

粮食供应链跨主体联邦协同优化计算方法

许继平^{1,2} 陈梓淇^{1,2} 李卉^{1,2} 王昭洋^{1,2} 张新^{1,2} 赵峙尧^{1,2}

(1. 北京工商大学计算机与人工智能学院, 北京 100048;

2. 中国轻工业工业互联网与大数据重点实验室, 北京 100048)

摘要: 粮食供应链在质量溯源透明化、风险预警协同过程中面临严重的信息孤岛、数据碎片化问题, 导致资源浪费与决策偏差, 亟须构建多主体协同的信息生态系统。本文针对粮食供应链多主体协同中的数据隐私性和异构性问题, 提出一种基于联邦学习的跨主体联邦协同优化计算方法, 融合联邦学习算法与深度学习框架实现供应链多环节间的协作优化。针对粮食供应链各环节数据异构特点, 构建了同环节不同主体的横向联邦和不同环节不同主体的纵向联邦协同计算架构。依据供应链中不同主体数据分布特征与应用场景异构问题, 提出一种多策略融合的MSGWO-FedNova联邦学习协同计算算法, 通过动态调整学习率, 提升模型训练速度和协同计算精度。试验结果表明, 联邦学习协同优化算法迭代周期缩短18%, 损失函数降低23%, 跨规模数据准确率提升7.2个百分点, 优化后的协同计算评估准确性F1分数达95.3%, 为粮食供应链精准需求预测、实时风险预警及多主体协同决策提供了技术支持。

关键词: 粮食供应链; 协同计算; 联邦学习; 超参优化

中图分类号: TP309 文献标识码: A 文章编号: 1000-1298(2026)20-0379-11

OSID:



Optimization of Cross-subject Federal Collaborative Computing in Grain Supply Chain

Xu Jiping^{1,2} Chen Ziqi^{1,2} Li Hui^{1,2} Wang Zhaoyang^{1,2} Zhang Xin^{1,2} Zhao Zhiyao^{1,2}

(1. School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

2. Key Laboratory of Industrial Internet and Big Data, China Light Industry, Beijing 100048, China)

Abstract: The food supply chain faces significant challenges such as information silos and data fragmentation during quality traceability and risk warning processes, leading to resource waste and decision-making biases. There is an urgent need to establish a multi-agent collaborative information ecosystem. Aiming to address the issues of data privacy and heterogeneity among multiple agents in the food supply chain, a cross-subject Federated collaborative optimization computing method was proposed based on Federated learning. This method integrated Federated learning algorithms with deep learning frameworks to achieve collaborative optimization across multiple stages of the supply chain. Considering the heterogeneous data characteristics at different stages, the horizontal federated learning models for the same-stage different-subjects and vertical Federated learning models for different-stage different-subjects were constructed. Based on the logistic regression algorithm, the model parameters were rapidly adjusted. Experimental results indicated that the Federated learning collaborative computing optimization algorithm shortened the iteration cycle by 18%, reduced the loss function by 23%, and improved the accuracy of cross-scale data by 7.2 percentage points. The optimized collaborative computing evaluation achieved an F1 score of 95.3%, providing technical support for precise demand forecasting, real-time risk warning, and multi-agent collaborative decision-making in the food supply chain.

Key words: grain supply chain; collaborative computing; Federated learning; hyperparametric optimization

收稿日期: 2025-06-23 修回日期: 2025-07-05

基金项目: 国家重点研发计划项目(2022YFF1101103)、北京市高层次创新创业人才支持计划科技新星计划项目(20240484720)和北京市属高校优秀青年人才培养计划项目(BPHR202203043)

作者简介: 许继平(1979—),男,副教授,博士,主要从事食品供应链安全风险评估研究,E-mail: xujp@th.btbu.edu.cn

通信作者: 王昭洋(1991—),女,副教授,博士,主要从事工业大数据及数字孪生研究,E-mail: wangzhaoyang@btbu.edu.cn

0 引言

粮食产业正加速数字化转型,生产效率提升,但信息化建设仍处初级阶段,数据流通效率低,限制了供应链协同,尤其在数据安全与隐私保护背景下,涉及商业机密和敏感信息的数据共享面临困难,影响了智能化发展。

为推动农业数字化,国家发布了《智慧农业行动计划》,提出通过信息技术推动农业现代化,提升数据价值挖掘能力。实现多主体高效协同计算、保护数据隐私成为粮食供应链数字化转型的关键问题。区块链技术作为解决方案,具有提升信息透明度和信任机制的潜力,但其“公开透明”特性与农业数据隐私需求存在冲突,特别在保护价格信息和生产流程等敏感数据方面,供应链参与方存在顾虑^[1]。

为解决数据隐私问题,文献[2]提出将工业互联网标识解析与联邦学习(FL)结合,在保证数据不出本地实现协同建模。然而,主流的 FL 算法如 FedAvg^[3-4] 仍面临隐私泄露风险,学者们采用差分隐私^[5-6]、同态加密^[7-8] 和安全多方计算^[9-11] 等技术进行隐私保护,但这些方法会增加计算和通信开销。

针对上述问题,Wang 等^[12] 提出的 FedNova 算法对本地更新参数进行归一化处理,适配异构设备

与非独立同分布数据的联邦学习场景,算法的运行过程仍会受到本地训练步数设置、各参与节点算力差异的制约。因此,本文搭建可适配横向、纵向 2 类数据结构的联邦协同计算架构,引入多策略灰狼优化算法对 FedNova 算法的超参数进行动态调优,构建 MSGWO – FedNova 算法模型。搭建适配横向与纵向场景的联邦协同计算架构,完善联邦学习场景下的数据交互与协同计算流程。依托异构数据分布的场景特征,在 MSGWO – FedNova 算法中嵌入动态学习率调整机制,优化算法的参数更新与模型训练逻辑。

1 联邦协同优化计算方法

粮食供应链涵盖种植、收储、运输等 6 个环节,数据特性呈双重维度:环节内企业间数据具有样本特征同构(特征相似、ID 相异)特性,适用横向联邦学习模型;跨环节数据则呈样本 ID 相同但特征异构特点,需采用纵向联邦学习模。横向模型通过跨主体同构数据聚合可实现环节内协同计算,但难以突破环节间数据壁垒。针对数据隐私性和异构性问题,提出基于粮食供应链跨主体联邦协同计算优化的横向与纵向联邦学习融合框架,引入纵向联邦计算模型,通过跨环节异构数据融合实现全局优化,粮食供应链跨主体联邦学习架构如图 1 所示。




图 1 粮食供应链跨主体联邦学习架构

Fig. 1 Cross-subjective Federated learning architecture for food supply chain

1.1 单环节横向联邦学习协同计算架构

采用分层联邦架构实现多方协同建模,任务执

行始于二级管控节点向中央服务器发送携带任务标识符的训练指令,触发模型初始化流程。中央服务

器解析指令后,将初始模型配置及联邦协议同步至各企业节点的边缘计算单元,完成分布式计算环境部署。各参与节点基于预设的数据权限策略,从加工环节的多维时序数据(涵盖工艺参数、环境监测指标、安全风险监测数据)中筛选有效特征,构建本地训练集并进行模型优化,期间通过正则化约束保障模型泛化能力。本地训练完成后,节点利用加密信道将模型更新量上传至中央服务器,后者基于联邦加权平均算法融合各节点贡献度,生成全局模型迭代版本。更新后的全局参数经同态加密处理后广播至所有参与节点,实现安全高效的参数同步。系

统持续监测全局模型参数变化幅度,当迭代更新量低于预设阈值时终止训练流程,最终由本地节点生成结构化风险评估编码,并通过交互式可视化图谱呈现供应链风险态势。

横向联邦学习在粮食行业可用于生产、加工、运输和销售环节等单环节下多个企业间的协同计算,如图 2 所示。以粮食加工企业 1 和 2 为例,2 个企业的数据要素均为品质质量、碾米方法、环境温度和湿度等特征数据,但数据分属不同生产批次产品,契合横向联邦学习“特征空间一致、样本主体互不重叠”的核心特点。




图 2 粮食加工企业横向联邦学习协同计算架构

Fig. 2 Horizontal Federated learning collaborative computing architecture for grain processing companies

1.2 跨环节纵向联邦学习协同计算架构

采用分级加密联邦架构实现多方协同建模。区域管控节点向中央服务器发起带时间戳的任务指令后,参与方执行加密实体对齐以建立可信数据交互通道。中央服务器根据任务编码初始化模型架构,生成非对称密钥对并分发公钥至认证节点。各企业通过私钥解密本地数据,采用梯度掩码技术完成跨域加密信息交换,更新初始模型参数。

本地训练阶段,参与方基于同态加密上传模型梯度至中央服务器,执行加权聚合后生成全局更新量。聚合梯度经盲化处理广播至各节点,完成联合解密与正则化修正以优化本地模型。系统通过监测

损失函数熵变率动态判定收敛条件,终止迭代后各节点输出结构化风险编码,并生成多维可视化决策图谱。

纵向联邦学习可用于稻谷企业中不同环节间的协同计算。同一批稻谷,在加工、种植和运输企业所包含数据参数各不相同,符合同一样本、不同特征的思想。可将粮食种植企业数据设为 $\{x_m\}$,粮食加工企业数据设为 $\{x_n\}$,将粮食运输企业数据设为 $\{x_v\}$ 。粮油加工企业纵向联邦学习架构如图 3 所示。

1.3 聚合方法对不同特征数据样本的适应性

联邦学习框架中,聚合算法的有效性高度依赖于参与节点的数据分布特性。在非独立同分布




图3 粮油加工企业纵向联邦学习架构

Fig. 3 Vertical Federated learning architecture for grain and oil processing companies

(Non-IID)数据场景下,传统联邦平均算法因忽略本地模型更新偏差,易引发全局模型收敛偏移问题。为此,分别引入 FedProx 的近端正则化约束与 FedNova 的标准化聚合机制,如图4所示,通过动态调整客户端贡献权重,有效平衡异质数据分布下的模型优化轨迹,显著提升跨域协同训练的鲁棒性与收敛效率。

粮食供应链多主体联邦学习范式中,多维异构特征空间对聚合机制的适应性构成显著挑战。供应链节点间的数据呈现典型跨域分布偏移特征,具体表现为跨主体数据偏态分布、特征模态异质及样本容量非均衡性三重维度。经典联邦聚合范式在处理

此类复杂特征交互时,易因客户端梯度偏差累积导致收敛震荡与精度损失。为此,通过解耦联邦聚合算法的特征适应机理,建立异质数据场景下模型收敛速度与泛化性能的权衡优化框架。

FedNova 是联邦学习中的一种改进算法,旨在解决在联邦学习过程中由于不同客户端数据异构性引起的收敛性和性能不稳定问题,即

$$\omega_t = \frac{1}{K} \sum_{k=1}^K \frac{\Delta \omega_t^k}{\|\Delta \omega_t^k\|^2} \quad (1)$$

式中 ω_t ——第 t 轮训练后全局模型参数
 $\Delta \omega_t^k$ ——第 k 个客户端在第 t 轮训练中计算出的模型参数更新量




图4 联邦学习聚合算法流程

Fig. 4 Flowchart of Federated learning aggregation algorithm

K ——参与该训练客户端总数

与 FedAvg 和 FedProx 不同, FedNova 通过基于梯度的标准化 (Gradient normalization) 调整客户端的更新, 使得每个客户端在模型更新时所占的权重更为均衡, 从而有效缓解数据异构性带来的问题^[13-18]。

2 基于多策略灰狼算法的 FedNova 聚合算法优化

联邦学习中的模型性能高度依赖于初始参数设定和超参数调优, 传统的手动调整方法效率低, 且难以在多源异构数据环境下获得全局最优解。为此, 引入多策略融合的灰狼优化算法 (MSGWO), 在联邦训练中自适应优化关键超参数, 提升模型在非独立同分布 (Non - IID) 数据场景下的收敛速度和预测精度。与其他智能优化算法相比, MSGWO 结合了全局搜索和局部开发能力, 融合动态权重调整、变异扰动和精英个体保留策略, 避免陷入局部最优, 增强稳定性和全局收敛性。此外, MSGWO 对资源异构、数据差异显著的分布式环境具有良好的适应性。将其与 FedNova 聚合机制结合, 优化参数配置, 提升模型准确性与计算效率, 为粮食供应链协同建模提供了更稳健、高效的解决方案。

2.1 FedNova 聚合算法参数影响

为研究超参数对模型性能的影响, 对 3 个关键超参数: 学习率 (Learning rate, l_r)、动量因子 (Momentum, μ) 和局部训练轮数 (Local epoch, β) 进行设置与调整。学习率决定模型参数每轮更新幅度, 是影响收敛速度与稳定性的重要因素; 动量因子用于加速收敛并抑制梯度震荡, 提升模型在非凸优化中的表现; 局部训练轮数反映客户端在每轮通信中进行本地训练的强度。采用精确率、召回率、准确率、AUC、F1 分数、准确率作为评价指标对参数优化结果进行评估, 结果如表 1 所示。通过限制每轮训练的批次数, 间接模拟小于 1 的局部训练轮数 (如 0.1 表示训练数据集的 10%)。设置需在通信成本与模型偏移风险之间取得平衡。结合试验目标, 学习率设置为 0.001 ~ 0.1, 动量因子与局部训练轮数分别在 0.001 ~ 0.1 及 0.001 ~ 0.1 之间进行调试, 以覆盖常见区间并观察其对模型性能的影响。通过系统性试验对比, 最终确定参数组合 l_r 为 0.01, μ 为 0.01, β 为 0.01 在多个评价指标上表现最优, 精确率达 91% 以上、召回率达 93% 以上、AUC 达 0.87 以上、F1 分数达 90% 以上、准确率达 89% 以上, 验证了该参数配置在本任务中的适应性与鲁棒性。

表 1 优化参数及结果

Tab. 1 Optimized parameters and results

参数			精确	召回	AUC	F1	准确
l_r	μ	β	率/%	率/%		分数/%	率/%
0.10	0.10	0.10	75.2	71.3	0.766	71.3	70.6
0.01	0.01	0.01	91.4	93.7	0.879	90.9	89.1
0.05	0.01	0.10	88.1	88.4	0.872	87.8	86.7
0.01	0.05	0.01	89.9	91.0	0.873	89.2	88.0
0.01	0.01	0.05	90.5	92.1	0.875	90.1	88.5
0.001	0.001	0.001	71.2	71.0	0.816	70.7	71.3
0.005	0.01	0.01	70.2	71.8	0.770	79.7	78.1
0.02	0.02	0.02	81.3	80.4	0.841	80.1	78.4

由表 1 可见, 超参数对模型性能影响显著, 亟需针对性优化。传统调参方式仅能获取局部较优组合, 难以应对庞大参数空间, 因此采用多策略融合灰狼算法实现自动化寻优。在联邦学习复杂场景下, 超参数优化是提升模型效果的关键手段。

2.2 基于多策略灰狼算法的 FedNova 超参数寻优

在联邦学习中, 多策略灰狼优化算法 (MSGWO) 作为一种高效的参数优化策略, 可用于自动寻优学习率、局部训练轮数等关键参数, 提升模型性能^[19-21]。通过模拟灰狼种群 ($\alpha, \beta, \delta, \omega$) 的协同捕猎行为, 实现全局优化搜索, 算法流程如图 5 所示。MSGWO 引入对立搜索与互补协调策略, 动态平衡全局与局部搜索能力, 通过在每轮迭代中随机调整部分候选解位置, 避免陷入局部最优, 优化后的参数用于联邦学习的分布式训练过程。

在该算法中, 对立搜索策略是在随机初始化阶段, 通过产生对立个体, 并与随机初始化个体进行适应度评价对比择优。数学表达式为

$$\bar{X}(0) = L_b + U_b - X(0) \tag{2}$$

其中
$$X(0) = \begin{cases} \bar{X}(0) & (f[\bar{X}(0)] < f[X(0)]) \\ X(0) & (f[\bar{X}(0)] \geq f[X(0)]) \end{cases} \tag{3}$$

式中 U_b —— X 的上界
 L_b —— X 的下界
 $X(0)$ ——初始化位置向量
 $\bar{X}(0)$ ——原始位置的镜像映射候选位置向量
 $f(\cdot)$ ——适应度评价函数

互补协调策略是通过轮盘赌的方式随机选择策略, 引用 DP 作为判断不同策略的参数。其中, DP = 1 时, 选择策略 1。在标准 GWO 算法上, 随机增加 1 匹灰狼 ε 参与灰狼的位置更新, 从而增强全局搜索能力, 计算式为

$$X(t+1) = \frac{X_1 + X_2 + X_3 + X_4}{4} \tag{4}$$




图5 基于多策略灰狼算法的联邦学习流程

Fig. 5 Federated learning process based on multi-policy gray wolf algorithm

式中 $X(t+1)$ ——下一代灰狼位置
 X_1, X_2, X_3, X_4 —— $\alpha, \beta, \delta, \omega$ 狼之间的方向向量
DP = 2 时, 选择策略 2。通过加入精英学习思想增强局部搜索能力, 添加 1 个精英灰狼位置 X_k 位, 与原始的精英灰狼位置共同作为备选, 灰狼位置计算公式为

$$X(t+1) = \frac{\omega_1 X_1 + \omega_2 X_2 + \omega_3 X_3 + \omega_4 X_k}{4} \quad (5)$$

其中

$$X_k = \frac{X_1 + X_2 + X_3}{3}$$
$$\omega_m = \frac{|X_m|}{|X_1| + |X_2| + |X_3| + |X_k|} \quad (6)$$

式中 ω_m ——权重, $m = 1, 2, 3, 4$
DP = 3 时, 选择策略 3。引入全面优化算法, 采用协调学习策略的方法增强并平衡算法的局部和全局搜索能力。同时, 也有效解决因为 $|A|$ 值不同, 产生的搜索区域不同造成的影响。利用随机灰狼 ε , 计算距离向量。当 $|A| > 1$ 时, 计算当代灰狼位置; 当 $|A| < 1$ 时, 利用全新灰狼位置公式计算当代灰狼位置, 增加灰狼位置随机性。最终根据位置更新公式计算下一代位置, 公式为

$$\begin{cases} X_a = \text{rand}(X_\alpha - A(X_4)) \\ X_b = \text{rand}(X_\beta - A(X_4)) \\ X_c = \text{rand}(X_\delta - A(X_4)) \end{cases} \quad (7)$$

式中 A ——系数向量
 X_a, X_b, X_c, X_4 —— $\alpha, \beta, \delta, \omega$ 狼与 ε 狼之间的方向向量

3 试验验证

3.1 试验设置

以湖南省大米供应链安全风险评估为研究场景, 基于 2020—2023 年运营数据, 构建横向联邦学

习框架验证体系。试验数据包括 3 个加工厂 (A、B、C) 产品数据, 每厂提供 10 000 组训练样本和 1 000 组验证样本。为考察数据规模差异的影响, 构建不同规模数据集。输入特征为加工工艺等级、环境温度、相对湿度和含水率, 输出标签为 5 级品质风险指标。数据呈非均衡分布, 风险等级样本量占比为 1: 1.5: 2: 4.5。试验环境基于联想 ThinkSystem ST558 服务器, 硬件配置包括双路 Intel Xeon 处理器、256 GB 内存、4 × 1.92 TB SSD 和 NVIDIA A2 GPU。软件环境为 Ubuntu 22.04 LTS, PyTorch 2.0.1 和 CUDA 12.2。通过控制变量试验设计, 固定超参数 (学习率 0.01、批尺寸 64、迭代次数 100、通讯轮次 30、抽样率 0.5), 重点考察不同聚合方法对模型泛化能力的影响。

3.2 联邦学习试验验证

3.2.1 训练损失

为验证联邦计算对训练损失函数的影响, 重点比较本地子模型训练过程中的损失函数曲线与中央服务器聚合后的全局模型损失变化。保证试验公平性采用相同数据集进行模型训练, 再通过 3 种聚合方式进行联邦学习协同计算, 对相同规模数据集训练损失值如图 6 所示。

图 6 中, 实线为各客户端在本地独立训练过程中的损失函数下降趋势, 反映每个子模型对自身数据的拟合情况; 虚线为通过联邦聚合生成的中央全局模型在每轮通信后的整体损失变化, 更能表示全局模型对各类数据分布的适应能力。

由图 6 可见, 尽管本地训练的损失函数均呈下降趋势, 但存在一定程度波动, 尤其在数据量较小或数据分布偏异的客户端上更为明显。相较而言, 中央服务器全局损失曲线下降更为平稳, 整体收敛速度更快, 体现出联邦协同计算在整合多源信息、缓解




图 6 相同规模数据横向联邦学损失值曲线

Fig. 6 Loss curves of horizontal Federated learning under data with the same scale

单一数据偏差方面的优势。

特别地,在训练轮次 300 ~ 800 之间,中央模型损失下降速度显著加快,表明系统在多轮通信后进入高效收敛阶段。此时 3 种聚合策略在表现上趋于一致,最终损失值均稳定下降至 1.2 以下,差异甚微。表明 3 种聚合方法均具备良好的稳定性和收敛性,也进一步验证了联邦学习在提升全局模型训练

效率与精度方面的有效性。

为考察所提方法的泛化性能,设计了多粒度数据试验,系统评估算法在不同数据规模下的表现。如图 7 所示,采用差异化样本量客户端配置:客户端 0 样本量级为 1×10^4 、客户端 1 样本量级为 1×10^3 及客户端 2 样本量级为 1×10^2 ,分别对应大、中、小规模数据集。




图 7 不同规模数据横向联邦学习损失值曲线

Fig. 7 Loss curves of horizontal Federated learning with different-scale datasets

在探讨多种规模数据集的训练效果时,当模型参数保持不变而仅改变数据集规模时,训练效果出现显著差异。对于小规模数据集,由于数据量较少,模型能较快捕捉数据规律,损失函数在相同训练轮次内较快收敛。

然而,面对大规模数据集时,尽管数据信息丰富,但由于数据量庞大,模型在相同训练轮次内难以充分学习全部特征,导致损失函数收敛不理想。表明本地训练过程中参数更新效果可能不如预期,模型在有限轮次内难以充分优化。

传统 FedAvg 模型因算法复杂、计算需求高、通信开销大及硬件资源需求高等问题,消耗大量资源预算。为解决这一问题,引入 FedNova 模型,在资源预算受限条件下优化本地训练参数更新策略,更有效地利用大规模数据集信息,提升训练效果。FedNova 为解决数据异构性问题提供了新思路,也为资源受限条件下的高效训练提供了新可能。

3.2.2 训练结果分析

对聚合方法下模型的准确性进行了系统性测试,结果如表 2 所示。使用相同规模数据集的试验结果显示,所有聚合方法均展现出良好的训练成效,其中 FedAvg 与 FedProx 在多项性能指标上保持相近水平。由表 2 可知,FedNova 聚合方法实现了更高的精确率和召回率,AUC 由 0.908 升至 0.969,F1 分数由 85.2% 增加至 90.5%,准确率从 83.7% 提至 91.7%。

表 2 相同数据规模横向联邦学习聚合算法训练结果

Tab.2 Training results of horizontal Federated learning aggregation algorithm with the same data size

方法	精确率/%	召回率/%	AUC	F1 分数/%	准确率/%
FedAvg	85.7	84.7	0.908	85.2	83.7
FedProx	87.5	83.7	0.921	87.4	88.1
FedNova	90.6	90.1	0.969	90.5	91.7

不同规模数据集在 30 个轮次下各项系数波动明显,如表 3 所示,精确率、召回率、AUC、F1 分数、

准确率分别从 91.4% 下降至 73.7%、93.7% 下降至 72.7%、0.879 下降至 0.758、90.9% 下降至 77.2%、89.1% 下降至 67.7%，最终所有性能指标均为 90% 左右。表明传统的 FedAvg 和 FedProx 算法在处理不同规模数据量的训练数据时的训练效果差距较大。小规模数据可以训练到较好的效果，但大规模数据在相同计算成本条件下训练效果欠佳。

表 3 不同数据规模横向联邦学习聚合算法训练结果
Tab.3 Training results of horizontal Federated learning aggregation algorithm with different data sizes

方法	精确率/%	召回率/%	AUC	F1 分数/%	准确率/%
FedAvg	73.7	72.7	0.758	77.2	67.7
FedProx	76.5	78.7	0.771	84.4	81.7
FedNova	91.4	93.7	0.879	90.9	89.1

FedNova 通过引入规范化平均策略，解决了 FedAvg 与 FedProx 在面对企业间数据质量差异时的挑战。该策略依据各客户端的本地更新量进行加权处理，确保全局模型的更新精准反映各客户端数据量和计算能力的实际贡献。这一方法消除了因更新次数差异导致的失配问题，使全局模型优化方向紧密贴合所有客户端的真实目标函数。

FedNova 通过调整更新规则，实现了对目标函




图 8 基于灰狼算法的试验结果

Fig.8 Experimental results based on MSGWO algorithm

表 4 为不同聚合算法预测性能。传统 FedNova 算法在各指标上表现良好，但引入 MSGWO 后，所提出的 MSGWO - FedNova 模型在所有评估指标上均

数的一致且适应性优化，提升了其在不同本地优化环境下的鲁棒性。尽管 FedNova 在训练时间上相较于 FedProx 有所增加，但其规范化平均策略带来的额外计算成本换来了显著的模型性能提升，表明 FedNova 在效率与效果之间取得了良好平衡。

3.3 优化计算方法试验验证

从损失函数曲线来看，MSGWO 算法在所有参数组合下均表现出明显的收敛性，损失值随着训练轮数增加逐渐下降，但不同参数组合下的收敛速度和稳定性差异显著，表明学习率等超参数对算法性能至关重要。精确率和 AUC 曲线的变化进一步验证了这一点，精确率波动范围达到 0.3 个百分点，表明参数选择对模型分类性能影响显著。

为评估超参数对模型性能的影响，在 MSGWO 框架下，通过手动调参得到的 9 组优选参数作为初始种群，并利用分层网格法生成 27 组代表性参数组合进行全局搜索。MSGWO 通过动态更新策略与精英保留机制，优化参数配置，提升模型的收敛性和泛化能力。

图 8 为 MSGWO 在全局搜索过程中对候选参数组合的训练评估。每组曲线对应一组参数配置，优化过程中，MSGWO 通过训练表现和验证集适应度筛选出最优的参数组合，最终在 F1 分数和 AUC 等指标上实现最优结果。

有显著提升，缩短迭代周期 18%，降低损失函数 23%，提升跨规模数据准确率 7.2 个百分点，优化后的协同计算评估准确性 F1 分数达 95.3%。由表 4

可知,MSGWO 有效提高了模型泛化能力和对高风险样本的识别准确性,验证了在联邦学习中引入智能优化策略的有效性。

表 4 横向联邦学习聚合算法预测结果
Tab.4 Prediction results of horizontal Federated learning aggregation algorithm

方法	精确率/%	召回率/%	AUC	F1 分数/%	准确率/%
FedNova	91.6	91.4	0.971	91.2	91.4
MSGWO – FedNova	95.1	94.7	0.988	95.3	98.6

通过混淆矩阵对比 FedNova 算法与经多策略灰狼优化算法优化后的试验结果,单独的 FedNova 算法结果由图 9a 可知,第 1 类别有 874 个真正例和 23 个假正例,第 2 类别有 85 个假负例和 676 个真正例,第 3 类别有 82 个假负例和 1 272 个真正例,第 4 类别有 191 个假负例和 1 365 个真正例,第 5 类别有 3 678 个真正例和 98 个假正例。由图 9b 可知,第 1 类别有 991 个真正例和 10 个假正例,第 2 类别有 65 个假负例和 870 个真正例,第 3 类别有 63 个假负例和 1 372 个真正例,第 4 类别有 178 个假负例和 1 495 个真正例,第 5 类别有 4 425 个真正例和 71 个假正例。FedNova 及其 MSGWO 优化版本的分类结果混淆矩阵如图 9 所示。

尽管存在少量假正例和假负例,但真正例数量远超错误预测,表明模型整体具有较高的分类准确率与鲁棒性。该结果验证了经多策略灰狼优化算法优化后的模型对各类别数据的有效区分能力,以及其在处理复杂分类任务时的稳定性和可靠性。

3.4 不同方法性能试验

为进一步验证所提方法的有效性与普适性,在原有基础上引入 3 种具有代表性的联邦学习算法 (SCAFFOLD、FedOpt 与 MOON) 作为对比。SCAFFOLD 通过引入控制变量缓解客户端漂移问题,适用于典型的非 IID 场景;FedOpt 则利用服务器端优化器(如 FedAdam) 加快模型收敛速度;MOON 结合对比学习机制提升客户端模型表征的一致性,适合个性化联邦学习任务。上述方法在近年来的联邦学习研究中被广泛采用,具有较强的代表性 with 适用性。由表 5 可知,尽管这些方法在多个指标上表现良好,但均不及本文 FedNova 方法,后者在精确率、召回率、F1 分数、AUC 与准确率等核心指标上均取得较优结果,验证了其在多客户端、异构数据环境下的鲁棒性与协同优化能力。

所提 MSGWO – FedNova 方法在所有关键性能指标上均表现最优,精确率、召回率、F1 分数、AUC





图 9 FedNova 与 MSGWO 分类结果混淆矩阵
Fig.9 Confusion matrix-FedNova of classification results for FedNova and its MSGWO optimized version

表 5 不同方法性能测试
Tab.5 Performance test of different methods

方法	精确率/%	召回率/%	AUC	F1 分数/%	准确率/%
SCAFFOLD	88.2	86.1	0.932	86.9	89.2
FedOpt	87.9	85.7	0.938	87.1	88.8
MOON	88.4	87.6	0.946	87.9	89.5
FedNova	91.6	91.4	0.971	91.2	91.4
MSGWO – FedNova	95.1	94.7	0.988	95.3	98.6

和准确率分别达到 95.1%、94.7%、95.3%、0.988 和 98.6%,显著优于其他 4 种对比算法。相比之下,SCAFFOLD、FedOpt 和 MOON 等方法虽在一定程度上改善了模型性能,但在泛化能力和整体协同优化效果方面仍不及 MSGWO – FedNova,尤其在 AUC 和准确率上存在明显差距。结果表明,本文提出的多策略灰狼优化联邦算法 (MSGWO – FedNova) 在多客户端非独立同分布数据环境下,能够实现更高效的全局聚合与更鲁棒的性能表现。

4 结束语

针对粮食供应链多主体协同中的数据隐私性和

异构性问题,提出一种基于联邦学习的跨主体联邦协同优化计算方法,融合联邦学习算法与深度学习框架实现供应链多环节间的协作优化。并采用适应性聚合算法结合多策略灰狼优化算法进行超参数优化,显著提高了模型的预测准确性。在粮食供应链安全风险评估场景下,试验结果表明,与标准的

FedAvg 算法相比,FedProx 和 FedNova 算法在不同规模的数据集上准确率分别提升 5 ~ 7 个百分点和 8 ~ 22 个百分点。通过 MSGWO 优化,FedNova 算法准确率在不同规模数据集上的提升达到 7.2 个百分点。联邦学习的优化方法有效提升了粮食供应链安全风险评估的准确。

参 考 文 献

[1] 许继平,李卉,王浩宇,等. 基于联邦学习的粮食供应链隐私数据要素协同计算研究[J]. 智慧农业(中英文),2023,5(4):79-91.
Xu Jiping, Li Hui, Wang Haoyu, et al. Research on cooperative computation of privacy data elements in food supply chain based on Federated learning[J]. Smart Agriculture, 2023, 5(4): 79-91. (in Chinese)

[2] 许继平,孔德政,王昭洋,等. 基于工业互联网的大米供应链数字孪生系统构建[J]. 农业机械学报,2023,54(3):372-381.
Xu Jiping, Kong Dezheng, Wang Zhaoyang, et al. Construction of digital twin system of rice supply chain based on industrial Internet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 372-381. (in Chinese)

[3] 陈明,孙浩,邹一波,等. 基于区块链的河豚供应链可信溯源优化研究[J]. 农业机械学报,2022,53(9):295-304.
Chen Ming, Sun Hao, Zou Yibo, et al. Trusted traceability optimization of pufferfish supply chain based on blockchain[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 295-304. (in Chinese)

[4] 许继平,孙鹏程,张新,等. 基于区块链的粮油食品全供应链信息安全管理原型系统[J]. 农业机械学报,2020,51(2):341-349.
Xu Jiping, Sun Pengcheng, Zhang Xin, et al. Prototype system of information security management of cereal and oil food whole supply chain based on blockchain[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 341-349. (in Chinese)

[5] 张新,彭祥贞,许继平,等. 基于区块链智能合约的稻米供应链动态监管模型[J]. 农业机械学报,2022,53(1):370-382.
Zhang Xin, Peng Xiangzhen, Xu Jiping, et al. Dynamic supervision model of rice supply chain based on blockchain and smart contract[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 370-382. (in Chinese)

[6] 于丽娜,张国锋,贾敬敦,等. 基于区块链技术的现代农产品供应链[J]. 农业机械学报,2017,48(增刊1):387-393.
Yu Li'na, Zhang Guofeng, Jia Jingdun, et al. Modern agricultural product supply chain based on block chain technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(S1): 387-393. (in Chinese)

[7] Wang Tianyu, Zhang Zhigang, Rehmani M H, et al. Privacy preservation in big data from the communication perspective: a survey[J]. IEEE Communications Surveys & Tutorials, 2019, 21(1): 753-778.

[8] Kang Junwei, Xiong Zhihui, Niyato D, et al. Incentive design for efficient federated learning in mobile networks: a contract theory approach[C]//2019 IEEE VTS Asia Pacific Wireless Communications Symposium (APWCS). IEEE, 2019: 1-5.

[9] Roy R, George T. Detecting insurance claims fraud using machine learning techniques[C]//2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT). IEEE, 2017: 1-19.

[10] Zhuang Yutao, Cai Min, Li Xueliang, et al. The next breakthroughs of artificial intelligence: the interdisciplinary nature of AI[J]. Engineering, 2020, 6(3): 245-247.

[11] Kempa M S, Peng Y. Machine learning algorithms for fraud prediction in property insurance: empirical evidence using real-world microdata[J]. Machine Learning with Applications, 2021, 5: 2-14.

[12] Wang Jianyuan, Liu Qihang, Liang Hao, et al. FedNova: normalized averaging in federated learning[C]//Advances in Neural Information Processing Systems, 2020: 16383-16394.

[13] 魏津瑜,汤玉巧,杨欣. 基于工业互联网的农机供应链创新结构及运作模式研究[J]. 中国农机化学报, 2019, 40(10): 154-161.
Wei Jinyu, Tang Yuqiao, Yang Xin. Research on the innovation structure of agricultural machinery supply chain under industrial Internet[J]. Journal of Chinese Agricultural Mechanization, 2019, 40(10): 154-161. (in Chinese)

[14] 于合龙,陈邦越,徐大明,等. 基于区块链的水稻供应链溯源信息保护模型研究[J]. 农业机械学报,2020,51(8):328-335.
Yu Helong, Chen Bangyue, Xu Daming, et al. Modeling of rice supply chain traceability information protection based on block chain[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 328-335. (in Chinese)

[15] 李林,顾进锋,宋安捷,等. 基于 GPU 的生态环境遥感评价模型并行化研究[J]. 农业机械学报,2017,48(5):135-141.
Li Lin, Gu Jinfeng, Song Anjie, et al. Parallelization on model of ecological environment remote sensing evaluation based on GPU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(5): 135-141. (in Chinese)

[16] 葛艳,黄朝良,陈明,等. 基于区块链的 HACCP 质量溯源模型与系统实现[J]. 农业机械学报,2021,52(6):369-375.
Ge Yan, Huang Chaoliang, Chen Ming, et al. HACCP quality traceability model and system implementation based on blockchain[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 369-375. (in Chinese)

[17] 张新,刘崇宣,许继平,等. 基于多链的果蔬全程全息信息管理模型构建与系统化实现[J]. 农业机械学报,2024,55(6): 365 – 379.
Zhang Xin, Liu Chongxuan, Xu Jiping, et al. Construction and systematic implementation of multi-chain-based management model for fruits and vegetables in full-process and information scheme[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(6):365 – 379. (in Chinese)

[18] 王文娟,汪海燕,陈明,等. 基于多链存储优化的水产品交易匹配模型研究[J]. 农业机械学报,2024,55(6):272 – 283.
Wang Wenjuan, Wang Haiyan, Chen Ming, et al. Aquatic product trading matching model based on multi-chain storage optimization[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(6):272 – 283. (in Chinese)

[19] Stranieri S, Riccardi F, Meuwissen P M, et al. Exploring the impact of blockchain on the performance of agri-food supply chains[J]. Food Control, 2021, 119: 107495.

[20] Sowah R A, Kuuboore M, Ofoli A, et al. Decision support system (DSS) for fraud detection in health insurance claims using genetic support vector machines (GSVMs)[J]. Journal of Engineering, 2019, 2019(1): 1432597.

[21] De Camargo F, Antunes R S, De Ramos G. On social consensus mechanisms for Federated learning aggregation[M]//Xavier-Junior C, Rios R A, et al. Intelligent systems. Cham: Springer International Publishing, 2022: 236 – 250.

(上接第 171 页)

[18] 王晓军,陈高宇,李晓航. 应用动态激活函数的轻量化 YOLOv8 行人检测算法[J]. 计算机工程与应用,2024,60(15): 221 – 233.
Wang Xiaojun, Chen Gaoyu, Li Xiaohang. Lightweight YOLOv8 pedestrian detection algorithm using dynamic activation function[J]. Computer Engineering and Applications, 2024, 60(15): 221 – 233. (in Chinese)

[19] Fang G, Ma X, Song M, et al. Depgraph: towards any structural pruning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 16091 – 16101.

[20] Fan Q, Chen R, Li B. Rice disease detection method based on multi-scale dynamic feature fusion[J]. Frontiers in Plant Science, 2025, 16: 1543986.

[21] Liu W, Duan B, Fan Z, et al. A lightweight edge-deployable framework for intelligent rice disease monitoring based on pruning and distillation[J]. Sensors, 2025, 26(1): 35.

[22] Dai J, Ren J, Li S. PHL – YOLO: a real-time lightweight yarn inspection method[J]. Journal of Real-Time Image Processing, 2025, 22(1): 20.

[23] Hadiur R N. Rice leaf spot disease annotated dataset[DS/OL]. V1.0. Kaggle[2026 – 06 – 16]. <https://www.kaggle.com/datasets/hadiurrahmannabil/rice-leaf-spot-disease-annotated-dataset>.

[24] Song Y, An K, Wang L, et al. Multi-scale closed-loop tuning via spatial frequency collaborative sensitivity for rice leaf disease detection[J]. PLoS One, 2026, 21(6): e0351727.

[25] Jegham N, Koh C Y, Abdelatti M F, et al. YOLO evolution: a comprehensive benchmark and architectural review of YOLOv12, YOLO11, and their previous versions[PP/OL]. V4. arXiv(2024 – 10 – 31)[2026 – 06 – 16]. <https://arxiv.org/abs/2411.00201>.

[26] Gong X, Yu J, Zhang H, et al. Aed – YOLO 11: a small object detection model based on YOLO 11[J]. Digital Signal Processing, 2025, 166: 105411.

[27] Liu C, Wang K, Li Q, et al. Powerful – IoU: more straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism[J]. Neural Networks, 2024, 170: 276 – 284.

[28] Zhang Y F, Ren W, Zhang Z, et al. Focal and efficient IoU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146 – 157.

[29] Zheng Z, Wang P, Liu W, et al. Distance – IoU loss: faster and better learning for bounding box regression[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 12993 – 13000.

[30] 李龙海,王铁哲,吴禹竺,等. 基于剪枝与蒸馏的轻量化玉米病害检测方法[J]. 农业工程学报,2025,41(17):194 – 202.
Li Longhai, Wang Yizhe, Wu Yuzhu, et al. Method for lightweight corn leaf diseases based on pruning and distillation[J]. Transactions of the CSAE, 2025, 41(17): 194 – 202. (in Chinese)

[31] Wen C, Liu L, Li S, et al. Sugarcane stem node detection with algorithm based on improved YOLO11 channel pruning with small target enhancement[J]. PLoS One, 2025, 20(9): e0332870.