

TRAUMA, CIRURGIA E MEDICINA INTENSIVA

EDIÇÃO XII

Capítulo 37

USO DE INTELIGÊNCIA ARTIFICIAL PARA O CONTROLE DA ALIMENTAÇÃO DOS PACIENTES DA UTI

CARLA ROSANA GUILHERME SILVA²
ANTÔNIO CLARET RATTI FILHO¹
GABRIELA BLASIOLI DALPINO¹
MARIANA HOFF BIAZON¹
VINÍCIUS PIETRO RIBEIRO DAL ZOTTO¹
MIGUEL FRANCO ROSA DE SANTIS¹
AUGUSTO CAMPOS MATTOS¹
MARCELO TEO SILVA DOS SANTOS¹
IGOR OLIVEIRA DE FARIA¹
IAN TIOSSO JOAQUIM¹
MÁRCIO FILIPE FERNANDES DE SOUSA¹
MATHEUS SIMIONATTO PATRÃO¹

¹Discente - Faculdade de Medicina da Pontifícia Universidade Católica de Campinas.

²Docente - Faculdade de Medicina da Pontifícia Universidade Católica de Campinas.

Palavras-chave: Inteligência Artificial; Terapia Nutricional; Pacientes Críticos.

DOI

10.59290/2130906029

EP EDITORA
PASTEUR

INTRODUÇÃO

A inteligência artificial já é aplicada na saúde em diagnóstico, estratificação de risco, apoio à decisão e monitorização, e a UTI se tornou um dos cenários mais promissores para esse uso por concentrar grande volume de dados clínicos, laboratoriais e fisiológicos em tempo real (PINSKY *et al.*, 2024; MOAZEMI *et al.*, 2023; GRECO *et al.*, 2020). Na terapia intensiva, os usos mais estudados da IA incluem predição de mortalidade e complicações, detecção precoce de sepse, suporte à ventilação mecânica, avaliação prognóstica e recomendação terapêutica, embora a incorporação rotineira dessas ferramentas ainda seja limitada por problemas de validação externa, viés, integração ao fluxo clínico e interpretabilidade (BERKHOUT *et al.*, 2025; HONG *et al.*, 2022; MOAZEMI *et al.*, 2023).

A terapia nutricional é parte central do cuidado ao paciente crítico, porque a desnutrição e o catabolismo na UTI se associam a perda muscular, fraqueza adquirida, mais complicações, maior mortalidade e recuperação prolongada (STOIAN *et al.*, 2025; LEWIS *et al.*, 2018; FREDERIKS *et al.*, 2024). Estudos observacionais e metanálises indicam que oferta adequada de calorias e proteínas se associa a melhor desmame ventilatório, menor risco de morte e menor infecção, enquanto a via enteral tende a ser preferida quando o trato gastrointestinal é funcional, reservando-se a nutrição parenteral para situações em que a enteral é inviável ou insuficiente (MATĚJOVIČ *et al.*, 2022; CHA *et al.*, 2022; BAIK *et al.*, 2024).

Nesse contexto, a inteligência artificial pode ser relevante para o controle da alimentação parenteral ao integrar múltiplos dados do paciente, acompanhar mudanças metabólicas dinâmicas, estimar necessidades energéticas e proteicas e identificar precocemente pacientes

sob maior risco de receber suporte nutricional inadequado (STOIAN *et al.*, 2025; MOAZEMI *et al.*, 2023). Como o uso de IA especificamente na nutrição de pacientes críticos ainda é descrito como limitado, caro e pouco testado à beira leito, estudar essa relação é necessário para verificar se essas ferramentas realmente conseguem personalizar a nutrição parenteral e, com isso, melhorar prognóstico, tempo de internação e complicações na UTI (STOIAN *et al.*, 2025; BERKHOUT *et al.*, 2025).

MÉTODO

Trata-se de uma revisão integrativa, em que a pergunta norteadora utilizou o modelo PICO chegando a “O Uso de Inteligência artificial para o controle da alimentação parenteral de pacientes na UTI melhorar seu prognóstico?”. A base de dados utilizada foi PUBMED, foram utilizadas as palavras chave: (*Artificial Intelligence*) and (*intensive care unit*) and (*Parenteral Nutrition*) e coletados apenas artigos dos últimos 10 anos, em português inglês ou espanhol.

Os critérios de inclusão foram: Artigos experimentais em humanos, artigos observacionais, relatos de caso, série de casos, estudos retrospectivos, texto completo disponível. Os Critérios de exclusão foram: Revisões, estudo em animais, estudos realizados fora do período estabelecido ou em outras línguas, estudos que apenas o resumo está disponível, estudos que não abordam o tema. A busca encontrou 55 artigos e, após os critérios de seleção, restaram 6 artigos que foram submetidos à leitura minuciosa para a coleta de dados e a produção do capítulo.

RESULTADOS E DISCUSSÃO

O primeiro estudo consistiu em uma pesquisa retrospectiva multicêntrica realizada nos Estados Unidos da América, com o objetivo de

avaliar o desempenho de uma ferramenta de inteligência artificial para auxiliar médicos na prescrição de nutrição parenteral (PHONGPREECHA *et al.*, 2025). A inteligência artificial, denominada TPN2.0, foi desenvolvida utilizando uma rede neural variacional treinada com aproximadamente 14.000 variáveis extraídas de prontuários eletrônicos (PHONGPREECHA *et al.*, 2025). Posteriormente, foram analisadas 80.000 prescrições de nutrição parenteral total (NPT), permitindo a identificação de 15 padrões principais e a elaboração de 15 fórmulas padronizadas (PHONGPREECHA *et al.*, 2025).

Foram incluídos 9.330 pacientes, sendo 5.913 provenientes do serviço interno e 3.417 do serviço externo, todos recém-nascidos e lactentes que receberam NPT nos dois primeiros anos de vida (PHONGPREECHA *et al.*, 2025). A concordância entre as prescrições geradas pela TPN2.0 e as prescrições dos especialistas foi de 0,94 na validação interna e de 0,91 na validação externa, indicando elevada proximidade entre as recomendações da inteligência artificial e as decisões dos especialistas (PHONGPREECHA *et al.*, 2025).

As prescrições que apresentaram maior divergência em relação às recomendações da TPN2.0 estiveram associadas a maior risco de mortalidade (OR = 5,15), colestase (OR = 5,16), enterocolite necrosante (OR = 3,33) e sepse (OR = 2,09) (PHONGPREECHA *et al.*, 2025). Além disso, a ferramenta apresentou menor variabilidade nas prescrições entre pacientes com características semelhantes (PHONGPREECHA *et al.*, 2025).

Os autores também realizaram uma análise qualitativa, por meio de um estudo cego envolvendo profissionais de saúde, na qual as prescrições elaboradas pela inteligência artificial obtiveram pontuação média de 56 pontos, enquanto as prescrições convencionais alcan-

çaram média de 35 pontos (PHONGPREECHA *et al.*, 2025).

Segundo os autores, os resultados demonstraram que a inteligência artificial foi capaz de conciliar a padronização dos processos com a personalização do cuidado nutricional (PHONGPREECHA *et al.*, 2025).

O segundo estudo realizou uma análise retrospectiva de prontuários eletrônicos em Taiwan, incluindo pacientes adultos internados em unidade de terapia intensiva (UTI) entre 2016 e 2019 (CHEN *et al.*, 2025). Foram avaliados 2.122 pacientes, dos quais 1.994 atenderam aos critérios de inclusão. A amostra foi composta por pacientes com insuficiência respiratória submetidos à ventilação mecânica, sendo excluídos indivíduos com idade inferior a 20 anos, gestantes, portadores de HIV e pacientes com permanência inferior a três dias na UTI (CHEN *et al.*, 2025).

Para o desenvolvimento da inteligência artificial, foi utilizado o conceito de *ground truth*, no qual seis nutricionistas experientes classificaram os pacientes em alto risco nutricional ($n = 701$) ou baixo risco nutricional ($n = 1.293$) com base em variáveis rotineiramente disponíveis na prática clínica, incluindo idade, sexo, peso, índice de massa corporal (IMC), albumina, hemoglobina, comorbidades e escores de gravidade APACHE II e SOFA. Essa classificação foi utilizada para treinar quatro algoritmos de aprendizado de máquina: regressão logística, *XGBoost*, *CatBoost* e *LightGBM* (CHEN *et al.*, 2025).

O desempenho dos modelos foi avaliado por meio da área sob a curva ROC (AUROC). O algoritmo *CatBoost* apresentou o melhor desempenho (AUROC = 0,926), seguido por *LightGBM* (0,923), *XGBoost* (0,921) e regressão logística (0,852), demonstrando elevada capacidade dos algoritmos baseados em *gradient boosting* para identificar pacientes com alto

risco nutricional (CHEN *et al.*, 2025).

As cinco variáveis com maior influência nas predições foram APACHE II, albumina, idade, IMC e hemoglobina. Valores mais elevados de APACHE II e idade estiveram associados a maior probabilidade de classificação como alto risco nutricional, enquanto maiores níveis de albumina, IMC e hemoglobina foram associados a menor risco (CHEN *et al.*, 2025).

Na comparação com ferramentas tradicionais de avaliação nutricional, o modelo desenvolvido a partir da classificação dos nutricionistas apresentou desempenho ligeiramente superior ao escore NUTRIC para prever permanência prolongada na UTI, sugerindo potencial para complementar os métodos de avaliação nutricional já utilizados na prática clínica (CHEN *et al.*, 2025).

O terceiro artigo é um estudo quantitativo observacional e prospectivo realizado entre 2022 e 2024 na Malásia. A equipe comparou os modelos de equações preditivas tradicionais e modelos *XG Boost*, *Random Forest Regressor* e *Support Vector Regression* para *machine learning*, além da CNN para *deep learning* para o estimar gasto energético de repouso (ANG *et al.*, 2025). Foram realizadas 300 medições de REE por calorimetria indireta e dentre os modelos de AI os melhores resultados foram obtidos pelo *XGBoost* teve RMSE de 199 calorias, seguido pelo *Random Forest Regressor*, com 200 calorias, e pelo *Support Vector Regression*, com 221 calorias enquanto o modelo de *deep learning*, CNN, apresentou RMSE entre 240 e 250 calorias (ANG *et al.*, 2025). Como menor RMSE indica menor erro, os resultados mostram que o *machine learning* foi mais preciso que as equações preditivas e que o *deep learning* neste estudo (ANG *et al.*, 2025).

O quarto estudo consistiu em uma coorte realizada com 412 pacientes internados em uma Unidade de Terapia Intensiva Neonatal (UTIN)

na Turquia. Foram incluídos recém-nascidos que permaneceram vivos por, no mínimo, 24 horas e que receberam pelo menos uma medicação ou nutrição durante a internação. O estudo teve como objetivo desenvolver modelos de *machine learning* capazes de identificar precocemente pacientes com maior risco nutricional (JANSSEN *et al.*, 2025). Foram desenvolvidos 22 modelos de *machine learning*, dos quais 13 foram destinados a tarefas de regressão e nove à classificação (JANSSEN *et al.*, 2025). Entre os modelos de regressão, o GLMnet apresentou o melhor desempenho na predição do peso na alta hospitalar, com erro quadrático médio da raiz (RMSE) de 393,83 e coeficiente de determinação (R^2) de 0,79 (JANSSEN *et al.*, 2025). Entre os modelos de classificação, o *XGBoost* apresentou o melhor desempenho para prever o ganho de peso durante a internação, alcançando área sob a curva ROC (AUC) de 0,79, acurácia de 81,3%, especificidade de 0,94 e *F1-score* de 0,74 (JANSSEN *et al.*, 2025). Além disso, os resultados demonstraram que foi possível reduzir o número de variáveis utilizadas no modelo de 57 para cinco, mantendo desempenho satisfatório, com AUC de 0,77 (JANSSEN *et al.*, 2025).

O quinto trabalho é um estudo retrospectivo realizado em Israel com 1.584 pacientes de 2011 a 2018 internados por, no mínimo, 48h e receberam nutrição parenteral, analisando sua idade, sexo, escores de gravidade (APACHE II e SOFA), sinais de intolerância alimentar, volume residual gástrico (GRV), sintomas gastrointestinais e uso de medicamentos procinéticos. A equipe utilizou modelos de *K-Nearest Neighbor (KNN)*, *Decision Tree*, *Random Forest*, *XG Boost*, *Gradient Boosting*, *Logistic Regression* e *AdaBoost* para identificar sinais precoces de intolerância de nutrição enteral (RAPHAELI *et al.*, 2023). Desse grupo de pacientes, 612 foram a óbito, e, ao analisar suas informações, encon-

traram que os marcadores de tolerância identificados foram os indicadores significativos de intolerância alimentar: Diarreia no primeiro dia (6,2% comparado a 2,6% nos sobreviventes), volume residual gástrico superior a 250 ml (27,9% dos pacientes que morreram e em 21,8% dos sobreviventes; no segundo dia, em 27,8% contra 16,9%; e no terceiro dia, em 28,8% contra 16,9%) e uso de eritromicina (3,7 versus 1,2%) (RAPHAELI *et al.*, 2023). Diante disso, os algoritmos apresentaram capacidade moderada de prever os desfechos analisados, com a mortalidade em 90 dias apresentando uma área sob a curva ROC (AUC-ROC) média de 0,73, com intervalo de confiança de 95% entre 0,71 e 0,75, para a previsão de falha precoce da nutrição enteral, a AUC-ROC média foi de 0,71, com intervalo de confiança de 95% entre 0,67 e 0,74 (RAPHAELI *et al.*, 2023). Por fim, as variáveis mais importantes para a previsão da mortalidade foram os escores APACHE II, idade, SOFA do primeiro e do terceiro dia e, especialmente, o volume residual gástrico elevado nos dias dois e três (RAPHAELI *et al.*, 2023). Entre todos os marcadores de intolerância alimentar avaliados, o volume residual gástrico superior a 250 mL no segundo dia de internação foi identificado como o fator mais relevante para a predição dos desfechos desfavoráveis (RAPHAELI *et al.*, 2023).

Por fim, o último trabalho é um estudo retrospectivo observacional com 45679 recém nascidos prematuros e extremamente prematuros com tempo médio de permanência hospitalar de 49 dias objetivando identificar padrões nutricionais neonatais e analisar esses padrões com os desfechos dos pacientes a partir do uso de AI (GREENBURY *et al.*, 2021). Neste trabalho foi aplicado um modelo de inteligência artificial não supervisionado denominado *Dirichlet Process Gaussian Mixture Model* que analisou leite materno (*Maternal Milk – MM*),

leite humano doado (*Human Donor Milk – HDM*), fortificante do leite materno (*Breast Milk Fortifier – BMF*), fórmula infantil (*Formula Milk – FM*), nutrição parenteral (*Parenteral Nutrition – PN*) e solução de glicose e eletrólitos (GE). Foi identificada uma mortalidade de 8%, enterocolite necrosante grave 3% e displasia broncopulmonar de 27%, enquanto 15,6% receberam leite materno exclusivamente, 3,3% apenas fórmula infantil, 49,7% combinação de leite materno e fórmula e 27,4% leite humano doado e 45% receberam fortificante do leite. Esse modelo identificou 46 padrões nutricionais distintos e a robustez do modelo foi testado pelo teste de reprodutibilidade com os principais cluster com concordância de $0,85 \pm 0,02$ e valor médio total de $0,82 \pm 0,01$. Os autores também encontraram uma associação entre esse resultado como maior exposição à fórmula infantil e menor exposição ao leite humano estavam com maior ganho ponderal e que o leite humano exerça efeito protetor contra a displasia broncopulmonar, corroborando achados previamente descritos na literatura.

DISCUSSÃO

Os artigos selecionados apresentaram resultados condizentes, sem contradições importantes. Os modelos de AI mostraram potencial para automatizar e padronizar prescrições de nutrição parenteral neonatal sem perder a individualização do tratamento, essa utilidade possibilitaria sua incorporação à prática clínica por meio do modelo *physician-in-the-loop*, no qual a inteligência artificial funciona como ferramenta de apoio à decisão, enquanto a responsabilidade final permanece com a equipe médica (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021). Dessa forma, possibilitaria usa-la como uma estratégia importante para reduzir a sobrecarga dos

serviços de saúde (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021).

Os principais benefícios percebidos são: redução dos erros de prescrição, diminuição de custos operacionais e melhoria da qualidade do cuidado nutricional em UTINs, capacidade de fornecer suporte contínuo à equipe assistencial, capacidade de captar relações mais complexas entre variáveis como superfície corporal, peso, idade, ventilação minuto e escores de gravidade (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021). Dessa forma, tais resultados sugerem que as ferramentas baseadas em aprendizado de máquina podem oferecer maior precisão na identificação de pacientes em condição de risco, contribuindo assim para intervenções mais precoces, direcionadas e personalizadas (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021). Apesar dos resultados promissores, esses modelos ainda precisam ser validados em amostras maiores e mais diversas antes de serem aplicados amplamente na prática clínica (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021).

As principais limitações identificadas são o treinamento do modelo limitado aos dados estruturados dos prontuários eletrônicos, sem incorporar informações provenientes de imagens médicas ou anotações clínicas em texto livre, somado a necessidade de informações derivadas de exames invasivos (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021). Além disso, grande parte dos estudos são retrospectivo observacional, o que impede a demonstração de relação causal entre o uso do sistema e a melhora dos

desfechos (PHONGPREECHA *et al.*, 2025; ANG *et al.*, 2025; JANSSEN *et al.*, 2025; RAPHAELI *et al.*, 2023; GREENBURY *et al.*, 2021). Diante disso, recomenda-se a realização de futuros estudos prospectivos e validações externas em diferentes populações antes que esses modelos sejam incorporados rotineiramente à prática clínica (RAPHAELI *et al.*, 2023).

CONCLUSÃO

A presente revisão integrativa demonstrou que a inteligência artificial apresenta elevado potencial para aprimorar a terapia nutricional de pacientes críticos, oferecendo suporte à tomada de decisão clínica por meio da identificação precoce do risco nutricional, otimização de prescrições, estimativa mais precisa das necessidades energéticas e predição de desfechos clínicos relevantes. Os estudos analisados evidenciaram que modelos de aprendizado de máquina e *deep learning* podem alcançar desempenho superior ou complementar às ferramentas tradicionais, favorecendo uma assistência mais individualizada, padronizada e eficiente.

Apesar dos resultados promissores, a maioria das evidências ainda deriva de estudos retrospectivos, desenvolvidos em populações específicas e dependentes de dados estruturados de prontuários eletrônicos, o que limita a generalização dos achados. Dessa forma, a incorporação da inteligência artificial à prática clínica deve ocorrer de maneira criteriosa, como ferramenta de apoio à equipe multiprofissional e não como substituta do julgamento clínico. Assim, tornam-se necessários estudos prospectivos, multicêntricos e com validação externa para confirmar a eficácia, segurança e aplicabilidade desses modelos em diferentes contextos assistenciais, possibilitando sua implementação ampla e contribuindo para melhores desfechos nutricionais e clínicos em pacientes críticos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANG, C. Y. S. *et al.* Methods for estimating resting energy expenditure in intensive care patients: A comparative study of predictive equations with machine learning and deep learning approaches. *Computer Methods and Programs in Biomedicine*, v. 262, p. 108657, 2025. DOI: <https://doi.org/10.1016/j.cmpb.2025.108657>.
- BAIK, S. M.; KIM, M.; LEE, J. G. Comparison of early enteral nutrition versus early parenteral nutrition in critically ill patients: a systematic review and meta-analysis. *Nutrients*, v. 17, n. 1, p. 10, 2024. DOI: <https://doi.org/10.3390/nu17010010>.
- BERKHOUT, W. E. M. *et al.* Operationalization of artificial intelligence applications in the intensive care unit. *JAMA Network Open*, v. 8, n. 7, p. e2522866, 2025. DOI: <https://doi.org/10.1001/jamanetworkopen.2025.22866>.
- CHA, J.-K. *et al.* Effect of early nutritional support on clinical outcomes of critically ill patients with sepsis and septic shock: a single-center retrospective study. *Nutrients*, v. 14, n. 11, p. 2318, 2022. DOI: <https://doi.org/10.3390/nu14112318>.
- CHEN, C.-H. *et al.* Artificial intelligence assisted nutritional risk evaluation model for critically ill patients: integration of explainable machine learning in intensive care nutrition. *PubMed*, v. 34, n. 3, p. 343–352, 2025. DOI: <https://doi.org/10.1097/MPG.00000000000003432>.
- FREDERIKS, P.; PEETERMANS, M.; WILMER, A. Nutritional support in the cardiac intensive care unit. *European Heart Journal – Acute Cardiovascular Care*, 2024. DOI: <https://doi.org/10.1093/ehjacc/ehu024>.
- GRECO, M.; CARUSO, P. F.; CECCONI, M. Artificial intelligence in the intensive care unit. *Seminars in Respiratory and Critical Care Medicine*, v. 42, n. 1, p. 2–9, 2020. DOI: <https://doi.org/10.1055/s-0040-1713405>.
- GREENBURY, S. F. *et al.* Identification of variation in nutritional practice in neonatal units in England and association with clinical outcomes using agnostic machine learning. *Scientific Reports*, v. 11, n. 1, 2021. DOI: <https://doi.org/10.1038/s41598-021-86234-1>.
- HONG, N. *et al.* State of the art of machine learning-enabled clinical decision support in intensive care units: literature review. *JMIR Medical Informatics*, v. 10, n. 3, p. e28781, 2022. DOI: <https://doi.org/10.2196/28781>.
- JANSSEN, S. M. W. *et al.* Machine learning models for predicting malnutrition in NICU patients: a comprehensive benchmarking study. *Computers in Biology and Medicine*, v. 192, p. 110326, 2025. DOI: <https://doi.org/10.1016/j.compbimed.2025.110326>.
- KANG, M. W. *et al.* Nocturnal enteral feeding and mechanical ventilation risk in intensive care unit patients: a deep learning-based causal inference study. *Clinical Nutrition*, v. 57, p. 106556, 2026. DOI: <https://doi.org/10.1016/j.clnu.2026.106556>.
- LEWIS, S. R. *et al.* Enteral versus parenteral nutrition and enteral versus a combination of enteral and parenteral nutrition for adults in the intensive care unit. *Cochrane Database of Systematic Reviews*, 2018. DOI: <https://doi.org/10.1002/14651858.CD012276.pub2>.
- MATEJOVIC, M. *et al.* Medical nutrition therapy and clinical outcomes in critically ill adults: a European multinational, prospective observational cohort study (EuroPN). *Critical Care*, v. 26, n. 1, 2022. DOI: <https://doi.org/10.1186/s13054-022-04009-7>.
- MOAZEMI, S. *et al.* Artificial intelligence for clinical decision support for monitoring patients in cardiovascular ICUs: a systematic review. *JMIR Medical Informatics*, v. 10, 2023. DOI: <https://doi.org/10.2196/43123>.
- PHONGPREECHA, T. *et al.* AI-guided precision parenteral nutrition for neonatal intensive care units. *Nature Medicine*, p. 1–13, 2025. DOI: <https://doi.org/10.1038/s41591-025-03012-9>.
- PINSKY, M. R. *et al.* Use of artificial intelligence in critical care: opportunities and obstacles. *Critical Care*, v. 28, n. 1, 2024. DOI: <https://doi.org/10.1186/s13054-024-04789-3>.
- RAPHAELI, O. *et al.* Using machine-learning to assess the prognostic value of early enteral feeding intolerance in critically ill patients: a retrospective study. *Nutrients*, v. 15, n. 12, p. 2705, 2023. DOI: <https://doi.org/10.3390/nu15122705>.
- STOIAN, M. *et al.* Personalized nutrition strategies for patients in the intensive care unit: a narrative review on the future of critical care nutrition. *Nutrients*, v. 17, n. 10, p. 1659, 2025. DOI: <https://doi.org/10.3390/nu17101659>.