

DOI:10.19651/j.cnki.emt.2209240

基于融合模型动态权值的气温预测^{*}

陈 岚¹ 文 碩¹ 贺 南² 陈 乐² 李 琪¹

(1. 成都信息工程大学通信工程学院 成都 610225; 2. 成都市温江气象局 成都 611130)

摘要: 气象数据为多元时间序列,为了解决传统气温预测算法预测误差大、时空特征提取不充分的问题,将灰色关联分析、卷积长短时记忆网络和双向长短时记忆网络融合,提出了一种GRA-Conv-BiLSTM气温预测方法。灰色关联分析法解决了传统方法中参数选择困难的问题,然后设定时间窗,结合历史气温作为模型的输入,建立卷积长短时记忆网络和双向长短时记忆网络动态加权融合的预测模型以增强模型的时空特征提取能力,并以四川省某气象站点历史数据作为样本进行实验。结果显示,对于数据量庞大的多元气象时间序列,该模型表现出更强的优越性,能够适应动态非线性变化,预测精度更高。

关键词: 灰色关联度分析;气温预测;时间序列;卷积长短时记忆网络;双向长短时记忆网络;动态加权

中图分类号: TP301.6 文献标识码: A 国家标准学科分类代码: 520.20

Temperature prediction based on dynamic weight of fusion model

Chen Lan¹ Wen Bin¹ He Nan² Chen Le² Li Qi¹

(1. School of Communication Engineering, Chengdu University of Information Technology, Chengdu 610225, China;

2. Chengdu Wenjiang District Meteorological Bureau, Chengdu 611130, China)

Abstract: The meteorological data is multi-element time series. In order to solve the problems of large prediction error and insufficient time feature extraction of traditional temperature prediction algorithm, a GRA-Conv-BiLSTM temperature prediction method is proposed by integrating grey correlation analysis, ConvLSTM and BiLSTM together. The grey correlation analysis method is used to solve the problem of difficult parameter selection in the traditional methods, and the time window is set. The grey correlation analysis method solves the problem of difficult parameter selection in traditional methods. The time window is set, combined with the historical temperature as the input of the model, the prediction model of ConvLSTM and BiLSTM dynamic weighted fusion is established to enhance the spatio-temporal feature extraction ability of the model, and the experiment is carried out with the historical data of a meteorological station in Sichuan Province as a sample. The results show that for the multivariate meteorological time series with a large amount of data, the model shows stronger advantages, can adapt to dynamic nonlinear changes and has higher prediction accuracy.

Keywords: grey relation analysis; temperature forecast; time series; convolutional long short-term memory network; bidirectional long short-term memory network; dynamic weighting

0 引言

天气预报对人们安排工作和日常生活具有指导性意义,精细化的定量大气温度预测是决定天气预报精准度的一项重要指标^[1],因此,研究气温预测具有重要意义。气温要素预测的传统方法包括统计学和机器学习两大类,前人已进行诸多研究,并取得一定成果。常见的统计学方法有三次指数平滑法^[2],滑动平均算法,求和移动平均自回归模

型(autoregressive integrated moving average model, ARIMA)^[3],季节性差分自回归滑动平均模型^[4]等,这些方法原理简单,计算速度快,但只针对单变量进行预测,没有考虑其他气象要素对目标要素的影响,且预测值多趋于平均值,预测精度不够高。

机器学习的主要方法有多元线性回归法^[5],支持向量机^[6],反向传播神经网络(back propagation neural network, BP)^[7],径向基函数神经网络^[8],随机森林算法^[9],

收稿日期:2022-03-11

*基金项目:四川省教育厅科研项目(2019YFS0490)资助

极端梯度提升回归算法 (extreme gradient boosting regression, XGBR)^[10] 等, 这些方法相较于传统的预测算法, 取得了良好的预测效果, 但由于没有将气象数据的时空相关性提取充分, 导致预测准确度无法进一步提高, 且这些方法不适合处理大量数据。

深度学习的快速发展, 为气温预测开拓了新的思路。气温预测方面, 经典的深度学习方法有卷积神经网络 (convolutional neural network, CNN)^[11]、循环神经网络 (recurrent neural network, RNN)^[12] 和深度信念网络^[13] 等。三者中, CNN 拥有强大的特征提取能力, 而在 RNN 基础上改进得到的长短时记忆神经网络 (long short-term memory networks, LSTM)^[14], 规避了 RNN 的缺点, 具备更出色的学习时间序列中的历史信息、依赖关系的能力。但 LSTM 神经网络存在只考虑单向的数据信息, 忽视了序列的反向信息对预测的影响, 且对多元时间序列数据的空间特征捕获能力不足的缺点。

对此, 本文提出一种基于灰色关联分析 (grey relation analysis, GRA) 的卷积长短时记忆网络 (convolutional long short-term memory network, ConvLSTM) 和双向长短期记忆神经网络 (bidirectional long short term memory network, BiLSTM) 动态权值融合的气温预测模型, 记为 GRA-Conv-BiLSTM 模型, 并选取了 2016~2019 年四川省某气象观测站点的气象数据进行实验分析。经实验验证, 该预测模型具有强大的时空特征学习能力, 针对多要素时间序列表现出更强的跟踪动态非线性变化的能力以及更高的准确性。

1 相关理论

1.1 BiLSTM 神经网络

双向长短期记忆神经网络是在长短期记忆神经网络和双向循环神经网络 (bi-directional recurrent neural network, BRNN) 中诞生的^[15]。BiLSTM 本质就是在 BRNN 的网络结构中将隐藏层的 RNN 循环单元更换成了 LSTM 记忆单元, 从而将 BRNN 和 LSTM 的优势很好的集中在一起, 用来更好的处理时间序列的研究问题。本文采用 BiLSTM, 优点在于可以避免单向学习造成较早学习部分特征和记忆效果差的问题, 并且双向学习可以充分挖掘气象数据小时之间双向的特征, 完整地学习到其整体特征。

BiLSTM 可以分为正向 LSTM 和反向 LSTM 两部分。二者分别根据时间顺序和反时间顺序读取信息, 然后前馈到同一个输出层, 可以理解为彼此之间相互独立且数据流向相反的网络进行组合, 即完全独立的两个隐含层。BiLSTM 在 $t-1$, t , $t+1$ 时刻沿时间轴展开的结果如图 1 所示。

图 1 中模型输入为 X_t , 隐藏层状态为 A , 输出为 Y 。假设 t 时刻正向 LSTM 的隐藏层状态为 A_t , 其计算公式如




图 1 BiLSTM 结构图

式(1)所示, 可以理解成单层的 LSTM 网络, 根据上一时刻状态 A_{t-1} , 计算 t 时刻状态 A_t 的过程, t 时刻的输入为 X_t 。

$$A_t = \text{LSTM}(X_t, A_{t-1}) = \sigma(W_{xA} \cdot X_t + W_{AA} \cdot A_{t-1} + b_A) \quad (1)$$

式(1)中, t 时刻正向 LSTM 隐藏层状态是 A_t , LSTM 即 LSTM 单元, X_t 为 t 时刻的输入, $t-1$ 时刻正向 LSTM 隐藏层状态为 A_{t-1} , W_{xA} 表示目前神经元的输入 X_t 到 t 时刻隐含层 A_t 的权重; W_{AA} 表示上一状态到当前状态的权重; A_{t-1} 表示上一时刻隐含层的输出值; b_A 为偏差项。类似的可以理解 t 时刻反向 LSTM 的隐藏层状态, 其计算公式如式(2)所示。

$$\tilde{A}_t = \text{LSTM}(X_t, \tilde{A}_{t-1}) = \sigma(W_{x\tilde{A}} \cdot X_t + W_{A\tilde{A}} \cdot \tilde{A}_{t-1} + b_A) \quad (2)$$

BiLSTM 预测模型中最终输出 Y_t 的预测值由 A_t 与 \tilde{A}_t 组合, 如下:

$$Y_t = W_{hY} \cdot A_t + W_{h\tilde{A}} \cdot \tilde{A}_t + b_Y \quad (3)$$

1.2 ConvLSTM 神经网络

神经网络其实就是按照一定规则连接起来的多个神经元, Shi 等^[16] 在全连接长短时记忆网络 (fully connected lstm, FCLSTM) 的基础上提出了卷积长短时记忆模型 (convolutional long short-term memory, ConvLSTM)。FCLSTM 擅长处理长时间序列, 但是该模型不能提取空间信息。多元气象数据中含有大量空间信息, 如不同的气象要素的时空关联等。ConvLSTM 通过将卷积运算应用于 FCLSTM 的“输入到状态”和“状态到状态”两部分以改进 FCLSTM, 从而保证得到时序关系的同时可以进行特征提取, 获得时空信息。FCLSTM 和 ConvLSTM 的结构如图 2、3 所示。

从图 2、3 中可以看到, ConvLSTM 和 FCLSTM 结构类似, 都采用了门控单元来控制信息的传递。ConvLSTM 包括输入、输出、遗忘三个门, 分别对应图中的 i_t 、 o_t 和 f_t , 网络主要通过学习对这三者的控制来得到理想的结果^[17]。门控单元负责选择性的遗忘或者保留数据, 从而控制数据是否参与到状态单元的更新中。记忆细胞 C_t 中存储了当前时刻的输入特征, 并掌控前一刻的信息有无必要继续向下传递^[18]。门控单元之间的关系如式(4)~(8)所示。




图 2 FCLSTM 内部结构图




图 3 ConvLSTM 内部结构图




图 4 灰色关联分析步骤框图

灰色关联分析的具体步骤包括：

1) 确定参考序列和比较序列，这里假设参考序列是 $b(j) = \{b(j) \mid j = 1, 2, \dots, n\}$ ；比较序列是 $a_i(j) = \{a_i(j) \mid j = 1, 2, \dots, n, i = 1, 2, \dots, m\}$ ；

2) 不同元素在数量级和量纲上都有差异，必须先消除这种差异才能进行关联系数，因此一般先对其进行无量纲处理；

3) 计算每个子序列中各项参数与母序列对应参数的关联系数，及参考序列和比较序列所对应的关联程度值。

$$\epsilon_i(j) = \frac{\min_j \min_j |b(j) - a_i(j)| + \rho \max_j |b(j) - a_i(j)|}{|b(j) - a_i(j)| + \rho \max_j |b(j) - a_i(j)|} \quad (10)$$

$$i_t = \sigma(W_{xi^*} * X_t + W_{hi^*} * H_{t-1} + W_{ci^*} * C_{t-1} + b_{i^*}) \quad (4)$$

$$f_t = \sigma(W_{xf^*} * X_t + W_{hf^*} * H_{t-1} + W_{cf^*} * C_{t-1} + b_{f^*}) \quad (5)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tanh(W_{xc^*} * X_t + W_{hc^*} * H_{t-1} + b_{c^*}) \quad (6)$$

$$o_t = \sigma(W_{xo^*} * X_t + W_{ho^*} * H_{t-1} + W_{co^*} * C_t + b_{o^*}) \quad (7)$$

$$H_t = o_t \cdot \tanh(C_t) \quad (8)$$

式(4)~(8)中，“·”表示矩阵对应元素相乘，“*”表示进行卷积， W 为网络的参数， H 和 C 分别代表着隐藏状态和单元状态。 σ 为 sigmoid 激活函数，其公式为：

$$\sigma(x) = 1/(1 + e^{-x}) \quad (9)$$

信息处理流程是：遗忘门 f_t 选择性的丢弃上一个单元下来的记忆细胞状态 C_{t-1} 中的信息，没被丢弃的信息则继续传递到输入门 i_t ；sigmoid 函数决定需要更新的信息， $tanh$ 层负责得到新细胞信息来执行细胞更新，模型的最终输出便等于输出门 o_t 的 sigmoid 的与 $tanh$ 的记忆细胞的数据做乘法运算^[19 20]。

本文选取 ConvLSTM，是因为对多时间步、多元数据处理而言，ConvLSTM 可以获取每个时间步局部感知域的卷积信息，然后局部特征集合起来，变成全局特征，这样有利于更准确的预测。

2 GRA-Conv-BiLSTM 气温预测模型

2.1 灰色关联分析选择特征

灰色关系分析法用曲线绘制出归一化后的影响元素的数据值，并将其与归一化后的目标元素值绘制的曲线进行比较，比较它们之间的趋势与相似度，由此来判断关联度，如图 4 所示。

式中： ρ 是分辨系数，通常取值范围为 $[0, 1]$ ，这里取 0.5。 $\epsilon_i(j)$ 表示比较序列 $a_i(j)$ 中第 i 个序列的第 j 个参数与参考序列 $b(j)$ 中的第 j 个参数的关联系数。

4) 计算关联度，关联度则反映了计算时段内子序列与母序列相关程度的平均值，关联度大小反映着子序列对母序列的影响深度。

$$r_i = \frac{1}{n} \sum_{j=1}^n \epsilon_i(j), j = 1, 2, \dots, n; i = 1, 2, \dots, m \quad (11)$$

5) 关联度排序，排序后 r_i 越大就表示其代表的比较序列与参考序列数据发展趋势越一致，相关性越高，对整个系统的影响就更大。

经过灰色关联分析计算后，得到各要素之间的关联度

如图 5 所示,可以看出,海平面气压、气温、最高气温、最低气温、相对湿度、小时降水量、2 分钟风向、2 分钟风速、10 分钟风向、10 分钟风速、能见度这些特征中,最高气温、最低气温因与气温测量方式相同,关联度较高。筛选是为了得到相对独立的 GRA-Conv-BiLSTM 模型输入神经元,因此去掉最高气温、最低气温。然后计算目标要素气温与剩下气象要素关联度,结果如表 1 所示。




图 5 各气象要素关联度图

表 1 气象要素关联度表

	海平面气压	相对湿度	降水量	2 分钟风向
气温	0.67	0.78	0.82	0.70
	2 分钟风速	10 分钟风向	10 分钟风速	能见度
气温	0.86	0.69	0.81	0.73

根据表 1 结果,去除关联度较小的海平面气压、2 分钟风向、10 分钟风向,将选择剩下这 5 个特征和历史气温数据作为输入变量。则输入变量 $U(t)$ 为:

$$U(t) = \begin{bmatrix} R(t) \\ P(t) \\ F(t) \\ W(t) \\ V(t) \\ T(t) \end{bmatrix}^T = \begin{bmatrix} R(t-n+1) & P(t-n+1) & F(t-n+1) & \cdots & T(t-n+1) \\ R(t-n+2) & P(t-n+2) & F(t-n+2) & \cdots & T(t-n+2) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ R(t) & P(t) & F(t) & \cdots & T(t) \end{bmatrix} \quad (12)$$

式(12)中, $R(t)$ 表示湿度, $P(t)$ 表示降水量, $F(t)$ 为 2 分钟风速, $W(t)$ 为 10 分钟风速, $V(t)$ 为能见度, $T(t)$ 为温度。 n 表示给定时间窗的宽度。每行代表同一时刻不同特征要素数据,每列代表在时间窗 $(t-n+1, t)$ 内的不同时刻的同一特征要素的数据。

2.2 GRA-Conv-BiLSTM 融合模型结构

为了充分提取气温数据中包含的时空信息,本文融合 ConvLSTM 模型和 BiLSTM 模型,提出了 GRA-Conv-BiLSTM 融合模型,模型结构如图 6 所示。




图 6 GRA-Conv-BiLSTM 融合模型结构

图 6 中,模型以 $U(t)$ 作为输入时间序列,分别使用 ConvLSTM 模型和 BiLSTM 模型,对小时地面观测数据进行预测,即前 t 个时刻各要素的值来预测下一时刻的气温。

ConvLSTM 建模选用 keras 中 ConvLSTM2D, 卷积核个数为 64, 大小为 1×2 , 然后经过展平层变成 1 维向量, 最后通过全连接层输出。BiLSTM 建模也利用 keras 进行, 其中 LSTM 的卷积核数量为 100, 两个模型训练过程中优化器均为 Adam, 迭代最高次数都设置为 200 次, 并设置检查点保存最优模型参数, 然后用最优模型进行测试。

假设 ConvLSTM 模型在 $t+1$ 时刻的预测值 $Q(t+1)$, BiLSTM 模型 $t+1$ 时刻的预测值为 $S(t+1)$, 再分别为二者的预测结果赋予动态权值 ω_1, ω_2 。最后通过计算两个模型的加权融合后的值,最终得到 GRA-Conv-BiLSTM 模型的预测结果,可以表示为:

$$E(t+1) = \omega_1 Q(t+1) + \omega_2 S(t+1), \quad \omega_1 + \omega_2 = 1 \quad (13)$$

$E(t+1)$ 是 ConvLSTM 与 BiLSTM 两种模型的最优权值组合的结果。融合模型的关键就是确定值,为了确定 GRA-Conv-BiLSTM 融合模型的最佳权值 ω_1, ω_2 ,首先需要在满足 $\omega_1 + \omega_2 = 1$ 的条件下将其初始化。然后让 ω_1 的取值范围为 $[0, 1]$ 中顺次递增 0.1 的 11 个数值, ω_2 的取值范围为 $[1, 0]$ 中顺次递减 0.1 的 11 个数值,期间仍然保

持 $\omega_1 + \omega_2 = 1$, 本文中定义均方误差 MSE 最小的组合为最优组合。

3 实验结果与分析

3.1 数据采集与预处理

1) 数据采集

本文数据集来自四川省温江气象局地面气象站定时

观测资料, 数据真实有效。数据包括了 2016 年 1 月 1 日 0 时到 2019 年 12 月 31 日 23 时四川省温江气象采集站的小时观测数据。将其按照 8 : 2 分割分别作为训练集和测试集。原始气象观测数据示例如表 2 所示。

由表 2 可以看出, 正常情况下各气象要素数据更新频率为 1 h/次, 具体包括的要素有: 年(Year)、月(Mon)、日(Day)、时(Hour)、海平面气压(PRS_Sea)、气温(TEM)、

表 2 原始气象数据示例表

年	月	日	时	海平面 气压	气温	最高 气温	最低 气温	相对 湿度	降水量	2 分钟 风向	2 分钟 风速	10 分钟 风向	10 分钟 风速	能见度
2016	1	1	0	1 031.2	11.2	11.2	11	62	0	6	1.7	1	2	6 422
2016	1	1	1	1 031.3	11.9	11.9	11.2	61	0	5	3.4	358	2.7	7 179
2016	1	1	2	1 031.3	12.6	12.6	11.9	60	0	330	2.9	339	2.3	7 728
2016	1	1	3	1 030.8	13	13.1	12.6	60	0	358	2.7	358	2.8	8 653
2016	1	1	4	1 029.6	13.7	13.7	13	60	0	0	2.6	1	2.8	9 750

最高气温(TEM_Max)、最低气温(TEM_Min)、相对湿度(RHU)、小时降水量(PRE_1h)、2 分钟风向(WIN_D_Avg_2mi)、2 分钟风速(WIN_S_Avg_2mi)、10 分钟风向(WIN_D_Avg_10mi)、10 分钟风速(WIN_S_Avg_10mi)、能见度(VIS_HOR_1MI)。从第 8 个气象要素起, 各要素单位分别为: hPa、℃、℃、%、mm、m/s、m/s、m/s、m/s、m。

2) 数据预处理

(1) 数据清洗。数据清洗是预测过程中至关重要的一步, 清洗的质量直接关系到建模的正确性和稳定性。本文中数据清洗主要针对的是数据表中缺失和重复值, 本文中选择用前后相邻 4 个时刻均值对缺测值进行填充; 对时间重复的两行数据, 选择随机删除某一行; 对数据表中重复的某一列值, 则直接删除。

(2) 归一化处理。为了避免量纲带来的影响不便于得出正确结论, 对样本数据归一化, 使样本数据统一在一个数量级, 将表 2 中的后 11 个气象要素进行归一化处理, 范围设置在 [0,1], 公式如下:

$$x^* = \frac{x - \min}{\max - \min} \quad (14)$$

式中: \max 某气象要素的最大值, \min 该气象要素的最小值, x^* 则是归一化结果。

(3) 将多元时间序列数据转换为有监督数据, 即为模型指定输入和输出。本文时间窗宽度为 4, 即以 $t, t-1, t-2, t-3$, 这 4 个时间步筛选后特征要素和气温的观测值作为输入, $t+1$ 时刻的气温数据作为预测输出。

3.2 模型评估指标

为了评价各模型对下一时刻气温预测效果, 本文选取了均方误差(MSE)和平均绝对误差(MAE)两个指标作为评估指标, 二者公式如式(15)、(16)所示。

$$MSE = \frac{1}{N} \sum_{i=1}^N (e'_i - e_i)^2 \quad (15)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |e'_i - e_i| \quad (16)$$

其中, N 为选取的样本数量, e'_i 为预测值, e_i 为实际观测值。显然, MSE 和 MAE 越小, 则表述预测值与真实值之间的偏差越小, 预测的准确度也就越高。

3.3 模型实验结果与分析

本文基于灰色关联分析, 将 GRA、ConvLSTM 和 BiLSTM 结合组成了 GRA-Conv-BiLSTM 气温预测模型, 实验过程中将 GRA-Conv-BiLSTM 和单一模型 LSTM、BiLSTM、ConvLSTM 进行对比。在经过预处理和归一化特征数据进行训练和测试, 以此来证明该模型的正确性与有效性。

此外, 为显示本文组合模型相比其他组合模型的优越性, 选取了基于求和白回归移动平均和长短期记忆网络的 ARIM-LSTM 模型, 以及基于弹性网络(elastic net, ENet)、K 近邻回归(K-nearest neighbors, KNN)、随机森林(random forest, RF)三者的组合模型(ENet-KNN-RF)进行对比实验, 实验过程中, 组合模型的融合方法与本文提出模型一样, 采用动态最优权值。

整个样本集数据量较大, 基于方便清晰展示模型效果考虑, 从测试集中随机选取了连续的 342 条数据进行测试, 测试过程中 GRA-Conv-BiLSTM 与其他 5 种模型的 MSE 和 MAE 的值如表 3 所示。

从表 3 中可以看出, LSTM 模型的 MSE 在 3 左右, 不是特别大, 说明 LSTM 适合时间序列分析。但其拟合效果不如其他 3 种模型好, 这也侧面印证了简单 LSTM 模型对序列的反向信息和空间特征捕获能力不足造成的预测精度降低问题。

表 3 不同模型测试结果表

模型	MSE	MAE
LSTM	2.713	1.430
ConvLSTM	0.932	0.758
BiLSTM	0.811	0.692
GRA-Conv-BiLSTM	0.417	0.471
ARIMA-LSTM	1.942	1.254
ENet-KNN-RF	4.850	3.415

3 种组合模型对比中, 机器学习组合模型 ENet-KNN-RF 效果最差, ARIM-LSTM 表现次之, 本文模型效果最好。这是因为针对气象数据这种多元时间序列的预测而言, 时序关系的提取是否充分对预测精度有很大影响, 而 ENet-KNN-RF 中并不具有循环神经网络的记忆功能, 因而不具备这种能力。

与此同时, 将 GRA-Conv-BiLSTM 模型训练及测试出的结果与随机森林算法, 岭回归, 极端梯度提升回归(XGBR)模型预测的结果相比较, 来进一步验证本文提出的 GRA-Conv-BiLSTM 气温预测模型的优越性, 同样随机抽取连续的 342 条数据, 最终的拟合结果对比如图 7~10 所示。




图 7 随机森林算法测试结果




图 8 岭回归算法测试结果

可以看出, 随机森林算法, 岭回归算法, XGBR 模型在气温波动较大的地方拟合效果并不好, 比如从样本量 150~200 这个数据段, 3 个模型预测出的气温值与实际气




图 9 XGBR 算法测试结果




图 10 GRA-Conv-BiLSTM 测试结果

温值相比都存在较大偏差。而 GRA-Conv-BiLSTM 模型在整个数据段, 与真实的气温数据贴合程度都较高, 在部分数据段, 预测气温值与真实气温几乎完全重合, 说明 GRA-Conv-BiLSTM 模型对数据波动、非线性变化更加敏感, 跟踪能力更强。表 4 列出了 GRA-Conv-BiLSTM 与其它气温预测模型的评估指标, 可以发现 GRA-Conv-BiLSTM 模型预测的误差最小, 性能最优, 且相对传统模型提升幅度较大。综上表明, 对于大规模, 非线性动态变化的多要素时间序列预测而言, 采用本文的 GRA-Conv-BiLSTM 模型, 表现更好。

表 4 不同模型测试结果对比表

模型	MSE	MAE
RF	10.738	2.602
岭回归	9.266	2.512
XGBR	10.756	2.653
GRA-Conv-BiLSTM	0.417	0.471

4 结 论

随着气象服务业的发展, 精细化气象服务对气象数据的精准度要求越来越高, 为此, 本文提出了基于灰色关联分析的 GRA-Conv-BiLSTM 动态权值融合模型, 通过要素关联度筛选特征要素, 减少输入神经元数量, 从而降低了

网络的复杂度,较好地解决了参数选择问题。同时针对用长短时记忆网络预测时间序列时,反向信息以及空间特征信息提取不充分导致预测精度受限的问题,提出了ConvLSTM 和 BiLSTM 组合模型的方法,并通过实验进行模型的对比分析,以探究方法的可行性。结果表明,组合模型比传统预测方法预测精度有很大提升,同时与单一模型预测相比,特征选择能力明显提升,提高了预测准确度;与常见的气温预测组合模型相比,预测精度也得到了有效提高,为气温预测提供了新思路,适合为气象监测部门和气象服务部门提高服务,达到防灾减灾等目的。

本文设计的 GRA-Conv-BiLSTM 融合模型在气温单步预测(只需要预测未来 1 h)方面效果表现较好,但也存在局限性,如该融合模型在气温序列多步预测(需要预测未来一段时间的气温)时,预测误差会随着时间步而显著增加,说明该模型在气温多步预测上还存在改进空间。这是因为气象数据具有周期性,比如年周期、月周期等,对于具有周期性的时间序列时,当前时间点的数据不仅与前一个时间点有联系,也与上一个周期的同一位置的数据点有关,而 ConvLSTM 和 BiLSTM 对周期数据并不敏感,因此如何提升多步预测的精度,将是未来研究工作的重点。

参考文献

- [1] 季彦东. 基于改进 LSTM 模型的大气温度预测[J]. 通化师范学院学报, 2020, 41(8):82-86.
- [2] 史永胜, 王文琪. 基于改进三次指数平滑法的航材需求预测 [J]. 计算机工程与设计, 2020, 41(11): 3118-3122.
- [3] 王源昊. 基于 ARIMA 模型和 LSTM 神经网络的全球气温预测分析[J]. 科学技术创新, 2021(35):166-170.
- [4] 胡衍坤, 王宁, 刘枢, 等. 时间序列模型和 LSTM 模型在水质预测中的应用研究[J]. 小型微型计算机系统, 2021, 42(8):1569-1573.
- [5] 郑增威, 杜俊杰, 周燕真, 等. 基于多因素稀疏回归预测模型的商家客流量预测[J]. 计算机应用研究, 2020, 37(5):1440-1444.
- [6] 付乐天, 李鹏, 高莲. 考虑样本异常值的改进最小二乘支持向量机算法[J]. 仪器仪表学报, 2021, 42(6): 179-190.
- [7] 李欢, 田芳明, 谭峰, 等. 基于 MEA-LM-BP 神经网络的棚室温度预测模型研究[J]. 农机化研究, 2021, 43(6):189-193.
- [8] 王卓, 朱宁宁, 郑祥. 基于 LDA 和 RBF 神经网络的开关柜局部放电模式识别方法研究[J]. 电子测量技术, 2021, 44(14):148-152.
- [9] 刘浩然, 刘秀清, 王春乐. 基于随机森林和超像素的极化 SAR 图像分类[J]. 国外电子测量技术, 2021, 40(9):29-35.
- [10] 石欣, 田文彬, 冷正立, 等. 基于 CFD 和 LightGBM 算法的建筑室内温度全局预测模型[J]. 仪器仪表学报, 2021, 42(1):237-247.
- [11] 袁路生, 吴春磊. 基于 AC-CNN 模型的过程故障识别[J]. 计算机工程与设计, 2020, 41(2):542-549.
- [12] 盛龙帅, 李策, 李欣. 基于注意力机制的乳腺 X 线摄影分类方法 [J]. 计算机工程与应用, 2020, 56(8): 166-170.
- [13] 邓勇, 蒋田, 赖治屹. 基于 DBN 和 LSSVM 的管道气体压力检测方法研究[J]. 电子测量与仪器学报, 2021, 35(6):198-204.
- [14] 张松, 李江涛, 别东洋, 等. 一种基于单通道 sEMG 分解与 LSTM 神经网络相结合的手势识别方法[J]. 仪器仪表学报, 2021, 42(4):228-235.
- [15] 陆旦宏, 王鑫, 吴雅玲, 等. 基于 PCA 和 BRNN 的土地负荷类型预测[J]. 电气应用, 2019, 38(11):17-24.
- [16] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]. Advances in Neural Information Processing Systems, 2015:802-810.
- [17] 徐瑞光, 梁士栋. 基于双线性递归神经网络的交通流量预测方法[J]. 综合运输, 2018, 40(11):70-75.
- [18] 王震宇, 张雷. 基于深度卷积和门控循环神经网络的传感器运动识别[J]. 电子测量与仪器学报, 2020, 34(1): 1-9.
- [19] 黄启桥, 麦雄发, 李玲, 等. 基于 ConvLSTM 的广西短临降水预报[J]. 气象研究与应用, 2021, 42(4):44-49.
- [20] 李英睿, 李琼, 魏加华, 等. 基于 ConvLSTM 的气象雷达回波外推[J]. 青海大学学报, 2021, 39(1):93-100.

作者简介

- 陈岚,工学硕士,主要研究方向为气象数据分析、人工智能与智能信息处理等。
E-mail: 2641787848@qq.com
- 文斌,工学博士,教授,主要研究方向为计算机软件和传感网技术,嵌入式系统设计等。
E-mail: 573991760@qq.com
- 贺南,高级工程师,主要从事气象探测及服务工作等。
E-mail: 121768297@qq.com
- 陈乐,高级工程师,主要从事气象探测及服务工作等。
E-mail: 563856660@qq.com
- 李琪,工学硕士,主要研究方向为嵌入式系统与物联网技术等。
E-mail: 979894512@qq.com