

引文格式:吉露,王明刚,周剑,等.基于XGBoost-BiLSTM-Attention模型的铝电解槽氟化铝添加量预测[J].中国有色冶金,2025,54(3):80-90.

Ji Lu, WANG Minggang, ZHOU Jian, et al. Prediction of aluminum fluoride addition based on XGBoost-BiLSTM-Attention model[J]. China Nonferrous Metallurgy, 2025, 54(3): 80-90.

基于 XGBoost-BiLSTM-Attention 模型的铝电解槽 氟化铝添加量预测

吉露¹, 王明刚², 周剑², 周晓红²

(1. 贵州中准科技有限公司, 贵州 贵阳 550025; 2. 遵义铝业股份有限公司, 贵州 遵义 563100)

[摘要] 在铝电解生产过程中,氟化铝的添加量对维护电解的高效和稳定起着关键作用,目前多通过工艺经验决定,而实际上其与氧化铝检化验数据、铝水平、电解温度等多个因素存在复杂的非线性关系,呈现出动态变化性,仅凭经验难以进行准确决策。本文针对铝电解过程的非线性、大时滞和强耦合特点,在BiLSTM网络基础上融入软注意力机制,构建了高精度的氟化铝添加量预测模型,并进行了大量的数据训练、测试与验证,实验结果表明所提出的算法在预测氟化铝添加量上展现出很高的预测精度。该模型利用XGBoost算法获取局部特征,提升模型的预测准确性和运行效率;模型结合了双向LSTM,能同时考虑数据前后依赖关系,通过注意力机制动态调节特征权重,增强了预测精度;XGBoost-BiLSTM-Attention模型的平均误差为0.014,平均百分比误差为2.64,线性拟合度达到0.963,整体性能均超过现有模型。该预测模型展现出良好的预测效果,为铝电解生产过程中精准控制氟化铝添加量提供了重要的决策指导,模型的预测结果对提升铝电解槽生产效率、降低能耗和实现精准控制具有重要价值和意义。

[关键词] 铝电解; 氟化铝添加量; 注意力机制; XGBoost-BiLSTM-Attention; 预测精度; 节能降耗

[中图分类号] TF821; TF391.99 [文献标志码] A [文章编号] 1672-6103(2025)03-0080-11

DOI:10.19612/j.cnki.cn11-5066/tf.2025.03.009

0 引言

在铝电解生产中,工艺参数相互关联,形成了复杂的耦合关系。能量平衡与物料平衡对于保持电解过程的高效和稳定性起着关键作用,而这两种平衡又受到诸多因素的影响,如铝电解过程中合适的氟化铝添加量正是维护这两方面平衡的关键,也是确保生产过程中经济收益最大化的有效手段^[1]。适量的氟化铝能够有效降低电解质的分子比,减少电解质的温度,并提升电流的使用效率^[2]。但是,如

果氟化铝添加过量,则会使氧化铝的溶解性降低,导致未溶解的氧化铝在电解槽底部堆积,这可能会引起电解槽的异常运作。因此,确定适宜的氟化铝添加量对于实现电解槽生产的节能和高效率极其重要^[3]。

目前,在铝电解生产过程中,氟化铝的添加量多通过工艺经验决定,且添加量又受各种因素影响,包括氧化铝检化验数据、铝水平、电解温度等。这些因素之间同时存在复杂的非线性关系,使得氟化铝每日添加量呈现出动态变化性^[4],这也导致工艺人员无法根据电解槽的实时变化情况,准确进行决策。近年来,众多专家学者致力于研究如何更有效控制氟化铝添加量,并提出了一系列策略。例如,黄涌波^[5]采用回归分析与遗传算法相结合的控制策略优化了氟化铝添加。彭强强等^[6]通过分析生产数据得出回归相关系数,建立了氟化铝添加量的决策

[收稿日期] 2024-12-11

[第一作者] 吉露(1995—),贵州毕节人,硕士,中级工程师、数据分析工程师,研究方向为深度学习,从事工业大数据分析与平台开发相关工作。

模型。张兴彤等^[7]借助在线检测装置,分析电解槽热平衡状态来确定氟化铝添加量。在神经网络的运用方面,Yue等^[8]将数据驱动和知识驱动相结合,提出增强型的 MDAAA 模糊策略控制氟化铝添加量。常家玮等^[9]利用深度学习算法研究铝电解过程中氟化铝添加量和出铝量的精准预测,取得了较好的效果。

氟化铝添加量的预测模型经历了从工艺经验、统计学习、机器学习到深度学习的演进,每个阶段都取得了显著成果。本文针对铝电解过程的非线性、大时滞和强耦合特点,在 BiLSTM 网络基础上融入软注意力机制。首先利用 XGBoost 选取对预测结果贡献大的局部特征,将局部特征输入带有注意力机制的 BiLSTM 模型,为特征向量分配权重,捕捉特征间的长距离依赖关系,并优化权重参数矩阵,最终建立了高精度的预测模型。通过采用该模型对贵州某铝厂的实际生产数据进行分析,验证了其有效性,模型分析预测结果对提升铝电解槽生产效率、降低能耗和实现精准控制具有重要价值和意义。

1 模型原理

1.1 XGBoost 算法原理

XGBoost 是集成多棵决策树预测结果的权重求和模型^[10-11],即由 t 个基决策树模型组合而成的集成模型,假设 $f_t(x)$ 为模型第 t 次迭代要输出的结果, $N_t(x)$ 为输入节点 x 在第 t 棵树的叶子节点区域,则算法 XGBoost 的输出见式(1)。

$$\hat{y}_i = \sum_{t=1}^T f_t(x_i) = \sum_{t=1}^T \sum_{q=1}^Q \omega_{qt} I(x_i \in N_{qt}) \quad (1)$$

式中: \hat{y}_i 表示第 i 个样本的预测值; T 表示决策树数量; f_t 表示第 t 棵决策树输出结果; x_i 表示第 i 个样本的特征向量; ω_{qt} 为第 t 棵树的第 q 个叶子节点的权重大小; $I(x_i \in N_{qt})$ 代表指示函数。

XGBoost 采用梯度提升算法逐步拟合残差,假设已有 $t-1$ 棵树,第 t 棵树的目标是拟合上一轮残差 $y_i - f_{t-1}(x)$,则第 t 棵树的目标函数为公式(2)。

$$L^{(t)} = \sum_{i=1}^n l(y_i, f_{t-1}(x_i) + f_t(x_i)) + \Omega(f_t) \quad (2)$$

式中: $l(y_i, f_{t-1}(x_i) + f_t(x_i))$ 为损失函数; $\Omega(f_t)$ 表示正则化项。

1.2 BiLSTM 模型原理

LSTM 是一种特殊的循环神经网络 (Recurrent

Neural Network, RNN) 模型^[12,13],在 RNN 基础上新增门限,包括遗忘门、输入门和输出门,其结构如图 1 所示。

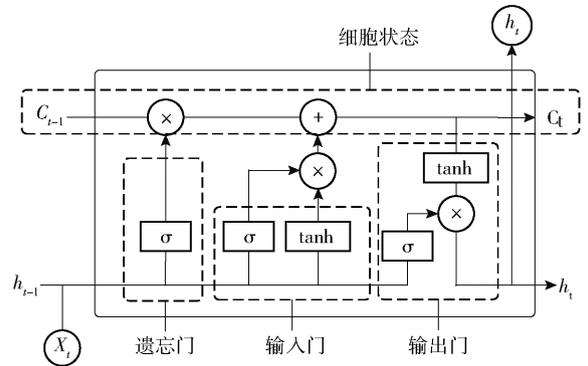


图 1 LSTM 神经元结构

Fig. 1 LSTM neuronal structure

LSTM 神经元通过门控机制管理状态信息,接收前一时间步的输出和当前时间步的输入。首先,遗忘门决定丢弃的信息,然后输入门收集当前信息并形成记忆,最终将更新后的状态传递给下一个神经元^[14]。

遗忘门的计算公式见式(3)。

$$f_t = \sigma(W_f[h_{t-1}, x_t]) + b_f \quad (3)$$

输入门和 t 时刻神经元状态的方程见式(4)——(6)。

$$i_t = \sigma(W_i[h_{t-1}, x_t]) + b_i \quad (4)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t]) + b_c \quad (5)$$

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \quad (6)$$

输出门方程见式(7)(8)。

$$o_t = \sigma(W_o[h_{t-1}, x_t]) + b_o \quad (7)$$

$$h_t = o_t \tanh(c_t) \quad (8)$$

式(4)——(8)中: f_t, i_t, o_t 代表三个门的控制信号及激活值; \tilde{c}_t 为候选记忆值向量; c_{t-1} 表示前一细胞状态; c_t 表示当前细胞状态; h_t 为当前状态输出; h_{t-1} 表示前一状态的输出; x_t 表示当前状态的输入; W_f, W_i, W_c, W_o 为权重; b_f, b_i, b_c, b_o 为偏置量; σ 为 sigmod 激活函数; \tanh 为双正曲函数。

BiLSTM 模型是一种结合了前向和后向信息的双向长短期记忆模型^[15, 16],在两个方向上对信息进行处理,前向层和后向层都存在隐藏层,这些隐藏层可在给定时间内同时提取前向和后向密钥信息,可获得更充分的数据特征,有助于提高模型的预测精度^[17]。BiLSTM 的模型结构图如图 2 所示。

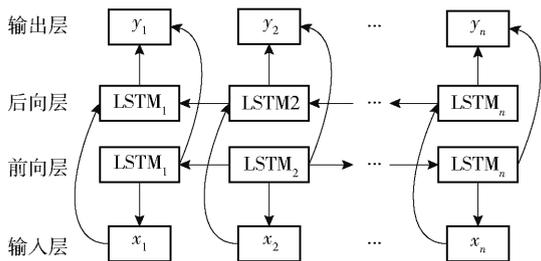


图2 BiLSTM 模型结构图

Fig.2 BiLSTM model structure diagram

BiLSTM 每一级隐藏层状态组合过程见式(9)–(11)。

$$h_t = LSTM(x_t, h_{t-1}) \quad (9)$$

$$h_t = LSTM(x_t, h_{t-1}) \quad (10)$$

$$h'_t = a_t h_t + b_t h_t + c_t \quad (11)$$

式中： h'_t 为每一级隐藏层状态； h_t 为前向层状态； h_t 为后向层状态； a_t, b_t 为权重； c_t 为偏置。

1.3 注意力机制

注意力机制通过聚焦重要特征来提升预测精度^[18]，通常分为硬注意力机制与软注意力机制。硬注意力机制随机选择输入序列中的信息，增加记忆训练难度；而软注意力机制则结合序列数据信息和输入信息计算加权平均值^[19]，有效提高模型对关键信息的关注度，实现合理的资源分配。本文引入软注意力机制提高氟化铝添加量预测模型准确率。

2 XGBoost – BiLSTM – Attention 模型

XGBoost – BiLSTM – Attention 模型充分利用 BiLSTM 网络的优势和注意力机制。该模型在利用 BiLSTM 网络的同时处理基于前向和后向的网络输

入，在特定时刻获取前一时刻和下一时刻的信息，捕捉数据的时序信息，其独特的双向网络结构，极大的提高训练过程中模型在输入信息的开始和结束阶段的信息记忆；另外，该模型还在 BiLSTM 网络基础上嵌入注意力机制，使得模型合理分配权重，增强关键信息的注意力。此改进模型可提高氟化铝添加量的预测效果，其网络结构如图3所示。

XGBoost – BiLSTM – Attention 模型可分为特征提取层、输入层、BiLSTM 层、注意层和输出层五部分。

1) 特征提取层。收集历史电解槽控制系统日报数据，采用 XGBoost 算法进行特征降维，对特征重要性评判并筛选出有效数据特征，提高模型训练速度和精度。

2) 输入层。对特征提取后的数据集划分训练集和测试集，输入模型的特征向量，本文的输入层侧重于将电解槽控制系统日报数据预处理成 BiLSTM 层直接接收和处理的向量。

3) BiLSTM 层。BiLSTM 层由正向和反向 LSTM 层组成，可设定 BiLSTM 算法的学习率、神经元个数和迭代次数等参数，捕捉序列前后信息特征。

4) 注意力层。该层核心为特征权重系数，在氟化铝添加量预测中，通过注意力机制训练神经网络，将注意力集中在某些关键特征，第一个阶梯计算每个特征重要性，根据特征重要性为每个特征分配相应权重，从输入初始状态过渡到新的注意状态，得到最终的输出状态向量。

5) 输出层。输出层的输入是隐藏层中注意力机制的输出，本文主要是对氟化铝添加量 y 向量的预测；通过不断优化更新权重和偏置量，使模型结构

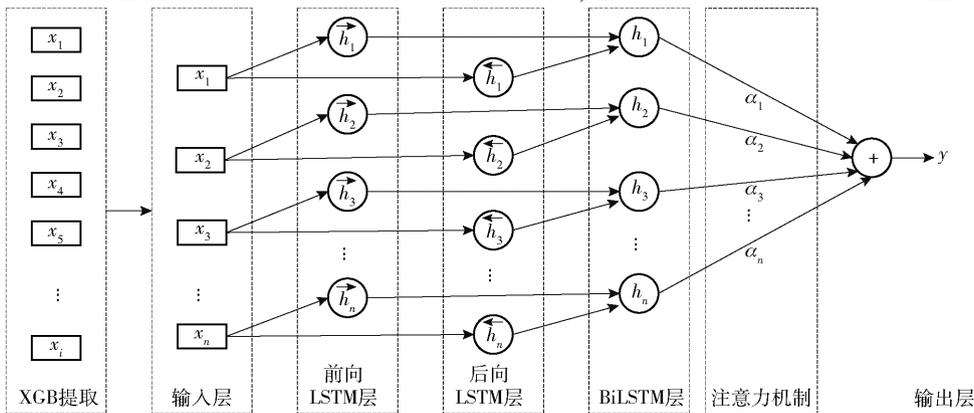


图3 XGBoost – BiLSTM – Attention 模型结构

Fig.3 XGBoost – BiLSTM – Attention model structure

中的损失函数逐渐变小,网络模型在训练期间优化更好。对训练集进行训练,模型完成设定的迭代次数后,获取模型训练的输出值。

采用预测结果的均方误差(MSE)作为适应度函数衡量神经元适应程度,确定全局最优适应值及最优全局位置。

3 实验

3.1 数据处理与分析

3.1.1 数据处理

本文数据集收集了贵州某铝厂 400 kA 系列 16 台槽(601—616 槽),近 1 年的电解槽控制系统日报

数据(2023-08-10 至 2024-08-10),共计 5 760 个时间序列和 15 个变量组成的氟化铝添加量数据集,数据以每日为单位进行收集。

收集电解槽控制系统日报多项关键工艺参数,涵盖日期、槽编号、铝水平、氧化铝浓度、电解质水平、电解温度、分子比、氟化铝添加量、平均电压、设定电压、工作电压、下料间隔(即设定的 NB 值)以及出铝量指示等共计 15 个重要指标。在实际生产过程中,分子比和阴极压降数据每周仅测量两次,导致数据缺失较为严重,因此在进行模型构建和训练时,需要对这两个参数的缺失数据进行填充,表 1 展示了部分收集到的日报数据。

表 1 电解槽控制系统近 7 d 的部分日报数据

Table 1 Partial daily data of the electrolytic cell control system in recent 7 days

样品 数据 编号	铝 水平/ cm	电解质 水平/ cm	电解 温度/ ℃	平均 电压/ V	分子 比	氧化 钠/%	氧化 钙/%	氧化 钾/%	设定 NB/ s	Fe 含量/ %	Si 含量/ %	炉底 压降/ mV	氧化铝 下料量/ t	均设 差* /v	氟化铝 添加量/ kg
1#	26.5	18	951	3.869	2.44	0.197	0.012	0.021	90	0.086	0.045	196	5.714	0.021	30
2#	28	17	959	3.973	2.42	0.178	0.013	0.017	90	0.085	0.047	193	5.537	0.03	26
3#	26	18	941	3.886	2.4	0.233	0.013	0.028	90	0.117	0.046	179	5.691	0.023	23
4#	27	18	947	3.885	2.36	0.209	0.013	0.022	88	0.112	0.043	183	5.722	0.021	17
5#	29	18	946	3.871	2.46	0.198	0.012	0.021	91	0.101	0.049	185	5.928	0.020	33
6#	29.5	16	950	4.008	2.44	0.214	0.007	0.037	88	0.082	0.032	264	6.624	0.036	30
7#	29	17	952	3.995	2.5	0.197	0.007	0.039	90	0.091	0.032	270	6.251	0.035	33

注:均设差*表示平均电压与设定电压之差。

1)数据缺失值填充。数据集中通常包含缺失或错误的值,由槽控制系统故障、人工测量误差和系统存储故障等原因造成,对模型预测精度造成较大影响。本文采用 KNN 算法对缺失值进行填补,选择与缺失数据样本相邻的 k 个邻居对样本中的缺失值依次填补,直到不存在缺失值。

2)数据异常值处理。由于人工测量数据不可靠、测量设备或其他因素等原因,槽控系统所采集的数据可能存在异常,在一定程度上影响模型预测精度,本文采用 3σ 原则识别数据集中异常值,将数据值超出 $(u-3\sigma, u+3\sigma)$ 范围的数据作为异常数据剔除。该方法可有效处理异常值,增加模型预测精度。

3)数据归一化处理。收集的氟化铝添加量数据集内,不同特征间的差别较大,例如氧化铝下料量、电解温度等数据与 Fe、Si 等化验数据的值相差较大。本文对数据进行归一化处理,以便进行综合性分析及后期数据的特征相关性分析,还解决了神

经网络模型对不同数据的敏感度问题。结合电解槽实际生产情况,采用 Max - Min 缩放方法对数据规范化,将数据映射到 $[0, 1]$ 区间,见式(12)。

$$f(x_i) = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (12)$$

3.1.2 数据分析

目前大多特征相关性分析都采用 Pearson 相关性分析及随机森林(RF)相关性分析,其中 Pearson 算法只能分析出两个变量的线性关系^[20, 21],无法确定更高维度特征的因果关系,导致模型在输入时维度过大,增加模型的复杂性,降低模型预测精度。RF 算法虽然在特征工程和分类预测领域得到了广泛应用,可以对各个特征的重要性进行评价,但在面对庞大且复杂的数据集时,RF 算法模型的运行速度会降低,这将导致模型复杂度增加。为降低模型输入特征数量,提高模型预测能力,采用 XGBoost 获取局部特征,特征选择流程如图 4 所示。

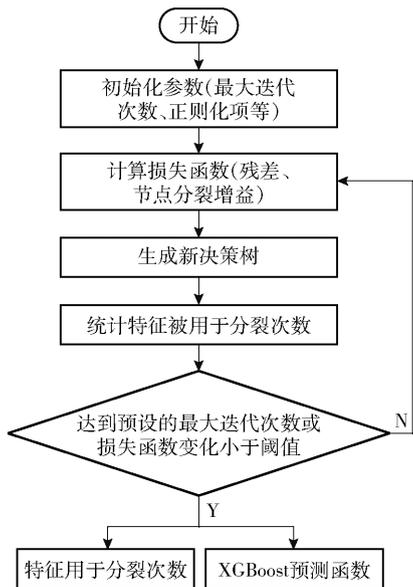


图4 XGBoost 算法特征提取流程

Fig. 4 XGBoost algorithm feature extraction process

XGBoost 算法特征选择的具体步骤如下所述。

1) 初始化模型。设置 XGBoost 的超参数,如学习率、树的最大深度、正则化等参数。

2) 计算损失函数。迭代计算出训练样本残差、决策树节点增益等。

3) 生成新决策树。利用贪心算法选择分裂点,生成新的决策树。

4) 统计分裂次数。分裂出的决策树添加至预测函数,汇总用于节点分裂的特征次数。

5) 预设值判断。判断损失函数变化或最大迭代次数是否满足预设值,若满足,继续转到下一步,若不满足,则返回步骤 2), 计算迭代计算损失函数变化。

6) 特征评估。分析特征在模型训练中的贡献度,评估特征重要性,获取影响系数,经过 XGBoost 算法特征选择后的特征重要性如图 5 所示。

如图 5 所示,根据 XGBoost 算法的分析结果,特征重要性大于 0.1 的包括分子比、氧化钠、氧化钾、氧化铝下料量,这些参数对氟化铝添加量存在不同程度的影响,其中分子比重要性达到了 0.64,对氟化铝添加量模型影响占据主导,该现象与工艺机理特性相符合^[22]。若重要性以 0.1 为阈值会导致特征维度较少,为降低模型过拟合风险和模型复杂度,本文选取特征重要性大于 0.05 的 9 个特征(电解质

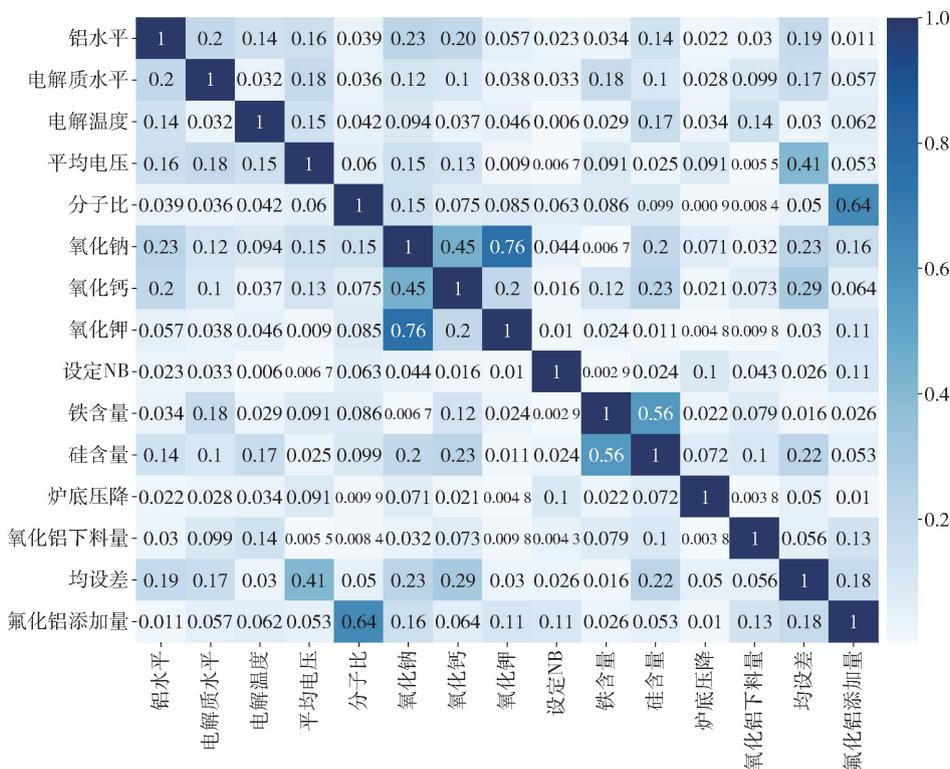


图5 XGBoost 特征重要性结果

Fig. 5 XGBoost feature importance results

水平、电解温度、平均电压、分子比、氧化钠、氧化钙、氧化钾、硅含量、氧化铝下料量) 构建特征集, 作为后续模型的输入特征。

3.2 模型参数配置及训练

本文模型训练采用控制变量法, 对输入参数 (input)、随机失活率 (dropout)、学习率 (learning_rate)、批尺寸 (batch_size)、训练周期 (epoch)、滑动窗口 (sliding_window) 分别优化。其中 dropout 选取 0~1 范围内的四个常用值 0、0.01、0.5、0.9 进行实验, learning_rate 按照 0.1、0.01、0.001 的降序进行实验, epoch 以 100 轮次递增的顺序进行实验, batch_size 以 128 为递增顺序进行实验。sliding_window 以 7 为递增的顺序进行实验, 其余参数均使用默认值。各模型优化后的参数如表 2 所示。

表 2 模型参数配置

Table 2 Configuration of model parameters

模型参数	XGBoost -			
	BiLSTM-Attention	LSTM	LSTM-Attention	RF-BiLSTM
sliding_window	7	3	4	6
lstm_units	16	8	16	16
learning_rate	0.001	0.057	0.126	0.048
dropout	0.01	0.06	0.05	0.02
epoch	300	300	300	300
input_size	9	9	9	9
output_size	1	1	1	1
batch_size	128	128	128	256
optimizer	ADAM	SGD	ADAM	ADAM

在实验中, 训练集和测试集按照比例 8:2 划分, 训练集规模为 (4 608, 7, 9), 测试集规模为 (1 152, 7, 1)。模型训练流程如图 6 所示, 实验过程分为五个步骤, 如下所述。

1) 输入大小为 (4 608, 7, 9) 的训练集样本, 共 4 608 条记录, 步长 sliding_window 为 7, 维度 input_size 为 9。

2) 随机初始化模型参数, 参数配置如表 2 所示, 包括 dropout、learning_rate、epoch 等。

3) 训练数据由 BiLSTM 学习, 特征向量 (None, 7, 9) 为输出, 通过注意力机制层将权重与时间状态连接, 最后通过 softmax 函数输出氟化铝日添加量预测结果 output_size。

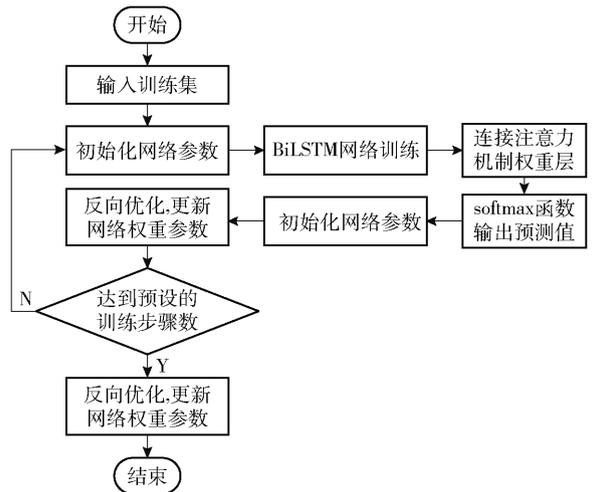


图 6 模型训练流程图

Fig. 6 Model training flow chart

4) 通过计算交叉熵损失来评估模型性能, 并使用 ADAM 优化器来调整网络中的权重参数。这一调整过程利用学习率计算损失函数梯度, 并沿负梯度方向优化模型, 将模型的预测输出与实际标签进行对比分析。

5) 根据模型训练流程, 重复模型训练步骤 1)~4)。

3.3 预测效果评价

3.3.1 模型评估及验证

四种模型在同样参数配置下的损失曲线变化如图 7 所示, XGBoost-BiLSTM-Attention 模型训练的损失曲线如图 7(a), 损失曲线随着模型训练时间的增加逐渐降低, 当迭代次数达到 300 轮时, 损失曲线下下降幅度减小并趋于平稳, 模型对训练集和测试集的拟合效果与稳定性最好。LSTM、LSTM-Attention 和 RF-BiLSTM 模型的曲线如图 7(b)~(d), 其中 LSTM 模型损失曲线存在较大波动, 模型训练不稳定。LSTM-Attention 与 RF-BiLSTM 模型的损失曲线经过较长时间训练后, 依然未能收敛。三个模型的拟合均存在噪声干扰和波动, 导致测试集的损失值具有随机性, 拟合效果较差。

根据实际氟化铝添加量值和预测的氟化铝添加量, 采取常用的评估指标 (均方误差 (MSE)、平均绝对百分比误差 (MAPE) 和模型拟合度 (R^2)) 评价模型的预测结果^[23]。MSE、MAPE 和 R^2 的计算式见式 (13)~(15), MSE 和 MAPE 越接近 0, R^2 越接近 1, 表明模型的拟合效果越好。

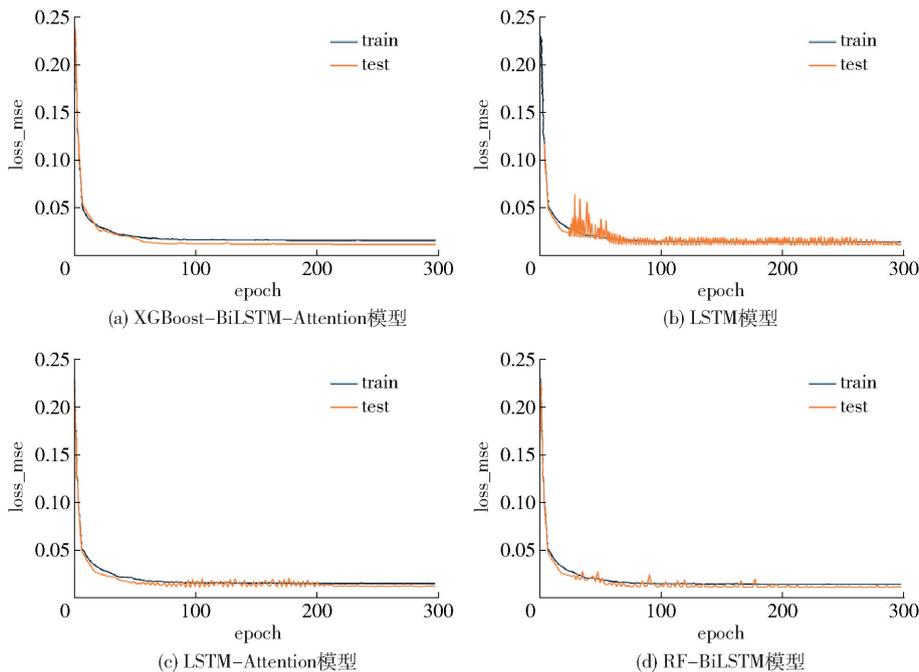


图7 损失曲线对比图

Fig.7 Loss curve comparison diagram

$$MSE = \frac{1}{n} \sum_{i=1}^n |(y_i - \tilde{y}_i)| \quad (13)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \tilde{y}_i}{y_i} \right| \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (15)$$

式(13)–(15)中： n 为数据集中的样本数； y_i 为实际值； \tilde{y}_i 为模型预测值； \bar{y}_i 为实际值的均值。当MSE、MAPE和 R^2 的值越趋近于0，表明模型效果越好。

如图8、图9所示，XGBoost-BiLSTM-Attention模型经特征降维、增加注意力机制权重等处理后，训练集和测试集的 R^2 值最大，误差值最小。XGBoost-BiLSTM-Attention模型与LSTM、LSTM-Attention和RF-BiLSTM模型的预测结果对比，其MSE值相较于LSTM、LSTM-Attention和RF-BiLSTM分别降低0.244%、0.062%和0.039%。MAPE值比LSTM、LSTM-Attention和RF-BiLSTM分别降低0.244%、0.062%和0.039%。 R^2 值比LSTM、LSTM-Attention和RF-BiLSTM分别提高8.6%、5.3%和3.6%。结果表明，本文模型的MSE与MAPE值较低，模型稳定性好； R^2 值较大，模型的拟合相关性强。在训练

集(train)和测试集(test)上的实验结果均验证了XGBoost-BiLSTM-Attention模型对氟化铝添加量预测的结果均普遍优于其他模型。

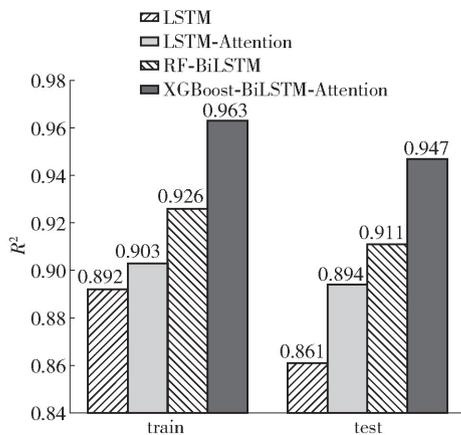


图8 R^2 对比图

Fig.8 R^2 comparison diagram

为量化XGBoost-BiLSTM-Attention模型对氟化铝添加量的影响，分别利用LSTM、BiLSTM、RF-BiLSTM模型进行训练，评估指标结果见表3。

从训练结果可看出，在测试集和训练集上，XGBoost-BiLSTM-Attention模型优于其他模型，在 R^2 、MSE和MAPE和指标上，本文模型的预测精度达到

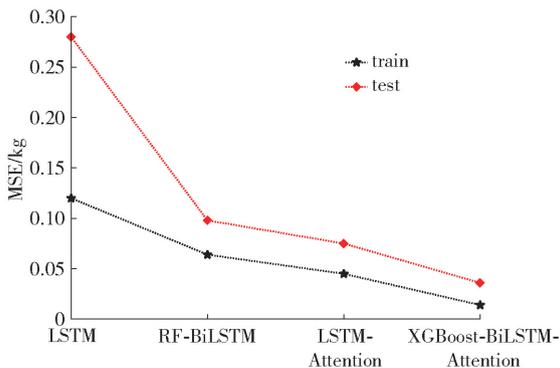


图9 MSE对比图

Fig. 9 MSE comparison diagram

表3 各模型评价指标分析

Table 3 Analysis of evaluation indicators of each model

对比模型	训练集			测试集			训练时间/s
	MSE/kg	MAPE/kg	R ²	MSE/kg	MAPE/kg	R ²	
LSTM	0.12	10.83	0.892	0.28	12.89	0.861	271
LSTM-Attention	0.64	5.17	0.903	0.098	9.04	0.894	254
RF-BiLSTM	0.045	4.28	0.926	0.075	7.15	0.911	247
XGBoost-BiLSTM-Attention	0.014	2.64	0.963	0.036	3.29	0.947	232

LSTM-Attention 模型与 RF-BiLSTM 相比之下拟合度较高,但 XGBoost-BiLSTM-Attention 模型经特征降维、注意力机制优化后,具有更高的预测精度,预测曲线与真实值高度吻合。这表明,本文提出的算法能够较好拟合数据,拟合度明显优于其他三个模型,具有更强的预测能力和准确性。

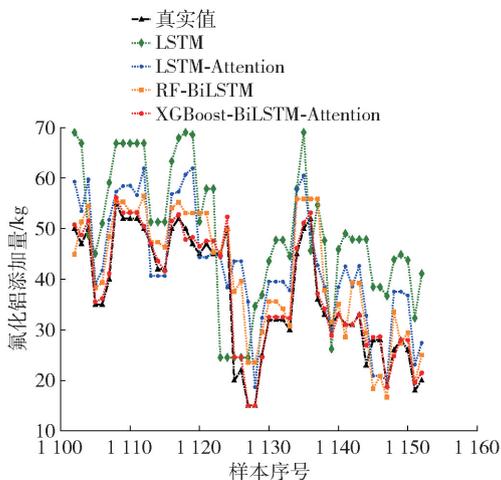


图10 模型预测结果对比

Fig. 10 Comparison of model prediction results

0.947,均方误差达到 0.036,平均绝对百分比误差为 3.29。在模型训练时间方面,四个模型的平均训练时间为 251 s,而 XGBoost-BiLSTM-Attention 模型的执行时间时间相对较短为 232 s,尽管该模型引入了注意力机制,但训练时间对比三个模型均有所缩短,既减少了训练时长,又提升了模型的预测精度。

3.3.2 预测结果可视化

本文选择测试集中的最后 50 条样本绘制预测效果图,根据训练后的模型对测试集进行预测,并与现有预测模型进行对比,如图 10 所示。结果表明,LSTM 模型的预测误差较大,且预测曲线与真实值之间存在明显偏离,反映出该模型拟合效果较差。

3.4 适用性验证

为验证模型的可靠性及适用性,选取贵州某铝厂的 2816 号电解槽连续 7 d 的预测数据对模型进行验证,预测结果如表 4 所示。

由表 4 可知,预测值与真实值之间的平均绝对误差为 1.06,且其极差在 0.301 6 至 2.276 2 之间。该误差范围表明模型的预测结果与实际值之间的偏差小,且不存在明显的波动幅度,对铝电解槽实际生产过程中分子比、电解温度等关键参数的稳定性不会产生显著影响,能够保证生产过程的精准控制和平稳运行。

4 结论

本文针对铝电解过程的非线性、大时滞和强耦合特点,在 BiLSTM 网络基础上融入软注意力机制构建了氟化铝添加量的高精度预测模型,并进行了大量的数据训练、测试与验证,实验结果表明所提出的算法在预测氟化铝添加量上展现出很高的预测精度,模型预测结果对提升铝电解槽生产效率、降低能耗和实现精准控制具有重要价值和意义。

1) 利用 XGBoost 算法获取局部特征,提升模型

表 4 氟化铝添加量预测模型验证

Table 4 Verification of the prediction model of aluminum fluoride addition

日期	2024-07-16	2024-07-17	2024-07-18	2024-07-19	2024-07-20	2024-07-21	2024-07-22
真实值/kg	30	27	33	30	23	34	30
预测值/kg	30.548 6	28.386 1	33.763 2	30.301 6	25.276 2	34.824 1	31.321 0
误差绝对值/kg	0.548 6	1.386 1	0.763 2	0.301 6	2.276 2	0.824 1	1.321 0

的预测准确性和运行效率。

2) 本文所提出的 XGBoost - BiLSTM - Attention 模型结合了双向 LSTM, 能同时考虑数据前后依赖关系, 通过注意力机制动态调节特征权重, 增强了预测精度。

3) 模型对比显示, XGBoost - BiLSTM - Attention 模型的平均误差为 0.014, 平均百分比误差为 2.64, 线性拟合度达到 0.963, 整体性能均超过现有模型。

4) 提出的组合模型集合了 XGBoost、LSTM 及 BiLSTM 模型的优势特点, 相较于其他模型, 该预测模型在运行速度上和预测精度上表现更优, 在实际铝电解生产中具有良好的工程应用价值和发展前景。

XGBoost - BiLSTM - Attention 氟化铝添加量预测模型虽然展现出良好的预测效果, 为铝电解生产过程中精准控制氟化铝添加量提供了重要的决策指导, 但在实验过程中发现该模型存在一定的滞后现象, 其准确性依赖于高质量数据和复杂变量处理, 且在不同环境和原料变化下可能出现偏差。后续研究中计划针对这种情况进行以下探索: ①当前采用手动调整参数的方法, 后续可借助网格搜索、粒子群等优化算法优化模型参数; ②在后续研究中, 收集不同类型电解槽控制系统的日报数据, 进行更为广泛的氟化铝添加量预测分析, 提高模型可靠性和适应性。

[参考文献]

[1] 杨刚. 铝电解生产降低氟化铝消耗的探索[J]. 有色矿冶, 2014, 30(2): 29-31.
YANG Gang. Practice and exploration on lowering consumption of aluminum fluoride during aluminum production [J]. Nonferrous Metals and Mining, 2014, 30(2): 29-31.

[2] 康自华, 骆先庆, 陈世月, 等. 利用 SPC 方法设计铝电解生产中氟化铝添加策略[J]. 轻金属, 2016(8): 27-33.
KANG Zihua, LUO Xianqing, CHEN Shiye, et al. Using SPC method to design aluminum fluoride addition strategy during aluminum reduction [J]. Light Metal, 2016(8): 27-33.

[3] 蒋科进. 铝电解参数工序能力与电流效率关系的研究[J]. 中国有色金属, 2012(S1): 516-519.

JIANG Kejin. Research on the relationship between parameter process capacity and current efficiency in aluminum electrolysis [J]. China Nonferrous Metals, 2012(S1): 516-519.

[4] 刘永强, 张平均, 姬凤武, 等. 数据分析在铝电解生产中的应用[J]. 云南冶金, 2011, 40(3): 68-70. 74.
LIU Yongqiang, ZHANG Pingjun, JI Fengwu, et al. The application of data analysis in aluminum electrolysis production [J]. Yunnan Metallurgy, 2011, 40(3): 68-70. 74.

[5] 黄涌波. 基于铝电解槽热平衡分析的氟化铝添加量控制策略研究[D]. 长沙: 中南大学, 2008.
HUANG Yongbo. Control strategy for aluminum fluoride addition based on thermal balance analysis of aluminum reduction cell [D]. Changsha: Central South University, 2008.

[6] 彭强强, 曾水平, 黄璜. 铝电解过程的氟化铝添加量的决策[J]. 冶金自动化, 2008(2): 339-341.
PENG Qiangqiang, ZENG Shuiping, HUANG Huang. Decision on the amount of aluminum fluoride added in aluminum electrolysis process [J]. Metallurgical Automation, 2008(2): 339-341.

[7] 张兴彤, 刘升, 黄胜. 铝电解生产过程中氟化铝添加控制策略探析[J]. 轻金属, 2011, (2): 38-40, 63.
ZHANG Xingtong, LIU Sheng, HUANG Sheng. Addition of fluorinated aluminium control strategy analysis in aluminium electrolysis production [J]. Light Metal, 2011, (2): 38-40, 63.

[8] YUE W, GUI W, CHEN X, et al. A data and knowledge collaboration strategy for decision-making on the amount of aluminum fluoride addition based on augmented fuzzy cognitive maps [J]. Engineering, 2019, 5(6): 1060-1076.

[9] 常家玮, 曾水平. 基于深度学习的氟化铝添加量和出铝量预测[J]. 世界有色金属, 2020, (22): 216-218.
CHANG Jiawei, ZENG Shuiping. Prediction of aluminium fluoride addition and output based on deep learning [J]. World Nonferrous Metals, 2020, (22): 216-218.

[10] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system [J]. CoRR, 2016. DOI:10.1145/2939672.2939785.

[11] 息佳琦, 石晓楠, 杨昭, 等. 基于 SSA-XGBoost 的变压器故障诊断[J]. 黑龙江大学自然科学学报, 2023, 40(6): 721-729.
XI Jiaqi, SHI Xiaonan, YANG Zhao, et al. Transformer fault diagnosis based on SSA-XGBoost [J]. Journal of Natural Science, Heilongjiang University, 2023, 40(6): 721-729.

[12] 侯素脉, 朱伟, 邹象, 等. 基于 ARIMA-LSTM 模型的核电厂运行事件变化分析及预测 [J]. 核技术, 2022, 45(12): 67-

74.
HOU Qinmai, ZHU Wei, ZOU Xiang. Analysis and prediction of nuclear power plant operation events based on ARIMA-LSTM model[J]. Nuclear Technology, 2022, 45(12): 67-74.
- [13] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[C]// Proceedings of the 29th International Conference on Neural Information Processing Systems-Volume 1, 2015.
- [14] 张枫毅, 王莉华, 叶文静. 基于多层级 LSTM 的铝板缺陷检测[J]. 力学学报, 2023, 55(11): 2566-2576.
ZHANG Fengyi, WANG Lihua, YE Wenjing. Aluminum plate defect detection based on multilevel LSTM[J]. Acta Mechanica Sinica, 2023, 55(11): 2566-2576.
- [15] 张程, 林谷青, 匡宇. 基于 MEEMD-QUATRE-BiLSTM 的短期光伏出力区间预测[J]. 太阳能学报, 2023, 44(11): 40-54.
ZHANG Cheng, LIN Guqing, KUANG Yu. Short-term photovoltaic output interval prediction based on MEEMD-QUATRE-BiLSTM[J]. Acta Energetica Solaris Sinica, 2023, 44(11): 40-54.
- [16] 孙少聪, 徐杨, 曹斌. 基于随机森林特征选择的 BiLSTM 电解槽出铝量预测[J]. 轻金属, 2023, (10): 30-36.
SUN Shaocong, XU Yang, CAO Bin. Prediction of aluminum yield from BiLSTM aluminum reduction pots based on random forest feature selection[J]. Journal of light metals, 2023, (10): 30-36.
- [17] MAHATO N K, DONG J, SONG C, et al. Electric power system transient stability assessment based on Bi-LSTM attention mechanism[C]// Proceedings of the 2021 6th Asia Conference on Power and Electrical Engineering(ACPEE), Chongqing, China, 2021.
- [18] 黄宇, 冯坤, 高俊峰, 等. 结合 LSTM 和 Self-Attention 的滚动轴承剩余使用寿命预测方法[J]. 振动工程学报, 2023, 36(6): 1744-1753.
HUANG Yu, FENG Kun, GAO Junfeng, et al. Combination of LSTM and Self-Attention for remaining life prediction of rolling bearings[J]. Journal of Vibration Engineering, 2023, 36(6): 1744-1753.
- [19] 高凯悦, 牟莉, 张英博. PCC-BiLSTM-GRU-Attention 组合模型预测方法[J]. 计算机系统应用, 2022, 31(7): 365-371.
GAO Kaiyue, MU Li, ZHANG Yingbo. Prediction method of PCC-BiLSTM-GRU-Attention combined model[J]. Computer System Applications, 2022, 31(7): 365-371.
- [20] WEI Y, LIU C, DUAN H, et al. Pearson K-mean multi-head attention model for deformation prediction of super-high dams in first impoundments[J]. Water, 2023, 15(9).
- [21] 王灿星, 朱杰勇, 喻聪骏, 等. 基于皮尔逊 III 型曲线的不同降雨工况下的崩滑地质灾害危险性评价[J/OL]. 地质科技通报, 2025, 44(1): 194-204.
WANG Canxing, ZHU Jieyong, YU Congjun, et al. Risk assessment of landslide geological hazards under different rainfall conditions based on the Pearson III curves[J/OL]. Bulletin of Geological Science and Technology, 2025, 44(1): 194-204.
- [22] 王锦. 浅谈降低铝电解氟化铝消耗的有效对策[J]. 化工管理, 2018, (14): 29.
WANG Jin. A brief discussion on effective countermeasures for reducing aluminum fluoride consumption in aluminum electrolysis[J]. Chemical Industry Management, 2018, (14): 29.
- [23] 楼泽霖, 郑军红, 何利力. 基于改进 SSA-LSTM 的销量预测研究[J]. 计算机时代, 2023, (10): 50-53, 58.
LOU Zelin, ZHENG Junhong, HE Lili. Research on sales forecasting based on improved SSA-LSTM[J]. Computer Times, 2023, (10): 50-53, 58.

Prediction of aluminum fluoride addition based on XGBoost-BiLSTM-Attention model

JI Lu¹, WANG Minggang², ZHOU Jian², ZHOU Xiaohong²

(1. Guizhou Zhongzhun Technology Co., Ltd., Guiyang 550025, China;

2. Zunyi Aluminum Co., Ltd., Zunyi 563100, China)

Abstract: In the aluminum electrolysis production process, the addition amount of aluminum fluoride plays a key role in maintaining the efficiency and stability of electrolysis. At present, it is mostly determined by experience. In fact, it has a complex nonlinear relationship with many factors such as alumina test data, aluminum level and electrolysis temperature, showing dynamic changes, and it is difficult to make accurate decisions based on experience alone. This study addresses the challenges posed by the nonlinear, large time-delay, and strong coupling characteristics of the aluminum electrolysis process by integrating a soft attention mechanism into a BiLSTM network to construct a high-precision prediction model for aluminum fluoride dosage. Extensive data training, testing, and validation were conducted to ensure model reliability. The experimental results demonstrate that the proposed algorithm achieves exceptional prediction accuracy in estimating aluminum fluoride dosage. By leveraging the XGBoost algorithm to extract local features, the model enhances both prediction accuracy and operational

efficiency. Furthermore, the integration of bidirectional LSTM enables the model to consider both forward and backward data dependencies, while the attention mechanism dynamically adjusts feature weights, further improving prediction performance. The XGBoost-BiLSTM-Attention model achieves an average error of 0.014, an average percentage error of 2.64%, and a linear fitting degree of 0.963, surpassing the overall performance of existing models. This prediction model provides significant decision-making support for precisely controlling aluminum fluoride dosage in aluminum electrolysis production, thereby enhancing production efficiency, reducing energy consumption, and achieving precise control.

Key words: aluminum electrolysis; The addition amount of aluminium fluoride; Attention mechanism; XGBoost-BiLSTM-Attention; Prediction accuracy; Energy Conservation and Consumption Reduction

打造绿色发展新高地中金岭南凡口铅锌矿尾矿库实现去功能化

在“双碳”目标引领下,深圳市中金岭南有色金属股份有限公司(以下简称“中金岭南”)以资源综合利用为纽带、固体废物资源化利用为突破,筑牢绿色可持续发展底色,探索出一条兼具生态效益、经济效益与社会效益的高质量发展路径。

2016年,当时的环境保护部华南环境保护督查中心提出了“对保护区建区前已有的设施制定逐步退出方案,明确时间节点,确保整改到位”的尾矿库逐步退出要求。在广晟控股集团的坚强领导下,中金岭南和凡口铅锌矿高度重视,全力推动尾矿库退出工作。

8年来,中金岭南以高度的责任感和使命感,基于技术研发进程和矿山生产实际,严格落实逐步退出方案提出的尾矿库污染物减量化和资源化利用、生态恢复治理以及尾矿库风险管控等3类12项环境综合整治项目,最终实现尾矿库去功能化。逐步退出项目是一项系统工程,尾矿全资源化利用等多项技术在当年处于技术空白。针对技术不成熟的项目,中金岭南开展了大量科研攻关,先后完成了“原矿预先抛废技术研究”“细粒级尾砂膏体充填材料实验研究”“尾砂胶结充填新材料扩大工业试验”“开展深锥浓密溢流水回用技术研究”等8项尾砂、废水资源化研发项目。目前,凡口铅锌矿已完成尾矿库清污分流、尾矿库生态恢复Ⅲ期、尾矿资源综合利用、全尾砂回收充填、选矿废水综合回收与循环利用、选矿废水厂前深度处理与回用等12项尾矿库污染物减量化、生态恢复和风险管控工程,攻克了细粒级尾砂充填和废水回用的技术难题。随着所有项目的正常运行,凡口铅锌矿实现了尾砂全部综合利用、选矿废水基本不外排、现有尾矿库逐步落实生态恢复治理的目标,达到尾矿库逐步退出工作要求。

所有项目完成建设并调试验收后,5月30日,在凡口铅锌矿尾矿库黄子塘库区,随着工人师傅手中氧气乙炔切割机火焰的喷射,1#—4#尾矿输送管被先后截断,标志着该矿有着57年历史的通过尾矿管输送选矿尾砂和废水到尾矿库的传统模式正式退出历史舞台。

(资料来源:中国有色金属报)