

6-28-2024

## Just-in-time Learning Energy Consumption Predictive Modeling Method in Multi-condition Production Process

Sheng Wei

*School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China, 2872704033@qq.com*

Yan Wang

*School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China, wangyan88@jiangnan.edu.cn*

Zhicheng Ji

*School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact [xtfzxb@126.com](mailto:xtfzxb@126.com).

---

# Just-in-time Learning Energy Consumption Predictive Modeling Method in Multi-condition Production Process

## Abstract

**Abstract:** Aiming at the problem that the global energy consumption prediction model is only suitable for part of the prediction sample and the model is computationally intensive, the idea of just-in-time learning is introduced, and the local weighted partial least squares method combined with the energy consumption model is used to establish a temporary local energy consumption prediction model. The inertia weights of the particle swarm algorithm are improved, considering the effects of particle fitness, number of iterations and population size on the convergence speed and convergence accuracy of the particle swarm algorithm, a nonlinear change adaptive inertia weight strategy is proposed, and the improved adaptive PSO(APSO) is used to optimize the bandwidth parameters of historical samples in the offline computing stage, then the local model is updated online when the predicted samples are available. Considering the prediction error caused by the different energy consumption of the samples under different working conditions in multi-working condition production scenarios, and increasing the measurement process of working condition similarity, an APSO-JITL-CLWPLS energy consumption prediction modeling method combining local weighted partial least squares algorithm and K-means algorithm is proposed, and the bandwidth parameters of the predicted samples are designed by selecting the historical samples of the same working conditions during prediction. Simulation experiments show that the algorithm has higher prediction accuracy and can better cope with the multi-working production scenarios.

## Keywords

just-in-time learning, locally weighted partial least squares, clustering, online modeling, multi-working conditions, bandwidth parameters, energy consumption

## Recommended Citation

Wei Sheng, Wang Yan, Ji Zhicheng. Just-in-time Learning Energy Consumption Predictive Modeling Method in Multi-condition Production Process[J]. Journal of System Simulation, 2024, 36(6): 1378-1391.

# 多工况生产过程下的即时学习能耗预测建模方法

卫升, 王艳\*, 纪志成

(江南大学 物联网工程学院, 江苏 无锡 214122)

**摘要:** 针对全局能耗预测模型只适用于部分预测样本且模型计算量大的问题, 引入即时学习思想, 采用局部加权偏最小二乘法结合能耗模型建立临时局部能耗预测模型; 改进粒子群算法的惯性权重, 考虑粒子适应度、迭代次数和种群大小对粒子群算法收敛速度和收敛精度的影响, 提出一种非线性变化的自适应惯性权重策略, 离线计算阶段使用改进的粒子群算法(*adaptive PSO*, *APSO*)对历史样本的带宽参数进行寻优, 当预测样本到来时在线更新局部模型。考虑多工况生产场景下不同工况样本之间的能耗差异性所导致的预测误差, 增加工况相似性度量过程, 提出局部加权偏最小二乘算法与 *K-means* 算法相结合的 *APSO-JITL (just-in-time learning)-CLWPLS (cluster locally weighted partial least squares)* 能耗预测建模方法, 在预测时选取同一工况的历史样本来设计预测样本的带宽参数。通过仿真实验验证了算法有着更高的预测精度且能更好地应对多工况生产场景。

**关键词:** 即时学习; 局部加权偏最小二乘; 聚类; 在线建模; 多工况; 带宽参数; 能耗

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2024)06-1378-14

DOI: 10.16182/j.issn1004731x.joss.23-0167

**引用格式:** 卫升, 王艳, 纪志成. 多工况生产过程下的即时学习能耗预测建模方法[J]. 系统仿真学报, 2024, 36(6): 1378-1391.

**Reference format:** Wei Sheng, Wang Yan, Ji Zhicheng. Just-in-time Learning Energy Consumption Predictive Modeling Method in Multi-condition Production Process[J]. Journal of System Simulation, 2024, 36(6): 1378-1391.

## Just-in-time Learning Energy Consumption Predictive Modeling Method in Multi-condition Production Process

Wei Sheng, Wang Yan\*, Ji Zhicheng

(School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

**Abstract:** Aiming at the problem that the global energy consumption prediction model is only suitable for part of the prediction sample and the model is computationally intensive, the idea of just-in-time learning is introduced, and the local weighted partial least squares method combined with the energy consumption model is used to establish a temporary local energy consumption prediction model. The inertia weights of the particle swarm algorithm are improved, considering the effects of particle fitness, number of iterations and population size on the convergence speed and convergence accuracy of the particle swarm algorithm, a nonlinear change adaptive inertia weight strategy is proposed, and the improved adaptive PSO(*APSO*) is used to optimize the bandwidth parameters of historical samples in the offline computing stage, then the local model is updated online when the predicted samples are available. Considering the prediction error caused by the different energy consumption of the samples under different working

收稿日期: 2023-02-20 修回日期: 2023-04-12

基金项目: 国家自然科学基金(61973138)

第一作者: 卫升(1998-), 男, 硕士生, 研究方向为离散制造系统能耗预测。E-mail: 2872704033@qq.com

通讯作者: 王艳(1978-), 女, 教授, 博导, 博士, 研究方向为网络化系统、智能产线能耗优化控制。E-mail: wangyan88@jiangnan.edu.cn

conditions in multi-working condition production scenarios, and increasing the measurement process of working condition similarity, an APSO-JITL-CLWPLS energy consumption prediction modeling method combining local weighted partial least squares algorithm and K-means algorithm is proposed, and the bandwidth parameters of the predicted samples are designed by selecting the historical samples of the same working conditions during prediction. Simulation experiments show that the algorithm has higher prediction accuracy and can better cope with the multi-working production scenarios.

**Keywords:** just-in-time learning; locally weighted partial least squares; clustering; online modeling; multi-working conditions; bandwidth parameters; energy consumption

## 0 引言

工业4.0时代以来,制造业在飞速发展的同时对能源的消耗也在日益增加,世界各地越来越重视工业生产过程的能耗问题。为了节省生产过程中的能耗,减少环境污染,需要建立准确而高效的能耗预测模型来控制生产的能耗。

然而,航空航天、汽车制造、金属加工、电子组装等离散制造产业的生产过程往往具有复杂性,且由于其过程由多个零件加工的子过程串联或者并联组成,包含着许多变化和不确定性,给生产能耗的预测带来了极大的困难。世界各地的专家对能耗预测做出了大量的研究,其中最直接的预测方法就是机理建模。该方法需要对生产过程的机理有着较深的掌握,能够充分利用质量守恒定律、能量守恒定律等先验知识,通过微分方程、差分方程等形式来建立可以精确反应生产过程输入和输出之间关系的数学模型,从而来预测生产过程的能耗。文献[1]分析了CNC车床车削钢材时材料去除率对能耗的依赖性,并通过这种依赖性的改进经验模型建立了由切削参数表示的直接能耗模型;文献[2]根据能量需求的不同特征,将加工过程分解为活动和活动转换,分别建立了活动和活动转变的能量消耗模型,提出了系统在整个加工过程中反映不同加工状态的能耗模型;文献[3]以永磁同步发电机转子角速度作为状态变量建立了一阶微分状态方程来描述微型燃气轮机发电系统的动态特性。上述方法所及,机理建模方法可以用来较好地预测简单工序的能量消耗,但对于存在频繁不确定性和动态干扰的

全局生产系统而言,基于机理建模预测能耗则难以达到满意的精度。

物联网技术的广泛应用,使得生产数据的实时获取成为可能,基于数据驱动<sup>[4-5]</sup>的能耗预测方法得到了关注。数据驱动的建模方法也被称为“黑箱建模”,其摆脱机理建模的局限性,利用系统的历史数据就能建立预测模型,建模成本低且准确度高。文献[6]利用改进的正余弦优化算法对长短期记忆网络中的超参数进行优化,提出了用于建筑能耗预测的ISCOA-LSTM模型;文献[7]利用CNN良好的特征提取能力与RNN良好的时序学习能力,提出用于预测办公建筑能耗的CNN-RNN组合模型;文献[8]应用基于DP的聚类方法拟合聚类中心以处理非线性,并用改进的Levenberg-Marquardt算法对提取的模糊规则的参数进行微调,提出一种基于密度峰的自适应模糊神经网络对污水处理过程的能耗进行预测。基于数据驱动的能耗预测模型因其简便的建模思路和原理常用于工业生产过程的能耗预测,但该方法基于全部的历史数据进行建模,工业生产所产生的数据量往往是十分庞大且分布不均衡的,随着数据量的增多模型的计算量也会大大增加。基于历史数据建模是一种离线训练方式,模型的结构和参数是固定的,而工业过程往往是多种工况的数据并存,基于全局的预测模型无法对所有的数据都保持良好的预测精度。

即时学习(just-in-time learning, JITL)<sup>[9]</sup>作为一种在线预测策略也被广泛用于预测能耗,其在预测样本到来时才选取合适的样本建立模型进行预

测,等到下一个预测样本到来时再建立新的模型。该方法的主要思想来源于数据库技术和局部建模思想,也被称为惰性学习<sup>[10]</sup>、局部加权学习<sup>[10]</sup>。文献[11]针对流程工业数据的非线性和时变性提出基于时空相似性的即时学习在线建模方法,并将所提算法应用于聚酯纤维聚合过程的聚合物特性粘度预测;文献[12]针对转炉炼钢生产过程数据高维、非线性等特性,基于即时学习思想实现了样本标签、方向和距离三者信息融合的一种新型CJS(cosine similarity and jensen shannon divergence)相似性度量策略,提出一种CJS-SLLE(supervised local linear embedding)降维算法用于过程数据的监督降维,并对转炉炼钢终点碳温进行了预测;文献[13]针对不同相似性度量策略的局限性,提出使用不同相似性度量准则的集成学习框架,通过集成策略对各个局部模型进行预测输出,并将该方法用于预测高炉炼铁的铁水质量。局部建模思想已被广泛应用于质量预测、参数估计、模式识别等领域,建模样本的选择是局部建模思想的核心,其没有特定的规范,需要根据不同的预测需求设计建模样本的选取原则。

本文分析了离散制造系统的能耗特性,针对离散制造系统的多工况问题提出了一种APSO-JITL-CLWPLS(locally-weight PLS)算法,采用基于即时学习的局部加权偏最小二乘算法<sup>[14]</sup>来建立预测模型,并采用改进的自适应粒子群算法对预测模型中的带宽参数进行优化。同时,针对多工况离散加工过程,本文使用k-means聚类算法将训练样本进行工况分类,在预测时增加工况相似性度量过程。

## 1 离散加工过程能耗模型

离散加工系统的基本组成要素为生产环境、加工设备、生产对象和管理者,存在着多样的加工任务、功能不同的加工设备、因人而异的调度方案等影响因素,是一个具有不确定性、复杂性的加工系统,为了建立准确的能耗模型,需要对离散加工系

统的层次结构和能量体系进行全面的研究所。

### 1.1 设备能耗分析

离散加工系统由不同层次的加工子过程组成,不同子过程之间的能耗相互独立。按照工艺流程可以将离散加工过程分为产品层、零件层、工序层和工步层。一个产品的整个加工过程最后都可以分解为不同的工步,各个工步的能耗以及调度所产生的能耗组成了整个离散加工系统的能量体系<sup>[15]</sup>。假设车间需生产的产品数量为 $m$ ,  $N_i(0 < i \leq m)$ 为第 $i$ 件产品的零件数量,则设备的工步层能耗定义为每一个工步都可以分为启动、待机、空载和运行4个阶段。

(1) 启动阶段能耗:设备开机时所消耗的能量,该阶段加工设备的功率会快速上升然后回落,是一个时间很短的非线性过程,其能耗为

$$E_{sta} = \int_0^{t_{sta}} P_{sta} dt \quad (1)$$

式中: $P_{sta}$ 为设备启动功率,为已知值; $t_{sta}$ 为设备启动时间。

(2) 待机阶段能耗:该阶段为设备开机或者工件更换后还未放入加工工件的阶段,该阶段设备只维持如显示屏等基本功能所需要的能量,该阶段能耗为

$$E_{std} = P_{std} t_{std} \quad (2)$$

式中: $P_{std}$ 为设备待机功率,是一个常量值; $t_{std}$ 为设备待机时长。

(3) 空载阶段能耗:载入加工工件后还没有开始进行加工的阶段,该阶段维持工件的基本运作,能耗为

$$E_{id} = P_{id} t_{id} \quad (3)$$

式中: $P_{id}$ 为设备空载功率,是常量值; $t_{id}$ 为设备空载时长。

(4) 运行阶段能耗:设备开始加工工件,此时设备的能耗受加工工艺参数、工件尺寸大小等多种因素的影响,该阶段的能耗是工步层的主要能耗,定义该阶段的能耗为 $E_c$ ,则工步层的能耗为

$$E_S = E_{sta} + E_{std} + E_{id} + E_c \quad (4)$$



多个工步组成如铣、削、磨等的一道工序, 多道工序加工一个零件, 而多个零件则组装成最终的产品。整个加工系统的能耗由工步层向上逐层累加, 而在各层次之间如运输、零件清洗上漆、辅助设备能耗在整个能量系统中的占比较少, 因此, 本文不考虑这些额外能耗。

经上述分析, 第*i*件产品生产过程的能耗模型为

$$E_{\text{pro},i} = \sum_{j=1}^{N_i} \sum_{k=1}^{N_{jk}} E_s \quad (5)$$

式中:  $N_{jk}$  为第*i*件产品第*j*个零件第*k*道工序的工步数;  $N_{ij}$  为第*i*件产品第*j*个零件的工序数。

## 1.2 设备能耗影响因素

离散加工系统的能耗可以分为设备生产和调度两部分, 当系统的调度方案确定以后, 各层级的诸如运输能耗和辅助设备能耗都可以直接获得, 同时设备在启动阶段、待机阶段和空载阶段的能耗也可以直接获得, 因此, 影响系统总能耗的主要因素是设备运行阶段的能耗。以DYNA DM4600 切削数控机床为例, 机床运行时的功率  $P_c$  由切削速度  $v(\text{m/min})$ 、切削深度  $d(\text{mm})$ 、每齿进给量  $f_t(\text{mm/t})$ 、切削力  $F(\text{N})$ , 以及表面粗糙度  $R(\mu\text{m})$  等工艺参数决定, 机床运行时能耗为

$$E_c = f(v, d, f_t, F, R) \quad (6)$$

式中:  $f(v, d, f_t, F, R)$  为切削过程工艺参数和设备运行时能耗之间的关系式。

本文在确定调度方案, 已知调度能耗和设备其他能耗的基础上, 将设备运行阶段的能耗作为影响系统总能耗的主要因素, 同时将工艺参数作为模型的输入变量来预测 DYNA DM4600 机床切削铸钢 ZG55 时的设备能耗。

## 1.3 多工况问题描述

离散加工系统的多工况问题指系统的能耗数据库中会包含加工设备在不同工作状态下的能耗数据, 而不同工况数据之间的能耗差异性会对预测模型的输出有很大的影响。

全局建模方式是将所有的历史样本都用来建模, 这样必然会使建模样本中包含不同工况之间的数据样本进而影响预测模型的精度。而局部建模方式会对建模样本进行筛选, 如图1所示, 一般的局部建模方式基于距离、角度等度量方式选取建模样本而忽略了工况差异性对模型精度的影响, 因此, 本文在局部建模思想的基础上, 针对多工况问题将历史样本进行分类, 在选取建模样本时增加工况相似性度量过程, 选取与预测样本具有相同能耗特性的工况数据建立预测模型, 提高模型预测精度。

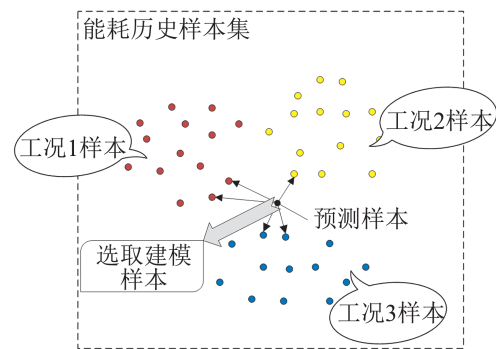


图1 离散加工过程多工况预测问题

Fig. 1 Multi-condition prediction problems in discrete machining processes

## 2 基于JITL的多工况能耗预测

### 2.1 预测目标

由离散加工过程的设备能耗模型可知整个加工系统的能耗以加工过程中每一个工步的能耗为基本组成单位, 因此, 本文以工步层的能耗为预测目标来预测产品整个加工过程的能耗。

### 2.2 JITL建模

JITL建模<sup>[16]</sup>是一种在线局部建模方式, 将历史数据储存在数据库中, 在预测数据样本点到来时根据相似度来选择合适的历史样本建立预测模型。同时在预测完毕后下一个预测样本数据到来时抛弃当前模型, 选择新的样本数据进行建模。在JITL建模中最关键的参数是带宽参数, 该参数决定着建模时所选用的样本规模, 即选择与预测样本在多大的

相似范围内的样本来建立模型。带宽参数的选择会对预测结果的准确性有着很大的影响。

图2为全局建模和JITL建模的区别，相比于全局建模，局部建模有以下优点：

(1) 每次只选择与预测样本相似度高的样本来建立模型，既保证了准确性，又能极大地简化过程和运算。

(2) 每次在预测完之后马上抛弃预测模型，等到新预测样本到来时重新选取样本建立新的模型，保证模型的时效性和适用性。

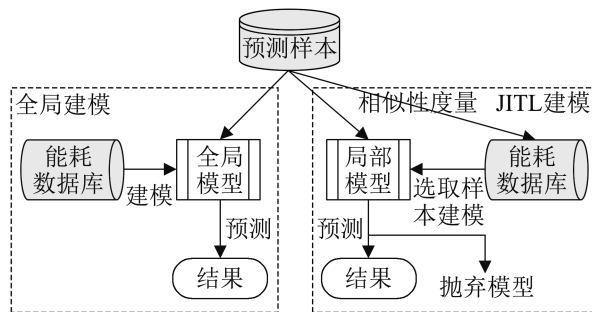


图2 全局建模和JITL建模对比  
Fig. 2 Comparison between global modeling and JITL modeling

### 2.3 相似性度量

在为预测样本选取相似样本时需要进行相似性度量，本文选取欧氏距离作为样本之间的相似性度量衡，衡量两个多维向量之间的绝对距离，距离越近，则样本间相似性越高。假如有 $m$ 个样本向量 $X_1 \sim X_m$ ，协方差矩阵记为 $S$ ，均值记为 $\mu$ ，则向量 $X_i$ 与 $X_j$ 之间的欧式距离为<sup>[17]</sup>

$$d(X_i, X_j) = \sqrt{(X_i - X_j)^T S^{-1} (X_i - X_j)} \quad (7)$$

欧氏距离中协方差矩阵为单位矩阵(即各个样本之间独立同分布)。

### 2.4 JITL-LWPLS 能耗预测模型

局部加权偏最小二乘算法(LWPLS)是对偏最小二乘法的一种改进，通过距离定义训练样本和预测样本之间的权值，并在计算权值时引入JITL思想中的带宽参数。LWPLS算法以权值来选择预测样本的

近邻样本集建立预测模型，大大减少了计算量。

通常样本输入变量之间都会或多或少地存在一些共线性，即他们之间本身就具有线性关系，会导致在进行预测运算时出现矩阵奇异的情况。LWPLS算法体现了降维的思想，将样本输入映射到隐空间，将输入变量转换为互不相关的隐变量再进行预测。LWPLS算法需要满足两点要求：一是要保证保留的原输入信息最多；二是要保证提取到的主成分与输出之间的相关性最大，相关性取的是变量之间的协方差最大。这样LWPLS算法既解决了输入变量之间共线性的问题，又能保证提取的主成分最能体现与输出之间的联系。

JITL-LWPLS算法流程如下。

(1) 对于 $n$ 个 $m$ 维样本，令第 $i$ 个样本的输入变量为

$$\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}] \quad (8)$$

式中： $x_{i1}, x_{i2}, \dots, x_{im}$ 为生产过程中的工艺参数，如数控车床切削过程中的切削速度、进给率、切削深度、主轴转速等。

(2) 设置隐变量个数 $R$ 和带宽参数 $h$ ，将历史样本和预测样本的输入变量和输出变量进行均值去中心化：

$$\mathbf{X}_0 = \mathbf{X} - \mathbf{1}_n [\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m] \quad (9)$$

式中： $\mathbf{1}_n$ 为全为1的 $n$ 行列向量； $\mathbf{X}$ 为历史样本集的工艺参数输入矩阵。

$$\mathbf{Y}_0 = \mathbf{Y} - \mathbf{1}_n \bar{y} \quad (10)$$

式中： $\mathbf{Y}$ 为历史样本集的工步层能耗输出矩阵。

$$\mathbf{x}_{q0} = \mathbf{x}_q - [\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m] \quad (11)$$

式中： $\mathbf{x}_q$ 为预测样本的工艺参数输入。

$$\bar{x}_a = \frac{\sum_{i=1}^n \omega_i x_{ia}}{\sum_{i=1}^n \omega_i}, \quad \bar{y} = \frac{\sum_{i=1}^n \omega_i y_i}{\sum_{i=1}^n \omega_i}, \quad a = 1, 2, \dots, m \quad (12)$$

(3) 计算第 $i$ 个样本 $\mathbf{x}_i$ 与查询样本 $\mathbf{x}_q$ 之间的相似度：

$$d_i = \sqrt{(\mathbf{x}_i - \mathbf{x}_q)^T (\mathbf{x}_i - \mathbf{x}_q)} \quad (13)$$

式中： $d_i$ 为预测样本和历史样本之间的欧氏距离。

$$\omega_i = \exp(-d_i / (\sigma_d / h)) \quad (14)$$

式中:  $\omega_i$  为第  $i$  个样本  $x_i$  的权重;  $\sigma_d$  为  $d_i$  的标准差。

(4) 由式(14)可知样本点与预测样本的距离越近, 其权重就越大, 以此可以得到所有样本的权重, 权重矩阵为

$$\Omega = \text{diag}(\omega_1, \omega_2, \dots, \omega_n) \quad (15)$$

(5) 提取历史样本和预测样本的隐变量:

$$t_1 = X_0 w_1 \quad (16)$$

$$t_{q,1} = x_{q0} w_1 \quad (17)$$

$$w_1 = \frac{X_0^T \Omega Y_0}{\|X_0^T Y_0\|} \quad (18)$$

(6) 计算负荷向量  $p_1$  和模型回归系数向量  $q_1$ :

$$p_1 = (X_0^T \Omega t_1) / (t_1^T \Omega t_1) \quad (19)$$

$$q_1 = (Y_0^T \Omega t_1) / (t_1^T \Omega t_1) \quad (20)$$

(7) 若提取到的隐变量个数  $\neq R$ , 则令

$$X_1 = X_0 - t_1 p_1^T \quad (21)$$

$$Y_1 = Y_0 - t_1 q_1^T \quad (22)$$

$$x_{q1} = x_{q0} - t_{q,1} p_1^T \quad (23)$$

(8) 重复上述(5)~(7)过程, 直到提取的隐变量个数等于  $R$ 。

$$P = [p_1, p_2, \dots, p_R] \quad (24)$$

$$Q = [q_1, q_2, \dots, q_R] \quad (25)$$

$$T_q = [t_{q,1}, t_{q,2}, \dots, t_{q,R}] \quad (26)$$

式中:  $P$  为负荷向量;  $Q$  为模型回归系数向量;  $T_q$  为预测样本的得分向量。

(9) 计算预测值:

$$E_c = T_q Q^T \quad (27)$$

式中:  $E_c$  为工步层运行阶段的能耗。

(10) 根据式(1)~(4)计算工步层的能耗, 则整个加工过程的能耗  $E_{pro}$  可由式(5)得出。

图 3 为 JITL-LWPLS 算法的机理图, 输入加工工件的工艺参数后算法会根据相似度和带宽参数选择合适的建模样本建立预测模型并预测结果, 下一个加工工件到来时会建立新的预测模型。

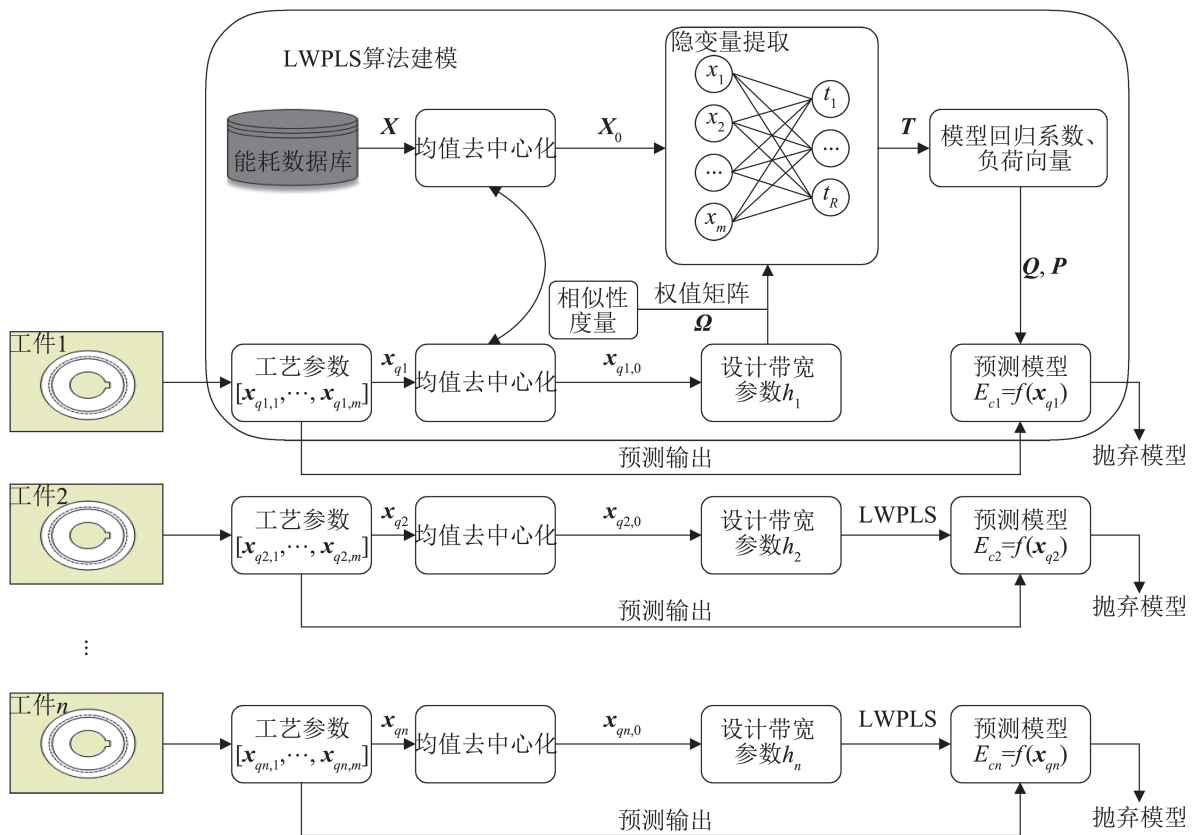


图 3 JITL-LWPLS 算法机理图  
Fig. 3 Diagram of LWPLS algorithm mechanis



## 2.5 带宽参数优化

JITL-LWPLS建模算法中的带宽参数 $h$ 决定着在选取历史样本时的范围，由式(14)可知 $h$ 越大，则每个样本分得的权重值就会减少，预测样本点的局部选取邻域越小。对于一般的情况， $h$ 常取值在0.5~1.5之间<sup>[16]</sup>，当 $h$ 取值较大时，选取的建模样本较少，会导致模型过拟合，泛化性差；当 $h$ 取值较小时，又会使用于建模的样本数过多，导致计算量大大增加，因此，在建模时选取合适的带宽参数会增强模型的泛化性，同时在保证计算简洁的条件下使预测的结果贴近真实值。如图4所示，不同的带宽参数会对最终的预测结果产生很大的影响，因此，需要选取合适的带宽参数。




图4 不同带宽值对LWPLS算法性能的影响  
Fig. 4 Influence of different bandwidth values on performance of LWPLS algorithm

### 2.5.1 优化策略

对于带宽参数 $h$ 的优化问题，可以分为全局优化和局部优化2种。全局优化通过最小化某个准则来全局设计最优的带宽参数，如最小化训练样本集的交叉验证误差；局部优化对每个样本设计不同的最优带宽参数，如最小化该样本的预测误差或均方根误差。这2种优化方式各有优缺点，全局优化思想比较简单，计算也比较方便，但是其设计的全局最优带宽参数并不适用于所有的样本，在样本较稀疏的时候可能会出现个别样本的预测误差很大的情况。局部优化针对不同的样本

设计不同的最优带宽参数，其优点是每个样本的预测误差很小，但是局部优化需要知道先验知识，而这种先验知识是需要预测的值，因此，如何在没有先验知识的前提下设计样本的最优带宽参数是局部优化的难点。文献[18]通过对近邻样本加权建立局部模型，这种通过近邻样本设计参数的方法已被证明可以取得很好的效果，但是对于离散制造系统不能仅考虑近邻样本，在多种工况存在的情况下通过相似性度量选取的近邻样本可能会不属于同一工况，而不同工况之间的能耗差异性将直接影响最优带宽参数的选取，会导致最后得到的最优带宽参数并不尽如人意。

本文采取了局部优化的方法，通过最小化预测误差来为每个训练样本设计最优带宽参数，同时针对多工况问题，将训练样本通过K-means算法进行分类，当预测样本到来时，对样本进行工况归类，选择与预测样本最相近工况内的历史样本，设计预测样本的最优带宽参数来建立预测模型，得到预测结果。

### 2.5.2 优化方法

采用上述局部带宽优化方法，需要离线计算出每个训练样本的最优带宽参数并将其作为样本信息一起存储起来。对于该种最优化问题，目前常用的有牛顿法、梯度下降法、黄金分割法等传统搜索方法，以及PSO<sup>[19-20]</sup>、GA<sup>[21]</sup>、SA<sup>[22]</sup>等智能搜索算法。由图4可以看出，不同的带宽参数会影响预测的误差，且存在多极值的情况，对于均匀分布的数据，其带宽参数和预测的均方根误差之间的函数关系体现在坐标轴上只有一个极小值；对于非均匀分布的数据，一般都有多个极值存在，而在工业生产中产生的样本数据基本上不可能是均匀分布的，因此，传统的搜索方式并不适用于工业预测，极可能陷入局部极值中。在智能搜索方法中，PSO算法<sup>[23]</sup>具有参数少、原理简单等特点，应用广泛。本文对PSO算法中的惯性权重进行改进，提出了一种APSO算法来优化预测模型

的带宽参数, 增强了粒子的收敛速度和跳出局部极值的能力, 具体的改进策略如下:

(1) 考虑粒子的适应度, 当粒子相距种群最优值较远时增大惯性权重, 提高算法的全局搜索能力; 反之则减小惯性权重, 提高局部搜索能力, 这样能使粒子跳出局部极值。

(2) 考虑迭代次数对算法收敛速度的影响, 在算法开始时应该有较大的惯性权重来快速收敛到最优值附近, 迭代次数增多后应该减小惯性权重提高算法的收敛精度。

(3) 考虑种群的大小, 种群的个体数量较多时不需要很大的惯性权重就能收敛到最优值, 个体数量较少时则增加惯性权重来保证粒子搜索的活力。

优化后 APSO 算法的惯性权重为

$$w = w_{\text{end}} + (w_{\text{st}} - w_{\text{end}}) \times \exp\left(\frac{f(x_i) - f(x_{g_{\text{best}}})}{f_{\text{avg}} - f(x_{g_{\text{best}}})} \cdot \left(\frac{i}{i_{\text{max}}}\right)^2\right) + \frac{1}{N} \quad (28)$$

式中:  $w$  的取值范围为  $[0.4, 0.9]$ <sup>[23]</sup>;  $w_{\text{end}}$  为惯性权重最小值;  $w_{\text{st}}$  为惯性权重最大值;  $f(x_i)$  为第  $i$  个粒子的适应度函数值;  $f(x_{g_{\text{best}}})$  为种群最优适应度值;  $f_{\text{avg}}$  为种群适应度的平均值;  $i$  为当前迭代次数;  $i_{\text{max}}$  为最大迭代次数;  $N$  为种群个体数量。

$$f = 1/(1 + (\tilde{y} - y)^2) \quad (29)$$

式中:  $f$  为适应度函数;  $\tilde{y}$  为工步层能耗预测值;  $y$  为训练样本实际能耗值。APSO 算法以适应度函数值最大为目标<sup>[20]</sup>, 得到最优带宽参数。

## 2.6 APSO-JITL-CLWPLS 算法建模流程

离散制造系统的历史样本数据库中包含系统在各种工况下加工工件的能耗数据, 当系统开始加工一件产品时, 按照第一节的离散加工系统能耗分析可以将生产过程分解为多个工步, 每个工步对应一种工况, 不同工况之间相互独立。系统的能耗则是由工步层产生的设备加工能耗和系统调度能耗构成。本节针对工业生产中的多工况情形, 在即时学习的基础上, 提出一种 APSO-JITL-

CLWPLS 算法建立预测模型, 将加工工件过程的工艺参数、工件尺寸大小等作为预测模型的输入变量, 工步层的设备生产能耗作为预测模型的输出。整个流程分为离线计算和在线预测两部分:

### (1) 离线计算

通过交叉验证法选取一个训练样本作为预测样本, 以该样本的预测误差最小为目标, 通过 APSO 算法设计该样本的最优带宽, 最终得到所有训练样本的最优带宽参数。同时将历史样本数据通过 K-means 算法进行工况分类, 计算出每个簇中心, 将得到的参数与训练样本一起存储起来以供预测阶段设计预测样本的带宽参数。

### (2) 在线预测

预测样本到来时, 计算预测样本与各个簇中心的距离, 经过工况相似性度量之后给预测样本归类, 在相应的簇中选取近邻样本设计最优带宽参数, 最后将该带宽参数代入到模型中进行预测。

### APSO-JITL-CLWPLS 算法

离线计算:

设置种群数量  $n$  和迭代次数  $R$

初始化粒子位置和速度

设置历史样本预测误差为适应度函数  $f_1$

运行 APSO, 交叉验证法为每个历史样本设计最优带宽参数

设置全局交叉验证误差为适应度函数  $f_2$

运行 APSO, 计算全局最优带宽参数  $h_{\text{global}}$

运行 K-means 算法将历史样本按工况分类

计算簇中心

在线预测:

提取加工工件过程工艺参数  $\mathbf{x}_q$  作为模型输入

将预测样本工艺参数输入  $\mathbf{x}_q$  和历史样本集的工艺参数输入矩阵  $\mathbf{X}$  进行均值去中心化

样本相似性度量, 得到权值矩阵  $\Omega$

工况相似性度量, 为预测样本归类

在相应的簇内选取近邻样本设计预测样本的带宽参数  $h$

运行 LWPLS 算法建立预测模型

将生产过程的工艺参数 $x_q$ 输入到预测模型中得到该工步运行阶段能耗 $E_c$ 。  
计算该工步启动、待机、空载阶段能耗抛弃模型，等待下一个工步加工过程各工步能耗累加，得到整个加工过程能耗 $E_{pro}$ 。

### 3 仿真实验与模型VV&A

本节对所提算法进行仿真实验，并对模型进行VV&A过程验证模型的准确性和有效性。仿真实验数据来源于国内某车间的DYNA DM4600数控车床切削铸钢ZG55时采集获得。

#### 3.1 运行环境

仿真实验均在处理器为Intel(R) Core(TM) i3-10105 CPU、系统为Windows 10版本、8G运存的计算机上进行，运行软件为MATLAB R2016a。

#### 3.2 APSO优化算法性能测试

为了测试APSO算法对历史样本带宽参数的优化性能，将APSO算法与3种不同惯性权重的PSO算法进行对比实验。在Sphere函数、Griewank函数、Rosenbrock函数和Ackley函数4个标准测试函数上验证APSO算法的优化性能，测试函数的函数形式、维数和理论极值如表1所示。各标准测试函数的目标精度分别为1、0.05、100、 $2.8^{[24-25]}$ ，算法寻化结果在目标精度以内视为该次实验达标。4种算法使用的惯性权重分别为自适应惯性权重、常系数惯性权重、线性递减惯性

权重和非线性递减惯性权重。

本次实验设置各算法的学习因子 $c_1=c_2=2^{[26]}$ ，种群数量为20，最大迭代次数为50，各算法在4个标准测试函数上分别寻优100次，寻优结果平均值的收敛曲线如图5所示。选取算法100次寻优结果的最小值、平均值和达标次数来评价算法的优化性能，实验结果如表2所示。由结果可知APSO算法100次实验的平均值、最小值均为最小，从达标次数来看APSO算法达标次数最多，说明APSO算法相比其他3种常用惯性权重的PSO算法有着更好的搜索精度和稳定性。

#### 3.3 模型VV&A过程

仿真是在模型的基础上进行的，保证和提高模型的可信度是仿真实验中重要的一环，本文通过VV&A理论验证算法的准确性，提高模型的可信度。

VV&A定义为校核、验证和确认，校核指的是检验是否正确地建立了模型，其关心的是所建模型是否正确描述了真实世界；验证指的是检验是否建立了正确的模型，其关心的是所建模型描述真实世界的正确程度；确认指的是评价模型性能的好坏。简单VV&A过程可以分为4个步骤：明确仿真目的、模型校核、模型验证，以及模型的验收，模型的校核、验证和确认都是在明确仿真目的的基础上进行的。本文以预测数控车床切削过程的设备运行能耗为仿真目的，并在此基础上分别对所建模型进行校核、验证和确认。

表1 标准测试函数  
Table 1 Standard test functions

函数	函数形式	维数	理论极值
Sphere	$f(x) = \sum_{i=1}^n x_i^2$	30	0
Griewank	$f(x) = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$	30	0
Rosenbrock	$f(x) = \frac{1}{4000} \sum_{i=1}^n (x_i^2) - \prod_{i=1}^n \cos(x_i / \sqrt{i}) + 1$	30	0
Ackley	$f(x) = -20 \times \exp \left( -0.2 \times \sqrt{\frac{1}{n} \sum_{j=1}^n x_j^2} \right) - \exp \left( \frac{1}{n} \sum_{j=1}^n \cos(2\pi x_j) \right) + 20 + e$	30	0

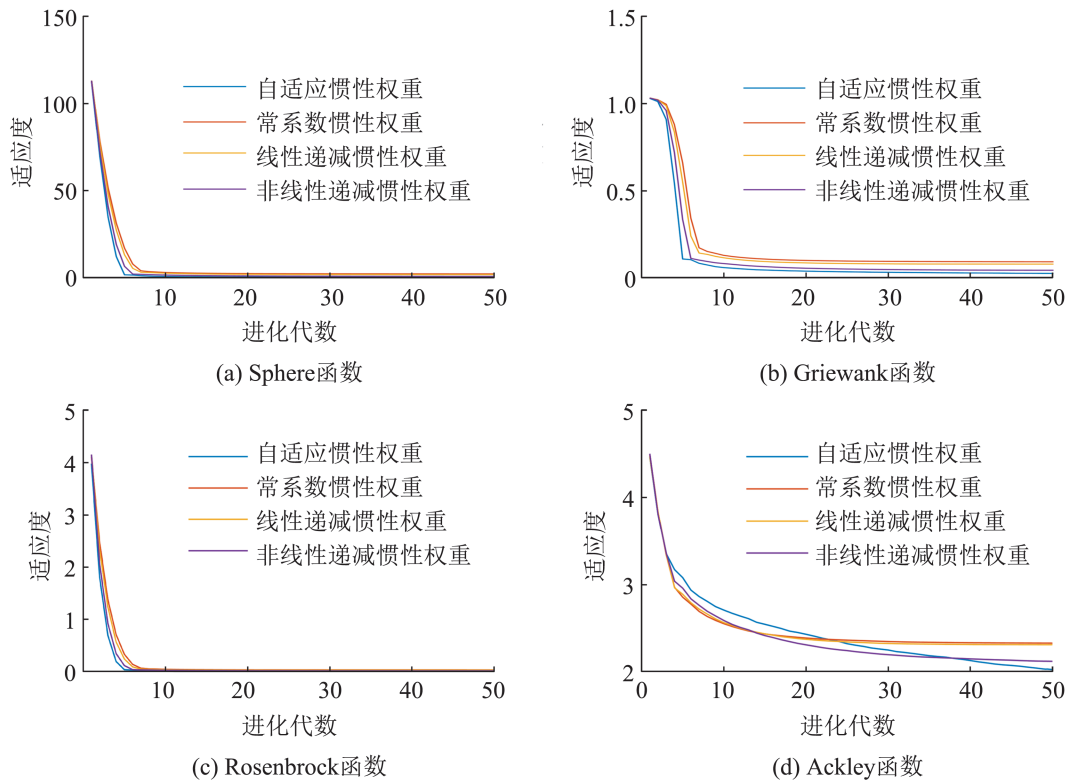


图5 4种算法在标准测试函数上的优化结果比较

Fig. 5 Comparison of optimization results of four algorithms on standard test functions

表2 4种算法在标准测试函数上的优化结果

Table 2 Optimization results of four algorithms on standard test functions

函数名	性能指标	自适应惯性权重	常系数惯性权重	线性递减惯性权重	非线性递减惯性权重
Sphere	最小值	<b>0.035 8</b>	0.870 8	0.538 4	0.267 9
	平均值	<b>0.272 6</b>	2.202 8	1.767 5	0.776 0
	达标次数	<b>100</b>	2	9	79
Griewank	最小值	<b>0.004 4</b>	0.034 6	0.015 5	0.013 0
	平均值	<b>0.024 8</b>	0.091 2	0.077 9	0.042 7
	达标次数	<b>96</b>	5	9	70
Rosenbrock	最小值	<b>40.571 5</b>	134.974 3	93.765 6	55.314 5
	平均值	<b>70.213 3</b>	283.874 8	239.357 5	126.473 6
	达标次数	<b>88</b>	0	1	25
Ackley	最小值	<b>1.231 3</b>	1.425 2	1.493 9	1.632 2
	平均值	<b>2.020 3</b>	2.326 8	2.308 1	2.117 4
	达标次数	<b>100</b>	97	97	100

### 3.3.1 模型校核过程

模型校核的任务是检验模型从一种形式转化为另一种形式的过程是否正确<sup>[27]</sup>。本文基于数据驱动建立的预测模型是一种“黑箱模型”，其本身就有一定的模型校核功能，对于本文所建模型的

校核就变成了对建模数据来源的可靠性进行校核。本文的建模数据皆来源于真实的车间加工数据，确保了数据来源的可靠性。采集的切削过程数据如表3所示<sup>[28]</sup>。



表3 数控机床铣削过程数据  
Table 3 CNC machine milling process data

序号	切削速度 $v/(m/min)$	切削深度 $d/mm$	每齿进给量 $f_t/(mm/t)$	切削力 $F/N$	表面粗糙度 $R/\mu m$	功耗 $E/W$
1	157.00	0.6	0.05	368	2.054	274
2	157.00	0.6	0.10	614	2.333	294
3	157.00	0.6	0.15	829	2.559	311
4	157.00	0.6	0.50	1 026	2.729	321
...						
61	251.57	1.5	0.05	839	1.887	632
62	251.57	1.5	0.10	1 401	2.243	693
63	251.57	1.5	0.15	1 892	2.481	757
64	251.57	1.5	0.50	2 340	2.666	893

### 3.3.2 仿真实验与模型验证过程

模型验证的任务是检验模型与真实场景的契合程度。对于数据驱动的算法模型最常用的模型验证方法是历史数据法，即将数据集中的一部分数据作为训练集训练模型，其他数据作为测试集验证模型的正确性。本文采用K折验证法(K取值为8)将数据集平均分为8份，每次取其中的一份作为测试集进行仿真实验，同时考虑模型的泛化性，每份测试集中都包含所有工况样本。

仿真实验时在离线计算阶段设定K-means算法的聚类数量为4，设置APSO算法的种群个体数量为20，最大迭代次数为100，计算簇中心点坐标和每个训练样本的最优带宽参数一并存入到数据集中。预测时先计算预测样本与各个簇中心的距离，通过工况相似性度量为测试样本归类，选择该类工况下相似度高的近邻样本的最优带宽参数来设计测试样本的带宽参数，最后将测试样本及其最优带宽参数代入到LWPLS模型中预测输出。其中，第*i*个近邻样本的权值计算公式为<sup>[8]</sup>

$$w_{q,i} = \exp(-d_i / (2 \times h_{\text{global}})) \quad (30)$$

式中： $h_{\text{global}}$ 为全局最优带宽，表示APSO算法在最小化测试集交叉验证误差的条件下求得的最优带宽参数。

实验选取平均误差 $E_{MA}$ 和相对平均误差 $E_{MR}$ 来

检验所建模型的准确性。

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n (f(x_i) - y_i) \quad (31)$$

式中： $n$ 为测试样本的数量； $f(x_i)$ 为第*i*个样本的预测值； $y_i$ 为第*i*个样本的真实值。

$$E_{MR} = E_{MA} / \bar{y} \quad (32)$$

式中： $\bar{y}$ 为测试样本真实值的平均。8次实验中的相关数据以及模型的能耗预测结果如表4所示。

将所建模型与BP神经网络算法、基于全局带宽参数的局部加权偏最小二乘算法(GLWPLS)，以及基于加权K近邻的局部加权偏最小二乘算法(LWPLS-WKNN)进行了性能比较。BP算法建立的全局模型由于建模样本中存在大量的不同工况样本导致预测误差较大，引入即时学习思想采用局部建模方法后可以看到预测误差有明显减少，而LWPLS-WKNN算法改进了GLWPLS算法带宽参数固定，不适用于所有样本的缺点，通过近邻样本的最优带宽参数设计预测样本的带宽参数，可以改善预测精度，但是该方法没有考虑不同工况数据之间的能耗差异性，会选取到不同工况的数据来建立模型导致额外的误差。本文所建模型的平均误差皆为最小，且相对平均误差基本上都在2%以下，8折验证的均值 $E_{MR}$ 仅为2.16%，说明本文所建模型可以较好地描述离散制造系统多工况生产场景下输入与输出之间的关系。

表4 预测误差统计分析及对比  
Table 4 Statistical analysis and comparison of prediction error of three algorithms

实验 序号	最优带宽 参数	BP		GLWPLS		LWPLS-WKNN		APSO-JITL-CLWPLS	
		$E_{MA}/W$	$E_{MR}/\%$	$E_{MA}/W$	$E_{MR}/\%$	$E_{MA}/W$	$E_{MR}/\%$	$E_{MA}/W$	$E_{MR}/\%$
1	0.490 4	11.922 0	2.76	5.290	1.23	4.352	1.01	3.642	0.84
2	0.472 8	33.269 0	6.51	26.901	5.27	24.551	4.81	23.643	4.63
3	0.486 5	9.853 0	2.07	5.324	1.12	4.680	0.98	4.198	0.88
4	0.660 4	24.847 0	4.12	13.571	2.25	13.618	2.26	11.204	1.86
5	0.507 8	10.654 0	2.02	5.280	1.01	5.532	1.05	4.194	0.79
6	0.493 2	50.752 9	8.01	30.615	4.82	30.582	4.82	30.541	4.81
7	0.556 8	22.268 2	3.96	10.823	1.92	9.930	1.76	8.019	1.42
8	0.771 2	24.812 1	3.55	16.501	2.36	15.759	2.25	14.302	2.05
平均值		23.547 3	4.13	14.288	2.50	13.626	2.37	12.468	2.16

### 3.3.3 模型确认过程

模型确认是在模型校核和验证的基础上评价模型性能的好坏。随机抽取8组数据作为测试集, 各种算法在测试集上的预测结果和真实值的对比如图6所示。为了更加直观地比较各算法的性能, 算法预测结果如表5所示。由测试结果和模型验证结果可得本文所提算法相比其他3种算法预测精度最好, 在预测时引入即时学习思想后的用时相比全局建模方法明显减小, 局部建模思想虽然有着额外的计算成本且会增加算法的复杂度, 但是其在建模时会对建模样本进行筛选, 可以根据需求设计建模方案应对工业生产过程中的复杂特性, 提高预测精度。由于降低了建模样本的数量, 在应对数据量较大的情况时可以有效减少预测时间, 提高预测效率。综上所述, 本文算法可以有效地应对多工况情形下的离散制造系统能耗预测问题。

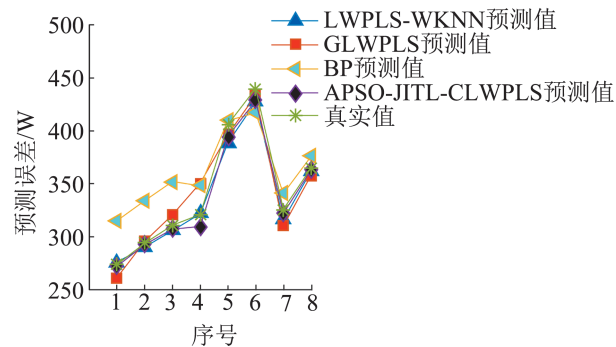


图6 各种算法预测结果与真实值的对比  
Fig. 6 Comparison of prediction results of various algorithms with true values

表5 预测误差统计分析及对比

Table 5 Statistical analysis and comparison of prediction error of the three algorithms

算法	MAE	MRE/%	t/s
BP	10.178 7	2.98	1.307
GLWPLS	4.944 7	1.45	0.231
LWPLS-WKNN	3.099 0	0.91	0.242
APSO-JITL-CLWPLS	2.575 0	0.75	0.245

## 4 结论

为了建立准确而有效的离散加工过程能耗预测模型, 分析了离散加工过程的能耗构成和特点, 提出了APSO-JITL-CLWPLS建模算法。针对生产过程中的全局预测模型内部参数固定, 不适用于所有样本且计算量大的问题, 引入了即时学习的思想, 将建模方式从全局变为局部建模, 在预测样本到来时建立局部临时模型, 不仅提高了预测精度还大大简化了预测时的计算量。同时, 对于离散加工过程中的多工况数据问题, 对数据集中不同工况的数据进行了聚类, 在预测时先对预测样本进行归类再选取近邻的样本设计预测模型的带宽参数, 进一步减小了预测误差。实验表明, 本文提出的算法在应对离散加工场景的多工况情形时可以在更短的时间内取得更好的预测效果。

本文算法模型的预测精度与聚类算法分类的准确性相关, 今后会考虑采用更加精确的聚类算法进行工况相似性度量, 进一步减小预测模型的预测误差。

## 参考文献:

- [1] Stefan Velchev, Ivan Kolev, Krasimir Ivanov, et al. Empirical Models for Specific Energy Consumption and Optimization of Cutting Parameters for Minimizing Energy Consumption During Turning[J]. *Journal of Cleaner Production*, 2014, 80: 139-149.
- [2] Gu Wenbin, Li Zhuo, Chen Zeyu, et al. An Energy-consumption Model for Establishing an Integrated Energy-consumption Process in a Machining System[J]. *Mathematical and Computer Modelling of Dynamical Systems*, 2020, 26(6): 534-561.
- [3] 钱军, 李欣然, 马亚辉, 等. 面向负荷建模的微型燃气轮机建模及其等效描述[J]. *电力系统自动化*, 2010, 34(19): 81-85.  
Qian Jun, Li Xinran, Ma Yahui, et al. Modeling and Equivalent Description of Microturbine for Load Modeling[J]. *Automation of Electric Power Systems*, 2010, 34(19): 81-85.
- [4] Abdulla Amin Aburomman, Mamun Bin Ibne Reaz. A Novel Weighted Support Vector Machines Multiclass Classifier Based on Differential Evolution for Intrusion Detection Systems[J]. *Information Sciences*, 2017, 414: 225-246.
- [5] 李艳姣, 张森, 尹怡欣, 等. 基于数据驱动的高炉料面优化决策模型研究[J]. *控制理论与应用*, 2018, 35(3): 324-334.  
Li Yanjiao, Zhang Sen, Yin Yixin, et al. Research on Optimization Model of Blast Furnace Burden Surface Based on Data Driven[J]. *Control Theory & Applications*, 2018, 35(3): 324-334.
- [6] Nivethitha Somu, Gauthama Raman M R, Krithi Ramamritham. A Hybrid Model for Building Energy Consumption Forecasting Using Long Short Term Memory Networks[J]. *Applied Energy*, 2020, 261: 114131.
- [7] 曾国治, 魏子清, 岳宝, 等. 基于CNN-RNN组合模型的办公建筑能耗预测[J]. *上海交通大学学报*, 2022, 56(9): 1256-1261.  
Zeng Guozhi, Wei Ziqing, Yue Bao, et al. Energy Consumption Prediction of Office Buildings Based on CNN-RNN Combined Model[J]. *Journal of Shanghai Jiao Tong University*, 2022, 56(9): 1256-1261.
- [8] Qiao Junfei, Zhou Hongbiao. Modeling of Energy Consumption and Effluent Quality Using Density Peaks-based Adaptive Fuzzy Neural Network[J]. *IEEE/CAA Journal of Automatica Sinica*, 2018, 5(5): 968-976.
- [9] Yuan Xiaofeng, Ge Zhiqiang, Huang Biao, et al. A Probabilistic Just-in-time Learning Framework for Soft Sensor Development with Missing Data[J]. *IEEE Transactions on Control Systems Technology*, 2017, 25(3): 1124-1132.
- [10] 宋月丽. 基于即时学习的工业生产过程质量预测建模方法研究[D]. 合肥: 合肥工业大学, 2020.  
Song Yueli. Research on Just-in-time Learning Based Modeling Methods for Quality Prediction of Industrial Production Process[D]. Hefei: Hefei University of Technology, 2020.
- [11] 施锦涛, 陈磊, 秦凯, 等. 基于时空相似性的即时学习在线建模[J]. *仪器仪表学报*, 2022, 43(6): 185-193.  
Shi Jintao, Chen Lei, Qin Kai, et al. Online Modeling of Just-in-time Learning Based on Spatial-temporal Similarity[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(6): 185-193.
- [12] 赵安, 刘辉, 陈甫刚, 等. 基于CJS-SLLE降维与即时学习的转炉炼钢终点碳温软测量方法[J]. *控制理论与应用*, 2023, 40(10): 1839-1850.  
Zhao An, Liu Hui, Chen Fugang, et al. Soft Measurement Method for End-point Carbon Temperature in Converter Steelmaking Based on CJS-SLLE Dimensionality Reduction and Real-time Learning[J]. *Control Theory & Applications*, 2023, 40(10): 1839-1850.
- [13] Yuan Xiaofeng, Zhou Jiao, Wang Yalin, et al. Multi-similarity Measurement Driven Ensemble Just-in-time Learning for Soft Sensing of Industrial Processes[J]. *Journal of Chemometrics*, 2018, 32(9): e3040.
- [14] 张莹, 王耀南. 基于局部加权偏最小二乘法的冷凝器污垢预测[J]. *仪器仪表学报*, 2010, 31(2): 299-304.  
Zhang Ying, Wang Yaonan. Prediction of Condenser Fouling Based on Locally Weighted Partial Least Squares Regression Algorithm[J]. *Chinese Journal of Scientific Instrument*, 2010, 31(2): 299-304.
- [15] 徐彬梓, 王艳, 纪志成. 基于实例的离散制造系统能耗知识建模与预测[J]. *控制与决策*, 2019, 34(1): 9-17.  
Xu Binzi, Wang Yan, Ji Zhicheng. Case-based Energy-consuming Knowledge Modeling and Prediction of Discrete Manufacturing System[J]. *Control and Decision*, 2019, 34(1): 9-17.
- [16] 易诚明, 周平, 柴天佑. 基于即时学习的高炉炼铁过程数据驱动自适应预测控制[J]. *控制理论与应用*, 2020, 37(2): 295-306.  
Yi Chengming, Zhou Ping, Chai Tianyou. Data-driven Just-in-time Learning Based Adaptive Predictive Control for Blast Furnace Ironmaking[J]. *Control Theory & Applications*, 2020, 37(2): 295-306.
- [17] 赵泉华, 王春畅, 李玉. 基于混合邻域约束项的改进FCM算法[J]. *控制与决策*, 2021, 36(6): 1457-1464.  
Zhao Quanhua, Wang Chunchang, Li Yu. Mixed

- Neighborhood Constraints Based Fuzzy C-means Algorithm[J]. *Control and Decision*, 2021, 36(6): 1457-1464.
- [18] Wang Guang, Yin Shen, Kaynak O. An LWPR-based Data-driven Fault Detection Approach for Nonlinear Process Monitoring[J]. *IEEE Transactions on Industrial Informatics*, 2014, 10(4): 2016-2023.
- [19] Wang Jiajun, Tufan Kumbasar. Parameter Optimization of Interval Type-2 Fuzzy Neural Networks Based on PSO and BBBC Methods[J]. *IEEE/CAA Journal of Automatica Sinica*, 2019, 6(1): 247-257.
- [20] Pratik Roy, Ghanshaym Singha Mahapatra, Kashi Nath Dey. Forecasting of Software Reliability Using Neighborhood Fuzzy Particle Swarm Optimization Based Novel Neural Network[J]. *IEEE/CAA Journal of Automatica Sinica*, 2019, 6(6): 1365-1383.
- [21] 徐文婕, 朱光宇. 直觉模糊集相似度遗传算法求解多目标车间调度问题[J]. *控制理论与应用*, 2019, 36(7): 1057-1066.
- Xu Wenjie, Zhu Guangyu. Genetic Algorithm Based on Similarity of Intuitionistic Fuzzy sets for Many-objective Flow Shop Scheduling Problems[J]. *Control Theory & Applications*, 2019, 36(7): 1057-1066.
- [22] 何庆, 吴意乐, 徐同伟. 改进遗传模拟退火算法在TSP优化中的应用[J]. *控制与决策*, 2018, 33(2): 219-225.
- He Qing, Wu Yile, Xu Tongwei. Application of Improved Genetic Simulated Annealing Algorithm in TSP Optimization[J]. *Control and Decision*, 2018, 33(2): 219-225.
- [23] 刘瑞兰, 牟盛静, 苏宏业, 等. 基于支持向量机和粒子群算法的软测量建模[J]. *控制理论与应用*, 2006, 23(6): 895-899, 906.
- Liu Ruilan, Mu Shengjing, Su Hongye, et al. Modeling Soft Sensor Based on Support Vector Machine and Particle Swarm Optimization Algorithms[J]. *Control Theory & Applications*, 2006, 23(6): 895-899, 906.
- [24] 薛明晨, 熊伟丽, 徐保国. 基于局部加权偏最小二乘的在线多模型建模[J]. *计算机应用研究*, 2015, 32(10): 2981-2984, 2995.
- Xue Mingchen, Xiong Weili, Xu Baoguo. Locally Weighted Partial Least Squares Based Online Soft Sensor Using Multi-model Method[J]. *Application Research of Computers*, 2015, 32(10): 2981-2984, 2995.
- [25] 杨扬. 基于改进GEP的数控铣削过程物理建模及工艺参数优化方法研究[D]. 武汉: 华中科技大学, 2013.
- Yang Yang. Improved GEP Based Physical Modeling and Process Parameters Optimization Methods for CNC Milling Process[D]. Wuhan: Huazhong University of Science and Technology, 2013.
- [26] Chen Weineng, Zhang Jun, Henry S H. Chung, et al. A Novel Set-based Particle Swarm Optimization Method for Discrete Optimization Problems[J]. *IEEE Transactions on Evolutionary Computation*, 2010, 14(2): 278-300.
- [27] Yuan Xiaofeng, Ge Zhiqiang, Huang Biao, et al. Semisupervised JITL Framework for Nonlinear Industrial Soft Sensing Based on Locally Semisupervised Weighted PCR[J]. *IEEE Transactions on Industrial Informatics*, 2017, 13(2): 532-541.
- [28] Venkata Vijayan S, Hare K Mohanta, Ajaya Kumar Pani. Adaptive Non-linear Soft Sensor for Quality Monitoring in Refineries Using Just-in-time Learning-generalized Regression Neural Network Approach[J]. *Applied Soft Computing*, 2022, 119: 108546.