



## 基于 UMAP-GWO-DNN 的转炉终点磷含量预测模型

王雪原<sup>1,2</sup>, 张力彬<sup>3</sup>, 周春芳<sup>1,2</sup>

(1 承德建龙特殊钢有限公司, 承德 067201; 2 河北省半钢水冶炼高洁净高品质特殊钢重点实验室, 承德 067201;  
3 河北省发展和改革委员会产业转型升级服务中心, 石家庄 050000)

**摘要:** 转炉终点磷含量的精准控制是提升钢材质量和冶炼效率的核心环节。本研究针对 42CrMo 钢种, 创新性地融合统一流形逼近与投影(UMAP)、灰狼优化算法(GWO)和深度神经网络(DNN)技术, 构建了多模态智能预测模型。通过 UMAP 算法对高维冶炼参数(如温度、氧枪高度、渣碱度等)进行非线性降维, 有效提取关键特征; 采用 GWO 优化 DNN 的初始权重和超参数, 显著提升模型收敛速度与稳定性。实验基于钢厂 200 炉次实际生产数据, 对比 BP 神经网络、标准 DNN 及 GWO-DNN 模型, UMAP-GWO-DNN 模型在  $\pm 0.001\%$  和  $\pm 0.002\%$  误差区间的命中率分别达到 86.7% 和 95.4%, 均方根误差(RMSE)降低 23.6%。工业验证表明, 该模型使终点磷含量波动标准差减少 41%, 平均值从 0.0012% 稳定至 0.0009%, 成功实现“窄窗口”控制目标。本研究为转炉冶炼过程的数字化升级提供了可推广的技术路径。

**关键词:** 终点磷含量; 转炉炼钢; 深度神经网络; 预测模型; 工业应用

**DOI:** 10.20057/j.1003-8620.2025-00142 **中图分类号:** TF711

## Prediction Model of End-point Phosphorus Content in Converter Based on UMAP-GWO-DNN

Wang Xueyuan<sup>1,2</sup>, Zhang Libin<sup>3</sup>, Zhou Chunfang<sup>1,2</sup>

(1 Chengde Jianlong Special Steel Co., Ltd., Chengde 067201, China; 2 Key Laboratory of High Clean and High Quality Special Steel Smelting for Semi Steel in Hebei Province, Chengde 067201, China; 3 Industrial Transformation and Upgrading Service Center of Hebei Provincial Development and Reform Commission, Shijiazhuang 050000, China)

**Abstract:** Precise control of the endpoint phosphorus content in converter steelmaking is a core aspect for enhancing steel quality and smelting efficiency. This study innovatively integrates Uniform Manifold Approximation and Projection (UMAP), Grey Wolf Optimization (GWO), and Deep Neural Network (DNN) technologies to construct a multimodal intelligent prediction model for 42CrMo steel. The UMAP algorithm is employed to perform nonlinear dimensionality reduction on high-dimensional smelting parameters (such as temperature, oxygen lance height, slag basicity, etc.), effectively extracting key features. The GWO algorithm is used to optimize the initial weights and hyperparameters of the DNN, significantly improving the model's convergence speed and stability. The experiments are conducted based on actual production data from 20 heats in a steel plant. Compared with the BP neural network, standard DNN, and GWO-DNN models, the UMAP-GWO-DNN model achieves hit rates of 86.7% and 95.4% in error ranges of  $\pm 0.001\%$  and  $\pm 0.002\%$ , respectively, and the root mean square error (RMSE) is reduced by 23.6%. Industrial validation shows that this model reduces the standard deviation of endpoint phosphorus content fluctuations by 41%, stabilizing the mean value from 0.0012% to 0.0009%, successfully achieving the "narrow window" control target. This study provides a scalable technical path for the digital upgrade of converter smelting processes.

**Key Words:** Endpoint Phosphorus Content; Converter Steelmaking; Deep Neural Network; Prediction Model; Industrial Application

钢铁工业是中国经济发展与国防建设的重要支柱产业, 2022 年我国粗钢产量已突破 10 亿吨, 位居世界第一<sup>[1-2]</sup>。同时, 钢铁行业也是能耗和碳排放的大户, 在“双碳”背景下, 如何减少炼钢过程能源及资源消耗是中国钢铁企业急需解决的难题<sup>[3]</sup>。转炉炼钢是长流程炼钢过程的关键环节之一, 具有温

度高、反应复杂和控制困难等特点。由于转炉冶炼过程取样测量困难以及原料品质的波动, 使得转炉终点精确控制难度较大<sup>[4-5]</sup>。

目前, 转炉终点控制主要分为人工经验控制, 静态模型, 动态模型等<sup>[6-7]</sup>。实际生产中, 为保证生产顺利及控制精度, 通常将几种控制手段结合使

作者简介: 王雪原(1976—), 男, 本科, 高级工程师; E-mail: wangxueyuan@ejianlong.com; 收稿日期: 2025-05-23  
通信作者: 周春芳(1986—), 女, 本科, 高级工程师; E-mail: zhouchunfang@ejianlong.com;

Editorial Office of Special Steel. OA under CC BY-NC-ND 4.0

用,但转炉终点控制效果依旧未得到根本改善。随着智能化制造在大工业生产中大规模应用,其中神经网络已成功应用于炼钢过程终点预测<sup>[8-9]</sup>、加料控制、精炼过程能量输入控制、温度控制、连铸过程表面缺陷检测以及漏钢预报等多种钢铁生产流程<sup>[10-12]</sup>。转炉终点磷含量是转炉终点控制的重要任务之一。这是由于钢液中磷含量过高时,冷却过程中磷元素会在晶界析出,形成“冷脆”缺陷,降低钢的塑性和韧性,严重影响钢产品的质量<sup>[13-14]</sup>。当前,转炉终点磷含量控制仍旧是采用人工经验控制,主要通过化渣情况、钢液温度及生产数据等因素综合评估终点磷含量范围。这种方法误差较大,难以达到稳定准确的控制效果。

目前,关于转炉终点控制及元素收得率的预测模型较多,且得到了较好的预测效果<sup>[15-18]</sup>。杨凌志等<sup>[19]</sup>建立反向传播(back propagation, BP)神经网络模型实现了转炉终点磷含量的预测。BP神经网络通常由重复的前向及反向传播来决定,其初始权重和阈值会随着隐含层节点数变化而变化,收敛和学习率较低,在工业生产应用具有耗时较长的缺点<sup>[20-21]</sup>。Mukherjee等<sup>[22]</sup>建立支持向量机(Support Vector Machine, SVM)模型应用于两个钢厂,分别获得64%和99.9%的准确率。SVM模型可解决高位问题且能够处理非线性特征的相互作用,但当数据样本较多时处理效率不高。同时,SVM模型并没有针对非线性问题的通用解决方案,难以应用于转炉现场的复杂工况<sup>[23-24]</sup>。田乃媛等<sup>[25]</sup>建立两步案例推理(Two Step-Case Based Reasoning, TS-CBD)模型预测终点磷含量,虽然解决了传统案例推理模型影响因素太多,求解效率低的问题,但在 $\pm 0.005\%$ 范围内命中率仅72.50%。张江山等<sup>[26]</sup>建立了主成分分析-深度神经网络(Principal Component Analysis-Deep Neural Network, PCA-DNN)预测钢包炉精炼过程元素收得率,在 $\pm 3\%$ 范围内获得了99.5%的准确率。DNN模型自由度高,非线性拟合能力强,在处理大样本数据量的场景中表现优异<sup>[27-28]</sup>。

以钢厂8转炉实际生产数据为建模样本,结合统一流形逼近与投影<sup>[29]</sup>(Uniform Manifold Approximation and Projection, UMAP)算法、灰狼优化算法<sup>[30]</sup>(Grey Wolf Optimizer, GWO)和深度神经网络(deep neural network, DNN)建立了42CrMo转炉冶炼终点磷含量预测模型。其中,UMAP降维算法可以有效处理高维、非线性数据集,运算性能优越。

引入GWO优化算法进一步优化DNN网络结构,能够进一步缩短模型处理时间,提高运算效率。实际工业生产中发现,相对于BP、DNN和GWO-DNN转炉终点磷含量预测模型,新建立的基于UMAP-GWO-DNN转炉终点磷含量预测模型预测精度最高,能够实现对转炉终点磷含量精确控制,可以有效应用于工业生产。

## 1 数据预处理和实验方法

### 1.1 数据预处理

数据来源于中国北部某钢企,以42CrMo钢为研究对象,生产工艺流程为氧气顶吹炼钢→钢包精炼→连铸。42CrMo钢的成分见表1。

表1 42CrMo钢的成分(质量分数)

Table 1 Composition of 42CrMo steel mass fraction				
				%
C	Si	Mn	P	S
0.41 ~ 0.43	0.22 ~ 0.26	0.56 ~ 0.60	≤0.018	≤0.008

收集了2024年1~3月间的1034条数据,最终得到775组实验数据,其中训练数据与测试数据的比例为8:2。记录转炉炼钢过程加料数据及钢液成分,共包括16个指标变量,然后利用公式(1)对数据进行归一化处理。

$$x_i^* = \frac{x_i - x_{i\min}}{x_{i\max} - x_{i\min}} \quad (1)$$

式中, $x_i$ 为输入的特征变量, $x_{i\max}$ 和 $x_{i\min}$ 为各独立样本数据的最大值和最小值。针对初始数据进行了数据质量评估、筛选等操作,通过去除异常数据,提高了数据集的数据质量,最终得到实验数据集。该数据集共有775组数据,其中,训练数据与测试数据的比例为8:2,数量分别为620组和155组。表2统计了每个指标变量的最大值、最小值、平均值和典型值。

典型值来源主要是基于大量的实验数据或生产数据统计而来,这些数据反映了材料或产品的关键性能指标。典型值列数据的作用主要有两点:一是用于分析和优化生产过程,帮助识别关键参数和潜在问题,从而改进生产工艺;二是为后续的产品设计、质量控制和性能评估提供依据,确保产品符合预定的标准和要求。

### 1.2 数据分析

采用灰色关联度方法分析了影响终点磷含量的关键因素,发现钢液温度、废钢质量和铁水磷含

表2 指标变量主要参数统计  
Table 2 Statistics of main parameters of indicator variables

指标变量	最大值	最小值	平均值	典型值
X <sub>1</sub> 铁水质量/t	90.9	69.1	79.58	81.8
X <sub>2</sub> 废钢质量/t	15.8	1.0	6.86	14.8
X <sub>3</sub> 倒炉次数/次	3.0	1.0	1.49	2.0
X <sub>4</sub> 钢液温度/°C	1 669	1 553	1 601.13	1 460
X <sub>5</sub> 氮气消耗量/m <sup>3</sup>	1 894	217	957.35	1 677
X <sub>6</sub> 吹氧量/m <sup>3</sup>	4 188	1 760	2 607.42	2 428
X <sub>7</sub> 石灰质量/kg	4 656	358	1 467.05	4 298
X <sub>8</sub> 白云石质量/kg	3 343	60	907.82	3 283
X <sub>9</sub> 合金渣重量/kg	2 070	0	684.11	2 070
X <sub>10</sub> 冶炼周期/min	53.12	25.57	36.23	27.55
X <sub>11</sub> 铁水 w[C]/%	4.53	4.21	4.34	4.31
X <sub>12</sub> 铁水 w[P]/%	0.126	0.094	0.106	0.032
X <sub>13</sub> 铁水 w[S]/%	0.079	0.026	0.044	0.053
X <sub>14</sub> 钢液 w[C]/%	0.420	0.010	0.091	0.410
Y <sub>1</sub> 钢液 w[P]/%	0.039	0.002	0.015	0.037

量等因素与终点磷含量高度相关。灰色关联理论<sup>[31-33]</sup>是通过确定目标参数序列和若干个比较参数序列的几何形状相似程度来判断其联系是否紧密,它反映了曲线间的关联程度,用数值大小定量的表示。若一个比较参数和目标参数的发展态势越趋于同步,其关联度值越趋近数值;反之,则趋近于0。计算步骤如式(2)-(6)

#### 1) 确定参数列表

设  $n$  个比较序列(比较参数),每个比较序列有  $m$  个元素。则  $n$  个比较序列的数据构成矩阵。

$$(X'_1, X'_2, \dots, X'_n) = \begin{pmatrix} X'_1(1) & \cdots & X'_n(1) \\ \vdots & \ddots & \vdots \\ X'_1(m) & \cdots & X'_n(m) \end{pmatrix} \quad (2)$$

$n$  组数据中的目标参数值构成参考序列(目标参数序列)。

$$X'_0 = [X'_0(1), X'_0(2), \dots, X'_0(n)] \quad (3)$$

#### 2) 无量纲化处理

采用均值法进行无量纲化处理,得到无量纲化矩阵。

$$(X_1, X_2, \dots, X_n) = \begin{pmatrix} X_1(1) & \cdots & X_n(1) \\ \vdots & \ddots & \vdots \\ X_1(m) & \cdots & X_n(m) \end{pmatrix} \quad (4)$$

#### 3) 计算关联系数

$$\xi_i(k) =$$

$$\frac{\min_i \min_k |y(k) - x_i(k)| + \rho \max_i \max_k |y(k) - x_i(k)|}{|y(k) - x_i(k)| + \rho \max_i \max_k |y(k) - x_i(k)|} \quad (5)$$

式中,  $x_i$  为第  $i$  个比较参数,  $i=1, 2, 3, \dots, n$ ;  $\xi_i(k)$  为  $x_i$  对  $y(k)$  的关联系数;  $\rho$  为灰色分析系数,取值范围  $(0, 1)$ ,取 0.5;  $\min_i \min_k$  为第  $i$  个比较参数对应第  $k$  个目标参数的极小值;  $\max_i \max_k$  为第  $i$  个比较参数对应第  $k$  个目标参数的极大值。将各组对应的关联系数代入公式(6),可求出比较参数  $x_i$  与目标参数  $y(k)$  的关联度  $r_i$ 。

$$r_i = \frac{1}{n} \sum_{k=i}^n \xi_i(k) \quad (6)$$

#### 4) 评价标准

将所求出的关联度从大到小排序,组成对比较参数的评价序列,其关联影响程度大小与该参考序列保持一致。

### 1.3 模型建立

结合 UMAP 算法、GWO 算法和 DNN 建立了预测模型。UMAP 算法用于数据降维, GWO 算法用于优化 DNN 的网络结构, DNN 则用于最终的预测任务。

UMAP 算法<sup>[34-35]</sup>是一种数据信息提取融合的优化算法,通过假设数据均匀分布在拓扑空间中将其近似映射到低维空间,其算法参数设置见表 3。由于具有更优越的运算性能、更好的可扩展性同时保留了更多的关键信息,UMAP 算法可以有效避免了传统多域特征提取方法构造特征的高维、非线性、信息冗余等问题。UMAP 算法的步骤如式(7)-(9)

1) 求每个数据点  $x_i$  的  $k$  近邻,定义  $\delta_i$  和  $\sigma_i$ , 设公式中的未知参数为  $\delta_i$ 。

表 3 UMAP 算法参数设置  
Table 3 Parameter settings of UMAP algorithm

参数	符号	取值/类型	作用说明	设定依据
近邻数	$k$	15~50	控制局部与全局结构平衡:值越小保留局部特征越精细,值越大全局结构越完整	数据规模与拓扑均匀性假设
最小距离	$\delta_i$	自适应计算	通过公式(7)动态确定数据点间距阈值,保证邻域连通性	数据分布密度自适应
尺度参数	$\sigma_i$	数值迭代求解	通过公式(8)约束概率分布,使各点近邻权重和为 $\log_2(k)$	概率归一化需求
低维空间维度	-	2~3	降维后的目标维度(通常选择2或3维实现可视化)	信息保留与可视化需求
超参数 a,b	a,b	默认 $a \approx 1.93, b \approx 0.79$	控制低维空间力导向布局的吸引/排斥强度(公式(9))	流形结构经验值

表 4 GWO 算法参数设置  
Table 4 Parameter settings of GWO algorithm

参数	符号	取值/类型	作用说明	设定依据
狼群规模	-	20~50	$\alpha/\beta/\delta$ 领导者数量与种群总数,规模过小易陷入局部最优	问题复杂度平衡
最大迭代次数	$t_{max}$	100~500	算法终止条件,需确保收敛稳定性	收敛速度实验验证
收敛参数	$a$	2→0 线性递减	控制探索与开发平衡:初始 $a=2$ 增强全局搜索,迭代中线性降至 0 强化局部优化	猎物逼近行为模拟
随机向量	$r_1, r_2$	[0,1] 均匀分布	通过公式(12)(13)生成随机性,使 A、C 波动以跳出局部最优	群体智能随机策略
位置更新权重	-	$(X1+X2+X3)/3$	公式(20)中 $\alpha/\beta/\delta$ 的位置均值决定新一代灰狼位置	社会等级协作机制

$$\delta_i = \min \{ d(x_i, x_{ij}) | 1 \leq j \leq k, d(x_i, x_{ij}) > 0 \} \quad (7)$$

$$\sum_{j=i}^k \exp \left( \frac{-\max [0, d(x_i, x_{ij}) - \delta_i]}{\sigma_i} \right) = \log_2(k) \quad (8)$$

2) 使用力导向图布局算法计算  $x_i$  的加权  $k$  邻域图的低维分布。

$$x_i = \frac{-2ab \|y_i - y_j\|^{2(b-1)}}{1 + \|y_i - y_j\|_2^2} w[(x_i, x_j)](y_i - y_j) \quad (9)$$

式中,  $a$  和  $b$  是超参数;  $y_i$  和  $y_j$  为坐标。

GWO 是一种新型群体智能优化算法,具有结构简单、设置参数少、收敛速度快以及全局寻优能力强等优点<sup>[36]</sup>。GWO 是模仿灰狼群的捕食特点,以狼群追踪、包围、追捕、攻击猎物为目标,实现最优搜

索,步骤如下,其算法参数设置见表 4。

$$D = |CX_{p(t)} - X_{(t)}| \quad (10)$$

$$X_{(t+1)} = X_{p(t)} - AD \quad (11)$$

$$A = 2ar_1 - a \quad (12)$$

$$C = 2r_2 \quad (13)$$

式中,  $t$  表示当前迭代次数;  $A$  和  $C$  是系数,次;  $X_p$  为猎物的位置;  $X_{(t)}$  为灰狼个体第  $t$  代的位置;  $r_1$  和  $r_2$  是  $[0, 1]$  中的随机值。在狼群的捕食过程中,  $a$  由 2 线性接近至 0 模拟灰狼逼近猎物,与此同时  $r_1$  和  $r_2$  使得灰狼有机会跳出局部最优解。

$\alpha, \beta, \delta$  均为灰狼个体,灰狼个体跟踪猎物位置的数学模型描述如式(14)-(20)

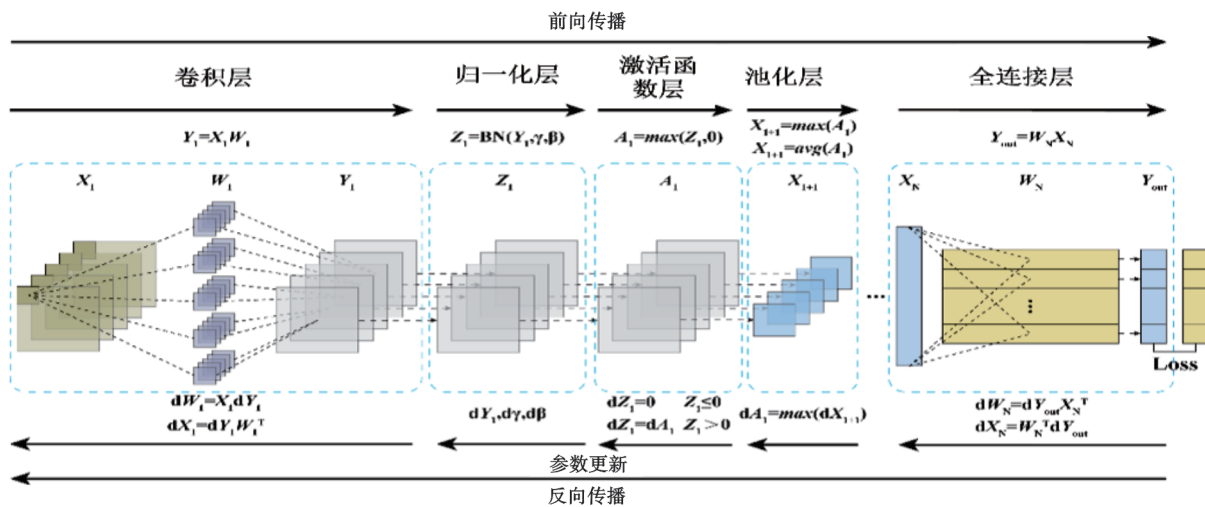


图 1 深度神经网络训练过程  
Fig. 1 Deep neural network training process

$$D_{\alpha} = |C_1 X_{\alpha} - X| \quad (14)$$

$$D_{\beta} = |C_2 X_{\beta} - X| \quad (15)$$

$$D_{\delta} = |C_3 X_{\delta} - X| \quad (16)$$

$$X_1 = X_{\alpha} - A_1 D_{\alpha} \quad (17)$$

$$X_2 = X_{\beta} - A_2 D_{\beta} \quad (18)$$

$$X_3 = X_{\delta} - A_3 D_{\delta} \quad (19)$$

$$X_{(i+1)} = \frac{X_1 + X_2 + X_3}{3} \quad (20)$$

式中,  $D_{\alpha}$ 、 $D_{\beta}$ 、 $D_{\delta}$  分别表示  $\alpha$ 、 $\beta$  和  $\delta$  与其他个体间的距离;  $X_{\alpha}$ 、 $X_{\beta}$ 、 $X_{\delta}$  分别代表  $\alpha$ 、 $\beta$  和  $\delta$  当前的位置;  $C_1$ 、 $C_2$ 、 $C_3$  是随机数;  $X$  是灰狼个体的当前位置。

DNN 是一种典型的深度学习方法<sup>[37]</sup>。传统 BP 神经网络只含有一个隐藏层,限制了其表达能力和学习能力,对于复杂的问题无法很好地进行建模和预测。而 DNN 模型通常由输入层、若干个隐藏层和输出层组成,信号从输入层向输出层单向传播。图 1 为深度神经网络训练过程。

DNN 模型最底层是输入层,中间是隐藏层,最后是输出层,其算法参数设置见表 5。每层有多个节点,相邻层的各个节点之间互相连接,所有节点都有输入、输出和存储数据的功能,其中隐藏层和输出层还有计算加权以及激活函数处理的功能。每个隐藏层中包含多个神经元,每个神经元都有自己的权重和偏置。其中神经元的权重是一个向量,表示输入数据在神经元中的重要程度。偏置是神经元的一个常数项,它可以调整神经元的输出值。神经元的权重和偏置是神经网络中需要训练的参数,通过反向传播算法可以更新这些参数,从而不断优化模型的性能。在 DNN 模型中,每一层对其输入进行非线性转换,并在这一层的输出中表示。DNN 模型中的数据只会按照输入层、隐藏层、输出

层的顺序单向流动,上一层的输出是下一层的输入。选择线性整流函数 (Rectified Linear Unit, ReLu) 为隐藏层的激活函数,相较于传统的 S 型函数,ReLu 函数具有防止梯度弥散、稀疏激活性与计算速度快等优势。

基于 UMAP-GWO-DNN 的元素收得率预测模型算法流程如图 2 所示。

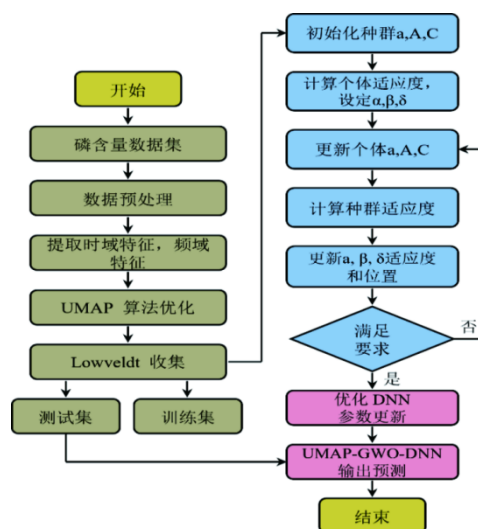


图 2 UMAP-GWO-DNN 预测模型算法流程

Fig. 2 UMAP-GWO-DNN prediction model algorithm flow

### 1.4 评价指标

选取均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、决定系数 (coefficient of determination, R2) 以及不同误差范围的命中率 (Hit rate, HR) 作为模型性能评价标准<sup>[5,8]</sup>, 各指标数学表达式为式

表 5 DNN 算法参数设置

Table 5 Parameter settings of DNN algorithm

参数	符号	取值/类型	作用说明	设定依据
网络结构				
输入层节点数	-	特征维度数	由 UMAP 降维后的特征数量决定	数据维度匹配
隐藏层数	-	3~5 层	深层结构增强非线性拟合能力 (图 1)	问题复杂性需求
隐藏层节点数	-	64~256	每层神经元数量, GWO 优化目标之一	特征表达能力平衡
输出层节点数	-	1 (w[P])	单输出回归任务	预测目标维度
训练参数				
激活函数	-	ReLU	隐藏层使用: $f(x) = \max(0, x)$ , 解决梯度消失问题并加速训练 (优于 Sigmoid)	梯度稳定性需求
损失函数	-	均方误差 (MSE)	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	回归任务标准指标
优化器	-	Adam	自适应学习率, 结合动量加速收敛	训练效率验证
学习率	$\eta$	$10^{-3} \sim 10^{-4}$	GWO 优化目标之一, 过大导致震荡, 过小收敛慢	超参数调优经验
批处理大小	-	32~128	单次训练样本数, 影响梯度更新频率	内存与收敛速度权衡

(21)-(25)。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2} \quad (21)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i| \quad (22)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - Y'_i}{Y_i} \right| \times 100\% \quad (23)$$

$$R^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2 - \sum_{i=1}^n (Y_i - Y'_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (24)$$

$$HR = \frac{n_{(|Y_i - Y'_i| \leq \varepsilon)}}{n} \times 100\% \quad (25)$$

式中,  $Y_i$ 、 $Y'_i$  和  $\bar{Y}$  分别代表实际值、预测值和平均值;  $n$  代表样本数。

## 2 结果和讨论

### 2.1 灰色关联

灰色关联度计算结果显示, 钢液温度、废钢质量和铁水磷含量是影响终点磷含量的主要因素。对 42CrMo 钢的 400 组数据进行灰色关联度计算。以转炉冶炼终点磷含量为参考目标, 表 2 中  $X_1$ - $X_{14}$  为比较序列中的比较参数进行灰色关联度计算, 计算的灰色关联度值如图 3 所示。




图 3 不同比较参数与转炉冶炼终点磷含量的灰色关联度  
Fig. 3 Gray correlation between different comparison parameters and end-point phosphorus in converter steelmaking

对比较参数灰色关联度大小的排序可知: 钢液温度 > 废钢质量 > 铁水磷含量 > 铁水质量 > 铁水碳含量 > 吹氧量 > 氮气消耗量 > 合金渣重量 > 倒炉次数 > 冶炼周期 > 石灰质量 > 钢水碳含量 > 铁水硫含量 > 白云石质量。

### 2.2 模型结构对预测结果的影响

以 RMSE 为评判标准 (RMSE (均方根误差, Root

Mean Squared Error) 是评估回归模型预测性能的核心指标, 用于量化预测值与真实值之间的平均偏差程度), 利用控制变量法确定了 UMAP-GWO-DNN 模型的超参数。首先控制隐藏层数量为 3, 隐藏层神经元数量为 30, 学习率设置为 0.01%, 正则项系数为 0.001, 改变初始迭代次数, 结果如图 4(a) 所示。随着初始迭代次数增加, RMSE 逐渐降低, 当初始迭代次数超过 3000 时, 曲线趋于平缓, 因此, 初始迭代次数最佳为 3000 次。

根据上述结论, 设置初始迭代次数为 3000 次, 其他超参数与上步相同, 改变正则项系数, RMSE 曲线呈“V”型。当正则项系数为 0.01 时, RMSE 最低为 2.31, 如图 4(b) 所示。设置初始迭代次数为 3000, 正则项系数为 0.01, 改变学习率, RMSE 曲线呈“U”型, 当学习率为 0.05 时, RMSE 最低为 2.43, 如图 4(c) 所示。以相同步骤确定隐藏层数为 3, 如图 4(d) 所示,  $N$  隐藏层神经元数为 30, 如图 4(f) 所示。

### 2.3 UMAP-GWO-DNN 模型与其他模型的比较

与 BP、DNN 和 GWO-DNN 模型相比, UMAP-GWO-DNN 模型在预测精度和泛化性能上均表现出色。在  $\pm 0.001\%$  和  $\pm 0.002\%$  范围内的命中率分别为 86.7% 和 95.4%, 优于其他模型。以相同原始数据为输入数据, 利用 BP 神经网络以及 DNN 预测模型进行预测, 并与本研究的 UMAP-GWO-DNN 模型预测结果进行对比。BP 模型选用含有一个隐含层的 3 层网络结构, 隐含层节点数设为 5, 初始学习率设定为 0.01%, 训练次数设为 3000 次, 激活函数选用线性函数, 训练函数选用 trainlm 函数。

图 5(a) 为 BP 神经网络预测转炉终点磷含量的结果, 其 RMSE 为 0.001 8, MAPE 值为 0.132,  $R^2$  仅为 0.481。预测 P 含量与实际值有较大差距, BP 模型的预测效果较差。DNN 模型预测效果相较于 BP 有所提升, 但预测精度依旧较低, 其 RMSE 为 0.001 4, MAPE 值为 0.097 6,  $R^2$  仅为 0.680, 如图 5(b) 所示。因此, 传统 BP 预测模型及 DNN 模型对于传统大工业生产过程中的大量数据预测效果不佳。而 GWO-DNN 神经网络预测精度较前两个模型有明显提升, 其 RMSE 为 0.000 9, MAPE 值为 0.058 0,  $R^2$  为 0.870, RMSE 值下降 0.000 5, MAPE 值下降 0.039 6,  $R^2$  值接近 0.9, 如图 5(c) 所示。表明 GWO-DNN 神经网络模型对于数据量较大的生产过程有较好的处理能力, 且对磷含量预测精度较高, 对炼钢过程关键因素的




图 4 RMSE(均方根误差)随不同因素的变化:(a)初始迭代次数,(b)正则化系数,(c)学习率,(d)隐藏层数,(e)DNN 预测模型的隐藏层神经元

Fig. 4 The variation of RMSE(root mean square error) with different factors : (a) initial number of iterations, (b) regularization coefficient, (c) learning rate, (d) number of hidden layers, (e) number of hidden layer neurons for the DNN prediction model

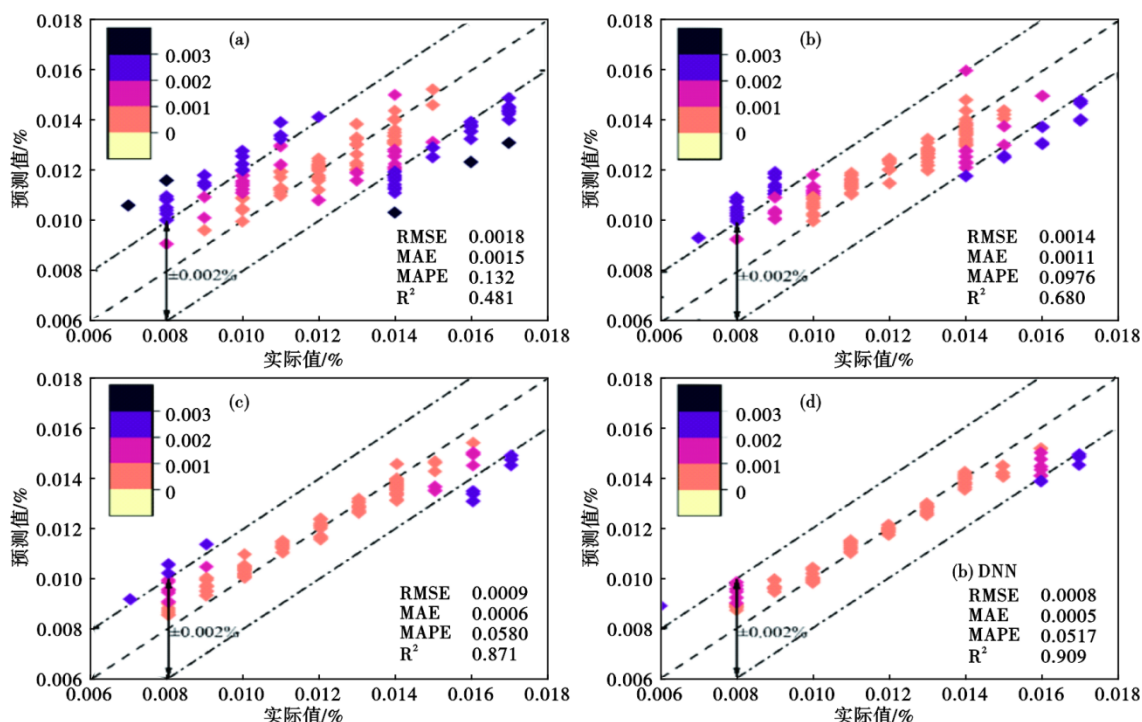


图 5 不同神经网络预测模型中实际和预测终点 P 含量值的比较:(a)BP,(b)DNN,(c)GWO-DNN,(d)UMAP-GWO-DNN

Fig. 5 Comparison between actual and predicted end-point P content values in (a) BP, (b) DNN, (c) GWO-DNN and (d) UMAP-GWO-DNN neural network prediction model

预测研究方面有显著优势。最后,UMAP-GWO-DNN 模型在 GWO-DNN 神经网络基础上引入 UMAP

降维算法,数据拟合能力进一步增强, RMSE 值达到 0.0008, MAPE 值达到 0.0517, R<sup>2</sup> 为 0.909, 如图 5(d)




图 6 不同神经网络预测模型中预测终点P含量命中率:(a)BP,(b)DNN,(c)GWO-DNN,(d)UMAP-GWO-DNN

Fig. 6 Hit rate predicting the end-point P content using (a) BP, (b) DNN, (c) GWO-DNN and (d) UMAP-GWO-DNN neural network prediction model.

所示。图6为四个模型在不同范围内的命中率占比统计。转炉终点磷含量BP预测模型在 $\pm 0.001\%$ 内的命中率为40.7%，在 $\pm 0.002\%$ 内的命中率为60.7%。在相同测试数据集的条件下，DNN预测模型在 $\pm 0.001\%$ 内的命中率为60%，在 $\pm 0.002\%$ 内的命中率为77.3%。GWO-DNN预测模型在 $\pm 0.001\%$ 内的命中率为82.7%，在 $\pm 0.002\%$ 内的命中率为92.7%。UMAP-GWO-DNN模型在 $\pm 0.001\%$ 内的命中率为86.7%，在 $\pm 0.002\%$ 内的命中率为95.4%。UMAP-GWO-DNN模型的预测精度较BP预测模型分别提升46%、34.7%，优化效果显著。

### 2.4 应用效果评价

将UMAP-GWO-DNN模型应用于42CrMo生产过程，发现预测误差均在 $\pm 0.002\%$ 以内，磷含量平均值由0.001 2%降至0.000 9%，实现了钢液的“窄成分”<sup>[38]</sup>控制。将本研究所建立的UMAP-GWO-DNN转炉终点磷含量预测模型应用于42CrMo钢生产过程，比较根据该模型预测钢液磷元素含量和实测值。其中，结合实际情况，选取100个炉次的转炉终点数据进行对比，实际误差均在 $\pm 0.002\%$ 以内，结果如图7所示。图8为应用UMAP-GWO-DNN预测模型前后转炉终点磷含量对比。结果表明，经UMAP-GWO-DNN模型预测磷含量辅助现场操作后的转炉炼钢过程磷元素含量比依据人工经验控制更稳定，磷元素含量平均值由0.001 2%降低为0.000 9%，实现转炉炼钢过程中实现钢液的“窄成分”控制。

转炉磷含量预测模型在特钢厂的核心价值体现为：工艺控制精度提升→质量缺陷减少→生产成本降低→跨工序智能协同。UMAP-GWO-DNN等先进模型的实际应用表明，在 $\pm 0.002\%$ 误差范围内实现稳定控制已具备工业化推广条件，为特钢企业“降本、提质、增效”提供关键技术支持。




图 7 UMAP-GWO-DNN模型预测钢液磷元素含量与实测值相对误差

Fig. 7 Relative error between the predicted phosphorus content of molten steel and the measured value by UMAP-GWO-DNN model




图 8 应用UMAP-GWO-DNN预测模型前后转炉终点磷含量

Fig. 8 Phosphorus content at the end of converter before and after applying UMAP-GWO-DNN predictive model

### 3 结论

本研究通过结合UMAP、GWO和DNN算法，建立了高精度的转炉终点磷含量预测模型。该模型

在实际应用中表现出色,为实现转炉炼钢的精确控制提供了有力支持。未来可进一步探索该模型在其他钢种和生产条件下的应用效果。

以42CrMo钢转炉终点磷含量为研究对象,以DNN为基础,结合灰色关联度分析,UMAP降维算法及GWO优化算法对转炉终点磷含量进行预测。得到以下结论:

1)炼钢过程数据呈非线性特点其而数据量巨大,DNN模型数据处理能力强,非线性拟合能力强。因此,利用DNN神经网络可有效预测转炉终点磷含量。转炉终点磷含量与钢液温度、废钢质量和铁水磷含量等因素高度相关。

2)通过比较不同实验参数下预测结果所得到

最佳UMAP-GWO-DNN神经网络结构的转炉终点磷含量预测模型。新模型初始迭代次数为3000,正则化系数为0.01,学习率为0.05,隐藏层数为3,隐藏层神经元数为30。

3)将UMAP-GWO-DNN神经网络结构与其他预测模型进行对比。UMAP-GWO-DNN神经网络结构磷含量预测模型在 $\pm 0.001\%$ 和 $\pm 0.002\%$ 内的命中率分别为86.7%、95.4%,相较于BP预测模型分别提高46%、34.7%。

4)实际应用过程中,磷含量预测模型误差均在 $\pm 0.002\%$ 内。转炉出钢时钢液中磷含量平均值由0.001 2%降低为0.000 9%,实现钢液“窄成分”控制。

#### 参考文献

- [1] Liu X, Bao Y P, Gu C, et al. Distribution and precipitation mechanism of TiN in industrial pure iron bloom [J]. *Steel Research International*, 2023, 94(3): 2200481.
- [2] Liu X, Wang D Z, Li Z W, et al. Efficient separation of iron elements from steel slag based on magnetic separation process [J]. *Journal of Materials Research and Technology*, 2023, 23: 2362-2370.
- [3] Tian B H, Wei G S, Li X, et al. Effect of hot metal charging on economic and environmental indices of electric arc furnace steelmaking in China [J]. *Journal of Cleaner Production*, 2022, 379: 134597.
- [4] Wang Z L, Bao Y P, Gu C. Convolutional neural network-based method for predicting oxygen content at the end point of converter [J]. *Steel Research International*, 2023, 94(1): 2370011.
- [5] Liu X, Bao Y P, Zhao L H, et al. Establishment and application of steel composition prediction model based on t-distributed stochastic neighbor embedding (t-SNE) dimensionality reduction algorithm [J]. *Journal of Sustainable Metallurgy*, 2024, 10(2): 509-524.
- [6] Xue C, Xu W L, Bao Y P, et al. Prediction of converter tapping weight based on principal component analysis-whale optimization algorithm-backpropagation algorithm neural network model [J]. *Steel Research International*, 2024, 95(3): 2300410.
- [7] Wang D Z, Gao F, Xing L D, et al. Continuous prediction model of carbon content in 12 converter blowing process [J]. *Metals*, 2022, 12(1): 151.
- [8] 刘玉潇,董艳伍,姜周华,等.基于MI和XGBoost算法电渣重熔终点磷含量预报模型[J].*特殊钢*, 2025, 46(1): 117-125.
- [9] 刘增山,冯亮花,康小兵.基于PSO-SVM模型的转炉终点预测[J].*特殊钢*, 2024, 45(3): 27-32.
- [10] Xin Z C, Zhang J S, Zheng J, et al. A hybrid modeling method based on expert control and deep neural network for temperature prediction of molten steel in LF [J]. *ISIJ International*, 2022, 62(3): 532-541.
- [11] Konovalenko I., Maruschak P., Brezinová J., et al. Steel surface defect classification using deep residual neural network. *Metals*, 2020, 10(6), 846.
- [12] Song Y J, Li S Z. Gas leak detection in galvanised steel pipe with internal flow noise using convolutional neural network [J]. *Process Safety and Environmental Protection*, 2021, 146: 736-744.
- [13] Zhao B, Wu W, Wu W, et al. Study on the occurrence of phosphorus in the slag of hot metal dephosphorization for stainless steel production [J]. *Steel Research International*, 2020, 91(7): 2000021.
- [14] Ye G F, Yang J, Zhang R H, et al. Behavior of phosphorus enrichment in dephosphorization slag at low temperature and low basicity [J]. *International Journal of Minerals, Metallurgy and Materials*, 2021, 28(1): 66-75.
- [15] Chen C, Wang N, Chen M. Prediction model of end-point phosphorus content in consteel electric furnace based on PCA-extra tree model [J]. *ISIJ International*, 2021, 61(6): 1908-1914.
- [16] He F, Zhang L Y. Prediction model of end-point phosphorus content in BOF steelmaking process based on PCA and BP neural network [J]. *Journal of Process Control*, 2018, 66: 51-58.
- [17] Zhou K X, Lin W H, Sun J K, et al. Prediction model of end-point phosphorus content for BOF based on monotone-constrained BP neural network [J]. *Journal of Iron and Steel Research International*, 2022, 29(5): 751-760.
- [18] Liu Z, Cheng S S, Liu P B. Prediction model of BOF end-point P and O contents based on PCA-GA-BP neural network [J]. *High Temperature Materials and Processes*, 2022, 41(1): 505-513.
- [19] Zou Y C, Yang L Z, Li B, et al. Prediction model of end-point phosphorus content in EAF steelmaking based on BP neural network with periodical data optimization [J]. *Metals*, 2022, 12(9): 1519.
- [20] Bashir T, Chen H Y, Tahir M F, et al. Short term electricity load forecasting using hybrid prophet-LSTM model optimized by

- BPNN[J]. *Energy Reports*, 2022, 8: 1678-1686.
- [21] Samantaray S, Sahoo A. Prediction of runoff using BPNN, FFBPNN, CFBPNN algorithm in arid watershed: A case study [J]. *International Journal of Knowledge-Based and Intelligent Engineering Systems*, 24(3): 243-251.
- [22] Li H, Barui S, Mukherjee S, et al. Least squares twin support vector machines to classify end-point phosphorus content in BOF steelmaking[J]. *Metals*, 2022, 12(2): 268.
- [23] Chandra M A, Bedi S S. Survey on SVM and their application in imageclassification[J]. *International Journal of Information Technology*, 2021, 13(5): 1-11.
- [24] Kurani A, Doshi P, Vakharia A, et al. A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting[J]. *Annals of Data Science*, 2023, 10(1): 183-208.
- [25] Liang Y R, Wang H B, Xu A J, et al. A two-step case-based reasoning method based on attributes reduction for predicting the endpoint phosphorus content [J]. *ISIJ International*, 2015, 55(5): 1035-1043.
- [26] Xin Z C, Zhang J S, Jin Y, et al. Predicting the alloying element yield in a ladle furnace using principal component analysis and deep neural network [J]. *International Journal of Minerals, Metallurgy and Materials*, 2023, 30(2): 335-344.
- [27] Aldahdooh A, Hamidouche W, Fezza S A, et al. Adversarial example detection for DNN models: A review and experimental comparison [J]. *Artificial Intelligence Review*, 2022, 55(6): 4403-4462.
- [28] Devan P, Khare N. An efficient XGBoost-DNN-based classification model for network intrusion detection system [J]. *Neural Computing and Applications*, 2020, 32(16): 12499-12514.
- [29] Sainburg T, McInnes L, Gentner T Q. Parametric UMAP embeddings for representation and semisupervised learning[J]. *Neural Computation*, 2021, 33(11): 2881-2907.
- [30] Tikhamarine Y, Souag-Gamane D, Najah Ahmed A, et al. Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey Wolf optimization (GWO) algorithm [J]. *Journal of Hydrology*, 2020, 582: 124435.
- [31] 邹雷雷, 吕庆, 刘东辉, 等. 基于加权灰色关联度法分析印尼海砂最佳配比的研究[J]. *中国冶金*, 2014, 24(9): 6-9.
- [32] Zhang S S, Gao H, Wei G W, et al. Grey relational analysis method based on cumulative prospect theory for intuitionistic fuzzy multi-attribute group decision making[J]. *Journal of Intelligent & Fuzzy Systems*, 2021, 41(2): 3783-3795.
- [33] Lv H L, Chen X Y, Wang X Y, et al. A novel study on a micro-mixer with Cantor fractal obstacle through grey relational analysis [J]. *International Journal of Heat and Mass Transfer*, 2022, 183: 122159.
- [34] Kobak D, Linderman G C. Initialization is critical for preserving global data structure in both t-SNE and UMAP[J]. *Nature Biotechnology*, 2021, 39(2): 156-157.
- [35] Wang Y F, Huang H Y, Rudin C, et al. Understanding how dimension reduction tools work: An empirical approach to deciphering t-SNE, UMAP, TriMAP, and PaCMAP for data visualization [J]. *J Mach Learn Res*, 2016, 22: 201: 1-201: 73.
- [36] Dubey A, Mishra R, Cheng C W, et al. Demonstration of a superior deep-UV surface-enhanced resonance Raman scattering (SERRS) substrate and single-base mutation detection in oligonucleotides [J]. *Journal of the American Chemical Society*, 2021, 143(46): 19282-19286.
- [37] Tembhrne J V, Almin M M, Diwan T. Mc-dnn [J]. *International Journal on Semantic Web and Information Systems*, 2022, 18(1): 1-20.
- [38] 李勃, 杨凌志, 等. 9 电弧炉炼钢流程一键合金加料优化系统应用[J]. *钢铁*. 2022, 57(4): 58-67.