

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

王琳¹, 张永渝², 金涛^{1*}, 任泽伟³, 焦夕尧³, 苑丹丹³
(1.清华大学软件学院, 北京 100084; 2.清华大学化学系, 北京 100084;
3.中国石化工程建设有限公司, 北京 100101)

摘要:提出一种基于稀疏特征提取和门控循环单元(GRU)的能耗预测方法。基于停时的时间间隔序列等效提取低精度信号;通过聚类分析和时间序列特征相似性分析实现数据降维和关键特征识别;构建基于GRU深度学习的能耗预测模型来捕捉和验证多变量间的复杂关系。通过加氢裂化装置实际运行数据验证,结果表明,能耗预测模型可以发现加氢裂化过程中的关键因素,有效预测给定环境下的能耗变化,为实际工艺流程提供可能的指导。

关键词:能耗预测;深度学习;加氢裂化;数据分析;低碳转型

中图分类号:TP39;TQ02

文献标志码:A

文章编号:0253-4320(2025)10-0253-06

DOI:10.16606/j.cnki.issn0253-4320.2025.10.040

Refinery energy consumption prediction method based on sparse feature extraction and gated recurrent unit

WANG Lin¹, ZHANG Yong-yu², JIN Tao^{1*}, REN Ze-wei³, JIAO Xi-yao³, YUAN Dan-dan³

(1.School of Software, Tsinghua University, Beijing 100084, China;

2.Department of Chemistry, Tsinghua University, Beijing 100084, China;

3.Sinopec Engineering Incorporation, Beijing 100101, China)

Abstract:This paper proposes an energy consumption prediction method based on sparse feature extraction and Gated Recurrent Units (GRU).Low-precision signals are extracted from time-interval sequences by equivalence based on dwell time.Data dimensionality reduction and key feature identification are achieved through clustering analysis and time-series feature similarity analysis.An energy consumption prediction model based on GRU deep learning is constructed to capture and validate the complex relationships among multiple variables.Verification using actual operational data from a hydrocracking plant shows that this energy consumption prediction model can identify key factors in the hydrocracking process,and predict effectively energy consumption changes under given conditions,providing potential guidance for actual process flow.

Key words:energy consumption prediction; deep learning; hydrocracking; data analysis; low-carbon transformation

应对气候变化与实现碳中和已成为全球性重大战略任务,全球能源供需格局正经历深刻变革,各国能源结构加速向绿色低碳方向转型^[1]。我国作为全球能源生产消费大国,明确提出“双碳”战略目标:2030年前达到碳排放峰值,2060年前实现碳中和^[2]。我国石化产业规模居世界首位,但碳排放占全国总量和工业领域的比重分别高达13%和17%,高能耗特征显著,亟需通过技术创新推动行业绿色转型^[3]。准确的能耗预测是实现节能降碳的基础和前提,对优化生产运行策略、制定合理的节能减排方案具有重要指导意义,但石化工业生产过程所呈现的复杂性、多变量性和强非线性特征对预测技术提出了严峻挑战。经典方法虽可通过数学方程描述物质能量转化规律,但其模型构建周期长、精度难以

保证且适应性不足等固有局限性,难以满足复杂工况下的动态预测需求。这促使石化行业向数字化、智能化方向转型,以实现能耗的精准管控并推动绿色低碳发展。

其中,加氢裂化作为石油炼化过程中的关键工艺,战略价值日益凸显。该工艺通过高温(300~450℃)、高压(2~20 MPa)条件下的催化加氢反应,将重质馏分油转化为高附加值的轻质油品,同时脱除硫、氮等杂质,在提升产品品质的同时满足日益严格的环保要求^[4]。然而,由于工艺过程的苛刻条件要求,加之氢气制备、反应加热和冷却分离等环节的大量能源消耗,使其成为炼化过程中的重要能耗单元^[5]。但从应用能源领域来看,加氢裂化不仅是实现产品升级和清洁化的核心技术,其在氢能应用和

收稿日期:2024-11-19;修回日期:2025-08-13

作者简介:王琳(2000-),女,硕士生;金涛(1980-),男,博士,副研究员,研究方向为业务过程管理、工作流、临床路径、大数据、数据安全等,通讯联系人,jintao16@mail.tsinghua.edu.cn。

碳减排方面的技术积累,更为氢能产业的发展提供了宝贵经验。因此,研究加氢裂化的能耗特征和优化方法,不仅有助于深化对裂化反应机理和炼油过程典型单元操作的理解,同时对推进石化行业节能降碳转型具有重要的理论意义和实践价值。

从石化领域的能耗预测研究现状来看,研究主要沿着 2 大技术路径开展:一是基于已有成熟体系的研究范式,包括定性的宏观政策框架分析和建立在热力学基础上的机理建模;二是基于数据驱动的智能建模方法。在宏观政策层面,李晓娇^[6]通过 SWOT 分析法对欧美炼油企业转型路径进行系统研究,深入剖析了不同国家在减排路径选择上的差异。结合中国实际情况,提出了“三结构”转型理论:即产业结构优化、产品结构调整和装置结构改造。在传统机理建模方面^[7],以加氢裂化和加氢精制反应过程为例,可通过热力学模型分析反应物的热解和反应热损失,获取反应速率、热交换和传质等关键参数,识别装置公用工程的主要消耗。在数据驱动方法中,回归预测取得了显著进展。例如,荆璐瑶等^[8]基于 LEAP 模型构建了 R-LEAP 模型,对某炼厂在不同情景下的碳排放进行了预测,研究发现 CCUS 技术具有最优成本效益比,并建议在 2040 年成本下降后推广绿氢和绿电技术,为企业制定长期减排策略提供科学依据。在过程优化方面,田健辉等^[9]提出了一种将 CO₂ 排放预测与企业计划优化模型相结合的建模方法,通过线性规划技术实现了碳排放和经济效益的多目标优化,能够为企业确定最优的原油采购方案和生产加工方案,实现经济效益与环境效益的协同优化。现有研究表明,通过对海量数据的实时分析,深度学习模型能够有效处理催化裂化装置 NO_x 排放、氯乙烯单体(VCM)生产过程等复杂工业场景的预测任务^[10],还能在传感器故障等异常情况下保持预测准确性,在某些应用场景中实现了高达 6.38% 的能效提升和 5.29% 的碳排放减少^[11]。

这些数据驱动方法通过对生产过程中的多源异构数据进行建模分析,在预测精度和实时性方面取得显著进展,为工业节能减排提供了有力支撑。然而,实现工业领域的低碳转型不仅需要准确的预测结果,更需要对影响能耗的关键因素进行系统的定性与定量分析。现有研究过分关注预测模型的输出性能,在影响因素的识别、筛选和解释方面存在明显不足^[12-14]。针对化工领域能耗预测中关键影响因素分析不足的问题,本研究提出了一种融合多种数

据处理技术的预测框架。首先,构建基于自回归门控循环单元(GRU)的预测模型,通过深度学习方法有效捕捉能耗变化的非线性动态特征。其次,为解决工业现场仪表精度受限导致的离散数据预测难题,提出基于脉冲事件编码的数据连续化方法,该方法能够将稀疏离散序列转化为具有丰富时序特征的连续曲线,显著提升数据的可预测性。在特征工程方面,本研究引入动态时间规整(DTW)技术进行序列对齐,并通过主成分分析(PCA)实现降维,结合聚类分析和时间序列相似性度量识别关键影响因素。这种多层次的特征提取与降维策略不仅提升了预测效率,更重要的是增强了模型对工艺参数影响程度的量化能力,为炼化行业的智能化与绿色化转型提供了新的技术路径。

1 理论框架与方法

1.1 炼化装置能耗预测模型构建

1.1.1 研究对象

加氢裂化是将重质馏分油转化为轻质油品的关键工艺过程,也是炼油过程中能耗较高的工艺单元之一^[15-17]。该过程主要涉及加氢精制和加氢裂化 2 类基础反应:前者通过脱除硫、氮、氧、金属等杂原子来确保油品清洁性并防止催化剂中毒;后者将大分子碳氢化合物分解为小分子,实现油品轻质化。整个装置由反应、分馏、脱硫、吸收稳定和公用工程 5 个主要工艺单元构成,集成了炼油生产过程中的典型操作单元。其中,反应单元配备进料泵、压缩机组、加热炉、反应器等设施;分馏单元包含主汽提塔、产品分馏塔等;公用工程单元则提供蒸气、工业用水、氮气等配套设施。

1.1.2 数据来源

针对炼厂中实际生产运行中的某加氢裂化装置为研究对象,从该装置 DCS(分散控制系统)中调取装置运行数据如加热炉排烟温度、塔釜温度、燃料气流量等共 189 组。数据采集频次为每 10 s 一次,周期为 1 a。经过工艺专家初步筛选,排除掉其中如烟气二氧化硫浓度等与能耗相关性极低的数据,最终挑选剩余 158 组数据作为模型搭建的输入数据。输出数据采用该装置 DCS 系统中的公用工程消耗数据,从中选取燃料气消耗、中压蒸气消耗、低压蒸气消耗 3 个主要耗能工质作为主要研究对象。数据采集频次为每 10 s 一次,周期为 1 a,与输入数据保持一致。

1.1.3 技术路线

本研究通过系统梳理深度学习方法在石化领域能耗预测应用的研究现状,构建了一套面向加氢裂化装置能耗预测与优化的三阶段技术路线,如图 1 所示。第一阶段聚焦数据预处理。采用差分和对数变换实现数据平稳化,通过归一化消除量纲影响。引入停时概念处理离散能耗值,为建模提供高质量

数据基础。第二阶段实现特征筛选。消除冗余,使用相关分析和 XGBoost 算法特征初筛,量化特征重要性。最终从初始特征集中识别出约 20% 的关键变量。第三阶段构建预测模型。基于自回归机制设计深度学习模型,有效捕捉时序数据的长短期依赖关系,且模型输入融合筛选后的特征时间序列、历史能耗值和聚类分析结果,提升预测精度。

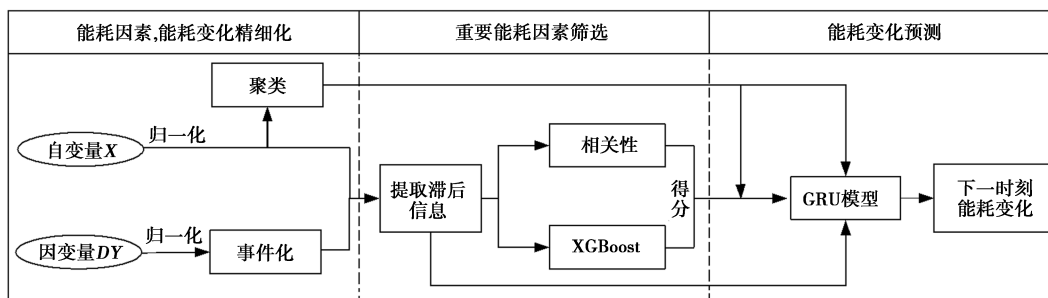


图 1 基于 GRU 的炼化装置能耗预测方法流程

1.2 炼化装置能耗因素与能耗变化的精细挖掘

1.2.1 能耗数据归一化处理

为消除量纲和数据分布不均的影响,对输入特征变量 X 和能耗响应变量 ΔY (记为 Y_{new}) 的一阶差分,均采用一阶差分、区间归一化和数据中心化的标准化流程,增强了模型对能耗局部波动的刻画能力,并保证了模型训练的数值稳定性。

1.2.2 能耗因素的聚类分析

为量化时间序列间的相似度特征,本研究采用动态时间规整 (dynamic time warping, DTW) 算法进行距离^[18]度量。DTW 通过动态调整时间轴实现序列的最优对齐,能够有效处理时间序列的形变和偏移,从而更准确地刻画序列间的形态相似性。具体地,DTW 通过构建距离矩阵,并采用动态规划方法求解最优对齐路径上的累积距离最小值。该过程通过递归式(1)计算:

$$\text{dtw}(i, j) = \min \{ \text{dtw}(i-1, j), \text{dtw}(i, j-1), \text{dtw}(i-1, j-1) \} + \text{dis}(i, j) \quad (1)$$

为量化时间序列间的形态相似性,采用动态时间规整算法作为距离度量。基于 DTW 距离,通过层次聚类将形态相似的特征序列归为一类,并利用主成分分析 (PCA) 对高维长序列特征进行降维 (保留 95% 累计贡献率),有效降低了数据冗余度和计算复杂度。聚类后产生的类别标签,作为新特征引入模型。

1.2.3 能耗变化时序连续化

然而,受测量仪器精度的限制, Y 的值为呈阶梯状跳跃上升的整数,这使得 Y_{new} 表现为跳跃的离散

序列。离散序列的非连续性质使得传统的线性预测方法难以直接应用,且原始脉冲序列呈现高度稀疏性,大量的零值 (表示无事件) 与少量的一值 (表示有事件) 并存,这使得揭示复杂的长距离依赖关系变得困难。

为了有效解决离散值预测的挑战,本文中提出一个非常简单的基于停时理论构建了脉冲事件编码方法。对随机过程,若某时刻 T 的事件发生与否仅依赖该时刻前的观测信息,则称该时刻为停时^[19]。在本研究中, Y_{new} 序列中非零值出现的时刻构成停时序列。具体而言,本研究引入了间隔时间等效脉冲事件序列,捕捉事件频率和规律性,如较短的时间间隔表示高频率的事件,而较长的时间间隔表示低频率的事件。脉冲事件编码方法包括以下步骤:首先,从原始数据中提取每小时内 Y_{new} 持续为零的时间间隔 $E[T]$,将处理后的数据与 Y_{new} 进行对齐和转换,得到新的 Y_{new} 。这种转换使得能耗变化的微小波动和长期趋势都能被清晰地呈现出来。

1.3 炼化装置关键能耗因素的筛选

1.3.1 基于相关性分析的特征筛选

能耗影响因素与能耗变化的相关性分析是识别关键影响因素的重要步骤,有助于优化分析流程并提高预测模型的准确性。本研究采用时间序列互相关函数评估各影响因素与能耗变化序列间的关联强度,使用公式(2)、(3)计算 X 中每个影响因素与 Y_{new} 中每个能耗值之间的相关性。

$$\text{Corr}(x_t, y_{t-h}) = \left[\sum_{t=1}^{N-h} (X_t - \bar{X})(Y_{t-h} - \bar{Y}) \right] /$$

$$\left(\sqrt{\sum_{i=1}^{N-h} (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^{N-h} (Y_{i-h} - \bar{Y})^2} \right) \quad (2)$$

$$\bar{X} = (1/n) \sum_{i=1}^n X_i, \bar{Y} = (1/n) \sum_{i=1}^n Y_i \quad (3)$$

其中 k 是滞后期 (lag)。为了提取 X 对 Y_{new} 影响的滞后信息, 研究需找到一个滞后期的阈值 $k_{\text{threshold}}$, 即当 $k < k_{\text{threshold}}$ 时, Y_{new} 具有明显的自相关性。因此为了预测下一时刻的能耗变化, 可以将过去 $k_{\text{threshold}} - 1$ h 的能耗变化值也作为模型输入。基于互相关系数的统计显著性, 本研究设定显著性阈值 r 对特征空间进行降维筛选。通过保留互相关系数位于前百分位的影响因素子集, 构建了具有显著预测能力的特征空间。

$$R_x(k) = (1/n) \sum_{t=1}^{n-k} [X(t) - \bar{X}][X(t+k) - \bar{X}] \quad (4)$$

1.3.2 基于 XGBoost 的特征筛选

XGBoost 特征筛选依赖其树模型的特征重要性评分, 可以捕捉特征间的非线性关系与交互作用, 从而度量特征对目标变量的贡献。在模型构建过程中, XGBoost 的树结构不仅关注 Y 值的时间变化, 还强调时间、变量的相关性。其特征筛选能力源于内部的特征重要性评估机制。在 XGBoost 中, 每棵决策树生成过程中会计算各特征的增益 (Gain), 增益表示该特征对模型的贡献度。本研究采用公式 (5)、(6) 计算增益, 计算公式为:

$$\text{Gain} = \Delta L_{\text{left}} + \Delta L_{\text{right}} \quad (5)$$

$$\text{Score}_i = \text{Gain}_i / \sum \text{Gain} \quad (6)$$

通过多轮迭代, XGBoost 累积各特征的增益, 得到特征的重要性评分。最终, XGBoost 基于重要性得分对特征进行排序, 从而实现特征筛选, 设定显著性阈值 r 排名选择最重要的特征。

1.3.3 聚类辅助的特征再筛选

本文中通过 2 种方法计算特征得分, 结合 PCA 降维压缩序列数据维度。随后运用 DBSCAN 聚类

算法和 DTW 距离度量进行特征去重, 从每类中选取代表性样本。该方法将特征数量从 40% 降至 20%, 在保持信息质量的同时有效提升了计算效率, 实现了特征集的稀疏化优化。

1.4 面向炼化装置的能耗预测深度学习模型构建与性能评估

采用自回归方法预测碳排放时序数据, 输入包含 158 个产品特征 (进料、温度等) 和 13 个能耗目标变量 (水、电、风、气等参数), 通过聚类优化特征和离散化目标变量构建等效脉冲事件序列。为每个时刻 T 构造一个包含 $T - k_{\text{threshold}}$ 至 T 时刻的 X 时间序列和 $T - k_{\text{threshold}}$ 至 $T - 1$ 时刻的 Y_{new} 时间序列。在模型选择中, 本研究构建了一个门控循环单元 (gated recurrent unit, GRU)^[20] 的循环神经网络, 能够有效捕捉长时间依赖关系, 模型采用一个 GRU 层, 该层具有指定数量的隐藏单元, 用于提取输入数据中的时间依赖特征。输入数据的形状为 $\text{window}_{\text{size}} + 1, \text{features}_x + \text{features}_y$, 其中 $\text{window}_{\text{size}} + 1$ 表示时间步数, features_x 和 features_y 分别表示输入特征和目标特征的数量。在模型构建完成后, 使用均方误差作为损失函数进行编译。同时, 选择了 Adam 优化器, 并以准确率作为评估指标。

2 结果与讨论

2.1 装置能耗因素、能耗变化的精细挖掘

通过 DTW 距离矩阵分析揭示了能耗因素时间序列间的相似性结构, 发现大量时间序列具有极小的 DTW 距离 (接近于 0), 表明存在显著的特征冗余现象, 如图 2 所示。基于此发现, 采用时间序列聚类分析成功将 158 个能耗因素压缩至约 20 个代表性类别, 实现了数据降维的同时保持了原始信息的完整性。以其中 1 个影响因素“加氢精制反应器一床温升”为例, 归一化前后“加氢精制反应器一床温升”

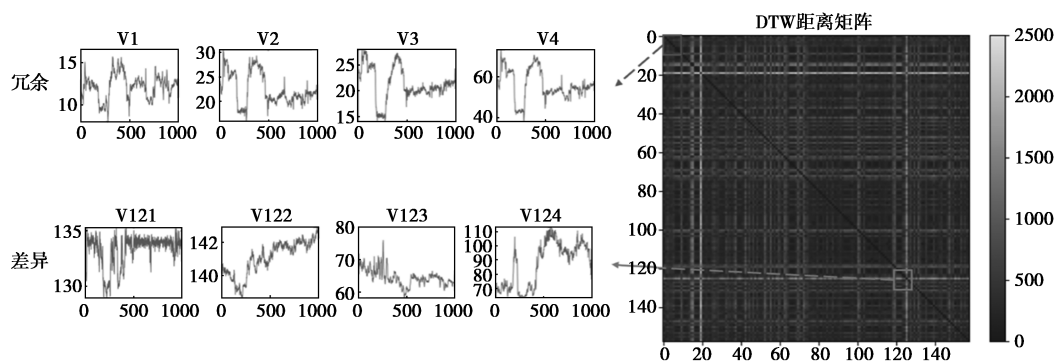


图 2 通过 DTW 距离矩阵发现冗余特征

时间序列。归一化后的数据范围统一,减少数值溢出的风险,在数值空间中更均匀分布,从而加快模型训练速度。

研究聚焦于 3 个主要能耗指标(燃料气、3.5 MPa 蒸气和 1.0 MPa 蒸气),这些指标共同占据总能耗的 90%。对能耗变化实施了系统性的数据预处理流程,包括小时级数据提取、均值平滑处理和数据对齐等步骤。这种预处理方法将离散的阶梯状数据转换为连续曲线表达,在保持较高数据精度(RMSE < 0.5)的同时,成功捕捉了能耗模式的微观波动和宏观趋势特征。研究结果表明,改进后的数据表征方法不仅提供了更为细腻的能耗动态特征描述,而且显著提升了数据的可分析性和可解释性。

2.2 重要能耗特征筛选

通过互相关分析和 XGBoost 特征重要性评估 2 种互补方法,从 158 个初始特征中筛选出约 60 个关键影响因素。互相关分析揭示了能耗系统的三重关联特性:能耗变化与影响因素之间的关联、能耗变化之间的互相关,以及能耗变化与因素复合的综合关联。研究发现能耗指标具有显著的时间自相关性,自相关值在 5 左右具有统计显著性。

XGBoost 分析则进一步揭示了特征间的非线性关系和交互作用。比较 2 种方法的筛选结果发现,在 60 个筛选特征中存在约 50% 的重叠,表明这 2 种方法能够从不同角度捕捉特征的重要性。互相关分析侧重于捕捉线性关联,而 XGBoost 则更擅长识别复杂的非线性模式。最终,通过结合 PCA 降维(保留 95% 信息量)和基于 DBSCAN-DTW 的聚类分析,将 60 个特征进一步压缩至 24 个代表性特征,实现了特征的高效稀疏化。


2.3 基于 GRU 神经网络的装置能耗变化的预测

本研究通过系统的模型比较和优化实验,全面验证了所提出预测框架的有效性。在模型架构设计中,采用了 2 层 GRU 网络结构,隐藏层维度分别设置为 128、64,并引入 0.2 的 dropout 机制有效防止过拟合。模型训练采用 Adam 优化器,设置初始学习

率为 0.001, batch size 为 32, 经过 100 轮迭代训练达到收敛。实验结果显示,不同模型在预测性能上展现出显著的互补特性:GRU 模型在捕获时序数据细节变化方面表现优异,平均绝对误差(MAE)较基准模型降低了 15%;Transformer 模型虽然具备较强的长程依赖建模能力,但存在过度平滑的倾向;而 XGBoost 模型虽然计算效率较高,但在时序特征的精细刻画方面相对较弱。

通过引入聚类信息后,模型性能得到质的提升。预测损失值从原始的 0.023 1 显著降低至 0.002 8,提升幅度接近 90%;预测值与真实值的拟合度 R^2 提高到 0.92,同时模型收敛速度提升约 30%,有效缓解了过拟合问题,验证集上的性能表现更加稳定。特征筛选实验进一步验证了方法的有效性:当特征数量降至原始的 40% 时,模型仍然保持了相当的预测精度;更值得注意的是,当特征进一步减少至 20% 时,部分预测指标反而提升了 3%~5%。这一发现强有力地证实了所筛选特征的代表性,同时也说明该模型对特征冗余具有良好的鲁棒性。

本研究首先以原始的影响因素作为输入,在此基础上逐步改进所提出的能耗预测方法,对未来 4 d (96 h) 的预测结果如图 3 所示,每次改进的成果如表 1 所示。



1—真实值;2—使用筛选的 20% 特征预测值;
3—使用筛选的 40% 特征预测值;4—使用全部特征预测值

图 3 使用不同数量的特征预测 1.0 MPa 蒸气排放值

表 1 方法改进成果

输入	改进点	损失值	提升点/%
只输入过去 24 h 的 158 个特征(如反应炉西炉膛氧含量、轻石脑油产品流量等)		0.0403	
输入过去 24 h 的 158 个特征、过去 23 h 的预测目标(如低压蒸气)	输入中加入预测目标值	0.0374	7
输入 158 个特征、预测目标、聚类结果	输入中加入聚类结果	0.0223	40
输入 158 个特征、连续化的预测目标、聚类结果	将预测目标值事件化	0.0139	37
输入包含“分馏塔底温”、“分馏塔一中段回流返塔温度”在内的 40% 的特征、连续化的预测目标、聚类结果	加入特征筛选	0.0127	8
输入 20% 的特征、连续化的预测目标、聚类结果	优化特征筛选	0.0123	3

由表 1 可以看出,本研究提出的方法的每个部分对能耗预测均有贡献。

在实际应用场景验证中,本研究对某炼化企业 1 个月的运行数据进行了预测测试。结果显示,燃料气消耗预测准确率达到 84.2%,中压蒸气消耗预测准确率为 82.7%,低压蒸气消耗预测准确率达到 81.6%,所有指标均稳定控制在误差 20% 以内,完全满足工业应用要求。深入分析预测误差分布特征发现,90% 以上的预测误差都集中在 $\pm 10\%$ 范围内,较大误差主要出现在工况突变期间,而对于渐变工况,模型则表现出优异的预测能力。预测结果展现出良好的时间连续性,有效避免了预测值的剧烈波动。

3 结论

本研究提出基于 GRU 的炼化装置能耗预测方法。通过关键因素挖掘、归一化和 DTW 处理时间序列数据,结合脉冲事件编码将离散能耗数据转化为连续序列。构建的 GRU 模型融合自相关分析,有效捕捉时序依赖关系。实验结果表明,该方法显著提升了能耗预测准确性,为炼化行业能耗管理提供新思路。

(1) 构建了基于 GRU 的能耗预测模型,有效解决了传统预测方法在处理复杂非线性关系时的局限性。该模型通过深度学习方法准确捕捉能耗变化的动态特征,预测精度显著提升,其中燃料气、中压蒸气和低压蒸气的预测准确率分别达到 84.2%、82.7% 和 81.6%,为炼化企业的能耗分析和预测提供了可靠的技术支撑。

(2) 针对仪表精度较低导致离散数据预测困难的情况,提出了一种将离散数据连续化为事件序列的方法。通过脉冲事件编码技术,将原本稀疏的离散序列转化为更具动态特征的连续曲线,从而增强了数据的可预测性和模型的稳定性。

(3) 在数据分析过程中,发现加氢裂化过程中的能耗变化与多种因素(如温度、压力等)存在复杂的非线性关系。通过动态时间规整等方法的应用,可以更好地捕捉到这些关系,为后续的优化决策提供了坚实的数据基础。

本研究的主要贡献在于:通过建立模型,从大数据的角度对炼化过程中典型的操作单元、反应机理进行预测分析研究,为其他装置建模提供了借鉴经验。根据模型结果,操作人员能够进行有效决策,提高了工作效率;GRU 模型与炼化装置深度结合为炼

化企业节能减排提供了新的思路,推动行业向更高效、环保的方向发展。

参考文献

- [1] 时倩瑶.我国石化行业节能减排的现状与发展趋势研究[D].长春:吉林大学,2010.
- [2] 江惠忠.我国石油化工产业的发展现状及前景[J].科技风,2012,(19):107.
- [3] 刘洋,苑丹丹,李浩,等.基于开源技术的 FCC 装置产品收率预测 BP 神经网络模型[J].石油炼制与化工,2021,52(3):87-92.
- [4] 刘军衡.重油催化裂化装置腐蚀在线监测数据优化与寿命预测技术研究与应用[D].北京:北京化工大学,2023.
- [5] 柳明军,石秀芳,李勇,等.炼化大机组设备预测性维护模型的研究与实践[J].山东工业技术,2024,(1):69-73.
- [6] 李晓娇.碳中和背景下我国炼油业低碳发展策略研究[D].北京:中国石油大学,2022.
- [7] 姚泓池.常压塔塔顶低温露点腐蚀风险预测及腐蚀机理研究[D].杭州:浙江理工大学,2023.
- [8] 荆璐瑶.基于 LEAP 模型炼厂的碳减排预测及减排路径研究[D].北京:中国石油大学(北京),2023.
- [9] 田健辉,罗玲,尚盼.基于线性规划技术构建炼化企业 CO₂ 放预测模型[J].世界石油工业,2022,29(5):26-32.
- [10] 张艳玲,马骏,梁峰,等.数据驱动的炼化装置静设备防腐蚀集中监控系统研究[J].安全、健康和环境,2024,24(6):48-55.
- [11] Geng Z Q,Zhang Y H,Li C F, *et al.* Energy optimization and prediction modeling of petrochemical industries: An improved convolutional neural network based on cross-feature [J]. Energy, 2020, 194:116851.
- [12] 陈琴.基于深度学习的炼化装置报警数据关联分析与预测研究[D].北京:中国石油大学(北京),2022.
- [13] 陆新元.基于 ARIMA 的腐蚀时序数据趋势预测[J].炼油与化工,2023,34(1):22-25.
- [14] 刘丽云.基于大数据分析的常减压装置腐蚀预测研究[D].西安:西安工业大学,2020.
- [15] 任博.惠州炼化加氢裂化装置分馏部分流程模拟研究[D].北京:中国石油大学(北京),2016.
- [16] 孙建怀.镇海炼化公司两套加氢裂化装置的优化运行[J].当代化工,2009,38(4):357-360,363.
- [17] 吴远建,李修能,赵文静,等.加氢反应器 RBI 检验及缺陷分析处理[J].化工机械,2021,48(4):599-603.
- [18] Berndt D J,Clifford J.Using dynamic time warping to find patterns in time series[C].Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining,1994:359-370.
- [19] Faulstich S,Hahn B,Tavner P J.Wind turbine downtime and its importance for offshore deployment[J].Wind Energy,2011,14(3):327-337.
- [20] Dey R,Salem F M.Gate-variants of gated recurrent unit (GRU) neural networks[C].2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS),2017:1597-1600. ■