

## 基于 GWO-RBF 神经网络的数字化制造业能耗预测研究

袁 靖<sup>1</sup> 蒋志飞<sup>1</sup> 贾延明<sup>1</sup> 陈鸿飞<sup>2</sup>

YUAN Jing JIANG Zhifei JIA Yanming CHEN Hongfei

## 摘 要

在持续制造过程中,受生产条件、设备状态及物料供应等动态因素影响,能耗数据呈现复杂变化特性。传统方法难以从多源异构数据中精确筛选与能耗强相关的特征,且所构建的预测模型无法依据多周期数据变化动态调整参数,导致预测准确性下降。为此,文章提出一种基于 GWO-RBF 神经网络的数字化制造业能耗预测方法。通过相关性分析提取能耗强相关变量作为特征,构建需求驱动的 RBF 神经网络并输出初始预测值。引入灰狼优化算法,以预测误差为适应度函数,通过模拟狼群包围与追捕行为对网络参数进行全局优化,并融合多周期能耗变化规律实现跨周期参数协同调整。嵌入增量学习机制持续迭代更新网络参数,使模型不断逼近最优预测解,解决模型难以适应长期动态变化的问题,确保长期预测的准确性与稳定性。实验结果表明:该方法平均绝对百分比误差(MAPE)均低于2.5%,预测偏差显著降低,准确性明显提高,表现出优越的预测性能。

## 关键词

GWO-RBF; 神经网络; 数字化技术; 制造业; 能耗预测; 平衡调度

doi: 10.3969/j.issn.1672-9528.2026.02.036

## 0 引言

受行业转型的影响,制造业能源利用效率优化逐渐成为核心问题。常规的能耗管理主要通过数据驱动以及预测模型实现,虽然可以完成日常的调度和控制,但是在复杂环境下无法捕捉能耗的动态变化,且自适应能力不足,对于能耗深层规律的分析不精准。针对上述情况,设计更加灵活、高效的能耗预测方案。

目前,王小春等<sup>[1]</sup>基于智能化视角设计的造纸企业能耗预测神经网络算法。融合制浆造纸工艺流程,以周期比对和调整方式逐步预测能耗,过程中用改进训练算法修正预测结果以确保达标。然而,该方法所依赖的周期比对与调整规则相对固定。当不同周期的生产条件、设备状态与物料供应等因素发生较大变化时,既定的规则难以及时、灵活地捕捉能耗的动态变化,因而无法依据实时工况动态调整预测参数,导致预测准确性下降。郭志喜等<sup>[2]</sup>在制造企业集群下设计的信息模型驱动的能耗分析及预测方法。依据统一协议的

OPCUA 信息模型和多元线性回归算法,消除特征变量冗余信息、提取影响权重、分配能耗结果、总结变动规律并给出预测结果,虽经对比分析验证算法有效,但在持续制造中不同周期动态变化可能改变特征变量与能耗关系,算法确定权重后续预测可能不根据实时数据更新,无法动态调整参数,影响预测准确性。丁文政等<sup>[3]</sup>结合 NC 程序设计的重型数控铣齿机床能耗预测方法。通过分析数控机床耗能部件能耗特征并按特征分类部件完成预测,然而持续制造中不同周期设备状态等因素变化可能改变部件能耗特征,该方法未明确体现如何根据实时变化动态调整预测参数,可能仍按初始方式预测,降低动态变化下的预测准确性。张华等<sup>[4]</sup>设计的数据与模型混合驱动箱体零件加工能耗预测方法。通过分析加工特征及其耦合关系变化探索特征目标并导入模型完成定向预测,虽考虑了加工特征及耦合关系变化,但持续制造不同周期生产条件、物料供应等因素变化可能使加工特征及耦合关系更复杂动态,若算法不能实时有效更新特征目标和调整模型参数,就难以依据实时变化动态调整预测参数,影响预测准确性。

针对上述弊端,本研究提出一种基于 GWO-RBF 神经网络的数字化制造业能耗预测方法。

## 1 数字化制造业能耗 GWO-RBF 神经网络预测方法设计

## 1.1 基于特征筛选的 RBF 神经网络能耗预测建模

在数字化制造系统中,持续制造过程中能耗处于持续增

1. 商丘工学院信息与电子工程学院 河南商丘 476000

2. 华能新能源股份有限公司广东分公司 广东广州 510610

[基金项目] 河南省软科学 2025 年度研究计划项目“工业化背景下制造业数字化绿色化协同发展的动力与路径研究”阶段性研究成果(252400411195); 商丘工学院科研基金资助项目“工业化背景下制造业数字化绿色化协同发展的动力与路径研究”阶段性研究成果(252400411195)

长状态，而控制成本需要对能耗进行约束控制。同时，数字化制造系统会产生多源异构数据，其中包含大量与能耗相关的信息，但并非所有变量都与能耗预测强相关<sup>[5]</sup>。通过相关性分析<sup>[6]</sup>筛选出与能耗强相关的多源制造变量作为特征输入，并构建 RBF 神经网络结构进行初始能耗预测，能够从复杂的数据中提取关键信息，为后续更精准的能耗预测和优化提供基础。

基于相关性分析原则<sup>[7]</sup>，数据中筛选与能耗预测强相关的变量提取特征。用公式表示为：

$$S_l = \int \left[ a^r \left( \sum_{u=1}^I \alpha_u - r_u \right) \times \frac{1}{X} \right] \times \frac{\gamma}{a^r} \quad (1)$$

式中： $S_l$  表示特征值； $a^r$  表示能耗相关系数； $\alpha$  表示能耗变量； $r$  表示固定量； $u$  表示 Pearson 系数； $I$  表示目标变量； $X$  表示制造周期； $\gamma$  表示预期总能耗。

通过数字化制造平台明确单个周期的能耗需求，设计 RBF 神经网络应用结构<sup>[8]</sup>。具体如图 1 所示。




图 1 能耗需求驱动的 RBF 神经网络结构

参考图 1 设计的网络结构进行细化设计。结合式 (1) 给定的特征目标，导入 RBF 神经网络之中。在能耗需求的驱动下，利用隐藏层交叉验证，输出一个初始的预测值<sup>[9]</sup>。用公式表示为：

$$\begin{cases} m = \sqrt{n+l} \times \frac{S_l \cdot (\gamma\epsilon - 1)^l}{a^r} \\ T = \left| \frac{h}{S_l} - \frac{1}{XS_l} \right| \times a^{rm} (\epsilon^{a^r} + \mathcal{G}I) \end{cases} \quad (2)$$

式中： $m$  表示隐藏层交叉验证结果； $n$  表示输入特征维度， $l$  表示输出特征维度； $\epsilon$  表示常数； $T$  表示初始预测值； $h$  表示中心向量； $a^{rm}$  表示时刻能耗； $\epsilon^{a^r}$  表示目标向量； $\mathcal{G}$  表示单周期实际向量。

## 1.2 GWO 优化 RBF 神经网络能耗预测参数

在完成基于特征筛选的 RBF 神经网络能耗预测建模后，由于 RBF 网络的预测精度高度依赖于中心向量和宽度等关键参数的选择，而传统参数设定方法在动态多周期、多工况的制造环境中容易陷入局部最优，导致模型泛化能力不足和预测误差累积，因此有必要引入具备全局搜索能力的智能优化算法以实现参数的系统性调优。灰狼优化算法 (GWO) 具有良好的全局搜索能力，可将其引入并以预测误差作为适应度

函数，通过模拟狼群的包围和追捕行为，动态优化 RBF 神经网络的关键参数，从而实现多周期内能耗参数的自适应协同调整。

GWO 优化旨在对 RBF 神经网络的关键参数进行持续优化，以提升模型的预测精度。先明确能耗预测时灰狼算法的适应度，用公式表示为：

$$L = \sqrt{\frac{\sum_{p=1}^P (f_{\text{actual}}^p - f_{\text{prediction}}^p)^2}{N}} \quad (3)$$

式中： $L$  表示适应度； $N$  表示采样点； $P$  表示权重； $f_{\text{prediction}}^p - f_{\text{actual}}^p = f_{\epsilon}$  和  $f_{\text{prediction}}^p$  分别表示真实能耗值和神经网络预测值。以设定的适应度为预测参考，利用 GWO 算法持续优化。当灰狼在狩猎时先对猎物进行包围，用公式表示为：

$$\begin{cases} G = |CX_L(t) - X(t)| \\ E(t+1) = X_L(t) - AG \end{cases} \quad (4)$$

式中： $G$  表示包围处理目标； $C$  和  $A$  均表示系数向量； $t$  表示迭代次数； $X_L(t)$  和  $X(t)$  分别表示猎物和灰狼的位置向量； $E(t+1)$  表示包围区域。完成猎物的包围之后，即确定了能耗预期的有效区间在该区间内展开追捕处理，用公式表示为：

$$\begin{cases} D_{\alpha} = |C_1 X(t)_{\alpha} - X| \\ D_{\beta} = |C_2 X(t)_{\beta} - X| \\ D_{\delta} = |C_3 X(t)_{\delta} - X| \end{cases} \quad (5)$$

式中： $D_{\alpha}$ 、 $D_{\beta}$ 、 $D_{\delta}$  分别表示追捕时与个体之间形成的距离； $C_1$ 、 $C_2$ 、 $C_3$  分别表示随机向量； $X(t)_{\alpha}$ 、 $X(t)_{\beta}$ 、 $X(t)_{\delta}$  分别表示狼的实时位置。结合灰狼算法的追捕过程，融合各周期实时能耗变化，逐步明确制造时的能耗变动，分析其变化规律。依照该方式对多个周期内的制造能耗进行预测，融合式 (3) 的结果，实现对能耗预测参数的优化。然而，单个周期输出的预测结果并不是固定的，需要根据预测需求持续计算，以此保证后续预测结果的可靠。

## 1.3 基于增量学习的多周期能耗精准预测

在灰狼算法<sup>[10]</sup>完成对参数的优化后，增量学习机制进一步开展工作。并非直接输出能耗预测的最优解，而是先对基于新数据和动态环境下的输出目标进行持续迭代处理，确保迭代过程中收敛因子呈现出递减的状态，用公式表示为：

$$U = a^{rm} + \frac{(x_{\max} - x_{\min})(\epsilon^{a^r} - a^{rm}\sigma)}{x_{\max} - x_{\min}} \quad (6)$$

式中： $U$  表示能耗预测迭代结果； $x_{\max}$ 、 $x_{\min}$  分别表示能耗预测的最大值、最小值； $\sigma$  表示缩放范围。使用 GWO 优化能耗预测的参数后，重构 RBF 神经网络，将迭代后的结果导入，展开最终预测分析，得到预测最优解，用公式表示为：

$$K_{arm} = \frac{E(t+1) \cdot \frac{1}{U}}{x_{\max} - x_{\min}} \times \int \sigma(\lambda - 1)^{x_L(t)} \quad (7)$$

式中： $K_{arm}$ 表示能耗预测最优解； $\lambda$ 表示增量更新参数。当前得到的这个最优解能够更为精准、有效地反映制造业能耗的限制情况，为企业的深度能源管控提供可靠依据。

## 2 实验

为验证基于 GWO-RBF 神经网络的数字化制造业能耗预测方法的应用效果，以某汽车制造企业（下文简称 K 企业）为实验场景，通过对比的方式展开分析，参考文献中选择智能化视角下造纸企业能耗预测神经网络算法优化、制造企业集群下信息模型驱动的能耗分析及预测方法为对照小组，基于设置的能耗预测要求，进行针对性分析验证。

### 2.1 实验准备

K 汽车企业的规模较大，覆盖范围也更广，在日常的制造过程中，能耗把控十分关键。此次为保证能耗预测结果的真实稳定，以 B/S 架构作为支撑，搭配测试平台及能耗监测系统，形成一体化的调度机制。在当前基础上接入辅助设备，如图 2 所示。




图 2 实验硬件环境图

依照图 2 构建的实验环境，进一步加强能耗预测的控制效果。能耗预测平台数据的采集需要按照周期获取，并及时预处理，保证最终预测方案的可行性。

使用 Vue3+Element UI 对往期能耗进行对比，过程中使用 PC 截取目标数据，通过平台传输至数据库作为参考依据。为增加实验的对比性，制造控制系统中拟设定启停机制，完善预测环境，如图 3 所示。




图 3 制造设备启停调度图

图 3 所设计的设备启停装置能够根据能耗波动进行及时调整与修正，从而实现能耗的精准控制，并强化预测效果。基于此，对上述方法进行有效性验证。

### 2.2 能耗需求驱动下 RBF 神经网络输出能耗比结果

汽车制造过程中，多周期能耗变动差异性较大，为保证输出能耗符合预期设定的标准，采用 RBF 神经网络进行能耗比的测算，具体结果如图 4 所示。




图 4 需求驱动下能耗输出结果分析

图 4 结果分析可知：各制造周期的能耗比分布范围在 10.2%~75% 之间，其变动特性与持续制造过程中生产任务、设备负载及工况的动态调整密切相关。其中，约 70% 的周期预测值集中在 40%~50% 区间内，表明模型能够基于能耗需求特征，在不同周期中实现相对稳定且符合实际运行趋势的能耗估算，具备较好的工况适应性。所提方法通过 RBF 网络的非线性映射与交叉验证机制，有效降低了传统经验测算中因特征提取不足导致的预测偏差，为后续的多周期协同优化提供了必要的初始预测输入。

### 2.3 制造能耗预测区间结果分析

多周期制造实践时，由于制造的环节和目标不同，所输出的能耗值也不同，K 厂区随机选定 1 组制造任务，参考往期的数据及信息，预测能耗的区间，如图 5 所示。




图 5 制造能耗预测区间结果分析

图 5 结果分析对比：根据图 4 结果输出的 40%~50% 能耗区间，选定该制造任务所输出的能耗值在 25%~60% 之间，其波动范围虽有所扩大，但整体仍处于实际运行可接受的有效能耗控制区间内。该结果表明，模型能够根据不同制造任务的特征差异，自适应调整预测输出，体现出对多任务、多



工况制造场景的适用性。通过融合多周期实时能耗变化规律，GWO 优化机制有效提升了预测区间与实际能耗波动趋势的贴合度，增强了模型在动态环境下的表征与泛化能力，从而为产线能耗的实时调控与优化决策提供了可靠区间参考。

## 2.4 性能结果对比分析

在选定的 8 个测试周期之内，依照部署的制造要求及任务展开实践，采用 3 种方法输出能耗预测的 MAPE 结果，如图 6 所示。




图 6 能耗预测 MAPE 结果分析对比

根据图 6 结果分析：对照组 1 得到的 MAPE 结果在 2.6%~3.6% 之间，对照组 2 的 MAPE 值在 2.5%~3.3% 之间，新提出的方法得出的 MAPE 结果均被控制在 2.5% 以下，经过对比可知，提出的方法对于能耗的预测偏差更小，这一结果从量化角度证明，引入 GWO 全局参数优化与增量学习机制后，模型在所有测试周期中均表现出更优的预测稳定性与精度一致性。与对照方法相比，本文方法不仅整体 MAPE 更低，且其不同周期之间的误差波动范围显著更小，说明其具备更好的抗干扰与自适应能力，可支持制造系统在复杂运行环境下实现更精准的能耗预测与能效管理。

## 3 结语

本文提出一种基于 GWO-RBF 神经网络的能耗预测方法：先经相关性分析筛选关键特征，构建需求驱动的低冗余 RBF 网络；再引入灰狼优化算法，动态全局寻优网络参数，融合多周期实时能耗变化，提升模型在动态环境中的适应性与泛化能力；接着结合增量学习机制，持续迭代更新参数，克服设备状态漂移、工艺调整等引发的模型退化问题，保障长期预测性能。实验表明，在汽车制造多周期测试场景中，该方法平均绝对百分比误差稳定在 2.5% 以内，预测精度和误差波动范围优于对照方法，鲁棒性与环境适应性良好。研究验证了该融合结构与增量学习机制在动态能耗预测中的有效性，为制造企业能源管理提供了技术参考。未来将探索其不同制造场景的泛化能力，并推动与实时控制系统深度融合。

## 参考文献：

- [1] 王小春, 张宏甫. 智能化视角下造纸企业能耗预测神经网络算法优化研究 [J]. 造纸科学与技术, 2025, 44(4): 98-101.
- [2] 郭志喜, 牛鹏飞, 郭峻源, 等. 制造企业集群下信息模型驱动的能耗分析及预测方法研究 [J]. 机电工程技术, 2025, 54(20): 1-6.
- [3] 丁文政, 贺文权, 张金, 等. 基于 NC 程序的重型数控铣齿机床能耗预测 [J]. 机床与液压, 2023, 51(21): 91-98.
- [4] 张华, 李曙光, 鄢威, 等. 数据与模型混合驱动的箱体零件加工能耗预测 [J]. 机械工程学报, 2023, 59(12): 97-108.
- [5] 靳婷蕾. 基于数字孪生的储能预制舱全生命周期能效预测模型 [J]. 现代制造技术与装备, 2025, 61(8): 83-85.
- [6] 黄锋, 黄洋, 彭元凯, 等. 机器学习在热加工过程能耗预测中的应用与研究进展 [J]. 塑性工程学报, 2025, 32(9): 157-172.
- [7] 杨晨晖, 李婷. 基于自适应卷积神经网络的能耗预测模型搭建与应用 [J]. 科技视界, 2025, 15(25): 10-13.
- [8] 王琳, 张永渝, 金涛, 等. 基于稀疏特征提取和门控循环单元的炼化装置能耗预测方法研究 [J]. 现代化工, 2025, 45(10): 253-258.
- [9] 王冲, 华德睿, 彭江, 等. 融合 EEMD 与 HGS-LSTM 的船厂生产车间能耗预测 [J]. 船海工程, 2025, 54(4): 115-120.
- [10] 顾增杰, 谢雨飞. 时间分类和多目标优化的建筑能耗区间预测 [J]. 计算机仿真, 2024, 41(8): 535-543.

## 【作者简介】

袁靖(1988—)，女，河南商丘人，硕士，讲师，研究方向：电力系统。

蒋志飞(1987—)，男，河南商丘人，硕士，讲师，研究方向：控制系统与自动化。

贾延明(1983—)，男，河南洛阳人，本科，副教授，研究方向：工业软件设计、算法研究。

陈鸿飞(1989—)，男，河南商丘人，本科，中级工程师，研究方向：新能源发电。

(收稿日期：2025-12-17 修回日期：2026-02-06)