

**REDES COMPLEXAS E INTELIGÊNCIA ARTIFICIAL NA SAÚDE: métodos de classificação aplicados ao diagnóstico e à gestão hospitalar**

**CAMILA DAMÁSIO**  
UNIVERSIDADE FEDERAL DE MINAS GERAIS (UFMG)

# REDES COMPLEXAS E INTELIGÊNCIA ARTIFICIAL NA SAÚDE: métodos de classificação aplicados ao diagnóstico e à gestão hospitalar

## 1 Introdução

O processo de digitalização na área da saúde tem modificado substancialmente a forma como os dados clínicos são gerados, armazenados, acessados e utilizados. A incorporação de prontuários eletrônicos, sistemas de monitoramento em tempo real, sensores corporais e dispositivos médicos conectados tem contribuído para a formação de um ecossistema informacional composto por dados volumosos, diversos, dinâmicos e com exigência de acurácia (ADENIYI *et al.*, 2024). Entre as tecnologias analíticas aplicadas ao processamento de dados em saúde, destaca-se a Inteligência Artificial (IA), com ênfase em abordagens baseadas na identificação de padrões e no aprendizado a partir de exemplos. Métodos supervisionados, não supervisionados e generativos têm apresentado desempenho relevante na classificação de riscos e na previsão de desfechos clínicos, como tempo de internação, mortalidade, reinternação em unidades de terapia intensiva e agravamento do estado clínico (RAJKOMAR *et al.*, 2018).

Paralelamente, a Teoria de Redes fornece uma estrutura matemática para compreender a dinâmica das relações nos sistemas de saúde. Representações gráficas em múltiplas camadas, com direcionalidade e variações temporais, ilustram desde fluxos de encaminhamento e contágios em ambientes hospitalares até interações medicamentosas. Indicadores como grau de conectividade, centralidade, comunidades e densidade de ligações permitem identificar unidades hospitalares influentes, segmentos de pacientes com características semelhantes e falhas estruturais, facilitando intervenções ágeis e direcionadas (BARABÁSI; PÓSFAL, 2016). Quando associadas a análises em rede e técnicas explicáveis, essas representações possibilitam previsões fundamentadas com evidências visuais que indicam quais elementos, como consultas, medicamentos ou exames, contribuíram para a decisão computacional (PARISOT *et al.*, 2018; SONG, 2024). Exemplos de aplicação incluem a segmentação de pacientes oncológicos para tratamento individualizado e o estudo de redes de ventilação cruzada para aprimorar medidas de controle de infecção hospitalar (LIAO, 2005).

A convergência entre IA e redes complexas inaugura uma nova direção na pesquisa em saúde, ao unir capacidade preditiva e explicabilidade, atributos essenciais em contextos regulados. No entanto, a construção de modelos escaláveis ainda enfrenta desafios. Estima-se que cerca de 80% do esforço analítico concentre-se no tratamento inicial dos dados. A variabilidade semântica dos prontuários eletrônicos dificulta a padronização de fluxos, e o uso de amostras limitadas acentua vieses com impacto direto na segurança do paciente (JOHNSON *et al.*, 2016). Estratégias de aprendizagem profunda e representações compactas têm mitigado parte dessas limitações, reduzindo a necessidade de engenharia manual. Ainda assim, alterações graduais nos dados e nos conceitos clínicos exigem monitoramento contínuo e retreinamento periódico dos modelos, para preservar sua acurácia em ambientes operacionais em constante evolução.

No contexto da gestão hospitalar, a integração entre IA e redes complexas tem contribuído para a reorganização de processos operacionais. Modelos preditivos de internação permitem que os centros de regulação antecipem a alocação de leitos diante do aumento da demanda. Métodos baseados em aprendizado por reforço têm sido empregados na elaboração de escalas de trabalho para equipes de enfermagem, considerando as exigências legais. Abordagens voltadas à otimização do fluxo de materiais ajustam o suprimento de insumos, reduzindo estoques ociosos e minimizando o risco de desabastecimento. Simulações computacionais de unidades de internação também têm sido utilizadas para testar cenários de movimentação de pacientes e avaliar estratégias de gestão antes de sua aplicação prática (TAVAKOLI *et al.*, 2022).

A medicina contemporânea enfrenta um paradoxo relacionado à produtividade. Apesar do aumento de investimentos e profissionais, os avanços nos resultados em saúde permanecem limitados (WOOLF; SCHOOMAKER, 2019). Esse descompasso evidencia falhas nos processos de diagnóstico, tratamento e organização do trabalho. Simultaneamente, o volume de informações gerado no ambiente clínico supera a capacidade de análise individual, exigindo sistemas que atuem como apoio cognitivo ao julgamento médico, sem substituí-lo (TOPOL, 2019). A integração entre conhecimento clínico e IA, contudo, demanda rotinas estruturadas, gestão de mudanças e capacitação das equipes para uso e interpretação de dados (SINGH; KUMAR, 2024).

A adoção dessas tecnologias também impõe desafios éticos e regulatórios, como decisões enviesadas por parte dos sistemas, preocupações com privacidade e a exigência de responsabilidade em novas regulamentações (OBERMEYER *et al.*, 2019). Ferramentas que permitem auditar decisões automatizadas, além de certificações de confiança, têm sido adotadas para demonstrar justiça e transparência. Estratégias como o treinamento conjunto de modelos entre instituições, com técnicas de preservação da identidade dos dados, vêm sendo testadas em redes hospitalares, possibilitando o desenvolvimento de sistemas seguros sem transferência de informações sensíveis (RIEKE *et al.*, 2020).

Diante do cenário atual, caracterizado pela convergência entre inovações tecnológicas e desafios de ordem ética, operacional e regulatória, torna-se necessário desenvolver soluções que integrem precisão analítica, utilidade clínica e viabilidade de aplicação. A combinação entre métodos de análise baseados em IA e estruturas provenientes da Teoria das Redes Complexas configura uma abordagem relevante para ampliar a capacidade de resposta dos sistemas de saúde, com potencial para aprimorar tanto a acurácia diagnóstica quanto a coordenação e a eficiência na gestão hospitalar.

Nesse contexto, surge a seguinte questão de pesquisa: como a integração de métodos de classificação baseados em Inteligência Artificial e modelagem de Redes Complexas pode auxiliar o diagnóstico médico, a definição de tratamentos e a gestão hospitalar de forma mais acurada e sistêmica?

Considerando a relevância do tema, que articula os métodos de classificação baseados em IA e a modelagem por Redes Complexas, este trabalho tem como objetivo geral analisar como a combinação entre essas abordagens pode contribuir para o aprimoramento do diagnóstico clínico, da escolha terapêutica e da gestão hospitalar. Essa integração representa uma oportunidade estratégica para lidar com a complexidade crescente dos dados clínicos, promovendo maior precisão analítica e eficiência operacional. No Brasil, onde o sistema de saúde é marcado por heterogeneidade regional, escassez de especialistas em determinadas áreas e fragmentação informacional, essa convergência entre IA e Teoria de Redes pode oferecer soluções mais adaptadas às necessidades locais, contribuindo para uma gestão mais equitativa.

A sinergia entre IA e redes complexas promete ganhos em acurácia diagnóstica, além de melhorias na coordenação de cuidados e no uso racional de recursos em saúde. Para alcançar esse objetivo, busca-se: identificar os principais algoritmos de classificação aplicados à saúde; mapear os tipos de redes complexas utilizados em sistemas clínicos e hospitalares; avaliar os impactos da integração entre IA e redes na acurácia diagnóstica e na predição de desfechos; discutir a contribuição das redes complexas na gestão de recursos, fluxos assistenciais e escalas de pessoal; e propor diretrizes para a implementação ética, segura e sustentável dessas tecnologias no ambiente hospitalar.

Diante do exposto, a combinação entre IA e redes complexas configura uma estratégia voltada à qualificação do cuidado em saúde e ao fortalecimento da gestão hospitalar. Ao explorar essa integração, busca-se aprofundar o entendimento sobre seu potencial de aplicação, com vistas a promover avanços que conciliem inovação tecnológica, eficiência operacional e responsabilidade ética no ambiente clínico.

## 2 Fundamentação Teórica

### 2.1 Integração da Teoria de Redes e IA na saúde

Os recentes avanços em IA e ciência de dados têm provocado mudanças significativas no campo da saúde, especialmente com a integração entre a IA e a Teoria de Redes. Essa convergência abre novos caminhos para a compreensão das complexidades dos dados clínicos e para o desenvolvimento de métodos de diagnóstico e tratamento mais precisos. A Teoria de Redes contribui diretamente para a explicabilidade dos modelos de IA ao permitir a visualização e análise das relações complexas entre dados clínicos, biomarcadores, comorbidades e outros elementos relevantes da trajetória dos pacientes. Essa abordagem auxilia os profissionais da saúde na interpretação das interações intrincadas dentro das redes de dados, favorecendo diagnósticos mais assertivos e planos terapêuticos personalizados (BIAN *et al.*, 2017).

Além disso, a análise de redes permite identificar padrões e relações ocultas nos dados, revelando conexões epidemiológicas, fatores de risco e possíveis caminhos de progressão de doenças. Com isso, fortalece-se o poder explicativo dos modelos de IA e amplia-se a capacidade dos profissionais em tomar decisões clínicas baseadas em evidências extraídas de grandes volumes de dados (CHING; HIMMELSTEIN, 2018). Essa aplicação é importante não apenas para fins diagnósticos e prognósticos, mas também para o monitoramento contínuo de pacientes, contribuindo para uma prática médica mais eficiente e orientada por dados (VALENTE, 2010).

O crescimento dessa abordagem tem sido impulsionado pelos avanços em hardware, bancos de dados estruturados e não estruturados, e pela evolução teórica da computação. A IA, enquanto ramo da ciência da computação que busca simular a inteligência humana, possui como um de seus principais subcampos o aprendizado de máquina (*Machine Learning* – ML), caracterizado pela capacidade de aprender com dados e aprimorar seu desempenho sem reprogramações contínuas. Dentro do ML, o aprendizado profundo (*Deep Learning*) destaca-se por operar com múltiplas camadas de análise e ser particularmente eficaz na identificação de padrões complexos em grandes conjuntos de dados (SHAFAT *et al.*, 2022).

Na prática médica, os modelos de IA são treinados com dados clínicos históricos e podem ser supervisionados ou não supervisionados. No aprendizado supervisionado, algoritmos como árvores de decisão (*Decision Trees* – DTs ou TDs), florestas aleatórias (*Random Forests* – RFs), máquinas de vetor de suporte (*support vector machines* – SVMs), bayes ingênuo (*Naive Bayes* – NB), regressão linear (*Linear Regression* – LR) e regressão logística (*Logistic Regression* – LogR) são amplamente utilizados, dada sua robustez na classificação médica e na previsão de desfechos clínicos (MOHAJERANI; SOTOUDEH, 2020). Por sua vez, o aprendizado não supervisionado, por meio de técnicas como *K-means*, agrupamento hierárquico, propagação de afinidade, modelagem de mistura gaussiana e mapas auto-organizados, permite identificar agrupamentos em dados médicos não rotulados, como subgrupos de pacientes com características clínicas semelhantes, contribuindo para a estratificação de risco e intervenções personalizadas (ATTYE *et al.*, 2019).

As Redes Neurais Artificiais (RNA), ou *Artificial Neural Networks* (ANNs), são uma classe de aprendizado de máquina que imita aproximadamente as redes neurais biológicas. A ANN utiliza uma série de camadas compostas de nós, incluindo camadas de entrada (*input layers*), camadas ocultas (*hidden layers*) e camadas de saída (*output layers*). Os nós (neurônios artificiais – *artificial neurons*) são interconectados dentro de uma camada e conectados entre camadas. A ANN é muito flexível para gerenciar vários tipos de dados. A rede neural padrão é denominada "*feedforward neural network* (FNN)", pois a hierarquia de dados flui apenas na direção direta (LEE *et al.*, 2017).

A Rede Neural Convolutacional (CNN – *Convolutional Neural Network*) é um subtipo de Rede Neural Artificial (RNA – *Artificial Neural Network*, ANN), que tem sido utilizada na classificação de imagens (*image classification*). Embora os modelos CNN sejam robustos na classificação de imagens, eles precisam de grandes conjuntos de dados para treinamento a fim de alcançar um desempenho aceitável. Esse desafio foi parcialmente resolvido pelas técnicas de aprendizagem por transferência (*transfer learning*). Na aprendizagem por transferência, os modelos CNN já treinados em grandes conjuntos de dados são ajustados (*fine-tuned*) em conjuntos de dados menores e podem alcançar um desempenho aceitável (LEE *et al.*, 2017).

Além das RNAs, outras técnicas de IA, como DTs, RFs e máquinas de reforço de gradiente (GBMs - *Gradient Boosting Machines*), também têm sido usadas com frequência na medicina. A TD é uma técnica de representação visual do processo de tomada de decisão. As TDs são capazes de classificar (dividir os dados em diferentes classes) e fazer regressão (prever um valor numérico). Os RFs consistem em um grande número de DTs individuais que trabalham juntos para obter melhor desempenho. Os GBMs iteram DTs preditivos fracos até que um limite preditivo relevante seja atingido. O GBM de reforço e o reforço de gradiente extremo (XGB) são um subtipo de GBM que usa as árvores de previsão fracas e combina muitas delas para produzir uma previsão mais robusta, permitindo o processamento paralelo de conjuntos de dados simultaneamente (LIVNE *et al.*, 2018; XIE *et al.*, 2019).

## 2.2 Detecção de comunidades e análise de interações medicamentosas com IA em redes de saúde

A detecção de comunidades identifica grupos de nós que compartilham características semelhantes nas redes. Esse método pode ser usado para identificar grupos de pacientes com características de doenças idênticas ou semelhantes em dados médicos (GIRVAN; NEWMAN, 2002). Quando combinada com os modelos da IA, essa técnica fornece aos profissionais da área médica *insights* sobre os padrões de início e propagação de doenças, ajudando no desenvolvimento de estratégias de prevenção e tratamento mais precisas.

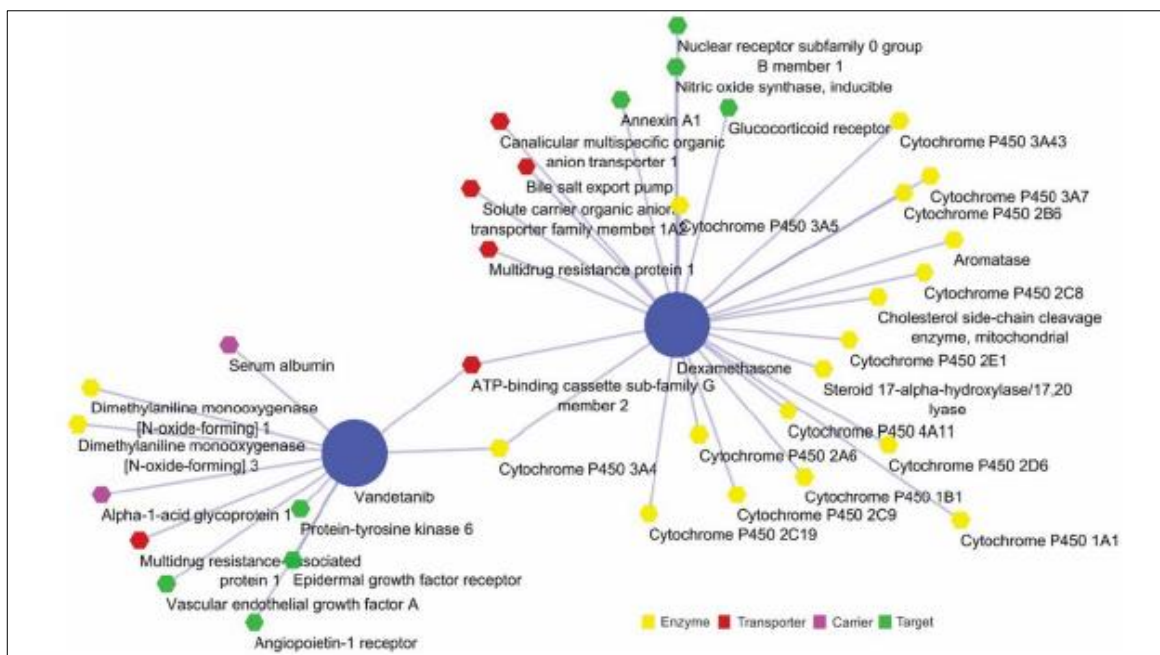
A incorporação de técnicas de detecção de comunidades em modelos de IA, especialmente na área da saúde, traz uma perspectiva inovadora para o atendimento ao paciente. Ao agrupar os pacientes em comunidades com base em características compartilhadas, esses modelos oferecem uma compreensão diferenciada dos padrões de doenças e das respostas dos pacientes aos tratamentos. Esse nível de granularidade é determinante na medicina personalizada, em que os planos de tratamento são adaptados a grupos específicos de pacientes ou até mesmo a pacientes individuais. A função da IA nesse contexto é tornar os complexos algoritmos por trás da detecção de comunidades transparentes e interpretáveis para os profissionais de saúde, garantindo que a base para agrupamentos e previsões esteja alinhada com o conhecimento e a lógica clínica (SONG, 2024).

O estudo de Shirazi *et al.*, (2020) oferece uma aplicação prática dessas técnicas na área da saúde. Sua pesquisa se concentra no uso da detecção de comunidades para identificar as verdadeiras especialidades dos médicos com base no histórico de prescrições. Esse novo aplicativo na área da saúde aproveita o *big data*, incluindo milhões de prescrições médicas, para categorizar os médicos em comunidades distintas. Esse método fornece evidências sobre padrões de prescrição e especialidades, oferecendo uma nova perspectiva para a compreensão das práticas dos profissionais de saúde. Essa abordagem demonstra o potencial da detecção de comunidades para aprimorar a compreensão de redes complexas de assistência médica. Quando integrados aos modelos IA, esses métodos podem levar a interpretações mais precisas e significativas dos dados de saúde, auxiliando nos processos de tomada de decisão e na formulação de políticas. A aplicação da detecção de comunidades nesse contexto ressalta a importância de técnicas sofisticadas de análise de dados para revelar padrões e relacionamentos ocultos na área médica (SHIRAZI *et al.*, 2020).

Complementarmente, os modelos de rede sobreposta analisam estruturas compostas por múltiplas redes interligadas, nas quais há compartilhamento de nós ou arestas entre diferentes camadas ou domínios. Essa abordagem permite a representação de sistemas complexos em que diferentes tipos de relações coexistem sobre o mesmo conjunto de entidades. Esse método é útil para identificar interações e possíveis efeitos colaterais entre medicamentos (KIVELÄ *et al.*, 2014).

Quando integrada à IA, essa abordagem permite que os profissionais da área médica prevejam com mais precisão várias interações e efeitos colaterais associados às prescrições de medicamentos, o que resulta em planos de tratamento ideais para os pacientes. Enquanto isso, Ferdousi, Safdari e Omid (2017), calcularam a similaridade de pares de medicamentos usando a abordagem Russel-Rao com base em medições de similaridade de 12 vetores binários para prever interações medicamentosas. A Figura 1 representa uma rede de previsão de interações medicamentosas (DDI – *drug-drug interactions*) baseada na similaridade biológica entre pares de fármacos, destacando os medicamentos Vandetanib e Dexametasona como nós centrais. Cada conexão (aresta) estabelece um vínculo entre esses medicamentos e seus respectivos alvos moleculares compartilhados, permitindo inferências sobre possíveis interações funcionais, metabólicas ou terapêuticas.

Figura 1 - Paradigmas de interações medicamentosas encontradas pelo método de similaridade



Fonte: Ferdousi; Safdari; Omid, 2017.

A estrutura gráfica evidencia que Dexametasona possui forte conexão com enzimas do metabolismo hepático, especialmente diversas isoformas do CYP450, o que sugere uma alta probabilidade de interação com outros fármacos metabolizados pelas mesmas vias. Já Vandetanib interage majoritariamente com proteínas sinalizadoras envolvidas em processos oncológicos, como o receptor do fator de crescimento epidérmico (EGFR) e o VEGF-A (FERDOUSI; SAFDARI; OMIDI, 2017).

Os elementos biológicos conectados aos fármacos são representados por nós coloridos, sendo diferenciados de acordo com sua função farmacológica na rede. Os nós amarelos correspondem às enzimas, como os diversos membros do sistema citocromo P450 (CYP450), importantes nos processos de metabolização de medicamentos. Já os nós vermelhos

representam os transportadores, como o ABCG2, responsáveis pelo transporte ativo de substâncias através das membranas celulares. Os nós roxos indicam os carreadores, a exemplo da serum albumin, que atuam no transporte de fármacos pela corrente sanguínea. Por fim, os nós verdes correspondem aos alvos terapêuticos, como receptores de glicocorticoides e fatores de crescimento, que são os pontos de ação dos medicamentos no organismo. Essa codificação por cores facilita a visualização e interpretação das interações moleculares e farmacológicas representadas na rede (FERDOUSI; SAFDARI; OMIDI, 2017).

### 2.3 IA e sistemas de saúde

A capacidade de prever desfechos clínicos-chave pode, teoricamente, tornar o uso de recursos hospitalares voltados aos cuidados paliativos mais eficiente e preciso. Por exemplo, caso um algoritmo fosse utilizado para estimar o risco de readmissão hospitalar de um paciente, risco esse que, de outra forma, passaria despercebido pelos critérios clínicos convencionais de alta, medidas preventivas poderiam ser adotadas para evitar a alta precoce e realocar adequadamente os recursos às questões subjacentes (WALSH *et al.*, 2017). Para um paciente gravemente enfermo, a identificação de uma probabilidade elevada de sobrevida em curto prazo pode auxiliar na definição de condutas médicas, como a realização de manobras de ressuscitação e a intubação orotraqueal para ventilação mecânica. Além disso, essa estimativa contribui para o processo de tomada de decisão compartilhada entre o paciente, sua família e a equipe médica, considerando os limites e os objetivos do cuidado (TOPOL, 2019).

Da mesma forma, a identificação de quais pacientes podem se beneficiar de cuidados paliativos, bem como daqueles sob risco de desenvolver condições graves como sepse ou choque séptico, pode ser facilitada por meio de ferramentas preditivas baseadas em IA. Utilizando dados provenientes de registros eletrônicos de saúde, algoritmos de aprendizado de máquina e de aprendizado profundo têm demonstrado capacidade de prever uma variedade de parâmetros clínicos relevantes, abrangendo desde a progressão da doença de Alzheimer até a estimativa de mortalidade, o que reforça o potencial dessas tecnologias como suporte à prática clínica baseada em dados (CHUNG *et al.*, 2018).

Em estudo retrospectivo recente, algoritmos de aprendizado por reforço foram aplicados a dois grandes conjuntos de dados para recomendar o uso de vasopressores, fluidos intravenosos e/ou fármacos, bem como para sugerir a dose ótima dessas intervenções em pacientes com sepse. O tratamento proposto pelo denominado “Clínico de IA” mostrou-se, em média, significativamente mais eficaz do que aquele escolhido por profissionais humanos. Tanto o tamanho das coortes analisadas quanto a variação nos valores da área sob a curva (AUC) reportados apresentaram significativa heterogeneidade, sendo que todos os estudos revisados possuem caráter retrospectivo e ainda carecem de validação em contextos clínicos reais (KOMOROWSKI *et al.*, 2018).

A visão computacional, conjunto de técnicas que permite a sistemas de IA interpretar dados visuais captados por sensores ambientais, tem recebido atenção crescente na área da saúde, sobretudo pelo seu potencial de aumentar a segurança do paciente. Diferentes aplicações já foram descritas: monitoramento automático da higiene das mãos de profissionais de saúde, contribuindo para a prevenção de infecções; vigilância contínua de pacientes críticos em unidades de terapia intensiva. No contexto da ventilação mecânica, um algoritmo de aprendizado por reforço alimentado por visão computacional demonstrou resultados promissores ao otimizar o processo de desmame, tradicionalmente conduzido de forma empírica e muitas vezes ineficiente (PRASAD *et al.*, 2017).

Paralelamente, iniciativas de digitalização intraoperatória buscam integrar múltiplas fontes de dados em tempo real. Entre elas destacam-se: a análise, por visão computacional, da dinâmica de equipes e equipamentos no campo cirúrgico; a geração de imagens anatômicas de alta resolução processadas por IA durante o ato operatório; e a consolidação de informações

pré-operatórias abrangentes, histórico clínico, exames laboratoriais e estudos de imagem para apoiar as decisões do cirurgião. Procedimentos microcirúrgicos de elevada complexidade, como intervenções intraoculares, já são realizados com suporte de sistemas de IA que ampliam a precisão e reduzem o tremor humano (GEHLBACH, 2018).

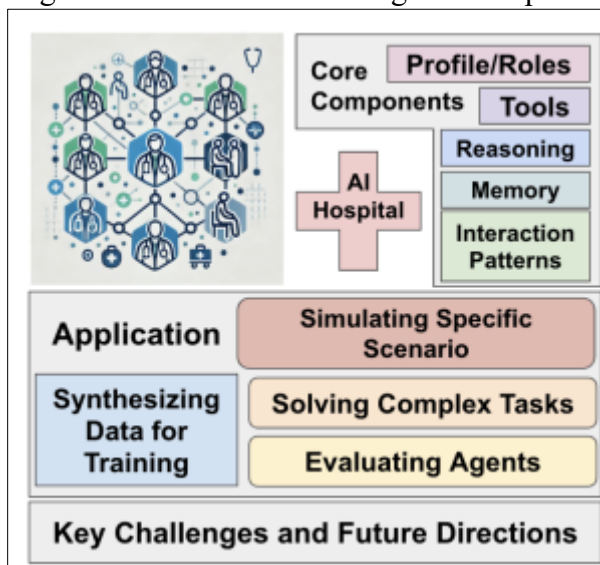
No domínio da radioterapia, algoritmos de aprendizado profundo têm sido empregados para reconstrução de imagens, permitindo reduções substanciais tanto na dose de radiação quanto no tempo de aquisição. Complementarmente, redes adversariais generativas vêm aprimorando a qualidade de exames de imagem médica, iniciativa que, quando adotada, tende a reforçar a segurança do paciente, otimizar fluxos de trabalho e diminuir custos assistenciais (ZHU *et al.*, 2018).

#### 2.4 IA e gestão hospitalar

A gestão hospitalar exige respostas rápidas e assertivas frente ao aumento da complexidade dos atendimentos, escassez de recursos e imprevisibilidade da demanda por serviços de saúde. No que diz respeito ao gerenciamento de leitos, a má alocação compromete a fluidez do atendimento e impacta negativamente os indicadores assistenciais. Estudos apontam que taxas de ocupação acima de 85% aumentam significativamente o tempo de espera nas emergências e os riscos à segurança dos pacientes. Durante a pandemia de COVID-19, muitos hospitais operaram com taxas superiores a 90%, agravando os atrasos e a sobrecarga dos profissionais de saúde. Sistemas tradicionais de rastreamento de leitos, que dependem de registros manuais e não se integram aos prontuários eletrônicos (EHRs), têm se mostrado insuficientes para lidar com essa complexidade (O'DOWD, 2021).

Conforme ilustrado na Figura 2, a adoção de sistemas de IA na gestão hospitalar envolve a articulação de componentes, como perfis de agentes, ferramentas, padrões de interação e memória com aplicações voltadas à resolução de tarefas complexas e suporte à tomada de decisão.

Figura 2 - Estrutura da IA na gestão hospitalar



Fonte: YAO; YU, 2025.

Por isso, o uso de IA para prever admissões, tempo de internação e altas, com base em dados estruturados (idade, sinais vitais, sexo) e não estruturados (notas clínicas), tem demonstrado resultados promissores. Instituições como o Hospital Johns Hopkins e o Humber River Hospital vêm empregando algoritmos preditivos para otimizar a alocação de leitos e

reduzir atrasos em transferências, gerando maior disponibilidade para casos complexos e críticos (LEE; YOON, 2021).

Um desafio recorrente na administração hospitalar é o planejamento de escalas médicas, especialmente em setores de alta pressão como UTIs e prontos-socorros. Atribuir turnos de forma justa e eficiente, conciliando a cobertura assistencial com as necessidades de descanso, treinamento e satisfação profissional dos trabalhadores, é uma tarefa de elevada complexidade. Os métodos convencionais, baseados em planilhas ou auto agendamento, são demorados e sujeitos a erros, o que pode gerar lacunas de pessoal, sobrecarga de trabalho e queda na qualidade do atendimento (MALIK; SOLAIMAN, 2024).

Soluções baseadas em IA permitem criar escalas otimizadas por meio de módulos de aprendizado de máquina e algoritmos de otimização que consideram tanto restrições rígidas (por exemplo, número mínimo de profissionais por turno ou presença obrigatória de especialistas) quanto preferências individuais dos profissionais. Tais soluções, como as adotadas por hospitais que aplicaram sistemas *open-source* de escalonamento automático, melhoraram a distribuição das cargas de trabalho, reduziram custos operacionais e aumentaram a satisfação das equipes (GALLOWAY *et al.*, 2022).

Além disso, a IA tem revolucionado o Suporte à Decisão Clínica (CDS), especialmente em contextos que envolvem grandes volumes de dados e decisões sensíveis ao tempo. Ferramentas de CDS assistidas por IA ajudam médicos a tomar decisões mais precisas ao oferecer informações clínicas personalizadas e oportunas. Aplicações vão desde a melhoria da codificação diagnóstica até sistemas de triagem inteligentes, como o Babylon Health, que analisa sintomas inseridos por usuários para oferecer recomendações clínicas com desempenho comparável ou superior ao de médicos humanos (RAZZAK *et al.*, 2018). Em ambientes de emergência pediátrica, algoritmos de IA já são utilizados para prever a necessidade de exames, como eletrocardiogramas ou ultrassonografias, ainda durante a triagem, otimizando o fluxo de atendimento e o uso de recursos laboratoriais. Essas soluções não apenas reduzem o tempo de espera e o custo operacional, como também aumentam a segurança do paciente ao evitar erros de priorização (MALIK; SOLAIMAN, 2024).

A implementação da IA na gestão hospitalar, portanto, representa uma inovação com potencial disruptivo. Quando aplicada de forma ética, responsável e baseada em dados de qualidade, a IA pode melhorar significativamente os indicadores de desempenho hospitalar, ampliar o acesso ao cuidado e fortalecer a tomada de decisão baseada em evidências. No entanto, seus benefícios dependem de uma infraestrutura completa de dados, da integração com sistemas legados e da capacitação contínua das equipes, além da necessidade de garantir a transparência dos algoritmos e o respeito à privacidade e autonomia dos pacientes (SOLAIMAN, COHEN, 2024).

### **3 Discussão**

A análise desenvolvida neste estudo evidencia que a convergência entre IA e Teoria de Redes oferece um arcabouço promissor para enfrentar desafios estruturais, assistenciais e operacionais nos sistemas de saúde contemporâneos. A partir da combinação entre técnicas de classificação, detecção de padrões, modelagem relacional e análise temporal, observa-se um avanço significativo na acurácia diagnóstica, na estratificação de riscos, na predição de desfechos clínicos e na eficiência da gestão hospitalar.

A literatura revisada corrobora o potencial da IA para identificar padrões clínicos complexos que escapam à análise humana tradicional, especialmente em ambientes marcados pela sobrecarga informacional, como unidades de terapia intensiva (JOHNSON *et al.*, 2016; KOMOROWSKI *et al.*, 2018). No entanto, é na interface com a Teoria de Redes que se observa um ganho em explicabilidade e aplicabilidade clínica. A representação visual das relações entre

pacientes, medicamentos, serviços e eventos clínicos confere maior interpretabilidade aos modelos, contribuindo para sua aceitação ética, regulatória e operacional (OBERMEYER *et al.*, 2019; SONG, 2024). Essa característica é particularmente relevante no contexto brasileiro, em que decisões clínicas muitas vezes precisam ser justificadas perante sistemas públicos de controle, como o Sistema Nacional de Auditoria do SUS (BRASIL, 2020), e diante das limitações de recursos humanos e tecnológicos.

A detecção de comunidades em redes clínicas permite identificar subgrupos de pacientes com características semelhantes, possibilitando uma personalização mais refinada de condutas terapêuticas e estratégias de prevenção (GIRVAN; NEWMAN, 2002; SHIRAZI *et al.*, 2020). Da mesma forma, a análise de interações medicamentosas em redes sobrepostas permite antecipar eventos adversos e ajustar protocolos farmacológicos com base em dados reais (FERDOUSI; SAFDARI; OMIDI, 2017). Essas aplicações reforçam o papel da modelagem em rede como ferramenta de suporte à decisão clínica com base em evidências relacionais e contextuais. Em sistemas de saúde de grande escala e heterogeneidade, como o brasileiro, esse tipo de abordagem pode ser essencial para apoiar a atenção primária em regiões remotas, com escassez de especialistas (PAIM, 2009), oferecendo mecanismos de triagem e estratificação de risco mais precisos.

No campo da gestão hospitalar, a integração entre algoritmos preditivos e dados estruturados e não estruturados tem demonstrado impactos positivos na alocação de recursos, na otimização de fluxos assistenciais e na elaboração de escalas de trabalho (LEE; YOON, 2021; GALLOWAY *et al.*, 2022). A capacidade da IA de antecipar internações, prever tempo de permanência e apoiar a triagem clínica fortalece a governança hospitalar baseada em dados e contribui para a racionalização de custos operacionais, sem comprometer a qualidade do cuidado. No Brasil, hospitais públicos de referência e instituições filantrópicas que operam com contratualização de metas poderiam se beneficiar diretamente dessas soluções para mitigar gargalos históricos, como a ocupação crítica de leitos, o tempo de espera elevado e a descontinuidade no cuidado. A experiência recente de hospitais como o Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo - HCFMUSP, que implementaram unidades de inteligência analítica e redes de prontuário eletrônico integradas, demonstra que há espaço para inovação mesmo em estruturas públicas, desde que haja apoio institucional, governança e capacitação (IEPS, 2022).

Por outro lado, a necessidade de retreinamento periódico dos modelos, em razão de alterações nos dados clínicos e nas práticas médicas, evidencia a volatilidade dos ambientes hospitalares (RAJKOMAR *et al.*, 2018). Essa exigência é ainda mais crítica no Brasil, onde a fragmentação dos sistemas de informação, a ausência de interoperabilidade entre plataformas estaduais e municipais e a baixa qualidade de registros clínicos digitalizados dificultam a continuidade e o aprendizado dos modelos (LIMA; VIEIRA, 2021). A padronização semântica dos dados e a interoperabilidade entre sistemas ainda representam gargalos técnicos significativos, limitando a escalabilidade das soluções. Além disso, aspectos éticos, como a auditabilidade dos algoritmos e a garantia de justiça nas decisões automatizadas, devem ser continuamente monitorados (RIEKE *et al.*, 2020; SINGH; KUMAR, 2023). Em um país marcado por desigualdades sociais e regionais, a introdução de algoritmos mal calibrados pode acentuar disparidades no acesso e na qualidade do cuidado, sobretudo se os modelos forem treinados com dados desbalanceados ou viesados.

Do ponto de vista metodológico, observa-se que muitas das aplicações analisadas baseiam-se em estudos retrospectivos, com baixa validação em ambientes clínicos reais. Essa limitação reforça a necessidade de pesquisas prospectivas e intervenções controladas para avaliar os impactos reais dessas tecnologias na prática assistencial. A adoção de políticas públicas voltadas à ciência de dados em saúde, como o fortalecimento do DataSUS (BRASIL, 2023), o investimento em redes integradas de pesquisa e a indução de parcerias público-

privadas, pode ser determinante para alavancar a implementação segura e escalável dessas soluções. Além disso, a adaptação das equipes à cultura orientada por dados e à leitura crítica dos *outputs* gerados por IA ainda requer investimentos em capacitação e gestão da mudança. No Brasil, essa necessidade se reflete em programas de educação permanente em saúde e na incorporação de competências digitais nos currículos de graduação e residência médica, como preconizado pelas Diretrizes Curriculares Nacionais (BRASIL, 2014).

A integração entre IA e redes complexas representa uma evolução no paradigma analítico da saúde, com efeitos positivos tanto na qualidade da assistência quanto na governança hospitalar. A literatura evidencia avanços robustos no nível técnico, mas também aponta a necessidade de atenção crítica quanto à sua implementação em contextos reais. As contribuições potenciais dessas tecnologias são inegáveis, desde que acompanhadas de estruturas institucionais, regulatórias e éticas compatíveis com sua complexidade e impacto. No Brasil, essa transformação exige não apenas inovação tecnológica, mas também compromisso com a equidade, com a qualificação dos dados e com o fortalecimento das capacidades locais de análise, governança e avaliação contínua.

#### **4 Conclusão**

Este estudo permitiu evidenciar que a integração entre Inteligência Artificial e Teoria das Redes Complexas constitui uma abordagem tecnicamente promissora e conceitualmente robusta para enfrentar os múltiplos desafios enfrentados pelos sistemas de saúde. Ao combinar a capacidade preditiva de algoritmos de aprendizado com a modelagem relacional própria das redes, observa-se um avanço significativo na acurácia diagnóstica, na predição de desfechos clínicos, na estratificação de riscos e na otimização da gestão hospitalar. A aplicabilidade dessas soluções ultrapassa o campo experimental, demonstrando potencial real de apoio à decisão clínica e à governança hospitalar baseada em dados.

Contudo, a efetividade dessas tecnologias depende de condições estruturais que garantam a qualidade dos dados, a interoperabilidade dos sistemas e a capacitação contínua das equipes. Em países com sistemas de saúde heterogêneos, como o Brasil, a implementação segura e equitativa dessas inovações exige o enfrentamento de barreiras como a fragmentação informacional, a escassez de infraestrutura digital e as desigualdades regionais de acesso a tecnologias e especialistas. A experiência de instituições brasileiras que já vêm adotando modelos de inteligência analítica reforça a viabilidade dessas soluções, desde que sustentadas por políticas públicas consistentes, governança interinstitucional e investimento em formação técnico-científica.

Do ponto de vista científico, este estudo contribui para consolidar um campo emergente de interseção entre Inteligência Artificial e Teoria das Redes na saúde, apresentando um arcabouço conceitual e aplicado que pode servir de referência para futuras investigações. A análise integrada das abordagens de classificação supervisionada e não supervisionada, aliada à modelagem de redes complexas, oferece um caminho metodológico relevante para pesquisas orientadas à explicabilidade dos modelos, especialmente em contextos de alta criticidade, como unidades hospitalares. Ao articular fundamentos teóricos com aplicações práticas validadas em estudos internacionais e nacionais, o trabalho amplia a base de conhecimento disponível para pesquisadores, gestores e profissionais clínicos interessados em inovação baseada em evidências.

Em termos institucionais, os resultados aqui sistematizados indicam que a adoção combinada dessas tecnologias pode contribuir para um modelo de gestão hospitalar mais preditivo, integrado e responsivo. Hospitais públicos e privados que enfrentam limitações operacionais, como indisponibilidade de leitos, filas de espera prolongadas e escassez de especialistas, podem se beneficiar de sistemas baseados em IA e redes complexas para otimizar

fluxos, priorizar atendimentos e apoiar a tomada de decisão em tempo real. Além disso, a transparência proporcionada pela visualização em rede pode auxiliar no cumprimento de exigências legais e na prestação de contas junto a órgãos reguladores e financiadores, promovendo maior confiança na adoção de tecnologias assistivas.

Finalmente, em termos de impacto social e sistêmico, a proposta investigada contribui para o fortalecimento da equidade em saúde, ao sugerir soluções adaptáveis às diferentes realidades regionais do Brasil. A capacidade de detectar padrões a partir de dados locais e de ajustar algoritmos às especificidades epidemiológicas e estruturais de cada território amplia as possibilidades de oferecer cuidado de qualidade mesmo em contextos de baixa densidade tecnológica. Ao reconhecer a centralidade da governança, da ética e da justiça algorítmica, este estudo reforça a necessidade de um ecossistema de inovação comprometido com o bem público, que coloque a inteligência computacional a serviço de um sistema de saúde mais resolutivo, acessível e sustentável.

## Referências

- ADENIYI, A. O.; AROWOOGUN, J. O.; CHIDI, R.; OKOLO, C. A.; BABAWARUN, O. The impact of electronic health records on patient care and outcomes: A comprehensive review. **World Journal of Advanced Research and Reviews**, v. 21, n. 2, p. 1446-1455, 2024.
- ATTYE, A.; OGNARD, J.; ROUSSEAU, F.; SALEM, D. B. Artificial neuroradiology: Between human and artificial networks of neurons? **Journal of Neuroradiology**, 2019, 46.5: 279-280.
- BARABÁSI, A. L.; PÓSFAL, M. **Network Science**. United Kingdom: Cambridge University Press, 2016. 456 p.
- BIAN, L.; LESLIE, S. J.; CIMPIAN, A. Gender stereotypes about intellectual ability emerge early and influence children's interests. **Science**, v. 355, n. 6323, p. 389-391, 2017.
- BRASIL. Ministério da Educação. **Resolução CNE/CES nº 3, de 20 de junho de 2014**. Institui Diretrizes Curriculares Nacionais dos Cursos de Graduação da Área da Saúde. Diário Oficial da União, Brasília, 23 jun. 2014. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-n-3-de-20-de-junho-de-2014-23113502>. Acesso em: 16 jul. 2025.
- BRASIL. Ministério da Saúde. **Sistema Nacional de Auditoria do SUS**. Brasília: MS, 2020. Disponível em: <https://www.gov.br/saude/sna>. Acesso em: 16 jul. 2025.
- BRASIL. Ministério da Saúde. **Departamento de Informática do SUS (DATASUS)**. 2023. Disponível em: <https://datasus.saude.gov.br/>. Acesso em: 16 jul. 2025.
- CHING, T.; HIMMELSTEIN, D. S.; BEAULIEU-JONES, B. K.; KALININ, A. A.; DO, B. T.; WAY, G. P.; GREENE, C. S. Opportunities and obstacles for deep learning in biology and medicine. **Journal of the royal society interface**, v. 15, n. 141, p. 20170387, 2018.
- CHUNG, Y.; ADDINGTON, J.; BEARDEN, C. E.; CADENHEAD, K.; CORNBLATT, B.; MATHALON, D. H.; NORTH AMERICAN PRODROME LONGITUDINAL STUDY (NAPLS) CONSORTIUM. Use of machine learning to determine deviance in neuroanatomical maturity associated with future psychosis in youths at clinically high risk. **JAMA psychiatry**, 2018, 75.9: 960-968.
- FERDOUSI, R.; SAFDARI, R.; OMIDI, Y. Computational prediction of drug-drug interactions based on drugs functional similarities. **Journal of biomedical informatics**, 2017, 70: 54-64.
- GALLOWAY, R.; ONYIRIUKA, O.; BROWN, A.; FITZPATRICK, C.; RICHARDSON, D. HealthRota: an evaluation of a digital rostering platform for managing hospital doctors' rotas and leave. **Future Healthcare Journal**, v. 9, n. 2, p. 166-170, 2022.
- GEHLBACH, P. L. Robotic surgery for the eye. **Nature biomedical engineering**, 2018, 2.9: 627-628.

GIRVAN, M.; NEWMAN, M. E.J. Community structure in social and biological networks. **Proceedings of the national academy of sciences**, 2002, 99.12: 7821-7826.

IEPS – INSTITUTO DE ESTUDOS PARA POLÍTICAS DE SAÚDE. **Inteligência Artificial e Big Data no HCFMUSP: o modelo InovaHC**. 2022. Disponível em: <https://ieps.org.br/>. Acesso em: 16 jul. 2025.

JOHNSON, A. E.; GHASSEMI, M. M.; NEMATI, S.; NIEHAUS, K. E.; CLIFTON, D. A.; CLIFFORD, G. D. Machine learning and decision support in critical care. **Proceedings of the IEEE**, 2016, 104.2: 444-466.

KIVELÄ, M.; ARENAS, A.; BARTHELEMY, M.; GLEESON, J. P.; MORENO, Y.; PORTER, M. A. Multilayer networks. **Journal of complex networks**, 2014, 2.3: 203-271.

KOMOROWSKI, M.; CELI, L. A.; BADAWI, O.; GORDON, A. C.; FAISAL, A. A. The artificial intelligence clinician learns optimal treatment strategies for sepsis in intensive care. **Nature medicine**, v. 24, n. 11, p. 1716-1720, 2018.

KUMAR, A.; MANI, V.; JAIN, V.; GUPTA, H.; VENKATESH, V. G. Managing healthcare supply chain through artificial intelligence (AI): A study of critical success factors. **Computers & Industrial Engineering**, v. 175, p. 108815, 2023.

LEE, E. J.; KIM, Y. H.; KIM, N.; KANG, D. W. Deep into the brain: artificial intelligence in stroke imaging. **Journal of stroke**, v. 19, n. 3, p. 277, 2017.

LEE, D.; YOON, S. N. Application of artificial intelligence-based technologies in the healthcare industry: Opportunities and challenges. **International journal of environmental research and public health**, v. 18, n. 1, p. 271, 2021.

LIAO, T. W. Clustering of time series data—a survey. **Pattern Recognition**, v. 38, n. 11, p. 1857–1874, 2005.

LIMA, D. L.; VIEIRA, F. S. **Sistemas de informação em saúde no Brasil: organização e desafios**. Brasília: IPEA, 2021. (Texto para Discussão, n. 2716). Disponível em: <https://www.ipea.gov.br/portal/publicacao/31506>. Acesso em: 16 jul. 2025.

LIVNE, M.; BOLDSSEN, J. K.; MIKKELSEN, I. K.; FIEBACH, J. B.; SOBESKY, J.; MOURIDSEN, K. Boosted tree model reforms multimodal magnetic resonance imaging infarct prediction in acute stroke. **Stroke**, 2018, 49.4: 912-918.

MALIK, A.; SOLAIMAN, B. AI in hospital administration and management: Ethical and legal implications. **Research handbook on health, AI and the Law**, p. 20-40, 2024.

MOHAJERANI, P.; SOTOUDEH, H. Essentials of AI Techniques: With a focus on medicine and healthcare, without math or coding. **Chicago. Independently published**, 2020.

OBBERMEYER, Z.; POWERS, B.; VOGELI, C.; MULLAINATHAN, S. Dissecting racial bias in an algorithm used to manage the health of populations. **Science**, v. 366, n. 6464, p. 447-453, 2019.

O'DOWD, A. Hospital bed occupancy rates in England reach dangerously high levels. **BMJ**, [s.l.], 2021.

PAIM, J. S. **O que é o SUS**. Rio de Janeiro: Editora Fiocruz, 2009.

PARISOT, S.; KTENA, S. I.; FERRANTE, E.; LEE, M.; GUERRERO, R.; GLOCKER, B.; RUECKERT, D. Disease prediction using graph convolutional networks: application to autism spectrum disorder and Alzheimer's disease. **Medical image analysis**, 2018, 48: 117-130.

PRASAD, N.; CHENG, L. F.; CHIVERS, C.; DRAUGELIS, M.; ENGELHARDT, B. E. A reinforcement learning approach to weaning of mechanical ventilation in intensive care units. **arXiv preprint**, arXiv:1704.06300, 2017.

RAJKOMAR, A.; OREN, E.; CHEN, K.; DAI, A. M.; HAJAJ, N.; HARDT, M.; DEAN, J. Scalable and accurate deep learning with electronic health records. **NPJ digital medicine**, v. 1, n. 1, p. 18, 2018.

RAZZAKI, S.; BAKER, A.; PEROV, Y.; MIDDLETON, K.; BAXTER, J.; MULLARKEY, D.; JOHRI, S. A comparative study of artificial intelligence and human doctors for the purpose of triage and diagnosis. **arXiv preprint arXiv:1806.10698**, 2018.

RIEKE, N.; HANCOX, J.; LI, W.; MILLETARI, F.; ROTH, H. R.; ALBARQOUNI, S.; CARDOSO, M. J. The future of digital health with federated learning. **NPJ digital medicine**, v. 3, n. 1, p. 119, 2020.

SHAFAT, O.; BERNSTOCK, J. D.; SHAFAT, A.; YEDAVALLI, V. S.; ELSAYED, G.; GUPTA, S.; SOTOUDEH, H. Leveraging artificial intelligence in ischemic stroke imaging. **Journal of Neuroradiology**, v. 49, n. 4, p. 343-351, 2022.

SHIRAZI, S.; ALBADVI, A.; AKHONDZADEH, E.; FARZADFAR, F.; TEIMOURPOUR, B. A new application of community detection for identifying the real specialty of physicians. **International journal of medical informatics**, 2020, 140: 104161.

SINGH, G.; KUMAR, J. Navigating the Future Through Adoption of AI in Healthcare: Legal and Ethical Perspectives. In: **AI Healthcare Applications and Security, Ethical, and Legal Considerations**. IGI Global, 2024. p. 240-260.

SOLAIMAN, B.; COHEN, I. G. Research Handbook on Health, AI and the Law: **RESEARCH HANDBOOKS IN HEALTH AND MEDICAL LAW**. 2024.

SONG, M. H. Transforming Patient Health Management: Insights from Explainable AI and Network Science Integration. **International Journal of Internet, Broadcasting and Communication**, 2024, 16.1: 307-313.

TAVAKOLI, M.; TAVAKKOLI-MOGHADDAM, R.; MESBAHI, R.; GHANAVATI-NEJAD, M.; TAJALLY, A. Simulation of the COVID-19 patient flow and investigation of the future patient arrival using a time-series prediction model: a real-case study. **Medical & biological engineering & computing**, v. 60, n. 4, p. 969-990, 2022.

TOPOL, E. J. High-performance medicine: the convergence of human and artificial intelligence. **Nature medicine**, v. 25, n. 1, p. 44-56, 2019.

VALENTE, T. W. **Social networks and health: Models, methods, and applications**. Oxford University Press, 2010.

WALSH, C. G.; RIBEIRO, J. D.; FRANKLIN, J. C. Predicting risk of suicide attempts over time through machine learning. **Clinical Psychological Science**, v. 5, p. 457-469, 2017.

WOOLF, S. H.; SCHOOMAKER, H. Life expectancy and mortality rates in the United States, 1959-2017. **Jama**, v. 322, n. 20, p. 1996-2016, 2019.

XIE, Y.; JIANG, B.; GONG, E.; LI, Y.; ZHU, G.; MICHEL, P.; ZAHARCHUK, G. Use of gradient boosting machine learning to predict patient outcome in acute ischemic stroke on the basis of imaging, demographic, and clinical information. **American Journal of Roentgenology**, 2019, 212.1: 44-51.

YAO, Z.; YU, H. A survey on LLM-based multi-agent AI hospital. **OSF Preprints**, 2025.

ZHU, B. LIU, J. Z.; CAULEY, S. F.; ROSEN, B. R.; ROSEN, M. S. Image reconstruction by domain-transform manifold learning. **Nature**, 2018, 555.7697: 487-492.