

文章编号: 2096-1618(2024)05-0527-07

# 基于改进麻雀算法的 PCC-DBN-LSTM 气温预测模型

王冬萌<sup>1</sup>, 文 斌<sup>1</sup>, 李晓燕<sup>2</sup>, 徐 越<sup>3</sup>, 刘书慧<sup>3</sup>, 付世军<sup>3</sup>

(1. 成都信息工程大学通信工程学院, 四川 成都 610225; 2. 山西省霍州市气象局, 山西 霍州 031400; 3. 四川省南充市气象局, 四川 南充 637000)

**摘要:** 气温预测是气象学中的一个重要研究领域。随着气象精准化发展, 迫切需提升气温预测的精准度。为解决传统气温预测算法效果不佳, 并且对于多个站点气象数据时空特征提取能力不足, 提出一种基于改进麻雀算法优化的皮尔逊积矩相关系数(PCC)-深度置信网络(DBN)-长短时记忆网络(LSTM)的气温预测模型。首先利用 Pearson 相关系数对众多的气象参数进行选择, DBN 网络对输入的多站点气象数据特征进行提取和降维, LSTM 对提取的特征进行建模和预测。由于模型初始化参数众多, 提出改进麻雀算法优化 DBN-LSTM 网络参数, 提高模型的预测精度和稳定性。实验表明: 所提模型的 RMSE 为 0.527, 精度高于单一模型和同类模型。

**关键词:** 气温预测; 皮尔逊积矩相关系数; 深度置信网络; 改进麻雀算法; 长短时记忆网络

中图分类号: TP389.6

文献标志码: A

doi: 10.16836/j.cnki.jcuit.2024.05.002

## 0 引言

大气温度预测是气象学中的一个重要研究领域。随着气象精准化发展, 迫切需提升气温预测的精准度。其中, 利用一定区域内多个站点的数据进行气温预测是一种常见的气象预测任务, 其涉及多个气象站点的气温数据, 需要对多个站点的气象数据进行综合分析和预测, 因此具有更高的预测难度和挑战性。

近年来, 深度学习的发展和应用为气温预测开辟了新思路。其中 DBN 是一种无监督的深度学习算法, 具有很强的特征提取能力<sup>[1]</sup>, RNN 适用于时间序列预测等任务, 但由于循环结构对于较长的序列容易出现梯度消失或爆炸问题, 致使模型难以训练。而在 RNN 基础上改进得到的门控循环单元(GRU)和长短时记忆网络(LSTM)可缓解梯度消失问题。花凡等<sup>[2]</sup>将长短期记忆网络应用在气温预测中, 实验结果显示, LSTM 预测精度高于 GRU 和 DNN, 但对多元时序的气象数据特征提取不充分从而精度不够高。考虑到 DBN 具有很强的特征提取能力, 所以本文结合深度置信网络-长短时记忆网络(DBN-LSTM)<sup>[3-4]</sup>进行气温预测。由于 DBN-LSTM 模型参数众多<sup>[5]</sup>, 参数的初始化选择关系到模型的预测精度, 所以对参数的初始化变得尤为重要<sup>[6]</sup>。

对此, 本文提出一种联合多站点基于改进麻雀算法优化的皮尔逊积矩相关系数<sup>[7]</sup>(PCC)-深度置信网

络(DBN)-长短时记忆网络(LSTM)的多站点气温预测模型, 即 ISSA-DBN-LSTM 模型, 选取四川省某地区 6 个相似区域自动站点 2017-2019 年的气象数据进行实验分析。经验证, 对于多站点的特征提取该预测模型表现得更优越, 针对多元时序的气象数据表现出更强的预测精度和泛化能力。

## 1 相关理论

### 1.1 DBN 网络

深度置信网络(deep belief networks, DBN)是深度学习方法中常用的算法之一, 是一种结合特征学习和深度学习的多层神经网络的无监督学习算法<sup>[8]</sup>。DBN 网络各层单元之间的连接采用受限玻尔兹曼机(restricted boltzmann machine, RBM)进行学习。在 DBN 网络中, 每个 RBM 都可以看作是一个单个的神经网络层, 每层之间的输入通过前一层的输出进行传递, 最后一层的输出可以作为输入用于监督学习或者分类等任务。

RBM 的结构如图 1 所示, 具有层内无连接的可见层和隐藏层, 存在可见层和隐藏层之间的双向全连接。RBM 的特点是: 每个隐藏单元的激活在提供可见层状态时是独立的(层内没有连接), 可见层单元的激活状态在提供隐藏层状态时也是独立的。根据玻尔兹曼分布, 可见层、隐藏层的激活概率如下:

$$p(v_i = 1 | h) = \sigma(a_i + \sum_j w_{ij} h_j) \quad (1)$$

$$p(h_j = 1 | v) = \sigma(b_j + \sum_i w_{ij} v_i) \quad (2)$$

收稿日期: 2023-06-06

基金项目: 四川省科学技术厅重点研发资助项目(2023YFN0051)

通信作者: 李晓燕. E-mail: 1036969486@qq.com

式中,  $v_i$  为可见层的输入,  $a_i$  为可见层的偏置量,  $h$  是隐藏层的变量,  $b_j$  为隐藏层的偏置量,  $w_{ij}$  为 RBM 的连接权值,  $\sigma$  是一个 Sigmoid 函数。




图1 RBM 结构图

DBN 的本质是将多个 RBM 堆叠起来, 训练过程是从低到高逐层训练<sup>[9]</sup>, 图2 为一个3 层 RBM 构成的 DBN 结构图。




图2 DBN 结构图

## 1.2 LSTM 神经网络

LSTM (long short-term memory) 是一种循环神经网络, 是在 RNN 网络的基础上增强的。LSTM 有效解决了较长的 RNN 循环结构序列容易导致梯度丢失或爆炸的问题, 与传统的 RNN 相比, LSTM 具有更强的记忆能力和更好的长期依赖建模能力<sup>[10]</sup>。LSTM 通过引入称为“门”的机制来控制信息流的进出, 从而使网络能够选择性地保存或遗忘输入序列中的信息, 其中包含 3 个门控单元: 遗忘门、输入门和输出门, 以及记忆细胞。单个 LSTM 基本结构如图3 所示, 其中  $X_t$  为  $t$  时刻输入,  $h_t$  为  $t$  时刻隐层状态,  $C_t$  为  $t$  时刻细胞状态。




图3 LSTM 单个结构

具体的信息处理流程是, 每个时间步的输入被遗忘门和输入门控制后, 通过前一时刻的输出和记忆单元计算得到当前时刻的输出和记忆单元时间。输出门再根据需要对输出进行控制。在 LSTM 中, 记忆细胞的状态可以在不同的时间步长中传递, 而隐藏状态则只在当前时间步长中传递。LSTM 的输入门和遗忘门可以控制细胞状态的更新, 输出门可以控制隐藏状态的输出。其中门控单元之间的关系式如下:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b'_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b'_c) \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b'_o) \quad (6)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

式中,  $i_t$  是新信息的保留部分,  $\tilde{C}_t$  是新的输入带来的信息,  $C_t$  表示当前新的状态,  $f_t$  是遗忘门给出的输出,  $o_t$  是输出门的输出,  $\sigma$  为激活函数。本文选用 sigmoid 函数作为激活函数, 并且将 DBN 网络的最后输出层与 LSTM 网络相连。

## 1.3 改进的麻雀算法 (ISSA)

DBN-LSTM 网络初始化参数较多, 随机输入初始权值会导致模型训练时间过长, 容易陷入局部最优解, 预测精度不足。考虑到 DBN-LSTM 预测模型的性能容易受到初始参数选择的影响, 本文采用改进的麻雀算法 (ISSA) 对 DBN-LSTM 网络的初始参数进行优化。

### 1.3.1 SSA 算法

SSA 是一种基于自然界中麻雀寻找食物行为的启发式算法, 能够有效地避免局部最优解, 并找到全局最优解<sup>[11]</sup>, 该算法主要由探索者、跟随者、警戒者 3 部分组成: 探索者指的是在搜索过程中找到更好解的麻雀, 在种群中的位置最好, 距离食物最近; 跟随者是指在搜索过程中跟随探索者的麻雀, 可以根据探索者更新位置, 从而增加找到食物的概率; 警戒者是指在搜索过程中, 当探索者或跟随者被捕食者捕食时, 距离被捕食者最近的麻雀, 当警戒者向群体发出警报时, 群体中的麻雀会相互靠近, 以降低被捕的概率。假设在  $D$  维空间中麻雀的位置以及麻雀的适应度值表示为

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1d} \\ x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nd} \end{bmatrix} \quad (8)$$

$$F_x = \begin{bmatrix} f([x_{11} & x_{12} & \cdots & x_{1d}]) \\ f([x_{21} & x_{22} & \cdots & x_{2d}]) \\ \vdots & \vdots & \vdots & \vdots \\ f([x_{n1} & x_{n2} & \cdots & x_{nd}]) \end{bmatrix} \quad (9)$$

其中  $n$  是麻雀数量,  $d$  表示要优化的变量维度。每行的值  $F_x$  代表每个麻雀的自适应度, 自适应度值越高的探索者在搜索过程中率先寻获食物。此外, 因为探索者负责寻找食物并指挥整个种群的流动方向, 因此探索者可以比跟随者在更广阔的范围内寻找食物。整个搜索过程中探索者的位置更新公式:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot \text{iter}_{\max}}\right) & R_2 < \text{ST} \\ X_{i,j}^t + Q \cdot L & R_2 \geq \text{ST} \end{cases} \quad (10)$$

其中  $t$  是迭代次数,  $X_{i,j}$  为麻雀的具体位置,  $Q$  是一个正态分布的随机数,  $L$  为一个  $1 \times d$  的矩阵,  $L$  中每个元素均为 1,  $\alpha$  为 0-1 的随机数,  $R_2$  为 0-1 的警报值, ST 为 0.5~1 的安全值。当  $R_2 < \text{ST}$  时代表群体周围无危险隐患, 探索者进入广泛的搜索模式, 若  $R_2 \geq \text{ST}$ , 说明警戒者发现了捕食者, 所有麻雀都需要迅速飞到其他安全区域。跟随者的位置更新公式:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}} + X_{i,j}^t}{t^2}\right) & i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L & i \leq n/2 \end{cases} \quad (11)$$

其中,  $X_p$  是探索者占据的最好位置,  $X_{\text{worst}}$  表示当前全局麻雀占据的最坏位置,  $A$  为一个  $1 \times d$  的矩阵,  $A$  中每个元素随机分配为 1 或 -1。当  $i > n/2$  时, 说明第  $i$  个跟随者没有觅食成功, 需要更换觅食地。当警戒者感到危险, 会做出反捕食行为, 其位置更新公式:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta |X_{i,j}^t - X_{\text{best}}^t|, & f_w > f_g \\ X_{i,j}^t + K \left( \frac{X_{i,j}^t - X_{\text{best}}^t}{(f_w - f_g) + \varepsilon} \right), & f_w = f_g \end{cases} \quad (12)$$

其中,  $X_{\text{best}}$  是麻雀全局最好的位置,  $\beta$  是步长控制参数, 是一个平均值为 0、方差为 1 的正态分布随机数,  $K$  是 -1~+1 的随机数。  $f_g$  和  $f_w$  分别是当前种群最高和最低适应度值。  $\varepsilon$  是最小的常数, 以避免零分误差。

当  $f_w > f_g$  表示麻雀位于种群的边缘, 易受到危险;  $f_w = f_g$  证明麻雀意识到危险的存在, 必须靠近其他个体以避免危险。  $X_{\text{best}}^t$  代表中心的位置, 并且在其周围是安全的。  $K$  代表麻雀的运动方向, 也是步长控制因子。

### 1.3.2 改进 SSA 算法

由于麻雀种群的初始位置太过随机, 会有过于分散或密集的情况出现, 影响整个种群的迭代寻优, 可能陷入局部最优解, 所以本文选用佳点集对种群初始值进行优化。

佳点集方法是一种可以均匀选择点的有效方法, 与随机方法相比, 利用佳点集方法优化种群初始值的选择, 可以使种群在搜索空间中分布更加均匀。因此, 本文使用佳点集方法改进 SSA 算法以此生成初始种群个体。佳点集生成个体如图 4 所示, 随机生成个体

分布如图 5 所示。




图4 佳点集生成的个体散点图




图5 随机生成的个体散点图

SSA 算法搜索效率高, 全局搜索能力强, 特别适用于高维、复杂的优化问题。本文采用 ISSA 算法来优化 DBN-LSTM 多站点气温预测模型, 以提高模型的预测性能和训练效率。

## 2 ISSA-PCC-DBN-LSTM 神经网络预测模型

### 2.1 皮尔逊积矩相关系数法选择特征

皮尔逊积矩相关系数法 (Pearson product-moment correlation coefficient, PCC) 是一种用来衡量两个变量之间线性相关性的统计量<sup>[12]</sup>。当相关系数为正时, 表示两个变量呈正相关, 即随着一个变量的增加, 另一个变量也增加; 当相关系数为负时, 表示两个变量呈负相关, 即随着一个变量的增加, 另一个变量减少。如果相关系数接近 0, 说明两变量之间几乎没有线性关系; 如果相关系数接近 1 或 -1, 说明两变量之间存在强烈的正相关或负相关。通常用符号  $r$  表示。其取值范围在 -1~1, 计算公式如下:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}, \quad \begin{cases} r = -1, \text{完全负相关} \\ -1 < r < 0, \text{负相关} \\ r = 0, \text{无相关性} \\ 0 < r < 1, \text{正相关} \\ r = 1, \text{完全正相关} \end{cases} \quad (13)$$



其中,  $X$  和  $Y$  分别表示两个变量的数据,  $\bar{X}$  和  $\bar{Y}$  分别表示  $X$  和  $Y$  的均值。为消除各变量间量纲差异, 先做归一化处理, 在进行皮尔逊积矩相关系数计算, 得到各气象要素之间的关联系数热力图, 如图6所示, 大气温度与2分钟风向的相关性为-0.49与10分钟风向的相关性为-0.53, 明显大气温度与2分钟风向和10分钟风向相关性要差一点。因此去掉2分钟风向和10分钟风向, 选择其余7种气象要素和历史气温数据作为输入。




图6 各要素皮尔逊相关系数热力图

## 2.2 ISSA-DBN-LSTM 模型结构

为了在预测温度时充分提取气象数据中包含的时空信息, 本文提出一种改进的麻雀算法 (ISSA) 优化 DBN-LSTM 模型, 模型结构如图7所示。

首先以欧几里得距离作为筛选相似性站点的指标, 选择与目标站点临近的5个站点和待预测站点历史数据经过预处理后, 通过 Pearsons 系数法进行特征提取后的数据作为输入时间序列, 初始化 DBN-LSTM 网络的权重, 计算麻雀个体适应度, 找出最好和最坏麻雀个体记录。利用式(10)~(12)调整麻雀的位置, 然后计算麻雀的个体适应度值, 评估是否更新麻雀的位置。如果是, 则更新麻雀的位置, 否则评估是否满足终止条件, 得到终止条件后最好麻雀个体的适应度值和

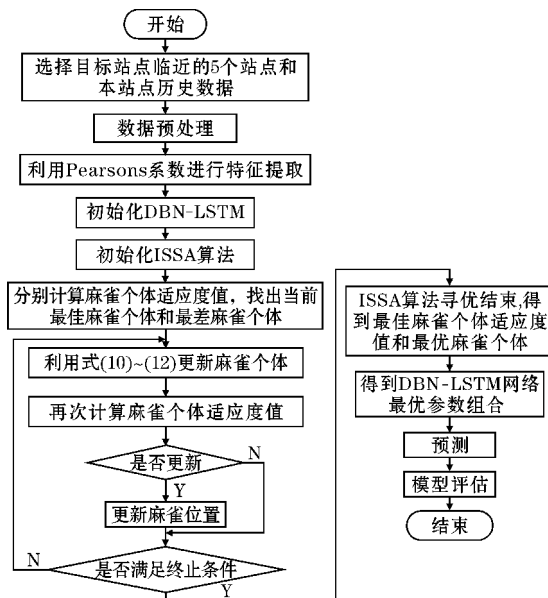


图7 ISSA-DBN-LSTM 模型结构

位置, 即 DBN-LSTM 的最优参数组合。使用此参数对模型 ISSA-DBN-LSTM 进行训练, 对10分钟地面观测气象数据进行预测, 即前  $t$  个时刻各个站点各气象要素的值来预测本站点下一时刻的气温。DBN-LSTM 模型建模选用 keras 包, 对比多个模型的均方误差 MSE, 其中 MSE 最小的模型为最优模型。

## 3 实验结果与分析

### 3.1 数据收集与预处理

#### 3.1.1 数据采集

信息来源于四川省某地的气象部门自动气象站观测数据, 数据真实有效。数据包括2017年1月1日0时0分到2019年12月31日23时50分气象站采集的10分钟观测数据。将其按照7:3分割为训练集测试集, 原始气象数据示例如表1所示, 每种气象要素的数据更新频率为10 min/次。

表1 原始气象数据示例

日期	时刻	气压 /hPa	温度 /℃	云量 /%	能见度 /m	相对 湿度/%	降水 量/mm	2分钟 风向/ $m \cdot s^{-1}$	2分钟 风速/ $m \cdot s^{-1}$	10分钟 风向/ $m \cdot s^{-1}$	10分钟 风速/ $m \cdot s^{-1}$
2019-04-07	20:10:00	964.85	12.08	68.3	9458	62.20	0	3.0	2.1	11	1.7
2019-04-07	20:20:00	964.96	12.10	68.4	9512	62.14	0	3.2	3.6	350	2
2019-04-07	20:30:00	965.00	12.26	68.6	9523	62.06	0	310	3.3	326	2.2
2019-04-07	20:40:00	965.02	12.52	69.0	9633	61.93	0	345	3.1	333	2.6
2019-04-07	20:50:00	965.13	12.30	69.2	9702	61.88	0	2.6	2.7	305	2.8
2019-04-07	21:00:00	965.29	12.19	69.5	9795	61.84	0	2.5	2.3	10	2.9

#### 3.1.2 预处理

气象数据预处理是指在气象数据分析和建模之前, 对原始气象数据的清洗、转换以及规范化等处理, 使其

能够适应后续分析和建模的需求。本文主要包括以下3个处理步骤: 数据清洗、数据规范化和数据变换。

数据清洗。首先需要进行数据清洗, 包括去除重复

数据、处理异常值、填充缺失值等。清洗后的数据能够减小分析误差,并提高后续处理的准确性。重复数据可以直接删除多余的记录;处理异常值时,对于单个或少量的异常值,也可以直接将其删除,为保证数据预测精准度可以将异常值替换成缺失值或者其他合理的值,例如使用平均值、中位数、众数等替换,直接将异常值替换成缺失值;关于缺失值的填补,由于观测数据 10 min 采集 1 次,采集时间比较相近,所以选取与缺失数据前后相邻的 2 个时刻数据做平均来对缺失值进行填补。

数据规范化。在进行数据建模前,需要对数据进行规范化,以便不同指标之间的比较和综合评价。规范化可以包括将数据进行标准化、归一化、离散化等操作。对经过数据清洗的数据作归一化处理,归一化处理可以将数据尺度缩小至 0~1,减少不同量纲和单位的影响,从而提高算法的效率和准确性,还能够减小模型的复杂度,避免模型出现过拟合的问题。归一化的公式如下:

$$x_{\text{new}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{14}$$

数据变换。时间滑窗设定为 5 天,即以 5 天的数据量作为输入,下一个 10 分钟温度数据作为输出,由此将多元时间序列数据变换为有监督的数据。

通过以上预处理,可以提高气象数据的质量和价值,为后续的模型预测提供更为可靠和准确的数据基础。

3.2 模型评估指标

为验证提出的模型的有效性,选取均方根误差 RMSE 和平均绝对误差 MSE 作为模型评估指标,两者公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{\text{pre}} - y_{\text{true}})^2} \tag{15}$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_{\text{pre}} - y_{\text{true}}| \tag{16}$$

其中, $N$  为选取的样本总数, $y_{\text{pre}}$  为预测值, $y_{\text{true}}$  为真实观测值。当 RMSE 和 MAE 越小,表明预测值与真实观测值间的差距越小,则证明模型预测的准确度越高。

3.3 模型实验结果与对比分析

本文基于改进的麻雀算法优化 DBN-LSTM,将 DBN-LSTM 网络结合并使用改进的麻雀算法进行优化组成了 ISSA-DBN-LSTM 多站点下的气温预测模型。实验过程中为验证 ISSA-DBN-LSTM 模型的预测性能,将 ISSA-DBN-LSTM 模型和单个模型 BP、DBN、LSTM 进行比对,以证明该模型提出的可行性和有效性。除此之外,为了表现本文组合模型的优越性,选取了深度置信网络、反向传播神经网络(BP)、DBN-BP 模型以及

DBN-LSTM 模型进行对比。

由于整个气象要素样本数巨大,为直观展示模型的效果,从测试集中选取连续的 200 条数据进行测试,ISSA-DBN-LSTM 模型与其他几种模型的 RMSE、MAE 值的测试结果如表 2 所示。

表 2 各模型测试结果

模型	RMSE	MAE
BP	1.993	2.473
DBN	1.816	1.451
LSTM	1.694	1.514
DBN-BP	1.282	1.211
DBN-LSTM	1.133	0.932
ISSA-DBN-LSTM	0.527	0.483

由表 2 可知,几种模型中单一模型 BP 效果最不理想,DBN 模型紧随其后,单模型中 LSTM 表现最好,说明 LSTM 模型在本文中适用于分析时间序列。但是单一的 LSTM 模型没有组合模型的效果好也说明了,LSTM 单模型对于长序列数据的特征提取能力还不够,从而造成预测精度较低问题。

接下来,将 ISSA-DBN-LSTM 模型的测试结果与没有经过改进的麻雀算法 SSA-DBN-LSTM 模型以及经过粒子群优化算法(PSO)优化的组合模型 PSO-DBN-LSTM 进行比对,进一步体现本文模型的正确性与优越性。随机抽取测试集中连续的 200 条数据,进行可视化展示,数据预测的结果对比如图 8~10 所示。




图 8 PSO-DBN-LSTM 模型测试结果




图 9 SSA-DBN-LSTM 模型测试结果




图10 ISSA-DBN-LSTM 模型测试结果

由图8~10可以看出, PSO-DBN-LSTM 模型在气温波动较小的地方预测效果没有 SSA-DBN-LSTM 和 ISSA-DBN-LSTM 模型好。这是由于 PSO 算法可能会出现早熟收敛或震荡现象, 导致算法无法得到全局最优解, 图8中100~150数据段以及175~200数据段其预测值和实际值的偏差都比较大。对于 SSA-DBN-LSTM 模型, 由于 SSA 算法没有经过改进, 所以在预测极大值时容易陷入局部最优解, 导致在极大值时预测的准确度不高。图9在样本数25和100附近, 明显极大值预测偏差较大。以上两种模型相较于本文的 ISSA-DBN-LSTM 模型, 明显本文的模型优越性较高, 在整个选取的200条数据上, 预测的气温值和真实气温值相当吻合, 说明 ISSA-DBN-LSTM 模型具有更加强大的时空特征提取能力, 针对多元时序的气象数据表现出更强的预测精度和泛化能力。以上3种模型的测试结果见表3。

表3 模型测试结果

模型	RMSE	MAE
PSO-DBN-LSTM	0.908	0.773
SSA-DBN-LSTM	0.716	0.680
ISSA-DBN-LSTM	0.527	0.483

## 4 结束语

首先介绍了 DBN、LSTM 以及改进的 SSA 算法, 提出一种基于改进的麻雀算法优化的皮尔逊积矩相关系数(PCC)-深度置信网络(DBN)-长短期记忆网络(LSTM)的多站点气温预测模型。使用皮尔逊积矩相关系数法进行特征选择, 减少不必要的神经元输入, 降低冗余信息。同时针对单个 LSTM 模型对于长序列数据的特征提取能力不足, 提出了使用 DBN 网络提前进行特征提取。针对 DBN-LSTM 组合模型的初始参数选择对性能影响较大的问题, 又将改进的麻雀算法来

对 DBN-LSTM 组合模型的初始参数选择进行优化, 并通过实验进行了模型的对比分析, 验证了本文模型的有效性。

实验中采用了四川某地区多站点的气温数据集, 并对比了单一模型和未进行优化的 DBN-LSTM 模型以及使用常用的粒子群算法优化的 DBN-LSTM 模型。通过对比实验结果可知, 本文提出的模型在预测精度上明显优于传统的气温预测模型。在误差评价指标方面, 本文所提出模型在均方根误差(RMSE)和平均绝对误差(MAE)方面都表现出较低的误差值, 说明其具有较好的预测效果。

致谢: 感谢四川省南充市科技局科研项目(22XCZX0005)对本文的资助

## 参考文献:

- [1] 王功明, 乔俊飞, 关丽娜, 等. 深度信念网络研究现状与展望[J]. 自动化学报, 2021, 47(1): 35-49.
- [2] 花凡, 李莉, 蔡鑫, 等. 长短期记忆网络在气温预测中的应用[J]. 智能计算机与应用. 2022, 12(11): 92-95+102.
- [3] 慎明俊, 高宏玉, 张守京, 等. 基于 DBN-LSTM 的滚动轴承剩余寿命预测模型[J]. 科学技术与工程. 2021, 21(31): 13328-13333.
- [4] 卿会, 郭军红, 李薇. 利用 SVM-LSTM-DBN 的短期光伏发电预测方法[J]. 华侨大学学报(自然科学版), 2022, 43(3): 371-378.
- [5] Wang Gongming, Li Wenjing, Qiao Junfei. Prediction of effluent total phosphorus using PLSR-based adaptive deep belief network[J]. CIESC Journal, 2017, 68(5): 1987-1997.
- [6] 常东峰, 南新元. 基于改进麻雀算法的深度信念网络短期光伏功率预测[J]. 现代电子技术, 2022, 45(17): 135-140.
- [7] 纪德洋, 金锋, 冬雷, 等. 基于皮尔逊相关系数的光伏电站数据修复[J]. 中国电机工程学报, 2022, 42(4): 1514-1523.
- [8] Wang Siying, Lin Xiaokun, Qi Xing. Research on Line Loss Prediction Method Based on Improved DBN Model[J]. Journal of Physics: Conference Series, 2022, 2395(1): 11-16.
- [9] 李新涛, 梁思聪. 基于并行深度信念网络的电力负荷预测[J]. 电力需求侧管理, 2022, 24(2): 54-58.
- [10] 沈皓俊, 罗勇, 赵宗慈, 等. 基于 LSTM 网络的

国夏季降水预测研究[J]. 气候变化研究进展, 2020,16(3):263-275.

[11] 石颀,杜国庆. 改进麻雀搜索算法优化 SVM 的方法及应用[J]. 计算机工程与设计,2023,44(3):954-961.

[12] 张华,龙呈,胡思洋,等. 基于层次聚类法与皮尔逊相关系数的配电网拓扑校验方法[J]. 电力系统保护与控制,2021,49(21):88-96.

PCC-DBN-LSTM Temperature Prediction Model based on Improved Sparrow Algorithm

WANG Dongmeng<sup>1</sup>, WEN Bin<sup>1</sup>, LI Xiaoyan<sup>2</sup>, XU Yue<sup>3</sup>, LIU Shuhui<sup>3</sup>, FU Shijun<sup>3</sup>  
(1. College of Communication Engineering, Chengdu University of information Technology, Chengdu 610225, China; 2. Huozhou Meteorological Bureau, Huozhou 031400, China; 3. Nanchong Meteorological Bureau, Nanchong 637000, China)

**Abstract:** Temperature prediction is an important research field in meteorology. With the development of meteorological technology, there is a need to improve the accuracy of temperature predictionurgently. To solve the poor effect of traditional temperature prediction algorithms and the insufficient ability to extract the spatiotemporal characteristics of meteorological data from multiple stations, a multi-station temperature prediction model based on the Pearson product-moment correlation coefficient (PCC) -Deep Belief Network (DBN) -Long Short-Term Memory Network (LSTM) optimized by the improved Sparrow algorithm was proposed. Firstly, Pearson correlation coefficients are used to select numerous meteorological parameters, DBN networks extract and reduce the dimensionality of input multi-site meteorological data, and LSTM modelspredict the extracted features. Due to the numerous initialization parameters of the model, an improved sparrow algorithm is proposed to optimize the parameters of the DBN-LSTM network, improving the prediction accuracy and stability of the model. Experiments show that the RMSE of the proposed model is 0.527, which is lower than that ofa single modeland other similar models.

**Keywords:** temperature prediction; pearson product-moment correlation coefficient; deep confidence network; improving the sparrow algorithm;long short-term memory network