

O aprendizado de máquina no contexto da competição das lógicas de padronização e personalização da atenção à saúde

Machine learning in the context of the competition between the logics of standardization and personalization of healthcare

El aprendizaje automático en el contexto de las lógicas contrapuestas de la normalización y la personalización en la atención sanitaria

DOI: 10.55905/ijsmtv10n3-008

Originals received: 04/08/2024

Acceptance for publication: 04/26/2024

Marco Aurélio Mazzei

Mestre em Administração

Instituição: Universidade Paulista (UNIP)

Endereço: Rua Dr. Bacelar, 1212, Vila Clementino - SP, CEP: 04026-002

E-mail: professor@didaticovirtual.com.br

Orcid: <https://orcid.org/0000-0002-1829-4153>

Arnaldo Luiz Ryngelblum

Doutor em Administração

Instituição: Universidade Paulista (UNIP)

Endereço: Rua Dr. Bacelar, 1212, Vila Clementino - SP, CEP: 04026-002

E-mail: arnaldo.ryngelblum@docente.unip.br

Orcid: <https://orcid.org/0000-0003-3519-6333>

RESUMO

A integração das Tecnologias de Informação e Comunicação na área da saúde criou oportunidades para a utilização de tecnologias analítico-preditivas de Big Data como ferramenta de tomada de decisão. Contudo, trata-se de um ambiente complexo onde diversas lógicas institucionais orientam os diferentes profissionais e atores envolvidos. Pela lente teórica das múltiplas Lógicas Institucionais, podemos identificar o alinhamento de propostas de integração do Aprendizado de Máquina na saúde a partir de duas lógicas principais: uma que enfatiza a padronização do atendimento, apoiada na abordagem científica da prática médica, e outra que prioriza a personalização, que valoriza o cuidado e a atenção individualizados aos pacientes inseridos em suas comunidades. Nossa análise indica que as técnicas e algoritmos utilizados para atingir esses objetivos variam dependendo da lógica institucional prevalente na área dos artigos acadêmicos sobre o uso de Aprendizado de Máquina. Por exemplo, na medicina, o foco está no desenvolvimento de algoritmos para melhoria diagnóstica, o que está associado a estratégias de personalização. Por outro lado, na gestão, a ênfase está nas estratégias de classificação para aumentar a eficiência dos processos de triagem em saúde, o que é típico da padronização. À medida que a tecnologia continua a avançar, as fronteiras entre padronização e personalização tornam-se menos distintas e as duas lógicas convergem.

Essa convergência se baseia em propostas de atendimento individualizado que aderem aos padrões médicos estabelecidos, utilizando algoritmos que permitem avanços diagnósticos e terapêuticos, ao mesmo tempo que aumentam a eficiência por meio da automação.

Palavras-chave: lógicas institucionais, atenção à saúde, aprendizado de máquina, big data, padronização, personalização.

ABSTRACT

The integration of Information and Communication Technologies in the health sector has created opportunities for the use of Big Data analytical-predictive technologies as a decision-making tool. However, it is a complex environment where different institutional logics guide the different professionals and actors involved. Through the theoretical lens of multiple Institutional Logics, we can identify the alignment of proposals for integrating Machine Learning in healthcare based on two main logics: one that emphasizes the standardization of care, supported by the scientific approach to medical practice, and another that prioritizes personalization, which values individualized care and attention to patients in their communities. Our analysis indicates that the techniques and algorithms used to achieve these goals vary, depending on the prevailing institutional logic according to the area of academic articles on the use of Machine Learning. For example, in medicine, the focus is on developing algorithms for diagnostic improvement, which is associated with personalization strategies. On the other hand, in management, the emphasis is on classification strategies to increase the efficiency of health screening processes, which is typical of standardization. As technology continues to advance, the boundaries between standardization and personalization become less distinct, and the two logics converge. This convergence is based on individualized care proposals that adhere to established medical standards, using algorithms that enable diagnostic and therapeutic advances, while increasing efficiency through automation.

Keywords: institutional logics, healthcare, machine learning, big data, standardization, personalization.

RESUMEN

La integración de las Tecnologías de la Información y la Comunicación en la sanidad ha creado oportunidades para el uso de tecnologías analítico-predictivas Big Data como herramienta de toma de decisiones. Sin embargo, se trata de un entorno complejo en el que diferentes lógicas institucionales guían a los distintos profesionales y actores implicados. A través de la lente teórica de las múltiples Lógicas Institucionales, podemos identificar la alineación de las propuestas de integración del Machine Learning en la sanidad en base a dos lógicas principales: una que enfatiza la estandarización de los cuidados, apoyada en el enfoque científico de la práctica médica, y otra que prioriza la personalización, que valora el cuidado individualizado y la atención a los pacientes en sus comunidades. Nuestro análisis indica que las técnicas y algoritmos utilizados para alcanzar estos objetivos varían en función de la lógica institucional imperante en el ámbito de los artículos académicos sobre el uso del Machine Learning. Por ejemplo, en medicina, la atención se centra en el desarrollo de algoritmos para mejorar el diagnóstico, lo que se

asocia a estrategias de personalización. Por otro lado, en gestión, el énfasis se pone en estrategias de clasificación para aumentar la eficiencia de los procesos de cribado sanitario, lo que es propio de la estandarización. A medida que avanza la tecnología, las fronteras entre normalización y personalización se hacen menos nítidas y ambas lógicas convergen. Esta convergencia se basa en propuestas de atención individualizada que se adhieren a las normas médicas establecidas, utilizando algoritmos que permiten avances diagnósticos y terapéuticos al tiempo que aumentan la eficiencia mediante la automatización.

Palabras clave: lógicas institucionales, sanidad, machine learning, big data, estandarización, personalización.

1 INTRODUÇÃO

No segmento de atenção à saúde, há uma necessidade constante de decidir como alocar os recursos para atendimento, sejam eles preventivos, diagnósticos ou terapêuticos, de acordo com as necessidades dos pacientes e a alocação inadequada de um recurso necessário implica em queda na qualidade geral do atendimento, aumento da mortalidade e da ocorrência de sequelas e redução na segurança do atendimento (Brownlee *et al.*, 2017; Glasziou *et al.*, 2017; Smith *et al.*, 2013; Tunis; Stryer; Clancy, 2003). A inserção cada vez maior da informática no segmento de atenção à saúde, criou as condições necessárias para o uso de estratégias analítico-preditivas de *Big Data* para suporte à decisão sobre alocação de recursos (Archenaa; Anita, 2015; Bates *et al.*, 2014; Smith *et al.*, 2013; Wang *et al.*, 2018). Entre as tecnologias de *Big Data*, a Inteligência Artificial ou IA na forma de Aprendizado de Máquina ou *Machine Learning* vem se destacando pela qualidade dos resultados obtidos no tratamento semi ou completamente automatizado de volumes maciços de dados. Diversos estudos têm demonstrado que pode haver ganhos com a inclusão dessas técnicas nos processos de atenção à saúde (Deo, 2015; Gulshan *et al.*, 2016; Herland; Khoshgoftaar; Wald, 2014; Jiang *et al.*, 2017; Palanisamy; Thirunavukarasu, 2019; Ting *et al.*, 2017).

A análise da inclusão do Aprendizado de Máquina na atenção à saúde, utilizando como lente teórica as múltiplas Lógicas Institucionais, permite identificar uma disputa entre uma lógica voltada à padronização do atendimento médico, comum entre os gestores

dos negócios de atenção à saúde, e uma lógica da personalização ou customização do atendimento médico (Mannion; Exworthy, 2017), na forma de uma medicina personalizada ou de precisão (Wiley *et al.*, 2015), como um fim em si mesmo. A inclusão do Aprendizado de Máquina se dá em duas frentes: em uma, ela permite a categorização e padronização de um número maior de opções diagnósticas e terapêuticas, com um número cada vez maior de variáveis utilizadas para identificar grupos cada vez menores de indivíduos em suas especificidades. A outra frente de inclusão é decorrente da incorporação das quantidades maciças de informações geradas pela biomedicina na forma das chamadas Ômicas: linhas de pesquisa da biomedicina baseadas no uso intensivo de dados de genes e moléculas e que incluem, entre outras, a Genômica, a Transcriptômica, a Proteômica e a Metabolômica, bem como suas interações químicas e metabólicas, como ferramentas de personalização do atendimento médico e que tem seu ápice na chamada biomedicina translacional (Altman, 2012; Chen *et al.*, 2013). Essas duas frentes de inserção dos algoritmos de Aprendizado de Máquina, alinham-se as lógicas de padronização e personalização do cuidado médico e preconizam formas contrastantes de organização e de prestação de serviço para os pacientes na atenção à saúde, decorrentes de compreensões diferentes dos objetivos das intervenções dos profissionais, das bases que lhes dão sustentação e dos critérios de sua avaliação e ocorrem em paralelo às outras lógicas já identificadas no campo, como a do profissionalismo e do gerencialismo (Kitchener, 2002; Mannion; Exworthy, 2017).

Há duas métricas para avaliar os ganhos obtidos com o uso dos algoritmos na atenção à saúde e que são comuns a qualquer teste diagnóstico: A primeira, a sensibilidade refere-se à capacidade de identificar corretamente, a partir dos dados disponíveis, a existência ou não de uma dada patologia, sendo maior esta capacidade quando há um número menor de falsos positivos, enquanto a segunda, a especificidade, refere-se à capacidade de indicar corretamente a inexistência da patologia, sendo maior quando for menor o número de falsos negativos. A sensibilidade alta permite descartar com mais confiança um diagnóstico no caso de um exame negativo, enquanto uma especificidade maior permite confirmar com mais confiança um resultado positivo.

Entretanto, há um quadro mais amplo para análise dos algoritmos em que a qualidade e a segurança do atendimento são mediadas pela definição do que é

compreendido como “ter saúde”, qual a responsabilidade dos diversos envolvidos na sua manutenção e como se dividem os recursos e seus custos do atendimento (Cohen *et al.*, 2014; Forster; Gabe, 2008; McDonald; Waring; Harrison, 2006; Mittelstadt *et al.*, 2016; Strome, 2013). Um mesmo algoritmo de Aprendizado de Máquina, apresentado a conjuntos diversos de dados, pode chegar a diagnósticos, previsões ou sugestões terapêuticas diversas, dependendo de como foram coletados, preparados e rotulados os dados e de qual o objetivo foi estabelecido para seu uso (Richter; Khoshgoftaar, 2020). Esses dados são definidos e são fornecidos aos algoritmos a partir da própria definição do que é “ter saúde” e do que são as patologias ou doenças que se quer identificar. Uma visão da atenção à saúde orientada para a padronização da prática médica define o que é “ter saúde” de forma diferente de uma visão da atenção à saúde orientada para a personalização da prática médica (Forster; Gabe, 2008; Mannion; Exworthy, 2017; Tenenbaum; Sansone; Haendel, 2014) e essas diferenças conduzirão a resultados diversos para a aplicação de um mesmo algoritmo.

Para entender melhor como as visões da atenção à saúde se relacionam com a inserção do Aprendizado de Máquina no atendimento é importante compreender como a seleção dos algoritmos está associada aos dados e objetivos que se deseja obter (Chen *et al.*, 2013; Herland; Khoshgoftaar; Wald, 2014; Richter; Khoshgoftaar, 2020; Tai-Seale *et al.*, 2017). Denominamos como algoritmos baseados em Aprendizado de Máquina ao conjunto de algoritmos criados para desenvolver um comportamento a partir de um conjunto de dados. Formalmente, esses algoritmos são capazes de “aprender pela experiência E, com respeito a algum tipo de tarefa T e performance P, se sua performance P nas tarefas em T, na forma medida por P, melhoram com a experiência E” (Mitchell, 1997, p. 2). Dentro desse conjunto, encontramos os algoritmos baseados em redes neurais de Aprendizado Profundo, *Deep Learning Neural Networks*. As redes neurais são compostas por neurônios artificiais que podem ser acionados por suas entradas de dados e/ou podem ser responsáveis por guardar um registro de acionamentos anteriores, utilizando diversas técnicas para esse registro (Mitchell, 1997). As redes neurais artificiais podem ter várias camadas de decisão ou acionamento e manter de diversas formas o registro dos acionamentos que já ocorreram. Quanto maior o número de camadas, maior a profundidade da rede. Os algoritmos dividem-se, em um primeiro nível

de análise, entre os métodos de Aprendizado Supervisionado, Não Supervisionado e Aprendizado por Reforço e são os que têm apresentado os melhores resultados ao serem treinados para reproduzir, otimizar ou superar as capacidades humanas (Deo, 2015; Schmidhuber, 2015).

No Aprendizado Supervisionado é fornecido ao algoritmo um conjunto de dados de entrada para treinamento e um conjunto de saída com rótulos indicativos do comportamento que se deseja desenvolver e que representam as saídas esperadas para os dados do conjunto de entrada. A partir desse conjunto de dados, o algoritmo desenvolve métodos otimizados para generalizar o comportamento esperado para qualquer conjunto de dados. Em geral, são utilizados para problemas de classificação, quando queremos categorizar os elementos de um conjunto, ou para problemas de regressão, quando queremos encontrar uma função contínua que os represente, evitando o sobre ajuste ou *overfitting*. Aplica-se a situações em que os dados de entrada são bem conhecidos em suas especificidades, precisão, significado, representatividade e qualidade (Deo, 2015; Jiang *et al.*, 2017).

No Aprendizado Não Supervisionado, o algoritmo é encarregado de desenvolver uma estratégia de organização dos dados. São utilizados para realizar agrupamentos ou *clustering* e para simplificar conjuntos de dados, mantendo apenas as variáveis que apresentam alguma importância estatística. Não há uma saída esperada ou padrão para as respostas. Seu uso é maior nas áreas em que se busca novas abordagens ou relações e o aprofundamento do conhecimento, como a pesquisa básica de novos medicamentos ou suas associações, bem como os vínculos entre um gene e sua expressão (Deo, 2015; Miotto *et al.*, 2016; Shomorony *et al.*, 2018).

Por fim, no Aprendizado por Reforço, os comportamentos vão sendo avaliados conforme o algoritmo os desenvolve, em uma estratégia de treinamento contínuo: se uma ação é desejável ela é recompensada e se ela é indesejável, é punida e o algoritmo vai se ajustando e aprendendo com esses retornos (Mitchell, 1997). Essa técnica é utilizada para situações que envolvem necessidade constante de reavaliação e revalidação do conhecimento e dos processos que se deseja otimizar e são mais utilizados em processos em que o homem acompanha ações realizadas pelos equipamentos, como a condução

autônoma de automóveis e, na atenção à saúde, para aplicações de telecirurgia e telemedicina (Johnson *et al.*, 2018).

A título de exemplo de como o resultado do uso de Aprendizado de Máquina se relaciona com os dados fornecidos aos algoritmos e aos objetivos estabelecidos para esse uso, Gulshan *et al.* (2016) desenvolveram um algoritmo de aprendizado supervisionado para detectar exclusivamente a retinopatia diabética através de fotografias do fundo da retina. O algoritmo recebeu imagens do fundo da retina de populações homogêneas de indivíduos brancos, rotuladas por um painel de oftalmologistas seniores, como imagens de fundo de olho de portadores e não portadores de retinopatia diabética. É importante destacar que não foram fornecidas as características do que é uma imagem de fundo de olho da retinopatia diabética: apenas os conjuntos de imagens, uma avaliação da qualidade da imagem e uma avaliação do grau da retinopatia diabética atribuída pelo painel de oftalmologistas. A partir desse conjunto de informações, o algoritmo desenvolveu a capacidade de identificar, com mais sensibilidade e especificidade do que os próprios integrantes do painel, a existência ou não da patologia em um conjunto de imagens de referência para validação. Em outro estudo, Ting *et al.* (Ting *et al.*, 2017) aprofundaram a análise, trabalhando com bases de imagens multiétnicas e incluindo a classificação do glaucoma e da degeneração macular relacionada à idade (DMRI), porque não identificar esses casos, em um exame de fundo de olho de rotina, é clinicamente inaceitável” (Ting *et al.*, 2017, p. 2212). Perceba-se que uma definição mais ampla do que é aceitável como padrão de saúde visual, implica em preparação adicional dos dados, por exemplo, incluindo múltiplas etnias e rotulagens adicionais para treinar o algoritmo. Como a qualidade do algoritmo está diretamente ligada à qualidade dos dados de treinamento fornecidos, a sua adequada rotulagem e a uma quantidade de dados suficiente para aquisição da precisão desejada, definições mais ou menos abrangentes do que seja “ter saúde” implicam em maior complexidade no processo de treinamento, em uso ampliado de recursos e em maior quantidade de dados necessários para o treinamento dos algoritmos. Um algoritmo que não tenha sido exposto a imagens rotuladas de uma patologia em uma dada etnia pode ser incapaz de identificar com a sensibilidade e especificidade desejada essa patologia em indivíduos dessa etnia. Da mesma forma, a rotulação de apenas uma dada patologia prepara o algoritmo para identificar apenas

aquela condição. No primeiro artigo que só identifica retinopatia em indivíduos brancos, foi identificada a necessidade de cerca de 60.000 imagens para saturação e, no segundo artigo que identifica retinopatia, glaucoma e degeneração macular pela idade em diversas etnias, foram necessárias 76.370 imagens para retinopatia, 125.189 para possível glaucoma e 72.120 para degeneração macular. Essas quantidades são necessárias para treinamento, mas é necessário ainda um conjunto maior para validação e outro para avaliação e as imagens precisam da rotulação, efetuada por um profissional experiente, que as classifica de acordo com o diagnóstico e grau de evolução da patologia.

A partir de artigos publicados em periódicos de medicina e artigos publicados em periódicos da gestão dos negócios de atenção à saúde identificamos se os seus objetivos se alinham a uma visão voltada à padronização ou à personalização do atendimento médico para uso do Aprendizado de Máquina (*Machine Learning*) na atenção à saúde utilizando, como lente teórica para essa análise a abordagem das múltiplas Lógicas Institucionais (Thornton; Ocasio; Lounsbury, 2012). A inserção do Aprendizado de Máquina na atenção à saúde ocorre em um contexto complexo de pluralismo de lógicas. A definição dos objetivos dessa inserção e das fontes de dados e técnicas de tratamento da informação, podem expressar seu maior alinhamento a uma ou outra lógica, além de reforçá-las ou refutá-las. Em nossa análise, avaliamos como os artigos mais citados, propondo o uso de Aprendizado de Máquina na atenção à saúde e publicados em periódicos de gestão de negócios se diferenciam dos artigos publicados em periódicos de medicina, no contexto de uma disputa entre as lógicas de padronização ou personalização do atendimento médico e como avaliam uma possível convergência entre essas abordagens, a partir da definição de seus objetivos, das fontes de dados consideradas e da avaliação de seus resultados.

2 FUNDAMENTAÇÃO TEÓRICA

O trabalho de Friedland e Alford (1991) reconhece a coexistência de múltiplas lógicas no nível da sociedade como orientadoras da ação e os primeiros estudos envolvendo a lógica institucional privilegiavam a abordagem da dominância da lógica de um campo sobre as demais como a base da previsibilidade e da ordem nas ações

organizacionais. As teorias institucionais avançaram então sobre a questão da existência e atuação de múltiplas lógicas nos diversos campos da atividade humana, explorando as relações entre os indivíduos, as organizações e a sociedade. A abordagem da sociedade como um sistema interinstitucional possibilita a introdução de fontes de heterogeneidade e a análise de contradições entre as lógicas prescritas pelas diferentes ordens institucionais atuando em um dado campo. Os contextos da ação dos atores são influenciados e a ação é moldada pela disputa das lógicas institucionais dos diferentes setores da sociedade, que Thornton, Ocasio e Lounsbury (2012) irão ampliar para seis: o mercado, a corporação, as profissões, o estado, a família, as religiões e a comunidade.

A metateoria que evoluiu a partir de Friedland e Alford (1991) também permite que essa ação se dê em diversos níveis. Por exemplo: nas organizações, nos mercados, em setores industriais, em redes interorganizacionais, comunidades geográficas e campos organizacionais. A complexidade que caracteriza a sociedade, de acordo com a metateoria, permite a análise de conflitos, competições e consensos entre as lógicas, a discussão de hibridizações entre as lógicas e diversos outros formatos de coexistência e mecanismos de mudança ou alternância da dominância de uma lógica sobre as demais. Scott *et al.* (2000), identificam múltiplas lógicas em atuação no ambiente de atendimento à saúde: as lógicas profissionais, a lógica de mercado, a lógica familiar, apenas para citar algumas. A abordagem que iremos utilizar alinha-se aos estudos que consideram a coexistência de múltiplas lógicas atuando (Dunn; Jones, 2010; Greenwood *et al.*, 2010; Reay; Hinings, 2009; Waldorff; Reay; Goodrick, 2013) para podermos identificar como essas lógicas se manifestam na escolha dos objetivos das propostas acadêmicas de introdução de algoritmos de Aprendizado de Máquina no suporte à prática médica e como se dá o alinhamento a uma lógica da personalização ou a uma lógica da padronização na alocação dos recursos e na avaliação dos objetivos e dos dados utilizados.

Dunn e Jones (2010) estudando o ensino de medicina nos Estados Unidos, encontraram um conflito entre lógicas orientadas pela pesquisa básica, pelo atendimento clínico e pela saúde pública. Enquanto os profissionais orientados pela universalização do atendimento na saúde pública focam suas análises em questões epidemiológicas, estatísticas e em seus resultados clínicos, a pesquisa básica orienta-se por compreender como se relacionam causas e efeitos de patologias e o atendimento clínico preocupa-se

com o melhor tratamento no contexto particular do paciente. O campo é, nesse contexto, arena de constante disputa entre as lógicas que buscam a primazia na orientação da ação médica, no estabelecimento de seus objetivos, na definição de regulamentos, leis e práticas e na própria formação dos novos médicos. Transportando essa discussão para a pesquisa sobre a inserção das tecnologias de informática (Exworthy, 2015) e de Aprendizado de Máquina na atenção à saúde (Mittelstadt *et al.*, 2016), podemos traçar paralelos para identificar quais as lógicas que estão orientando as pesquisas realizadas no âmbito da gestão de negócios de atenção à saúde e no âmbito da prática médica. Nossa análise alinha-se com a de Dunn e Jones no sentido de reconhecer nos artigos publicados uma orientação à uma ou outra lógica, como resultado de disputas por influência das identidades profissionais (Scott, 2008), que atuam em conjunto no campo e que trabalhos anteriores já identificaram como alinhados a personalização ou padronização, (Mannion; Exworthy, 2017). Da mesma forma, nossa análise considera possível o surgimento de lógicas híbridas, resultado das interações e disputas entre as lógicas.

McDonald *et al.* (2006) identificaram que a questão da segurança do paciente é considerada de forma diversa por gestores hospitalares e médicos. Suas identidades profissionais conduzem a orientações diversas de como se deve avaliar e garantir a segurança do paciente no atendimento. Essa diferença de identidades se expressa entre uma orientação científico-determinista típica dos gestores de negócios de atenção à saúde e de algumas especialidades da medicina, que buscam a padronização do atendimento e que avaliam que a aplicação de recursos iguais conduz a resultados iguais, em oposição à uma orientação da prática médica que a compreende como uma arte e avalia que os resultados são obtidos em um contexto sempre único e que não pode ser plenamente reproduzido, conduzindo a resultados sempre diversos. O uso de tecnologia no ambiente hospitalar e, em particular, das técnicas de *Big Data* e Aprendizado de Máquina, viabilizaram um caminho entre as duas orientações: uma quantidade cada vez maior de situações particulares pode ser registrada e documentada em sistemas que objetivam fornecer subsídios à tomada de decisão no atendimento aos pacientes levando em conta suas especificidades (Mannion; Exworthy, 2017; Wiley *et al.*, 2015) e incorporando novas fontes de dados e novos indicadores do que seja ter saúde.

3 METODOLOGIA

Grupos profissionais diferentes podem ter experiências e expectativas diferentes com relação aos recursos à sua disposição (Fryback; Thornbury, 1991). A partir dos artigos mais citados, publicados em periódicos da área da gestão de negócios de atenção à saúde e dos artigos mais citados, publicados em periódicos da área médica, avaliamos um conjunto de características das técnicas de *Big Data* e *Machine Learning* elencadas nas propostas de seu uso, indicadas no Quadro 1 - Critérios de classificação dos artigos.

Os valores constantes do quadro são aqueles encontrados nos 23 artigos selecionados para análise. Esses critérios foram avaliados considerando o alinhamento dos artigos às características das lógicas institucionais dos profissionais da gestão de negócios de atenção à saúde, considerados como mais inclinados a uma orientação para a padronização, regularização e regulamentação da ação de atendimento em contraposição aos artigos voltados aos profissionais da área médica atuantes na atenção à saúde, considerados como mais inclinados a uma orientação para a personalização e customização do atendimento e do gerenciamento da saúde do paciente, a partir de trabalhos anteriores que avaliaram a características das lógicas a partir dos grupos profissionais em que elas apresentam prevalência (Dunn; Jones, 2010; Exworthy, 2015; Mannion; Exworthy, 2017; Mittelstadt *et al.*, 2016; Scott, 2008).

Quadro 1 - Critérios de classificação dos artigos

Indicador/Critério	Valores	
Técnica	Aprendizado Supervisionado Aprendizado não supervisionado Aprendizado semi-supervisionado	Aprendizado por reforço Mista
Objetivo	Preditivo Classificatório Diagnóstico Exploratório	Teórico Vigilância Redução de custos Aumento dos atendimentos
Fontes de dados	Equipamentos diagnósticos Sensores corporais profissionais Sensores corporais pessoais (IOT) Profissionais (Médicos/Enfermeiros/Técnicos) Usuários (Pacientes, população, segmentos)	Bases de dados públicas Bases de dados privadas Bases de dados temporais Prontuários eletrônicos
Qualidade dos dados	Explicitamente citada Não citada	Implicitamente citada
Orientação	Orientado à padronização	Orientado à padronização e personalização

Indicador/Critério	Valores
	Orientado à personalização

Fonte: Pesquisa dos autores na base de dados Scopus

A classificação dos artigos segundo essas características objetivou identificar diferenças entre as abordagens utilizadas pelos autores dos artigos, seus objetivos e avaliações das restrições de recursos consideradas. Para a classificação segundo a orientação à padronização ou personalização, consideramos as características das lógicas institucionais descritas por trabalhos sobre lógicas em competição na atenção à saúde, orientadas por estratégias de padronização ou de personalização do atendimento (Deo, 2015; Mannion; Exworthy, 2017; McDonald; Waring; Harrison, 2006; Waring *et al.*, 2016). Esses trabalhos avançam sobre a questão de como a orientação a padronização e a orientação a personalização são resultado das identidades profissionais em ação no ambiente de atenção à saúde e como se conectam aos objetivos profissionais. Em consonância com essa análise, Waldorf e Madsen (2023) registraram os mecanismos pelos quais os atores realizam um trabalho de alinhamento entre as lógicas prevalentes atuando no campo no processo de tradução de novos conceitos e práticas de gestão para permitir a mudança ou a manutenção das práticas anteriores. O resultado de nossa análise encontra-se no Quadro 2 - Parâmetros indicativos de alinhamento à padronização ou personalização em que as práticas do atendimento na atenção à saúde são apresentadas com suas interpretações segundo as lógicas de padronização e personalização.

Quadro 2 - Parâmetros indicativos de alinhamento à padronização ou personalização

Práticas	Padronização	Personalização
Gestão da saúde	Baseada em padrões de atendimento definidos para grupos socioeconômicos	Baseada no uso de marcadores moleculares e genéticos para identificar grupos
Serviços e tratamentos	Baseados em padronizações de práticas, nomenclaturas e rotinas diagnósticas	Baseados em uma visão holística do paciente, envolvendo seus valores, desejos e estilos
Gestão do tratamento	Baseada na capacidade financeira de grupos socioeconômicos	Baseada na escolha individual com base em um mercado de produtos oferecidos como <i>commodities</i>
Definição de saúde para o atendimento médico	Padrões definidos profissionalmente do que seja saúde e atendimento médico-terapêutico	Participação do paciente na definição de estado de saúde, tornando-se corresponsáveis por seus tratamentos e condições de saúde

Fonte: Elaborado pelos autores a partir de (Mannion; Exworthy, 2017)

Foram realizadas duas pesquisas na base Scopus com os seguintes critérios: Artigos publicados após 2014, contendo os termos *Machine Learning* e *Health Care*. A primeira pesquisa limitou os artigos àqueles publicados em periódicos da área da Medicina, apresentados no Quadro 3 - Artigos da área da Medicina.

Quadro 3 - Artigos da área da Medicina

Título	Ano	Citações
1 - Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs (Gulshan <i>et al.</i> , 2016)	2016	1157
2- Machine learning in medicine (Deo, 2015)	2015	309
3 - Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes (Ting <i>et al.</i> , 2017)	2017	259
4 - Using recurrent neural network models for early detection of heart failure onset (Choi <i>et al.</i> , 2017)	2017	143
5 - Personal Sensing: Understanding Mental Health Using Ubiquitous Sensors and Machine Learning (Mohr; Zhang; Schueller, 2017)	2017	100
6 - Automated grading of age-related macular degeneration from color fundus images using deep convolutional neural networks (Burlina <i>et al.</i> , 2017)	2017	86
7 - Prediction of In-hospital Mortality in Emergency Department Patients with Sepsis: A Local Big Data-Driven, Machine Learning Approach (Taylor <i>et al.</i> , 2016)	2016	84
8 - Arrhythmia detection using deep convolutional neural network with long duration ECG signals (Yıldırım <i>et al.</i> , 2018)	2018	78
9 - An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU (Nemati <i>et al.</i> , 2018)	2018	67
10 - Interpretable Deep Models for ICU Outcome Prediction (Che <i>et al.</i> , 2016)	2016	61

Fonte: Pesquisa dos autores na base de dados Scopus

A segunda pesquisa recuperou os artigos publicados nas áreas de negócios, gestão e administração, apresentados no Quadro 4 - Artigos da área da Gestão de negócios de atenção à saúde.

Quadro 4 - Artigos da área de gestão de negócios

Título	Ano	Citações
1 - Predicting overall survivability in comorbidity of cancers: A data mining approach (Zolbanin; Delen; Hassan Zadeh, 2015)	2015	40
2 - A case-based reasoning system for aiding detection and classification of nosocomial infections (Gómez-Vallejo <i>et al.</i> , 2016)	2016	29
3 - Transforming hospital emergency department workflow and patient care (Lee <i>et al.</i> , 2015)	2015	21
4 - Big data and health care system using mlearning (Rajesh; Sairam, 2019)	2019	18

Título	Ano	Citações
5 - An analytics approach to designing combination chemotherapy regimens for cancer (Bertsimas <i>et al.</i> , 2016)	2016	18
6 - Reducing hospital readmissions by integrating empirical prediction with resource optimization (Helm <i>et al.</i> , 2016)	2016	15
7 - Predicting graft survival among kidney transplant recipients: A Bayesian decision support model (Topuz <i>et al.</i> , 2018)	2018	12
8 - Predicting HCAHPS scores from hospitals' social media pages: A sentiment analysis (Huppertz; Otto, 2018)	2018	10
9 - Big Data and the Precision Medicine Revolution (Hopp; Li; Wang, 2018)	2018	5
9 - An integrated machine learning framework for hospital readmission prediction (Jiang <i>et al.</i> , 2018)	2018	5
9 - Predictive analytics: A case study in machine-learning and claims databases (Kvancz; Sredzinski, 2016)	2016	5
10 - A comparative data analytic approach to construct a risk trade-off for cardiac patients' readmissions (Nasir <i>et al.</i> , 2019)	2019	3

Fonte: Pesquisa dos autores na base de dados Scopus

Os artigos foram ordenados em ordem decrescente de número de citações, sendo selecionados os 10 mais citados na área de medicina e, 12 na área de gestão de negócios, em função de haver três com o mesmo número de citações na nona posição. Os resultados foram então avaliados segundo os critérios apresentados nos Quadros 1 e 2, considerando a técnica proposta, o objetivo de uso dos algoritmos, as fontes de dados utilizadas, as considerações sobre a qualidade dos dados e a orientação a uma lógica da padronização ou da personalização do atendimento, e agrupados por área (Medicina ou Gestão de Negócios de atenção à saúde), resultando no quadro 5 - Resultados agrupados por área segundo critérios de avaliação:

Quadro 5 - Resultados agrupados por área segundo critérios de avaliação

Critério	Gestão de negócios	Quant.	Medicina	Quant.
Técnica	Semi-supervisionado	5	Não supervisionado	4
	Supervisionado	3	Supervisionado	4
	Mista	1	Mista	2
	Não se aplica '	2		
	Não avaliado	1		
Objetivo	Classificatório	9	Diagnóstico	9
	Preditivo	9	Teórico	2
	Teórico	2	Preditivo	3

Critério	Gestão de negócios	Quant.	Medicina	Quant.
	Vigilância	1		
	Não avaliado	1		
Fontes	Bases de dados privadas	11	Sensores corporais	7
	Prontuários eletrônicos	7	Prontuários eletrônicos	6
	Sensores corporais	2	Imagens diagnósticas	4
	Registros observacionais	2	Avaliação por especialista	4
Qualidade dos dados	Explicitamente citada	8	Explicitamente citada	10
	Implicitamente citada	0	Implicitamente citada	
	Não citada	4	Não citada	
Orientação	Orientado à padronização	9	Orientado à padronização	3
	Orientado à personalização		Orientado à personalização	6
	Padronização e personalização			
		3	Padronização e personalização	1

Fonte: Pesquisa dos autores na base de dados Scopus

4 DISCUSSÃO DOS RESULTADOS

Avaliando as distinções entre as duas áreas de estudo que podem ser vinculadas às lógicas de padronização ou personalização, iniciamos destacando as técnicas utilizadas nos estudos: enquanto o supervisionado e semi-supervisionado são predominantes para as pesquisas na área de gestão de negócios de atenção à saúde, na área médica encontramos uma divisão entre os estudos supervisionados e não supervisionados. O motivo dessa distinção pode ser associado às lógicas de padronização ou personalização: enquanto a padronização é construída a partir da classificação feita com base em critérios bem definidos, típica dos algoritmos supervisionados e semi-supervisionados, a personalização está em busca da construção desses critérios, e os algoritmos não supervisionados são os mais adequados para suportar essa busca.

Na área médica, o uso dos algoritmos não supervisionados vincula-se ao caráter de pesquisa básica com objetivo de simplificar os conjuntos de dados ou de encontrar novas relações e abordagens (Schmidhuber, 2015), como pode ser identificado na explicação a seguir, sobre a performance dos algoritmos não supervisionados em identificar novas características preditivas:

... talvez a lição mais importante tenha sido que as novas características aprendidas eram essenciais para melhorar o desempenho... não se pode simplesmente inserir um conjunto estabelecido de características em um novo pacote algorítmico e esperar uma classificação superior. Muitas das características preditivas aprendidas ... eram inteiramente novas, apesar de

décadas de exames de lâminas de câncer de mama por patologistas. (Deo, 2015, p. 1924)

A afirmação se alinha a uma oposição baseada na disputa entre a incerteza classificatória de uma arte médica e a certeza classificatória da gestão de negócios. Encontramos indícios do reconhecimento dessa oposição quando o autor afirma que “... uma das principais contribuições do Aprendizado de Máquina é adotar uma abordagem imparcial para identificar variáveis informativas inesperadas” (Deo, 2015, p. 1924). Essa afirmação é importante porque, sendo destinada a área médica, demonstra o reforço de uma visão da medicina baseada na ciência em oposição a compreensão da atividade médica como uma arte, pessoal. O destaque dado a identificação imparcial dos fatores de uma dada patologia que, apesar de décadas de prática, ainda não são completamente conhecidos, reforça a importância de manter a prática médica associada à pesquisa científica na busca do avanço da qualidade do atendimento. De fato, mais adiante, o autor afirma que “...o aprendizado não supervisionado pode ser visto como um meio de seleção de recursos, pois pode permitir a descoberta de descritores biológicos robustos, que podem ser usados em um modelo supervisionado para a previsão de doenças” (Deo, 2015, p. 1926). Essa afirmativa demonstra que a convergência entre a padronização e a personalização não está afastada, mas ela aqui se dá em um sentido inverso ao do proposto pelos estudos da área de gestão de negócios. Descobrimos os fatores que se manifestam nos casos individuais realizando pesquisa básica com métodos não supervisionados e, munidos dos resultados, padronizamos e generalizamos seu uso.

Na gestão de negócios o caminho a ser percorrido ocorre no sentido contrário: Hopp *et al.* (2018) afirmam que ao final, a transição da padronização (uma medicina de tamanho único) para a personalização (uma medicina de precisão) ocorrerá pela melhoria e pelo aumento das fontes de dados e pela evolução das técnicas de análise. Essas interpretações da convergência, tanto da área médica, quanto da gestão de negócios, se repetem nos demais artigos selecionados, e são consequência dos objetivos dos estudos nas duas áreas: enquanto, para a área médica a maioria dos estudos têm o objetivo de aprofundar o conhecimento para melhorar o diagnóstico e os tratamentos em uma ciência que ainda não é exata e se aproxima mais da arte, para a gestão de negócios a classificação em grupos para atendimento, reconhecidos por uma ciência exata é predominante. Um

exemplo dessa orientação pode ser visto no seguinte trecho do artigo da área de gestão de negócios de atenção à saúde:

Do ponto de vista dos gestores hospitalares, uma estratégia para controlar a taxa de readmissão é implementar sistemas de descoberta de conhecimento para identificar pacientes que apresentam alto risco de readmissão... para fornecer intervenções precoces e intensivas em recursos para os pacientes com maior risco, como cuidados intensivos pós-alta, gerenciamento das condições em sua casa e planejamento de outros tipos de alta (Jiang *et al.*, 2018, p. 73).

Os pacientes deste estudo foram classificados em 4 grupos: Retorno necessário em até 30, 60, 120 ou 180 dias, característicos de estratégias de classificação. A partir desse agrupamento, a aplicação de técnicas de descoberta de conhecimento associa fatores aos grupos, permitindo maior eficiência na classificação e automação do processo. Em Topuz *et al.* (2018), outro artigo da área de gestão de negócios, é destacada a busca de uma metodologia que combina seleção de variáveis com técnicas de aprendizado para melhorar a capacidade preditiva dos algoritmos. O agrupamento aqui ocorre em três grupos: alto, médio e baixo risco, a partir da variável binária sobrevivência ou não dos pacientes com intervalos de análise de 1, 3, 7 e 9 anos. Esses intervalos foram utilizados porque variáveis binárias para avaliar sobrevivência proporcionam informação limitada por depender dos pontos de corte considerados para definição do que é sobrevida. Se o estudo determinar 365 dias como o ponto de corte, pacientes que viveram 366 dias ou 3650 dias são considerados no mesmo grupo. Da mesma forma, se o estudo determinar 10 anos, pacientes que viveram 3649 dias ou 3 dias estarão no mesmo grupo, o que torna variáveis binárias pouco precisas para a avaliação. O uso de diversos pontos de corte objetiva reduzir essa imprecisão.

Os objetivos diagnósticos e o uso como ferramenta de suporte na seleção de tratamentos personalizados são claramente enunciados, em um artigo da área de medicina: “predição é claramente menos importante do que a interdição (da sepse): não é suficiente saber, temos que atuar para melhorar os resultados centrados nos pacientes” (Nemati *et al.*, 2018, p. 552). O objetivo final dos autores é o de que estratégias de tratamento sejam indicadas pelo algoritmo para seleção pelos médicos para cada paciente, a partir do levantamento precoce dos fatores conduzindo à sepse no caso particular. Este

sistema de intervenção permite que os cuidadores identifiquem e tratem pacientes com antibióticos, medicamentos, fluidos e outras terapias auxiliares com base em uma estimativa confiável de sua probabilidade de desenvolver sepse no futuro próximo. O que se busca aqui, não é apenas categorizar os pacientes, mas antecipar seu diagnóstico e orientar a seleção dos tratamentos e dos profissionais que podem atuar, inclusive, remotamente. O objetivo de maior eficiência diagnóstica aparece em 7 dos 10 artigos da área médica, enquanto na área de negócios há uma divisão entre aumento da eficiência, redução de custos e artigos que se limitam a explicar as potencialidades das técnicas, com quatro artigos cada um.

A avaliação do aumento dos sensores e fontes de informações nos ambientes hospitalares modernos, em particular nas UTIS, também permite avaliar a diferença de orientação entre os autores dos artigos. O aumento do número de sensores é citado como responsável pelo aumento da complexidade destes ambientes pelos médicos, tornando cada vez mais difícil dominar todos os aspectos do acompanhamento dos pacientes nessas unidades (Che *et al.*, 2016; Mittelstadt *et al.*, 2016), é e avaliado como importante componente para avançar o conhecimento a partir dos dados coletados. É destacada a necessidade de registrar e compreender melhor as relações entre os dados coletados por uma profusão de sensores e as evoluções dos diversos pacientes (Che *et al.*, 2016), considerando tanto as técnicas supervisionadas, quanto não supervisionadas. Dois dos artigos médicos alertam para a necessidade de uma tradução entre os resultados obtidos com o uso do Aprendizado de Máquina na análise das complexas combinações dos dados avaliados, em regras e procedimentos compreensíveis pelos profissionais médicos (Che *et al.*, 2016; Nemati *et al.*, 2018). Um deles questiona explicitamente: “... como podemos desenvolver novas soluções baseadas em dados que podem alcançar desempenho de última geração como modelos de aprendizagem profunda e, ao mesmo tempo, podem ser facilmente interpretados por profissionais de saúde e médicos?” (Che *et al.*, 2016, p. 371). Essa é uma preocupação comum nos artigos da área médica e demonstra que uma das dificuldades da personalização está em como tornar compreensíveis para os médicos, as situações particulares dos pacientes, cada uma potencialmente diferente das outras.

Nos artigos da área médica, os sensores corporais, os prontuários eletrônicos e as imagens diagnósticas e suas avaliações por especialistas são citados como elementos para

uma compreensão maior dos fatores em ação para a condição de um dado paciente com o uso da Aprendizagem de Máquina, enquanto nos artigos para a gestão de negócios de atenção à saúde, os dados provenientes de bases de dados e de prontuários eletrônicos são utilizados para treinar algoritmos para o desenvolvimento de sistemas de categorização e classificação. A partir da análise de dados históricos e dos desfechos clínicos, os sistemas permitem o desenvolvimento da categorização dos pacientes em grupos para diagnóstico ou prevenção de patologias. Essa categorização afasta ou reduz a necessidade de um sistema para interpretação dos resultados, pois recorre a padrões já estabelecidos e reconhecidos pelos médicos do que seja “ter saúde”. Mas esses padrões não são definitivos e os exemplos apresentados sobre a discussão do que é saúde visual e quais as patologias que devem ser identificadas em um exame e tratadas, indicam como a classificação não é uma estratégia suficiente para a atenção em saúde.

A avaliação da qualidade dos dados é citada explicitamente em oito dos doze estudos da área de negócios, enquanto a totalidade dos estudos médicos afirmam que seus resultados se relacionam com a qualidade dos dados. Diversos dos estudos da área médica citam a captura de diagnósticos por imagem e sua junção com outros sensores para oferecer dados em um nível de precisão superior ao do olhar do especialista, permitindo diagnósticos precoces e melhorias de prognósticos graças ao início imediato da ação terapêutica (Burlina *et al.*, 2017; Che *et al.*, 2016; Chougrad; Zouaki; Alheyane, 2018; Gulshan *et al.*, 2016; Ting *et al.*, 2017). Aqui, novamente, os estudos não supervisionados identificam e realizam agrupamentos que, posteriormente, são avaliados a partir da literatura e da prática médica para identificar porque ocorreram, como devem ser compreendidos e qual ou quais as melhores estratégias terapêuticas.

Retomando a discussão sobre a oposição das lógicas de padronização e personalização descritas por Mannion e Exworthy (2017), encontramos na área de gestão de negócios a orientação principal para padronização em 9 artigos, caracterizada por citação de categorias, agrupamentos e rótulos para atribuição aos pacientes e em 3 artigos é aventado que a padronização pode evoluir para a personalização. Na área médica há uma orientação predominante para a personalização em 6 dos 10 artigos, seja pela citação específica da individualização dos resultados diagnósticos, seja pelo objetivo de

individualizar os tratamentos; em três artigos, a categorização para atendimento é citada e em um há o objetivo de categorizar para, posteriormente, personalizar.

5 CONCLUSÃO

Os artigos envolvendo o uso de Aprendizado de Máquina na área da atenção à saúde alinham-se a duas interpretações de como se deve orientar a prática médica, características de duas lógicas distintas. Uma interpreta a prática médica como passível de padronização, sujeita a regras e normatizações codificadas em rotinas no interior dos estabelecimentos, selecionadas entre categorias identificadas a partir de um conjunto cada vez maior de critérios. Outra, conceitua a prática médica como passível de personalização, representada por um conjunto de fatores, mensurados e avaliados por uma quantidade cada vez maior de sensores e registradas nos sistemas que forneceriam roteiros particulares e precisos de estratégias de tratamento e prevenção de doenças. Entre ambas, em comum, a necessidade de uma definição do que seja “ter saúde” comum a todos os envolvidos. Um exemplo tornará essa necessidade mais clara: entre três artigos da área médica que sugerem estratégias para melhoria dos processos de diagnóstico e prevenção de processos degenerativos da visão, um se preocupa apenas com a melhoria da qualidade do diagnóstico da retinopatia diabética (Gulshan *et al.*, 2016), outro se concentra com a degeneração macular (Burlina *et al.*, 2017), enquanto o terceiro afirma que é inadmissível que um tal algoritmo não possua ambas as capacidades diagnósticas, além de diagnosticar também o glaucoma (Ting *et al.*, 2017). Esse exemplo é um registro claro de como a atenção à saúde pode definir o objetivo de ter saúde de forma diversa, de acordo com a existência de recursos materiais, intelectuais e tecnológicos, mesmo quando compartilhem da mesma identidade profissional.

Quando a análise cruza as linhas entre identidades profissionais, também são ampliados os termos em que as distinções se colocam. Os profissionais da gestão dos negócios de atenção à saúde almejam a otimização da alocação de recursos no atendimento de emergência para evitar a readmissão ou retorno dos pacientes (Helm *et al.*, 2016; Jiang *et al.*, 2018; Lee *et al.*, 2015), levando em conta questões socioeconômicas e demográficas em que o atendimento de emergência é, muitas vezes, o

primeiro ponto de contato com o sistema de atenção à saúde, e recorrem a categorias estabelecidas para essa otimização. Os profissionais da área médica concentram-se na melhoria do diagnóstico e atendimento: focados nos dados coletados por sensores corporais e de unidades de terapia intensiva, almejam a ampliação de sua compreensão das patologias em conjunto com o histórico do paciente registrado em prontuários eletrônicos e com dados das ômicas: genômica, proteômica e metabolômica, por exemplo, para personalização dos tratamentos (Che *et al.*, 2016; Nemati *et al.*, 2018; Taylor *et al.*, 2016). A convergência é reconhecida como uma tendência, mas é interpretada de forma diversa pelos autores das duas linhas: ao mesmo tempo em que os artigos de medicina reconhecem a necessidade de avançar no conhecimento científico para fazer uso da personalização, eles a citam como objetivo e possibilidade imediata para alguns pacientes, em um aparente paradoxo, decorrente do reconhecimento de que alguns grupos étnicos e algumas patologias ainda carecem de registros de dados de saúde e de estudos mais aprofundados para elucidação de seus fatores. Os artigos de gestão de negócios de atenção à saúde consideram a personalização um ponto de chegada mais distante, mas defendem o uso imediato das tecnologias para otimização de seus processos, a partir do conhecimento consolidado.

A abordagem científica se encontra no suporte de ambas as lógicas, mas com aplicações diferentes: enquanto na abordagem dos artigos orientados pela personalização o foco é no desenvolvimento do conhecimento diagnóstico e terapêutico, com a busca de novos fatores, novos indicadores mais precisos e novos procedimentos mais assertivos para a cura, além da expansão das etnias e patologias registradas e analisadas, na abordagem da padronização esse foco se desloca para a aplicação do conhecimento científico atual e o refinamento dos processos baseados nesse conhecimento, na forma de categorizações cada vez mais detalhadas, que permitam o atendimento mais efetivo na atenção à saúde. Em comum, a análise auxiliada por algoritmos que permitem ampliar a capacidade de atuação dos profissionais e a compreensão de que o objetivo final é o de personalizar o atendimento a partir da maior quantidade possível de dados coletados e do maior conhecimento sobre suas correlações com os objetivos clínicos desejados.

Restringir a avaliação a apenas duas áreas, a de gestão de negócios e a medicina, e a 10 artigos de cada envolvendo o uso de Aprendizado de Máquina, constituiu uma

limitação que poderá ser superada com a ampliação para outras áreas como a de enfermagem, bem como a ampliação do número de artigos e do número de termos, incluindo por exemplo, Redes Neurais e *Big Data*. Outra possibilidade teórica surge da análise dos termos mais utilizados em cada agrupamento de artigos: a interpretação de itens como custo, segurança do paciente, qualidade de dados e qualidade dos resultados poderiam, a partir da categorização dos termos, ser mais bem avaliados em suas relações de ocorrência.

AGRADECIMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001

REFERÊNCIAS

ALTMAN, R. B. Translational Bioinformatics: Linking the Molecular World to the Clinical World. *Clinical Pharmacology & Therapeutics*, [s. l.], v. 91, n. 6, p. 994–1000, 2012. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1038/clpt.2012.49>. Acesso em: 16 abr. 2024.

ARCHENAA, J.; ANITA, E. A.Mary. A Survey of Big Data Analytics in Healthcare and Government. *Procedia Computer Science*, [s. l.], v. 50, p. 408–413, 2015. Disponível em: <https://doi.org/10.1016/j.procs.2015.04.021>. Acesso em: 16 abr. 2024.

BATES, David W. *et al.* Big data in health care: Using analytics to identify and manage high-risk and high-cost patients. *Health Affairs*, [s. l.], v. 33, n. 7, p. 1123–1131, 2014.

BERTSIMAS, Dimitris *et al.* An Analytics Approach to Designing Combination Chemotherapy Regimens for Cancer. *Management Science*, [s. l.], v. 62, n. 5, p. 1511–1531, 2016. Disponível em: <https://pubsonline.informs.org/doi/abs/10.1287/mnsc.2015.2363>. Acesso em: 16 abr. 2024.

BROWNLEE, Shannon *et al.* Evidence for overuse of medical services around the world. *The Lancet*, [s. l.], v. 390, n. 10090, p. 156–168, 2017. Disponível em: <http://www.thelancet.com/article/S0140673616325855/fulltext>. Acesso em: 16 abr. 2024.

BURLINA, Philippe M. *et al.* Automated Grading of Age-Related Macular Degeneration From Color Fundus Images Using Deep Convolutional Neural Networks. *JAMA Ophthalmology*, [s. l.], v. 135, n. 11, p. 1170–1176, 2017. Disponível em: <https://jamanetwork.com/journals/jamaophthalmology/fullarticle/2654969>. Acesso em: 16 abr. 2024.

CHE, Zhengping *et al.* Interpretable Deep Models for ICU Outcome Prediction. *AMIA Annual Symposium Proceedings*, [s. l.], v. 2016, p. 371, 2016. Disponível em: </pmc/articles/PMC5333206/>. Acesso em: 6 abr. 2024.

CHEN, Jiajia *et al.* Translational biomedical informatics in the cloud: Present and future. *BioMed Research International*, [s. l.], v. 2013, 2013. Disponível em: Acesso em: 25 abr. 2024.

CHOI, Edward *et al.* Using recurrent neural network models for early detection of heart failure onset. *J. Am. Med. Inform. Assoc.*, [s. l.], v. 24, n. 2, p. 361–370, 2017.

CHOUGRAD, Hiba; ZOUAKI, Hamid; ALHEYANE, Omar. Deep Convolutional Neural Networks for breast cancer screening. *Computer Methods and Programs in Biomedicine*, [s. l.], v. 157, p. 19–30, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0169260717301451>.

COHEN, I. Glenn *et al.* The legal and ethical concerns that arise from using complex predictive analytics in health care. *Health Affairs*, [s. l.], v. 33, n. 7, p. 1139–1147, 2014.

DEO, Rahul C. Machine Learning in Medicine. *Circulation*, [s. l.], v. 132, n. 20, p. 1920–1930, 2015. Disponível em: <https://www.ahajournals.org/doi/abs/10.1161/CIRCULATIONAHA.115.001593>. Acesso em: 5 abr. 2024.

DUNN, M. B.; JONES, C. Institutional Logic, and Institutional Pluralism. *Administrative science quarterly*, [s. l.], v. 55, n. 1, p. 114–149, 2010.

EXWORTHY, Mark. The Iron Cage and the Gaze: Interpreting Medical Control in the English Health System. *Professions and Professionalism*, [s. l.], v. 5, n. 1, 2015.

FORSTER, Rudolf; GABE, Jonathan. Voice or choice? Patient and public involvement in the national health service in England under new labour. [S. l.: s. n.], 2008.

FRIEDLAND, R.; ALFORD, R. Bringing Society Back In - Symbols, Practices and Institutional Contradictions. In: POWELL, W.; DIMAGGIO, P. (org.). *The New Institutionalism in Organizational Analysis*. [S. l.]: University Of Chicago Press, 1991. p. 232–263.

FRYBACK, Dennis G.; THORNBURY, John R. The efficacy of diagnostic imaging. *Medical Decision Making*, [s. l.], v. 11, n. 2, p. 88–94, 1991.

GLASZIOU, Paul *et al.* Evidence for underuse of effective medical services around the world. *The Lancet*, [s. l.], v. 390, n. 10090, p. 169–177, 2017. Disponível em: <http://www.thelancet.com/article/S0140673616309461/fulltext>. Acesso em: 16 abr. 2024.

GÓMEZ-VALLEJO, H. J. *et al.* A case-based reasoning system for aiding detection and classification of nosocomial infections. *Decision Support Systems*, [s. l.], v. 84, p. 104–116, 2016. Disponível em: Acesso em: 16 abr. 2024.

GREENWOOD, Royston *et al.* The multiplicity of institutional logics and the heterogeneity of organizational responses. *Organization Science*, [s. l.], v. 21, n. 2, p. 521–539, 2010.

GULSHAN, Varun *et al.* Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, [s. l.], v. 316, n. 22, p. 2402–2410, 2016. Disponível em: <https://jamanetwork.com/journals/jama/fullarticle/2588763>. Acesso em: 16 abr. 2024.

HELM, Jonathan E. *et al.* Reducing Hospital Readmissions by Integrating Empirical Prediction with Resource Optimization. *Production and Operations Management*, [s. l.],

v. 25, n. 2, p. 233–257, 2016. Disponível em: <https://journals.sagepub.com/doi/10.1111/poms.12377>. Acesso em: 16 abr. 2024.

HERLAND, Matthew; KHOSHGOFTAAR, Taghi M.; WALD, Randall. A review of data mining using big data in health informatics. *Journal of Big Data*, [s. l.], v. 1, n. 1, p. 1–35, 2014. Disponível em: <https://journalofbigdata.springeropen.com/articles/10.1186/2196-1115-1-2>. Acesso em: 5 abr. 2024.

HOPP, Wallace J.; LI, Jun; WANG, Guihua. Big Data and the Precision Medicine Revolution. *Production and Operations Management*, [s. l.], v. 27, n. 9, p. 1647–1664, 2018. Disponível em: <https://journals.sagepub.com/doi/10.1111/poms.12891>. Acesso em: 16 abr. 2024.

HUPPERTZ, John W.; OTTO, Peter. Predicting HCAHPS scores from hospitals' social media pages: A sentiment analysis. *Health Care Management Review*, [s. l.], v. 43, n. 4, p. 359–367, 2018. Disponível em: <https://journals.lww.com/00004010-201810000-00010>.

JIANG, Shancheng *et al.* An integrated machine learning framework for hospital readmission prediction. *Knowledge-Based Systems*, [s. l.], v. 146, p. 73–90, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0950705118300443>.

JIANG, Fei *et al.* Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, [s. l.], v. 2, n. 4, p. 230–243, 2017.

JOHNSON, K.W. *et al.* Artificial Intelligence in Cardiology. *Journal of the American College of Cardiology*, [s. l.], v. 71, n. 23, p. 2668–2679, 2018.

KITCHENER, Martin. Mobilizing the Logic of Managerialism in Professional Fields: The Case of Academic Health Centre Mergers. *Organization Studies*, [s. l.], v. 23, n. 3, p. 391–420, 2002. Disponível em: <http://journals.sagepub.com/doi/10.1177/0170840602233004>.

KVANCZ, David A.; SREDZINSKI, Marcus N. Predictive Analytics: A Case Study in Machine-Learning and Claims Databases. [S. l.], 2016. Disponível em: <https://www.pharmacytimes.com/view/predictive-analytics-a-case-study-in-machinelearning-and-claims-databases>. Acesso em: 16 abr. 2024.

LEE, Eva K. *et al.* Transforming hospital emergency department workflow and patient care. *Interfaces*, [s. l.], v. 45, n. 1, p. 58–82, 2015.

MANNION, Russell; EXWORTHY, Mark. (Re) Making the Procrustean Bed? Standardization and Customization as Competing Logics in Healthcare. *International Journal of Health Policy and Management*, [s. l.], v. 6, n. 6, p. 301–304, 2017. Disponível em: http://ijhpm.com/article_3340.html.

MCDONALD, Ruth; WARING, Justin; HARRISON, Stephen. Rules, safety and the narrativisation of identity: a hospital operating theatre case study. *Sociology of Health & Illness*, [s. l.], v. 28, n. 2, p. 178–202, 2006. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/j.1467-9566.2006.00487.x>. Acesso em: 16 abr. 2024.

MIOTTO, Riccardo *et al.* Deep Patient: An Unsupervised Representation to Predict the Future of Patients from the Electronic Health Records. *Scientific Reports* 2016 6:1, [s. l.], v. 6, n. 1, p. 1–10, 2016. Disponível em: <https://www.nature.com/articles/srep26094>. Acesso em: 16 abr. 2024.

MITCHELL, T M. *Machine Learning*. [S. l.]: McGraw-Hill, 1997. (McGraw-Hill International Editions). Disponível em: <https://books.google.com.br/books?id=EoYBngEACAAJ>.

MITTELSTADT, Brent Daniel *et al.* The ethics of algorithms: Mapping the debate. *Big Data and Society*, [s. l.], v. 3, n. 2, 2016. Disponível em: <https://journals.sagepub.com/doi/10.1177/2053951716679679>. Acesso em: 16 abr. 2024.

MOHR, David C.; ZHANG, Mi; SCHUELLER, Stephen M. Personal Sensing: Understanding Mental Health Using Ubiquitous Sensors and Machine Learning. *Annual Review of Clinical Psychology*, [s. l.], v. 13, n. Volume 13, 2017, p. 23–47, 2017. Disponível em: <https://www.annualreviews.org/content/journals/10.1146/annurev-clinpsy-032816-044949>. Acesso em: 16 abr. 2024.

NASIR, Murtaza *et al.* A comparative data analytic approach to construct a risk trade-off for cardiac patients' re-admissions. *Industrial Management and Data Systems*, [s. l.], v. 119, n. 1, p. 189–209, 2019. Disponível em: Acesso em: 16 abr. 2024.

NEMATİ, Shamim *et al.* 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. Disponível em: <http://journals.lww.com/00003246-201804000-00010>.

PALANISAMY, Venketesh; THIRUNAVUKARASU, Ramkumar. Implications of big data analytics in developing healthcare frameworks – A review. *Journal of King Saud University - Computer and Information Sciences*, [s. l.], v. 31, n. 4, p. 415–425, 2019. Disponível em: Acesso em: 16 abr. 2024.

RAJESH, M.; SAIRAM, R. Big data and health care system using mlearning. *International Journal of Recent Technology and Engineering*, [s. l.], v. 8, n. 1, p. 208–210, 2019. Disponível em: <https://www.ijrte.org/portfolio-item/a00480581s219/>. Acesso em: 16 abr. 2024.

REAY, Trish; HININGS, C.R. Managing the Rivalry of Competing Institutional Logics. *Organization Studies*, [s. l.], v. 30, n. 6, p. 629–652, 2009. Disponível em: <http://journals.sagepub.com/doi/10.1177/0170840609104803>.

RICHTER, Aaron N.; KHOSHGOFTAAR, Taghi M. Sample size determination for biomedical big data with limited labels. *Network Modeling Analysis in Health Informatics and Bioinformatics*, [s. l.], v. 9, n. 1, p. 1–13, 2020. Disponível em: <https://link.springer.com/article/10.1007/s13721-020-0218-0>. Acesso em: 16 abr. 2024.

SCHMIDHUBER, Jürgen. *Deep Learning in neural networks: An overview*. [S. l.]: Elsevier Ltd, 2015.

SCOTT, W. Richard *et al.* *Institutional Change and Healthcare Organizations: From Professional Dominance to Managed Care*. Chicago: University of Chicago Press, 2000.

SCOTT, W. Richard. Lords of the dance: Professionals as institutional agents. *Organization Studies*, [s. l.], v. 29, n. 2, p. 219–238, 2008.

SHOMORONY, Ilan *et al.* Unsupervised integration of multimodal dataset identifies novel signatures of health and disease. *bioRxiv*, [s. l.], p. 432641, 2018. Disponível em: <https://www.biorxiv.org/content/10.1101/432641v1>. Acesso em: 22 abr. 2024.

SMITH, Mark D. (Physician) *et al.* *Best Care at Lower Cost*. Washington, D.C.: National Academies Press, 2013. Disponível em: <http://www.nap.edu/catalog/13444>.

STROME, Trevor L. *Healthcare Analytics for Quality and Performance Improvement*. [S. l.]: Wiley, 2013.

TAI-SEALE, Ming *et al.* Electronic health record logs indicate that physicians split time evenly between seeing patients and desktop medicine. *Health Affairs*, [s. l.], v. 36, n. 4, p. 655–662, 2017.

TAYLOR, R. Andrew *et al.* Prediction of In-hospital Mortality in Emergency Department Patients With Sepsis: A Local Big Data–Driven, Machine Learning Approach. *Academic Emergency Medicine*, [s. l.], v. 23, n. 3, p. 269–278, 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/acem.12876>. Acesso em: 23 abr. 2024.

TENENBAUM, Jessica D.; SANSONE, Susanna Assunta; HAENDEL, Melissa. A sea of standards for omics data: Sink or swim?. *Journal of the American Medical Informatics Association*, [s. l.], v. 21, n. 2, p. 200–203, 2014.

THORNTON, Patricia H.; OCASIO, Willian; LOUNSBURY, Michael. *The Institutional Logics Perspective: A new approach to culture, structure and process*. [S. l.]: Oxford University Press, 2012.

TING, Daniel Shu Wei *et al.* Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations With Diabetes. *JAMA*, [s. l.], v. 318, n. 22, p. 2211–2223, 2017. Disponível em: <https://jamanetwork.com/journals/jama/fullarticle/2665775>. Acesso em: 25 abr. 2024.

TOPUZ, Kazim *et al.* Predicting graft survival among kidney transplant recipients: A Bayesian decision support model. *Decis. Support Syst.*, [s. l.], v. 106, p. 97–109, 2018.

TUNIS, Sean R.; STRYER, Daniel B.; CLANCY, Carolyn M. Practical Clinical Trials: Increasing the Value of Clinical Research for Decision Making in Clinical and Health Policy. *JAMA*, [s. l.], v. 290, n. 12, p. 1624–1632, 2003. Disponível em: <https://jamanetwork.com/journals/jama/fullarticle/197353>. Acesso em: 17 abr. 2024.

WALDORFF, Susanne Boch; MADSEN, Marie Henriette. Translating to Maintain Existing Practices: Micro-tactics in the implementation of a new management concept. *Organization Studies*, [s. l.], v. 44, n. 3, p. 427–450, 2023.

WALDORFF, Susanner Boch; REAY, Trish; GOODRICK, Elizabeth. A Tale of Two Countries How Different Constellations of Logics Impact Action. *Research in the Sociology of Organizations*, [s. l.], v. 39, p. 99–129, 2013. Disponível em: <https://www.researchgate.net/publication/259291815>. Acesso em: 16 out. 2021.

WANG, Yichuan *et al.* An integrated big data analytics-enabled transformation model: Application to health care. *Information & Management*, [s. l.], v. 55, n. 1, p. 64–79, 2018. Disponível em: Acesso em: 17 abr. 2024.

WARING, Justin *et al.* Healthcare quality and safety: a review of policy, practice and research. *Sociology of Health & Illness*, [s. l.], v. 38, n. 2, p. 198–215, 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/1467-9566.12391>. Acesso em: 22 abr. 2024.

WILEY, Laura K. *et al.* Harnessing next-generation informatics for personalizing medicine: a report from AMIA's 2014 Health Policy Invitational Meeting. *Journal of the American Medical Informatics Association*, [s. l.], v. 23, n. 2, p. 413–419, 2015. Disponível em: <https://dx.doi.org/10.1093/jamia/ocv111>. Acesso em: 22 abr. 2024.

YILDIRIM, Özal *et al.* Arrhythmia detection using deep convolutional neural network with long duration ECG signals. *Computers in Biology and Medicine*, [s. l.], v. 102, p. 411–420, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0010482518302713>.

ZOLBANIN, Hamed Majidi; DELEN, Dursun; HASSAN ZADEH, Amir. Predicting overall survivability in comorbidity of cancers: A data mining approach. *Decision Support Systems*, [s. l.], v. 74, p. 150–161, 2015. Disponível em: Acesso em: 23 abr. 2024.