

doi: 10.7690/bgzd.2025.11.019

基于 RSJSO_BiLSTM 的高精度降雨预测模型研究

陈 亮, 沈 吉

(浙江省大气探测技术保障中心, 杭州 310018)

摘要: 为提高降雨预测的准确性和效率, 提出一种基于双向长短期记忆网络 (bi-directional long short-term memory, BiLSTM) 和鼠群水母群优化算法 (rat swarm and jellyfish search optimizer, RSJSO) 的降雨预测模型。利用缺失数据插补和特征融合技术对降雨数据进行预处理, 通过弦距离和基于骑手优化算法的神经网络 (rider optimization algorithm-based neural network, RideNN) 优化特征提取过程, 并采用过采样技术增强数据集。实验结果表明: 该模型在多种评估指标上表现突出, 能够为相关决策提供可靠的精细化降雨信息支撑, 有效增强复杂场景下的突发事件响应能力。

关键词: 深度学习; 降雨预测; BiLSTM; RideNN; JSO

中图分类号: TP183 **文献标志码:** A

Research on High-precision Rainfall Prediction Model Based on RSJSO_BiLSTM

Chen Liang, Shen Ji

(Zhejiang Atmosphere Observation Technical Support Center, Hangzhou 310018, China)

Abstract: In order to improve the accuracy and efficiency of rainfall forecasting, a network based on bi-directional long short-term memory (BiLSTM) and rat swarm and jellyfish search optimizer (RSJSO) is proposed. The rainfall data is preprocessed by using missing data interpolation and feature fusion technology, and the feature extraction process is optimized by chord distance and based on rider optimization algorithm and based neural network (RideNN). Oversampling techniques are used to enhance the dataset. The experimental results show that the model performs well in a variety of evaluation indicators, and can provide reliable support for the relevant decision-making of refined rainfall information, and effectively enhance the ability to respond to emergencies in complex scenarios.

Keywords: deep learning; rainfall prediction; BiLSTM; RideNN; JSO

0 引言

降雨的形成源于非线性动态多尺度环流系统的作用, 是区域大气环流、热力效应与地形地貌特征相互耦合的结果。作为人类社会存续的基础性要素, 其发生频率与强度不仅关乎民生福祉, 而且对军事行动的规划与执行具有决定性影响, 例如野外作战部署、装备三防保障、战术机动路线选择等, 均需以精准的降雨预测为前提。作为水文循环的核心环节, 降雨的建模与预测不仅支撑水资源管理、农业灌溉等民生领域, 而且是军事气象保障的核心任务, 直接影响部队的战场适应力与任务达成率。气象与气候条件的动态变化是驱动降水事件的主要因素, 而全球气候变化引发的区域降雨量失衡, 进一步凸显了高精度降雨预测的战略价值。对军事领域而言, 准确预判降雨可有效降低装备故障风险、规避野外行动中的水文灾害, 保障作战人员安全与任务连贯

性。尽管现有模型通过线性、非线性等多种结构设计提升预测精度, 但如何在精简输入数据的同时实现高效预测, 仍是减少军事行动中突发降雨损失的关键。

降雨预测的难点在于多变性和不可预测性, 主要方法包括基于历史数据的经验方法和基于大气模拟的动力方法^[1]; 近年来, 元启发式优化算法被用于模拟水资源问题, 深度学习通过无监督训练的多层设计学习数据非线性表示^[2], 其主要类型如深度神经网络 (deep neural network, DNN)、循环神经网络 (recurrent neural network, RNN)、人工神经网络 (artificial neural network, ANN)、卷积神经网络^[3] (convolutional neural networks, CNNs)。准确的降雨预测对水资源管理至关重要。现有模型存在计算耗时问题, 而长短期记忆网络 (long short-term memory, LSTM)、生成对抗网络 (generative adversarial network, GAN) 等技术能高效处理大量

收稿日期: 2024-10-12; 修回日期: 2024-11-18

第一作者: 陈 亮 (1981—), 男, 江苏人, 硕士。

数据, 其中 LSTM 在水文领域表现突出, 可解决预测问题^[4]。

降雨预测的及时性和精确性直接影响民生。现有模型依赖复杂统计方法, 计算成本高且实用性有限, 故需探索机器学习与时间序列数据结合的方案。Venkatesh 等结合 LSTM 与 GAN 进行降雨预测^[5], 对季节性和年度降雨的预测精度有所提升, 但训练耗时耗资源。Ananth^[6]设计卷积长短期记忆网络(convolutional long short-term memory, ConvLSTM)用于农业降雨预测, 其 MapReduce 框架处理海量数据效率较高, 但仅适用于印度。Piyush^[7]等提出的多变量卷积长短期记忆网络(multivariate convolutional long short-term memory, MVC-LSTM)能捕捉时空相关性及变量相互作用, 但受 LSTM 模型噪声和复杂性影响, 预测仍具挑战性。

国内研究学者对中国不同区域降雨进行预测研究。李遥^[8]对 CNNs 模型和 LSTM 模型组合成深度学习模型, 并基于孔雀算法对 CNN-LSTM 模型进行了优化, 可精度较高的预测西南地区极端降水事件。宋毅等^[9]提出用于短时降雨预测的新型全卷积网络(pre-predicted precipitation now-casting network, PpNet), 其核心包括预先预测辅助结构(pre-prediction auxiliary inference, PPAI)和特征约束器(temporal features constraint, TFC)。研究数据表明, 该网络对全卷积网络的性能有明显改善, 但全卷积网络自身无法主动提取时序信息仍未得到解决。郭杨^[10]提出对 BP 神经网络结合粒子群优化算法(particle swarm optimization, PSO), 引入多种优化参数以及数据预处理方式构建预测模型, 针对福建省内的降雨预测有较好的预测能力。

笔者利用双向长短期记忆网络(BiLSTM)深度学习模型进行降雨预测, 通过结合鼠群优化算法(rat swarm optimizer, RSO)和水母搜索优化算法(jellyfish search optimizer, JSO)形成的鼠群水母群优化算法(RSJJO)创新其训练过程。以浙江杭州历史天气数据集为基础, 经缺失值插补、去噪等预处理后, 提取技术指标, 利用基于骑手优化算法的神经网络(RideNN)和弦距离技术进行特征融合, 结合过采样增强数据, 最终通过 RSJJO 训练的 BiLSTM 实现预测。核心贡献为开发用于降雨预测的 RSJJO_BiLSTM 模型, 通过 JSO 与 RSO 结合形成的 RSJJO 训练 BiLSTM, 以提高预测精度。该组合优化算法在解决预测相关优化问题时具有高准确性

和效率。

1 用于降雨预测的 RSJJO_BiLSTM

笔者基于时间序列数据, 提出 RSJJO_BiLSTM 进行降雨预测。对输入的时间序列数据采用缺失数据插补进行预处理, 提取技术指标。采用 RideNN 和弦距离进行特征融合, 并采用过采样进行数据增强以提高数据质量。将这些数据用于降雨预测, 预测通过 BiLSTM 实现。该 BiLSTM 由 RSJJO 训练, RSJJO 是通过结合 RSO 和 JSO 设计而成。所提模型系统如图 1 所示。




图 1 RSJJO 增强的 BiLSTM 降雨预测

1.1 数据获取

笔者使用浙江杭州历史天气数据集^[11], 从中获取输入时间序列数据。数据集 R 包含多个数据, 如式(1)所示:

$$R = \{R_1, R_2, \dots, R_x, \dots, R_\delta\}。 \quad (1)$$

式中: R 为降雨数据集; R_x 为第 x 个位置的数据; δ 为数据集中的数据总数。这里, R_x 为输入序列数据, 将进一步进行预处理。

数据预处理在确保降雨预测数据质量方面起着至关重要的作用, 用于去除输入数据中的无用噪声。通过 2 种方法处理缺失数据: 1) 用数据点的平均值替换数值型值; 2) 用最常见的类别替换分类型值。数值型缺失值用该属性值的平均值插补, 而分类型数据则用最频繁出现的类别替换。因此, 插补后的数据 R_x 是预处理阶段的最终输出。

1.2 技术指标提取

预处理阶段得到的插补数据 R_x 将用于提取技术指标。这里涉及的各种技术指标包括相对强弱指数(relative strength index, RSI)、线性回归斜率(linear regression model, LRM)、三重指数移动平均值(triple exponential moving average, TRIX)、威廉指标(Williams percentage range, WillR)、双指数移动平均(double exponential moving average, DEMMA)、威尔斯·怀尔德平滑平均(Welles Wilder

smoothing, WWS)、终极振荡器 (ultimate oscillator, ULTOSC) 和移动平均收敛散度 (moving average convergence divergence, MACD)。提取的技术指标以 $(v \times w)$ 维的向量形式表示, 如式(2)所示:

$$\kappa_{\chi} = \{\kappa_1, \kappa_2, \dots, \kappa_8\}. \quad (2)$$

式中: κ_1 为 RSI; κ_2 为 LRM; κ_3 为 TRIX; κ_4 为 WillR; κ_5 为 DEMA; κ_6 为 WWS; κ_7 为 ULTOSC; κ_8 为 MACD。

1.3 基于 RideNN 和弦距离的特征融合

RideNN^[12] 的网络包括输入层、隐藏层和输出层, 每层由多个神经元组成, 输入向量是基于巴氏系数的特征向量。不同层的神经元通过将一个神经元的输出连接到另一个神经元的输入来实现连接, 如式(3)所示:

$$t^m = \{t_1^m, t_2^m, \dots, t_{\vartheta}^m, \dots, t_{\sigma}^m\}; 1 \leq \vartheta \leq \sigma. \quad (3)$$

网络各层神经元的权重分配用于实现预测。隐藏层神经元的权重分配如式(4)所示:

$$Y = \{Y_1, Y_2, \dots, Y_{\sigma}\}. \quad (4)$$

可以假设, 产生电势的隐藏层神经元具有偏置 $Y_{\sigma+1}$ 。输出层神经元也有权重, 表示为 $Y_{\sigma+2}$, 输出层的偏置为 $Y_{\sigma+3}$ 。分类器输出由传递函数表示, 如式(5)所示:

$$z^m = Y_{\sigma+2} * \left[\log \text{sig} \left(\sum_{\vartheta=1}^{\sigma} t_{\vartheta}^m * Y_{\vartheta} + Y_{\sigma+1} \right) \right] + Y_{\sigma+3}. \quad (5)$$

式中: $\log \text{sig}$ 为对数 sigmoid 传递函数; t_{ϑ}^m 为第 ϑ^h 个神经元的输入; Y_{ϑ} 为隐藏层第 ϑ^h 个神经元的权重; $Y_{\sigma+2}$ 为输出权重; $Y_{\sigma+1}$ 和 $Y_{\sigma+3}$ 为偏置。

融合后的特征表示为 Z_{χ} , 维度为 $(v \times u)$, 其中 $u < w$ 。RideNN 架构如图 2 所示。




图 2 RideNN 架构

1.4 通过过采样进行数据增强

融合后的特征 Z_{χ} 将进行数据增强, 通过过采样技术实现。设从特征融合过程中获取的数据大小为 $(v \times u)$ 。这里, 将该数据增加到 $(o \times u)$, 使得 $u < o$ 且 $v < o$ 。这意味着通过对数据进行过采样, 将 v 增加到 o 。在过采样过程中, 确定每列的最大值和最小值, 并在该区间内随机生成平衡样本。增强后的数

据表示为 W_{χ} , 维度为 $(o \times u)$ 。

2 利用 BiLSTM 进行降雨预测

笔者利用 BiLSTM^[13], 从增强数据 W_{χ} 中预测降雨。该 BiLSTM 由混合优化算法 RSJSO 训练。RSJSO 是结合了 RSO 和 JSO 的优化算法。

2.1 BiLSTM 的架构

BiLSTM 是为解决 LSTM 网络问题而设计的网络^[14-15]。该架构由 2 个 LSTM 网络组成, 一个 LSTM 用于前向传播, 另一个用于反向传播。BiLSTM 将 2 个网络的结果组合成一个大向量, 从而对任何边缘左右两侧的数据进行编码。

$$\text{BiLSTM}(\zeta_{1:H}, N) = \text{LSTM}_E(\zeta_{1:N}) \circ \text{LSTM}_I(\zeta_{H:N}). \quad (6)$$

式中 $\text{LSTM}_E(\zeta_{1:N})$ 接收输入向量 $(\zeta_{1:N})$ 作为从左到右的序列, 然后在位置 N 输出。此外, 网络基于左侧在位置 N 对整个序列的信息进行编码。研究结果表明, 双 LSTM 的使用有助于实现更好的降雨预测。

2.2 RSJSO 训练 BiLSTM

RSJSO 是一种混合优化算法, 用于训练 BiLSTM。RSJSO 结合了 JSO 和 RSO。JSO 的灵感来自水母的行为, 包括它们在洋流中的运动、群体动态、时间控制机制以及它们所处的边界条件。在各种基准函数和实际应用中, JSO 的性能优于许多流行的元启发式算法, 具有更好的收敛搜索能力, 速度更快, 参数更少^[16]。同样, RSO 是一种创新性的仿生优化算法, 其灵感来源于野生老鼠的追逐和攻击行为, 具有较好的收敛行为, 并在时间和空间复杂度方面突出了计算复杂性^[17]。

RSJSO 的算法流程详细说明如下: 初始化是算法流程的起始阶段, JSO 种群通常随机初始化。为“水母种群”设定初始个体位置、数量等基础参数; 通过式(7)进行适应度评估, 依据特定公式衡量“水母个体”在解空间中位置的优劣:

$$B = \frac{1}{\delta} \sum_{\chi=1}^{\delta} [T_{\chi}^* - B_{i_{\chi}}]^2. \quad (7)$$

式中: B 为适应度函数; $B_{i_{\chi}}$ 为 BiLSTM 输出; δ 为处理样本; T_{χ}^* 为目标输出。

完成评估后开始计算食物量, 模拟水母觅食场景, 确定不同解空间点的食物量; 基于食物量结果, 找到食物最多位置的水母, 筛选出当前种群里处于优质位置的个体; 之后进行时间控制机制计算, 引入时间维度逻辑, 为后续运动决策提供依据。为了

模拟这种行为, 采用了时间控制机制, 该机制利用了时间控制函数 $X(d)$ 和常数 x_0 。时间控制函数如式(8)所示:

$$X(d) = \left\lfloor \left(1 - \frac{d}{\max iter} \right) \times (2 \times \text{rand}(0,1) - 1) \right\rfloor. \quad (8)$$

式中: $X(d)$ 为时间控制函数; x_0 为常数, 等于 0.5; d 为时间或迭代次数; $\max iter$ 为最大迭代次数。当 $X(d) > x_0$ 时, 水母跟随洋流; 当 $X(d) < x_0$ 时, 水母在群体内移动; 当水母在群体内移动时, 再次判断 $\text{rand}(0,1) > (1-X(d))$, 满足条件时水母被动运动, 以相对缓慢方式调整位置, 不满足则水母主动运动, 快速探索新区域; 最后判断 RSJSO 终止以找到训练 BiLSTM 的最优解, 通过评估式(7)所述的适应度方程得到该最优解。

3 结果与讨论

3.1 实验设置

基于 RSJSO 的 BiLSTM 在 Python 工具中实现, 使用浙江杭州历史天气数据集。表 1 显示了本研究中使用的参数值。

表 1 数据集参数

参数	值
迭代次数	5
批数	32
学习率/%	0.1


3.2 数据集处理

该研究使用浙江杭州历史天气数据集^[11], 要预测的目标变量是“明天是否下雨”。该数据集提供了杭州历史天气的逐小时数据, 包括温度、降水、风向、风速、气压、湿度等。


3.3 性能分析

图 3 描述了所提出的 RSJSO_BiLSTM 在不同训练数据下的性能评估。图 3(a)展示了所提出方法的均方误差 (mean squared error, MSE) 评估结果, 对于 50% 的训练集, RSJSO_BiLSTM 在迭代 10、20、30 和 40 时的均方误差分别为 0.976、0.773、0.606 和 0.498。图 3(b)描述了基于均方根误差 (root mean squared error, RMSE) 的性能分析, 对于 60% 的训练集, RSJSO_BiLSTM 在迭代 10、20、30 和 40 时的均方根误差值分别为 0.892、0.836、0.766 和 0.602。图 3(c)展示了基于平均绝对百分比误差 (mean absolute percentage error, MAPE) 的性能分析, 对于 70% 的训练集, RSJSO_BiLSTM 在迭代 10、


20、30 和 40 时的平均绝对百分比误差分别为 0.659、0.601、0.493 和 0.296。图 3(d)说明了基于相对绝对误差 (relative absolute error, RAE) 的性能分析, 对于 70% 的训练集, RSJSO_BiLSTM 在迭代 10、20、30 和 40 时的值分别为 0.282、0.193、0.132 和 0.023。




(a) RSJSO_BiLSTM 不同迭代次数均方误差



(b) RSJSO_BiLSTM 不同迭代次数均方根误差



(c) RSJSO_BiLSTM 不同迭代次数平均绝对百分比误差




(d) RSJSO_BiLSTM 不同迭代次数相对绝对误差


图 3 RSJSO_BiLSTM 的曲线性能评估

图 4 提供了所提方法的箱线图。图 4(a)描述了 MSE 分析, 所提出的 RSJSO_BiLSTM 模型在迭代 10、20、30 和 40 时的中值分别为 0.631、0.564、0.425 和 0.208。图 4(b)展示了基于 RMSE 的所提出


RSJSO_BiLSTM 的箱线图分析, 所提出的 RSJSO 在迭代 10、20、30 和 40 时的中值分别为 0.795、0.753、0.652 和 0.459。图 4(c)通过箱线图表示所提出的 RSJSO 模型的 MAPE 分析, RSJSO 模型在迭代 10、20、30 和 40 时的中值分别为 0.659、0.601、0.493 和 0.293。图 4(d)通过箱线图说明了 RAE 分析, 所提出的模型在迭代 10、20、30 和 40 时的中值分别为 0.432、0.359、0.242 和 0.086。




(a) RSJSO_BiLSTM 不同迭代次数均方误差



(b) RSJSO_BiLSTM 不同迭代次数均方根误差



(c) RSJSO_BiLSTM 不同迭代次数平均绝对百分比误差



(d) RSJSO_BiLSTM 不同迭代次数相对绝对误差

图 4 RSJSO_BiLSTM 的箱式图性能评估

4 结论

笔者基于时间序列数据, 开发一种高效的 RSJSO_BiLSTM 降雨预测技术。其中, BiLSTM 由

RSJSO 训练。对输入的时间序列数据应用缺失数据插补以去除噪声。从预处理后的数据中提取多种技术指标, 以显示降雨随时间的平均预测情况。此外, 借助 RideNN 和弦距离实现特征融合过程, 性能更优且计算复杂度更低。采用过采样技术对融合特征进行数据增强, 以生成最终的降雨预测。笔者将 RSO 和 JSO 等优化器相结合, 形成 RSJSO, 用于评估所提出策略性能的 MSE、RMSE、MAPE 和 RAE 等指标的最小值分别为 0.208、0.459、0.293 和 0.023, 表明该技术在降雨预测方面表现突出。

参考文献:

- [1] AGBOOLA A H, GABRIEL A J, ALIYU E O, et al. Development of a fuzzy logic based rainfall prediction model[J]. Int J Eng Technol, 2013, 3(4): 427-435.
- [2] WEI C C, HUANG T H. Modular neural networks with fully convolutional networks for typhoon-induced short-term rainfall predictions[J]. Sensors, 2021, 21(12): 4200.
- [3] 王军, 陈百艳, 程勇. 基于多任务长短时卷积网络的降雨预测[J]. 计算机工程与设计, 2022, 43(9): 2686-2693.
- [4] 赵玉, 陈丽霞, 梁梦姣. 基于 LSTM-TCN 模型的降雨型滑坡时间概率预测及气象预警建模[J]. 地质科技通报, 2024, 43(2): 201-214.
- [5] VENKATESH R, BALASUBRAMANIAN C, KALIAPPAN M. Rainfall prediction using generative adversarial networks with convolution neural network[J]. Soft Comput, 2021, 25(6): 4725-4738.
- [6] ANANTH J P. MapReduce and optimized deep network for rainfall prediction in agriculture[J]. Computer J, 2020, 63(6): 900-912.
- [7] PIYUSH K P, ACHYUTHA P N, CHETANA S, et al. Pre-diction of Rainfall in Karnataka Region using optimised MVC-LSTM Model[C]. IEEE International Conference on Integrated Circuits and Communication Systems (ICICACS), India, 2023: 1-8.
- [8] 李遥. 基于优化深度学习的西南地区极端降雨事件预测模型构建[J]. 水资源开发与管理, 2024, 10(4): 64-70.
- [9] 宋毅, 张晗奕, 孙丰, 等. PpNet: 基于预先预测的降雨短时预测模型[J]. 电子与信息学报, 2024, 46(2): 492-502.
- [10] 郭杨. 基于 PSO 优化 BP 神经网络的 GNSS PWV 和气象数据的尾矿库降雨预测研究[J]. 福建冶金, 2023, 52(5): 24-30.
- [11] METEOBLUE. 浙江杭州历史天气 [EB/OL]. [2025-08-01]. https://www.meteoblue.com/en/weather/week/hangzhou_china_1808926.
- [12] BINU D, KARIYAPPA B S. RideNN: a new rider optimization algorithm-based neural network for fault

- diagnosis in analog circuits[J]. IEEE Trans Instrum Meas, 2018, 68(1): 2–26.
- [13] DO X C, DAO M H, NGUYEN H D. APT attack detection based on flow network analysis techniques using deep learning[J]. Intell Fuzzy Syst, 2020, 39(3): 4785–4801.
- [14] 蔡子龙, 李嘉棋, 沈赋, 等. 基于 SDAE-EEMD 降噪分解与改进 Informer-BiLSTM 模型的电力短期负荷预测方法[J/OL]. 电网技术, 1-16[2025-09-10]. <https://link.cnki.net/urlid/11.2410.tm.20250716.1903.009>.

(上接第 66 页)

设备性能的安全性、可靠性高于经济性。由于备件无法及时到货或者排除故障耗时间很长, 耽误型号试验, 造成的损失和影响很大; 因此, 对一些关键设备, 必须提出安全性、可靠性要求以及充分备份。

新技术在不断更新发展, 旧设备在不断淘汰, 设备性能完善无止境, 这就要求设备操作使用者, 要不断地详细记录使用过程中出现的各种偶然、必然的各类问题, 以便后来者进一步更新完善设备。

(上接第 90 页)

4 结论

笔者提出一种基于多传感器融合和改进 EfficientNetV2-B0 的电机故障诊断方法, 主要贡献:

- 1) 实现了多模态传感器的信号的像素级融合, 使得多源融合数据具有丰富而全面的异常特征。
- 2) 在 EfficientNetV2-B0 中引入 DSConv 和 EMA 模块, 在保持特征提取精度的同时降低神经网络中卷积层的计算成本, 将注意力集中在更敏感的特征上。
- 3) 提出模型参数量低的改进 EfficientNetV2-B0 迁移学习模型, 从多传感器融合数据中学习具有代表性的故障特征, 实现故障识别。

笔者采用多种不同的基于 CNN 的深度学习架构进行对比。结果表明: 该故障诊断方法是有效的,

- [15] 陈小乾, 尹亮, 展宗辉, 等. 基于注意力机制和 RCN-BiLSTM 融合的风电机组故障识别[J]. 中国电力, 2025, 58(8): 94–102.
- [16] 赵学武, 王红梅, 刘超慧, 等. 面向人脑功能划分的人工水母搜索优化算法[J]. 计算机科学与探索, 2022, 16(8): 1829–1841.
- [17] 刘锦春, 洪晓霖, 罗树荣, 等. 用于提升旋转双棱镜系统指向性能的基于鼠群优化算法的校正方法研究及其性能分析[J]. 中国激光, 2025, 52(13): 141–152.

参考文献:

- [1] 孙保生, 杜明才, 李国清, 等. 降低整体式多路阀故障的措施[J]. 建筑机械, 2007(19): 105–107.
- [2] 孟祥伟. 液压控制技术在带压作业系统中的应用研究[D]. 大庆: 大庆石油学院, 2010.
- [3] 穆胜军. 同步马达在液压升降系统中的应用[J]. 资源节约与环保, 2017(12): 2–3.
- [4] 刘行行. 基于 PLC 的液压控制系统在工业计量中的研究与设计[D]. 青岛: 中国石油大学(华东), 2018.
- [5] 曹毅. 对同步马达多缸同步液压控制系统的分析及改进[J]. 机床与液压, 2017, 45(4): 99–101.

可以用于电机故障的检测和分类, 用于预测性维护应用。

参考文献:

- [1] MAO W T, DING L, TIAN S Y, et al. Online Detection for Bearing Incipient Fault Based on Deep Transfer Learning[J]. Measurement, 2020, 152: 107278.
- [2] 刘瑞剑, 陈树越, 张甲杰. MSR 算法在红外图像增强中的应用[J]. 弹箭与制导学报, 2008, 28(4): 193–195.
- [3] 韩潇, 彭力. 基于改进拉普拉斯金字塔变换的图像融合方法[J]. 自动化与仪器仪表, 2014(5): 191–194.
- [4] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-Excitation Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42: 2011–2023.
- [5] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211–252.