DOI：10.13890/j.issn.1000-128X.2023.06.014
文章编号：1000-128X(2023)06-0114-08

基于融合注意力机制的多智能体磁浮谐波预测算法

王宗艳[1]，毛中亚[1]，黄世泽[2]，郭其一[1]
（1. 同济大学 电子与信息工程学院，上海 201804；
2. 同济大学 交通运输工程学院，上海 201804）

摘 要：为减小高速磁浮系统谐波对牵引供电网产生的影响，解决谐波治理存在的时滞性问题，通常需要对谐波电流进行预测。对此，采用融合深度学习算法的组合模型相比于传统算法的表现更加出色。文章提出一种新的融合注意力机制的多智能体磁浮谐波预测算法，该算法通过麻雀搜索算法（SSA）优化变分模态分解（VMD）的相关参数，并利用该优化参数将原始电流信号分解为多个不同中心频率的谐波分量，将各个分量分别输入融合注意力机制的长短时记忆网络（LSTM）中进行时序预测，形成多个独立预测智能体，再对各个智能体预测结果进行重构，从而实现对高速磁浮谐波电流预测。在此基础上引入误差修正机制，进一步提高模型的预测精度。对上海高速磁浮牵引系统进行理论分析与仿真，采集网侧电流数据，并用所提出的算法模型对此数据进行试验和分析。结果表明，与其他模型相比，所提的预测模型在磁浮谐波电流预测方面具有较好的性能，并可使时滞性得到进一步改善。

关键词：谐波预测；麻雀搜索算法；变分模态分解；长短时记忆神经网络；注意力机制
中图分类号：U237　　**文献标识码：**A

Multi-agent maglev harmonic prediction algorithm based on integrated attention mechanism

WANG Zongyan[1], MAO Zhongya[1], HUANG Shize[2], GUO Qiyi[1]

(1. College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China;
2. College of Transportation Engineering, Tongji University, Shanghai 201804, China)

Abstract: To mitigate the impact of high-speed maglev harmonics on the traction power supply network and address the time lag in harmonic control, predicting harmonic current is commonly necessary. In this context, a superior alternative to traditional algorithms is a combined model that integrates deep learning algorithms. In this paper, a new multi-agent maglev harmonic prediction algorithm with integrated attention mechanism was proposed. The algorithm optimized the parameters of variational mode decomposition (VMD) by sparrow search algorithm (SSA), and used these optimized parameters to decompose the original current signal into harmonic components with different center frequencies. Subsequently, all components were input into the long short-term memory (LSTM) network of the integrated attention mechanism for time series prediction, and multiple independent prediction agents were formed, followed by the reconstruction of each agent's prediction results, so as to predict the harmonic current of the high-speed maglev. On this basis, the error correction mechanism was introduced to enhance the prediction accuracy of the model. Theoretical analysis and simulations of Shanghai high-speed maglev traction system were conducted, with the grid-side current data collected for experiment and analysis using the proposed algorithm model. The results indicate that, compared with other models, the proposed prediction model demonstrated superior performance

基金项目：国家重点研发计划项目（2017YFB1200901-11）
通信作者：王宗艳（1999—），女，硕士研究生，主要从事深度学习与地铁牵引系统谐波治理方面的研究；E-mail: 2133078@tongji.edu.com
引用格式：王宗艳, 毛中亚, 黄世泽, 等. 基于融合注意力机制的多智能体磁浮谐波预测算法[J]. 机车电传动, 2023(6): 114-121.
Citation: WANG Zongyan, MAO Zhongya, HUANG Shize, et al. Multi-agent maglev harmonic prediction algorithm based on integrated attention mechanism[J]. Electric drive for locomotives,2023(6): 114-121.

in predicting maglev harmonic current, with the potential for further reducing the time lag.

Keywords: harmonic prediction; sparrow search algorithm; variational mode decomposition; long short-term memory neural network; attention mechanism

0　引言

随着我国社会生产力的发展，我国高速磁浮技术进入了世界领先水平。然而高速磁浮列车在运行时会产生大量谐波，进而影响系统的安全运行，对牵引供电网的电能质量造成严重影响。因此，对高速磁浮系统产生的谐波进行治理具有重要意义。

对系统谐波进行治理通常采用“检测–滤波–补偿”的方法。随着相关研究的发展，各国学者提出了多种谐波检测方法，包括基于传统变换域的傅里叶变换[1]、瞬时无功功率理论[2]、小波变换[3]、模态分解[4]和基于人工智能的神经网络理论[5-7]。但是由于滤波器的数字控制器的采样和转换等会引入严重的延迟，影响滤波器的补偿性能，因此这种谐波治理过程存在一定的时滞性。文献[8-9]详细研究了数据采集和数字信号处理过程中延时时间对补偿参考信号的影响。对此，更多学者着眼于谐波电流预测策略的研究，实行“预测检测–滤波–补偿”的治理过程。文献[10]基于正向线性预测理论，对下一采样周期的电流进行预测，以最小的误差补偿谐波电流，但传统的算法理论存在精度和速度的不足；文献[11-12]将人工神经网络运用于谐波电流预测，令径向基神经网络与i_p-i_q法相结合，对低频谐波信号进行分离，并实时计算时滞误差，改善谐波治理过程中的时滞性。研究表明，深度学习作为一种强大的表征学习算法，能够挖掘数据之间的更多深层特征[13]，文献[14-15]将融合深度学习算法的组合模型运用于风电、负荷序列预测领域，并已取得了较好的效果，但预测模型与参数间的选取存在差异。

综上所述，考虑到高速磁浮系统的谐波电流也是时序性较强的连续信号，本文以上海高速磁浮牵引系统为例，对其进行建模仿真，分析谐波特性，采集网侧产生的谐波电流，并提出一种新的基于麻雀搜索算法（Sparrow Search Algorithm，SSA）优化的多智能体融合注意力机制的谐波时序预测算法模型，实现对磁浮谐波的预测，改善其时滞性。该算法模型利用经SSA优化后的变分模态分解（Variational Mode Decomposition，VMD）将原始序列信号分解为多个谐波分量的本征模式函数集（Intrinsic Mode Function Set，IMFS），采用长短时记忆网络（Long Short-Term Memory，LSTM）对各个IMFS进行预测，引入注意力机制（Attention）提升模型对时间关联性的筛选能力，由此形成多个“IMF-LSTM-Attention”预测智能体，各个智能体之间独立预测，互不干扰，并在模型的最后引入误差修正机制（Error Correction，EC），进一步提升模型的预测效果。

1　预测模型的相关理论和算法

1.1　基于SSA优化变分模态分解

SSA算法[16]是由受到麻雀觅食和反追捕行为机制启发而提出的一种群智能优化算法，相比传统的粒子群算法，SSA的收敛速度与精度都得到了提高，全局搜索能力较强，不易陷入局部最优解。SSA算法通过在有D维解的空间内选取合适的适应度函数，初始化每只麻雀的位置X与其对应的适应度值f，当满足一定的约束条件时，每只麻雀在安全区域内搜索食物，反之立即转移，以此来更新位置，搜索最优适应度值和对应的值。

VMD是由DRAGOMIRETSKIY K[17]提出的一种自适应信号处理算法，该算法克服了经验模态分解及其变种技术中存在的模态混叠[18]等问题。VMD通过迭代搜索最优的变分模型，计算每个分解模态的中心频率与频带宽度，将信号$x(t)$分解为K个调幅调频信号u_k。

VMD的中心思想是变分问题的构造和求解，分解对应的约束变分模型表达式为：

$$\left.\begin{aligned}&\min_{\{u_k\}\{\omega_k\}}\left\{\sum_k\left\|\partial_t\left[\left(\delta(t)+\frac{\mathrm{j}}{\pi t}\right)*u_k(t)\right]\mathrm{e}^{-\mathrm{j}\omega_k t}\right\|_2^2\right\}\\&\text{s.t.}\sum_{k=1}^{K}u_k=f\end{aligned}\right\}\tag{1}$$

式中：K为需分解的模态个数；$\{u_k\},\{\omega_k\}$分别为分解后第k个IMF和对应的中心频率；$\delta(t)$为狄克拉函数；$*$为卷积运算符。

VMD可抗噪声干扰，并且具有较好的数据分解精度，但是其惩罚参数α和分解个数K的不同组合会对分解结果产生影响，因此本文所提模型以VMD的包络熵E_p作为适应度函数，采用SSA优化算法对2个参数寻优。E_p体现了待分解序列的稀疏性，当分解模态中噪声较少，特征信息较多时，E_p值小，反之E_p值较大。包络熵的计算公式[19]如下：

$$E_p=-\sum_{j=1}^{N}\left(p_j\cdot\lg p_j\right)\tag{2}$$

$$p_j=\frac{a(j)}{\sum_{j=1}^{N}a(j)}\tag{3}$$

$$a(j)=\sqrt{\left[u(j)\right]^2+\left\{\mathrm{H}\left[u(j)\right]\right\}^2}\tag{4}$$

式中：$a(j)$为由VMD分解得到的模态分量经希尔伯特解调后的包络信号；H[ ]代表希尔伯特变换；$u(j)$为长度为N的IMF信号；p_j为计算归一化得到的概率分布序列；N为采样点数。

1.2 长短时记忆－注意力机制算法

LSTM是循环神经网络（Rerrent Neural Network，RNN）的变种结构之一，有效解决了RNN在反向学习过程中可能产生的梯度消失和梯度爆炸问题，同时LSTM可以对长时间序列中的信息进行传递和表达，而且不会导致学习时间间隔过长的有用信息被遗忘，因此LSTM被更广泛地应用于时间序列处理[20]。每个LSTM单元结构包含4个交互层，构成了遗忘门、输入门和输出门3个门控机制，对单元信息进行记忆与更新。

Attention机制是模拟生物注意力理论的一种模型，为节省时间和运行成本、提高精确度，将有限的注意力放在关键数据上，从中快速提取最有用的信息[21]。Attention机制的本质是计算相似度值，即隐含层对应的权重值，使用softmax函数对其进行归一化并加权求和。Attention机制的原理如图1所示。本文设计的LSTM-Attention谐波预测模型如图2所示。

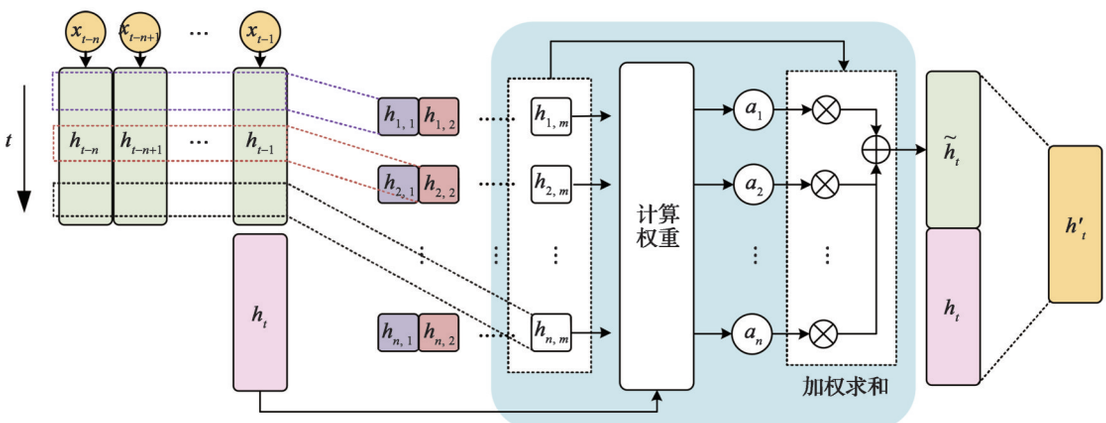


图1 注意力机制原理图

Fig. 1 Schematic diagram of attention mechanism

在图1中，$h_{1,m}$, $h_{2,m}$, …, $h_{n,m}$为m时刻LSTM输出的隐含单元状态，通过归一化得到每个状态对于当前的输出所占的权重值，并进行加权求和得到当前输出隐含单元的值h'_t。本文所提算法采用的注意力计算公式为：

$$e_{i,t}=\boldsymbol{S}_{t-1}^{\mathrm{T}}\times\boldsymbol{h}_{i,t} \tag{5}$$

$$a_{i,t}=\frac{\exp(e_{i,t})}{\sum_{k=1}^{T}\exp(e_t,k)} \tag{6}$$

式中：$e_{i,t}$为相似度值；$a_{i,t}$为归一化后的权重，反映了当前输出$\boldsymbol{h}_{i,t}$相对于先前隐含状态$\boldsymbol{S}_{t-1}$在决定下一状态的$\boldsymbol{S}_t$和输出时的重要程度。

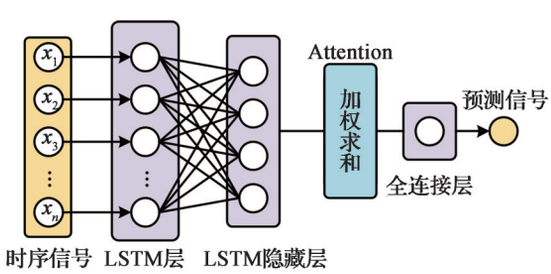


图2 基于LSTM-Attention机制的模型结构图

Fig. 2 Diagram of the model structure based on LSTM-attention mechanism

实际上，系统产生的电流并不是单一的正弦波，而是受噪声与谐波干扰影响而形成的组合信号，在利用LSTM进行谐波电流预测工作时，采用融合注意力机制的LSTM-Attention模型可以为LSTM的隐含状态赋予不同的权值，即选择性地强调某个输入数据的重要性，进而得到更精确的预测结果。

2 多智能体谐波时序预测算法模型建立

本文提出一种新型的多智能体组合算法模型（SSAVMD-LSTM-ATN-VLEC），用于高速磁浮系统谐波电流信号的预测。该算法模型基于SSA优化VMD，融合带有注意力机制的LSTM，并引入误差修正机制（VLEC）。算法模型的整体架构如图3所示。

图3所示的多智能体组合算法预测的主要步骤分为以下5个部分：

①收集待预测系统的前期历史电流信号，使用SSA-VMD算法对历史数据进行优化分解，得到最优分解值K与最优惩罚因子α。

②使用最优参数对历史数据集进行VMD分解和降噪，得到若干包含不同频率谐波特征的模态分量IMFS，即将复杂、特征多样的电流信号分解为更平稳的子序列，用于后续训练模型。

③为把握时间序列各个节点的相关性，构建神经网络时序预测模型，将分解得到的各个IMF输入搭建

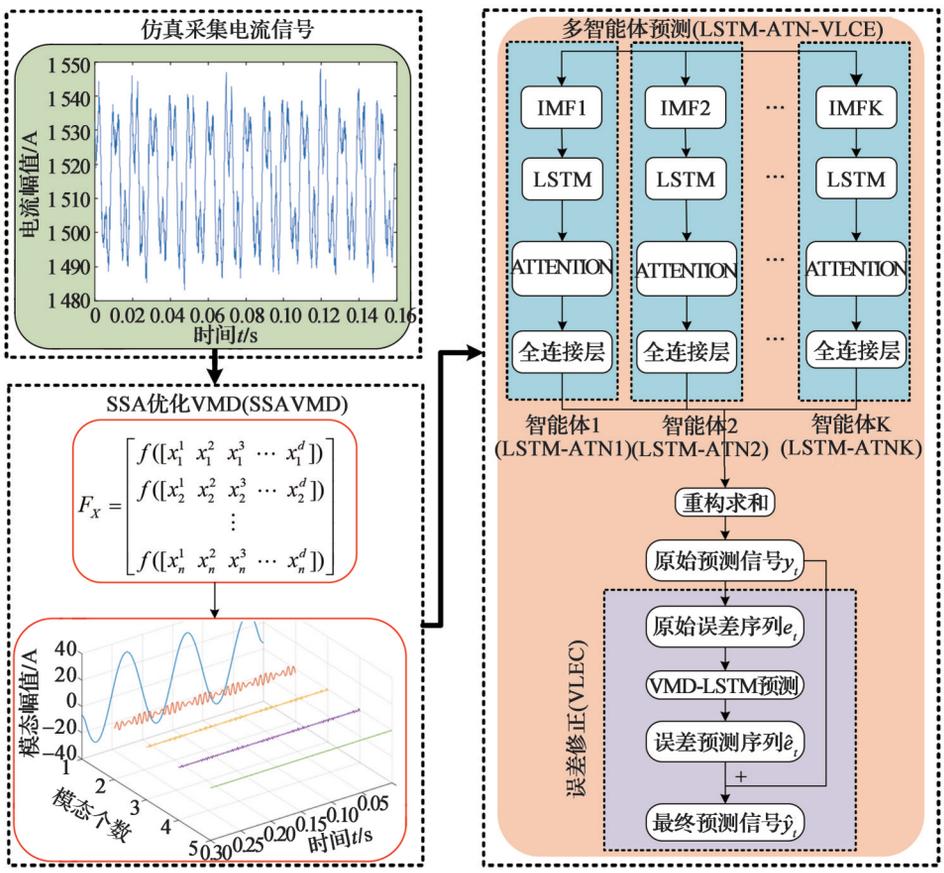


图3　基于SSA优化VMD的多智能体融合LSTM注意力机制算法模型结构

Fig. 3　Multi-agent integrated LSTM-attention mechanism algorithm model structure with VMD optimized on the basis of SSA

好的LSTM-Attention模型中进行训练与预测，形成单个结构为“IMF-LSTM-Attention”的预测智能体，使用Adam算法对网络参数进行优化。

④将各个智能体的预测结果进行重构，得到总的原始预测电流信号y_t，并与真实电流数据y进行比较，计算误差e_t，评估该算法模型的预测效果。

⑤采用误差修正（EC）对原始预测结果进行评估和调整。由于所得到的误差存在较强的非线性与非平稳性，因此先对误差序列e_t进行VMD分解，再通过LSTM进行预测（VLEC），得到误差预测信号$\hat{e}_t$，令其对原始预测信号y_t进行补偿，得到最终预测序列y_t'，评估该算法的预测效果。

3　试验分析与评估

为评估本文提出的SSAVMD-LSTM-ATN-VLEC多智能体算法模型在谐波电流预测方面的优越性，以上海高速磁浮牵引供电系统为例，对其谐波特性进行分析，并基于MATLAB/Simulink对磁浮系统进行建模仿真，采集电网侧的谐波电流，使用本文提出的多智能体组合模型对采集数据进行分析，验证该模型的有效性和可拓展性。

3.1　高速磁浮谐波电流数据来源

在上海高速磁浮牵引供电系统中，谐波电流主要来源于整流器，该系统采用的是等效24脉冲多重整流装置，即由2个双三相半控12脉冲多重整流电路并联连接组成，由于其谐波特性与三相半控12脉波整流电路的谐波特性相似，根据对12脉冲整流器一次侧电流i_a的傅里叶分析可得

$$i_a=\frac{4\sqrt{3}\,I_d}{\pi}\left[\sin\omega t+\frac{1}{n}\sum_{\substack{n=12k\pm1,\\ k=1,2,3,\cdots}}\left[(-1)^k\sin\omega t\right]\right] \tag{7}$$

由式(7)可知，在双三相半控12脉波整流电路中，一次侧电流主要包含$12k\pm1$次的谐波，即高速磁浮网侧电流中应主要含有11, 13, 23, 25, … 等$12k\pm1$奇数次谐波。

根据上述理论，本文基于MATLAB/Simulink建立高速磁悬浮牵引系统模型，三相电源设定35 kV，输出端接阻感负载。对仿真后的谐波电流进行FFT分析可知网侧主要包含11, 13, 23, 25, 35, 37次等高次谐波，设置采样时间为3×10^{-5} s，采样率为33 333 Hz对其进行采样，共得到6 667个数据采样点进行后续分析。

3.2　多智能体融合注意力预测模型分析

采用本文提出的SSAVMD-LSTM-ATN-VLEC多智

能体算法模型对采集到的高速磁浮谐波时序电流进行提前步长的预测处理。首先使用SSA对VMD的分解个数和惩罚因子进行优化，设置种群数量为20，迭代次数为50，最终确定当VMD分解的最优分解个数取7、惩罚因子取309时，VMD分解效果最好。图4为对原始电流数据集进行VMD分解后得到的7个模态分量IMF，以及1组残差序列。

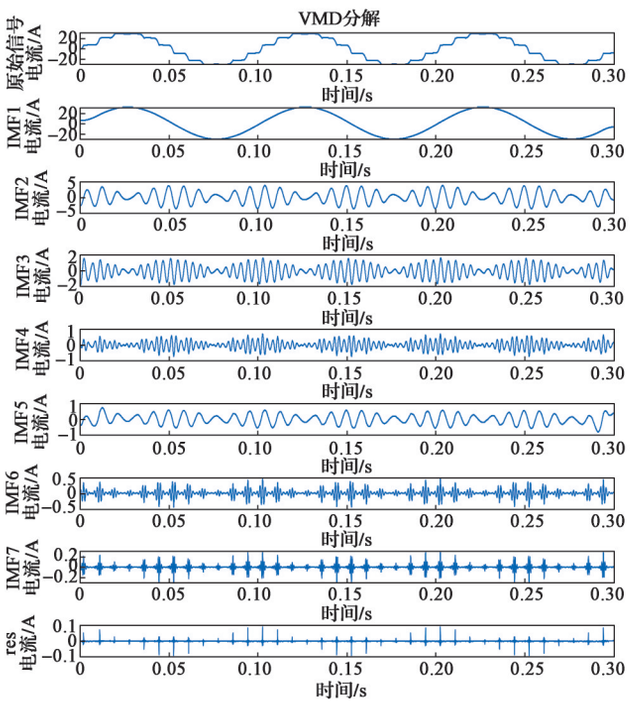


图4 高速磁浮牵引系统网侧电流变分模态分解示意图

Fig. 4 Schematic diagram of grid-side current VMD of high-speed maglev traction system

3.2.1 拟合时滞性与精度分析

为验证本文提出算法模型的预测性能，设定预测窗口为50，预测步长为1，预测结果如图5所示。

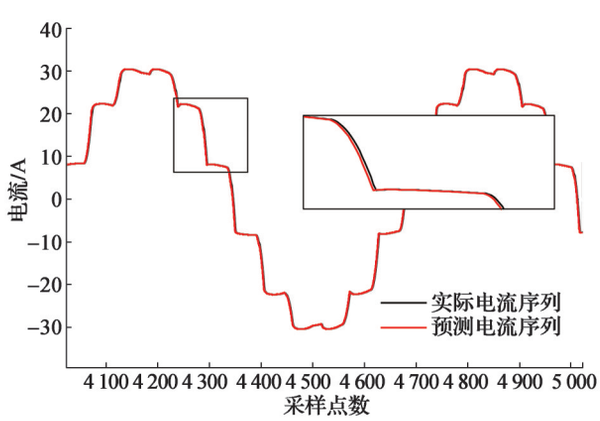
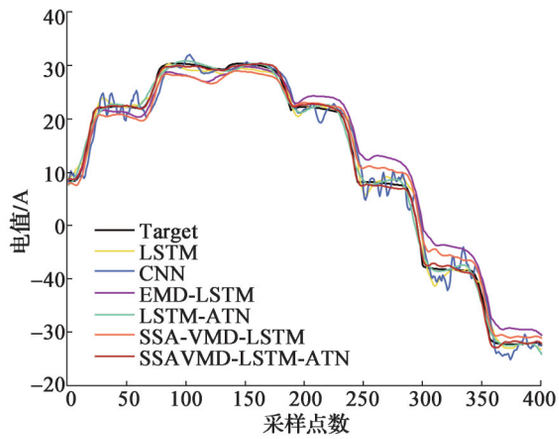


图5 模型预测效果图

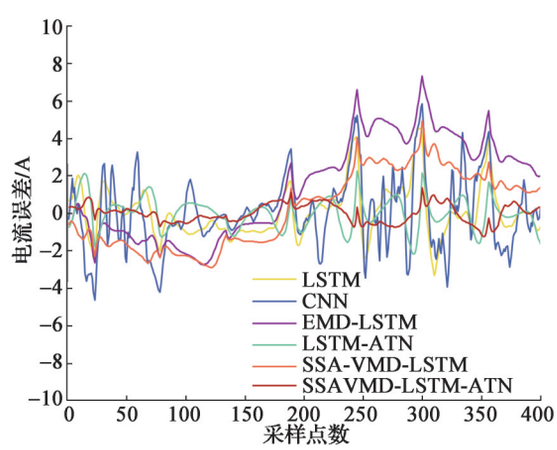
Fig. 5 Model prediction effect diagram

由图5可知，该算法模型实现了提前步长的时序预测，相当于提前1个步长采集到了谐波电流数据，有利于改善后续滤波过程产生的时滞问题。

将SSAVMD-LSTM-ATN的预测结果与2种单一模型（LSTM和CNN）、3种组合模型（EMD-LSTM、LSTM-ATN和SSA-VMD-LSTM）的预测结果进行对比，得到的拟合结果对比和误差对比如图6所示。从图6(a)的拟合结果对比可看出，本文提出模型的预测效果优于其他5种模型，真实还原了谐波电流的变化趋势；由图6(b)的误差对比可知，本文提出模型的误差最小，拟合精度最高。



(b) 各模型预测拟合效果对比图



(a) 各模型预测误差对比图

图6 各模型拟合结果对比与误差对比

Fig. 6 Comparison of model fitting results and errors

3.2.2 误差指标分析

表1给出了6种模型在训练集与预测集上的误差指标。

由表1可知，采用本文设计的算法模型，在测试集上的评估指标RMSE、MAE和MAPE分别为0.452 1，0.377 3，0.093 8%，与其他模型对比，误差最高降低了91.7%，91.1%，98.8%，比单一的LSTM误差降低了66.7%，59.9%，68.0%，比组合的SSA-VMD-LSTM误差降低了62.1%，62.6%，16.7%，比组合的LSTM-ATN误差降低了44.3%，40.7%，51.6%，并且本文设计模型的R^2在训练集和测试集上都达到了最高值0.999 6，这表明模型的拟合效果最好，具有更优的预测精度，符合理论预期结果。

表 1　各个模型在训练集和预测集的误差指标对比

Table 1　Comparison of error indicators of each model in the training set and the prediction set

模型	训练集				测试集			
	RMSE	MAE	MAPE/%	R^2	RMSE	MAE	MAPE/%	R^2
LSTM	1.376 6	0.952 3	0.334 3	0.996 0	1.356 8	0.941 0	0.292 8	0.996 3
CNN	1.870 3	1.360 3	0.226 5	0.992 6	1.893 2	1.377 9	0.254 4	0.992 7
EMD-LSTM	2.019 0	1.550 4	0.091 9	0.991 4	5.441 3	4.253 8	7.957 9	0.938 9
LSTM-ATN	0.830 1	0.652 2	0.015 0	0.998 6	0.811 2	0.636 0	0.194 0	0.998 7
SSA-VMD-LSTM	1.259 6	1.056 9	0.706 3	0.996 7	1.192 1	1.008 9	0.112 6	0.997 1
SSAVMD-LSTM-ATN	0.443 6	0.364 2	0.101 9	0.999 6	0.452 1	0.377 3	0.093 8	0.999 6

注：RMSE—方均根误差；MAE—平均绝对误差；MAPE—平均绝对百分比误差；R^2—决定系数。

3.2.3　相关性分析

为从多维度讨论本文设计模型的预测准确性，引入相关性指标来衡量原始谐波电流序列与预测序列之间的线性关系的强度和方向，本文采用 Pearson 相关系数[22]进行论证。

Pearson 相关系数的取值范围为 [−1, 1]，其中“1”表示完全正相关，“−1”表示完全负相关，“0”表示无相关性。由于数据量较大，将各个模型测试集的每 100 个数据点划分为 1 组，每组延迟 1 个步长取值，每个模型共 1 000 组数据，计算各个模型每组数据与实际值之间 Pearson 相关系数。图 7 给出了各个模型预测值与实际值之间 Pearson 相关系数的箱形图。

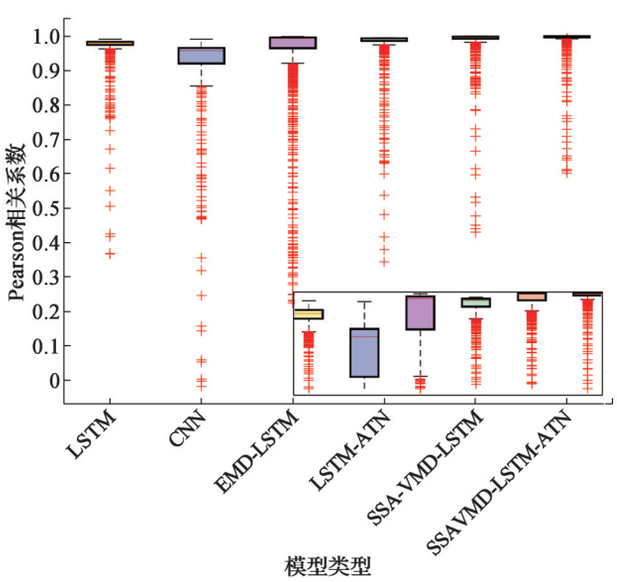


图 7　各个模型预测值与实际值之间的 Pearson 相关系数

Fig. 7　Pearson correlation coefficient between the predicted value of each model and the actual value

由图 7 可知，本文所提出的组合模型 Pearson 相关系数的四分位数都高于其他模型，异常值较少，箱体扁、端线短，这说明数据集中、波动程度小、更接近于数值“1”，与实际谐波电流值的相关性更高。

3.2.4　多次试验分析

为提高验证工作的严谨性，避免单次预测任务产生偶然性，本文使用每种算法模型分别进行 10 次独立预测训练，每次训练的 RMSE 值如图 8 所示。由图 8 可知，在 10 次预测过程中，出现了 8 次本文所提模型的 RMSE 值最低，并且大部分可以降低到 0.5% 以下，对比其他预测模型具有一定的优越性。

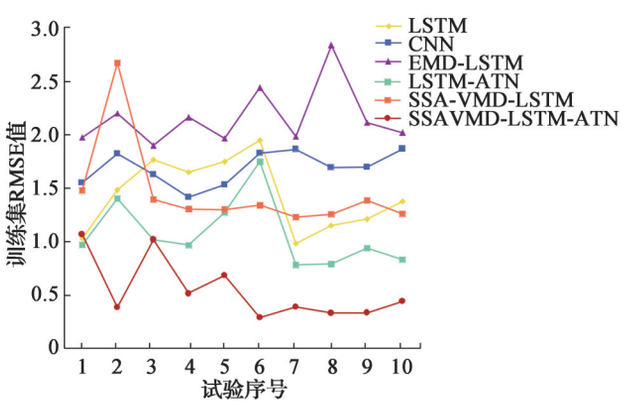


图 8　各个模型独立验证 10 次 RMSE 值对比图

Fig. 8　Comparison of RMSE values for 10 times of independent verification of each model

3.3　误差修正机制

为进一步提高该算法模型进行谐波预测任务时的精确度，在此基础上加入误差修正机制（SSAVMD-LSTM-ATN-VLEC）。由于误差的波动性较强，采用 VMD-LSTM 的组合模型对误差进行二次预测，并将预测得到的误差序列与原始预测序列进行叠加重构，实现误差补偿。修正后的测试集 RMSE、MAE、MAPE 分别可降低为 0.177 7，0.137 8，0.002 2%，相比未进行误差修正的算法，误差分别降低了 60.7%，63.5%，97.65%。图 9 为引入误差修正前后的电流预测拟合效果对比图。由图 9 可知，修正后所得的预测误差更低，拟合效果更好。

综上所述，对于高速磁浮牵引供电系统网侧电流这种波动性较强、谐波成分复杂的时序信号，单一的预测模型并不能满足精度需求，本文设计的多智能体组合算法模型融合了优化算法和注意力机制，使预测精度得到了大幅度提高，并加入误差修正模块，进一步减小了预测误差。同时，采用模型进行提前步长的时序预测，相当于提前采集到谐波电流数据，抵消滤

波器引入的延迟时间，改善时滞性，更有利于下一步谐波补偿工作的进行。

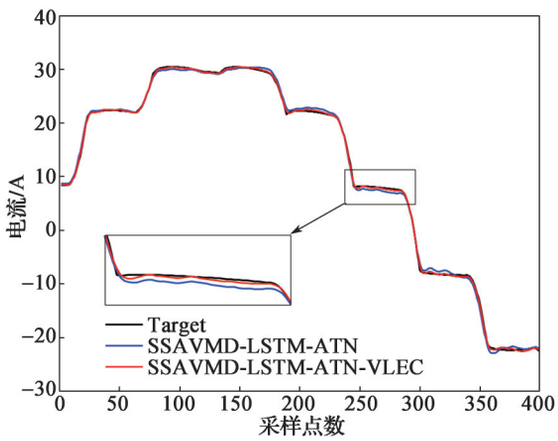


图9　误差修正前后拟合效果对比图

Fig. 9　Comparison of fitting effects before and after error correction

4　结束语

针对现有的高速磁浮谐波电流治理中存在着时滞性与低精度问题，本文对上海高速磁浮牵引供电系统进行建模仿真，采集其谐波电流，并提出一种新的基于SSA优化的融合注意力的多智能体谐波电流预测算法模型。该算法模型在SSA算法优化的基础上，利用变分模态分解将原始电流序列分解为多个LSTM谐波预测分量，并融合注意力机制，形成了多个结构为“IMF-LSTM-Attention”的智能体，得到了良好的预测结果。同时，采用VMD-LSTM模型的误差修正机制对原始预测序列进行误差补偿，进一步提高了预测精度。试验分析和评估结果表明，与其他5种预测模型对比，本文提出的算法模型预测误差更小，相关性更高。该算法模型为谐波补偿与深度学习理论的结合提供了更广阔的研究思路。后续研究将考虑将电流预测与检测、滤波环节相结合，进一步提高谐波的治理效果。

参考文献：

[1] 谭保华, 张文宇, 黄程旭, 等. 基于全相位FFT三谱线校正的电网谐波与间谐波检测算法[J]. 华中师范大学学报(自然科学版), 2021, 55(6): 1044-1050.
TAN Baohua, ZHANG Wenyu, HUANG Chengxu, et al. Harmonic and interharmonic detection algorithm based on all-phase FFT triple spectrum line correction[J]. Journal of central China normal university (natural sciences), 2021, 55 (6): 1044-1050.

[2] CZARNECKI L S. Instantaneous reactive power p-q theory and power properties of three-phase systems[J]. IEEE transactions on power delivery, 2006, 21(1): 362-367.

[3] 周建萍, 郑应平, 王志萍. 基于小波包变换的电力系统谐波分析[J]. 中国电力, 2009, 42(7): 6-9.
ZHOU Jianping, ZHENG Yingping, WANG Zhiping. Harmonic analysis of power system using wavelet packet transform[J]. Electric power, 2009, 42(7): 6-9.

[4] WANG Rongkun, HUANG Wenjie, HU Bingtao, et al. Harmonic detection for active power filter based on two-step improved EEMD[J]. IEEE transactions on instrumentation and measurement, 2022, 71: 1-10.

[5] YUE Qianqian, HU Rui, ZHANG Xiaoling. A power system harmonic problem based on the BP neural network learning algorithm[J]. Computational intelligence and neuroscience, 2022, 2022: 7247881.

[6] LIU Nixuan, FEI Juntao. Adaptive fractional sliding mode control of active power filter based on dual RBF neural networks[J]. IEEE access, 2017, 5: 27590-27598.

[7] KUYUMANI E M, HASAN A N, SHONGWE T. A hybrid model based on CNN-LSTM to detect and forecast harmonics: a case study of an Eskom substation in South Africa[J]. Electric power components and systems, 2023, 51(8): 746-760.

[8] ZHOU J Z, RAJAPAKSE A, GOLE A M. Effects of control systems time delay on the performance of direct harmonics elimination (power network active filters)[C]//IEEE. Canadian Conference on Electrical and Computer Engineering 2004. Niagara Falls: IEEE, 2004: 609-612.

[9] LE ROUX W, VAN WYK J D. The effect of signal measurement and processing delay on the compensation of harmonics by PWM converters[J]. IEEE transactions on industrial electronics, 2000, 47(2): 297-304.

[10] 李圣清, 罗晓东, 李永安, 等. 基于前向线性预测理论的混合电力滤波器谐波电流预测方法[J]. 中国电机工程学报, 2011, 31(34): 100-104.
LI Shengqing, LUO Xiaodong, LI Yongan, et al. A harmonic current forecasting method for hybrid active power filters based on the forward linear prediction theory[J]. Proceedings of the CSEE, 2011, 31(34): 100-104.

[11] MARKS J H, GREEN T C. Predictive transient-following control of shunt and series active power filters[J]. IEEE transactions on power electronics, 2002, 17(4): 574-584.

[12] 翟晓寒, 丁惜瀛, 姚润宇, 等. 基于径向基神经网络的UPQC并联侧谐波电流预测与补偿[J]. 电测与仪表, 2021, 58(8): 139-145.
ZHAI Xiaohan, DING Xiying, YAO Runyu, et al. Prediction and compensation of harmonic current in parallel side of unified power quality controller based on radial basis neural network[J]. Electrical measurement & instrumentation, 2021, 58(8): 139-145.

[13] ZHOU Min, WANG Bo, GUO Shudong, et al. Multi-objective prediction intervals for wind power forecast based on deep neural networks[J]. Information sciences, 2021, 550: 207-220.

[14] HAN Li, ZHANG Rongchang, WANG Xuesong, et al. Multi-step wind power forecast based on VMD-LSTM[J]. IET renewable power generation, 2019, 13(10): 1690-1700.

[15] 刘杰, 金勇杰, 田明. 基于VMD和TCN的多尺度短期电力负荷预测[J]. 电子科技大学学报, 2022, 51(4): 550-557.
LIU Jie, JIN Yongjie, TIAN Ming. Multi-scale short-term load forecasting based on VMD and TCN[J]. Journal of university of electronic science and technology of China, 2022, 51(4): 550-557.

[16] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems science & control engineering, 2020, 8(1): 22-34.

[17] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE transactions on signal processing, 2014, 62(3): 531-544.

[18] ZHONG Jun, BI Xiaowen, SHU Qin, et al. Partial discharge signal denoising based on singular value decomposition and empirical wavelet transform[J]. IEEE transactions on instrumentation and measurement, 2020, 69(11): 8866-8873.

[19] 姜飞, 林政阳, 王文烨, 等. 考虑最小平均包络熵负荷分解的最优Bagging集成超短期多元负荷预测[J/OL]. 中国电机工程学报: 1-17. (2023-04-27) [2023-08-22]. https://doi.org/10.13334/j.0258-8013.pcsee.223470.
JIANG Fei, LIN Zhengyang, WANG Wenye, et al. Optimal bagging ensemble ultra short term multi-energy load forecasting considering least average envelope entropy load decomposition[J/OL]. Proceedings of the CSEE: 1-17. (2023-04-27) [2023-08-22]. https://doi. org/10.13334/j. 0258-8013. pcsee.223470.

[20] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.

[21] 陈海涵, 吴国栋, 李景霞, 等. 基于注意力机制的深度学习推荐研究进展[J]. 计算机工程与科学, 2021, 43(2): 370-380.
CHEN Haihan, WU Guodong, LI Jingxia, et al. Research advances on deep learning recommendation based on attention mechanism[J]. Computer engineering and science, 2021, 43 (2): 370-380.

[22] LIAO Wenlong, YANG Zhe, CHEN Xinxin, et al. Wind-GMMN: scenario forecasting for wind power using generative moment matching networks[J]. IEEE transactions on artificial intelligence, 2022, 3(5): 843-850.

收稿日期：2023-07-12
修回日期：2023-08-25