Moody, B., Li, Q., Kella, D., Chahin, A., Kooistra, T., Perry, D., Mark, R.G. False alarm reduction in critical care (2016) *Physiological Measurement*, . DOI: 10.1088/0967-3334/37/8/E5
- 481) Shirwaikar, R.D., Acharya, U.D., Makkithaya, K., Surulivelrajan, M., Lewis, L.E.S. Machine learning techniques for neonatal apnea prediction (2016) *Journal of Artificial Intelligence*, . DOI: 10.3923/jai.2016.33.38
- 482) Che, Z., Purushotham, S., Khemani, R., Liu, Y. Interpretable Deep Models for ICU Outcome Prediction (2016) *AMIA ... Annual Symposium proceedings. AMIA Symposium*, .
- 483) Senthilkumar, S., Tholkappia Arasu, G. Implementation of context aware medical ontology and health recommender framework (2016) *Journal of Chemical and Pharmaceutical Sciences*, .
- 484) Georgatzis, K., Lal, P., Hawthorne, C., Shaw, M., Piper, I., Tarbert, C., Donald, R., Williams, C.K.I. Artefact in physiological data collected from patients with brain injury: Quantifying the problem and providing a solution using a factorial switching linear dynamical systems approach (2016) *Acta Neurochirurgica, Supplementum*, . DOI: 10.1007/978-3-319-22533-3\_60
- 485) Ngufor, C., Murphree, D., Upadhyaya, S., Madde, N., Pathak, J., Carter, R., Kor, D. Predicting Prolonged Stay in the ICU Attributable to Bleeding in Patients Offered Plasma Transfusion (2016) *AMIA ... Annual Symposium proceedings. AMIA Symposium*, .
- 486) Reinhart, W.H. The optimum hematocrit (2016) *Clinical Hemorheology and Microcirculation*, . DOI: 10.3233/CH-168032
- 487) Huddar, V., Desiraju, B.K., Rajan, V., Bhattacharya, S., Roy, S., Reddy, C.K. Predicting Complications in Critical Care Using Heterogeneous Clinical Data (2016) *IEEE Access*, . DOI: 10.1109/ACCESS.2016.2618775
- 488) Palm, R., Trutschel, D., Simon, M., Bartholomeyczik, S., Holle, B. Differences in Case Conferences in Dementia Specific vs Traditional Care Units in German Nursing Homes: Results from a Cross-Sectional Study (2016) *Journal of the American Medical Directors Association*, . DOI: 10.1016/j.jamda.2015.08.018
- 489) Zufferey, D., Hofer, T., Hennebert, J., Schumacher, M., Ingold, R., Bromuri, S. Performance comparison of multi-label learning algorithms on clinical data for chronic diseases (2015) *Computers in Biology and Medicine*, . DOI: 10.1016/j.combiomed.2015.07.017
- 490) Wang, C., Savkin, A.V., Clout, R., Nguyen, H.T. An intelligent robotic hospital bed for safe transportation of critical neurosurgery patients along crowded hospital corridors (2015) *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, . DOI: 10.1109/TNSRE.2014.2347377
- 491) Clifton, D.A., Niehaus, K.E., Charlton, P., Colopy, G.W. Health Informatics via Machine Learning for the Clinical Management of Patients (2015) *Yearbook of medical informatics*, . DOI: 10.15265/IY-2015-014
- 492) Attin, M., Feld, G., Lemus, H., Najarian, K., Shandilya, S., Wang, L., Sabouriazad, P., Lin, C.-D. Electrocardiogram characteristics prior to in-hospital cardiac arrest (2015) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-014-9616-0
- 493) Albert, T.J., Fassier, T., Chhuoy, M., Bounchan, Y., Tan, S., Ku, N., Chhor, N., LoGerfo, J.P., West, T.E. Bolstering medical education to enhance critical care capacity in Cambodia (2015) *Annals of the American Thoracic Society*, . DOI: 10.1513/AnnalsATS.201412-557AR
- 494) Houthoofd, R., Ruysinck, J., van der Herten, J., Stijven, S., Couckuyt, I., Gadeyne, B., Ongenaes, F., Colpaert, K., Decruyenaere, J., Dhaene, T., De Turck, F. Predictive modelling of survival and length of stay in critically ill patients using sequential organ failure scores (2015) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2014.12.009
- 495) Liu, Y., Traskin, M., Lorch, S.A., George, E.I., Small, D. Ensemble of trees approaches to risk adjustment for evaluating a hospital's performance (2015) *Health Care Management Science*, . DOI: 10.1007/s10729-014-9272-4
- 496) King, A.J., Cooper, G.F., Hochheiser, H., Clermont, G., Visweswaran, S. Development and Preliminary Evaluation of a Prototype of a Learning Electronic Medical Record System (2015) *AMIA ... Annual Symposium proceedings. AMIA Symposium*, .
- 497) Kennedy, C.E., Aoki, N., Mariscalco, M., Turley, J.P. Using time series analysis to predict cardiac arrest in a PICU (2015) *Pediatric Critical Care Medicine*, . DOI: 10.1097/PCC.0000000000000560

- 498) Holder, A.L., Clermont, G. Using what you get: Dynamic physiologic signatures of critical illness (2015) *Critical Care Clinics*, . DOI: 10.1016/j.ccc.2014.08.007
- 499) Pirracchio, R., Petersen, M.L., Carone, M., Rigon, M.R., Chevret, S., van der Laan, M.J. Mortality prediction in intensive care units with the Super ICU Learner Algorithm (SICULA): A population-based study (2015) *The Lancet Respiratory Medicine*, . DOI: 10.1016/S2213-2600(14)70239-5
- 500) Wang, Y., Chen, W., Heard, K., Kollef, M.H., Bailey, T.C., Cui, Z., He, Y., Lu, C., Chen, Y. Mortality Prediction in ICUs Using A Novel Time-Slicing Cox Regression Method (2015) *AMIA ... Annual Symposium proceedings. AMIA Symposium*, .
- 501) Kale, D.C., Che, Z., Bahadori, M.T., Li, W., Liu, Y., Wetzel, R. Causal Phenotype Discovery via Deep Networks (2015) *AMIA ... Annual Symposium proceedings. AMIA Symposium*, .
- 502) Temple, M.W., Lehmann, C.U., Fabbri, D. Predicting discharge dates from the nicu using progress note data (2015) *Pediatrics*, . DOI: 10.1542/peds.2015-0456
- 503) Marafino, B.J., John Boscardin, W., Adams Dudley, R. Efficient and sparse feature selection for biomedical text classification via the elastic net: Application to ICU risk stratification from nursing notes (2015) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2015.02.003
- 504) Judge, S., Hawley, M.S., Cunningham, S., Kirton, A. What is the potential for context aware communication AIDS? (2015) *Journal of Medical Engineering and Technology*, . DOI: 10.3109/03091902.2015.1088091
- 505) Bonds, B.W., Yang, S., Hu, P.F., Kalpakis, K., Stansbury, L.G., Scalea, T.M., Stein, D.M. Predicting secondary insults after severe traumatic brain injury (2015) *Journal of Trauma and Acute Care Surgery*, . DOI: 10.1097/TA.0000000000000698
- 506) Bataille, B., Riu, B., Ferre, F., Moussot, P.E., Mari, A., Brunel, E., Ruiz, J., Mora, M., Fourcade, O., Genestal, M., Silva, S. Integrated Use of Bedside Lung Ultrasound and Echocardiography in Acute Respiratory Failure: A Prospective Observational Study in ICU (2014) *Chest*, . DOI: 10.1378/chest.14-0681
- 507) Wang, K., Bhandari, V., Giuliano, J.S., Jr., O'Hern, C.S., Shattuck, M.D., Kirby, M. Angiotensin-converting enzyme 1, angiotensin-converting enzyme 2 and bicarbonate as diagnostic biomarkers in children with severe sepsis (2014) *PLoS ONE*, . DOI: 10.1371/journal.pone.0108461
- 508) Mani, S., Ozdas, A., Aliferis, C., Varol, H.A., Chen, Q., Carnevale, R., Chen, Y., Romano-Keeler, J., Nian, H., Weitkamp, J.-H. Medical decision support using machine learning for early detection of late-onset neonatal sepsis (2014) *Journal of the American Medical Informatics Association*, . DOI: 10.1136/amiajnl-2013-001854
- 509) Perotte, A., Pivovarov, R., Natarajan, K., Weiskopf, N., Wood, F., Elhadad, N. Diagnosis code assignment: Models and evaluation metrics (2014) *Journal of the American Medical Informatics Association*, . DOI: 10.1136/amiajnl-2013-002159
- 510) Liu, N.T., Holcomb, J.B., Wade, C.E., Batchinsky, A.I., Cancio, L.C., Darrach, M.I., Salinas, J. Development and validation of a machine learning algorithm and hybrid system to predict the need for life-saving interventions in trauma patients (2014) *Medical and Biological Engineering and Computing*, . DOI: 10.1007/s11517-013-1130-x
- 511) Pinsky, M.R., Dubrawski, A. Gleaning knowledge from data in the intensive care unit (2014) *American Journal of Respiratory and Critical Care Medicine*, . DOI: 10.1164/rccm.201404-0716CP
- 512) Zhai, H., Brady, P., Li, Q., Lingren, T., Ni, Y., Wheeler, D.S., Solti, I. Developing and evaluating a machine learning based algorithm to predict the need of pediatric intensive care unit transfer for newly hospitalized children (2014) *Resuscitation*, . DOI: 10.1016/j.resuscitation.2014.04.009
- 513) Liu, N.T., Cancio, L.C., Salinas, J., Batchinsky, A.I. Reliable real-time calculation of heart-rate complexity in critically ill patients using multiple noisy waveform sources (2014) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-013-9503-0
- 514) Xu, J., Zhang, Y., Mahmood, A., Khatoon, S., Li, Y. A hybrid framework for ICU mortality prediction (2014) *Journal of Software Engineering*, . DOI: 10.3923/jse.2014.361.374
- 515) Jiménez, F., Sánchez, G., Juárez, J.M. Multi-objective evolutionary algorithms for fuzzy classification in survival prediction (2014) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2013.12.006
- 516) Rejab, F.B., Noura, K., Trabelsi, A. Health monitoring systems using machine learning techniques (2014) *Studies in Computational Intelligence*, . DOI: 10.1007/978-3-319-04702-7\_24
- 517) Cerqueira, F.R., Ferreira, T.G., de Paiva Oliveira, A., Augusto, D.A., Krempser, E., Corrêa Barbosa, H.J., do Carmo Castro Franceschini, S., de Freitas, B.A.C., Gomes, A.P., Siqueira-Batista, R. NICeSim: An open-source simulator based on machine learning techniques to support medical research on prenatal and perinatal care decision making (2014) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2014.10.001
- 518) Klann, J.G., Szolovits, P., Downs, S.M., Schadow, G. Decision support from local data: Creating adaptive order menus from past clinician behavior (2014) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2013.12.005

- 519) Janssens, T., Antanas, L., Derde, S., Vanhorebeek, I., Van den Berghe, G., Güiza Grandas, F. Charisma: An integrated approach to automatic H&E-stained skeletal muscle cell segmentation using supervised learning and novel robust clump splitting (2013) *Medical Image Analysis*, . DOI: 10.1016/j.media.2013.07.007
- 520) Rogers, S., Sleeman, D., Kinsella, J. Investigating the disagreement between clinicians' ratings of patients in ICUs (2013) *IEEE Journal of Biomedical and Health Informatics*, . DOI: 10.1109/JBHI.2013.2252182
- 521) Maslove, D.M., Podchiyska, T., Lowe, H.J. Discretization of continuous features in clinical datasets (2013) *Journal of the American Medical Informatics Association*, . DOI: 10.1136/amiajnl-2012-000929
- 522) Güiza, F., Van Eyck, J., Meyfroidt, G. Predictive data mining on monitoring data from the intensive care unit (2013) *Journal of Clinical Monitoring and Computing*, . DOI: 10.1007/s10877-012-9416-3
- 523) Johnson, A.E.W., Kramer, A.A., Clifford, G.D. A new severity of illness scale using a subset of acute physiology and chronic health evaluation data elements shows comparable predictive accuracy (2013) *Critical Care Medicine*, . DOI: 10.1097/CCM.0b013e31828a24fe
- 524) Bailey, T.C., Chen, Y., Mao, Y., Lu, C., Hackmann, G., Micek, S.T., Heard, K.M., Faulkner, K.M., Kollef, M.H. A trial of a real-time Alert for clinical deterioration in Patients hospitalized on general medical wards (2013) *Journal of Hospital Medicine*, . DOI: 10.1002/jhm.2009
- 525) Belle, A., Kon, M.A., Najarian, K. Biomedical informatics for computer-aided decision support systems: A survey (2013) *The Scientific World Journal*, . DOI: 10.1155/2013/769639
- 526) Oniško, A., Druzdzal, M.J. Impact of precision of Bayesian network parameters on accuracy of medical diagnostic systems (2013) *Artificial Intelligence in Medicine*, .DOI: 10.1016/j.artmed.2013.01.004
- 527) Ongenaes, F., Van Looy, S., Verstraeten, D., Verplancke, T., Benoit, D., De Turck, F., Dhaene, T., Schrauwen, B., Decruyenaere, J. Time series classification for the prediction of dialysis in critically ill patients using echo statenetworks (2013) *Engineering Applications of Artificial Intelligence*, . DOI: 10.1016/j.engappai.2012.09.019
- 528) Harrison, D., Muskett, H., Harvey, S., Grieve, R., Shahin, J., Patel, K., Sadique, Z., Allen, E., Dybowski, R., Jit, M., Edgeworth, J., Kibbler, C., Barnes, R., Soni, N., Rowan, K. Development and validation of a risk model for identification of non-neutropenic, critically-ill, adult patients at high risk of invasive Candida infection (2013) *Health Technology Assessment*, . DOI: 10.3310/hta17030
- 529) Güiza, F., Depreitere, B., Piper, I., Van Den Berghe, G., Meyfroidt, G. Novel methods to predict increased intracranial pressure during intensive care and long-term neurologic outcome after traumatic brain injury: Development and validation in a multicenter dataset (2013) *Critical Care Medicine*, . DOI: 10.1097/CCM.0b013e3182742d0a
- 530) Kamsu-Foguem, B., Tchuente-Foguem, G., Allart, L., Zennir, Y., Vilhelm, C., Mehdaoui, H., Zitouni, D., Hubert, H., Lemdani, M., Ravaux, P. User-centered visual analysis using a hybrid reasoning architecture for intensive care units (2012) *Decision Support Systems*, . DOI: 10.1016/j.dss.2012.06.009
- 531) Li, Q., Clifford, G.D. Signal quality and data fusion for false alarm reduction in the intensive care unit (2012) *Journal of Electrocardiology*, . DOI: 10.1016/j.jelectrocard.2012.07.015
- 532) Roussel, M., Gros, A., Gacouin, A., Le Meur, N., Le Tulzo, Y., Fest, T. Toward new insights on the white blood cell differential by flow cytometry: A proof of concept study on the sepsis model (2012) *Cytometry Part B - Clinical Cytometry*, .DOI: 10.1002/cyto.b.21027
- 533) Li, Q., Clifford, G.D. Dynamic time warping and machine learning for signal quality assessment of pulsatile signals (2012) *Physiological Measurement*, . DOI: 10.1088/0967-3334/33/9/1491
- 534) Clifford, G.D., Behar, J., Li, Q., Rezek, I. Signal quality indices and data fusion for determining clinical acceptability of electrocardiograms (2012) *Physiological Measurement*, . DOI: 10.1088/0967-3334/33/9/1419
- 535) Stein, D.M., Hu, P.F., Chen, H.H., Yang, S., Stansbury, L.G., Scalea, T.M. Computational gene mapping to analyze continuous automated physiologic monitoring data in neuro-trauma intensive care (2012) *Journal of Trauma and Acute Care Surgery*, . DOI: 10.1097/TA.0b013e31825ff59a
- 536) Sleeman, D., Moss, L., Aiken, A., Hughes, M., Kinsella, J., Sim, M. Detecting and resolving inconsistencies between domain experts' different perspectives on (classification) tasks (2012) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2012.03.001
- 537) Bakhshi-Raiez, F., de Keizer, N.F., Cornet, R., Dorrepaal, M., Dongelmans, D., Jaspers, M.W.M. A usability evaluation of a SNOMED CT based compositional interface terminology for intensive care (2012) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2011.09.010
- 538) Patrick, J., Li, M. An ontology for clinical questions about the contents of patient notes (2012) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2011.11.008
- 539) Kim, S., Kim, W., Woong Park, R. A comparison of intensive care unit mortality prediction models through the use of data mining techniques (2011) *Healthcare Informatics Research*, . DOI: 10.4258/hir.2011.17.4.232

- 540) Thomas, E.M., Temko, A., Lightbody, G., Marnane, W.P., Boylan, G.B. Advances in automated neonatal seizure detection (2011) *Studies in Computational Intelligence*, . DOI: 10.1007/978-3-642-11739-8\_5
- 541) Sutherland, A., Thomas, M., Brandon, R.A., Brandon, R.B., Lipman, J., Tang, B., McLean, A., Pascoe, R., Price, G., Nguyen, T., Stone, G., Venter, D. Development and validation of a novel molecular biomarker diagnostic test for the early detection of sepsis (2011) *Critical Care*, . DOI: 10.1186/cc10274
- 542) Temko, A., Thomas, E., Marnane, W., Lightbody, G., Boylan, G. EEG-based neonatal seizure detection with Support Vector Machines (2011) *Clinical Neurophysiology*, . DOI: 10.1016/j.clinph.2010.06.034
- 543) Temko, A., Thomas, E., Marnane, W., Lightbody, G., Boylan, G.B. Performance assessment for EEG-based neonatal seizure detectors (2011) *Clinical Neurophysiology*, . DOI: 10.1016/j.clinph.2010.06.035
- 544) Meyfroidt, G., Güiza, F., Cottem, D., De Becker, W., Van Loon, K., Aerts, J.-M., Berckmans, D., Ramon, J., Bruynooghe, M., Van Den Berghe, G. Computerized prediction of intensive care unit discharge after cardiac surgery: Development and validation of a Gaussian processes model (2011) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/1472-6947-11-64 22027016
- 545) Lee, J., Mark, R.G. An investigation of patterns in hemodynamic data indicative of impending hypotension in intensive care (2010) *BioMedical Engineering Online*, . DOI: 10.1186/1475-925X-9-62
- 546) Saria, S., Rajani, A.K., Gould, J., Koller, D., Penn, A.A. Integration of early physiological responses predicts later illness severity in preterm infants (2010) *Science Translational Medicine*, . DOI: 10.1126/scitranslmed.3001304
- 547) Van Loon, K., Guiza, F., Meyfroidt, G., Aerts, J.-M., Ramon, J., Blockeel, H., Bruynooghe, M., Van Den Berghe, G., Berckmans, D. Prediction of clinical conditions after coronary bypass surgery using dynamic data analysis (2010) *Journal of Medical Systems*, . DOI: 10.1007/s10916-008-9234-9
- 548) Sleeman, D., Aiken, A., Moss, L., Kinsella, J., Sim, M. A system to detect inconsistencies between a domain expert's different perspectives on (classification) tasks (2010) *Studies in Computational Intelligence*, . DOI: 10.1007/978-3-642-05179-1\_14
- 549) Quiniou, R., Callens, L., Carrault, G., Cordier, M.-O., Fromont, E., Mabo, P., Portet, F. Intelligent adaptive monitoring for cardiac surveillance (2010) *Studies in Computational Intelligence*, . DOI: 10.1007/978-3-642-14464-6\_15
- 550) Meyfroidt, G., Güiza, F., Ramon, J., Bruynooghe, M. Machine learning techniques to examine large patient databases (2009) *Best Practice and Research: Clinical Anaesthesiology*, . DOI: 10.1016/j.bpa.2008.09.003
- 551) Imhoff, M., Kuhls, S., Gather, U., Fried, R. Smart alarms from medical devices in the OR and ICU (2009) *Best Practice and Research: Clinical Anaesthesiology*, . DOI: 10.1016/j.bpa.2008.07.008
- 552) Crump, C., Saxena, S., Wilson, B., Farrell, P., Rafiq, A., Silvers, C.T. Using Bayesian networks and rule-based trending to predict patient status in the intensive care unit. (2009) *AMIA ... Annual Symposium proceedings / AMIA Symposium*. AMIA Symposium, .
- 553) Luaces, O., Taboada, F., Albaiceta, G.M., Domínguez, L.A., Enríquez, P., Bahamonde, A. Predicting the probability of survival in intensive care unit patients from a small number of variables and training examples (2009) *Artificial Intelligence in Medicine*, . DOI: 10.1016/j.artmed.2008.11.005
- 554) Eshelman, L.J., Lee, K.P., Frassica, J.J., Zong, W., Nielsen, L., Saeed, M. Development and evaluation of predictive alerts for hemodynamic instability in ICU patients. (2008) *AMIA ... Annual Symposium proceedings / AMIA Symposium*. AMIA Symposium, .
- 555) Hiissa, M., Pahikkala, T., Suominen, H., Lehtikunnas, T., Back, B., Karsten, H., Salanterä, S., Salakoski, T. Towards automated classification of intensive care nursing narratives (2007) *International Journal of Medical Informatics*, . DOI: 10.1016/j.ijmedinf.2007.03.003
- 556) Guyet, T., Garbay, C., Dojat, M. Knowledge construction from time series data using a collaborative exploration system (2007) *Journal of Biomedical Informatics*, . DOI: 10.1016/j.jbi.2007.09.006
- 557) Vanhoutte, K.J.A., Laarakkers, C., Marchiori, E., Pickkers, P., Wetzels, J.F.M., Willems, J.L., Van Den Heuvel, L.P., Russel, F.G.M., Masereeuw, R. Biomarker discovery with SELDI-TOF MS in human urine associated with early renal injury: Evaluation with computational analytical tools (2007) *Nephrology Dialysis Transplantation*, . DOI: 10.1093/ndt/gfm170
- 558) Mueller, M., Wagner, C.L., Annibale, D.J., Knapp, R.G., Hulsey, T.C., Almeida, J.S. Parameter selection for and implementation of a web-based decision-support tool to predict extubation outcome in premature infants (2006) *BMC Medical Informatics and Decision Making*, . DOI: 10.1186/1472-6947-6-11
- 559) Lucas, P. Bayesian analysis, pattern analysis, and data mining in health care (2004) *Current Opinion in Critical Care*, . DOI: 10.1097/01.ccx.0000141546.74590.d6
- 560) Mueller, M., Wagner, C.L., Annibale, D.J., Hulsey, T.C., Knapp, R.G., Almeida, J.S. Predicting extubation outcome in preterm newborns: A comparison of neural networks with clinical expertise and statistical modeling (2004) *Pediatric Research*, . DOI: 10.1203/01.PDR.0000129658.55746.3C

- 561) Ganzert, S., Guttman, J., Kersting, K., Kühlen, R., Putensen, C., Sydow, M., Kramer, S. Analysis of respiratory pressure-volume curves in intensive care medicine using inductive machine learning (2002) *Artificial Intelligence in Medicine*, . DOI: 10.1016/S0933-3657(02)00053-2
- 562) Sierra, B., Serrano, N., Larrañaga, P., Plasencia, E.J., Inza, I., Jiménez, J.J., Revuelta, P., Mora, M.L. Using Bayesian networks in the construction of a bi-level multi-classifier. A case study using intensive care unit patients data (2001) *Artificial Intelligence in Medicine*, . DOI: 10.1016/S0933-3657(00)00111-1
- 563) Demšar, J., Zupan, B., Aoki, N., Wall, M.J., Granchi, T.H., Robert Beck, J. Feature mining and predictive model construction from severe trauma patient's data (2001) *International Journal of Medical Informatics*, . DOI: 10.1016/S1386-5056(01)00170-8
- 564) Parmanto, B., Deneault, L.G., Denault, A.Y. Detection of hemodynamic changes in clinical monitoring by time-delay neural networks (2001) *International Journal of Medical Informatics*, . DOI: 10.1016/S1386-5056(01)00174-5
- 565) Morik, K., Imboff, M., Brockhausen, P., Joachims, T., Gather, U. Knowledge discovery and knowledge validation in intensive care (2000) *Artificial Intelligence in Medicine*, . DOI: 10.1016/S0933-3657(00)00047-6
- 566) Tsien, C.L., Kohane, I.S., McIntosh, N. Multiple signal integration by decision tree induction to detect artifacts in the neonatal intensive care unit (2000) *Artificial Intelligence in Medicine*, . DOI: 10.1016/S0933-3657(00)00045-2
- 567) McKeown, K.R., Pan, S. Prosody modelling in concept-to-speech generation: Methodological issues (2000) *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, . DOI: 10.1098/rsta.2000.0595
- 568) Tsien, C.L. Event discovery in medical time-series data. (2000) *Proceedings / AMIA ... Annual Symposium. AMIA Symposium*, .