

# 融合序列分解与时空卷积的时序预测算法

金苍宏<sup>1</sup>,董腾然<sup>1</sup>,陈天翼<sup>1</sup>,吴明晖<sup>1</sup>,李国军<sup>2</sup>,周胜利<sup>2</sup>

(1. 浙大城市学院,浙江杭州 310015; 2. 浙江警察学院,浙江杭州 310053)

**摘要:** 现有深度学习方法在对时间序列预测时,未充分考虑空间依赖性,且长期预测的准确率也较低. 针对此问题,提出一种融合时间序列分解策略和时空卷积神经网络的时序预测模型 SDBRNN (Series-Decomposition-Block Recurrent Neural Network). 该模型首先学习序列的多周期值并对序列进行最优 STL 分解;然后结合相邻观察点构造兼具时空数据块;再采用 Block-LSTM 中的三维卷积模块对时空数据块进行特征提取,让三维块在 LSTM 细胞中参与状态更新和反向传播,最终实现模型对时空特征的学习. 结合多个时空序列测试数据分析,表明该模型在具有空间依赖关系的时序数据集上,比传统的时间卷积模型和循环神经网络具有更好的时空特征提取能力和拟合预测能力,验证了该模型的有效性.

**关键词:** 时间序列预测; 序列分解; 时空卷积

**中图分类号:** TP181

**文献标识码:** A

**文章编号:** 0372-2112 (2021)02-0233-06

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20200738

## Spatio-Temporal Convolutional Forecasting Based on Time-Series Decomposition Strategy

JIN Cang-hong<sup>1</sup>, DONG Teng-ran<sup>1</sup>, CHEN Tian-yi<sup>1</sup>, WU Ming-hui<sup>1</sup>, LI Guo-jun<sup>2</sup>, ZHOU Sheng-li<sup>2</sup>

(1. Zhejiang University City College, Hangzhou, Zhejiang 310015, China;

2. Zhejiang Police College, Hangzhou, Zhejiang 310053, China)

**Abstract:** There are various deep learning methods already implemented in time-series forecasting problems, and some of them show better performance and adaptability than the methods based on statistics. However, the spatial dependence implicit in multiple series usually is not considered within the existing time-series forecasting methods, which also results in unsatisfactory performance in long-term forecasting. Thus, we propose a model series-decomposition-block recurrent neural network (SDBRNN), which fuses time-series decomposition strategy and the spatio-temporal convolutional layer. This model relies on an improved STL decomposition strategy to get optimal series-components and to combine them into spatio-temporal blocks. Then an long-short term memory (LSTM) variant network called Block-LSTM is used to extract spatio-temporal features from blocks and achieve forecasting. Experiments on real-world datasets proved that the model has excellent capabilities of feature extraction and long-term forecasting compared with other methods such as temporal convolutional network and recurrent neural network.

**Key words:** time-series forecasting; series decomposition; spatio-temporal convolutional

## 1 引言

时间序列数据被用于描述事物随时间发展变化的特征,研究时间序列能从中认识事物历史发展的模式,可根据序列的均值、方差、协方差等特征分为平稳时间序列和非平稳时间序列,并以此来预测事物未来的变化趋势<sup>[1]</sup>,如股票价格波动、道路车流量预测、用户行为分析等<sup>[2]</sup>.

传统的时间序列预测方法,有支持向量机、决策树等机器学习算法<sup>[3,4]</sup>. 同时,近年来出现多种神经网络应用

在时间序列预测上的模型. 包括利用循环神经网络 RNN (Recurrent Neural Network) 将序列的时间特征引入到了神经网络内部,在去趋势化的时间序列数据上进行预测<sup>[5]</sup>. 长短期记忆网络 LSTM (Long-Short Term Memory) 改进了 RNN 存在的梯度消失问题,并利用门机制帮助序列对长期依赖的特征具有记忆功能<sup>[6]</sup>. 另一方面,虽然卷积网络受限于卷积核大小不能像 RNN 结构一样先天适合抓取时序特征,但通过合理的结构设计却让它在时序预测上取得很好效果. 如时域卷积网络 TCN (Temporal Con-

收稿日期:2020-07-16;修回日期:2021-01-02;责任编辑:李勇锋

基金项目:浙江省自然科学基金(No. LY21F020003);浙江省公益技术研究计划(No. LGF20G030001);浙江省重点研发项目(No. 2021C01164, No. 2021C02060)

volutional Network) 不仅比 LSTM 训练得更快, 抓取局部时域特征的能力也更强<sup>[7]</sup>. 此外, 卷积网络也能适应更复杂的时间序列形式, 如 WaveNet 模型<sup>[8]</sup> 被用于语音合成的声学模型建模中, ConvLSTM 用于雷达天气图像<sup>[9]</sup>, G-MAN 用图注意力来表示序列空间关系进行交通流预测<sup>[10]</sup>. 上述方法, 都是利用序列原始数据进行预测, 文献<sup>[11]</sup> 则利用序列分解方法, 将时间序列分解为趋势成分、季节性成分和随机成分后组合并进行预测来提高预测效果. 可用序列分解方法还有 STL (Seasonal and Trend decomposition using LOESS) 分解<sup>[12]</sup> 和小波分解<sup>[13]</sup> 等.

虽然神经网络在时间序列预测上, 尤其在具有空间依赖关系的多观测点序列预测中<sup>[14]</sup> 有良好表现<sup>[15,16]</sup>, 但对于将时序分解、时空依赖和神经网络相结合的研究较少. 为此, 本文提出了一种融合序列分解策略和三维时序卷积的神经网络模型 SDBRNN (Series-Decompose-Block RNN). 本模型首先基于 STL 分解策略, 将一维时序数据进行时序分解, 并拼接成为一个三维数据块, 再利用三维

卷积模型提取数据块的高维时空特征, 最后利用 LSTM 模块对高维特征进行反向传播学习. 针对原有 STL 分解中周期不确定的问题<sup>[16]</sup>, 提出了基于趋势季节性分解的改进算法; 时序块构造时, 根据相关性进行成分组合, 以使三维卷积模块可以更好的提取时空特征; 同时, 三维卷积块是内嵌于 LSTM 细胞内部的模块, 代替 LSTM 的门更新操作, 使 LSTM 可以带着数据的时空特征进行学习. SDBRNN 把一维的时序特征扩展成兼具时间和空间依赖的三维特征. 结合 5 种数据集实验, 证明了时序块构造的合理性和模型的有效性.

## 2 SDBRNN 模型

一种融合序列分解策略和三维时序卷积的神经网络模型 SDBRNN 结构如图 1 所示, 可分成两个模块, 分别是基于分解策略的时序块构造模块和时空融合预测模块, 其中时空融合预测模块包括了三维卷积模块和 Block-LSTM 模块.

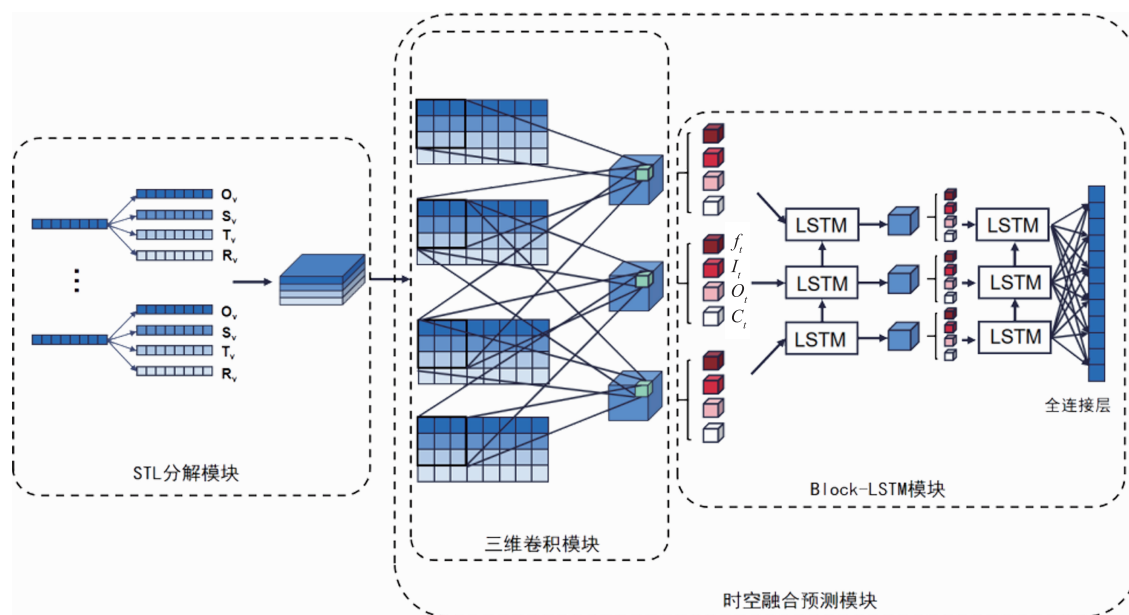


图1 SDBRNN网络结构

### 2.1 时序块构造

将时间序列中的特征进行分解组合构成时序块, 并根据观察点的顺序对不同序列进行拼接, 形成兼具时序特征的三维数据.

时序块构造可分为 STL (Seasonal and Trend decomposition using LOESS) 分解阶段和分量重组阶段, 其中 LOESS 为局部加权回归. STL 分解是一种以鲁棒加权回归作为平滑方法的时序分解算法, 它将序列认为是趋势分量  $T$ 、季节性分量  $S$  和残差分量  $R$  的累加. 其分解具体操作包括六个步骤: 去趋势、周期子序列平滑、周期子序列低通滤波、去平滑周期子序列趋势、去季节

性和趋势平滑、残差成分计算.

在 STL 分解阶段中, 对于原始一维输入序列需要先确定其周期  $P$ . 为了使周期  $P$  取值最合理化, 首先输入备选周期  $P_i (i=1, 2, \dots)$ , 对原始序列分别做不同周期的 STL 分解, 得到  $T_i, S_i, R_i$  与它们的和  $O_i (i=1, 2, \dots)$ , 对  $O_i$  分别与原始序列  $O$  计算 DTW 距离  $d_i$ , 本方法中取  $d_i$  最小的周期参数  $P_k (k=1, 2, \dots)$ , 作为 STL 分解参数, 得到  $T, S$  和  $R$ , 可表示为

$$O = T + S + R \quad (1)$$

不同于已有的方法对分量进行独立的预测学习<sup>[12,13]</sup>, 本模型在分量重组阶段中, 对 STL 分解得到的

三个分量与原始序列本身共四个等长序列,构建出一个二维矩阵  $M_{N \times h} = [O, T, S, R]$ , 其中,  $N$  为单个序列长度,  $h$  表示 4 个分量.

显然,对 4 个分量的组合顺序会影响形成的二维矩阵值,根据卷积运算的特性<sup>[14]</sup>,对于上述给定的  $M_{N \times h}$ ,位于矩阵中间的行向量  $T$  和  $S$ ,将会比位于边缘的行向量  $O$  和  $R$  多参与一次卷积计算.则将重要程度高的分量置于中间位置,卷积运算将会提取更好的特征.不同排序方法的预测效果将在本文实验部分给出实验证明.最后将不同观测点的二维矩阵进行拼接,得到兼具时间和空间特征的三维时序块.

#### 算法 1 时序块构造算法

输入:  $m$  个长度为  $N$  原始序列  $O_i (i=1, 2, \dots, m)$ , 备选周期  $P_j (j=1, 2, \dots)$

输出:  $N \times m \times h$  的时序块

1. 分别依据不同  $P_j$  进行 STL 分解、计算 DTW 距离,得出最优分解周期;
2. 计算  $O, T, S, R$  两两之间相关性累加和,按相关度进行排序得到二维矩阵  $M_{N \times h}$ ;
3. 不同观测点所得二维矩阵拼接得到三维数据块.

## 2.2 时空融合卷积网络

定义时空融合卷积网络 3DConv-LSTM, 包括三维卷积模块和 LSTM 模块. (1) 三维卷积模块:通过对时序块进行三维卷积操作提取高维特征,代替了 LSTM 的门更新的操作;(2) LSTM 模块:将三维卷积模块的输出作为 LSTM 模块的输入.

LSTM 其核心部分为传输在每个 LSTM 细胞中的细胞状态  $C_t$ , 而细胞状态  $C_t$  又由三个门控机制来决定,分别是遗忘门  $f_t$ 、输入门  $I_t$  和输出门  $O_t$ .

本文提出 Block-LSTM 模块,它与“卷积层 + LSTM”网络不同,Block-LSTM 的三维卷积运算在 LSTM 细胞内部底层实现,并代替了 LSTM 的门更新和细胞更新操作. Block-LSTM 不仅能像 CNN 网络一样,利用多序列之间的相关性提取空间特征,还能利用 LSTM 建立序列间的时序关系.




图2 SDBRNN细胞结构

如图 2 的三维卷积模块所示,当三维卷积核在时序块上滑动并与时序块上的像素点进行卷积运算,得到高阶三维特征块,对特征块进行均匀分割得到四个

小特征块,作为 LSTM 细胞的遗忘门  $f_t$ 、输入门  $I_t$ 、输出门  $O_t$  和候选细胞  $C_t$ . 其中,输入门  $I_t$  与上一时刻的隐藏层信息  $h_{t-1}$  拼接,并使用 *sigmoid* 激活;遗忘门  $f_t$  与  $h_{t-1}$  拼接和 *sigmoid* 激活函数激活;候选细胞  $C_t$  与  $h_{t-1}$  拼接使用 *tanh* 激活函数激活;新的细胞状态  $C_t$  为  $\tilde{C}_t$  与  $I_t$  的乘积和  $f_t$  与前一细胞状态  $C_{t-1}$  之和. SDBRNN 的细胞工作方式如式(2)所示,其中 \* 代表卷积操作.

$$\begin{cases} f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \\ I_t = \sigma(W_f * [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \\ C_t = f_t \cdot C_{t-1} + I_t \cdot \tilde{C}_t \\ O_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \end{cases} \quad (2)$$

## 3 实验与分析

### 3.1 数据集描述

本文采用 5 个多观测点真实序列数据集,它们的训练集和测试集维度如表 1 所示.

表 1 数据集概述

数据集	训练集维度	测试集维度
PeMS-Bay	[1450 × 288 × 1 × 4 × 30]	[450 × 288 × 1 × 4 × 30]
Seattle	[1100 × 288 × 1 × 4 × 30]	[300 × 288 × 1 × 4 × 30]
Solar	[675 × 80 × 1 × 4 × 100]	[237 × 80 × 1 × 4 × 30]
Roasting	[2448 × 60 × 1 × 4 × 3]	[1008 × 60 × 1 × 4 × 3]
TRD-Dalry	[354 × 60 × 1 × 4 × 12]	[111 × 60 × 1 × 4 × 12]

使用  $k$  折交叉检验 ( $k$ -folds cross validation) 做交叉检验计算,其中  $k = 10$ .

### 3.2 基准方法和参数设置

本实验主要比较各类经典神经网络预测模型<sup>[1,17]</sup>: LSTM<sup>[6]</sup>, GRU<sup>[18]</sup>, WaveNet<sup>[8]</sup>, TCN<sup>[7]</sup>, ConvLSTM<sup>[9]</sup>. 对比算法涉及到的参数都使用相应文献的建议或者采用交叉验证进行参数调优,受篇幅所限在此不予赘述.

### 3.3 参数设置

本文提出的模型参数配置如表 2 所示.

表 2 模型参数

网络层数	3	卷积核	3 × 3 × 3
卷积 stride	1 × 1 × 1	卷积 padding	1 × 1 × 1
学习率	1e-4	学习衰减率	0.9
批尺寸	8	训练轮数	100
第一层卷积(输入,输出)	(16, 64)		
第二层卷积(输入,输出)	(32, 64)		

### 3.4 实验评价和结果分析

本文选用 3 个预测评价指标,分别为 RMSE、MAE 和 MAPE. 对于每个算法,我们在所有数据集上进行了 10 次 5 折交叉验证.

#### 3.4.1 模块组合策略影响分析

在构造时序块时,为了研究原始序列  $O_t$ 、趋势成分

$T$ 、季节性成分  $S$  和残差成分  $R$  的不同组合方式对预测精度的影响,构造了 4 个不同组合顺序,分别为:OTSR、SOTR、OTRS 和 TORS. 对四种不同的组合方式的时序块在 PeMS-Bay 数据集上进行训练,其中,每次训练模型结构、超参数相同,预测步长为 12. 结果如表 3 所示.

预测效果最好的组合为 OTSR, MAPE 值为 2.54%,比效果最差的组合 OTRS 低 1.84%,比次优的组合 SOTR 低 1.21%,效果差异明显. 相关性越高,即越重要的序列成分置于时序块的中间位置,以让卷积模

块对它们进行多次卷积运算,可以更好的提取时序特征并达到最佳的预测效果.

表 3 不同组合时序块预测效果

	RMSE	MAE	MAPE
OTSR	7.20	1.67	2.54%
SOTR	9.76	2.39	3.76%
OTRS	11.31	2.78	4.38%
TORS	10.60	2.60	4.11%

表 4 5 类数据集上的预测结果

		3 时间片			6 时间片			12 时间片		
		RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
PeMS-Bay	LSTM	5.08	2.69	6.46%	6.31	2.77	6.91%	7.27	3.20	8.42%
	GRU	4.99	2.73	6.38%	6.22	2.54	6.57%	7.01	2.92	8.75%
	WaveNet	8.92	5.35	13.11%	8.91	5.30	13.18%	8.76	5.24	12.63%
	TCN	<b>2.32</b>	<b>1.45</b>	<b>2.94%</b>	6.85	2.62	4.38%	7.84	2.00	4.31%
	ConvLSTM	5.68	2.43	3.71%	7.31	2.41	34.71%	15.47	3.24	5.02%
	SDBRNN	4.40	3.40	5.50%	<b>5.85</b>	<b>2.21</b>	<b>3.47%</b>	<b>7.20</b>	<b>1.67</b>	<b>2.54%</b>
Seattle	LSTM	4.27	2.74	<b>5.37%</b>	4.53	2.96	5.84%	4.84	3.19	6.33%
	GRU	<b>3.99</b>	<b>2.60</b>	5.40%	4.29	2.81	5.89%	5.12	3.26	7.12%
	WaveNet	8.44	6.04	12.76%	9.76	7.53	15.00%	11.97	7.66	15.40%
	TCN	4.02	2.60	4.97%	4.10	2.73	5.12%	4.51	2.96	5.75%
	ConvLSTM	7.58	3.48	5.65%	8.96	3.07	5.00%	16.95	3.64	6.19%
	SDBRNN	4.61	3.53	6.59%	<b>4.02</b>	<b>2.83</b>	<b>4.60%</b>	<b>4.51</b>	<b>2.91</b>	<b>4.70%</b>
Solar	LSTM	5.93	4.05	19.00%	5.77	4.08	18.65%	6.64	4.25	19.41%
	GRU	<b>5.07</b>	<b>3.73</b>	<b>19.02%</b>	<b>5.38</b>	<b>3.96</b>	<b>18.51%</b>	<b>6.19</b>	<b>4.42</b>	<b>18.13%</b>
	WaveNet	16.54	12.72	45.90%	16.60	12.77	45.80%	16.67	12.76	45.67%
	TCN	7.72	4.44	21.99%	7.86	4.57	22.87%	8.08	4.72	23.32%
	ConvLSTM	7.60	5.34	30.28%	6.79	4.84	25.91%	7.26	5.24	27.50%
	SDBRNN	7.19	5.11	37.74%	7.28	5.28	39.74%	7.38	5.38	40.44%
Roasting	LSTM	32.84	25.42	10.5%	40.10	27.60	10.43%	36.73	27.08	10.42%
	GRU	31.16	24.33	9.58%	38.03	26.15	10.40%	37.23	28.41	10.66%
	WaveNet	34.18	25.57	12.74%	33.05	25.04	11.96%	33.16	25.05	11.64%
	TCN	<b>28.24</b>	<b>21.25</b>	<b>9.07%</b>	30.35	24.79	10.21%	31.20	23.54	10.76%
	ConvLSTM	39.70	35.43	13.51%	32.93	28.71	11.29%	36.84	24.84	10.30%
	SDBRNN	30.87	24.71	9.90%	<b>30.23</b>	<b>22.48</b>	<b>9.91%</b>	<b>30.17</b>	<b>23.43</b>	<b>9.21%</b>
TRD_Dalry	LSTM	2.85	2.22	<b>6.03%</b>	2.97	2.31	7.25%	3.10	2.43	6.68%
	GRU	2.55	2.42	6.71%	2.77	2.48	7.35%	3.52	3.17	7.03%
	WaveNet	16.78	14.66	65.17%	16.96	11.47	65.29%	17.09	14.82	65.38%
	TCN	<b>2.59</b>	<b>1.97</b>	6.30%	<b>2.69</b>	<b>2.05</b>	<b>6.61%</b>	<b>2.83</b>	<b>2.18</b>	7.17%
	ConvLSTM	5.69	3.21	12.60%	4.43	2.59	10.37%	2.85	1.64	7.14%
	SDBRNN	5.59	3.77	19.84%	7.53	4.70	22.11%	8.07	4.95	22.74%

### 3.4.2 数据趋势和相关性分析

选择 3 个不同类别的预测数据集 PeMS-Bay, Roasting 和 TRD\_Dalyr. 首先,使用皮尔逊相关系数计算不同观测点之间的相关性,生成热力图如图 3~5 所示.




图3 PeMS-Bay数据集




图4 Roasting数据集




图5 TRD\_Dalyr数据集

热力图中,颜色越深的区域代表序列之间的相关性越高.如图 3 至图 5 所示,PeMS-Bay 和 Roasting 数据集的序列间相关度较高,而 TRD-Dalyr 数据集的序列间不具有明显关系.同时,对多观测点序列的分布显示,Roasting 传感器之间的温度同步性较好;PeMS-Bay 的车速趋势性一致,但是速度有差异;而 TRD 股票之间的趋势和数值差异都较大.结合表 4 的预测效果,SDBRNN 在 PeMS-Bay、Seattle 和 Roasting 数据集的长期预测表现都是最优的,而在 TRD-Dalyr 股票数据集的效果不如 LSTM、GRU 和 TCN 等单序列的预测模型.因此,我们得出结论:SDBRNN 模型更适用于不同观测点在现实逻辑上有关联,相关性较强的数据集.对于多序列之间相关性低,差异性大,趋势不一致的则不适合时空同步的卷积.

## 4 结束语

本文针对当前序列预测方法在长期预测能力和多观测点序列融合上的不足之处,提出了一种基于 STL

分解策略和三维时空卷积的 SDBRNN 模型.模型基于 STL 分解,并根据它们的相关度进行组合,融合时空特征.基于三维卷积,将时空特征从底层嵌入 LSTM 细胞内部的门控机制中,使 LSTM 的细胞在反向传播时,对时空依赖关系进行信息的保留、丢弃,提升预测效果.实验证明 SDBRNN 模型在趋势相似、空间依赖较强的多序列数据集中效果较其他神经网络模型更好.


下一步工作包括对序列分解的方法和特征排列组合做研究,进一步增加特征表达的精确度和代表性.此外,优化三维卷积核的形状大小,并融合其它序列预测的方法如空洞神经网络,考虑把推理神经网络以及异构网络等引入到本课题中,改进当前算法,获得更佳的预测效果.

## 参考文献

- [1] FILDES R. Forecasting, structural time series models and the Kalman filter; Bayesian forecasting and dynamic models[J]. Journal of the Operational Research Society, 1991, 14(1): 554 - 555.
- [2] DICKEY DAVID. Time series theory and methods[J]. Technometrics, 1989, 31(1): 121 - 121.
- [3] GUO Z, WANG H, LIU Q. Financial time series forecasting using LPP and SVM optimized by PSO[J]. Soft Computing, 2012, 17(5): 805 - 818.
- [4] GUO W, RAGE U K, Ninomiya S. Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model[J]. Computers & Electronics in Agriculture, 2013, 96: 58 - 66.
- [5] KAUSHIK P, YADAV P, AKHTER S. De-seasoning-based time series data forecasting method using recurrent neural network (RNN) and tensor flow[J]. IEEE ICSC, 2019, 13(6): 978 - 981.
- [6] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735 - 1780.
- [7] WAN R, MEI S, WANG J, et al. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting[J]. Electronics, 2019, 8(8): 876 - 871.
- [8] OORD A V D, DIELEMAN S, ZEN H, et al. WaveNet: a generative model for raw audio[J]. arXiv Preprint, 2016, arXiv: 1609.03499.
- [9] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[J]. Computer Science, 2015, 10(4): 42 - 47.
- [10] ZHENG C, FAN X, WANG C, et al. GMAN: A graph multi-attention network for traffic prediction[A]. Proceedings of the AAAI Conference on Artificial Intelligence[C]. Hawaii: AAAI, 2019, 34(1): 1234 - 1241.

- [11] HIGUCHI T. Frequency domain characteristics of linear operator to decompose a time series into the multi-components[J]. Annals of the Institute of Statistical Mathematics, 1991, 43(3): 469–492.
- [12] LI Y, BAO T, GONG J, et al. The prediction of dam displacement time series using STL, extra-trees, and stacked LSTM neural network[J]. IEEE Access, 2020, PP(99): 1–1.
- [13] POUR, MASOUD. Determining surface roughness of machining process types using a hybrid algorithm based on time series analysis and wavelet transform [J]. International Journal of Advanced Manufacturing Technology, 2018, 12(7): 11–18.
- [14] DUMOULIN V, VISIN F. A guide to convolution arithmetic for deep learning [J]. arXiv Preprint, 2016, arXiv: 1603.07285.
- [15] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [A]. Twenty-Seventh International Joint Conference on Artificial Intelligence IJCAI-18 [C]. Stockholm: IJCAI, 2018. 429–438.
- [16] CLEVELAND R B, CLEVELAND W S, MCRAE J E, et al. STL: A seasonal-trend decomposition procedure based on loess [J]. Journal of Official Statistics, 1990, 6(1): 3–33.
- [17] CRISTINA G, HERNANDO O, RAINER V S. Time-dependent dual-frequency coherence in multivariate non-stationary time series [J]. Journal of Time, 2019, 40(1): 3–22.
- [18] XU Z, SHEN F, ZHAO J, et al. Time series forecasting using GRU neural network with multi-lag after decomposition [A]. International Conference on Neural Information Processing [C]. Guangzhou: ICONIP, 2017. 523–532.

#### 作者简介




**金苍宏** 男, 1982 年 10 月出生, 浙江绍兴. 副教授. 2015 年毕业于浙江大学计算机学院获得博士学位. 主要从事大数据框架、时空数据挖掘和人工智能行业应用研究.

E-mail: jinch@zucc.edu.cn



**董腾然** 男, 1999 年 1 月出生, 浙江宁波人. 浙大城市学院计算机与计算科学专业本科生, 主要研究方向为数据挖掘、人工智能.

E-mail: dongtr@foxmail.com



**陈天翼** 男, 1998 年 12 月出生, 浙江宁波人. 浙大城市学院计算机与计算科学学院本科生, 主要研究方向为数据挖掘、时间序列.

E-mail: 31701007@stu.zucc.edu.cn



**吴明晖** 男, 1976 年出生于江西景德镇, 教授、硕士生导师. 2012 年获得浙江大学计算机科学与技术博士学位, 主要研究方向为移动互联网和人工智能教学与应用.

E-mail: mhwu@zucc.edu.cn



**周胜利 (通讯作者)** 男, 1982 年生. 计算机科学与技术博士, 浙江警察学院高级工程师, 硕士生导师. 主要研究方向为网络安全、机器学习.

E-mail: 76933768@qq.com