

智能电网多变量太阳辐射预测：淘金优化双向 LSTM 网络的深度耦合智算

李东旭，张雪敏*

(西安思源学院工学院，陕西 西安 710038)

摘要 太阳能是化石能源的理想补充，而精确太阳辐射度预测是提高太阳能利用效率的重要手段。但受太阳能固有间接性和随机性的限制，获得有效的太阳辐射度预测结果一直是一个难题。本文提出一种基于淘金算法优化的双向长短期记忆神经网络（双向长短期记忆神经网络）的多变量太阳辐射度预测模型。首先，根据相关性分析选择影响因子（气温 $r=0.675$ 、太阳高度角 $r=0.397$ 、相对湿度 $r=0.743$ 、气压 $r=0.166$ ）优化模型输入；然后搭建卷积神经网络（卷积神经网络）用于特征提取，并运用淘金算法对模型进行优化；最后利用双向长短期记忆神经网络进行预测，以期为保障智能电网的安全运行和促进全球新能源发展提供参考。结果表明，该模型预测效果良好（ $R^2 > 0.99$ ， $RMSE < 0.26$ ），且泛化能力和鲁棒性强。

关键词 淘金优化；双向长短记忆网络；卷积神经网络

基金项目 本研究为陕西省大学生创新创业训练计划项目成果（项目编号：S202513121027）。

中图分类号 TM615；TM76；TP183

文献标志码 A

DOI 10.3969/j.issn.2097-3365.2026.22.005

0 引言

本文提出一种基于淘金算法优化的 CNN-BiLSTM 混合模型进行多变量太阳辐射度预测新方法。利用淘金算法代替遗传算法进行模型参数寻优，以克服单一遗传算法优化的局限性，同时利用卷积神经网络提取太阳辐射度多变量的空域特征以及双向长短时记忆神经网络充分挖掘太阳辐射度的双向时序特征，进而提高太阳辐射度预测精度和泛化能力，为保证光伏并网电源的高效、安全运行提供参考。

1 研究背景

在化石能源仍为主流能源的环境下，全球能源排放不断增加^[1]，发展太阳能等可再生能源迫在眉睫^[2]。虽然光伏发电技术成熟，但因光伏出力受太阳辐射度的不稳定影响而波动较大，故提高太阳辐射度预测的精度对于电网的安全稳定运行和能源调度有着重要意义。当前对于太阳辐射度的预测方法主要有持续方法、物理模型、统计学习方法、机器学习方法和混合模型，利用人工智能的混合模型预测精度相对较高。精准预测可有效提高光伏电站的利用效率和对光伏电站出力的辅助决策，在低碳减排、帮助各行业发展的同时实现目标。

2 数据处理

由于太阳辐射受多种因素影响，计算当中需要考虑大量指标，建立的数据模型复杂度较高，为了简化模型运算复杂度，提高模型精度，根据研究结果显示去除相关性较低的指标，选取相关性强的特征作为输入。而相关性分析是统计学中经常使用的一种分析手段，可以判断两个变量之间的线性关系强度及方向，从而判断变量之间的相互关系，并进一步分析这些变量之间的关系是否显著。

皮尔逊相关系数是用于度量两组数据 X 、 Y 之间的相关性，皮尔逊相关系数不受变量的位置和测量尺度影响，被广泛应用于新能源功率预测领域的清洗、特征分析、降维、相似日提取等。皮尔逊相关系数的公式如下：

$$\rho = \frac{\text{cov}(X, Y)}{\sigma_x \sigma_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式(1)中， $\text{cov}(X, Y)$ 表示 X, Y 的协方差， σ_x 、 σ_y 分别表示两个变量的标准差。 $\bar{x}$ 、 $\bar{y}$ 分别表示 X, Y 的均值 n 表示输入的时间序列的长度， ρ 表示了变量之间的相关程度，越大表示相关性越大，若为负数则表示为负相关。

作者简介：李东旭（2004-），男，本科，研究方向：智能电网场景作用下的多变量太阳辐射高精度预测。

***通信作者**：张雪敏（1981-），女，硕士研究生，副教授，研究方向：声学（超声学）。E-mail: xue0314min@163.com

进行相关性分析计算相关性系数之后,需要对相关性系数进行显著性检验,以判断变量间的关系是否显著。显著性检验就是统计学中判断观察到的效果是否真实存在的一个常用方法。在进行显著性检验过程中,需要选定一个显著性水平,一般取 0.05 或 0.01。若检验表明变量间的关系是显著的,则认为该关系是真实存在的。

根据计算分析可知,与 GHI 相关的指标有温度、太阳高度角、相对湿度及相对压力等,它们的相关系数分别为 0.675、0.397、0.743、0.166,说明上述几个因素是影响太阳辐射的主要因素,故为了降低计算量,选取相关系数较大的几个指标进行计算。

3 基于淘金算法优化神经网络的多变量太阳辐射预测

3.1 淘金优化算法

淘金算法 (Gold Rush Optimizer) 是模仿淘金热中淘金的人在河床寻找黄金而得到启发的一种智能优化算法,它通过不断地改变搜索位置和搜索方式以逐渐接近最优值。将优化问题类比为寻矿过程,在此过程中,淘金算法中搜索代理“淘金者”在解空间内通过勘探和开采,最终发现全局最优值。

探矿者的角色和粒子群算法以及遗传算法中的粒子群是相似的。探矿者所占位置信息存放在一个叫 MGP 的矩阵中,如式(2)所示, x_{nd} 表示第 n 个探矿者第 d 个维度的位置, d 表示维数, n 表示探矿者个数。

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

在优化过程中需要一个目标函数来评价找矿者,根据式(3)将找矿者的评价价值存储在评价矩阵 MF 中。式(3)中, x_{nd} 为找矿者 n 在第 d 维的位置, f 为评价函数。

$$M_F = \begin{bmatrix} f(x_{11} & x_{12} & \cdots & x_{1d}) \\ f(x_{21} & x_{22} & \cdots & x_{2d}) \\ \vdots & \vdots & \ddots & \vdots \\ f(x_{n1} & x_{n2} & \cdots & x_{nd}) \end{bmatrix} \quad (3)$$

像发现金矿的淘金者一样,执行启发式算法时,最佳的“金矿”位置也就是搜索空间的最优值。由于其准确位置不明,目前找矿人探测的最佳金矿位置就作为最佳金矿位置的近似值。

为了模拟探矿者向金矿迁移的这种行为,可以用公式(4)和(5)来表示金矿以及探矿者所处位置的变迁。

$$\vec{D}_1 = \vec{C}_1, \vec{X}^*(t) - \vec{X}_i(t) \quad (4)$$

$$\vec{X}_{new_i}(t+1) = \vec{X}_i(t) + \vec{A}_1 \cdot \vec{D}_1 \quad (5)$$

式(4)、(5)中, X 和 t 分别为最佳金矿的位置,金矿探矿者 i 的位置,当前迭代 t 。 X_{new} 为金矿 i 的新位置, A_1 和 D_1 可表达为:

$$\begin{aligned} \vec{A}_1 &= 1 + l_1 \left(\vec{r}_1 - \frac{1}{2} \right) \\ \vec{C}_1 &= 2\vec{r}_2 \end{aligned} \quad (6)$$

式(6)中 r_1 和 r_2 为随机向量,取值范围为 $[0, 1]$ 。1是由式(7)定义的收敛分量;如果 e 等于1,它从2到1个 $\max_{iter}$ 线性减小,对于大于1的值,它非线性减小。

$$l_e = \left(\frac{\max_{iter} - iter}{\max_{iter} - 1} \right)^e \left(2 - \frac{1}{\max_{iter}} \right) + \frac{1}{\max_{iter}} \quad (7)$$

将淘金者向假定的金矿移动的过程数学建模为向量 A_1 的运算。若采用式(5)中的向量 A_1 进行迁移数学建模,则当向量 A_1 的值为1时,意味着导引头正朝着假定的金矿移动;当向量 A_1 取值小于1时,表示导引头当前位置在假定的金矿之前方,即向假定的金矿移动;当向量 A_1 取值大于1时,表示导引头当前位置在假定的金矿之后方,即远离假定的金矿移动。

在金矿勘探的数学模型中,可将每个勘探者的坐标近似看成是金矿所在地的近似坐标,这已经被考虑到了与金矿开采有关的数学关系中。

$$\begin{aligned} \vec{D}_2 &= \vec{X}_i(t) - \vec{X}_r(t) \\ \vec{X}_{new_i}(t+1) &= \vec{X}_i(t) + \vec{A}_2 \cdot \vec{D}_2 \end{aligned} \quad (8)$$

在式(9)所示的对勘探者位置更新的条件当中,若评估函数的目标函数有所提升,则表示对金矿勘探者而言,其改变位置比留守原地更能采集到更多的金矿;反之,若评估函数的目标函数未改进,则表示该勘探者留守在原来位置。

$$\vec{X}_i(t+1) = \vec{X}_{new_i}(t+1) \text{ if } f(\vec{X}_{new_i}(t+1)) < f(\vec{X}_i(t)) \quad (9)$$

基于前面相关概念,GRO 算法从随机放置在搜索空间中的探矿者初始种群开始。将搜索得到的最优解作为最佳金矿的位置(全局最优)。每个勘探者在每次迭代中使用迁移、金矿开采和协作方法中的一种获取新的位置。如果新位置的黄金数量(目标函数的值)大于当前位置(最小化时目标函数减少,最大化时目标函数增加),探矿者移动到新位置;这个过程一直持续到迭代循环结束。到目前为止找到的最佳解被认为是算法的最终解。

3.2 卷积神经网络

卷积神经网络(CNN)是针对图像、具有空间结构数据处理提出的一种深度学习神经网络模型,它是模

拟人脑视觉机理而提出的。与全连接神经网络不同, CNN 通过在输入数据上进行卷积操作来提取局部信息, 并通过训练过程学习卷积操作的参数。卷积神经网络主要由卷积层、采样层、池化层和全连接层构成, 如图 1 所示。




图 1 卷积神经网络结构示意图

2. 池化层 (Pooling Layer): (1) 用于降采样, 减少特征图的空间尺寸, 降低计算量并增强模型鲁棒性; (2) 常用最大池化 (Max Pooling), 保留局部最显著特征, 抑制冗余信息。

3. 全连接层 (Fully Connected Layer): (1) 整合卷积层和池化层提取的特征, 通过全局连接实现分类或回归预测; (2) 作用类似于传统神经网络, 对高阶特征进行非线性组合以输出最终结果。

CNN 可有效提取太阳辐射数据的时空特征, 适用于高精度预测任务。

3.3 长短期记忆网络

长短期记忆网络 (LSTM)^[3] 是循环神经网络 (RNN) 的改进架构, 通过引入门控机制 (遗忘门、输入门、输出门) 和细胞状态, 有效解决了传统 RNN 的梯度消失 / 爆炸问题。该结构能够更好地建模长序列数据中的长期依赖关系, 在时序预测、自然语言处理等任务中表现优异。相关的计算见式 (10):

$$\begin{aligned} f(t) &= \sigma(W_f h_{t-1} + U_f X_t + b_f) \\ i(t) &= \sigma(W_i h_{t-1} + U_i X_t + b_i) \\ c(t) &= \tanh(W_c h_{t-1} + U_c X_t + b_c) \\ o(t) &= \sigma(W_o h_{t-1} + U_o X_t + b_o) \end{aligned} \quad (10)$$

3.4 混合算法

构建基于淘金算法优化神经网络的多变量太阳辐射预测模型^[4]。模型结构参数设置如下: (1) 输入特征维度为 9, 时间步长为 8; (2) 采用单卷积层结构, 不设池化层; (3) CNN-LTM-I 模块使用 1×3 卷积核, 通道数为 32; (4) 卷积步长为 1, 不进行零填充。

模型首先对原始时间序列进行特征提取, 随后通

1. 卷积层 (Convolutional Layer): (1) 由多个可学习的滤波器 (卷积核) 构成, 通过在输入数据上滑动进行局部特征提取, 生成特征图; (2) 不同滤波器可检测边缘、纹理等低级特征, 多层堆叠后可学习更高级的抽象特征。

过预测算法完成序列预测, 并采用淘金算法进行参数优化。

4 结果与讨论

4.1 测试结果

利用淘金算法优化神经网络的多变量太阳辐射预测^[5] 利用其训练集对数据进行预测, 其结果如图 2 所示。通过对测试集数据进行预测, 得到了测试集预测数据与真实数据的对比图, 根据图 2 可以看出, $R^2 > 0.99$, 其 RMSE 为 0.2 533 说明预测的效果较好, 真实值与预测值偏差不大。

4.2 误差分析

误差分析是反映预测效果好坏的重要因素。RMSE 被认为是评价点预报误差最广泛使用的方法, 它通常对测量值与预测值之间的较大偏差更为敏感。

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{I}(t) - I(t))^2} \quad (11)$$

式 (11) 中, MAE 表示测量值与预测值之间的平均距离。

$$MAE = \frac{1}{N} \sum_{t=1}^N |\hat{I}(t) - I(t)| \quad (12)$$

测试集上对测试的误差进行分析, 带入数据得误差范围在 $[-0.4 \sim +0.5]$ 之间, 预测的误差小于 1, 误差百分比比较小, 其预测效果也较好。

在对模型进行训练的过程中, 随着迭代次数的增加, 损失值不断下降, 在 25 轮迭代时损失值达到稳定。RMSE 随着迭代次数的增加, 也不断下降, 其在 50 轮左右达到稳定状态, 在 0.1 附近, 说明仅需要训练 50 轮




图 2 训练集预测结果对比图

就可以得到理想的参数数据,过多的训练将增加运算的复杂度。

5 模型的优缺点

5.1 模型的优点

双向长短期记忆网络即双向 LSTM (BiLSTM), 是两个方向的 LSTM 网络的组合, 分别从前向后以及从后向前对序列进行处理, 双向 LSTM 通过同时利用序列数据的前向和后向信息, 比单向的 LSTM 模型能够更加充分地提取序列数据的上下文信息, 有利于模型对序列数据内容理解能力的提升。所以, 相较于单向 LSTM 模型, 双向 LSTM 可以充分利用序列数据的信息, 对序列数据的建模效果有更好的帮助, 也因为双向的结构, 可以减轻传统 LSTM 模型中遗忘历史信息的缺点。

5.2 模型的缺点

双向 LSTM 通过同时学习输入序列的正向和反向信息, 从而捕捉输入序列的双向依赖关系, 相比单向 LSTM 具有更多的模型参数和隐藏状态, 所以双向 LSTM 的训练和预测往往需要更多的计算资源和时间。

6 结束语

本研究所提出的双向 LSTM 淘金算法优化的深度耦合智算模型可以较好地进行太阳能光伏发电系统的太阳辐射预测, 利用相关性分析对影响太阳辐射的气象因子进行筛选, 通过卷积神经网络 (CNN) 提取空间特

征, 以淘金算法 (GRO) 自动搜索优化神经网络的超参数等方法, 有效提高了太阳辐射预测精度, 预测模型具有较好的稳定性, 对训练数据集和测试数据集的 R^2 均大于 0.99, RMSE 均小于 0.26, 明显优于传统的统计方法。下一步工作是降低神经网络模型的计算复杂度, 尝试更为轻量化的网络模型, 并结合多气象数据源和遥感卫星云图数据进行融合, 以期达到更长时间尺度、更高分辨率的太阳辐射预测, 为保障新型电力系统的安全和经济调度运行提供更加可靠的技术手段。

参考文献:

- [1] 国际能源署.2021 年全球能源展望:二氧化碳排放[R].巴黎:国际能源署,2021.
- [2] 张华,冯超,周小敏.中国实现碳中和:低碳城市试点政策能否提升碳排放效率?[J].可持续生产与消费,2022(33):312-329.
- [3] 库玛丽 P,托什尼瓦尔 D.基于长短期记忆-卷积神经网络的深度混合太阳辐射度预测方法[J].应用能源,2021(295):117061.
- [4] 斯里瓦斯塔夫 S,萨迪斯塔普 S.用于短期太阳辐射度预测的混合 CNN-BiLSTM 模型[J].电气与电子工程师协会接入,2021(09):76070-76080.
- [5] 吉米尔 S,迪奥 R C,唐斯 N J,等.基于遗传算法优化混合人工神经网络的全球太阳辐射预测[J].可再生能源,2021(171):1056-1075.