

Sistema de recomendação nutricional personalizado baseado em Redes Neurais para optimização clínica no Hospital Provincial da Matola

Rafael Beto Mpfumo* e Erasmo de Abreu

Departamento de Tecnologias da Informação e Comunicação, Instituto Superior de Transportes e Comunicações, Prol. Av. Kim Il Sung, Maputo, Moçambique

*e-mail do autor correspondente: rmphfumo@isutc.ac.mz

Resumo – A alta prevalência de desnutrição em Moçambique, exacerbada pelas limitações de recursos humanos em ambientes clínicos, impõe desafios significativos à recuperação de pacientes no Hospital Provincial da Matola (HPM). Este projecto visa desenvolver e validar um Sistema de Recomendação Nutricional (SRN) personalizado, utilizando Inteligência Artificial (IA) para classificação objectiva do estado nutricional, visando a optimização do tratamento. Adoptando a *Design Science Research* (DSR), o SRN foi desenvolvido em uma arquitectura web de quatro camadas. O cerne é uma Rede Neural Artificial (RNA) Densa com arquitetura de 3 camadas (Input: 7, Hidden: 64, Output: 3), implementada com TensorFlow e Keras. O modelo foi treinado em um dataset de 1.000 registos simulados/fictícios de biomarcadores e 1.000 registos sintéticos/gerados de biomarcadores (hemoglobina, ferritina, etc.), com divisão 80% de treino / 20% de validação. O algoritmo alcançou uma acurácia de validação média de 94,15%, demonstrando alta capacidade predictiva para classificação de deficiências nutricionais em condições controladas. A solução web automatiza a triagem nutricional, mitigando a dependência do profissional 24h/dia. O SRN desenvolvido é tecnicamente viável e representa uma inovação de aplicação local. A limitação principal: o modelo requer validação futura com dados clínicos reais do HPM para confirmar a generalização do desempenho.

Palavras-chave - Inteligência Artificial; Sistemas de Recomendação; Nutrição Clínica; Redes Neurais Artificiais (RNA); Hospital Provincial da Matola.

I. INTRODUÇÃO

A necessidade de adaptação e evolução tecnológica é constante, impulsionando o desenvolvimento de tecnologias que simplificam tarefas, economizam tempo e aumentam a eficiência. No contexto contemporâneo, as TICs desempenham um papel crucial na área da saúde. Problemas relacionados à nutrição são prevalentes globalmente, com taxas de desnutrição variando entre 20% e 50% em adultos hospitalizados (WHO, 2020; FAO, 2020). Em Moçambique, esse cenário é agravado por desafios socioeconómicos e organizacionais, com altos

índices de desnutrição que pressionam o sistema de saúde pública (SETSAN, 2014).

Este projecto propõe a criação de uma plataforma para a personalização da orientação nutricional no Hospital Provincial da Matola (HPM). Com os avanços em Inteligência Artificial e Aprendizado de Máquina, verifica-se a importância da utilização destas ferramentas para apoiar o diagnóstico de problemas de saúde (Garrow et al., 2001; Nguyen et al., 2017). A nutrição clínica, essencial para a recuperação (Smith & Smith, 2019), enfrenta no HPM desafios de natureza tecnológica e organizacional, como a predominância de procedimentos manuais e a indisponibilidade contínua de nutricionistas.

A Inovação com IA: A Inteligência Artificial (IA), particularmente o Aprendizado de Máquina (ML), oferece o potencial de automatizar e personalizar a assistência nutricional (Chen et al., 2021). Este projecto propõe o desenvolvimento de um Sistema de Recomendação Nutricional (SRN) no HPM, empregando TICs e ML para fornecer orientação nutricional específica e imediata, com base em indicadores biomarcadores do paciente. A contribuição reside na aplicação adaptada desta tecnologia a um contexto hospitalar moçambicano com recursos limitados.

Diante desses desafios, torna-se imperativa a implementação de um sistema *web* inovador e personalizado. O objetivo geral é desenvolver um SRN no HPM.

1.1. Objectivos Específicos do Projecto

- Desenvolver a arquitetura de uma Rede Neural Artificial Densa (RNA) para classificação do estado nutricional com base em biomarcadores.
- Validar a acurácia do modelo de IA usando dados sintéticos para comprovar a viabilidade técnica da solução (*Proof of Concept*).
- Implementar um protótipo *web* de baixo custo, integrado ao algoritmo, para triagem e recomendação nutricional imediata no ambiente hospitalar.
- Analisar criticamente a viabilidade de aplicação local e as limitações impostas pela natureza dos dados.

II. REVISÃO DA LITERATURA E FUNDAMENTAÇÃO

2.1. IA e Sistemas de Recomendação em Nutrição Clínica

Sistemas de Recomendação (SR) utilizam filtragem colaborativa, baseada em conteúdo ou híbrida para fornecer sugestões (Henver et al., 2004). No domínio da saúde, o ML é cada vez mais usado em:

- **Diagnóstico e Classificação:** Modelos de *ML* são empregues para classificar o risco de desnutrição ou a adequação de dietas (Loheswaran et al., 2022; Santos et al., 2023).
- **Personalização Nutricional:** Sistemas predizem a resposta do paciente a intervenções dietéticas com base em biomarcadores e dados clínicos.

O presente trabalho foca-se na classificação do estado nutricional (Baixo/Normal/Alto) de biomarcadores através de uma Rede Neural Artificial (*RNA*), alinhando-se a estudos que utilizam *ML* para triagem nutricional objectiva (Chen et al., 2021).

2.2. Sistemas Similares e Análise Comparativa

Para justificar a necessidade e a aplicabilidade da solução no Hospital Provincial da Matola (HPM), foi realizada uma análise comparativa de plataformas de recomendação nutricional existentes. Embora sejam tecnologicamente avançados, estes sistemas apresentam barreiras de implementação significativas no contexto moçambicano.

Tabela 1. Sistemas de recomendação nutricional similares.

Plataforma Similar	Foco Principal	Barreira para o HPM/Moçambique
Nutrium (Software de Nutrição)	Criação de planos detalhados, <i>tracking</i> de paciente e telemonitorização.	Alto custo de licenciamento por profissional; adaptação dietética a alimentos locais e regionais é complexa.
Card Nutri (App)	Educação alimentar e cálculo de valor nutricional de refeições.	Não possui funcionalidade de classificação de risco ou recomendação baseada em biomarcadores clínicos em tempo real.
PROTEIN AI Advisor (Modelo ML)	Recomendação otimizada de consumo proteico (IA).	Focado em mercados e <i>datasets</i> estrangeiros; falta de dados de treino local e barreira linguística.

O Sistema de Recomendação Nutricional (SRN) proposto neste projeto difere das soluções comerciais por

ser uma solução de baixo custo, adaptada para lidar com dados de entrada, biomarcadores locais, e focada na classificação objetiva do nível de deficiência (Baixo/Normal/Alto). Esta abordagem prioriza a eficiência de triagem e a acessibilidade dentro do ambiente hospitalar.

III. METODOLOGIA

3.1. Metodologia de Desenvolvimento e Tipo de Investigação

Para esta pesquisa, foi utilizada a metodologia *Design Science Research* (DSR; Figura 1) (Henver et al., 2004), focada na criação de um artefacto inovador para resolver um problema real no HPM. A *DSR* busca aprimorar as bases de conhecimento em tecnologia por meio da criação de artefactos que resolvem problemas e melhoram o ambiente em que são implementados. O uso do *DSR* é justificado por sua abordagem pragmática e orientada para a resolução de problemas reais.

A pesquisa, quanto à sua natureza, foi aplicada, e quanto à abordagem, foi mista (integrando dados quantitativos para o algoritmo e qualitativos para a análise de requisitos).

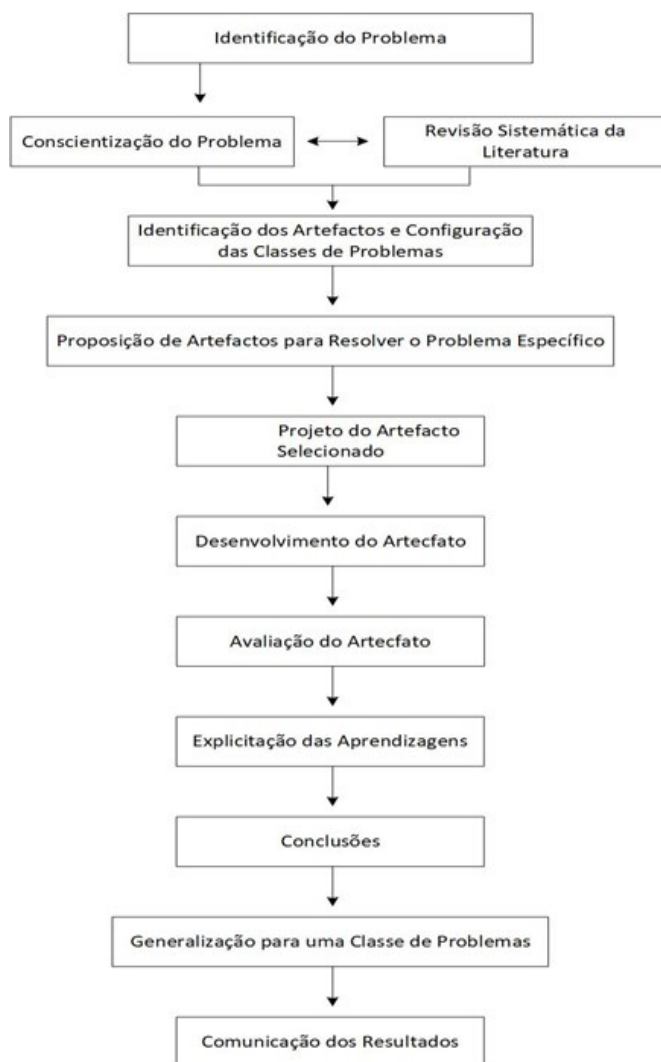


Figura 1. Ciclo de implementação da metodologia DSR (Fonte: Hevner et al., 2004).

3.2. Procedimentos Utilizados Para a Recolha e Análise de Dados

3.2.1. Análise documental e sistemas similares

Foram consultados artigos publicados e avaliados sistemas similares (*Nutrium*, *Card Nutri*, *PROTEIN AI Advisor*) para fundamentação e análise comparativa.

3.2.2. Entrevistas e questionários

Foram realizadas entrevistas com nutricionistas (2), enfermeiros (2), médicos (2) e doentes hospitalizados (4) no HPM. Estas entrevistas confirmaram as seguintes Lacunas Organizacionais e Tecnológicas que fundamentaram o design do SRN: As entrevistas com profissionais e pacientes do HPM confirmaram as seguintes lacunas:

- Organizacionais: Predominância de procedimentos manuais e falta de disponibilidade de nutricionistas 24h por dia;
- Tecnológicas: Inadequação de sistemas globais (como *Nutrium* e *Card Nutri*) devido a custos elevados e inadaptação dietética/linguística ao contexto moçambicano.

3.2.3. Técnicas de análise e tratamento de dados

Utilizaram-se a análise de discurso, análise de conteúdo e análise temática para os dados qualitativos. Para os dados quantitativos, utilizaram-se o *Microsoft Excel* e as ferramentas de análise do *Python* (*Pandas* e *NumPy*).

3.2.4. Ferramentas e Tecnologias utilizadas para o desenvolvimento

As ferramentas e tecnologias usadas no desenvolvimento da presente pesquisa e o seu propósito neste estudo, estão indicados na Tabela 2.

Tabela 2. Ferramentas e tecnologias utilizadas

Função	Ferramentas no Chave	Propósito no Projecto
Página Web/Front-end	HTML5, CSS3, JavaScript, Bootstrap	Desenvolvimento da interface responsiva de (Camada de Apresentação).
Lógica/Back-end	PHP	Conexão com DB e execução da lógica de negócio e da API do algoritmo (Camada de Aplicação).
Algoritmo de IA	Python, Google Colab, TensorFlow, Keras	Criação, treinamento e teste da Rede Neural Artificial (RNA) Densa.
Armazenamento/BD	MySQL, XAMPP	Gestão de dados clínicos e execução local do sistema.

3.3. Arquitetura e Implementação do Algoritmo de IA

3.3.1. Conjunto de dados e pré-processamento

- **Natureza dos Dados:** Foram utilizados 1.000 registos sintéticos/gerados de pacientes, justificando-se pela ausência de um *dataset* clínico padronizado e anonimizado em Moçambique.
- **Variáveis de Entrada (Features):** Sete biomarcadores: Hemoglobina, Ferritina, Albumina, Vitamina B12, Vitamina D, Cálcio e Zinco.
- **Variável de Saída (Label):** Uma de três categorias (*one-hot encoded*): Baixo, Normal, Alto.
- **Pré-processamento: Normalização dos dados** para o intervalo [0, 1] (escalamento Min-Max) para garantir a estabilidade do treino da RNA.

3.3.2. Arquitetura da Rede Neural Artificial (RNA)

A RNA Densa foi seleccionada pela sua eficácia em problemas de classificação categórica. A tabela 3 representa os parâmetros de treinamento.

Tabela 3. Parâmetros de treinamento

Parâmetro	Detalhe	Justificativa Técnica
Divisão Dados	80% Treino / 20% Validação	Padrão para avaliar a generalização durante o treino.
Optimizador	Adam	Optimizador eficiente e robusto.
Função de Perda (Loss)	Categorical Crossentropy	Adequada para classificação multi-classe.
Métrica	Acurácia	Mede a proporção de previsões corretas.
Épocas (Epochs)	50	Número de iterações escolhido para otimizar o desempenho.

A Tabela 4 apresenta a arquitetura de camadas, neurónios e activações

Tabela 4: arquitetura de camadas.

Camada	Tipo	Unidades (Neurónios)	Função de Ativação
1 (Input)	Densa	7	ReLU
2 (Hidden)	Densa	64	ReLU
3 (Output)	Densa	3	Softmax

3.3.3. Testes de software

Foram realizadas provas unitárias (*unit tests*) para verificar a correcta funcionalidade dos métodos individuais de código. Testes de Integração/API foram essenciais para validar a comunicação entre o *Backend* (PHP) e o modelo de IA (*TensorFlow/Python*), garantindo que a inferência e a classificação eram executadas correta-mente. Adicionalmente, o Microsoft Edge Lighthouse foi utilizado para medir e auditar a performance do *Front-end* (*web page*)

quality).

Para a realização dos testes foi utilizado um computador com as seguintes características: Dell Inspiron 15 3000 com 16Gb de RAM, 512 SSD, placa gráfica RADEON.

IV. RESULTADOS

4.1. Lacunas do Processo Actual (Resultados da Análise Qualitativa)

As entrevistas confirmaram as seguintes lacunas no processo de recomendação nutricional no HPM:

- Existência de procedimentos manuais e *timing* de resposta lento;
- Falta de disponibilidade de nutricionistas 24h por dia.
- Não atendimento à necessidade nutricional específica de cada paciente, dificultando a recuperação.

A análise de sistemas similares justificou a necessidade de uma solução personalizada e eficiente para o HPM.

4.2. Especificação de Requisitos e Arquitetura

4.2.1. Requisitos Funcionais

O sistema foi concebido para atender a três actores principais, com foco na gestão de utentes, pacientes, recomendações e diagnósticos (Tabela 5).

Tabela 5. Actores do sistema e suas permissões.

Requisito	Descrição	Actor
RF01	O sistema deve permitir gerir utilizadores	Administrador
RF02	O sistema deve permitir gerir pacientes	Administrador, Técnico, Médico
RF03	O sistema deve permitir gerir recomendações nutricionais	Administrador, Médico

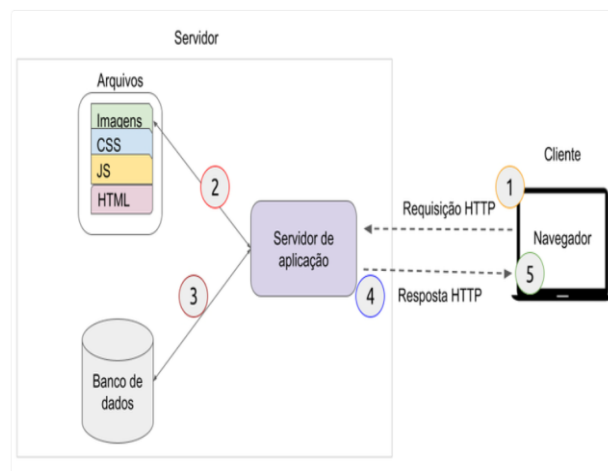
Os *RNFs* suportados incluem: Performance (carregamento em <=5 segundos), Compatibilidade (múltiplos *hardwares* e *browsers*), Segurança (autenticação e proteção de dados), Usabilidade (interface amigável) e Disponibilidade (approx 99,9%).

4.3. Modelo Arquitectónico

A solução resultou em uma aplicação *web* com quatro camadas, acessível via navegador:

- Camada Cliente: O navegador do utilizador;
- Camada de Apresentação: Interface visível (HTML/CSS/JS);
- Camada de Aplicação/Lógica: Onde residem as regras de negócio e a integração com o algoritmo de IA (PHP);
- Camada de Dados: Servidor de base de dados (MySQL).

A Figura 2 representa o modelo arquitectónico da solução proposta, seguida da legenda.



Principais elementos e fluxo de acesso a um site dinâmico

Figura 2. Modelo arquitectónico da solução.

Legenda nos números presentes na Figura 2:

- 1- A requisição é feita pelo cliente através do navegador.
- 2- O servidor interage com os arquivos (parte lógica) e com a base de dados.
- 3- O servidor interage com a base de dados.
- 4- Retorno da resposta.
- 5- Apresentação da resposta.

4.4. Treinamento do Algoritmo de IA

O modelo de RNA alcançou os seguintes resultados, essenciais para a validação técnica sob condições simuladas:

- Acurácia de Validação Média: 94.15% (variou entre 93,80% e 94,50%)
- Perda de Validação: 0.2060

Estes resultados confirmam a alta capacidade predictiva do modelo na classificação dos biomarcadores simulados.

4.5. Testes de Performance (Lighthouse)

Os testes de performance realizados com o *Lighthouse* confirmaram que a qualidade da página web está em conformidade com padrões de Performance, Acessibilidade e Melhores Práticas, garantindo uma experiência de utilizador rápida e funcional (Figura 3).

4.6. Interfaces do Usuário (Demonstração do Artefacto)

O sistema foi demonstrado através de interfaces *web* desenvolvidas em *PHP/HTML*, que incluem telas de *login*, gestão de pacientes e a página de teste do algoritmo. A *interface* mais relevante é onde o utilizador insere os dados dos biomarcadores e recebe o nível (Baixo, Normal, Alto) e a recomendação nutricional específica. Nas Figuras 4 a 9, estão representadas algumas telas dos usuários.

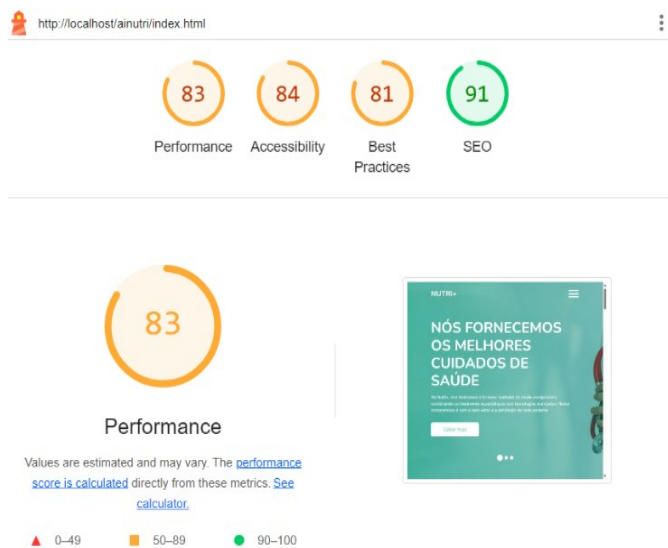


Figura 3. Resultados do teste de performance com a ferramenta *lighthouse*.



Figura 4. Página inicial do sistema.

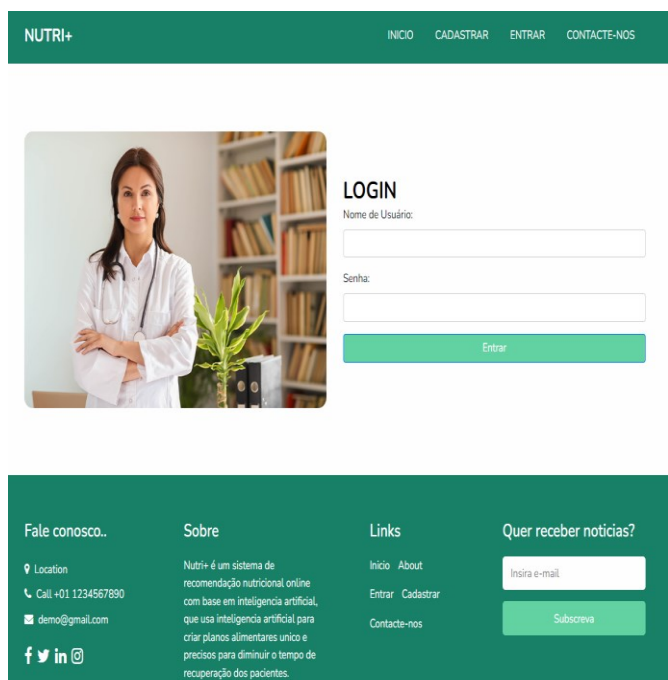


Figura 5. Ecrã de login do sistema.



Figura 6. Página de gestão de pacientes.



Figura 7. Página de gestão de diagnósticos.

V. DISCUSSÃO E IMPLICAÇÕES

O sistema desenvolvido representa uma transição crítica de procedimentos manuais, limitados pela falta de recursos 24h/dia, para um serviço de recomendação nutricional automatizado e individualizado.

A alta acurácia de validação (94,15%) do modelo de RNA demonstra que a IA é tecnicamente viável para classificar os níveis de biomarcadores dos pacientes, permitindo que a recomendação nutricional seja baseada em dados clínicos objetivos. O sucesso da RNA, mesmo com dados fictícios para treinamento inicial, sugere um potencial robusto para a aplicação em dados reais do HPM no futuro. A implementação da solução *web* no HPM tem a capacidade de:

- Reduzir erros e subjetividade nas recomendações;

- Optimizar o tempo dos profissionais de saúde, liberando-os para casos mais críticos;
- Melhorar a recuperação do paciente através de dietas mais alinhadas às suas necessidades específicas.
- O diferencial de aplicação local é crucial. O SRN é de baixo custo e focado na triagem imediata, superando as barreiras de custo e adaptação dietética das soluções comerciais como *Nutrium* ou *Protein AI*.

Figura 8. Página para inserção de características de pacientes, para posterior recomendação.

Inserir Dados Bioquimicos

Nome do Usuario:

Hemoglobina:

Ferritina:

Albumina:

Vitamina B12:

Vitamina D:

Calcio:

Zinco:

Recomendacoes

- Para Hemoglobina (Alto): Evitar suplementos de ferro
- Para Ferritina (Baixo): Carne Vermelha, Frutos do Mar, Leguminosas
- Para Albumina (Normal): Manter uma dieta equilibrada
- Para Vitamina_B12 (Baixo): Fígado, Peixe, Carne Vermelha
- Para Vitamina_D (Alto): Reduzir exposição ao sol e suplementos
- Para Calcio (Alto): Reduzir consumo de laticínios
- Para Zinco (Baixo): Frutos do Mar, Carnes, Nozes

Figura 9. Tela de recomendação para um paciente.

VI. CONCLUSÕES, LIMITAÇÕES E TRABALHOS FUTUROS

A implementação de um Sistema de Recomendação Nutricional personalizado baseado em Inteligência Artificial para os pacientes do Hospital Provincial da Matola alcançou resultados significativos, comprovando a sua viabilidade técnica. O sistema é um protótipo funcional que integra algoritmos de RNA Densa e tecnologias *web* para fornecer recomendações nutricionais personalizadas.

6.1. Limitações e Perspectivas de Futuro

- **Limitação Principal (Dados Fictícios):** O algoritmo foi treinado com dados simulados. A generalização do modelo no ambiente clínico real não está confirmada sem testes em campo. As conclusões sobre a eficácia são limitadas a um ambiente de teste controlado;
- **Novidade Técnica:** A inovação reside na aplicação localizada e adaptada a Moçambique, e não na arquitetura da RNA, que é um modelo padrão na literatura.

Trabalhos Futuros deverão focar-se em:

1. Validação Clínica: Colaboração com o HPM para treinar e validar o modelo com dados clínicos reais e anonimizados, permitindo a implementação em produção;
2. Expansão da Arquitetura: Explorar modelos mais robustos, como Redes Neurais Recorrentes (RNN) ou modelos *Transformer*, para incluir dados de séries temporais (evolução histórica do paciente) e processamento de dados não-estruturados (notas clínicas) no processo de recomendação.

REFERÊNCIAS

Food and Agriculture Organization of the United Nations (FAO). (2020) *The State of Food Security and Nutrition in the World*. Rome.

Garrow, J. S.; James, W. P. T.; Ralph, A. (2001). Human Nutrition and Dietetics. 10th ed. Edinburgh: Churchill Livingstone.

Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design science in information systems research. *MIS quarterly*, vol. 28, 75-105.

Loheswaran, S.; Isaza, S. J.; Sio, K. J. J.; Cohen, M. A.; Moore, L. S.; Marchessault, J. R. (2022). Machine learning for prediction of malnutrition in hospitalized patients *Scientific Reports*, vol. 12, no. 1, pp. 1-12.

Nguyen, D. T., Cohen, E., Pourhomayoun, M., & Alshurafa, N. (2017, March). SwallowNet: Recurrent neural network detects and characterizes eating patterns. In 2017 IEEE International Conference on Pervasive Computing and Communications Workshops (pp. 401-406).

Santos, A. S.; Antunes, L.; Correia, T. R.; Nabais, P.; Ferreira, L. (2023). A Machine Learning approach to predict nutritional status based on clinical biomarkers. *International Journal of Medical Informatics*, vol. 172, art. 105011, 2023.

SETSAN (2014). *Relatório sobre a Segurança Alimentar e Nutricional em Moçambique*. Maputo: Secretaria Técnica de Segurança Alimentar e Nutricional.

Smith, J. and Smith, J. (2019). Impact of Malnutrition on Hospital Stay and Costs. *International Journal of Health Care*, vol. 35, no. 2, pp. 350-358, 2019.

World Health Organization (WHO). (2020) *Global Nutrition Report*. Geneva.