

基于多层感知机的个性化减肥营养搭配模型研究

蒋汝元^{1,*}, 温彦鑫², 李斌¹, 李欣阳¹, 赵太燕¹

¹ 乐山师范学院数学与统计学院, 四川乐山, 中国

² 乐山师范学院物理与光电工程学院, 四川乐山, 中国

*通讯作者

【摘要】肥胖及其健康隐患已成为全球范性公共卫生难题。当前主流减重营养干预方案多以群体方案为主, 难以匹配个体代谢、生活习惯与健康需求差异, 导致干预精准度和长期效果受限。为此, 本研究构建基于多层感知机 (MLP) 架构的个体化营养配比智能模型。该模型融合用户体脂率、基础代谢率等生理指标, 活动强度、运动频率等行为数据及个性化减重需求, 搭建三层隐含层的 MLP 回归网络, 精准预测每日总能量以及蛋白质、碳水化合物、脂肪三大宏量营养素摄入水平。训练中引入 Dropout 与 L2 正则化, 有效避免过拟合, 提升模型稳定性与泛化能力。基于 600 人样本测试显示, 模型总热量预测的决定系数 (R^2) 达 0.882, 精度优于多元线性回归、随机森林等模型。12 周随机对照试验表明, 相较传统统一膳食指南组, 模型定制方案的实验组在体重、体脂率、BMI、腰围等指标上改善更显著, 依从性与满意度更高。本研究结合算法创新与实践验证, 证明了 MLP 模型在个体化营养推荐中的应用价值, 为科学减重迈向智能化、精准化提供了新路径与理论支撑。

【关键词】多层感知机 (MLP) 个体化营养配比; 减重干预; 随机对照试验

【基金项目】大学生创新创业训练计划项目 (编号: S202510649205)

1. 引言

1.1 研究背景与问题提出

全球超重肥胖人群呈增长、低龄化趋势, 我国居民肥胖率亦逐年走高[1]。肥胖不仅是独立病症, 更是诱发心血管疾病、II型糖尿病等慢性病的重要因素, 既损害个人健康, 也加重社会公共卫生负担, 2024 年我国已将体重管理提升至国家公共卫生战略层面[2]。当前减肥市场需求激增, 但传统减肥方式易引发营养失衡、效果反弹等问题, 市面通用型配餐方案未兼顾个体身体指标、饮食运动习惯及减重目标的差异, 致使减重效果优劣不一。

在此背景下, 突破传统配餐“一刀切”局限, 打造贴合个体需求的个性化减肥营养配餐方案成为行业关键问题, 需解决四大核心问题: 全面精准收集多维度用户数据、挖掘多源数据的复杂关联、基于实时反馈动态调整配餐方案、兼顾配餐的经济性与可操作性。

1.2 研究内容与创新点

本研究开发基于 MLP 的个性化营养配餐系统, 构建多源数据整合至智能方案生成的技术框架, 采集用户人体测量、代谢、饮食运动及减重目标等多维信息, 通过 MLP 模型挖掘特征非线性关系生成个性化膳食方案, 同时引入成本约束机制优化食材组合。并采用随机对

照试验, 将肥胖受试者分为实验组 (MLP 系统) 与对照组 (传统方案), 对比体成分与代谢指标, 验证系统效能并为推广提供实证依据。

本研究创新主要包含三点: 融合多源数据全面刻画个体特征, 突破传统配餐单因素局限; 利用 MLP 模型挖掘复杂数据关联, 实现精准个性化营养配比; 构建动态调整机制, 可依据用户实时数据与反馈迭代方案, 适配不同减重阶段。本研究将 MLP 与多元线性回归、随机森林、SVM 等传统模型开展对比分析, 从预测能力、建模机制与特征适配性等维度验证算法优势, 具体性能对比结果如表 1 所示。

2. 理论基础

本研究的模型构建以现代营养科学为理论根基, 严格遵循《中国居民膳食指南 (2022)》和《成人肥胖食养指南 (2024 年版)》的核心准则, 融合能量代谢平衡理论与行为营养学研究方法, 把宏量营养素的供能比例建议转化为模型输出的约束条件, 同时融入“三因制宜”的实践原则, 实现对个体的精准适配, 以及模型在地域、季节层面的灵活调整。

基于 Python 技术栈完成全流程技术实现: 借助 Pandas、NumPy 和 scikit-learn 工具库开展数据清洗及特征工程相关工作; 基于

TensorFlow 框架搭建含三层隐藏层的神经网络，引入 ReLU 激活函数，并结合 Dropout 与 L2 正则化策略提升模型泛化能力，模型整体结构如图 1 所示。通过 Flask 与 Vue.js 搭建出完整的 Web 应用。核心算法选用多层感知机（MLP），依靠多层非线性转换实现从用户特征到营养需求的端到端映射；该 MLP 模型设置 17 维输入层、神经元数依次为 128、256、128 的三层隐藏层及 4 维输出层，优化器采用 Adam 算法，同时结合 Dropout 机制与早停策略避免过拟合，具备出色的非线性关系建模能力。

表 1.模型性能对比表

对比维度	MLP 模型	多元线性回归	随机森林	支持向量机 (SVM)
核心预测指标 (测试集)	总热量: R²=0.882, MSE=145.5; 蛋白质: R²=0.865, MSE=18.2; 碳水化合物: R²=0.854, MSE=28.7	总热量: R²=0.701, MSE=385.2; 蛋白质: R²=0.672, MSE=42.1; 碳水化合物: R²=0.685, MSE=58.9	总热量: R²=0.798, MSE=252.1; 蛋白质: R²=0.763, MSE=315.5; 碳水化合物: R²=0.779, MSE=41.2	总热量: R²=0.815, MSE=231.7; 蛋白质: R²=0.788, MSE=28.9; 碳水化合物: R²=0.802, MSE=38.5
关系建模能力	支持多特征复杂非线性关系 (如“基础代谢率+活动水平+慢病标记”交互作用)，可捕捉“BMR 超临界值后能量需求饱和”等规律	仅能捕捉单一线性关系，无法处理特征间交互与非线性关联	可处理部分非线性，但对 17 维高维特征冗余敏感，易忽略细粒度关联	可处理非线性，但对样本量敏感，难以适配个体异质性强场景
特征适配性	支持 17 维多源特征 (8 个数值型+9 个编码后类别型)，通过 Z-score 标准化、独热编码实现全维度融合	对类别型特征 (如性别、慢病标记) 适配性差，无法有效利用多源数据	对编码后的高维类别特征处理能力弱，易受无关特征干扰	特征处理复杂度高，对“身体指标+行为数据+健康目标”多源融合支持不足
效率与泛化能力	参数量~120 K, 训练集与测试集 R² 差距仅 0.03, Dropout 正则化有效防过拟合	参数量~20, 但模型容量不足导致欠拟合，泛化能力弱	推理时间 3ms, 但泛化能力受样本分布影响大，小样本场景易波动	推理时间 15ms, 效率最低; 小样本场景下易过拟合，泛化差




图 1.模型构建流程图

3.研究方法
 与系统实现
 3.1 数据收集与预处理

本研究参照《中国食物成分表（第六版）》搭建含 500 余种食材的营养数据库，收录热量、营养组分、膳食纤维等核心指标，为个性化配餐研究提供数据支撑。研究以 600 名 18 - 51 岁超重肥胖受试者 ($BMI \geq 24kg/m^2$) 为研究对象，通过线上调研、体格检测、自主填报相结合的方式，采集慢性病指征、体测数据、减重预期等 13 项核心信息。数据集涵盖连续型与分类型两类特征，各特征的取值、来源及处理方式如表 2 所示。

表 2.数据集特征信息说明表

特征名称	数据类型	取值范围/分类标准	数据来源	说明
年龄	数值型	18-51 岁，精确到整数岁	校园招聘+合作健身机构体测与问卷	按 18-25 岁、26-35 岁、36-45 岁、46-51 岁划分为 4 个区间，用于匹配不同年龄段营养需求
性别	分类变量	男、女	校园招聘+合作健身机构问卷	采用独热编码转换为二进制向量 (男: [1,0], 女: [0,1])
身高	数值型	140.0-190.0cm, 精确到 0.1cm	专业体测设备采集	用于计算 BMI、基础代谢率等关键身体指标
体重	数值型 (连续)	40.0-120.0kg, 精确到 0.1kg	专业体测设备采集	结合目标体重确定减重幅度
体脂率	数值型 (连续)	15.0%-45.0% (男性)、20.0%-50.0% (女性), 精确到 0.1%	专业体脂秤采集	用于调整宏量营养素摄入比例

数据预处理分四个环节：核心字段缺失剔除 8 例样本，非核心字段按类型中位数/众数填充，食物营养数据按缺失占比处理；按 3σ 原则剔除 5 例异常样本，结合可穿戴设备修正活动水平；数值型特征 Z-score 标准化、分类型特征独热编码；将志愿者数据按 7:2:1 划分为训练集 411 例、验证集 117 例、测试集 59 例，保持字段分布一致。样本数据如图 2 所示，年龄集中在 30-40 岁，BMI 以超重和轻度肥胖为主，超重群体占比 57.7%，为模型训练提供有效特征参考。




图 2.特征分布图

对 600 名受试者做描述性统计，分析年龄、BMI 等六项指标分布。样本多为 30-40 岁，以超重、I 期肥胖群体居多。该部分仅校验样本代表性，为减重营养模型建模提供基础，干预效果需后续试验进一步验证。

3.2 多层感知机模型构建

基于 PyTorch 深度学习框架构建 MLP 回归模型，实现个体每日能量及宏量营养素需求的精准预测，模型前向传播计算过程如下：

$$\begin{cases} h_1 = \text{ReLU}(W_1x + b_1) \\ h'_1 = \text{Dropout}(h_1, p = 0.3) \\ h_2 = \text{ReLU}(W_2h'_1 + b_2) \\ h'_2 = \text{Dropout}(h_2, p = 0.3) \\ h_3 = \text{ReLU}(W_3h'_2 + b_3) \\ h'_3 = \text{Dropout}(h_3, p = 0.3) \\ \hat{y} = W_4h'_3 + b_4 \end{cases} \quad (1)$$

其中， x 为 17 维输入特征向量，包含 8 个标准化数值特征与 9 个独热编码分类特征； W_1, W_2, W_3, W_4 为各层权重矩阵； b_1, b_2, b_3, b_4 为偏置向量； h_1, h_2, h_3 分别为三层隐藏层输出，神经元维度依次为 128、256、128； Dropout 丢弃概率设置为 0.3； $\hat{y}$ 为 4 维输出向量，对应能量、蛋白质、脂肪、碳水化合物四项预测结果。

模型采用均方误差作为回归损失函数，公式：

$$\mathcal{L}_{MSE} = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|_2^2 \quad (2)$$

其中， y_i 为样本真实标签， $\hat{y}_i$ 为模型预测输出， N 代表批次样本数量。

训练采用 Adam 优化器[3]，初始学习率 0.001；使用 ReduceLROnPlateau 动态调参，验证集损失连续 10 轮未下降则将学习率下调至 0.0001。设置总训练轮次 500，批次大小 32；数据集按 420/120/60 划分为训练、验证、测试集。每轮迭代完成前向传播、损失求解、反向传播与参数更新，依托验证集损失监控模型过拟合现象[4]，保存验证损失最低的模型权重，整体训练流程如图 3 所示。

模型训练完成后，选取多元线性回归作为基线模型进行对比实验。评价指标采用决定系数 R^2 与均方根误差 $RMSE$ ，同时保存验证集最优模型参数，为后续推理预测与系统部署提供模型支撑。




图 3. 模型训练流程图

4. 模型结果与分析

本研究从消融实验、特征重要性分析等方面全面评估 MLP 模型性能，剖析模型内部作用机制，验证模型设计的合理性与科学性，对比传统营养计算方法，论证该模型在个体能量与宏量营养素预测任务上的应用优势。

4.1 消融实验与模型鲁棒性分析

为量化各网络组件、输入特征对预测性能的贡献程度，本研究设置多组消融对照实验，以总热量预测任务测试集决定系数 R^2 作为核心评价指标，对比不同配置下模型预测效果，以此验证各模块的实际作用。消融实验结果如表 3 所示。

表 3. 消融实验结果（以总热量预测 R^2 为例）

实验配置	测试集 R^2	性能下降百分比
完整模型(基准)	0.882	基准
移除 Dropout 层	0.841	-4.6%
隐藏层减至 2 层 (128->64->4)	0.851	-3.5%
使用 Sigmoid 函数替代 ReLU 激活函数	0.812	-7.9%
仅使用数值特征(去除类别特征)	0.798	-9.5%

完整模型测试集降至 0.841，性能下降 4.6%，证实 Dropout 正则化能强制网络学习冗余表征，有效抑制过拟合、提升鲁棒性；隐藏层减至两层后 R^2 为 0.851，下降 3.5%，说明三层隐藏结构为学习足够特征抽象层次的必要条件，浅网络存在容量不足问题；使用 Sigmoid 函数替代 ReLU 激活函数后 R^2 为 0.812，下降

7.9%，印证 ReLU 可缓解梯度消失、加速收敛，更适配模型训练需求[5]；仅使用数值特征后 R^2 下降 9.5%，为所有消融实验中降幅最大。该结果表明类别特征提供的个体化上下文信息不可替代，多源数据融合是模型实现高性能的关键。

4.2 特征重要性及模型可解释性探索

为解析 MLP 模型的决策逻辑[6]，本研究采用特征排列重要性与部分依赖图 PDP 开展可解释性分析。对某一特征的样本取值做随机打乱，观测模型预测误差的变化幅度，其计算公式为

$$PI_j = \mathcal{L}(\hat{y}, y) - \mathcal{L}(\hat{y}_{perm(j)}, y) \tag{3}$$

其中， PI_j 为第 j 个特征的排列重要性， $\mathcal{L}$ 代表模型损失函数， $\hat{y}$ 为原始特征输入得到预测结果， $\hat{y}_{perm(j)}$ 为打乱第 j 列特征取值后得到的预测输出。 PI_j 数值越大，代表该特征对模型预测输出的影响越高。为直观呈现各输入特征对模型能量预测结果的贡献权重，本研究对所有特征进行重要性排序，具体分布结果如图 4 所示。




图 4.特征重要性排序图

基础代谢率、体重、体脂率、日常活动强度是能量预测任务贡献度最高的 4 项特征，说明模型学习到符合生理逻辑的特征关联，提升预测结果可信度。

进一步采用部分依赖图分析特征与模型输出之间的映射关系，部分依赖函数定义：

$$f_{PDP(x_j)} = \frac{1}{N} \sum_{i=1}^N \hat{f}(x_j, x_{i, \setminus j}) \tag{4}$$

其中， $\hat{f}(\cdot)$ 代表训练完成的 MLP 模型； x_j 为待分析目标特征； $x_{i, \setminus j}$ 为样本 i 除特征 j 以外其余全部输入特征。PDP 可以固定其余特征，观察单一特征变化时模型输出的整体变化趋势，可视化特征与预测目标之间的线性或非线性关联。为深入挖掘核心特征与营养预测结果的非线性关联规律，本研究绘制

关键特征部分依赖图，直观展示特征变化对模型输出的影响机制[7]，具体结果如图 5 所示。




图 5.关键特征部分依赖图

PDP 可视化表明，关键特征和营养预测输出呈非线性关联，体现深度学习挖掘复杂规律的优势。针对糖尿病相关特征，模型自主调整宏量营养素配比，习得对应营养干预倾向，说明其在个性化营养推荐中具备应用价值[8]。

5.效果验证

本研究开展 12 周随机对照试验，从临床疗效、行为转变、使用体验三方面评价 MLP 个性化膳食干预系统。从 600 人样本中选取 200 名 BMI≥24 超重受试者，随机分两组各 100 例，受试者纳入标准参考《中国成人超重和肥胖预防控制指南》。实验组使用模型动态生成减重膳食，对照组依据 2022 版膳食指南提供标准化减重指导[9]。

试验划分为基线、过程监控、终点测量三个阶段，采集成分及代谢生理指标；实验组通过 APP 记录依从信息，对照组每两周线下随访。计量、计数资料分别选用 t 检验、卡方检验分析，干预后采用 5 点 Likert 量表获取主观评价与开放性反馈[10]。

实验组 APP 数据表明受试者整体依从性较好，多数用户高频访问膳食方案，食材获取是主要使用障碍。干预后受试者满意度超 85%，对口味适配、动态调整功能认可度高，营养认知也有所提升。

对开放式反馈提炼出三大核心主题，证实动态 MLP 个性化干预在体验与依从性上优于传统固定方案，可为超重人群数字化减重提供参考依据。

6.结论

面向个性化减重配餐的市场需求与行业痛点，本研究设计并验证基于 MLP 的智能营养配餐方案，主要成果如下：第一，融合 17 维多源特征搭建 MLP 回归模型，网络结构为 17 维输入-128/256/128 隐藏-4 维输出，通过

Dropout、L2 正则缓解过拟合,能够精准计算个体每日总热量与宏量营养素摄入,兼顾减重效果与营养均衡。第二,模型预测效果优于多元线性回归、随机森林等传统算法,测试集热量、蛋白质、碳水、脂肪的 R^2 依次为 0.882、0.865、0.854、0.843,推理耗时仅 5 毫秒,可支撑实时调用。第三,12 周随机对照试验表明,实验组体重、体脂率、BMI 及空腹血糖等指标改善显著优于对照组 ($P<0.05$),证实模型实际干预效果。第四,系统用户接受度良好,配餐初始接受度 88%,核心满意度超 90%;搭载成本约束模块优化食材组合,提升方案落地可行性与经济性。

综上,本研究突破传统减肥配餐“一刀切”局限,通过“模型构建-性能验证-对照试验-用户分析”三位一体评估体系,验证了人工智能技术在健康管理领域的应用价值,也为后续个性化营养推荐系统的优化与推广提供了实证参考。

参考文献

- [1] 吴东哲,瞿超艺,饶志坚,等.中国及全球成年人归因于超重和肥胖的疾病负担变化趋势与未来风险预测[J].体育科学, 2025, 45 (05): 3-16.
- [2] 国家卫生健康委办公厅.成人肥胖食养指南(2024 年版)[J].卫生研究, 2024, 53

(03): 347-351.

- [3] Kingma P D, Ba J. Adam: A Method for Stochastic Optimization[J]. CoRR, 2014, abs/1412.6980
- [4] Srivastava N, Hinton E G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1):1929-1958.
- [5] Yann L, Yoshua B, Geoffrey H. Deep learning[J]. Nature, 2015, 521(7553): 436-44.
- [6] 陈锐, 张泓.基于多层感知机的人体营养需求预测模型[J].计算机工程与应用, 2023, 59 (12): 267-274.
- [7] 李洋, 刘建伟, 罗雄麟.黑盒机器学习模型事后可解释方法综述[J].模式识别与人工智能, 2020, 33 (08): 724-738.DOI: 10.16451/j.cnki.issn1003-6059.202008006.
- [8] 刘思琦, 陈曦.黑盒神经网络回归模型可解释方法研究进展[J].模式识别与人工智能, 2023, 36 (09): 817-832.DOI: 10.16451/j.cnki.issn1003-6059.202309005.
- [9] 中国营养学会.《中国居民膳食指南(2022)》在京发布[J].营养学报, 2022, 44 (06): 521-522.
- [10] 陈卉, 李康.Likert 等级量表数据的统计分析论文报告规范[J].中国卫生统计, 2024, 41 (02): 289-293.DOI: 10.3969/j.issn. 1002-3674.2024.02.022.