面向密闭空间内外温度的时序预测模型

周俊炎[1]，王竟成[1]，舒畅[1]，黄伦[1]，张志豪[1]，张凯[2]

（1.西南技术工程研究所，重庆 400039；
2.甘肃敦煌大气环境材料腐蚀国家野外科学观测研究站，甘肃 敦煌 736202）

摘要：目的 研究密闭空间条件下已知外部温度时间序列对内部实时温度的预测推理问题。**方法** 选取密闭空间内外温度时序预测典型场景，抽象为多变量时间序列预测问题，分析变量间的关联性和依赖性。借鉴特征融合、注意力机制、多任务模型等思路，结合物理机制与数据特征，基于长短期记忆网络基本网络单元，构建密闭空间内外温度时序预测模型，并在万宁、敦煌、漠河对某型密闭空间进行数据采样，基于三地数据集进行不同模型试验。**结果** 多变量模型比单变量模型具有更好性能，注意力机制对该场景没有显著性能提升，结合物理机制的模型结构设计充分考虑了变量之间的关联性和依赖性，能显著提升预测精度，双输入双输出的多变量时序预测模型具有相对最高的精度和最稳定的鲁棒性，是面向密闭空间内外温度时序预测的相对最优模型。**结论** 研究结论可指导密闭空间其他环境特征建模，研究思路可为其他多变量时序建模问题中变量之间的关联性、依赖性分析提供参考。

关键词：密闭空间；内外温度；时序预测；物理机制；多变量时间序列；长短期记忆网络
中图分类号：TP391 **文献标识码：**A **文章编号：**1672-9242(2023)11-0166-11
DOI：10.7643/ issn.1672-9242.2023.11.021

Time Series Prediction Model for Internal and External Temperature of Confined Space

ZHOU Jun-yan[1], *WANG Jing-cheng*[1], *SHU Chang*[1], *HUANG Lun*[1], *ZHANG Zhi-hao*[1], *ZHANG Kai*[2]

(1. Southwest Institute of Technology and Engineering, Chongqing 400039, China; 2. Dunhuang Atmospheric Material Corrosion Field National Observation and Research Station, Gansu Dunhuang 736202, China)

ABSTRACT: Research on the prediction and inference problem of known external temperature time series for internal real-time temperature under confined space conditions. Typical scenarios of internal and external temperature time series prediction in confined spacewere selected, which was abstracted as a multi-variable time series prediction problem, and the correlation and dependence analysis among variables were the key difficulties. By referring to the ideas of feature fusion, attention mechanism and multi-task model, combined with the physical mechanism and data characteristics, and based on the basic network unit of long and short term memory network, the internal and external temperature time series prediction model of confined space was constructed. The data of a certain type of confined space was collected in Wanning, Dunhuang and Mohe, and different model experiments were carried out based on the data sets of the three places. The multi-variable model had better performance than the univariable model, and the attention mechanism did not significantly improve the performance of this scenario. The model structure design combined with the physical mechanism fully considered the correlation and dependence between variables,

收稿日期：2023-02-15；**修订日期：**2023-05-10
Received：2023-02-15；**Revised：**2023-05-10
引文格式：周俊炎，王竟成，舒畅，等. 面向密闭空间内外温度的时序预测模型[J]. 装备环境工程, 2023, 20(11): 166-176.
ZHOU Jun-yan, WANG Jing-cheng, SHU Chang, et al. Time Series Prediction Model for Internal and External Temperature of Confined Space[J]. Equipment Environmental Engineering, 2023, 20(11): 166-176.

which could significantly improve the prediction accuracy. The multi-variable time series prediction model with double input and double output had the highest accuracy and the most stable robustness. It was a relatively optimal model for the prediction of internal and external temperature time series in confined space. The research conclusions can guide the modeling of other environmental characteristics in confined space, and the research ideas can provide references for the correlation and dependency analysis among variables in other multi-variable sequential modeling problems.

KEY WORDS: confined space; internal and external temperature; time series prediction; physical mechanism; multi-variable time series; long and short term memory network

工业、军事领域中存在大量密闭空间，密闭空间是指与外界相对隔离，进出口受限，自然通风不良，密封式或半密封式的空间。如水电领域的盾构密闭空间[1]、化工领域的制氧装置[2]、军事领域的装药结构密闭空间[3]等。监测密闭空间内外环境，尤其是密闭空间内部环境，是安全性、可控性管理的必要手段，掌握导弹贮运发射筒一类高危、重要的密闭空间内部环境特征十分重要。

密闭空间分为内外 2 种环境，一般而言，密闭空间外部环境是相对容易测量的，甚至可以使用所在区域的环境特征代替。如使用气象环境特征近似作为外部环境，但内部环境通常不易测量，甚至不能测量。如导弹贮运发射筒内部无法安装传感器探头，内部环境根本无法测量，但暴露值班条件下筒内温度会较高，若超过一定阈值，将影响弹药贮存，致使导弹无法正常使用，甚至导致安全事故。密闭空间内部环境会随外部环境的变化而变化，具有延迟伴随性，通常在外部环境变化后，内部环境随后才会逐渐变化。因为内部环境由于壳体形成小型生态，外部环境对内部的影响不会实时传递，存在延迟伴随的特征，所以内部环境时间序列高度依赖于外部环境时程数据，通过外部环境推测内部环境是获取内部环境特征的可行手段。温度作为一种典型环境特征，是工业上极为重要的环境因素之一，且温度的传递最具有规律性。本文选取温度为研究对象，并进行实地试验采集某型密闭空间内外部温度时程数据，用于模型构建与评估分析。

面向密闭空间内外温度预测实际上是一种时间序列预测，时间序列预测的主要目的是基于历史观测的时间序列数据，分析序列的时序模式（包括趋势、周期性、波动性等），建立合适的序列模型，然后使用该模型为对应的时间序列生成未知的未来数据，即进行预测[4]。时间序列预测在研究人员的不断推动下，从传统的统计算法，如 ARIMA[5]，发展到支持向量机[6]、决策树[7]等机器学习算法，到近来火热的深度学习领域[8-9]，在大数据支撑下，深度学习模型达到极高精度，具有很好的预测性能[10]。

通过外部环境温度推测内部环境温度实则是一种多变量时间序列预测问题，多变量时间序列预测是利用多个具有相关性的时间序列构建模型，提高建模精度，多变量时间序列预测的核心问题是分析不同变量之间的关联性和依赖性，并准确捕捉复杂的时序模式[11]。传统的多变量时序预测算法，如统计分析算法 Vector Autoregression（VAR）[12]，结构复杂，优化困难，现多采用深度神经网络构建模型，并在各个领域得到运用。如陈秀清等[13]采用多变量长短期记忆网络对服务质量进行了分析。郑育靖等[14]采用门控循环单元结构（Gated Recurrent Unit，GRU）模型进行了时序数据异常检测。模型也不断被改良调优，如堆叠式自动编码器（SAE）[15]用于提取多变量的有效特征，基于两阶段注意力机制的循环神经网络多变量预测算法 DARNN[16]，可通过加入注意力机制捕捉长范围的时序信息与依赖关系。

尽管学者已开展大量时间序列预测研究，其中多变量时间序列预测是研究重点之一，如何充分运用不同变量之间的关联性和依赖性是多变量时间序列预测的核心问题。针对密闭空间内部温度预测的现实需求，首先采用单变量（即内部温度）自迭代方法进行预测，作为基准方案，然后结合内外部温度进行多变量时序预测，并设计一种面向密闭空间内外温度的时序预测模型。其中，单变量时序预测与多变量时序预测主要用于验证内部温度存在与外部温度的关联与依赖。对于多变量时序预测模型是本文研究重点，提出并研究了密闭空间条件下已知外部温度时间序列对内部实时温度的预测推理问题，搭建常用的时序预测模型，通过试验评估常用模型的精度与局限性。基于物理机制与特征表示定制化设计了多输入多输出的时序预测模型，增强面向密闭空间内外温度预测模型的适用性。横向对比各类模型，评估所提算法的有效性。试验结果表明，这种面向密闭空间内外温度的双输入双输出时序预测模型，具有较好的整体预测精度，适合 2 种物理量关联的时序预测。

1　时间序列预测研究现状

1.1　单变量时间序列预测

传统的单变量时间序列预测方法主要为统计类算法，如自回归模型（AR）、指数平滑预测算法（Exponential Smoothing，ES）等。统计类算法运用随机过程理论构建模型，被广泛应用于各领域，如陈

伟[17]运用自回归模型在变形监测领域进行数据处理，张慧娥等[18]基于指数平滑法对功率预测进行了研究。

自回归模型用自身做回归变量的过程，即利用前期多个时刻随机变量的线性组合来描述未来某时刻随机变量的线性回归模型，存在一个时间序列 $[x_1,x_2,x_3,\cdots,x_n]$，自回归模型认为 x_n 是前面 p 个序列的线性组合，即：

$$x_n=\beta_0+\beta_1 x_{n-1}+\beta_2 x_{n-2}+\cdots+\beta_p x_{n-p}+e_n \tag{1}$$

式中：β_0 为常数项；β_p 为模型参数；e_n 为白噪声。自回归模型是一种基础的时序预测方法，适用于平稳序列。

指数平滑预测算法适合具有逐渐衰减或增强趋势的时程曲线，单一移动平均过去观测值的权重是相等的，而指数平滑则随着观测值的变化赋予指数递减的权重，基本公式为：

$$S_n=a\cdot y_n+(1-a)S_{n-1} \tag{2}$$

式中：S_n 为 n 个时刻的预测值（指数平滑值）；y_n 为 n 个时刻的实际值；a 为平滑指数，$a\in[0,1]$。任意时刻的指数平滑值都是本时刻实际观察值与前一时刻指数平滑值的加权平均，即下一时刻数据与此时刻的实际值和上一时刻的指数平滑值相关。

统计类算法引入分解、转换等思路进行模型调优。张量分解[19]、STL 分解[20]等分解方法将时序转化为趋势性更强的子序列，小波变化[21]、傅里叶变换[22]等转换方法提取时间序列频率特征，通过特征重构增强统计类算法预测精度。

近年来，随着机器学习算法的推广应用，其在时序预测领域也得到了广泛应用，如支持向量机、随机森林等算法。支持向量机通过非线性映射使低维空间线性不可分转换到高维空间线性可分。将支持向量机运用到时间序列预测，实际上是将前 n 个时刻的序列视为变量输入，进行支持向量机回归，在复杂模式的时间序列预测问题上取得了较好成绩。如岳鹏程等[23]运用其进行了二氧化硫预测。

机器学习算法的一般思路为将前 n 个时刻数据作为输入，进行后续变量的预测，等价于回归问题，适合复杂模式的大数据预测，但没有充分应用序列信息之间的有向连接关系。基于序列信息和权重共享机制，循环神经网络（Recurrent Neural Network，RNN）被提出，并得到广泛应用。RNN 借助循环核，从时间维度提取信息，循环核参数时间共享，增加状态向量，且后一时刻存在前一时刻的有向连接，使任一时刻的状态都和前一个序列紧密相关，增加循环核共享机制，减少过拟合，RNN 现已成为自然语言处理领域的核心技术。

基础循环神经网络结构容易出现梯度消失和长期依赖性的问题，长短期记忆网络（Long Short-Term Memory，LSTM）[24]被提出。LSTM 在 RNN 的基础上加入门控机制，控制参数的流通和损失，其网络结构如图 1 所示。

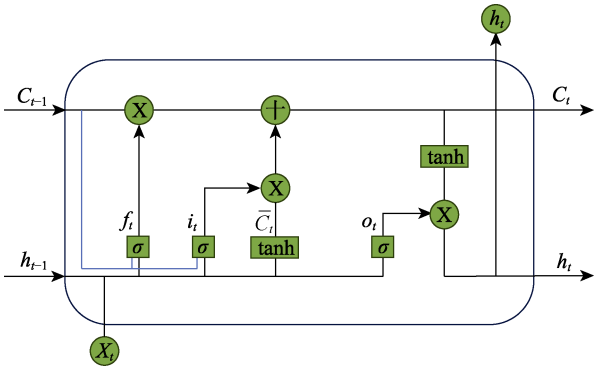

图 1　LSTM 网络结构
Fig.1 Network structure of LSTM

LSTM 包含遗忘门、输入门和输出门，输入数据经过一个 LSTM 单元获得当前单元状态 C_t，C_t 会一直传播，每经过一个单元更新状态，每个单元包含输入值 x_t 和上一时刻的输出值 h_{t-1}。输入数据进入后，先经过遗忘门，对不重要信息进行遗忘，由输入门进行计算和控制，并由输出门分别输出。公式如式（3）~（8）所示。

$$f_t=\sigma\left[\boldsymbol{W}_f\cdot(h_{t-1},x_t)+b_f\right] \tag{3}$$

$$i_t=\sigma\left[\boldsymbol{W}_i\cdot(h_{t-1},x_t)+b_i\right] \tag{4}$$

$$\overline{C_t}=\tanh\left[\boldsymbol{W}_c\cdot(h_{t-1},x_t)+\boldsymbol{b}_c\right] \tag{5}$$

$$C_t=f_t\cdot C_{t-1}+i_t\cdot\overline{C_t} \tag{6}$$

$$o_t=\sigma\left[\boldsymbol{W}_o\cdot(h_{t-1},x_t)+\boldsymbol{b}_o\right] \tag{7}$$

$$h_t=o_t\cdot\tanh(C_t) \tag{8}$$

式中：f_t 为遗忘门；i_t 为输入门；o_t 为输出门；C_t 为状态信息，用以保存所有长期和短期信息；h_{t-1} 为 t–1 时刻隐藏单元的输出信息；h_t 为 t 时刻的输出信息；x_t 为 t 时刻的输入数据；$\boldsymbol{W}$、$\boldsymbol{b}$ 为各个门的权重矩阵、偏置；σ 为 sigmoid 激活函数。

LSTM 作为目前应用较广泛的网络结构，在不断发展中也出现了 GRU（相较 LSTM 简化门控结构，在参数量较少的情况下尽量保证精度）[25]、SRU[26]（具有卷积神经网络相同的并行度，保证精度、加速训练）、phi-lstm[27]（基于短语层级模型，分层级序列表征有助于提取特定结构）等。本文采用 LSTM 结构作为网络基础单位。

1.2　多变量时间序列预测研究现状

基于不同变量之间的关联性和依赖性进行多变量时间序列预测，传统算法如 VAR[12]采用多方程联立的方法，分别构建多个自回归模型，以两变量为例：

$$y_{1,t} = \mu_1 + \pi_{1,1} y_{1,t-1} + \pi_{2,1} y_{2,t-1} + u_{1,t} \tag{9}$$

$$y_{2,t} = \mu_2 + \pi_{1,2} y_{1,t-1} + \pi_{2,2} y_{2,t-1} + u_{2,t} \tag{10}$$

式中：$y_{1,t}$ 为 t 时刻序列 1 的值；$y_{2,t-1}$ 为 t–1 时刻序列 2 的值；μ_1、μ_2 为常量系数，$u_{1,t}$、$u_{2,t}$ 为白噪声。VAR 算法是一种线性假设，利用滞后值进行回归，建立联立方程估计后一时刻各变量的动态关系。

传统方法也包括隐马尔可夫方法等，但普遍不适用于较长时间序列的建模，算法涵盖的信息较少。随着深度学习的推广，给多变量时间序列预测带来了新的思路。对于多变量时间序列预测问题，如何有效表征特征是建模的关键，涌现出了多种特征提取的网络结构。如用于时间序列分类的多通道深度卷积神经网络 MC-DCNN[28]，网络构建多个通道，每个通道将多维时间序列数据的一个维度作为输入，并单独学习特征，再融合投入 MLP 来执行分类，实现不同变量之间的有机融合。试验表明，MC-DCNN 性能优于基于欧几里德距离和动态时间包络的 K 近邻基线方法。如堆叠式自动编码器（SAE）[15]，由多层稀疏自编码器组成，前一层自编码器的输出作为其后一层自编码器的输入，逐层非监督学习训练，可以从多变量时序中提取特征。

随着对序列预测研究的深入，对于长序列易存在难以捕获长序列复杂关系的问题，注意力机制的提出一定程度上解决了这个问题。注意力机制的目标就是将注意力集中在某些重要特征上，能够使识别更加精准。对于长序列，根据需求关注信息的特定部分更有助于特征的理解。时间注意力机制评估变量在历程中的依赖信息，通过给不同数据分配不同的权重，引入新的信息。注意力机制与 LSTM[29]有机结合，融合 LSTM 善于捕捉时序各个时间步关联特征和注意力机制善于抽象序列信息的特殊处理机制，改善多变量时序预测模型效果。

循环神经网络适用于序列数据建模，其网络结构利于序列数据的前后相关性分析，适合任意输入输出长度。同样，研究者发现，卷积神经网络（CNN）也较适用于序列建模，尤其是多变量时序，CNN 广泛应用于图像，图像具有二维特征，而当序列为多变量时，可直接堆叠成二维，采用卷积神经网络结构处理能兼顾每条序列的前后相关性与不同序列间的依赖性，但 CNN 具有旋转不变性，存在不同序列间与单序列前后相关性权重一致的问题。ConvLSTM 网络[30]是一种典型的时序卷积网络结构，用于多变量时间序列预测，捕捉时空相关性。对于本文的研究对象密闭空间内外温度时序预测模型，只有内部温度和外部温度 2 条序列，若强行建立 ConvLSTM 模型将导致二维平面为 2×n 结构，不利于进行卷积，所以本文不构建此模型。

多任务学习是一种通过将相关任务训练信号中包含的信息作为归纳偏置来改进泛化性能，共享特征的同时还并行学习这些任务，每个任务学到的“知识”能够帮助其他任务学得更好的方法[31]。在模型中加入并行任务，优化多变量时间序列预测精度和模型泛化能力，组成多输入、多输出的结构，构建变体多变量时序预测模型。

综上所述，本文主要参考特征融合、注意力机制、多任务学习等关键技术，结合 LSTM 模型进行多变量时间序列预测模型研究。

2　面向密闭空间内外温度的时序预测模型

2.1　问题建模

问题核心是对密闭空间内部温度序列的预测，即存在外部温度 x_{out_t}、内部温度 x_{in_t} 两条时间序列，其描述如式（11）所示。

$$\begin{aligned} x_{in_t} &= \mathrm{model}\left(x_{\mathrm{in}_{t-T}} : x_{\mathrm{in}_{t-1}}, x_{\mathrm{out}_{t-T}} : x_{\mathrm{out}_{t-1}}\right) = \\ &\mathrm{concat}\left[\mathrm{MP}\left(x_{\mathrm{in}_{t-T}} : x_{\mathrm{in}_{t-1}}\right), \mathrm{AP}\left(x_{\mathrm{out}_{t-T}} : x_{\mathrm{out}_{t-1}}\right)\right] \end{aligned} \tag{11}$$

式中：T 为模型输入序列长度，一般与序列的周期性相关，用前一周期的外部温度和内部温度序列预测后一个时刻的内部温度；model(·)指构建的模型；MP(·)表示主要流程（Main Process）；AP(·)表示辅助流程（Auxiliary Process），在单变量时序预测模型中辅助流程为空；concat(·)表示主要流程和辅助流程的组合拼接，在单变量时序预测模型中默认无组合拼接步骤。本文主要针对 model(·)部分进行不同模型的构建。

2.2　单变量时序预测模型

基于 LSTM 单元构建单变量时序预测模型，采用基础的流式结构，对多层 LSTM 网络进行叠加，将前一层 LSTM 网络的输出，作为后一层 LSTM 网络的输入，堆叠多层 LSTM 网络以保证能够提取深层次抽象特征，增加模型的非线性拟合能力。以密闭空间内部环境温度时序作为单变量输入，输出结果为下一时刻的内部温度数据。数据进入模型后，通过 2 层 LSTM，逐层学习深层特征。LSTM 输出后，接全连接层 dense 进行输出，并添加额外 2 层 dense，增强模型的鲁棒性，如图 2 所示。

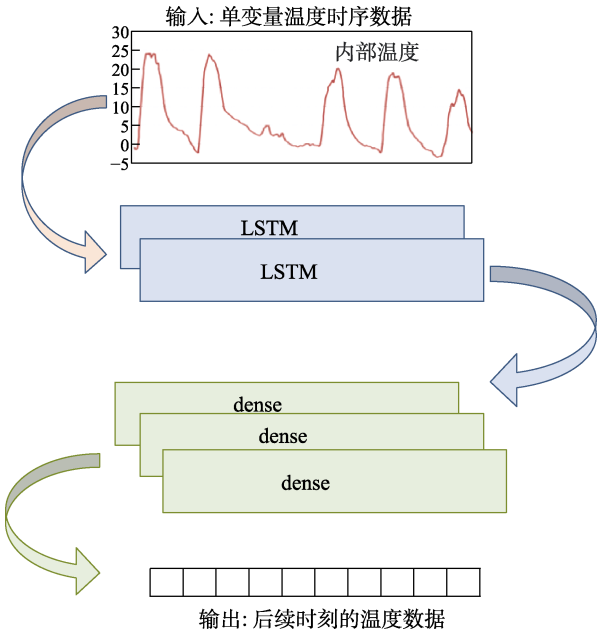

图 2　单变量时序预测模型
Fig.2 Univariable time series prediction model

2.3　多变量时序预测模型

借鉴多通道提取特征、特征融合、注意力机制等思路，构建双输入单输出、带注意力机制的双输入单输出模型。考虑到多输出时序模型能共享特征信息，增强学习效果，同时具备集成学习的特点，能增强模型的鲁棒性，鉴于此，构建双输入三输出模型。在试验过程中，发现双输入三输出模型不够符合外温预测内温场景的特点，针对数据特征、物理机制构建双输入双输出模型。综上，构建双输入单输出、带注意力机制的双输入单输出、双输入三输出、双输入双输出 4 种多变量时序预测模型进行密闭空间内外温度的预测。

双输入单输出模型如图 3 所示，输入为内部温度和外部温度 2 条温度时序数据，分别经过 LSTM 层特征提取后，经过 concat 拼接融合为一条特征序列，然后经过全连接层 dense 输出。因为密闭空间内部温度会随着外部温度变化，具有延迟伴随性，所以双输入模型相较于单变量时序模型具有较高的预测精度。

带注意力机制的双输入单输出模型如图 4 所示。核心逻辑仍然是分别提取密闭空间内外部温度特征序列，融合后接全连接层进行预测。与双输入单输出模型的唯一区别在于 LSTM 后接了一层自注意力 attention 层，在不使用其他额外信息的前提下，基于自注意力机制关注本身，抽取相关信息，扩展了模型专注于不同位置的能力。

双输入三输出模型如图 5 所示。在双输入单输出模型的基础上，增加 2 路辅助输出，用于自修正 LSTM 层，主线思路仍是融合内外温特征进行精准预测，同时内部与外部温度本身是 2 条独立的时间序列，可以

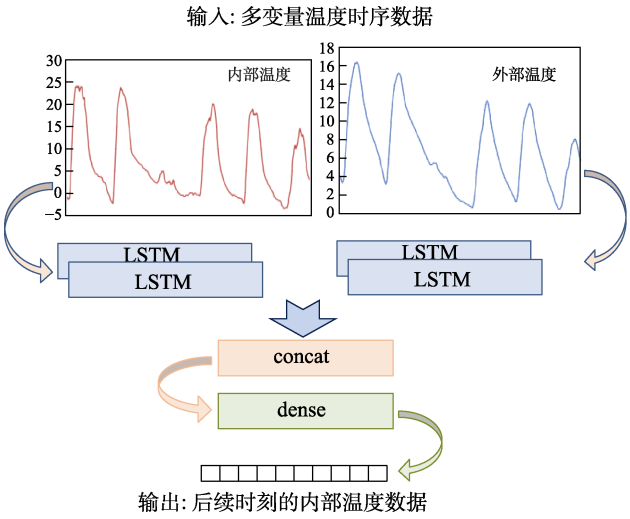

图 3　双输入单输出模型
Fig.3 Doubleinput and singleoutput model

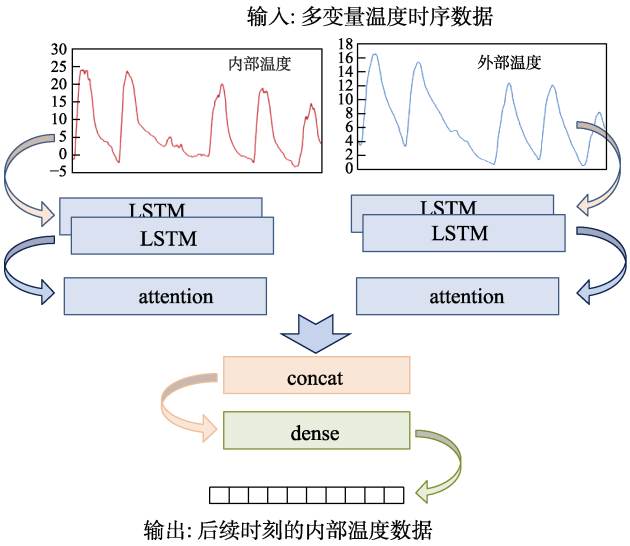

图 4　带注意力机制的双输入单输出模型
Fig.4 Double input and singleoutput model with attention mechanism

自迭代预测后续数据，以此修正网络参数。多输出模型实际上是多任务学习，训练时并行学习任务和共享相关任务之间的信息。这些具有相关性的任务将促进彼此的学习，同时多任务之间不相关的部分有助于逃离局部极小值点。

双输入双输出模型如图 6 所示。相较于双输入三输出模型，双输入双输出模型剔除了内部温度自修正辅助路线。内温自预测是通过内温自身时间序列对下一时刻内温进行预测，结合外温预测内温是通过外温时间序列对下一时刻内温进行预测，外温自预测是通过外温自身时间序列对下一时刻外温进行预测。因此，外温预测内温和外温自预测都是学习外温时序信息，容易共享信息，促进彼此学习，但内温自预测的机理与其余 2 路不同，存在冲突对其他造成负面影响。从物理意义层面可知，双输入双输出模型相较于

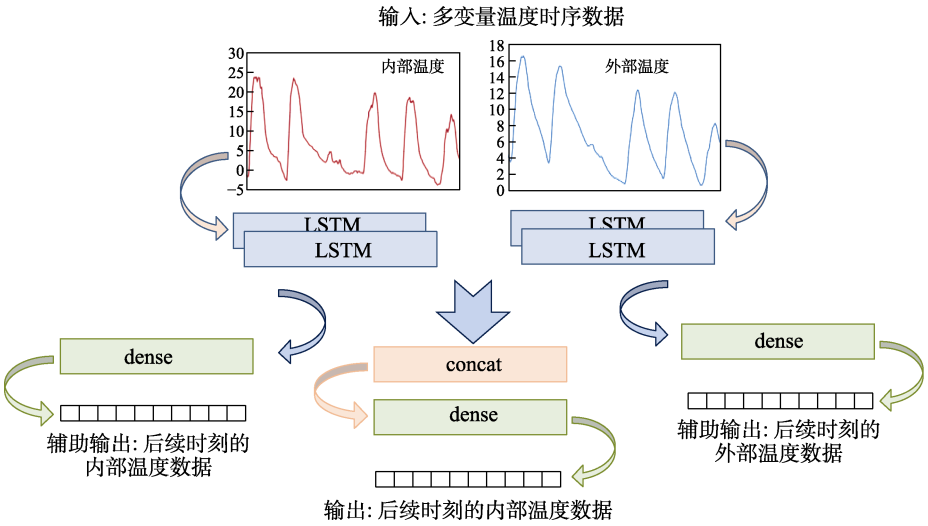

图 5　双输入三输出模型
Fig.5 Double input and threeoutput model

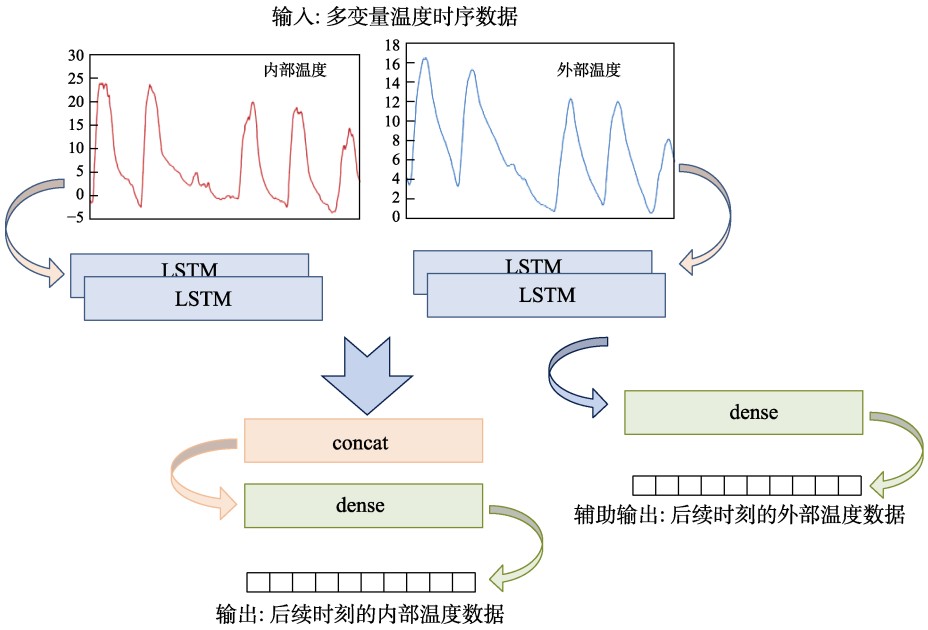

图 6　双输入双输出模型
Fig.6 Double input and double output model

双输入单输出模型多 1 路外温自预测，通过相关任务促进训练，增强了模型鲁棒性；相较于双输入三输出模型少 1 路内温自预测，防止不相关事务造成负面影响。

3　实验验证

3.1　实验环境与数据集

实验基于 centos 7.6 环境，使用 Python 语言，基于 Tensorflow2 人工智能框架进行模型的搭建。平台主要硬件参数：CPU 使用 Intel Xeon Gold 5218，264 G 内存，无 GPU。

采用真实试验数据，对于同一型号密闭空间内外温度进行监测，分别在万宁、敦煌、漠河三地采集数据。这三地分别是温带海洋性气候、干热沙漠性气候、极寒气候的代表，其温度具有差异性、代表性。采集时间超过 1 a，每 10 min 传感器自动采集 1 次数据，每个地点数据条数为 56 000+，用于验证面向密闭空间内外温度的时序预测模型是否具有适用性。

3.2　评价指标

模型精度的评价指标为均方误差（Mean Square Error，MSE）η_{MSE}，公式如式（12）所示。其中 y_i 代表真实值，$\hat{y}_i$ 代表预测值，取平方避免正负值叠加抵消，最后取整体平均值作为 MSE 最终结果，MSE 量化了测量预测值和真实值的匹配程度。

$$\eta_{\mathrm{MSE}}=\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2 \tag{12}$$

决定系数 R^2 为回归平方和与总平方和之比，$\hat{y}_i$ 代表预测值，y_i 代表真实值，$\bar{y}$ 代表平均值，R^2 反映因变量（预测值）的波动，可以判断统计模型对数据的拟合能力。

$$R^2=\frac{\sum_i\left(\hat{y}_i-\bar{y}\right)^2}{\sum_i\left(y_i-\bar{y}\right)^2} \tag{13}$$

评价方式是对真实场景的预测评价，真实场景为已知连续的外部温度监测值和内部温度初始值，通过模型预测得到下一时刻内部温度值，再迭代放入模型中，不断获取新的内部温度数据。如图 7 所示，已知 T 时刻内温初始值与外温数据，作为输入序列预测得到 T 时刻内温预测值，滑动窗口，将 T 时刻内温预测值作为 T+1 时刻输入，预测得到 T+1 时刻内温预测值，以此类推。

3.3　实验参数

为横向对比各模型，通过 keras 提供的内置函数 summary 输出模型参数量，确保不同模型参数量近似一致，保证同一数量级。带注意力机制的双输入单输出模型见表 1，x_out 代表外温输入，x_in 代表内温输入，y_pred 代表内温预测值。该模型参数的总量为 5 057，其余模型不再枚举。

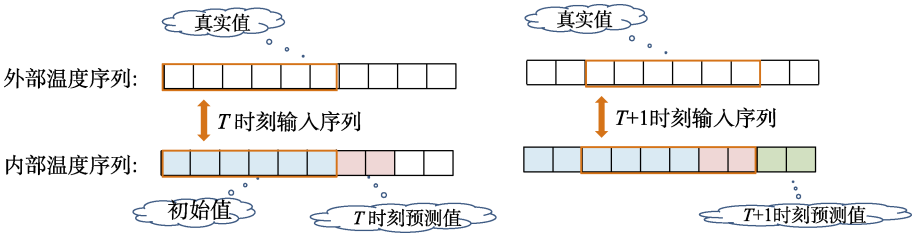

图 7　迭代预测示意图
Fig.7 Iterative prediction diagram

表 1　带注意力机制的双输入单输出模型架构与参数信息
Tab.1 Structure and parameter information of double input and singleoutput model with attention mechanism

Layer (type)	Parameters	Inputs	Output
LSTM	2480	x_out	c1
LSTM	24	c1	c2
LSTM	2480	x_in	c3
LSTM	24	c3	c4
attention	2	c2	c5
attention	2	c4	c6
concatenate	0	c5,c6	c7
dense	45	c7	y_pred

3.4　实验结果与分析

分别使用一种单变量时序预测模型和双输入单输出、带注意力机制的双输入单输出、双输入三输出、双输入双输出 4 种多变量时序预测模型，对漠河、敦煌、万宁 3 个站点的不同数据集进行密闭空间内外温度预测，进行多次实验分析。

同时进行其他实验验证，如多变量时序模型是否采用多层全连接层 dense 增强鲁棒性，实验显示对结果影响不大，所以最终保留 1 层 dense。如采用 GRU 单元代替 LSTM 单元，实验结果显示，训练加速效果一般，训练结果略微下降。采用基础 RNN 单元代替 LSTM 单元，结果显示，RNN 效果差很多，所以最终选用 LSTM 结构。在经过实验验证的前提下，最终采用上述 4 类模型作为面向密闭空间内外温度的多变量时序预测模型。

单变量时序预测模型在漠河数据集上表现结果如图 8 所示。可以看出，训练集、验证集、预测集的预测效果均较精准。已知初始值，通过模型计算得出

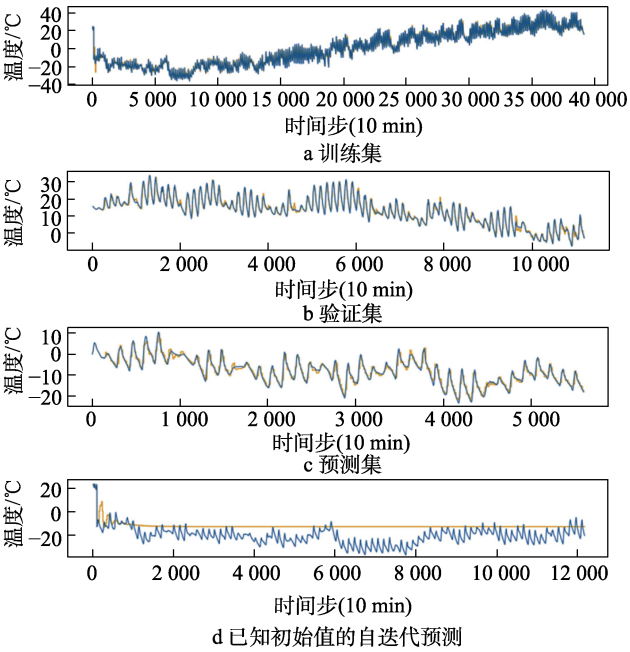

图 8　单变量时序预测模型在漠河数据集的预测结果
Fig.8 Prediction results of univariable time series prediction model in Mohe dataset: a) training set; b) validation set; c) prediction set; d) self iterative prediction with known initial values

下一时段值再滑动窗口不断迭代计算的情况，即模拟已知初始数据但后续数据无法测量的实际情况。由实验结果可知，在前有限个序列预测中，预测值和实际值基本贴合，随后逐渐偏离。因为实际温度是不断变化的，外界条件复杂多变，在没有其他输入的情况下，模型逐渐偏离正常值，直到形成波动极小的平稳曲线。这也是单变量时序自迭代预测易出现的情况，对于短期预测效果较好，但无法实现自迭代预测长期结果。因此，密闭空间内部温度预测使用单变量时间序列预测模型效果较差，只能预测短期结果。

多变量时序预测模型预测效果较好，双输入双输出模型在敦煌数据集的预测结果如同 9 所示。可以看出，训练集、验证集、预测集的预测值和真实值基本贴合。已知初始值，通过模型计算得出下一时段值再滑动窗口不断迭代计算的情况，存在小扰动，基本趋势和预测结果较准确。除双输入双输出模型外，其他多变量时序预测模型在各个数据集上表现均类似，存在小波动，但是整体趋势、周期性、贴合性都较好。

对于漠河、敦煌、万宁 3 个站点的不同数据集，分别通过不同模型进行验证，运行 000 次，每次随机取 70%数据作为训练数据，取最优一次 η_{MSE}、R^2 作为模型最优值。若出现 nan、inf 计算错误，或者 R^2 小于 0.8（即偏差过大）的情况，认为该次训练为失效训练，统计 1 000 次训练中出现失效训练的数量，以此作为模型鲁棒性评估的依据。VAR(MSE)指正常训练情况下 MSE 的方差，若 MSE 的方差越小，说明多次训练的 MSE 越集中，训练结果越稳定。模型大小指模型参数量，实验评估的前提是所有模型参数量不存在量级差异，控制冗余变量。不同模型在不同数据集上预测效果对比见表 2。

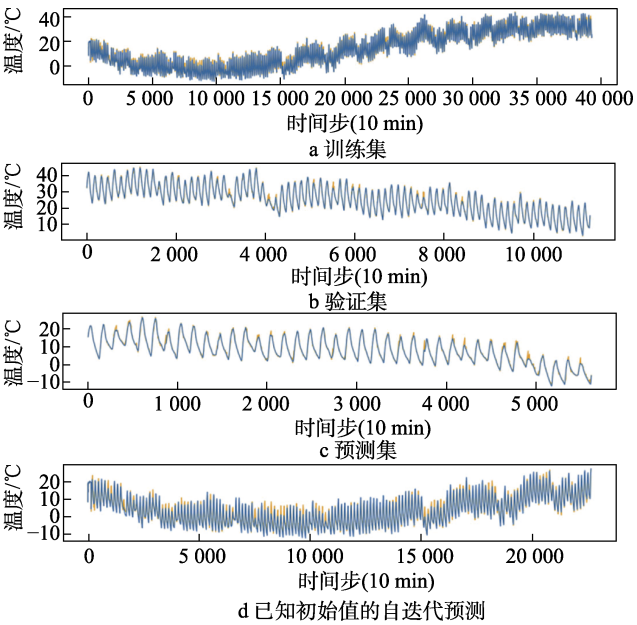

图 9　双输入双输出模型在敦煌数据集的预测结果

Fig.9 Prediction results of doubleinput and doubleoutput model in Dunhuang dataset: a) training set; b) validation set; c) prediction set; d) self iterative prediction with known initial values

表 2　不同模型在不同数据集上预测效果对比

Tab.2 Comparison of prediction effects of different models in different datasets

数据集	模型	η_{MSE}	R^2	失效训练数量	VAR(MSE)	模型大小
漠河	单变量时序预测模型	381.885 4	—	1 000	—	6 823
	双输入单输出	2.669 6	0.992 7	19	104.755 7	5 053
	带注意力的双输入单输出	2.466 1	0.993 2	26	85.506 0	5 057
	双输入三输出	2.586 1	0.992 6	27	62.325 6	5 627
	双输入双输出	2.336 7	0.993 3	14	18.796 0	5 340
敦煌	单变量时序预测模型	510.539 8	—	1 000	—	6 823
	双输入单输出	2.419 4	0.988 9	27	38.092 2	5 053
	带注意力的双输入单输出	2.579 5	0.988 3	35	20.498 4	5 057
	双输入三输出	2.977 9	0.985 6	46	2.610 0	5 627
	双输入双输出	2.071 9	0.990 4	23	5.081 8	5 340
万宁	单变量时序预测模型	37.444 3	—	1 000	—	6 823
	双输入单输出	0.948 6	0.973 6	29	1.364 6	5 053
	带注意力的双输入单输出	0.919 4	0.974 6	21	0.781 6	5 057
	双输入三输出	1.013 2	0.971 6	35	0.071 8	5 627
	双输入双输出	0.849 2	0.975 5	8	0.019 8	5 340

由实验结果可知：

1）单变量时序预测模型在无外界辅助输入的情况下，预测结果非常有限。由于只能预测短期序列，导致 R^2 评估时难以大于 0.8，所有训练均评判为失效，MSE 方差等也失去意义。该模型相较于 4 种多变量时序预测模型效果很差，这也充分说明内部温度存在与外部温度的高度关联与依赖。

2）对比 4 种多变量时序预测模型，双输入单输

出作为一种基准模型、评估标准，观察其 MSE、R^2、预测曲线等，双输入单输出模型表现尚可。

3）带注意力机制的双输入单输出模型在漠河、万宁数据集上表现比双输入单输出模型更好，但在敦煌数据集上表现更差，稳定性也是因数据集而异。可见，带注意力机制的双输入单输出模型并不能直接提高密闭空间内外温度预测精度。注意力机制的目的是建立大的全局感受野，一般而言，不适用于只有局部信息没有全局信息或引入全局信息会引起歧义的情况。在本实验中，输入数据长度为 150，即 1 500 min（传感器每 10 min 取样 1 次），超过 1 d 时间（1 d 是 1 个波动周期），所以数据信息含有全局信息。但是后一时刻温度与前一时刻温度强相关，与自然语言处理领域不同的是，句尾不需要考虑距离较远的句首，注意力机制适用性较弱。同时，模型为双输入，内温紧随外温变化，有外温提供趋势，所以注意前一周期的数据是无关紧要的，实验结果也体现出注意力机制对模型没有直接正向或负向影响。

4）双输入三输出模型在各个数据集上都表现较差，且模型鲁棒性也更弱了，不推荐在密闭空间内外温度预测场景下使用双输入三输出模型。在密闭空间外温预测内温的前置条件下，内温的自预测、外温影响内温的机制逻辑是有悖的。内温自预测的依据是内温前段时间的温度变化，外温影响内温的依据是外温的变化影响下一时刻内温的变化，前者学习内温蕴含的信息，后者学习外温蕴含的信息，所以二者冲突，若同时在模型中存在反而影响精度，无法共享任务信息。

5）双输入双输出模型无论从预测精度或者模型鲁棒性都是表现最优的，该模型适用于面向密闭空间外温预测内温的实际场景。在双输入双输出模型中，保留外温自预测和外温预测内温两路输出，二者具有一定相关性。一个的目的是预测下一时刻外温，需要以外温作为基准数据，一个的目的是预测下一时刻内温，同样需要外温作为基准数据，通过外温自预测修正外温部分的 LSTM 网络结构。双输出模式有助于促进彼此学习，达到更优的结果，同时有助于提高模型鲁棒性。

4 结语

本文基于 LSTM、特征融合、注意力机制、多任务模型等核心思路进行模型构建研究，结果表明，双输入双输出模型具有较好的预测精度，模型鲁棒性较好，在密闭空间外温预测内温场景下表现良好。但模型存在局限性，由于该模型的关联性与依赖性都源自特定场景的物理机制，只能在同类型场景中推广应用，不能提供一种普适性的模型变量关联性、依赖性分析方案。在未来的工作中，应将进行更多典型环境的试验，以更多数据集验证结论的准确性，指导密闭空间内外温度时序预测模型构建。考虑引入图神经网络，尝试新网络结构能否带来精准度的提升，考虑引入物理信息神经网络，优化现有模型直接拼接融合特征的方式，考虑引入深层网络模型，探究模型深度与广度对该场景时序预测的影响。另一个重要方向是开展基于热力学仿真的数字样机有限元分析，通过仿真手段进行对比测试，进一步优化面向密闭空间外部环境温度推测内部环境温度场景的模型，提升模型精度与鲁棒性，验证结论正确性。

参考文献：

[1] 方超刚, 李亮. 密闭空间盾构高位长距离过站施工技术[J]. 云南水力发电, 2022, 38(10): 84-88.
FANG Chao-gang, LI Liang. Construction Technology of High-Position and Long-Distance Crossing Station of Closed Space Shield[J]. Yunnan Water Power, 2022, 38(10): 84-88.

[2] 朱耿溪, 李艳, 孔庆平, 等. 密闭空间化学制氧技术研究进展[J]. 现代制造技术与装备, 2022, 58(8): 105-107.
ZHU Geng-xi, LI Yan, KONG Qing-ping, et al. Research Progress of Chemical Oxygen Production Technology in Confined Space[J]. Modern Manufacturing Technology and Equipment, 2022, 58(8): 105-107.

[3] 阚润哲, 聂建新, 刘正, 等. 复合装药密闭空间爆炸能量释放特性[J]. 火炸药学报, 2022, 45(3): 377-382.
KAN Run-zhe, NIE Jian-xin, LIU Zheng, et al. Energy Release Characteristics of Composite Charge in Confined Space Explosion[J]. Chinese Journal of Explosives & Propellants, 2022, 45(3): 377-382.

[4] 万晨, 李文中, 丁望祥, 等. 一种基于自演化预训练的多变量时间序列预测算法[J]. 计算机学报, 2022, 45(3): 513-525.
WAN Chen, LI Wen-zhong, DING Wang-xiang, et al. A Multivariate Time Series Forecasting Algorithm Based on Self-Evolution and Pre-Training[J]. Chinese Journal of Computers, 2022, 45(3): 513-525.

[5] ZHANG G P. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model[J]. Neurocomputing, 2003, 50: 159-175.

[6] 徐学奎. 基于时序分析与支持向量机的水泥熟料 f-CaO 含量软测量模型研究[D]. 长沙: 湖南大学, 2017.
XU Xue-kui. Study on Soft-Sensing Model of Cement Clinker f-CaO Content Based on Time Series Analysis and Support Vector Machine[D]. Changsha: Hunan University, 2017.

[7] 王盼盼. 基于决策树和相关权重的水质评价与时序预测研究——以太湖为例[D]. 保定: 河北大学, 2018.
WANG Pan-pan. Study on Water Quality Evaluation and Time Series Prediction Based on Decision Tree and Re-

lated Weights— A Case Study of Taihu Lake[D]. Baoding: Hebei University, 2018.

[8] 徐友刚, 曹基南, 孙进, 等. 基于深度学习的 SF6 气体压力时序数据预测[J]. 东华大学学报(自然科学版), 2022, 48(2): 81-85.
XU You-gang, CAO Ji-nan, SUN Jin, et al. Time Series Data Prediction of SF6 Gas Pressure Based on Deep Learning[J]. Journal of Donghua University (Natural Science), 2022, 48(2): 81-85.

[9] 周佳玮, 涂理林, 陈洪建, 等. 融合空间和时序遥感信息的深度学习水稻提取[J]. 地理空间信息, 2022, 20(2): 39-44.
ZHOU Jia-wei, TU Li-lin, CHEN Hong-jian, et al. Deep Learning-Based Rice Paddy Extraction by Fusing Spatial and Temporal Remote Sensing Information[J]. Geospatial Information, 2022, 20(2): 39-44.

[10] ONG Y J, QIAO Mu, JADAV D. Temporal Tensor Transformation Network for Multivariate Time Series Prediction[C]// 2020 IEEE International Conference on Big Data (Big Data). Atlanta: IEEE, 2021.

[11] YIN Jia-ming, RAO Wei-xiong, YUAN Ming-xuan, et al. Experimental Study of Multivariate Time Series Forecasting Models[C]// Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019.

[12] LÜTKEPOHL H. New Introduction to Multiple Time Series Analysis[M]. Heidelberg: Springer, 2005.

[13] 陈秀清. 基于多变量 LSTM 的服务质量预测方法研究[D]. 武汉: 武汉大学, 2021.
CHEN Xiu-qing. Research on Service Quality Prediction Method Based on Multivariable LSTM[D]. Wuhan: Wuhan University, 2021.

[14] 郑育靖, 何强, 张长伦, 等. 基于 GRU-Attention 的无监督多变量时间序列异常检测[J]. 山西大学学报(自然科学版), 2020, 43(4): 756-764.
ZHENG Yu-jing, HE Qiang, ZHANG Chang-lun, et al. GRU-Attention Based Unsupervised Multivariate Time Series Anomaly Detection[J]. Journal of Shanxi University (Natural Science Edition), 2020, 43(4): 756-764.

[15] COUTINHO M G F, TORQUATO M F, FERNANDES M A C. Deep Neural Network Hardware Implementation Based on Stacked Sparse Autoencoder[J]. IEEE Access, 2019, 7: 40674-40694.

[16] QIN Y, SONG D, CHEN H, et al. A DualStage Attention-Based Recurrent Neural Network for Time Series Prediction[C]// Proceedings of Twenty-Sixth International Joint Conference on Artificial Intelligence. Melbourne: [s. n.], 2017.

[17] 陈伟. 自回归模型估计理论及其在变形监测数据处理中的应用[D]. 武汉: 武汉大学, 2013.
CHEN Wei. Autoregressive Model Estimation Theory and Its Application in Deformation Monitoring Data Processing[D]. Wuhan: Wuhan University, 2013.

[18] 张慧娥, 朱婷婷, 胡衡, 等. 基于时序指数平滑法的风电场短期功率预测研究[J]. 电子测试, 2021(20): 53-54.
ZHANG Hui-e, ZHU Ting-ting, HU Heng, et al. Research of Short Term Power Prediction of Wind Farm Based on Sequential Index Smoothing Method[J]. Electronic Test, 2021(20): 53-54.

[19] 李大舟, 于锦涛, 高巍, 等. 融合延迟变换和张量分解的金融时序预测算法[J]. 计算机工程与设计, 2022, 43(5): 1295-1303.
LI Da-zhou, YU Jin-tao, GAO Wei, et al. Financial Timing Prediction Algorithm Fusing Delay Transform and Tensor Decomposition[J]. Computer Engineering and Design, 2022, 43(5): 1295-1303.

[20] 王晓燕, 郎贺, 王品, 等. 基于 STL 分解的平均故障间隔时间组合预测[J]. 机床与液压, 2021, 49(17): 196-200.
WANG Xiao-yan, LANG He, WANG Pin, et al. Combined Prediction of Mean Time between Failures Based on STL Decomposition[J]. Machine Tool & Hydraulics, 2021, 49(17): 196-200.

[21] 李美虹. 基于小波变换和神经网络的工业时序分析方法研究与应用[D]. 北京: 中国科学院大学, 2022.
LI Mei-hong. Research and Application of Industrial Time Series Analysis Method Based on Wavelet Transform and Neural Network[D]. Beijing: University of Chinese Academy of Sciences, 2022.

[22] HARRIS F J. On the Use of Windows for Harmonic Analysis with the Discrete Fourier Transform[J]. Proceedings of the IEEE, 1978, 66(1): 51-83.

[23] 岳鹏程, 张林梁, 马阅军. 基于模糊时序和支持向量机的高速公路 SO_2 浓度预测算法[J]. 计算机系统应用, 2017, 26(6): 1-8.
YUE Peng-cheng, ZHANG Lin-liang, MA Yue-jun. Prediction for SO_2 Concentration Based on the Fuzzy Time Series and Support Vector Machine(SVM) on Expressway[J]. Computer Systems & Applications, 2017, 26(6): 1-8.

[24] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[25] GENSLER A, HENZE J, SICK B, et al. Deep Learning for Solar Power Forecasting—An Approach Using AutoEncoder and LSTM Neural Networks[C]// 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Budapest: IEEE, 2017.

[26] 张稣荣, 卜佑军, 陈博, 等. 基于多层双向 SRU 与注意力模型的加密流量分类方法[J]. 计算机工程, 2022, 48(11): 127-136.
ZHANG Su-rong, BU You-jun, CHEN Bo, et al. Encrypted Traffic Classification Method Based on Multi-Layer Bidirectional SRU and Attention Model[J]. Computer Engineering, 2022, 48(11): 127-136.

[27] TAN Ying-hua, CHAN C S. Phi-LSTM: A Phrase-Based Hierarchical LSTM Model for Image Captioning[C]// Asian Conference on Computer Vision. Cham: Springer, 2017.

[28] ZHENG Yi, LIU Qi, CHEN En-hong, et al. Exploiting Multi-Channels Deep Convolutional Neural Networks for Multivariate Time Series Classification[J]. Frontiers of Computer Science, 2016, 10(1): 96-112.

[29] 冷天翔. 基于注意力机制和 LSTM 神经网络的股票价格预测分析[D]. 南京: 南京理工大学, 2021.
LENG Tian-xiang. Analysis of Stock Price Forecasting Based on Attention Mechanism and LSTM Neural Network[D]. Nanjing: Nanjing University of Science and Technology, 2021.

[30] SHI Xing-jian, CHEN Zhou-rong, WANG Hao, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting[C]// Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal: ACM, 2015.

[31] CARUANA R. Multitask Learning[J]. Machine Learning, 1997, 28(1): 41-75.

责任编辑：刘世忠