

基于PMHA的CNN-BiLSTM-XGBoost催化裂化装置产率预测

姚拙成, 王亚刚

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2024年4月30日; 录用日期: 2024年5月23日; 发布日期: 2024年5月31日

摘要

催化裂化装置是石油炼制过程中至关重要的设备之一, 其石油产品产率的准确预测对于优化生产和资源利用至关重要。针对传统的机理模型方式存在的建模困难、参数估计困难、对复杂系统的局限性以及难以处理非线性关系和高维数据等劣势, 数据驱动的建模方式更灵活适应复杂系统和大量数据, 能够有效处理非线性关系和高维数据, 具有更强的预测准确性和实时性。因此, 采用并行结构多头注意力机制, 构建了一种基于CNN-BiLSTM-XGBoost的催化裂化装置产率预测模型, 以应对这些挑战。实验结果表明, 该模型的预测准确率能达到98%, 显著优于SVR、RF、AdaBoost等传统回归模型, 为催化裂化过程的智能化升级提供新的思路。

关键词

催化裂化装置, 产率预测, 长短期记忆网络, 注意力机制, 卷积神经网络, XGBoost

PMHA-Based CNN-BiLSTM-XGBoost Catalytic Cracking Unit Yield Prediction

Zhuocheng Yao, Yagang Wang

School of Optoelectronic Information and Computer Engineering, Shanghai of University for Science and Technology, Shanghai

Received: Apr. 30th, 2024; accepted: May 23rd, 2024; published: May 31st, 2024

Abstract

The catalytic cracking unit is one of the most crucial equipment in the petroleum refining process, and accurate prediction of its petroleum product yield is crucial for optimizing production and

resource utilization. In view of the disadvantages of traditional mechanism model methods such as modeling difficulties, parameter estimation difficulties, limitations in complex systems, and difficulty in processing nonlinear relationships and high-dimensional data, data-driven modeling methods are more flexible and adaptable to complex systems and large amounts of data. It can effectively handle nonlinear relationships and high-dimensional data, and has stronger prediction accuracy and real-time performance. Therefore, a parallel structure multi-head attention mechanism was used to construct a catalytic cracking unit yield prediction model based on CNN-BILSTM-XGBoost to address these challenges. Experimental results show that the prediction accuracy of this model can reach 98%, which is significantly better than traditional regression models such as SVR, RF, and AdaBoost, and provides new ideas for the intelligent upgrade of the catalytic cracking process.

Keywords

Catalytic Cracking Unit, Production Rate Prediction, Long and Short-Term Memory Network, Attention Mechanism, Convolutional Neural Network, XGBoost

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

催化裂化作为一种重要的石油炼制方法,在石油化工厂中有着举足轻重的地位,仍然是炼油业务的核心关键技术[1]。催化裂化装置的建模方法主要可分为两类:机理建模和数据驱动模型。机理建模,也称为机理驱动模型或知识驱动模型,依赖于数学、物理和化学的公式与定理,通过分析工业系统的内部机制来构建模型。Bollas [2]等在模拟流体催化裂化(Fluid Catalytic Cracking, FCC)操作时,对反应动力学、流体力学和催化剂失活等因素进行深入理解的重要性,并基于实验数据开发了聚合模型,通过考虑选择性催化剂失活,提高了对FCC产品分布的预测准确性,证明了该方法的有效性。John [3]等将催化裂化装置的瓦斯油裂化成柴油、汽油、液化石油气、干气和焦炭的六类建立了一套六集总动力学模型,与工业数据相比较低的误差预测催化裂化装置的提升管分布。Nazarova [4]等开发了一个涉及C13-C40烃、汽油组、气体单个烃和焦炭形成反应等高分子量的新动力学模型,通过使用具有较高沸点的油馏分来预测原料碱膨胀下的催化裂化装置,有效的改进和预测石油燃料生产的不稳定过程。Yang [5]等人提出了一种结合动态模型与深度学习的催化裂化装置混合预测策略。首先,他们构建了一个综合的动态模型,该模型由8个子模型构成。随后,他们利用原料油的数据作为主要输入到神经网络中,并将动态模型的预测输出作为额外输入。通过比较仅使用同等结构神经网络的情况,发现预测误差减少了9%,这验证了所提方法的优越性。

与机理建模相比,数据驱动建模(Data-driven Model)通过模型的结构和参数通常是通过对大量现有数据进行分析、学习和统计推断来确定的,而无需基于物理原理或先验知识的建模。模型预测控制(Model Predict Control, MPC)自从上世纪80年代起在石油化工领域得到应用,是一种多变量的进阶过程控制方式,通过减少预测结果和期望输出的差距,从而寻找到最优的输入输出映射方程[6]。Abou-Jeyab等通过线性规划(Linear Programming, LP) [7]方式使得催化裂化装置模型预测控制的约束问题无需分解,提高了传统优化问题中模型预测控制性能。Jerez等提出了一种可以处理具有输入、输入速率和软状态约束的线性二

次模型预测控制(Model predictive control, MPC) [8]问题的快速 MPC 算法, 相比于之前模型预测算法在性能上有了提升。近年来随着机器学习的发展, 催化裂化装置建模中出现了越来越多与机器学习算法相结合的方法。Chen 等将智能特征选择策略与随机森林(Random Forest, RF) [9]相结合用于对催化裂化装置进行建模, 用来预测产品收率, 通过在轻柴油、重柴油、汽油以及干燥气体四种场景下 AIGA-RF 模型均方误差和相关系数 R2 优于其他模型, 证明这种方式能够消除过程扰动变量并且适用于不同场景。肖强[10]等使用(Radial Basis Function, RBF)网络来预测催化裂化装置中重汽油馏分加氢产品硫含量, 该方法预测的平均相对误差达到 1.32%, 证明了模型的准确性。陈延展[11]等利用极度梯度提升树(eXtreme Gradient Boosting—XGBoost)和改进灰狼优化算法预测辛烷值损失, 准确率达到了 99.81%。因此, 证明了基于数据驱动的机器学习和神经网络算法对催化裂化装置的建模方式是有效的。

在实际工业过程中, 过程监控变量通常是高维、非线性的时间序列, 监控的变量往往受到多种因素的影响, 并且这些因素之间可能存在复杂的相互作用[12]。但是过程特征和跨系列相关性可以通过特征提取技术捕获, 并将它们转化为可用于建模和预测的形式[13]。这样的特征提取过程可以为时序预测提供有价值的信息[14]。近年来, 基于深度学习的方法在这方面取得了显著进展[15]。同时, 催化裂化装置面向产品质量或收率的过程数学建模分析一直是石油加工领域的关注焦点和挑战[16]。

目前, 通过基于过程工业中测量和存储的大量数据构建预测模型, 这种数据驱动方式已成为研究热点[17]。Michalopoulos 等人提出一种用于流体催化裂化(FCC)装置的前馈神经网络模型, 利用神经网络技术成功地对 FCC 过程的高度非线性行为进行建模[18]。Yang 等人考虑到各种变量的收集特征, 使用神经网络结构来处理不同时间尺度的输入变量, 通过堆叠不同时间尺度的 LSTM 进行以提取时间和空间特征[19]。

工业时间序列变量大多存在空间维度以及时间维度的特征, 仅考虑一方面的情况可能会导致预测效果不理想, 而且大多数是高维和非线性的时间序列。针对这一问题本文提出一种采用并行结构的多头注意力机制(Parallel structure Multi-Head Attention mechanism, PMHA) CNN-BiLSTM-XGBoost 神经网络模型对于催化裂化装置产率预测的方法。首先, 通过多头注意力机制加强对数据的时间信息的处理能力。其次, 利用 CNN-BiLSTM 对多维时间序列数据进行预处理, 能够有效捕获空间信息特征; 然后, 通过并行结构 PMHA-CNN-BiLSTM 模型进一步提高了模型增强了对于高维和非线性数据的处理能力; 最后, 使用 XGBoost 模型对预测结果进行微调, 提高了预测性能。

2. 工作原理

2.1. 预测问题的表述

在催化裂化(FCC)工艺中, 对生产数据和中间变量的实时监测对于维持生产过程的效率和安全性至关重要。因此, 传统机理建模方法的研究对于催化裂化工业实践具有重大意义。然而, FCCU 反应再生系统机理模型是一个复杂的多变量模型, 具有非线性和强耦合的特征。在先进控制领域, 研究人员在短期内难以掌握化工过程复杂的偏微分方程和代数方程。因此, 越来越多的先进控制领域研究人员采用神经网络技术构建了简化的 FCCU 反应再生系统模型。这种方法能够利用大量生产数据快速学习复杂的非线性关系, 从而为控制方案的验证提供了模型。为验证 PMHA-CNN-BiLSTM-XGBoost 催化裂化装置在产品产率预测方向的应用。我们将 FCC 单元视为一个整体, 并将其定义为多输入多输出(Multiple Input Multiple Output, MIMO)系统如图 1 所示。输入变量主要包括三大类: 原料、温度和压力, 这是影响产品收率的主要因素。输出变量产品流量主要包括汽油(Gasoline, GSL)、液化气(Liquefied Petroleum Gas, LPG)、干气(Gas, GS)以及柴油(Diesel Oil, DO), 以此构建 FCCU 反应再生系统简化模型。

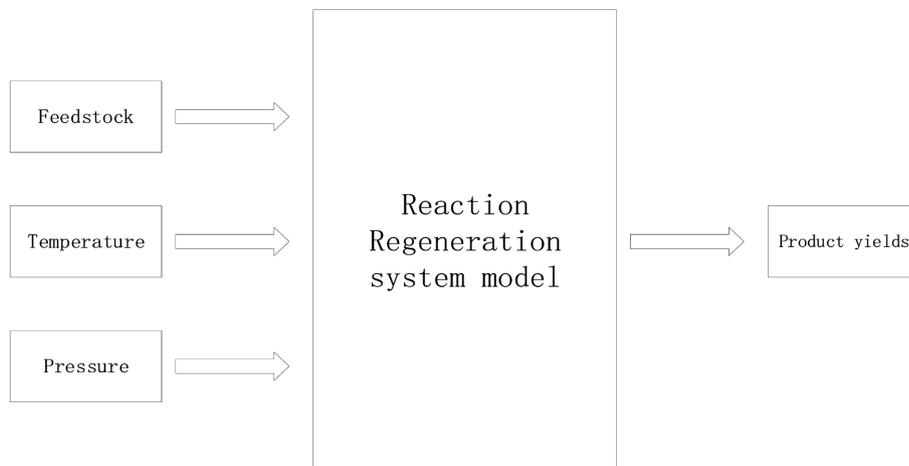


Figure 1. Multiple input multiple output system structure
图 1. 多输入多输出系统结构

本章提出一种基于 Seq2Seq (Sequential to Sequential) 框架, 构建 CNN-BiLSTM 混合神经网络模型, 如图 2 整体框架流程图所示。首先对产品产率进行数据预处理, 同时输入进料量、温度以及压力等变量之后得到特征矩阵。然后, 对特征矩阵进行数据集的划分以及归一化处理。其次, 将预处理后的数据传入 Sep2Sep 框架中并通过 XGBoost 进行微调。最后, 通过反归一化得到预测输出值。通过相关试验, 证明了本文所建立的 FCC 反再系统的预测模型是可行的, 并在催化裂化反应再生系统仿真上进行了应用。

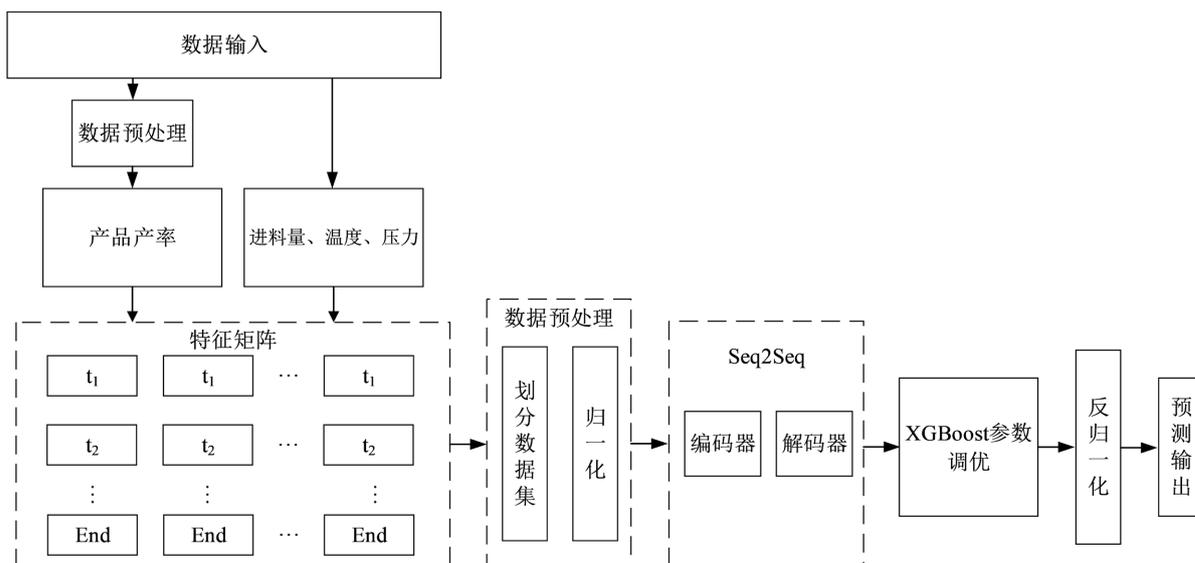


Figure 2. PMHA-CNN-BiLSTM overall framework flow chart
图 2. PMHA-CNN-BiLSTM 整体框架流程图

2.2. Seq2Seq + Fine Tuning 框架

Seq2Seq 是一种将序列数据转化为序列数据的神经网络结构, 最初是用于进行文本翻译和对话生成等工作。由于 Seq2Seq 解决序列转序列问题的特性, 后 Seq2Seq 也被逐渐应用于时序数据预测的领域。Seq2Seq + Fine tuning 的结构如图 3 所示。

在预训练模式 Sep2Sep 中, 输入顺序和输出顺序数据表示输入序列数据, 编码器(Encoder)表示编码器, C (编码器)表示隐态, Decoder 表示译码器。Seq2Seq 典型地由编码器和解码器两部分构成。编码器是一种基于属性的卷积神经网络, 它能高效地捕获序列间的内在联系, 它是一个或几个以上的神经网络叠加而成的。Decoder 是一个双线性短时记忆模型, 它的输出是一系列编码器所学到的特征集合。由于在某些特定的任务或领域, 通用的预训练模型可能无法获得最佳性能。Fine-tuning 是一种迁移学习技术, 本文通过使用 XGBoost 在预训练模型的基础上对特定任务进行微调, 以提高模型在该任务上的性能。该框架结合了 Seq2Seq 模型的序列建模能力和 Fine-tuning 技术的迁移学习优势, 通过灵活调整模型结构和微调策略, 可以在催化裂化装置产品产率预测任务上取得较好的效果。

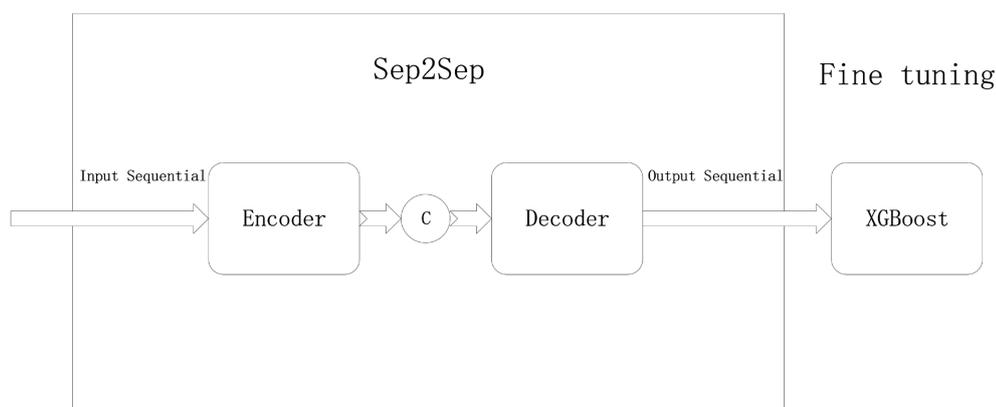


Figure 3. Seq2Seq + Fine tuning framework structure

图 3. Seq2Seq + Fine tuning 框架结构

2.3. PMHA-CNN-BiLSTM

基于常规网络在预测时出现的问题, 本文提出了一种基于 Seq2Seq 的催化裂化装置的预测模型 PMHA-CNN-BiLSTM, 其结构如图 4 所示。

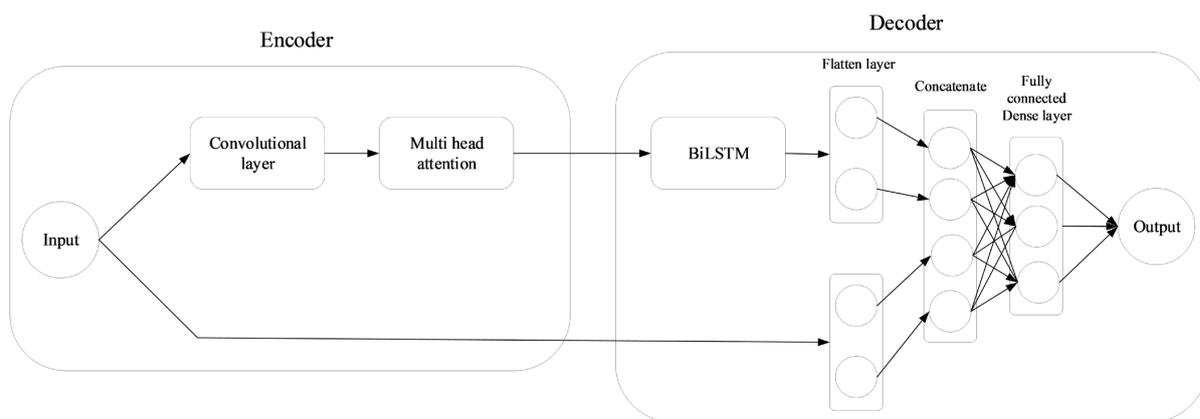


Figure 4. PMHA-CNN-BiLSTM structure

图 4. PMHA-CNN-BiLSTM 结构

其中输入部分是一段时问序列数据, 编码器由 Multi Head Attention based CNN 构成, 解码器为 BiLSTM 网络组成。为了解决基于单向结构实现的多变量预测时, 模型预测结果不理想的问题。Multi Head

Attention based CNN 主要对整体的结构进行了改进。由于整体网络模型采用一个并行结构(Parallel Structure)的方式, 加入原始数据的输入, 进而由编码器传入的隐藏层状态, 将两部分的信息整合至一个全连接网络, 最后将输入数据的最终表示形式传入到密集层以产生预测输出。这种结构保留原始数据的端对端形式可以有助于模型可以更好地理解输入数据的多样性和复杂性, 从而提高模型预测处理高维非线性数据的能力。

3. 实验设计与结果分析

3.1. 评价指标

回归算法的模型评价指标主要有均方误差(Mean Square Error, MSE)、平均绝对误差(Mean Absolute Error, MAE)、均方根误差(RMS Error, RMSE)以及决定系数 R2。

3.1.1. 决定系数

R2 即决定系数, 是衡量预测值对真实值拟合好坏的程度。R2 的范围在(0~1)之间, 越接近 1, 说明模型拟合的越好。

3.1.2. 均方误差

均方误差 MSE 是真实值与预测值的差值的平方然后求和平均, 范围 $[0, +\infty)$, 当预测值与真实值完全相同时为 0, 误差越大, 该值越大。如公式(1)所示:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

3.1.3. 平均绝对误差

平均绝对误差 MAE 是预测值与真实值之差的绝对值的平均值。与 MSE 不同, MAE 不受异常值的影响, 更能反映模型的预测准确性。如公式(2)所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

3.1.4. 均方根误差

均方根误差 RMSE, 实际上就是真实值与模型预测值之差的平方求均值后的算术平方根, 其取值范围也是 $[0, +\infty)$, RMSE 值越小, 说明模型的预测产品产率与催化裂化装置中真实产品产率越接近, 具体计算公式(3)如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|} \quad (3)$$

3.2. 数据集预处理

1) 产品产率定义

产品流量直接从催化裂化装置的实时数据库中获取, 但最终需要的是产品收率。产品流量和产品产量之间的关系如公式(4)所示:

$$Y(i) = \frac{R(i)}{F} * 100\% \quad (4)$$

其中, 表示第 i 个产品的产率, $R(i)$ 表示第 i 个产品经过催化裂化反应转化后的物料量, F 表示原始物料量。 $Y(i)$ 的数值越大代表该产品的收益率越好。

2) 标准化处理

由于 FCC 系统结构复杂, 在实际生产中所获得的有关数据往往维度不一。如果不对不同维度的特性进行转换, 则会使大尺度特性在模型学习中占据主导地位, 而对小尺度特性则有可能被忽视。所以, 在数据预处理过程中, 为了消除维数的影响, 提高模型的性能, 减小离群点对模型的影响, 还必须对其进行归一化处理。数据可以在统一的尺度上变化, 使得不同特征之间的比较更加合理和可靠, 同时提高模型的鲁棒性和稳定性。本文选择了利用标准化来预处理数据, 按照公式(5)对数据进行缩放:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

其中, X_{norm} 表示为经过归一化后的数据, X_{\min} 表示为特征的最小值, X_{\max} 表示为特征的最大值, X 表示为原始数据。

3.3. 实验设计

由于支持向量回归(SVR)、多层感知器(MLP)、决策树(DT)等是最先进的回归模型, 而单层 LSTM (SL-LSTM)、多层 LSTM (ML-LSTM)和双向循环神经网络(BiLSTM)是常见的循环模型, 因此选择它们与所提出的 PMHA-CNN-BiLSTM-XGBoost 进行产量预测的比较, 并且通过对比自注意力机制、多头注意力机制等是常见的注意力机制验证 PMHA-CNN 结构提升预测模型性能的有效性。

本文的数据主要为某炼油厂的流体催化裂化装置反应再生系统共 3681 条数据。通过采样间隔为 1 分钟为了横向对比 PMHA-CNN-BiLSTM-XGBoost 在不同数据间的效果, 均采用各指标前 3500 条数据作为训练集, 最后 181 条数据作为测试数据集。本文在 PMHA-CNN-BiLSTM-XGBoost 网络中选择催化裂化装置温度、压力、原物料量为输入变量对相关产品产率数据进行分析。此外, 在后续的实验中, 进一步分析和研究了选择每个模块间对时间序列预测以及对模型整体预测性能的影响。PMHA-CNN-BiLSTM 模型训练过程中, 迭代次数为 50 次, 均方差 MSE 作为损失函数, 采用 Adam 作为优化算法, 学习率为 0.001, 训练集中有 3500 个样本数据, 以 9:1 的比例划分, 其中使用 Dropout 层, 通过在训练过程中随机丢弃一部分神经元的输出, 降低模型对训练数据的过度依赖, 减少过拟合的风险。其中 XGBoost 的主要参数, 如表 1 所示。

Table 1. XGBoost main parameter settings

表 1. XGBoost 主要参数设置

名称	描述	参数值
n_estimators	决策树的个数	200
learning_rate	学习率	0.3
max_depth	树的最大深度	4
min_child_weight	决定最小叶子节点样本权重和	3
名称	描述	参数值
n_estimators	决策树的个数	200
learning_rate	学习率	0.3

3.4. 结果分析

经 50 次迭代训练后的 PMHA-CNN-BiLSTM-XGBoost 的对各产品产率的预测结果分别如下图所示。

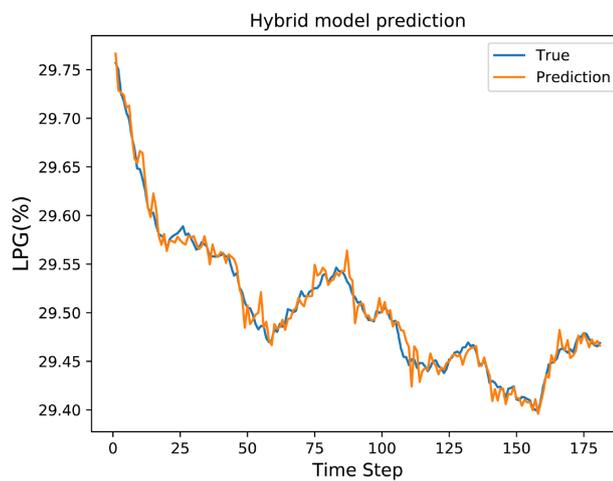


Figure 5. LPG product yield prediction

图 5. LPG 产品产率预测

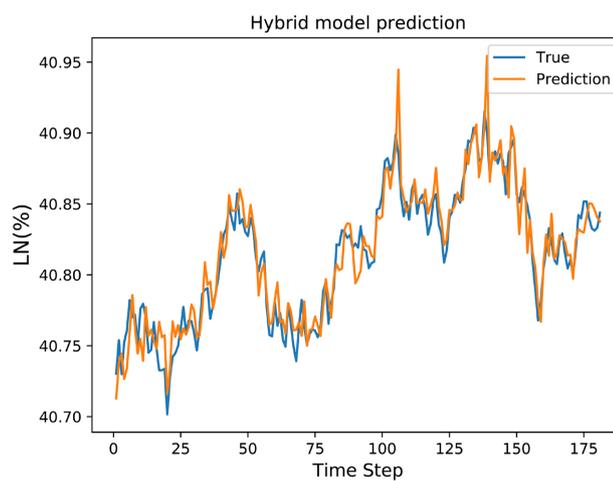


Figure 6. GSL product yield prediction

图 6. GSL 产品产率预测

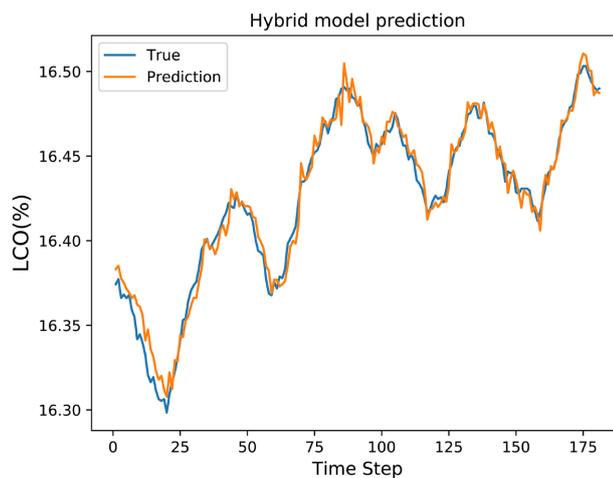


Figure 7. DO product yield prediction

图 7. DO 产品产率预测

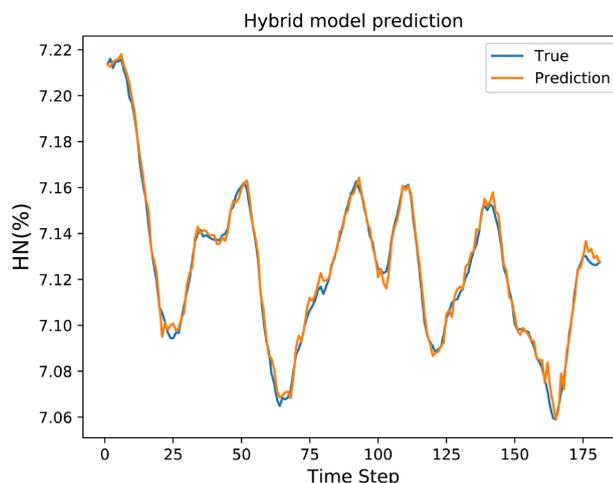


Figure 8. GS product yield prediction

图 8. GS 产品产率预测

从图 5、图 6、图 7 以及图 8 中, 我们可以看到 PMHA-CNN-BiLSTM-XGBoost 的预测精度很高, 大部分情况下, 该模型都能对目标进行比较精确的预报, 误差只有 5%, 也就是 95%, 与行业要求的精度基本一致。其中, PMHA-CNN-BiLSTM-XGBoost 应用于 GSL FCC 柴油合成组分输入输出数据的预测精度明显低于其它数据, 这主要是由于 FCC 反应类型复杂, 单一的投入产出数据不能很好地刻画关联变量与目标变量间的联系, 但 95% 的精度已经足够为我国 FCC 汽油产品的研发提供数据支持。通过试验, 验证了 PMHA-CNN-BiLSTM-XGBoost 模型对 FCC 逆再系统产率进行预测的可行性与有效性。在此基础上, 通过与其它回归分析的比较, 验证了 PMHA-CNN-BiLSTM-XGBoost 模型在预测精度上的优越性。

根据表 2 所示, 随机森林(RF)和基于 PMHA-CNN-BiLSTM-XGBoost 的模型在所有指标中表现最佳, 具有较低的 MSE、较低的 RMSE、较低的 MAE 以及较高的决定系数(R²)值, 显示出更高的预测准确性和解释能力。支持向量回归(Support Vector Regression, SVR)和多层感知器(Multi Layer Perceptron, MLP)模型的性能略逊于决策树(Decision Tree, DT)和 AdaBoost 模型, 但仍然具有一定的预测能力, 尤其是在较高的 R² 值方面表现较好。DT 和 AdaBoost 模型相对于 SVR 和 MLP 模型具有更高的预测准确性和解释能力, 但仍然不及随机森林和基于 PMHA-CNN-BiLSTM-XGBoost 的模型。基于 PMHA-CNN-BiLSTM-XGBoost 的模型在所有指标中表现最佳, 具有最低的预测误差和最高的决定系数, 显示出在不同回归模型中对催化裂化装置产率预测任务的出色适应性和优越性能。

根据表 3 所示, SL-LSTM 模型的 MSE 为 0.00089, 相对较高, 而其 RMSE 为 0.02985, MAE 为 0.02319, 决定系数 R² 为 0.69979, 表现相对较低。ML-LSTM (Multi Layer-LSTM)模型的性能略优于 SL-LSTM (Single Layer-LSTM)模型, 但仍然不够理想, 其 MSE 为 0.00075, RMSE 为 0.02740, MAE 为 0.02274, R² 为 0.75342。BiLSTM 模型表现更好, 其 MSE 为 0.00062, RMSE 为 0.02486, MAE 为 0.01933, R² 为 0.80153, 显示出更高的预测准确性和解释能力。进一步, 采用注意力机制的 SA-CNN-BiLSTM (Self-attention-CNN-BiLSTM)、MHA-CNN-BiLSTM (Multi-Head-Attention-CNN-BiLSTM)和 PMHA-CNN-BiLSTM 模型在各项指标中均有显著改进, 分别达到了较低的 MSE、RMSE 和 MAE, 以及较高的 R² 值。特别是 PMHA-CNN-BiLSTM 模型, 其 MSE 仅为 0.00177, RMSE 为 0.04202, MAE 为 0.03467, R² 为 0.97645, 表现最为优秀。最后, 基于 PMHA-CNN-BiLSTM-XGBoost 的模型在所有指标中表现最佳, 其 MSE 仅为 0.00010, RMSE 为 0.01002, MAE 为 0.00728, R² 为 0.98009, 表现出色, 显示出对不同循环神经网络情况下催化裂化装置产率预测任务的出色适应性和优越性能。

Table 2. Comparison of prediction results of different recurrent neural network models
表 2. 不同循环神经网络模型预测结果比较

模型	MSE	RMSE	MAE	R2
SVR	0.21937	0.46836	0.35872	0.89721
DT	0.19771	0.44465	0.26462	0.91400
MLP	0.20931	0.45750	0.35596	0.90895
RF	0.11505	0.33920	0.22271	0.94995
AdaBoost	0.16690	0.40854	0.31938	0.92740
PMHA-CNN-BiLSTM-XGBoost	0.00010	0.01002	0.00728	0.98009
模型	MSE	RMSE	MAE	R2

Table 3. Comparison of prediction results of different regression models
表 3. 不同回归模型预测结果比较

模型	MSE	RMSE	MAE	R2
SL-LSTM	0.00089	0.02985	0.02319	0.69979
ML-LSTM	0.00075	0.02740	0.02274	0.75342
BiLSTM	0.00062	0.02486	0.01933	0.80153
SA-CNN-BiLSTM	0.00233	0.04831	0.04273	0.95719
MHA-CNN-BiLSTM	0.00188	0.04339	0.03663	0.97218
PMHA-CNN-BiLSTM	0.00177	0.04202	0.03467	0.97645
PMHA-CNN-BiLSTM-XGBoost	0.00010	0.01002	0.00728	0.98009

4. 结论

本文提出了一种对催化裂化装置有效处理时序数据中的空间和时间信息的预测模型 PMHA-CNN-BiLSTM-XGBoost。PMHA-CNN-BiLSTM-XGBoost 主要结构为 PMHA-CNN 模块和 BiLSTM 模块，PMHA-CNN 模块负责在建模过程中提取序列数据的多尺度特征和增强局部感知野，BiLSTM 模块负责捕捉序列数据中的时序依赖关系，并减轻梯度消失问题。通过并行加入原始数据的方式，提高了模型对于处理高维和非线性数据的能力。最终通过 XGBoost 对 PMHA-CNN-BiLSTM 模型的微调能够进一步优化模型的性能，提高预测的准确性。本文实验结果将为 FCC 生产工艺优化提供新的思路和方法，为 FCC 生产工艺优化提供理论依据，也为 FCC 产品收率的综合、立体的预测奠定基础。PMHA-CNN-BiLSTM-XGBoost 与各种机器学习模型比较试验结果表明，PMHA-CNN-BiLSTM-XGBoost 方法用于 FCC 产品收率的预测具有较高的可靠性。未来将需要不断优化网络结构以及数据集的扩充来提升模型的预测准确率，继续探索更优的时序数据预测方式、神经网络等深度学习模型对 FCC 产品产率进行预测。

参考文献

- [1] Santander, O., Kuppuraj, V., Harrison, C.A., *et al.* (2022) An Open Source Fluid Catalytic Cracker-Fractionator Model to Support the Development and Benchmarking of Process Control, Machine Learning and Operation Strategies.

- Computers & Chemical Engineering*, **164**, 107900. <https://doi.org/10.1016/j.compchemeng.2022.107900>
- [2] Bollas, G.M., Lappas, A.A., Iatridis, D.K., *et al.* (2007) Five-Lump Kinetic Model with Selective Catalyst Deactivation for the Prediction of the Product Selectivity in the Fluid Catalytic Cracking Process. *Catalysis Today*, **127**, 31-43. <https://doi.org/10.1016/j.cattod.2007.02.037>
- [3] John, Y.M., Mustafa, M.A., Patel, R., *et al.* (2019) Parameter Estimation of a Six-Lump Kinetic Model of an Industrial Fluid Catalytic Cracking Unit. *Fuel*, **235**, 1436-1454. <https://doi.org/10.1016/j.fuel.2018.08.033>
- [4] Nazarova, G., Ivashkina, E., Ivanchina, E., *et al.* (2021) A Predictive Model of Catalytic Cracking: Feedstock-Induced Changes in Gasoline and Gas Composition. *Fuel Processing Technology*, **217**, 106720. <https://doi.org/10.1016/j.fuproc.2020.106720>
- [5] Yang, F., Dai, C., Tang, J., *et al.* (2020) A Hybrid Deep Learning and Mechanistic Kinetics Model for the Prediction of Fluid Catalytic Cracking Performance. *Chemical Engineering Research and Design*, **155**, 202-210. <https://doi.org/10.1016/j.cherd.2020.01.013>
- [6] Jia, C., Rohani, S. and Jutan, A. (2003) FCC Unit Modeling, Identification and Model Predictive Control, a Simulation Study. *Chemical Engineering and Processing: Process Intensification*, **42**, 311-325. [https://doi.org/10.1016/S0255-2701\(02\)00055-7](https://doi.org/10.1016/S0255-2701(02)00055-7)
- [7] Abou-Jeyab, R.A. and Gupta, Y.P. (2001) Constrained Multivariable Control of Fluidized Catalytic Cracking Process Using Linear Programming. *Chemical Engineering Research and Design*, **79**, 274-282. <https://doi.org/10.1205/026387601750281806>
- [8] Jerez, J.L., Goulart, P.J., Richter, S., *et al.* (2014) Embedded Online Optimization for Model Predictive Control at Megahertz Rates. *IEEE Transactions on Automatic Control*, **59**, 3238-3251. <https://doi.org/10.1109/TAC.2014.2351991>
- [9] Chen, C., Zhou, L., Ji, X., *et al.* (2020) Adaptive Modeling Strategy Integrating Feature Selection and Random Forest for Fluid Catalytic Cracking Processes. *Industrial & Engineering Chemistry Research*, **59**, 11265-11274. <https://doi.org/10.1021/acs.iecr.0c01409>
- [10] 肖强, 国庆, 李义一, 等. RBF神经网络在催化裂化汽油加氢装置中的应用[J]. 石油化工, 2018, 47(1): 37-42.
- [11] 陈延展, 胡浩, 任紫畅, 等. 基于 XGBoost 和改进灰狼优化算法的催化裂化汽油精制装置的辛烷值损失模型分析[J]. 石油学报(石油加工), 2022, 38(1): 208-219.
- [12] Jiang, H., Zhang, S., Yang, W., *et al.* (2023) Integration of Encoding and Temporal Forecasting: Toward End-to-End NO_x Prediction for Industrial Chemical Process. *IEEE Transactions on Neural Networks and Learning Systems*, **35**, 2984-2996. <https://doi.org/10.1109/TNNLS.2023.3276593>
- [13] Khaldi, M.K., Al-Dhaifallah, M. and Taha, O. (2023) Artificial Intelligence Perspectives: A Systematic Literature Review on Modeling, Control, and Optimization of Fluid Catalytic Cracking. *Alexandria Engineering Journal*, **80**, 294-314. <https://doi.org/10.1016/j.aej.2023.08.066>
- [14] Soni, A.N. (2018) Feature Extraction Methods for Time Series Functions Using Machine Learning. *International Journal of Innovative Research in Science, Engineering and Technology*, **7**, 8661-8665.
- [15] Yuan, Z., Yang, Z., Ling, Y., *et al.* (2021) Spatiotemporal Attention Mechanism-Based Deep Network for Critical Parameters Prediction in Chemical Process. *Process Safety and Environmental Protection*, **155**, 401-414. <https://doi.org/10.1016/j.psep.2021.09.024>
- [16] Pinheiro, C.I.C., Fernandes, J.L., Domingues, L., *et al.* (2012) Fluid Catalytic Cracking (FCC) Process Modeling, Simulation, and Control. *Industrial & Engineering Chemistry Research*, **51**, 1-29. <https://doi.org/10.1021/ie200743c>
- [17] Kadlec, P., Gabrys, B. and Strandt, S. (2009) Data-Driven Soft Sensors in the Process Industry. *Computers & Chemical Engineering*, **33**, 795-814. <https://doi.org/10.1016/j.compchemeng.2008.12.012>
- [18] Michalopoulos, J., Papadokonstadakis, S., Arampatzis, G., *et al.* (2001) Modelling of an Industrial Fluid Catalytic Cracking Unit Using Neural Networks. *Chemical Engineering Research and Design*, **79**, 137-142. <https://doi.org/10.1205/02638760151095944>
- [19] Yang, F., Sang, Y., Lv, J., *et al.* (2022) Prediction of Gasoline Yield in Fluid Catalytic Cracking Based on Multiple Level LSTM. *Chemical Engineering Research and Design*, **185**, 119-129. <https://doi.org/10.1016/j.cherd.2022.06.040>