

联邦学习的社群化制造韧性能力预测建模

张富强^{1,2}, 王浩杰^{1,2}, 惠记庄^{1,2}, 丁凯^{1,2}

(1. 长安大学道路施工技术与装备教育部重点实验室, 710064, 西安;

2. 长安大学智能制造系统研究所, 710064, 西安)

摘要: 针对社群化制造资源分散化布局的特点,以及传统集中式建模面临的数据隐私与信息孤岛等问题,提出了一种基于联邦学习的韧性能力预测框架,从多角度分析不同因素对产品生产加工工时的影响。首先,考虑不同工序中断情况,以订单交付周期为目标函数,搭建了工时扰动模型计算损失时间,进而基于分布式学习范式,搭建了联邦学习网络模型;其次,设计了联邦小批量梯度下降(FedMBGD)算法,明确算法流程并进行本地训练;最后,结合工时扰动模型和算法,对社群化制造的韧性能力进行预测,通过与其他算法的对比,验证了所提算法的可行性与有效性。研究结果表明:所提出的算法能够显著提升收敛性与寻优能力,可将预测精确度提高至90%以上,并且在不共享原始数据的前提下,实现了社群化制造韧性的动态精准预测,解决了数据隐私与协同建模之间的矛盾。该研究为社群化制造模式下韧性能力预测提供了理论参考,为隐私数据的算法训练、参数上传及信息共享提供了一定的指导意义。

关键词: 社群化制造;工时扰动;联邦小批量梯度下降算法;韧性能力预测

中图分类号: TP166 **文献标志码:** A

DOI: 10.7652/xjtuxb202508002 **文章编号:** 0253-987X(2025)08-0011-09

Federated Learning-Based Predictive Modeling of Resilience Capability in Social Manufacturing

ZHANG Fuqiang^{1,2}, WANG Haojie^{1,2}, HUI Jizhuang^{1,2}, DING Kai^{1,2}

(1. Key Laboratory of Road Construction Technology and Equipment of MOE, Chang'an University, Xi'an 710064, China;

2. Institute of Smart Manufacturing Systems, Chang'an University, Xi'an 710064, China)

Abstract: Considering the characteristics of decentralized resource layouts in social manufacturing, as well as the issues of data privacy and information silos faced by traditional centralized modeling, this paper proposes a resilience capability prediction framework based on federated learning. The framework analyzes the impact of various factors on product processing time from multiple perspectives. First, considering different interruption scenarios in production processes, a working hour disturbance model is established with the order delivery cycle as the objective function to calculate loss time. Subsequently, a federated learning network model is constructed based on a distributed learning paradigm. Next, a federated mini-batch gradient descent (FedMBGD) algorithm is designed, detailing the algorithmic process and performing local training. Finally, the resilience capability of social manufacturing is predicted in conjunction with the working hour

disturbance model and the algorithm. The feasibility and effectiveness of the proposed algorithm are validated through comparisons with other algorithms. The research results indicate that the proposed algorithm significantly enhances convergence and optimization capabilities, raising prediction accuracy to over 90%. Furthermore, it enables dynamic and precise prediction of social manufacturing resilience without sharing raw data, resolving the conflict between data privacy and collaborative modeling. This study provides theoretical references for predicting resilience capabilities in social manufacturing models and offers guidance for algorithm training with private data, parameter uploading, and information sharing.

Keywords: social manufacturing; working hour disturbance; federated mini-batch gradient descent; manufacturing resilience capacity prediction

在全球化浪潮与先进制造技术的双重驱动下,生产制造业的资源布局呈分散化趋势,这要求多个领域的制造资源必须实施深度重组与优化配置,并且转型为一个高度集成化且各环节间紧密相连、相互依存的生态系统,其稳定性和抗风险能力研究至关重要^[1]。分散化的制造节点工时扰动是社群化制造中一种不可忽视的影响因素,设备故障、紧急插单、原材料短缺等原因而引发的工时变动会直接影响订单的交付周期^[2-5]。

针对多节点工时扰动的问题,需要引入联邦学习等分布式机器学习范式^[6],通过聚合在数据生成客户端本地训练的模型来学习全局模型^[7-8],主要的效率影响可归纳为通信、训练与安全隐私保护。借助联邦学习可打破数据孤岛,联合构建群智模型^[9];在多移动边缘节点上设备可共同训练机器学习模型^[10],缩短了数据处理计算节点与用户之间的距离,联合云计算技术,从用户处获取数据并进行本地训练^[11];云则聚合本地模型,实现数据隐私保护^[12-13]。Kong等^[14]提出了联邦学习框架,为中小企业的订单级风险评估提供了可能性;Rokoss等^[15]对比了不同算法模型对预测本身的影响;Abdollahi等^[16]提出了一种具有预测订单部分的时间窗口动态路由方法;文献^[17-18]提出了交付可靠性评估方法;Chu等^[19]研究了小批量订单锻造过程中生产计划与调度的集成;Ackermann等^[20]提出了一种离散时间混合整数线性公式,来解决批处理和调度问题。在韧性制造方面,位世云^[21]搭建分布式平台,设计了扰动特征表现形式,构建了车间扰动特征库;侯娅楠^[22]分析了工序间关联,提出了柔性调度的鲁棒性调度方法,制定了具有抗干扰能力的调度方案;刘道元等^[23]以特征选择算法预测订单剩余完工时间;顾松松^[24]以客户需求为中心,开发生产交付能力提升系统。综上,当前对工时扰动以及韧

性能力的研究大多是侧重于风险评估和工序调度方面:一方面,由于数据源不共享,难以实现多种扰动因素的数据收集;另一方面,对扰动分析的制造系统韧性能力难以预测。引入联邦学习与韧性能力相结合,可提高数据共享能力,结合算法可实现系统韧性能力的预测。

联邦小批量梯度下降(FedMBGD)算法是结合联邦批量梯度下降(FedBGD)算法和联邦随机梯度(FedSGD)算法下降这两者优点的一种经典联邦学习方法,本文基于工时扰动模型,研究了节点工时扰动对社群化制造韧性能力的影响,并提出了预测建模方法,采用联邦学习相关框架算法,进行多节点的本地数据分析和参数训练,揭示了工时扰动事件对社群化制造生产计划和资源调配的影响规律。

1 问题的描述

社群化制造背景下,为避免数据泄露,节点的模型训练需要在节点本地进行,之后上传模型更新参数,同时由于制造节点众多,在节点本地训练的模型也需考虑多节点模型聚合问题,因此如何完成制造节点的本地训练及各节点的全局聚合来预测整个订单的交付韧性能力,这是需要解决的难题。

社群化制造的韧性能力是指企业通过车间环境布局 and 快速响应机制,在遭受加工机器、约束条件异常等意外因素导致生产任务停止后,确保维持功能并快速恢复的综合能力。将韧性能力预测问题描述为一个六元组 $\{A, C, M, E, R, W\}$, $A = \{A_1, A_2, \dots, A_n\}$, 其中 A 表示任务集合, n 为任务数量; $C = \{C_1, C_2, \dots, C_q\}$, C 表示企业集合, q 为企业数量; $M = \{M_0, M_1, M_2, \dots, M_m\}$, M 表示加工机器集合, m 为加工工位数量; E 表示车间环境; R 表示约束条件的集合; W 表示目标函数的集合。将多参与者的社群化制造订单交付能力预测问题描述为 q 个参与

者有 n 个任务需要在 m 个工位上完成加工,每道工序都有一个预定的加工顺序,并且每道工序都有一个对应的加工机器集合和加工时间,进而通过整合工时数据完成交付能力的预测。

2 社群化制造节点的工时扰动模型

本文在面向社群化制造订单的基础上,采用联邦学习框架以及去中心化联邦学习算法进行韧性能力预测,如图1所示。首先,根据订单模式的特征需求,建立联邦学习网络模型,以实现多个参与者的本地数据训练和上传;其次,根据加工订单进行所需加工数据的采集与筛选,在本地进行数据训练处理,得到数据模型后上传至联邦学习聚合服务器;最后,服务器经过全局训练,得到全局模型后服务器进行广播,使得用户能够下载全局模型到本地,进行下一轮训练。当数据模型更新达到要求后,生成的全局模型即可完成生产交付周期的预测任务。




图1 基于联邦学习的韧性能力预测逻辑

Fig.1 Federated learning-based resilience capability prediction logic

2.1 基于工时延误的扰动分析

在加工过程中,产品生产通常会在执行过程中受到各种随机扰动的影响,例如原材料缺失、加工设

备故障、紧急订单或订单取消等,进而使得原生产过程不再可行,这时就需要重新分配任务,通过将某些工序的起始加工时间向后延迟最小时间量来响应扰动,最终交付时间则是以最新分配任务完成时间为准。基于此,给出生产受扰动重分配状态下的工序时间预测算法^[25],由于生产过程中机床故障类型的扰动频发,故采用机床故障来分析扰动的影响。机床故障对工序造成的影响可大致分为3种:①存在被中断工序,机床在工作进程中出现故障;②不存在被中断工序,机床在工作完成后出现故障,需修复后投入工作;③无影响工序,机床故障不影响工序进程。基于上述3种情况设计损失时间预测算法,步骤如下。

(1)设置 $i_P = 1, i_D = 1, T_{dev} = 0, P = \emptyset, D = \emptyset, j_T = m_T = 0$, 其中 P 为受扰动的工序集合, i_P 为集合 P 的索引, D 为重分配后受扰动的工序集合, i_D 为集合 D 的索引, T_{dev} 为原分配方案和新分配方案开始时间的偏移值。

(2)判断第一个受扰动的工序 $P[1], m_T = T_m, i_P + 1$ 。其中 m_T 为机床工序的开始加工时间, T_m 为机床可加工时间。

(3)当前工序 N_T 为最大值, $N_{ET} = N_T + T_{i_0}$, 其中 N_T 为新分配方案中工序的开始加工时间, N_{ET} 为新分配方案中工序的结束加工时间, T_{i_0} 为当前工序的工时。

(4)设置第 i_D 个受扰动的工序, $D[i_D]$ 为当前工序集合, $i_D + 1$ 。

(5) $T_j = T_{dev} + (N_{ET} - N_T)_{S[i]}$, T_j 为扰动后工序加工时间, S 为扰动发生时需重新调度的剩余工序集合。

(6)由工件的工艺路线获得工件的下一工序 j_{next} , 若 j_{next} 存在且其原分配方案中工序的开始加工时间 P_T 小于当前工序 N_{ET} , 则设置 $P[i_P] = j_{next}$, $P[i_P]$ 工件工序的开始加工时间 $j_T = N_{ET}, i_P + 1$ 。

(7)由原分配方案获得机床上的下一工序 m_{next} , 若 m_{next} 存在且其 P_T 小于当前工序 N_{ET} , 则设置 $P[i_P] = m_{next}$, $P[i_P]$ 机床工序的开始加工时间 $m_T = N_{ET}, i_P + 1$ 。

(8)从集合 P 中移除当前工序, 并加入步骤(6)、(7)中的新工序。

(9)如果 $P = \emptyset$, 结束, 输出交付时间 $T_s = T_j$; 否则, 从集合 P 中随机选择一个工序作为当前工序, 转到步骤(3)。

2.2 联邦学习网络模型搭建

去中心化联邦学习具有隐私保护和高通用性的优势,能有效提高企业间信息传递的效率,并避免节点依赖。假设联邦学习共有 q 个参与节点,节点 q_i 的本地数据集记为 $d_i \in D, d_i = \{(x_j^i, y_j^i)\}_{j=1}^{n_i}$,其中 $i \in \{0, 1, \dots, q-1, q\}$, n_i 为节点 q_i 的样本数, x 为样本, y 为因变量, $D = \{d_i\}_{i=1}^q$ 表示所有参与节点的数据总和。在第 m 轮通信过程中,节点 q_i 利用本地数据集 d_i 训练出一个本地模型 w_i^m , q_i 的优化目标是最小化本地损失 ζ_i^m ,即

$$\arg \min_{w_i^m} \frac{1}{n_i} \sum_{j=1}^{n_i} \zeta_i^m(x_j^i, y_j^i, w_i^m) \quad (1)$$

联邦学习的总目标是通过聚合服务端 w_i ,得到一个全局损失最小化的模型参数 w_g^* ,即

$$\arg \min_{w_g^*} \frac{1}{q} \sum_{i=1}^q \zeta_i^m = \frac{1}{N} \sum_{i=1}^q \sum_{j=1}^{n_i} \zeta_i^m(x_j^i, y_j^i, w_i^m) \quad (2)$$

在去中心化联邦学习中,每个训练节点的设备都使用本地数据进行模型训练,并将模型更新参数发送给周围的邻居设备。各个训练节点需要克服本地生产设备和供应链等多方面的扰动影响,建立完善的扰动模型从而准确地进行参数更新,这些邻居设备可以接受更新并根据自身的本地数据进行模型训练。该过程反复执行多次,直到所有设备的模型达到收敛状态。相较于其他的联邦学习方式,去中心化联邦学习不需要集中式服务器来协调设备之间的通信,因此极大地减少了通信开销和单点故障风险。

假设有 n 个设备共同参与联邦学习任务,目标是学习一个全局模型 θ ,使得每个设备 d 都能使用本地数据进行模型推理。在去中心化联邦学习中,首先每个设备都初始化一个本地模型 θ_d ,每一轮迭代由以下步骤组成:选择一个随机子集 $S_t \subseteq 1, 2, \dots, n$ 作为通信设备组;每个设备 $d \in S_t$ 使用本地数据计算梯度 $\nabla_{\theta_d} J(\theta_d)$,其中 $J(\theta_d)$ 是本地模型 θ_d 的损失函数;将梯度 $\nabla_{\theta_d} J(\theta_d)$ 发送给所有邻居设备 $j \in N_i$,其中 N_i 表示邻居设备集合;每个设备 d 更新本地模型 θ_d ,得到新模型 $\theta_d^{t+1} = \theta_d^t - \eta \frac{1}{|S_t|} \sum_{j \in S_t} \nabla_{\theta_j} J(\theta_j)$,其中 η 为学习率;直到所有设备的模型 $\theta_1^{t+1}, \theta_2^{t+1}, \dots, \theta_n^{t+1}$ 均更新完毕,进行下一轮迭代。

2.3 面向订单交付周期的目标函数

面向订单交付周期的计算流程如图2所示。




图2 交付周期的计算流程

Fig. 2 Calculation process for delivery cycle

交付能力预测的主要目标为交付时间精确性,即预测交付时间与实际交付时间的差值最小,可以表示为

$$W = \omega_1 \Delta T + \omega_2 \lambda \quad (3)$$

$$\Delta T = \left| \sum_{k=1}^n \sum_{i=1}^{m_k} T_{pi}^k - T_a \right| \quad (4)$$

$$T_a = \sum_{k=1}^n \sum_{i=1}^{m_k} T_{oi}^k + T_t \quad (5)$$

$$\lambda = \frac{T_c + T_s}{T_a} \times 100\% \quad (6)$$

式中: W 为交付预测精确率; ω_1, ω_2 为目标权重; ΔT 为预测工时与实际工时的差值; λ 为设备故障率; m_k 为第 k 个参与方拥有的样本数; $\sum_{k=1}^n m_k = m$; T_{pi}^k 为第 k 个参与方中第 i 个工序的工时预测值; T_a 为实际生产的总工时; T_{oi}^k 为第 k 个参与方中第 i 个工序的标准工时; T_t 为运输时间; T_c 为停机等待时间; T_s 为维修时间。

计算实际生产的总工时需要用工序标准工时 T_0 ,计算式为

$$T_0 = t_0(1 + \omega)(1 + \delta) \quad (7)$$

式中: t_0 为工序操作的实际观测时间; ω 为评比系数,起调节作用,规定为一个上下差值; δ 为宽放率,一般分为生理宽放、疲劳宽放、异常宽放和管理宽放等。

将式(4)~(7)代入式(3),得目标函数

$$W = \omega_1 \left| \frac{\sum_{k=1}^n \sum_{i=1}^{m_k} T_{pi}^k - \left(\sum_{k=1}^n \sum_{i=1}^{m_k} T_{oi}^k + T_t \right)}{\sum_{k=1}^n \sum_{i=1}^{m_k} T_{oi}^k + T} \right| \times 100\% + \omega_2 \left(\frac{T_c + T_s}{T_a} \times 100\% \right) \quad (8)$$

3 基于梯度下降算法的韧性能力预测

3.1 联邦小批量梯度下降算法

梯度下降是一种迭代优化算法,其工作原理是通过计算损失函数的梯度,然后按梯度的负方向更新参数,逐步优化参数,使得损失函数的值不断减小,最终达到一个局部最小值。采用介于随机梯度、批量梯度下降之间的小批量梯度下降,在算法的每一步,从 m 个样本的训练集中随机抽出一小批量(mini-batch)样本 $(x^{(1)}, x^{(2)}, \dots, x^{(m')})$ 。小批量的数目 m' 通常是一个相对较小的数,当训练集大小 m 增长时, m' 通常是固定的,而在拟合几十亿的样本时,每次更新计算只用到几百个样本。

在梯度下降初期,能接受较大的步长(学习率),以较快的速度进行梯度下降;当收敛时,希望步长小一点,并且在最小值附近小幅摆动。假设模型已经接近梯度较小的区域,若保持原来的学习率,只能是最优点附近徘徊。如果降低学习率,目标函数能够进一步降低,有助于算法的收敛,更容易接近最优解。算法步骤如下:随机初始化模型参数 θ ,设置学习率 η ,设置迭代次数 N_i ;对于每个 $i \in [1, N_i]$,随机选择一个样本 (X_i, y_i) ;计算当前样本的损失函数 $\nabla L(\theta) = 2(X_i\theta - y_i)X_i$;更新模型参数 $\theta' = \theta - \eta \nabla L(\theta)$;返回最终学习的模型参数 θ' 。

3.2 算法流程设计

根据联邦学习的分布式特性以及企业生产数据的相关性,采用本地数据计算梯度下降的方法来解决回归方程。算法流程如图 3 所示。




图 3 交付能力回归算法求解流程图

Fig. 3 Flowchart of delivery capacity regression algorithm solution

对于每个设备 $d \in S_i (S_i \subseteq 1, 2, \dots, n)$, 算法从训练数据集中随机抽取样本 x_i , 有

$$x_i = [x_0, x_1, \dots, x_n], i \in [1, n], x_0 = 1 \quad (9)$$

构建各变量数据集

$$\begin{cases} \mathbf{X} = [x_1, x_2, \dots, x_m]^T \\ \mathbf{y} = [y_1, y_2, \dots, y_m]^T \end{cases} \quad (10)$$

式中: $\mathbf{X}$ 为训练数据集; $\mathbf{y}$ 为因变量。

样本损失函数为

$$J(\mathbf{w}) = \frac{1}{2m} \sum_{i=1}^{m_k} (y_i - x_i \mathbf{w})^2 \quad (11)$$

式中: $\mathbf{w}$ 为回归系数矩阵; m 为样本数; n 为特征数; x_i 为第 i 个样本特征值集合。

通过计算损失函数对模型参数的梯度,沿着梯度方向更新参数以最小化损失,逐步逼近最优解。损失函数 $J(\mathbf{w})$ 的梯度为

$$\frac{\partial J(\mathbf{w})}{\partial w_j} = \frac{1}{m} \sum_{i=1}^{m_k} x_{ij} (x_i \mathbf{w} - y_i) \quad (12)$$

为使全局更新方向更接近所有数据联合训练的结果,需聚合多个客户端的梯度,则整个样本的梯度为

$$\nabla_{\theta_i} J(\mathbf{w}) = \begin{bmatrix} \frac{\partial J(\mathbf{w})}{\partial w_0} \\ \frac{\partial J(\mathbf{w})}{\partial w_1} \\ \vdots \\ \frac{\partial J(\mathbf{w})}{\partial w_n} \end{bmatrix} = \begin{bmatrix} \frac{1}{m} \sum_{i=1}^{m_k} x_{i0} (x_i \mathbf{w} - y_i) \\ \frac{1}{m} \sum_{i=1}^{m_k} x_{i1} (x_i \mathbf{w} - y_i) \\ \vdots \\ \frac{1}{m} \sum_{i=1}^{m_k} x_{in} (x_i \mathbf{w} - y_i) \end{bmatrix} =$$

$$\begin{bmatrix} \frac{1}{m} \mathbf{X}[:, 0]^T (\mathbf{X} \mathbf{w} - \mathbf{y}) \\ \frac{1}{m} \mathbf{X}[:, 1]^T (\mathbf{X} \mathbf{w} - \mathbf{y}) \\ \vdots \\ \frac{1}{m} \mathbf{X}[:, n]^T (\mathbf{X} \mathbf{w} - \mathbf{y}) \end{bmatrix} = \frac{1}{m} \mathbf{X}^T (\mathbf{X} \mathbf{w} - \mathbf{y}) \quad (13)$$

本地模型迭代完成后,设备将梯度 $\nabla_{\theta_d} J(\theta_d)$ 发送给所有邻居设备 $j \in N_d$, 即

$$\mathbf{w}' = \mathbf{w} - \eta \nabla_{\theta_d} J(\mathbf{w}) \quad (14)$$

对回归系数中 $\mathbf{w}$ 的每个元素分别求偏导乘以学习率 η ,迭代更新 $\mathbf{w}$,直到迭代次数达到最大值或参数集合内的数值更新前后无明显变化时停止迭代,此时 $\mathbf{w}$ 即为最优解。

4 案例分析

4.1 数据采集与分析

将某企业采集到的数据分为两部分,70%为训练联邦学习所用数据集,30%为验证数据集,通过验证该部分加工数据输入模型后生成的预计完工时间与该订单实际完成时间是否相符或接近,来判断模型的有效性。

表 1 企业 A 生产现场加工工时数据

Table 1 Machining work-hour data at company A's production site

工序	5 次工序观测时间/s					平均值/s	工序标准工时/s
	1	2	3	4	5		
T1	235	242	238	243	238	239	258
T2	238	236	242	243	240	239	259
T3	298	296	301	305	298	299	324
T4	502	496	501	502	497	499	540
T5	198	201	200	197	205	200	216
T6	242	239	236	241	245	240	260

表 2 机床加工数据分析

Table 2 Machine tool machining data analysis

机床	故障率 $\lambda/\%$	T_m/h	T_{dev}/h
M1	2	4.31	0.18
M2	3	4.32	0.20
M3	1	5.40	0.05
M4	2	9.01	0.13
M5	4	3.61	0.23
M6	3	4.34	0.17

4.2 实验结果

预测精确度是衡量模型预测结果与真实值之间

在交付周期的目标函数中,以加工工时数据来进行案例验证,表 1 所示为企业 A 的生产现场加工工时数据的采集。记评比系数为 0.05,宽放率为 3%。采集生产过程中加工机床的工作时间及工作状态等加工信息如表 2 所示。故障率较低的机床设备的 T_{dev} 更小,且故障率 λ 、 T_{dev} 呈正相关性,表明故障率对节点工时扰动影响较大。

一致性的指标,是预测模型对实际数据的拟合程度,预测精确度越高,表示模型的预测值与真实值之间的差异越小。梯度下降算法通过最小化损失函数来优化模型参数,从而提高模型的预测精确度。为了评估该算法在扰动情况下的有效性,在联邦学习架构中,采用本地小批量随机梯度下降的方法求解回归方程,进而求解出预测的订单进度信息,与实际加工进度信息进行对比,得出预测精确度。使用 FedSGD、FedBGD 两种算法进行对比,图 4~图 6 为不同算法模型对订单进度的预测精确度。




图 4 FedSGD 算法预测与实际结果的对比

Fig. 4 Comparison of FedSGD projections and actual results




图 5 FedBGD 算法预测与实际结果的对比

Fig. 5 Comparison of FedBGD projections and actual results





图 6 FedMBGD 算法预测与实际结果对比

Fig. 6 Comparison of FedMBGD projections and actual results

对比图 4~图 6,可以看到 3 种算法的最值较为相近。从预测值和实际值的相合程度来看,由于 FedSGD 算法噪声较 BGD 要多,SGD 并不是每次迭代都接近整体最优化方向,预测结果准确度不高,预测和实际加工进度的数据相差较大;FedBGD 算法的一次迭代是对所有样本进行计算,因此预测准确度更高,但当样本数据集过大时会影响训练时间;FedMBGD 算法综合了上述两种算法,每次使用一批量可以大大减小收敛所需迭代数,同时可以使收敛结果更加接近梯度下降的效果,所以其预测结果相比 FedBGD 算法更加准确、快速。

不同算法在训练中的丢失率和精度如图 7 所示。从图 7 可知,当训练轮数逐渐增大时,算法训练丢失率的曲线逐渐下降,算法训练精度的曲线逐渐上升,且在 10 轮之前下降幅度较高,而代表 FedMBGD 算法的训练丢失率曲线下降最多,虽略有起伏但绝大部分位于其他两种算法之下。在前 30 轮训练中,FedMBGD 算法由于学习率的衰减,其训练精度明显比 FedBGD、FedSGD 算法高,训练丢失率较低;30 轮之后, FedSGD 算法迭代次数较多,精度较差, FedBGD、FedMBGD 算法的训练精度相差很小;当 40 轮以上时, FedBGD、FedMBGD 算法的训练丢失相差非常小,且都小于 FedSGD 算法。因此, FedMBGD 算法在迭代过程中的训练数据丢失更少,精度更高,能更好地应用于实际。



(b)不同算法的训练精度

图 7 不同算法的训练丢失率和训练精度

Fig. 7 Training loss and accuracy of different algorithms


5 结 论

韧性能力预测不仅能为企业防止供应链断链现象的发生提供预测方法、实现高效管理、增强企业竞争力,还能为内部隐私数据的算法训练和参数上传及共享提供指导意义。

(1)本文搭建了面向社群化制造的联邦学习网络环境平台,各本地节点以全局损失最小化为目标进行本地参数优化,实现了订单交付周期的多节点参与预测。

(2)针对生产过程中出现的众多扰动因素对工序加工的影响问题,以机床故障率为主要扰动因素,建立了工时扰动模型,来计算损失时间。分析了机床故障导致的 3 种工序中断类型,并设计损失时间预测算法,来计算机床故障引发的工序时间偏移。

(3)针对各个训练节点进行韧性能力预测的求解难题,提出了一种联邦学习梯度下降算法进行求解。设计了小批量梯度下降方式和算法流程,引入学习率,提高了算法的收敛性和全局寻优能力。与 FedSGD、FedBGD 算法的优化结果相比,所提 FedMBGD 算法性可将预测精确度提高至 90% 以上,最高训练精确度可达 0.925 5。



(a)不同算法的训练丢失率

参考文献:

- [1] LENG Jiewu, ZHONG Yuanwei, LIN Zisheng, et al. Towards resilience in Industry 5.0: a decentralized autonomous manufacturing paradigm [J]. Journal of Manufacturing Systems, 2023, 71: 95-114.
- [2] 于成龙, 侯俊杰, 蒲洪波, 等. 基于数据挖掘的机加工生产进度预测方法 [J]. 现代制造工程, 2020(2): 34-41.
YU Chenglong, HOU Junjie, PU Hongbo, et al. Forecasting method of machine work schedule based on data mining [J]. Modern Manufacturing Engineering, 2020(2): 34-41.
- [3] 魏法杰, 都本正, 田爽, 等. 多品种小批量物料采购延迟交付预测 [J]. 北京航空航天大学学报(社会科学版), 2018, 31(3): 78-83.
WEI Fajie, DU Benzhen, TIAN Shuang, et al. Prediction of material procurement delays in delivery for multi-variety and small batch manufacturing [J]. Journal of Beijing University of Aeronautics and Astronautics(Social Sciences Edition), 2018, 31(3): 78-83.
- [4] 彭锦永. 基于汽车行业整车订单交付时间优化方法研究 [D]. 广州: 华南理工大学, 2018.
- [5] 温兴漳, 任卓明. 基于区域配送中心时空特征预测电子商务平台订单交付时长 [J/OL]. 运筹与管理. (2022-10-09)[2024-12-12]. <http://kns.cnki.net/kcms/detail/34.1133.G3.20221009.0915.002.html>.
WEN Xingzhang, REN Zhuoming. Predicting the order delivery time of E-commerce platform based on the temporal and spatial features of regional distribution center [J/OL]. Operations Research and Management Science. (2022-10-09)[2024-12-12]. <http://kns.cnki.net/kcms/detail/34.1133.G3.20221009.0915.002.html>.
- [6] 肖雄, 唐卓, 肖斌, 等. 联邦学习的隐私保护与安全防御研究综述 [J]. 计算机学报, 2023, 46(5): 1019-1044.
XIAO Xiong, TANG Zhuo, XIAO Bin, et al. A survey on privacy and security issues in federated learning [J]. Chinese Journal of Computers, 2023, 46(5): 1019-1044.
- [7] 王健宗, 孔令炜, 黄章成, 等. 联邦学习算法综述 [J]. 大数据, 2020, 6(6): 64-82.
WANG Jianzong, KONG Lingwei, HUANG Zhangcheng, et al. Research review of federated learning algorithms [J]. Big Data Research, 2020, 6(6): 64-82.
- [8] 梁天恺, 曾碧, 陈光. 联邦学习综述: 概念、技术、应用与挑战 [J]. 计算机应用, 2022, 42(12): 3651-3662.
LIANG Tiankai, ZENG Bi, CHEN Guang. Federated learning survey: concepts, technologies, applications and challenges [J]. Journal of Computer Applications, 2022, 42(12): 3651-3662.
- [9] 杨强, 童咏昕, 王晏晟, 等. 群体智能中的联邦学习算法综述 [J]. 智能科学与技术学报, 2022, 4(1): 27-44.
YANG Qiang, TONG Yongxin, WANG Yansheng, et al. A survey on federated learning in crowd intelligence [J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(1): 27-44.
- [10] 张雪晴, 刘延伟, 刘金霞, 等. 面向边缘智能的联邦学习综述 [J]. 计算机研究与发展, 2023, 60(6): 1276-1295.
ZHANG Xueqing, LIU Yanwei, LIU Jinxia, et al. An overview of federated learning in edge intelligence [J]. Journal of Computer Research and Development, 2023, 60(6): 1276-1295.
- [11] 刘庆祥, 许小龙, 张旭云, 等. 基于联邦学习的边缘智能协同计算与隐私保护方法 [J]. 计算机集成制造系统, 2021, 27(9): 2604-2610.
LIU Qingxiang, XU Xiaolong, ZHANG Xuyun, et al. Federated learning based method for intelligent computing with privacy preserving in edge computing [J]. Computer Integrated Manufacturing Systems, 2021, 27(9): 2604-2610.
- [12] ZHU Konglin, CHEN Wentao, JIAO Lei, et al. On-line training data acquisition for federated learning in cloud-edge networks [J]. Computer Networks, 2023, 223: 109556.
- [13] 李少波, 杨磊, 李传江, 等. 联邦学习概述: 技术、应用及未来 [J]. 计算机集成制造系统, 2022, 28(7): 2119-2138.
LI Shaobo, YANG Lei, LI Chuanjiang, et al. Overview of federated learning: technology, applications and future [J]. Computer Integrated Manufacturing Systems, 2022, 28(7): 2119-2138.
- [14] KONG Lingxuan, ZHENG Ge, BRINTRUP A. A federated machine learning approach for order-level risk prediction in Supply Chain Financing [J]. International Journal of Production Economics, 2023, 268: 109095.
- [15] ROKOSS A, POPKES L, SCHMIDT M. Analysis of the relevance of models, influencing factors and the point in time of the forecast on the prediction quality in order-related delivery time determination using machine learning [C]//6th Conference on Production Systems and Logistics. Hannover, Germany: Publish-Ing, 2024: 415-431.

[16] ABDOLLAHI M, YANG Xinan, NASRI M I, et al. Demand management in time-slotted last-mile delivery via dynamic routing with forecast orders [J]. European Journal of Operational Research, 2023, 309 (2): 704-718.

[17] GAJEWSKA T, KACZOR G, SZKODA M. Forecasting of warranty returns based on the reliability of delivery assessment [J]. Technical Gazette, 2021, 28 (3): 994-999.

[18] MATSUOKA R, KOBAYASHI K, YAMASHITA Y. Online optimization of pickup and delivery problem considering demand forecasting [C]//2023 IEEE 12th Global Conference on Consumer Electronics (GCCE). Piscataway, NJ, USA: IEEE, 2023: 879-880.

[19] CHU Hongyan, DONG Ke, LI Rui, et al. Integrated modeling and optimization of production planning and scheduling in hybrid flow shop for order production mode [J]. Computers & Industrial Engineering, 2022, 174: 108741.

[20] ACKERMANN S, FUMERO Y, MONTAGNA J M. Taking advantage of order consolidation in simultaneous batching and scheduling of multiproduct batch plants [J]. Computers & Chemical Engineering, 2022, 156: 107564.

[21] 位世云. 基于数字孪生的智能车间动态生产过程扰动识别方法研究 [D]. 济南: 山东大学, 2023.

[22] 侯娅楠. 机器故障下基于工序关系网络的柔性作业车间鲁棒性调度研究 [D]. 乌鲁木齐: 新疆大学, 2020.

[23] 刘道元, 郭宇, 黄少华, 等. 一种面向订单剩余完工时间预测的 SOM-FWFCM 特征选择算法 [J]. 中国机械工程, 2021, 32(9): 1073-1079.

[24] 顾松松. 具备客户需求预测的生产交付能力提升系统的设计与实现 [D]. 重庆: 重庆大学, 2019.

[25] 周亚勤, 李蓓智, 杨建国, 等. 响应随机扰动的受影响工序重调度方法研究 [J]. 制造技术与机床, 2013 (4): 105-108.

[26] ZHOU Yaqin, LI Beizhi, YANG Jianguo, et al. Study on an affected operations rescheduling method responding to stochastic disturbances [J]. Manufacturing Technology & Machine Tool, 2013(4): 105-108.

(编辑 赵炜)