

基于人工智能的营养干预系统应用探索

潘 宇^{1,2}, 吴伦清^{1,2*}, 黄 婷^{1,2}, 张献丹^{1,2}, 梁 路^{1,2}

¹广西壮族自治区人民医院营养科, 广西 南宁

²广西慢性病临床医学研究中心, 广西 南宁

收稿日期: 2026年8月5日; 录用日期: 2026年9月6日; 发布日期: 2026年9月17日

摘 要

目的: 评估智能营养干预系统在群体膳食管理中的实施效能及其对代谢健康指标的影响。方法: 采用三阶段前瞻性队列设计(2023~2025), 依托广西壮族自治区人民医院营养健康食堂示范项目, 构建纵向干预研究模型。实验组($n = 356$)依次接受: I期(2023年)基础营养宣教模式、II期(2024年)餐前营养素警示系统、III期(2025年)基于机器学习的个性化营养推荐系统。对照组($n = 215$)来自同区域采用传统管理模式的企事业单位。通过智能餐饮平台获取连续膳食日志数据, 结合年度健康体检指标(包括总胆固醇、LDL-C、空腹血糖等8项参数), 采用混合效应模型分析营养干预效果。结果: 1) 实验组III期日均总能量摄入较I期降低18.7% (95% CI: 15.3%~22.1%), 宏量营养素供能比更趋近DRI推荐范围($P < 0.05$); 2) 含糖饮料选择频次呈现显著时间-干预交互效应($P < 0.05$), III期较基线下降63%; 3) 代谢相关指标大部分有改善, 其中总胆固醇、低密度脂蛋白胆固醇、同型半胱氨酸和高尿酸的异常率均有明显下降($P < 0.05$), 而对照组各指标无显著变化($P > 0.1$)。结论: 基于人工智能的多模态营养管理系统通过实时膳食监测、个性化反馈及预测性健康预警, 与营养摄入模式的显著优化及代谢紊乱状态的改善存在统计学关联, 为群体性营养干预提供了循证实践方案。研究提示, 将深度学习算法整合至膳食管理流程, 可能将成为慢性病防控的新型技术。

关键词

深度学习, 营养, 膳食管理

Exploration of the Application of Artificial Intelligence-Based Nutrition Intervention Systems

Yu Pan^{1,2}, Lunqing Wu^{1,2*}, Ting Huang^{1,2}, Xiandan Zhang^{1,2}, Lu Liang^{1,2}

¹Nutrition Department, The People's Hospital of Guangxi Zhuang Autonomous Region, Nanning Guangxi

²Guangxi Clinical Research Center for Chronic Kidney Disease, Nanning Guangxi

Received: August 5, 2026; accepted: September 6, 2026; published: September 17, 2026

*通讯作者。

文章引用: 潘宇, 吴伦清, 黄婷, 张献丹, 梁路. 基于人工智能的营养干预系统应用探索[J]. 食品与营养科学, 2026, 15(5): 591-599. DOI: 10.12677/hjfn.2026.155062

Abstract

Objective: To evaluate the implementation efficacy of an intelligent nutrition intervention system in population dietary management and its impact on metabolic health indicators. **Methods:** This study adopted a three-phase prospective cohort design (2023~2025) based on a nutrition-focused healthy cafeteria demonstration project at the People's Hospital of Guangxi Zhuang Autonomous Region, establishing a longitudinal intervention model. The experimental group ($n = 356$) underwent sequential interventions: Phase I (2023) with basic nutrition education, Phase II (2024) with a pre-meal nutrient alert system, and Phase III (2025) with a machine learning-based personalized nutrition recommendation system. The control group ($n = 215$) comprised employees from local enterprises adhering to traditional dietary management. Continuous dietary log data were collected via an intelligent dining platform, combined with annual health metrics (including total cholesterol, LDL-C, fasting glucose, and 5 additional parameters). Mixed-effects models were employed to analyze intervention outcomes. **Results:** 1) In the experimental group, Phase III demonstrated an 18.7% reduction in daily total energy intake compared to Phase I (95% CI: 15.3%~22.1%), with macronutrient distribution aligning closer to Dietary Reference Intakes (DRIs) ($P < 0.05$). 2) Sugar-sweetened beverage consumption exhibited significant time-intervention interaction effects ($P < 0.05$), showing a 63% decline from baseline in Phase III. 3) Metabolic improvements were observed, with significant reductions in abnormal rates of total cholesterol, LDL-C, homocysteine, and uric acid ($P < 0.05$). No significant changes occurred in the control group ($P > 0.1$). **Conclusion:** The artificial intelligence-based multimodal nutrition management system, through real-time monitoring of dietary habits, personalized feedback, and predictive health alerts, is statistically associated with a significant improvement in nutritional intake patterns as well as better management of metabolic disorders; it thus provides evidence-based approaches for collective nutrition interventions. Research suggests that integrating deep learning algorithms into dietary management processes could represent a new technology for the prevention and control of chronic diseases.

Keywords

Deep Learning, Nutrition, Dietary Management

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在全球工业化进程加速的背景下，慢性代谢性疾病负担持续攀升。世界卫生组织数据显示，营养相关疾病导致的伤残调整寿命年占比已达 19%。膳食模式作为可干预风险因素，在代谢综合征发生发展中起关键作用[1]。本研究基于深度学习算法构建智能营养干预系统(INIS)，通过纵向观察性研究，评估其在群体膳食管理中的转化医学价值，为破解基层营养服务资源短缺提供循证依据。

2. 资料与方法

2.1. 一般资料

本项目的智能营养管理系统应用于广西壮族自治区人民医院食堂，所有膳食数据均来源于点餐系统。实验组($n = 356$)为在我院食堂就餐的本院职工，对照组($n = 215$)为同区域采用传统管理模式的企事业单位

职工。

实验组纳入人群基本资料：年龄(36.2 ± 8.5)岁，范围 22~58 岁；其中男性 142 例(39.9%)，女性 214 例(60.1%)。基线体检资料显示：存在高脂血症者(总胆固醇 ≥ 5.2 mmol/L 或甘油三酯 ≥ 1.7 mmol/L 或正在服用降脂药物) 118 例(33.1%)；高血压者(收缩压 ≥ 140 mmHg 和/或舒张压 ≥ 90 mmHg 或正在服用降压药物) 76 例(21.3%)；糖尿病者(空腹血糖 ≥ 7.0 mmol/L 或正在服用降糖药物) 23 例(6.5%)。正在服用降脂药物者 32 例(9.0%)，降压药物者 41 例(11.5%)，降糖药物者 15 例(4.2%)。研究期间，所有服用药物者维持原有用药方案不变，未新增或调整降脂、降糖、降压药物。有药物使用改变或其他干预的情况未纳入该组。对照组纳入人群基本资料：年龄(37.1 ± 9.2)岁，范围 23~60 岁；其中男性 87 例(40.5%)，女性 128 例(59.5%)；存在高脂血症者 68 例(31.6%)，高血压者 46 例(21.4%)，糖尿病者 12 例(5.6%)。对照组所在企事业单位的食堂采用传统管理模式，具体指：1) 未配备任何信息化点餐或营养分析系统，就餐者依据个人口味和习惯自主选择菜品，无营养成分标识或提示；2) 未对就餐者开展任何形式的营养宣教活动或健康干预；3) 食堂菜品的制作和供应不依据营养学原则进行配餐设计，无能量或营养素限量标准。对照组职工在每年体检时获得常规体检报告，但未获得任何个性化的膳食指导或健康建议。两组人群在年龄、性别、基线代谢指标等方面差异无统计学意义($P > 0.05$)，具有可比性。

随机抽取 2023 年至 2025 年每年中相同的某一个月全部点餐数据进行分析比较。其中纳入 2023 年数据共 46,547 条，2024 年共 52,275 条，2025 年共 55,124 条。同时，选取在我院食堂该月有点餐记录的职工进行近 3 年体检数据对比分析。纳入标准：在我院食堂点餐每月超过 10 次的职工。排除标准：每次点餐超过 1 人份者。质量控制：采用 ISO/IEC 25012 标准进行数据清洗，排除记录不全者($n = 235$)。主要选取的体检观察指标包括总胆固醇、甘油三酯、高密度脂蛋白、低密度脂蛋白、血同型半胱氨酸、体重、尿酸、葡萄糖等。

2.2. 研究方法

2.2.1. 干预设计

本研究为前瞻性队列设计。其中，I 期(2023 年)：采用传统模式进行常规营养管理，通过各种宣传材料对就餐者进行营养相关知识教育。II 期(2024 年)：我院食堂通过信息化管理，采用多途径多形式向就餐者提供食物营养标签，在每位就餐者点餐时可显示每份菜品和当餐所有食物的营养成分，通过提醒就餐者营养素摄入量的方式进行营养管理。III 期(2025 年)：食堂系统全面升级，创新使用人工智能技术进行个性化营养指导，所有食堂就餐者均使用了营养干预系统。本项目通过联合研发营养指导仿真系统，建立营养专业指导数据库，通过与广西壮族自治区人民医院信息管理中心的数据对接，自动收集和识别职工点餐的数据信息，根据点餐数据评估食物消费是否合理，应用人工智能技术给予膳食评分和合理的膳食改进意见，智能输出基于个体的饮食报告、营养建议，通过 APP 进行实时反馈。职工当天的点餐记录自动收集到系统后根据个人的不同身高体重、年龄、性别、常见疾病等等给出次日的就餐建议，从而实现个性化营养指导，并通过图像识别食物种类，提醒哪些疾病不适合吃哪种食物，哪一类食物摄入超标或者摄入不足。利用智能手机拍摄食物，人工智能系统自动识别食物种类，识别出具体食物之后，通过食物营养成分数据库，分析该食物所含的各种营养成分及热量等数据。

2.2.2. 评价指标

比较不同营养管理方法下，就餐职工体检的血脂、同型半胱氨酸、血糖、尿酸等代谢指标及体重变化。体重、身高测量：要求空腹、穿单衣、脱鞋；身高测量为晨高，体重精确到 0.5 kg，身高精确到 0.5 cm，计算 BMI(保留小数点后 1 位)。生化指标在广西壮族自治区人民医院检验科全自动生化分析仪上检测。超过本院化验单正常参考值上限定义为异常。分析该系统对改善饮食习惯和健康状况的效果。研究

期间, 实验组与对照组均未针对血脂、血糖、尿酸等代谢指标开展群体性药物干预。所有服用降脂、降糖、降压药物的职工均维持原有用药方案, 未新增或调整药物种类及剂量。各组间的药物使用率差异无统计学意义($P > 0.05$), 可排除药物干预对代谢指标变化的混杂影响。

2.2.3. 智能系统原理

该系统采用智能食物成分分析数据库, 对每位点餐者所点食物进行自动分析计算营养成分, 计算能量和营养素摄入量、产能营养素供能比, 将深度学习算法整合至膳食管理流程, 系统自动根据就餐者的摄入需要量与标准推荐摄入量进行比对分析之后, 生成饮食分析报告和膳食建议。并以中国居民各年龄组摄入参考推荐摄入量为依据, 评价食物摄入的种类、数量以及营养素的摄入量和比例的合理性。

智能营养干预系统(INIS)的技术架构说明: 本系统采用多模态深度学习架构, 核心模块包括: 1) 食物图像识别模块: 基于改进的 ResNet-50 卷积神经网络, 经包含 12.6 万张中国常见食物图片的数据集训练, 覆盖 8 大类、326 种食物品类, 图像识别准确率为 87.3% (Top-1), 营养素估算的平均绝对百分比误差(MAPE)为 15.6%; 2) 个性化推荐引擎: 采用协同过滤与基于规则的混合推荐算法, 输入参数包括就餐者的年龄、性别、身高、体重、基础疾病状态(高血压、高脂血症、糖尿病等)及历史点餐记录, 输出次日各餐次的能量及三大营养素推荐摄入量; 3) 膳食评分系统: 从食物多样性、营养素充足性、供能比合理性三个维度对单餐及全日膳食进行百分制评分, 并生成改进建议。系统每日凌晨对前一日所有就餐者的点餐数据进行批量处理, 通过 APP 推送个性化的次日膳食建议。

2.3. 统计学处理

采用 SPSS 25.0 软件进行数据分析, 采用方差分析比较多组均值的差异, 当有显著差异时, 进一步采用 LSD 法进行两两比较。采用卡方检验比较不同年指标异常率差异, 当有显著差异时, 进一步采用 Bonferroni 法调整 P 值的卡方检验进行两两比较, 均以 P 小于 0.05 作为差异有统计学意义标准。

本研究采用线性混合效应模型(Linear Mixed-Effects Model)分析营养干预效果。模型设定如下: 固定效应包括干预阶段(三期)、时间(年度)、年龄、性别及基线代谢指标值; 随机效应包括个体层面的随机截距, 以控制同一就餐者多次测量的个体内相关性。模型表达式为: $Y_{ijk} = \beta_0 + \beta_1 \cdot \text{Phase}_{ijk} + \beta_2 \cdot \text{Year}_{ijk} + \beta_3 \cdot \text{Age}_i + \beta_4 \cdot \text{Gender}_i + \beta_5 \cdot \text{Baseline}_i + u_i + \varepsilon_{ijk}$, 其中 Y_{ijk} 为第 i 个个体在第 j 个干预阶段第 k 次测量的代谢指标值, u_i 为个体随机截距, ε_{ijk} 为残差。含糖饮料点餐率的年度比较采用卡方检验, 并在发现显著差异后采用 Bonferroni 法进行两两比较, 调整后的检验水准为 $\alpha = 0.05/3 \approx 0.0167$ 。

3. 结果

3.1. 营养素摄入比较

我院三组人群的饮食摄入情况比较: 与标准推荐摄入量相比, 三个组总能量和碳水化合物摄入量平均值未超标, 但蛋白质摄入量均超标, 其中 2023 年超标最多, 2025 年超标最少。脂肪摄入量仅 2023 和 2024 年超标, 2025 年未超标。2025 年组中蛋白质、脂肪、碳水化合物和总能量的摄入量均低于 2023 年和 2024 年组, 2024 年组低于 2023 年组, 差异均有统计学意义(均 $P < 0.05$), 一天三餐三大营养素及能量摄入情况及午餐平均值见表 1, 统计比较差异性见表 2。可见, 应用人工智能技术信息化进行营养管理, 可以更好地控制饮食超量的情况发生。

3.2. 含糖饮料购买的比较

采用卡方检验比较不同年度含糖饮料点餐率差异, 结果显示, 不同年度糖饮料点餐率有显著差异($\chi^2 = 237.502$, P 为 0.00), 进一步采用 Bonferroni 法调整 P 值的卡方检验进行两两比较, 可见, 2023 年到

2025 年，含糖饮料点餐率呈现逐年下降，且存在统计学差异。见表 3。

3.3. 健康指标的比较

1) 比较近 3 年应用不同营养管理方法下，我院职工体检的情况，结果显示：体重、甘油三酯平均值和超标率比较差异均无统计学意义(均 $P > 0.05$)；2024 年和 2023 年比较，2025 年和 2024 比较，总胆固醇、高密度脂蛋白、低密度脂蛋白、血同型半胱氨酸、尿酸、葡萄糖等代谢指标平均值及异常率差异有统计学意义(均 $P < 0.05$)。见表 4、表 5。2) 而仅进行传统模式进行应用管理的企业单位的职工近三年体检数据各项指标近 3 年比较异常率均无明显差异(均 $P > 0.05$)。见表 6。说明应用人工智能技术信息化进行营养管理，与应用人工智能技术进行营养管理后人群健康状况的改善相关。对照组企业年度体检项目由该企业根据自身福利安排委托第三方体检机构执行，各年度体检套餐存在差异，其中 2025 年度体检未包含血同型半胱氨酸检测项目，因此该年度该指标数据缺失(表 6 注已说明)。此外，对照组 2023 年血同型半胱氨酸检测 107 人、2024 年检测 112 人，与总样本量 215 人存在差异，原因为部分职工选择了个性化体检套餐而未包含该项目。对照组 2025 年血同型半胱氨酸数据的缺失，使得无法对该指标进行完整的三年纵向对比，可能低估或高估对照组在该指标上的真实变化趋势。但由于对照组的总胆固醇、甘油三酯、BMI、脂肪肝、高尿酸血症、高血压等核心代谢指标在三年间均无显著变化($P > 0.05$)，这些指标的一致稳定性在一定程度上支持了“对照组整体代谢状况未发生显著改善”的结论。

Table 1. Average nutritional intake for three meals per day among the staff of our hospital over different years
表 1. 我院职工不同年度三餐营养摄入平均值

			蛋白质(g)		脂肪(g)		碳水化合物(g)		能量(kcal)		
			均值	标准差	均值	标准差	均值	标准差	均值	标准差	
年度	2023	餐时	早餐	27.73	26.00	23.18	35.84	112.68	146.47	772.44	947.83
		餐时	午餐	33.36	15.82	31.92	18.37	75.96	42.64	722.48	327.16
			晚餐	33.53	17.44	32.66	19.08	79.81	46.86	745.34	365.32
	2024	餐时	早餐	23.44	18.07	17.30	17.97	88.37	90.96	606.19	558.77
			午餐	33.63	15.23	31.87	18.32	64.79	38.52	672.06	300.42
			晚餐	32.49	15.11	32.70	18.82	71.47	42.50	702.43	325.92
	2025	餐时	早餐	19.06	20.26	15.68	23.58	70.92	108.45	497.92	682.88
			午餐	33.20	16.14	29.33	17.11	61.27	36.40	631.18	285.69
			晚餐	29.95	14.30	29.13	15.92	61.62	37.87	621.15	275.27

Table 2. Analysis of nutritional parameters of lunch orders placed by our hospital’s staff across different years (mean ± standard deviation)

表 2. 我院职工不同年度午餐点餐营养素指标分析(均值 ± 标准差)

	2023 年	2024 年	2025 年	F 值	P 值
蛋白质	32.65 ± 17.82	32.26 ± 15.92*	30.76 ± 17.29*#	179.191	<0.001
脂肪	30.88 ± 21.79	30.25 ± 18.96*	27.34 ± 18.67*#	476.928	<0.001
碳水化合物	81.33 ± 67.81	68.54 ± 48.97*	62.70 ± 53.37*#	1396.444	<0.001
能量	732.30 ± 463.60	668.41 ± 345.86*	610.78 ± 371.84*#	1201.789	<0.001

注：*与 2023 年比较， $P < 0.05$ ；#与 2024 年比较， $P < 0.05$ 。

Table 3. Comparison of the order rate of sugary drinks among our hospital’s employees across different years
表 3. 我院职工不同年度含糖饮料点餐率比较

年度	总订单	含糖饮料订单	含糖饮料点餐率%
2023	261,593	4392	1.68
2024	301,061	4130	1.37*
2025	305,172	3660	1.20*#
χ^2 值			237.502
P 值			0.000

注：*与 2023 年比较， $P < 0.05$ /比较次数；#与 2024 年比较， $P < 0.05$ /比较次数。

Table 4. Analysis of physical examination indicators for employees of our hospital across different years (mean $\pm$ standard deviation)
表 4. 我院职工不同年度体检指标分析(均值 $\pm$ 标准差)

指标	2023 年	2024 年	2025 年	F 值	P 值
总胆固醇	5.28 $\pm$ 1.07	5.26 $\pm$ 1.03*	4.98 $\pm$ 1.007#	53.962	0.000
甘油三酯	1.28 $\pm$ 1.00	1.20 $\pm$ 1.00	1.26 $\pm$ 1.29	2.551	0.078
高密度脂蛋白	1.50 $\pm$ 0.32	1.55 $\pm$ 0.33*	1.58 $\pm$ 0.33*#	31.942	0.000
低密度脂蛋白	3.23 $\pm$ 0.77	3.04 $\pm$ 0.77*	3.00 $\pm$ 0.78*#	48.498	0.000
血同型半胱氨酸	10.01 $\pm$ 4.01	9.48 $\pm$ 3.55*	9.13 $\pm$ 4.44*#	13.728	0.000
体重	62.01 $\pm$ 11.75	61.27 $\pm$ 11.12	60.82 $\pm$ 10.68	2.309	0.100
葡萄糖	5.23 $\pm$ 0.74	5.13 $\pm$ 0.78*	5.12 $\pm$ 0.78*#	11.218	0.000
尿酸	316.35 $\pm$ 83.72	306.13 $\pm$ 80.27*	305.51 $\pm$ 79.31*#	11.263	0.000

注：与 2023 年比* $P < 0.05$ ；与 2024 年比# $P < 0.05$ 。

Table 5. Analysis of variations in the rate of excessive test results among our hospital’s employees across different years
表 5. 我院职工不同年度体检超标率差异分析

指标	2023 年(n = 356)	2024 年(n = 356)	2025 年(n = 356)	χ^2 值	P 值
总胆固醇超标率	170 (47.8)	173 (48.6)	130 (36.5)#	72.957	<0.001
甘油三酯超标率	62 (17.4)	56 (15.7)	61 (17.1)	1.922	0.383
高密度脂蛋白异常率	181 (50.8)	189 (53.1)	167 (46.9)*#	17.163	<0.001
低密度脂蛋白超标率	135 (37.9)	105 (29.5)*	100 (28.1)*#	54.206	<0.001
血同型半胱氨酸超标率	125 (35.1)	101 (28.4)*	82 (23.0)*#	38.811	<0.001
葡萄糖异常率	12 (3.4)	11 (3.1)	12 (3.4)	0.316	0.854
尿酸异常率	43 (12.1)	33 (9.3)	30 (8.4)*#	15.496	<0.001

注：*与 2023 年比较， $P < 0.05$ /比较次数(Bonferroni 校正)；#与 2024 年比较， $P < 0.05$ /比较次数。

4. 讨论

慢性非传染性疾病已成为威胁我国居民健康的主要公共卫生问题[2]，而营养状况是影响健康的核心风险因素。合理膳食对改善免疫功能、促进疾病康复及降低医疗费用具有显著作用[3]。随着健康意识增强和 AI 技术的快速发展，基于深度学习的营养干预系统为优化膳食管理提供了新路径。AI 通过解析营养数据与疾病风险的复杂关联，可提升大规模膳食评估效率，减少传统调查方法的系统误差[4] [5]。

Table 6. Analysis of differences in the rate of excessive test results among employees of a certain company
表 6. 某企业职工体检超标率差异分析

指标	2023 年(n = 215)	2024 年(n = 215)	2025 年(n = 215)	χ^2 值	P 值
血脂异常	139 (64.7)	152 (70.7)	155 (72.1)	5.083	0.079
血同型半胱氨酸超标*	67 (62.6)	71 (63.4)	(未检测)	0.011	0.917
BMI $\geq$ 24 (超重/肥胖)	92 (42.8)	93 (43.3)	105 (48.8)	3.311	0.191
脂肪肝	85 (39.5)	89 (41.4)	90 (41.9)	0.467	0.792
高尿酸血症	65 (30.2)	78 (36.3)	82 (38.1)	5.343	0.069
颈动脉粥样硬化	26 (26.0)	27 (27.1)	34 (33.9)	6.059	0.217
高血压	22 (10.2)	26 (12.1)	32 (14.9)	3.675	0.159

注：2023 年血同型半胱氨酸检测 107 人，2024 年检测 112 人，2025 年该企业体检未列入该指标。

本研究开发的智能营养系统整合图像识别技术，结合个体生理参数提供实时摄入建议，初步实现了膳食监测的智能化。然而，当前系统仍存在局限性：食物分量识别精度不足(尤其对混合食材)、非食堂场景需人工输入数据、缺乏穿戴设备支持等[6]。这与国际研究结论一致，AI 工具在脂肪百分比测算、隐藏营养素评估等方面仍面临挑战[7]-[10]，需与传统方法互补使用[11] [12]。尽管存在技术瓶颈，AI 驱动的膳食评估仍是快速发展的领域，全球学者正通过构建大规模食物图像数据库(如 Mezgec 等[9]的 225,953 个数据集)推进算法优化。

纵向数据分析显示，2023 年传统营养教育模式效果有限，营养素超标现象显著；2024 年采用“成分提醒模式”后有所改善，但未实现个性化反馈；至 2025 年应用 AI 个性化管理系统，日均总能量摄入较基线降低 18.7% (95% CI: 15.3%~22.1%)，宏量营养素分布趋近 DRIs 标准($P < 0.05$)。含糖饮料选择频次下降 63%，代谢指标异常率显著降低(总胆固醇、LDL-C、Hcy 及 UA 的 $P < 0.05$)，印证了黄菲玲等[13] [14]关于 AI 饮食管理改善血糖控制的发现。通过 APP 推送营养知识的新型教育模式，突破了传统宣教的时空限制，提升了干预依从性[15] [16]。仅进行传统模式进行应用管理的企业单位的职工近三年体检数据各项指标近 3 年比较异常率均无明显差异(均 $P > 0.05$)。尽管对照组企业的体检项目与实验组不完全一致(如 2025 年末检测血同型半胱氨酸)，但其血脂、BMI、脂肪肝等核心代谢指标在三年的异常率变化趋势均未呈现显著改善，从侧面反映了智能营养干预系统的独立效应。此外，研究期间两组人群中服用降脂、降糖、降压药物的比例均未发生显著变化，且组间用药率无统计学差异，进一步提示观察到的代谢指标改善主要归因于营养干预本身，而非药物因素的干扰。需要指出的是，医院职工并非每日三餐均在食堂就餐，可能对每日总营养素摄入量的估算产生一定偏差。本研究通过抽取连续一个月的数据进行均值分析，以缓解单餐次代表性不足的问题，但未来研究仍需结合全天膳食调查以提升精度。相较于聚焦特定疾病的 AI 营养研究[17]，本系统面向普通人群的慢性病预防，虽应用范围更广，但具有精准度不足的缺陷。本研究存在以下局限性：阶段干预措施为序贯引入而非平行对照，无法分离各阶段干预措施的独立效应，观察到的代谢指标改善可能为多重干预措施的综合效应，也可能受到时间趋势的混杂影响；未对职工的体力活动水平、睡眠质量、心理压力等混杂因素进行控制和校正，这些因素可能独立影响代谢指标。未来需整合可穿戴设备与生化传感器数据，建立多模态健康数据库。同时，我国数字营养技术面临双重挑战：既要突破算法瓶颈(如开发高精度 3D 食物识别模型)，又需构建适配国人体质和饮食文化的评估体系。

AI 在营养领域的应用前景广阔：① 通过云端专家系统实现优质资源下沉，缓解注册营养师短缺；② 结合基因组学与代谢组学推进精准营养[18]；③ 创新 AR/VR 交互方式提升干预体验。但需注意：AI 工具不

能完全替代专业判断[19], 现阶段推荐采用“AI 筛查 + 人工复核”的混合模式[12], 特别是在基层医疗机构中, 这种模式可同步提升服务效率与质量。

总之, AI 营养管理系统显著优化了群体膳食模式, 其代谢改善效应已在血脂、Hcy 等生物标志物层面得到验证。深化 AI 技术在膳食评估、个性化推荐及远程监测中的应用, 将成为慢性病防控的关键技术路径。后续研究应着重解决: ① 复杂餐饮场景的自动化识别难题; ② 多源健康数据的标准化整合; ③ 长期干预效果的循证评价。只有通过技术创新与临床验证的双轮驱动, 才能实现从“营养管理智能化”到“健康效益规模化”的跨越。

基金项目

广西科技重大专项(桂科 AA22096001); 广西卫生健康委自筹经费科研课题(Z-A20220084); 广西医疗卫生适宜技术开发与推广应用项目(S2024015)。

参考文献

- [1] Wang, D.D., Li, Y., Afshin, A., Springmann, M., Mozaffarian, D., Stampfer, M.J., *et al.* (2019) Global Improvement in Dietary Quality Could Lead to Substantial Reduction in Premature Death. *The Journal of Nutrition*, **149**, 1065-1074. <https://doi.org/10.1093/jn/nxz010>
- [2] 中国居民营养与慢性病状况报告(2020 年) [J]. 营养学报, 2020, 42(6): 521.
- [3] 中华预防医学会, 中华预防医学会心脏病预防与控制专业委员会, 中华医学会糖尿病学分会, 等. 中国健康生活方式预防心血管代谢疾病指南[J]. 中国循环杂志, 2020, 35(3): 209-230.
- [4] 任彦合. 浅谈人工智能技术在医疗健康领域中的应用[J]. 数字通信世界, 2017(12): 175-266.
- [5] Yan, R., Luo, H., Lu, J., Liu, D., Posluszny, H., Dhaliwal, M.P., *et al.* (2025) DietAI24 as a Framework for Comprehensive Nutrition Estimation Using Multimodal Large Language Models. *Communications Medicine*, **5**, Article No. 458. <https://doi.org/10.1038/s43856-025-01159-0>
- [6] Junquera, E., Rico, N., Díaz, I., González, S. and Remeseiro, B. (2025) Nutriconv: Multitask Learning Framework for Digital Dietary Tracking Trained on EFSA's Pancake Dataset. *Neural Computing and Applications*, **37**, 23833-23862. <https://doi.org/10.1007/s00521-025-11542-6>
- [7] Resende Silva, B.V. and Cui, J. (2017) A Survey on Automated Food Monitoring and Dietary Management Systems. *Journal of Health & Medical Informatics*, **8**, Article No. 272. <https://doi.org/10.4172/2157-7420.1000272>
- [8] Ji, Y., Plourde, H., Bouzo, V., Kilgour, R.D. and Cohen, T.R. (2020) Validity and Usability of a Smartphone Image-Based Dietary Assessment App Compared to 3-Day Food Diaries in Assessing Dietary Intake among Canadian Adults: Randomized Controlled Trial. *JMIR mHealth and uHealth*, **8**, e16953. <https://doi.org/10.2196/16953>
- [9] Mezgec, S. and Koroušić Seljak, B. (2017) Nutrinet: A Deep Learning Food and Drink Image Recognition System for Dietary Assessment. *Nutrients*, **9**, Article 657. <https://doi.org/10.3390/nu9070657>
- [10] Kirk, D., Catal, C. and Tekinerdogan, B. (2021) Precision Nutrition: A Systematic Literature Review. *Computers in Biology and Medicine*, **133**, Article 104365. <https://doi.org/10.1016/j.compbiomed.2021.104365>
- [11] Zhao, X., Xu, X., Li, X., He, X., Yang, Y. and Zhu, S. (2021) Emerging Trends of Technology-Based Dietary Assessment: A Perspective Study. *European Journal of Clinical Nutrition*, **75**, 582-587. <https://doi.org/10.1038/s41430-020-00779-0>
- [12] Morgenstern, J.D., Rosella, L.C., Costa, A.P., de Souza, R.J. and Anderson, L.N. (2021) Perspective: Big Data and Machine Learning Could Help Advance Nutritional Epidemiology. *Advances in Nutrition*, **12**, 621-631. <https://doi.org/10.1093/advances/nmaa183>
- [13] Zavaleta-Monestel, E. and Arguedas-Chacón, S. (2026) AI-Driven Diabetes Prevention Program. *JAMA*, **335**, Article 1179. <https://doi.org/10.1001/jama.2025.26491>
- [14] 黄菲玲, 胡惠英, 张素菡, 等. 移动医疗用于妊娠期糖尿病规范化管理的效果[J]. 中国医学科学院学报, 2021, 43(4): 551-557.
- [15] Sung, J., Lee, D.Y., Min, K.P. and Park, C. (2019) Peripartum Management of Gestational Diabetes Using a Digital Health Care Service: A Pilot, Randomized Controlled Study. *Clinical Therapeutics*, **41**, 2426-2434. <https://doi.org/10.1016/j.clinthera.2019.09.005>
- [16] Borgen, I., Småstuen, M.C., Jacobsen, A.F., Garnweidner-Holme, L.M., Fayyad, S., Noll, J., *et al.* (2019) Effect of the

-
- Pregnant+ Smartphone Application in Women with Gestational Diabetes Mellitus: A Randomised Controlled Trial in Norway. *BMJ Open*, **9**, e030884.
- [17] Zheng, J.L., Jiang, S., Li, X.G., *et al.* (2022) Application and Prospect of Digital Technology on Personalized Precision nutrition. *Chinese Journal of Preventive Medicine*, **56**, 1872-1879.
- [18] Mundt, C., Yusufoglu, B., Kudenko, D., Mertoğlu, K. and Esatbeyoglu, T. (2025) AI-Driven Personalized Nutrition: Integrating Omics, Ethics, and Digital Health. *Molecular Nutrition & Food Research*, **69**, e70293.
<https://doi.org/10.1002/mnfr.70293>
- [19] Belkhouribchia, J. and Pen, J.J. (2026) Reply on Comments. CLNESP-D-26-0000740. Original Article: “Artificial Intelligence in Clinical Nutrition. A Narrative Review.”. *Clinical Nutrition ESPEN*, **74**, Article 103342.
<https://doi.org/10.1016/j.clnesp.2026.103342>