

基于Seq2Seq模型的瞬态反应堆热工参数 预测方法研究

陈镜宇 刘喜洋 杨腾伟 赵鹏程 刘紫静

(南华大学核科学技术学院 衡阳 421001)

摘要 反应堆不同工况堆芯瞬态热工水力参数准确性直接影响反应堆安全性,快速、准确预测关键热工参数变化趋势有助于提高反应堆安全性。本文提出一种长短期记忆神经网络(Long Short-Term Memory, LSTM)与卷积神经网络(Convolutional Neural Networks, CNN)耦合的Seq2Seq(Sequence to Sequence)神经网络模型,运用小波分解法对热工参数数据预处理,通过子通道程序SUBCHANFLOW生成中国实验快堆(China Experimental Fast Reactor, CEFR)数据样本,使用秩和比法(Rank-sum Ratio, RSR)对结果进行综合评价得出一种最优的预测方案。最后通过基于时间序列的K交叉折叠验证法、自助法对该方案进行泛化能力分析。研究表明:耦合CNN-LSTM的Seq2Seq神经网络模型预测性能最优,其具有较高的精度,更强的拟合能力,最大平均相对误差为0.552%。本文构建的模型方法能够快速提取时间序列特征,泛化能力强,对于预测反应堆关键热工参数具有一定参考意义。

关键词 Seq2Seq神经网络模型, 参数预测, SUBCHANFLOW, 中国实验快堆

中图分类号 TL433

DOI: 10.11889/j.0253-3219.2025.hjs.48.240132

CSTR: 32193.14.hjs.CN31-1342/TL.2025.48.240132

Prediction method of reactor transient thermal-hydraulic parameters based on Seq2Seq model

CHEN Jingyu LIU Xiyang YANG Tengwei ZHAO Pengcheng LIU Zijing

(School of Nuclear Science and Technology, University of South China, Hengyang 421001, China)

Abstract [Background] The accuracy of transient thermal-hydraulic parameters within different operational states of a reactor core is crucial for reactor safety. Rapid and precise prediction of key thermal parameter trends is essential for enhancing reactor safety. [Purpose] This study aims to propose a novel prediction method of reactor transient thermal-hydraulic parameters based on Sequence-to-Sequence (Seq2Seq) neural network model for improving the accuracy and speed of predicting thermal parameters to ensure the safe operation of nuclear power plants. [Methods] Firstly, Long Short Term Memory (LSTM) neural network was coupled with the Convolutional Neural Networks (CNN) to form a Seq2Seq (Sequence to Sequence) neural network model, and the wavelet decomposition was applied to preprocessing thermal parameter data. Then, the SUBCHANFLOW sub-channel program was employed to generate data samples from the China experimental fast reactor (CEFR), and results were comprehensively evaluated using the rank-sum ratio (RSR) method to derive an optimal prediction scheme. Finally, the generalization ability of this scheme was further assessed through time-series-based K-fold cross-validation and bootstrapping methods. [Results] The coupled CNN-LSTM Seq2Seq neural network model exhibits superior predictive performance, with

第一作者: 陈镜宇, 男, 2003年出生, 现南华大学本科在读, 核能科学与工程专业

通信作者: 刘紫静, E-mail: liuzijing1123@163.com

收稿日期: 2024-04-21, 修回日期: 2024-11-26

First author: CHEN Jingyu, male, born in 2003, currently studying at University of South China, major in nuclear energy science and engineering

Corresponding author: LIU Zijing, E-mail: liuzijing1123@163.com

Received date: 2024-04-21, revised date: 2024-11-26

high accuracy and robust fitting capabilities. The maximum average relative error recorded is 0.552%. **[Conclusions]** The developed Seq2Seq model in this study efficiently extracts time series features and demonstrates strong generalization capabilities, providing a valuable reference for predicting critical thermal parameters in reactors.

Key words Seq2Seq neural network model, Accident parameter prediction, SUBCHANFLOW, China Experimental Fast Reactor (CEFR)

反应堆堆芯在各种工况下由于燃料包壳表面最高温度等关键热工参数变化会导致其他热工参数变化。在较短时间内快速、准确预测反应堆各种工况的关键热工参数有助于提高反应堆安全性。通过数据驱动实现人工神经网络建模的技术已经取得显著的成果^[1],目前神经网络广泛应用于堆芯热工参数的预测中^[2]。陈涵瀛等^[3-4]利用极限学习机和遗传算法优化的BP(Back Propagation)神经网络对摇摆流动不稳定热工参数进行了预测。相比于传统的反向传播神经网络,该方法通过解析计算避免了陷入局部最优的问题,并在处理大规模神经网络时显示出明显的优越性;宋厚德^[5]提出一种基于RELAP5程序与Elman神经网络结合的方式,对核反应堆参数未来状况进行预测,提高了原RELAP5模型计算精度与模型对未来预测能力;杨博皓^[6]采用经验关联式与机器学习模型混合框架对沸腾换热中热工参数快速预测,结果表明,该方法预测效果更稳定;Lee等^[7]结合长短期记忆神经网络(Long Short-Term Memory, LSTM)与基于功能层次结构安全系统自主操作算法对核电厂安全运行情况进行了评估;Moshkbar-Bakhshayesh^[8]通过不同监督学习方法预测了核电厂瞬态的重要参数,结果表明,正态分布函数和高斯核函数学习算法对时间序列预测更加精确。相关研究普遍采用的是单一的神经网络模型或通过程序与模型算法结合的方式进行热工参数预测评估。在热工参数预测过程中,由于单一模型的局限性会造成预测精度不足、学习率低、迭代次数多、时间长等问题。而模型与算法结合的方式又会造成计算复杂性高、超参数选择困难等问题。本文构建的Seq2Seq(Sequence-to-Sequence)神经网络模型,能够克服各自模型的局限性,从而提高模型对核反应堆热工参数预测的精准性、快速性。

本文首先提出一种基于LSTM、卷积神经网络(Convolutional Neural Networks, CNN)耦合的Seq2Seq神经网络模型。然后通过子通道程序SUBCHANFLOW得到中国实验快堆(China Experimental Fast Reactor, CEFR)数据样本,接着运用小波分解法对数据样本进行预处理。通过Seq2Seq模型对数据进行训练预测,使用和秩比方法对结果进行综合评估,得到一种最优预测方案。

最后通过基于时间序列的K交叉折叠验证法、自助法对最优耦合的神经网络进行泛化能力分析,进一步验证该耦合神经网络的性能。

1 参数预测方法

1.1 LSTM神经网络

LSTM称为长短期记忆网络,是循环神经网络(Recurrent Neural Network, RNN)的一种变体,通过引入记忆单元(Memory Cell)解决长期依赖问题,LSTM可防止梯度消失和梯度爆炸的发生^[9-10]。

LSTM神经网络的神经元结构如图1所示。其中, c_t 表示神经元状态; X_t 表示神经元隐藏层的输入变量; t 表示神经元当前时间; \tanh 表示 \tanh 激活函数; σ 表示 σ 激活函数, $\sigma = \frac{1}{1 + e^{-x}}$; f_t 、 X_t 、 O_t 分别表示遗忘门、输入门、输出门。

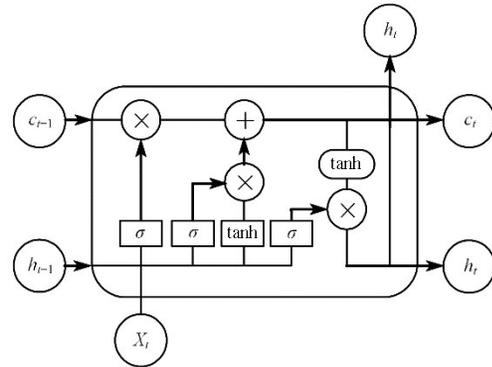


图1 LSTM神经网络的神经元结构
Fig.1 Neural structure of LSTM neural networks

输出门 O_t 控制新的输入信息流入程度。它通过sigmoid激活函数将之前记忆状态和当前的输入组合得到一个介于(0,1]的值。然后通过 \tanh 激活函数将当前输入与记忆状态组合成为行的记忆候选值。设细胞状态 C_{t-1} 数字,遗忘门读取 x_t 和 h_{t-1} ,1为保存,0为舍弃, a 为神经元隐藏层状态。有如下舍弃信息表达式:

$$f_t = \sigma(W_f[a^{(t-1)}, x(t)] + b_f) \quad (1)$$

式中: W_f 与 b_f 为学习权重与偏差。经过遗忘门与输入门处理后得到一部分信息,将这些信息存储并传

递到后续节点,更新细胞状态表达式:

$$C_t = i_t \times \hat{C} + f_t + C_{t-1} \quad (2)$$

式中: C_t 为当前神经元状态; \hat{C} 为更新后神经元的输出; C_{t-1} 为上一时刻神经元状态。通过 sigmoid 和 tanh 激活函数评估当前输入和记忆组合,得到一个介于 0 和 1 之间的值,同时通过 tanh 激活函数处理当前神经元记忆状态,再与输出门的值相乘得出当前输出。具体公式如下:

$$\begin{cases} h_t = \tanh(C_t) \times O_t \\ O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \end{cases} \quad (3)$$

LSTM 神经网络不仅只有标准 LSTM (Vanilla LSTM), 还有一些变体和扩展, 双向 LSTM (Bidirectional LSTM, BiLSTM)、带注意力机制的 LSTM (Attention LSTM) 等。由于标准 LSTM 网络结构相对简单, 在训练的过程中更加易于收敛。相较于标准 LSTM, 其余的变种 LSTM 网络相对复杂计算量更大, 需要在特定的环境下运用才能使计算精度较高与训练时间较短, 在热工参数预测过程中训练时间与精度不如标准 LSTM 神经网络, 因此本文选用标准 LSTM 神经网络。

1.2 CNN 神经网络

卷积神经网络 (Convolutional Neural Networks, CNN) 主要用来对比识别新特征和原来数据的相似性^[11], 其是一种可以高效处理多维数据的神经网络模型^[12-13], 本质是多层监督学习神经网络, 采用不断迭代训练提高网络精度, 采用梯度下降法将损失函数最小化。它具有良好的自主学习能力、并行处理能力与容错能力, 在大规模处理数据时相较于其他神经网络具有优势。

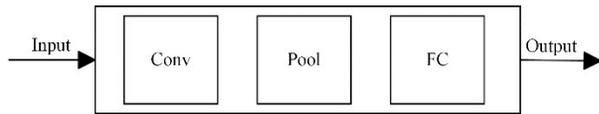


图2 CNN结构单元
Fig.2 CNN structural unit

图2是CNN结构单元。Conv代表卷积层 (Convolutional, Conv), 通过卷积运算能够降低噪声并强化初始信号的特征, 卷积层公式如下:

$$N = \frac{W - F + 2P}{S} + 1 \quad (4)$$

式中: N 为输出大小; W 为输入大小; F 为卷积核大小; P 为填充值大小; S 为步长大小。Pool代表池化层 (Pooling layer, Pool), 通过缩小神经网络矩阵大

小, 进一步降低全连接层中节点个数, 同时也防止过拟合, 加快了计算的速度, 池化层具体公式如下:

$$N = \frac{W + 2P - D \cdot (F - 1)}{S} + 1 \quad (5)$$

式中: D 为空洞。FC代表全连接层 (Fully Connected Layer), 全连层会将多轮的卷积层与池化层进行处理, 提取特征映射, 并最后转换成相应的输出。

1.3 耦合的Seq2Seq模型

Seq2Seq模型是一种特殊的递归神经网络模型^[14], 由编码器 (encoder) 与译码器 (decoder) 组成, 属于 encoder-decoder 结构的一种。LSTM 作为编码器, 负责接收并处理输入序列, 将其转换为固定长度的上下文向量; 而 CNN 作为解码器, 根据编码器生成的上下文向量逐步生成输出序列。CNN 中, 通常采用梯度下降法来最小化损失函数。CNN 通过卷积操作和反向传播, 逐层计算梯度并更新权重。然而, CNN 在处理较深层网络时, 可能会遇到梯度消失或梯度爆炸的问题, 尤其是在长时间依赖或复杂时序数据中。LSTM 的引入则能够很好地弥补这一不足。通过这种耦合方式, Seq2Seq 模型由 LSTM 与 CNN 的结合构成, 充分利用 LSTM 在时序数据上的长依赖捕捉能力以及 CNN 在空间特征提取上的优势, 实现了对复杂数据的高效建模与预测。

如图3所示, 输入序列 (x_1, x_2, \dots, x_n) 通过编码器得到隐向量 (h_1, h_2, \dots, h_m) , 令最后时刻的 h_m 作为潜在向量, 潜在向量具体公式如下:

$$h_t = f(h_{t-1}, y_{t-1}, h_m) \quad (6)$$

式中: t 表示当前时刻; $t-1$ 表示上一时刻。通过解码器对潜在向量包含的全部输入信息解码。将解码器的上一时刻输出的 y_t 作为解码器下一时刻的输入并进行预测, 得到输出向量 (y_1, y_2, \dots, y_n) 。

热工参数预测模型是一个典型的序列问题, 随着预测步数增加, 序列预测模型误差不断积累, 预测

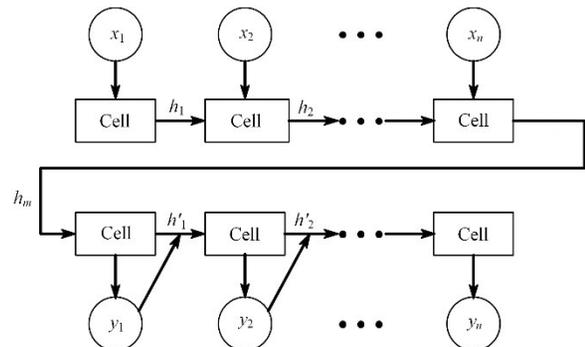


图3 Seq2Seq模型原理图
Fig.3 Schematic diagram Seq2Seq model

的效果会迅速恶化。由于单步预测只需考虑当前时刻输入,虽然计算效率较高但是单步预测对输入数据的噪声极为敏感,可能会导致预测效果不稳定。连续预测虽然占用更多的计算资源,但是可以更好捕捉信息的动态变化,对于输入信息具有更强的抗干扰能力,因此本文选用连续预测方法。

神经网络性能评价指标有许多,本文选用平均相对误差 (Mean Relative Error, MRE)、均方误差 (Mean Squared Error, MSE)、最大相对误差

(Maximum Relative Error)、模型训练时间 (Model Training Time) 这几个典型代表的指标评价不同组合的编码器-译码器神经网络预测效果。

1.4 小波分解

小波分解能够有效地捕捉信号的局部特征,其分为信号分解与信号重构。信号分解是对原始信号或每一层的近似分量 (cA) 进行离散化的小波变换 (Discrete Wavelet Transform, DWT), 获得下一层细节分量与近似分量, 如图 4 所示。

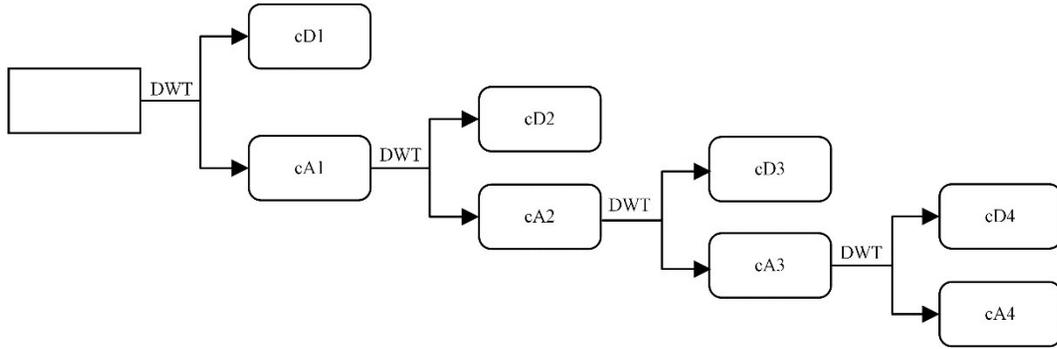


图4 小波分解示意图

Fig.4 Schematic diagram of wavelet decomposition

其中, cD 表示细节分量; cA 表示近似分量。通过选择适当的小波基函数使分解产生不同的结果, 形成不同的类型信号, 再通过小波分解的阶次, 确定分解的层次。通过不断对信号单支重构至上一层信号直至与原始信号同等长度, 形成最终的结果。小波分解的具体公式如下:

$$d_{j+1} = Hd_j \quad j = 1, 2, 3, \dots, N \quad (7)$$

$$a_{j+1} = Ga_j \quad j = 1, 2, 3, \dots, N \quad (8)$$

式中: G 为低通滤波器; H 为高通滤波器; a_j 为得到趋势序列; d_j 为得到的细节序列。通过反复进行, 基于分解所得的趋势序列不断分解。

因为趋势序列的信息通过下一阶段被分解到不同的时间点, 由此分解得到的结果的细节序列与初始序列长度不等, 为了保持它们的一致性, 需要重构前后的数据, 保证它们长度相等。重构公式如下:

$$A_j = H^*d_{i+1} + G^*a_{i+1} = N - 1, N - 2, \dots, 0 \quad (9)$$

式中: H^* 、 G^* 为对偶算子。通过上述式子得到的序列相加合成能够得到一个精确的原始数据。由于较高的分解会导致噪音与信号中细微的变化过于敏感, 同时计算复杂度也会随之增加, 较低阶数的小波分解可能会导致无法捕捉信号中的细微细节和高频信息, 经过多次的测试分解, 分解 4 次效果最佳。

2 算例验证

钠冷快堆是第四代先进核能系统的优选堆型, 可以大幅度提高铀的资源利用率, 在我国是一种全新的核工程技术^[15]。CEFR 堆芯分了 4 个燃料区, 每盒组件内有 61 根燃料棒^[16]。相关堆芯参数数据见表 1^[17]。假设燃料组件内各燃料棒具有相同的轴向与径向功率, 将单个组件内所有的冷却剂通道合并成一个以燃料棒为中心的、加热周长与润湿周长等效的大通道^[18]。通过 SUBCHANFLOW 得到 771 组数据样本。

由 §1.4 可知, 图 5 是通过小波分解对 CEFR 反应堆的燃料包壳最大温度数据分解图, 图中表示初始数据、分解后的一阶、二阶、三阶、四阶近似分量和一阶细节分量的包壳温度随时间的变化。由图 5 看出, 未经过小波分解的包壳最大温度一定时间内在 551~589 °C 反复振荡。通过小波分解进行四阶分解后得到预测温度介于 560~571 °C, 即近似分量在 560~571 °C。

以 771 组数据的堆芯入口流量与燃料包壳最高温度作为输入, 燃料包壳最高温度作为输出。取前 507 组 (83.35%) 作为训练集数据, 即 0~63 s 的数据作为训练集。508~631 组, 即后 124 组 (16.65%) 作为预测集数据, 即 64~80 s 的数据作为预测集, 相关数据结果如表 2、图 6~9 所示。

表1 CEFR堆芯设计参数
Table 1 CEFR core design parameters

参数 Parameters	数值 Values
功率 Power / MW	65
组件内燃料棒数 Number of fuel rods in the module	61
活性区高度 Height of active zone / mm	450
燃料棒直径 Fuel rod diameter / mm	6.0
包壳厚度 Shell thickness / mm	0.3
芯块外径/内径 Core block outer/inner diameter / mm	5.2/1.6
堆芯进口/出口温度 Inlet/outlet temperature of the core / °C	360/530
定位绕丝螺距 Positioning winding pitch / mm	100

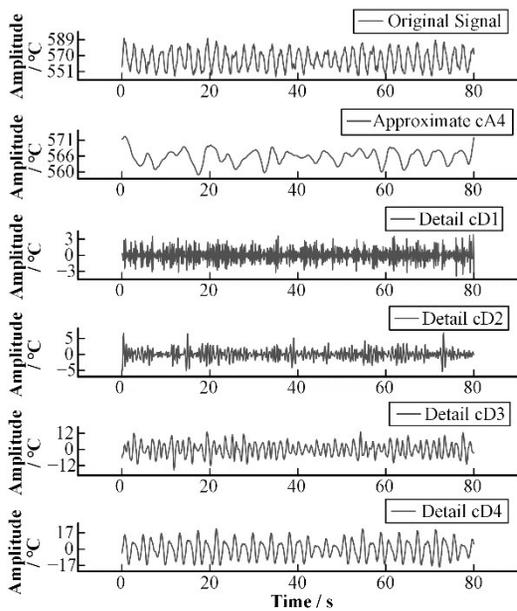


图5 中国实验快堆最高包壳温度小波分解结果
Fig.5 Wavelet analysis decomposition results of the highest envelope temperature of China experimental fast reactor

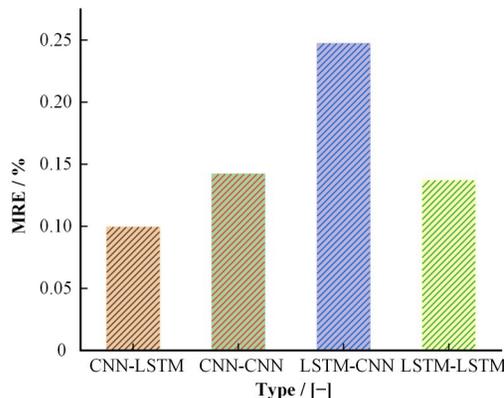


图6 4种编码器-译码器组合平均相对误差(MRE)比较
(彩图见网络版)
Fig.6 Comparison of Mean Relative Error (MRE) among four encoder-decoder combinations (color online)

4种编码器-译码器组合中,CNN-CNN训练时间最短为190.038 s。CNN-LSTM的MRE、RMSE、

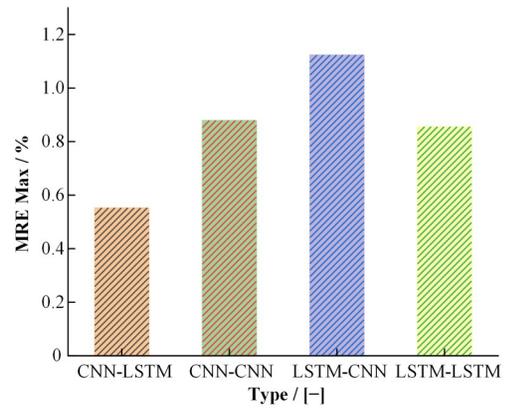


图7 4种编码器-译码器组合最大相对误差比较
(彩图见网络版)

Fig.7 Comparison of maximum relative error among four encoder-decoder combinations (color online)

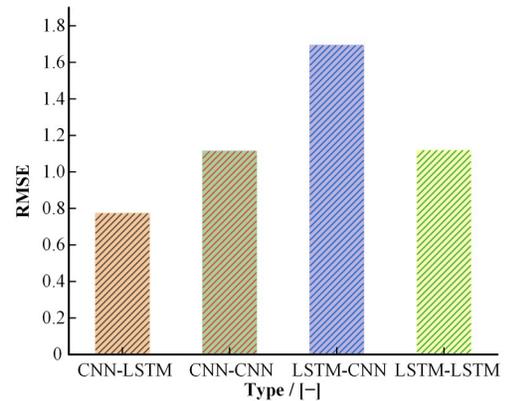


图8 4种编码器-译码器组合RMSE比较(彩图见网络版)
Fig.8 Comparison of RMSE among four encoder-decoder combinations (color online)

最大相对误差均比CNN-CNN低,其分别为0.099%、0.772 28、0.552%。计算MRE、最大相对误差、RMSE、训练时间的权重为0.178、0.369、0.179、0.274,CNN-CNN、CNN-LSTM、LSTM-CNN、LSTM-LSTM综合评价因子依次分别为0.182 312、0.203 875、0.062 500、0.176 313,通过秩和比法(Rank-Sum Ratio, RSR)进行综合评估得出最优耦

合 Seq2Seq 神经网络为 CNN-LSTM, 具体预测结果 如图 10 所示。

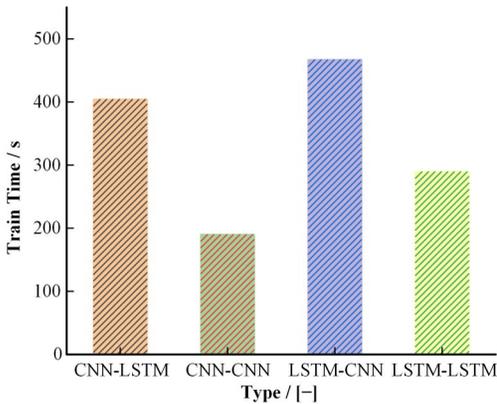


图9 4种编码器-译码器组合训练时间比较(彩图见网络版)

Fig.9 Comparison of the training time among four encoder-decoder combination (color online)

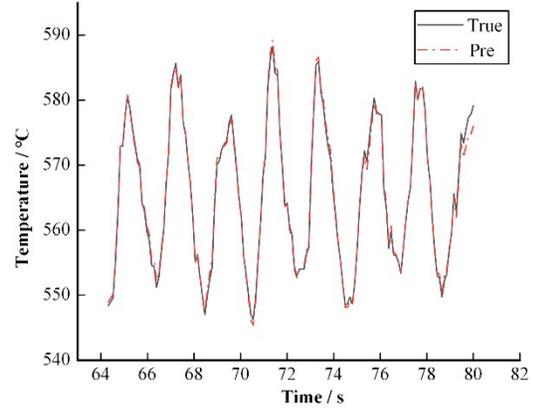


图10 温度的CNN-LSTM预测值与真实值的对比(彩图见网络版)

Fig.10 Comparison of temperature between CNN-LSTM predicted value and real value (color online)

表2 Seq2Seq模型不同编码器-译码器的预测误差
Table 2 Seq2Seq model prediction error of different encoders-decoders

预测变量 Predictor variables	神经网络模型结构(编码器-解码器) Neural network model structure (encoder-decoder)	MRE× 100%	RMSE	最大相对误差 Maximum relative error / %	模型训练时间 Model training time / s
包壳最高温度 Maximum shell temperature	CNN-CNN	0.142	1.112 74	0.878	190.038
	CNN-LSTM	0.099	0.772 28	0.552	404.467
	LSTM-CNN	0.247	1.692 33	1.123	467.045
	LSTM-LSTM	0.137	1.117 49	0.855	289.722

3 模型泛化能力分析

神经网络泛化性是指神经网络模型在学习完成以后推广应用的能力。泛化能力是衡量神经网络性能优劣的一个重要的方面^[19]。神经网络模型泛化能力越强,捕捉数据中的一般规律的能力就越强,而不是过度依赖于训练数据的特定模式。

3.1 基于时间序列的K交叉折叠验证

K折叠交叉验证法能够用于评估神经网络模型的性能。将整个时间序列的数据按照时间顺序划分为k个大小相等的样本子集,然后依次遍历k个子集。在每一次训练和验证过程中,其中的一个子集作为验证集,而其余的k-1个子集作为训练集,并评估模型。具体如图11所示。

图11中test表示测试集,train表示训练集。时间序列的K折叠交叉验证方法对于热工参数预测更加符合实际的情况,保证模型在未来时间点上的泛化能力。

取k=5,将整个SUBCHANFLOW获得的钠冷快

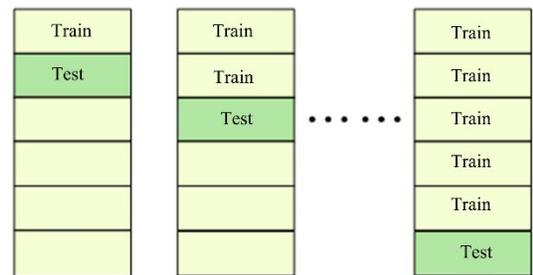


图11 基于时间序列的K折叠验证交叉法示意图
Fig.11 Schematics of K-fold cross-validation based on time series

堆的数据按照时间划分为6个折叠,依次遍历其余5个子集,将当前子集的前一时刻的子集作为训练集。在每一次迭代的过程中得到评估性能的各个指标。其中损失函数是神经网络模型训练过程的一个重要的指标,用以度量模型训练集与验证集的性能,较低的损失函数意味着神经网络模型较好。由前文已知最佳的编码器-译码器耦合神经网络为CNN-LSTM,通过时间序列K交叉折叠验证法测试后,得出损失函数、最大平均相对误差、训练时间、均方根误差。损失函数如图12所示。

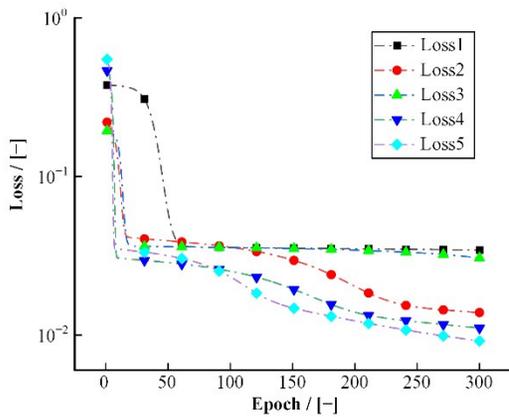


图12 CNN-LSTM神经网络5次折叠交叉验证的损失函数(彩图见网络版)

Fig.12 Loss function of CNN-LSTM neural network with 5 folds cross-validation (color online)

图12表示5次折叠交叉验证的损失函数随迭代次数变化关系。由图12可知,1~5次的损失函数在约50次迭代后变化趋势趋于平缓,第5次在0~50次迭代下降最快,第1次在0~50次迭代下降最缓慢。

表3表示CNN-LSTM神经网络5次折叠交叉验证的预测误差。5次计算的平均值分别为(依次为最大相对误差,模型训练时间)0.237%、1.650 90、0.704%、247.508 s。由表3可知,CNN-LSTM耦合的Seq2Seq神经网络的各种预测误差参数较低,训练时间较短。较小的MRE表明,模型对目标参数预测准确度较高,较短的训练时间表明模型整体能够高效快速地学习,较小的RMSE表示模型对数据整体的拟合效果较好,较小的最大相对误差表示模型对于整个数据集具有相对较好的准确性。

表3 CNN-LSTM神经网络5次折叠交叉验证的预测误差
Table 3 Prediction error of CNN-LSTM neural network with 5 folds cross-validation

预测变量 Predictor variables	次数 Number of times	MRE×100%	RMSE	最大相对误差 Maximum relative error / %	模型训练时间 Model training time / s
包壳最高温度 Maximum shell temperature	1	0.426	2.722 32	0.796	82.953
	2	0.288	2.080 65	0.926	154.763
	3	0.153	1.093 82	0.528	247.583
	4	0.200	1.404 01	0.549	339.037
	5	0.116	0.953 69	0.721	413.203

3.2 自助法验证

自助法通过直接自助采样法作为基础,设771个样本为数据集D,在数据集D中每次随机挑选一个样本,并拷贝放入数据集D(new)中,同时将该样本放回原始数据集D中,确保该样本能够在下一次的采集中被采集到,重复执行771次,得到包含771个样本的数据集D(new)。由于数据集D中有一部分样本在数据集D(new)中重复出现,另一部分不会出现。于是在771次采样中从未被采集的概率是 $(1-1/m)^m$, m 为样本数量,通过极限知:

$$\lim_{m \rightarrow \infty} \left(1 - \frac{1}{m}\right)^m \rightarrow \frac{1}{e} \approx 0.368 \quad (10)$$

初始数据D中约36.8%的样本没有在D(new)数据集出现,令新的数据集作为训练集,原始数据集剔除新数据集的元素后作为测试集。

图13表示CNN-LSTM神经网络通过5次自助法验证的损失函数示意图,从图中得出,损失函数整体呈现下降趋势,最后得到较好的效果。表4是CNN-LSTM神经网络5次自助法验证的预测误差,

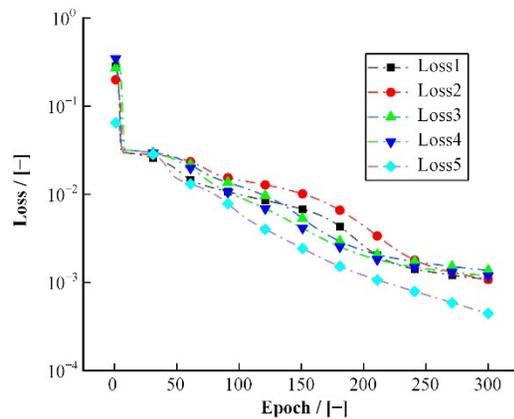


图13 CNN-LSTM神经网络5次自助法验证的损失函数(彩图见网络版)

Fig.13 Loss function of CNN-LSTM neural network verified five times by self help method (color online)

通过5次自助法验证,结果表明,在不同的数据集下,该模型都能够收敛到一个比较好的效果,即CNN-LSTM耦合的Seq2Seq神经网络模型泛化能力强。

表4 CNN-LSTM 神经网络5次自助法验证的预测误差
Table 4 Prediction error of CNN-LSTM neural network verified by five self help methods

预测变量 Predictor variables	次数 Number of times	MRE×100%	RMSE	最大相对误差 Maximum relative error / %	模型训练时间 Model training time / s
包壳最高温度 Maximum shell temperature	1	0.062 3	0.457 61	0.796	481.099
	2	0.060 2	0.442 18	0.926	448.932
	3	0.080 7	0.589 93	0.528	437.014
	4	0.060 4	0.438 45	0.549	446.559
	5	0.044 1	0.327 50	0.721	438.514

4 结语

针对瞬态反应堆堆芯关键热工参数预测的问题,本文首先提出 LSTM、CNN 耦合的 Seq2Seq 神经网络模型,运用小波分解法处理数据样本。其次通过 SUBCHANFLOW 得到中国实验快堆样本数据,通过秩和比法对结果进行综合评价,得出一种最优的方案。最后通过基于时间序列的 K 交叉折叠验证法、自助法对该方案的模型泛化能力进行分析。验证结果如下:

1)通过秩和比法综合评价得出耦合 CNN-LSTM 的 Seq2Seq 神经网络为最优方案。本文提出的神经网络模型预测方法相较于单一的模型算法、模型程序结合的预测方法,具有较高的精度、较短时间。在无须优化算法进行超参数优化下具有较高的精度。

2)通过基于时间序列的 K 交叉折叠验证法、自助法对编码器-译码器为 CNN-LSTM 的 Seq2Seq 模型泛化能力进行检验,得出该模型的泛化能力较强,对噪声和变化具有一定鲁棒性和稳健性。

本文提出的耦合的 Seq2Seq 神经网络方法对于燃料包壳最高温度变化趋势预测具有较高精度,同时该模型泛化能力较强,在后续的工作中将开展其他关键热工参数预测。

作者贡献声明 陈镜宇负责论文整体设计, SUBCHANFLOW 程序设计,起草文案;刘喜洋负责 Seq2Seq 模型设计,模型泛化能力分析设计;杨腾伟负责获取钠冷快堆堆芯的有效数据;赵鹏程负责对文章作批评性审阅,研究经费支持,思想政治指导;刘紫静负责行政、技术或材料支持,指导。

参考文献

1 Galib S M, Bhowmik P K, Avachat A V, *et al.* A comparative study of machine learning methods for automated identification of radioisotopes using NaI gamma-ray spectra[J]. Nuclear Engineering and Technology, 2021, 53(12): 4072 - 4079. DOI: 10.1016/j.

net.2021.06.020.

2 焦炜. 机器学习算法在多相热工水力参数快速预测的应用研究[D]. 北京: 华北电力大学, 2022. DOI: 10.27140/d.cnki.ghbbu.2022.001539.

JIAO Wei. Application of machine learning algorithm in rapid prediction of multiphase thermal and hydraulic parameters[D]. Beijing: North China Electric Power University, 2022. DOI: 10.27140/d.cnki.ghbbu.2022.001539.

3 陈涵瀛, 高璞珍, 谭思超, 等. 基于极限学习机模型的流动不稳定性多热工参量联合预测方法[J]. 原子能科学技术, 2015, 49(12): 2164 - 2169. DOI: 10.7538/yzk.2015.49.12.2164.

CHEN Hanying, GAO Puzhen, TAN Sichao, *et al.* Joint prediction of multiple thermal variables for flow instability based on extreme learning machine model[J]. Atomic Energy Science and Technology, 2015, 49(12): 2164 - 2169. DOI: 10.7538/yzk.2015.49.12.2164.

4 陈涵瀛, 高璞珍, 谭思超. 摇摆流动不稳定性遗传算法优化神经网络预测[J]. 原子能科学技术, 2015, 49(2): 273 - 278. DOI: 10.7538/yzk.2015.49.02.0273.

CHEN Hanying, GAO Puzhen, TAN Sichao. Prediction of flow instability under rolling motion based on neural network optimized by genetic algorithm[J]. Atomic Energy Science and Technology, 2015, 49(2): 273 - 278. DOI: 10.7538/yzk.2015.49.02.0273.

5 宋厚德. 基于热工水力最佳估算程序与 Elman 神经网络的核反应堆参数未来状态预测[D]. 上海: 上海交通大学, 2021. DOI: 10.27307/d.cnki.gsjtu.2021.000763.

SONG Houde. Future state prediction of nuclear reactor parameters based on thermodynamic best estimation procedure and Elman neural network[D]. Shanghai: Shanghai Jiao Tong University, 2021. DOI: 10.27307/d.cnki.gsjtu.2021.000763.

6 杨博皓. 基于机器学习的沸腾换热中热工水力参数快速预测方法及应用[D]. 北京: 华北电力大学, 2023. DOI: 10.27140/d.cnki.ghbbu.2023.000669.

- YANG Bohao. Rapid prediction methods and applications of thermal hydraulic parameters in boiling heat transfer based on machine learning[D]. Beijing: North China Electric Power University, 2023. DOI: 10.27140/d.cnki.ghbbu.2023.000669.
- 7 Lee D, Seong P H, Kim J. Autonomous operation algorithm for safety systems of nuclear power plants by using long-short term memory and function-based hierarchical framework[J]. *Annals of Nuclear Energy*, 2018, **119**: 287 - 299. DOI: 10.1016/j.anucene.2018.05.020.
- 8 Moshkbar-Bakhshayesh K. Comparative study of application of different supervised learning methods in forecasting future states of NPPs operating parameters[J]. *Annals of Nuclear Energy*, 2019, **132**: 87 - 99. DOI: 10.1016/j.anucene.2019.04.031.
- 9 倪铮, 梁萍. 基于 LSTM 深度神经网络的精细化气温预报初探[J]. *计算机应用与软件*, 2018, **35**(11): 233 - 236, 271. DOI: 10.3969/j.issn.1000-386x.2018.11.040.
- NI Zheng, LIANG Ping. Fine temperature forecast based on lstm deep neural network[J]. *Computer Applications and Software*, 2018, **35**(11): 233 - 236, 271. DOI: 10.3969/j.issn.1000-386x.2018.11.040.
- 10 徐一轩, 伍卫国, 王思敏, 等. 基于长短期记忆网络(LSTM)的数据中心温度预测算法[J]. *计算机技术与发展*, 2019, **29**(12): 1 - 7. DOI: 10.3969/j.issn.1673-629X.2019.12.001.
- XU Yixuan, WU Weiguo, WANG Simin, *et al.* Data center temperature prediction algorithm based on long short-term memory network[J]. *Computer Technology and Development*, 2019, **29**(12): 1 - 7. DOI: 10.3969/j.issn.1673-629X.2019.12.001.
- 11 陈秀秀, 朱凯. 基于 CNN-LSTM 和注意力机制的锂电池健康状态评估[J]. *工业控制计算机*, 2022, **35**(12): 80 - 82. DOI: 10.3969/j.issn.1001-182X.2022.12.029.
- CHEN Xiuxiu, ZHU Kai. Assessment of health status of lithium batteries based on CNN-LSTM and attention mechanism[J]. *Industrial Control Computer*, 2022, **35**(12): 80 - 82. DOI: 10.3969/j.issn.1001-182X.2022.12.029.
- 12 Li X, Ding Q, Sun J Q. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. *Reliability Engineering & System Safety*, 2018, **172**: 1 - 11. DOI: 10.1016/j.ress.2017.11.021.
- 13 Zhou S, Xiao M H, Bartos P, *et al.* Remaining useful life prediction and fault diagnosis of rolling bearings based on short-time Fourier transform and convolutional neural network[J]. *Shock and Vibration*, 2020, **2020**: 8857307. DOI: 10.1155/2020/8857307.
- 14 汤健, 侯慧娟, 陈洪岗, 等. 基于 BI-GRU 改进的 Seq2Seq 网络的变压器油中溶解气体浓度预测方法[J]. *电力自动化设备*, 2022, **42**(3): 196 - 202, 217. DOI: 10.16081/j.epae.202111017.
- TANG Jian, HOU Huijuan, CHEN Honggang, *et al.* Concentration prediction method based on Seq2Seq network improved by BI-GRU for dissolved gas in transformer oil[J]. *Electric Power Automation Equipment*, 2022, **42**(3): 196 - 202, 217. DOI: 10.16081/j.epae.202111017.
- 15 郝老迷, 谢晖. 堆芯冷却剂流量下降 DNBR 计算[J]. *原子能科学技术*, 1993, **27**(5): 422 - 425.
- HAO Laomi, XIE Hui. DNBR calculation in the case of decrease in core coolant flow rate[J]. *Atomic Energy Science and Technology*, 1993, **27**(5): 422 - 425.
- 16 徐镱. 我国快堆发展战略目标研究[J]. *核科学与工程*, 2008, **28**(1): 20 - 25. DOI: 10.3321/j.issn:0258-0918.2008.01.004.
- XU Mi. Fast reactor development strategy targets study in China[J]. *Chinese Journal of Nuclear Science and Engineering*, 2008, **28**(1): 20 - 25. DOI: 10.3321/j.issn:0258-0918.2008.01.004.
- 17 Gomez A, Jäger W, Sanchez V, *et al.* On the influence of shape factors for CHF predictions with the sub channel code SUBCHANFLOW during a rod ejection[C]. NUTHOS-9, Kaohsiung, Taiwan, 2012.
- 18 胡培政. 堆芯热工水力多尺度耦合计算研究[D]. 哈尔滨: 哈尔滨工程大学, 2019.
- HU Peizheng. Study on multi-scale thermal-hydraulic coupling calculation method for reactor core[D]. Harbin: Harbin Engineering University, 2019.
- 19 谢文兰. 对提高 BP 神经网络泛化能力的分析和总结[J]. *广东科技*, 2011, **20**(14): 72 - 73. DOI: 10.3969/j.issn.1006-5423.2011.14.045.
- XIE Wenlan. Analysis and summary of improving the generalization ability of BP neural network[J]. *Guangdong Science & Technology*, 2011, **20**(14): 72 - 73. DOI: 10.3969/j.issn.1006-5423.2011.14.045.