

DOI:10.19651/j.cnki.emt.2517808

基于改进 SSA 和 CNN-BiLSTM-Attention 的 UWB 测距误差缓解算法*

张 翠¹ 刘津铭² 郑新鹏² 张烈平^{2,3}

(1. 南宁理工学院信息工程学院 桂林 541006; 2. 桂林理工大学广西高校先进制造与自动化技术重点实验室 桂林 541006; 3. 桂林航天工业学院广西特种工程装备与控制重点实验室 桂林 541004)

摘要: 针对超宽带在实际环境下存在的测距误差问题,提出了基于改进麻雀搜索算法和卷积双向长短期注意力模型的超宽带测距误差缓解算法。采用 Tent 映射,利用自适应调整方法,结合北方苍鹰算法,并在跟随阶段采用螺旋飞行策略对 SSA 算法改进,提高算法的全局搜索性能,避免陷入局部最优的情况,将改进后的算法命名为 TANSSSA。利用 BiLSTM 模型和注意力机制改进 CNN-LSTM 模型,构建 CNN-BiLSTM-Attention 模型,提高模型对长序列数据的处理能力,使得模型对数据有更精确的权重分配。使用 TANSSSA 优化 CNN-BiLSTM-Attention 模型的超参数,构建 TANSSSA-CNN-BiLSTM-Attention 模型。在模型性能验证实验中,对比 SSA-CNN-BiLSTM-Attention、CNN-BiLSTM-Attention、CNN-BiLSTM、CNN-LSTM-Attention、CNN-LSTM、GRU 以及 TCN 模型,平均绝对误差降低了 12.05%~62.31%。在实际环境中,TANSSSA-CNN-BiLSTM-Attention 对比其他 7 种模型,平均绝对误差降低了 45.70%~83.82%,测距误差得到有效地缓解。

关键词: 超宽带;麻雀搜索算法;卷积神经网络;双向长短期记忆网络;注意力机制

中图分类号: TN92 **文献标识码:** A **国家标准学科分类代码:** 510.40

UWB ranging error mitigation algorithm based on improved SSA and CNN-BiLSTM-Attention

Zhang Cui¹ Liu Jinming² Zheng Xinpeng² Zhang Lieping^{2,3}

(1. School of Information Engineering, Nanning College of Technology, Guilin 541006, China; 2. Key Laboratory of Advanced Manufacturing and Automation Technology, Guilin University of Technology, Guilin 541006, China; 3. Guangxi Key Laboratory of Special Engineering Equipment and Control, Guilin University of Aerospace Technology, Guilin 541004, China)

Abstract: Aiming at the ranging error problem of ultra-wideband in actual environment, a UWB ranging error mitigation algorithm based on improved sparrow search algorithm and convolutional neural network bi-directional long short-term memory attention model is proposed. Tent mapping is adopted, adaptive adjustment method is used, combined with northern goshawk algorithm, and spiral flight strategy is adopted in the following stage to improve the SSA algorithm, improve the global search performance of the algorithm and avoid falling into the local optimum. The BiLSTM model and attention mechanism are used to improve the CNN-LSTM model, and the CNN-BiLSTM-Attention model is constructed to improve the model's ability to process long sequence data, so that the model has more accurate weight distribution for data. TANSSSA is used to optimize the hyperparameters of the CNN-BiLSTM-Attention model, and the TANSSSA-CNN-BiLSTM-Attention model is constructed. In the model performance verification experiment, the average absolute error of SSA-CNN-BiLSTM-Attention, CNN-BiLSTM-Attention, CNN-BiLSTM, CNN-LSTM-Attention, CNN-LSTM, GRU and TCN models was reduced by 12.05%~62.31%. In the actual environment, the average absolute error of TANSSSA-CNN-BiLSTM-Attention was reduced by 45.70%~83.82% compared with the other seven models, and the ranging error was effectively alleviated.

Keywords: ultra-wideband; sparrow search algorithm; CNN; BiLSTM; attention mechanism

0 引 言

随着无人驾驶、物联网等技术的发展,室内定位技术得

到了广泛的关注。与 WiFi 定位,超声波定位和蓝牙定位等室内定位技术相比,超宽带(ultra wide band, UWB)凭借其高精度、抗干扰、穿透性强、高分辨率等优势^[1],在室内定位

收稿日期:2025-01-03

* 基金项目:国家自然科学基金(61741303)、广西空间信息与测绘重点实验室基金(21-238-21-16)项目资助

场景中具有广阔的应用前景。然而, UWB 定位在实际应用中依然面临诸多问题, 尤其是由于多径效应和非视距(non-line-of-sight, NLOS)环境导致的测距误差问题。

近年来基于机器学习的 UWB 测距误差缓解方法得到广泛关注, 如支持向量机(support vector machine, SVM)^[2]、随机森林(random forest, RF)^[3]等机器学习技术。然而, 这些方法的波形统计数据会丢失 UWB 测距信号的部分特征并且对新环境的泛化能力有限, 因而对误差缓解的效果有限。与传统机器学习方法相比, 深度学习(deep learning, DL)^[4]以复杂神经网络为模型, 可以提取大量数据的特征, 具有强大的函数近似能力和泛化能力。已有众多学者提出采用 DL 方法对 UWB 测距误差进行缓解。Angarano 等^[5]利用 DL 方法和图优化技术来实现有效的边缘测距误差缓解。但图优化技术在实践中, 涉及到多种非线性因素的优化问题时, 难以直观地调整和调试, 影响测距误差缓解的效率。郑宏舟等^[6]根据超宽带的信号特征的时间序列特性, 采用循环门控单元(gate recurrent unit, GRU)来搭建神经网络, 训练其特征, 以提高 UWB 的测距精度。但 GRU 模型的性能依赖于输入时间序列的长度, 影响误差缓解效果。

卷积神经网络(convolutional neural networks, CNN)和长短期记忆网络(long short-term memory, LSTM)由于其优秀的数据处理和学习性能被众多学者研究^[7-8]。李大占等^[9]提出一种基于 CNN 和 LSTM 相结合的 UWB 测距误差改正模型。CNN 从信道状态信息数据的频域特征中提取特征, LSTM 从信道状态信息的时变特征中提取特征, 以减少测距误差对 UWB 测距值精度的影响。但传统的 LSTM 只能从序列的前向方向捕捉依赖关系, 对误差的缓解效果有限。

由于 CNN-LSTM 模型对长序列结构数据处理能力有限, 本文提出卷积双向长短期注意力网络模型(convolutional neural networks bi-directional long short-term memory attention, CNN-BiLSTM-Attention), 该方法在 CNN-LSTM 模型的基础上引入 BiLSTM 结构^[10], 利于模型捕捉长距离的依赖关系。同时融入注意力机制, 提高模型对关键数据的提取能力。并且, 采用改进的麻雀搜索算法命名为 TANSSSA 优化 CNN-BiLSTM-Attention 模型的超参数, 使得模型在训练过程中更快地收敛, 自动找到模型的最优参数设置, 使模型效果进一步提高。

1 相关基础模型介绍

1.1 LSTM 模型

LSTM 是一种特殊的循环神经网络, 它由 3 个门组成: 输入门, 输出门和遗忘门。通过门控制机制, 可以选择性地记忆, 更新和输出信息^[11]。LSTM 具体实现步骤如下:

步骤 1) 利用 LSTM 的遗忘门从原始序列数据中丢弃

相应的变量。输入向量 h_{t-1} 和 x_t 被输入到一个 sigmoid 函数中, 得到输出向量 f_t 。输出向量 f_t 方程如式(1)所示。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

式中: $\sigma(\cdot)$ 为 sigmoid 函数, W_f 为更新权值向量, b_f 为偏差向量。

步骤 2) 在原始序列数据中存储更新变量。利用 LSTM 输入门中的 sigmoid 层更新变量, 利用 tanh 层创建新候选值的向量。输入门的函数描述如式(2)和(3)所示。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

式中: W_i, W_c, b_i, b_c 为参数, 通过训练确定。 W_i 和 b_i 是计算向量 i_t 的权重和偏置, W_c 和 b_c 是用 tanh 函数计算候选值状态 \tilde{C}_t 的权重和偏置。

步骤 3) 最后输出门运行一个 sigmoid 层, 输出预测变量。函数描述如式(4)和(5)所示。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (5)$$

1.2 CNN 模型

CNN 是一种带有卷积结构的前馈神经网络, 包括卷积层、池化层和全连接层^[12]。CNN 算法的基本步骤如下:

步骤 1) CNN 的卷积层利用滤波器对输入数据进行特征提取, 得到输出特征。其函数描述如式(6)和(7)所示。

$$y_i^{(l)} = a \left(\sum_{r=1}^{N_k^{(l)}} w_r^{(l)} x_{r+i \times N_s^{(l)}} + b^{(l)} \right) \quad (6)$$

$$0 \leq i \leq \frac{N - N_k^{(l)}}{N_s^{(l)}}; l = 1, 2, \dots, L \quad (7)$$

式中: $N_k^{(l)}$ 为滤波器的核大小, $w_r^{(l)}$ 和 $b^{(l)}$ 为核的权值和偏置, l 为卷积层数。

步骤 2) CNN 的池化层通过对输出特征进行下采样操作, 减少输出特征的维度, 降低模型的计算量。

步骤 3) CNN 的全连接层将多维特征连接成一维, 并通过激活函数进行非线性变换。

2 算法设计

2.1 改进麻雀算法设计

麻雀搜索算法(sparrow search algorithm, SSA)是一种新兴的群体智能优化算法, 其灵感来源于麻雀觅食行为, 麻雀群体通过合作和竞争实现全局最优解^[13]。改进麻雀搜索算法(TANSSSA)的具体思路为: 1) 选择 Tent 映射初始化麻雀种群, Tent 映射产生的序列具有较好的随机性和分布性, 使得麻雀个体在搜索空间内分布均匀, 利于提高 SSA 算法的搜索效率。2) 引入自适应权重调整策略, 在 SSA 算法的发现阶段添加惯性权重 w , 使其根据当前迭代状态改变探索和开发的权重。3) 结合北方苍鹰算法(northern goshawk optimization, NGO)。在 SSA 的初始阶段, 当发

现者个体较优时,易导致SSA快速收敛从而陷入局部最优的情况。NGO对个体随机进行选择,增加了SSA算法的全局搜索能力。4)引入螺旋飞行机制,通过螺旋搜索策略和莱维飞行机制来实现。该机制改进了麻雀搜索个体的运动方式,利于在不同维度上进行更为广泛的探索。TANSSSA算法的具体步骤如下:

步骤1)初始化麻雀种群的参数,如发现者数 $pNum$,最大迭代次数 $iter_{max}$ 等。

步骤2)根据有规则的Tent映射初始化种群中个体的位置,产生 pop 个麻雀个体,具体策略如式(8)所示。

$$z_{i+1} = \begin{cases} 2z_i + rand(0,1) \times \frac{1}{N}, & 0 \leq z_i \leq \frac{1}{2} \\ 2(1 - z_i) + rand(0,1) \times \frac{1}{N}, & \frac{1}{2} \leq z_i \leq 1 \end{cases} \quad (8)$$

式中: N 代表序列中的粒子总数, Z_i 代表生成的 Z 序列。

步骤3)根据优化的目标函数计算每个个体的适应度 f_i ,并更新最大适应度 f_w ,最小适应度 f_g 以及相应的具体位置。

步骤4)依照适应度对种群进行排序。

步骤5)将种群分为发现者和跟随者,选择 $pLum$ 个适应度较好的个体作为发现者,剩余的作为跟随者。引入自适应权重调整策略,在发现阶段添加惯性权重 w ,并根据式(10)更新发现者的位置。式(9)为惯性权重 w 的计算公式。

$$w(t) = 0.2 \cos\left(\frac{\pi}{2} \left(1 - \frac{t}{iter_{max}}\right)\right) \quad (9)$$

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

式中: Q 表示服从正态分布的随机数。 L 表示一个 $1 \times d$ 的矩阵, $iter_{max}$ 是最大迭代次数, $X_{i,j}$ 是第 i 个麻雀在第 j 维中的位置信息, $\alpha \in (0,1]$ 是一个随机数, $R_2(R_2 \in [0,1])$ 和 $ST(ST \in [0.5,1])$ 分别表示预警值和安全值。

步骤6)结合NGO算法。具体策略如式(11)所示。

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + r_1 \times (X_k^t - I \times X_{i,j}^t), & f_i > f_k \\ X_{i,j}^t + r_2 \times (X_{i,j}^t - I \times X_k^t), & \text{其他} \end{cases} \quad (11)$$

式中: r_1, r_2 表示 $0 \sim 1$ 的随机数, $k \in [1, 0.2n]$, X_k^t 表示随机一个麻雀的位置, f_k 表示发现者的适应度值。

步骤7)引入螺旋飞行机制,使跟随者更新搜索路径。该算法中引入一个动态可调的螺旋参数 z ,提高跟随者探索未知位置的能力。其基本公式如式(12)、(13)和(14)所示。使用式(12)和(13)来更新跟随者的位置。

$$x'_i(t) = x_i(t) + l \oplus levy(\lambda) \quad (12)$$

$$X_{i,j}^{t+1} =$$

$$\begin{cases} e^{z_1} \cdot \cos(2\pi l) \cdot Q \cdot \exp\left(\frac{X_{worst}^t - X_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ X_{i,j}^{t+1} + |X_{i,j}^t - X_{i,j}^{t+1}| \cdot A^+ \cdot L \cdot e^{z_2} \cdot \cos(2\pi l), & i \leq \frac{n}{2} \end{cases} \quad (13)$$

$$z = e^{k \cdot \cos\pi \cdot \left(1 - \left(\frac{1}{\max}\right)\right)}$$

$$(14)$$

式中:式(12)中 l 表示步长控制参数, $x_i(t)$ 是第 i 个个体在第 t 次迭代中的位置, $1 < \lambda \leq 3$ 。式(13)中 k 是变化系数, $k=5$, l 是 $[-1,1]$ 的均匀分布随机数。

步骤8)做出危险预警,在一次迭代完成后,重新计算个体适应度 f_i ,并更新最小适应度 f_w 和最大适应度 f_g 。

步骤9)判断是否达到最大迭代次数或最优解不再显著改进。如果满足条件,输出最优解,否则返回步骤4)。

2.2 CNN-BiLSTM-Attention模型

针对CNN-LSTM只能从序列数据的前向时间步中捕捉信息的问题,提出使用BiLSTM模型。一部分LSTM从序列的前向时间步中捕捉特征,另一部分从反向时间步中学习特征,避免因仅考虑过去而忽略未来信息数据的情况,从而提升对时序数据的建模能力。但由于不同时间步的数据对模型输出的影响是不一样的。因此,引入注意力机制。注意力机制允许模型自动关注输入序列中最关键的时间步,通过计算当前时间步与每个输入时间步之间的相关性权重,将权重赋予输入序列的各个时间步,凸显重要的时间点,提高模型对重要信息的关注度,从而缓解UWB测距误差。

CIR信号是一种重要的信号特征,它反映了信号在传输过程中的时域、频域和空间特性。常用的CIR特征值有上升时间、峰值时间、信号梯度、最大振幅、信号总能量等等。本文采用接收信号强度指示(received signal strength indication, RSSI)、第一路径功率强度(first path power level, FPPL)和上升时间(rise time, RT)3个CIR信号特征。具体介绍如下:

1)RSSI用于衡量接收到的信号强度,它的值越大,代表接收的信号强度越强。其公式如式(15)所示。

$$RSSI = 10 \times \lg\left(\frac{C \times 2^{17}}{N^2}\right) - A \quad (15)$$

式中: C 表示CIR功率值, A 为脉冲重复频率常数, N 为同步码累积计数值。

2)FPPL指的是UWB信号中,最先到达接收器路径的功率强度。其公式如式(16)所示。

$$FPPL = 10 \times \lg\left(\frac{F_1^2 + F_2^2 + F_3^2}{N^2}\right) - A \quad (16)$$

式中: F_1, F_2, F_3 是第一路径周围的第一、第二和第三振幅; A 为脉冲重复频率常数, N 为同步码累积计数值。

3)RT是指信号从0到峰值所需的时间。其公式如式(17)所示。

$$RT_{\text{standard}} = t_{\text{stop}} - t_{\text{start}} \quad (17)$$

式中： $t_{\text{start}} = \min\{t_i : |r(t_i)| \geq 0.1F_{\text{max}}\}$ ， $t_{\text{stop}} = \min\{t_i : |r(t_i)| \geq 0.9F_{\text{max}}\}$ ， t_i 为第 i 次的采样时间， t_i 时刻采样幅值为 $r(t_i)$ ， F_{max} 为全部采样点中最大幅值。然而，该公式需要对所有 CIR 采样点幅值进行比较，花费时间较长。因此，为缩短读取 CIR 采样点幅值的时间，本文对该公式进行改进，具体如式(18)所示。

$$RT = t_{F_{\text{max}}} - t_{F_1} \quad (18)$$

式中： t_{F_1} 表示第一路径第一采样幅值 F_1 所在采样时间。

本文设计的 CNN-BiLSTM-Attention 模型结构如图 1 所示，具体实现过程如下：

步骤 1)首先，由 RSSI、FPPL、RT 3 个 CIR 信号特征构成数据集。每个特征在时间轴上形成一个信号序列，将这 3 种特征结合起来，形成一个形如(batch_size, time_steps, num_features)的张量，该张量包含了每个时间步的所有特征信息。RSSI、FPPL、RT 在不同时间步都有对应的值。因此，构建数据集的方式是：每个样本都包含 1 个时间序列，其长度为 time_steps，在每个时间步，包含 3 个信号特征 RSSI、FPPL、RT。因此每个时间步的输入数据就是一个包含 3 个值的向量，形如(batch_size, time_steps, 3)。其中 batch_size 代表批量大小，time_steps 代表信号序列长度，num_features=3 表示 RSSI、FPPL 和 RT 3 个信号特征。为加快模型训练速度，本文对该数据集进行归一化处理，将该数据集映射到 0~1 区间范围内。

步骤 2)将构建的 CIR 特征数据集输入到 CNN 中。CNN 用于提取 CIR 数据的局部特征，CNN 的输出是通过卷积层得到的特征图，这些特征图包含了信号的局部模式或特征，可以有效地表示原始信号的特性。此外，CNN 的池化层能够降低特征维度，减少模型计算量。CNN 的结构设计：首先，设置 2 层卷积层，一层具有 10 个过滤器，4 个卷积核，另一层具有 20 个过滤器，4 个卷积核。激活函数选择 ReLU。接着，设置最大池化层数为 2，池化窗口大小为 3×3 。池化层中采用最大池化函数进行特征降维和选取。最后通过全连接层将卷积和池化后的特征进行整合，并通过激活函数进行非线性变换。

步骤 3)BiLSTM 负责处理 CNN 输出的特征图，学习信号的时序依赖性。BiLSTM 通过双向学习序列数据的前后文信息，能够更全面地理解时序特征。BiLSTM 处理后的输出是每个时间步的时序特征，这些特征包含了信号的长期依赖信息。BiLSTM 的结构设计。设置 25 个隐藏单元，两层 LSTM 层堆叠，隐层维度为 256，序列长度设置为 100，为防止过度拟合，丢弃率 Dropout 设置为 0.2，激活函数选择 tanh 和 sigmoid。

步骤 4)Attention 机制的目的是根据输入特征的重要性动态地分配权重。Attention 模块能够让模型关注输入序列中对误差缓解最重要的部分。Attention 的结构设计。注意力机制中 Q, K, V 的维度一般应与 BiLSTM 的输出维

度相同或者为其输出维度的一半。为避免计算复杂，本文取 BiLSTM 输出维度的一半作为 Q, K, V 的值，因此创建 1 个单头，128 个键和查询通道的自注意力层。丢弃率 Dropout 设置为 0.2。注意力机制的核心公式如式(19)所示。

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (19)$$

式中： Q 是查询，用于对输入元素进行加权，计算注意力分数。 K 是键，与查询进行比较，计算每个值的关联程度。 V 是值，代表最终计算出加权求和的结果，作为输出。 d_k 是键的维度， T 是序列长度。

步骤 5)BiLSTM 与 Attention 生成的加权时序特征，传递给全连接层进行处理。最终，使用 regressionLayer 函数输出数值预测。

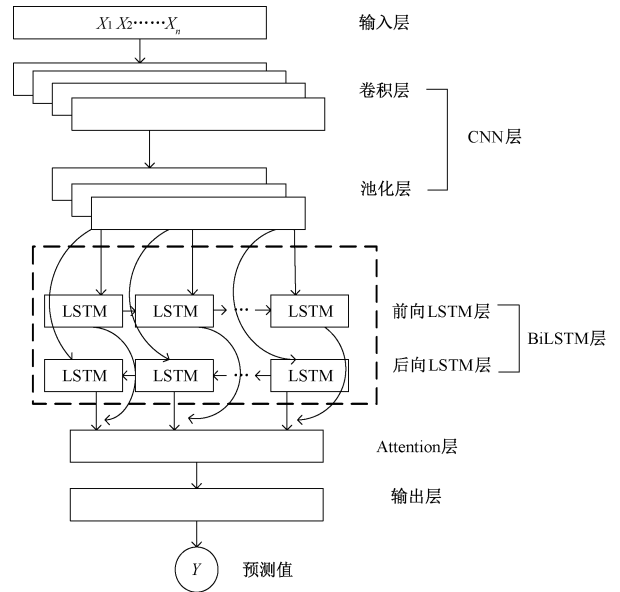


图 1 CNN-BiLSTM-Attention 模型结构
Fig. 1 CNN-BiLSTM-Attention model structure

2.3 TANSSSA-CNN-BiLSTM-Attention 模型及 UWB 测距误差缓解方法

本文利用 TANSSSA 算法优化 CNN-BiLSTM-Attention 模型中的超参数，优化的参数包括卷积核大小，学习率，LSTM 单元数，注意力机制中的参数等，确保模型在全局搜索空间中找到最优的参数配置。TANSSSA-CNN-BiLSTM-Attention 模型的构建如图 2 所示，具体步骤如下：

步骤 1)构建 CNN-BiLSTM-Attention 模型，初始化超参数配置，初始化麻雀种群数目，然后通过 TANSSSA 算法在全局范围内随机初始化 CNN-BiLSTM-Attention 模型的超参数。

步骤 2)模型的训练与评估，对于每组超参数配置，训练 CNN-BiLSTM-Attention 模型，并评估其性能，生成适应度值。

步骤 3)基于评估结果，TANSSSA 对当前模型的超参

数进行更新,逐步优化。

步骤 4)在超参数优化达到收敛条件后,选择最优的超参数配置,完成模型训练和预测。

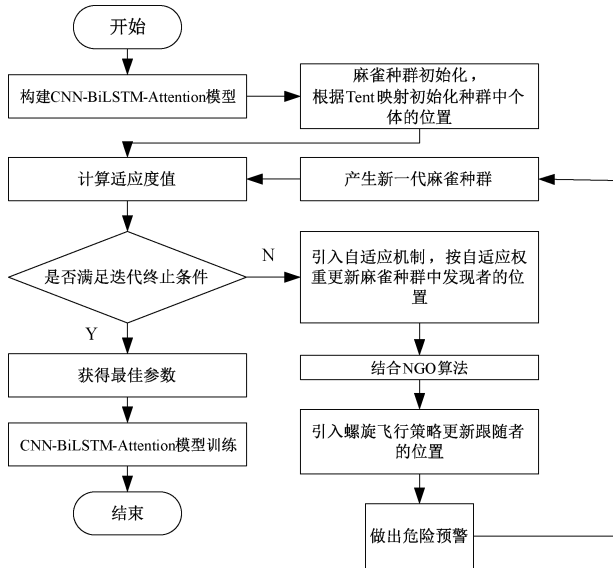


图 2 TANSSSA 算法优化 CNN-BiLSTM-Attention 模型超参数流程

Fig. 2 TANSSSA algorithm optimizes CNN-BiLSTM-Attention model hyperparameter flow chart

在实际环境下,缓解 UWB 测距误差的具体实现流程如图 3 所示。首先,通过 UWB 定位设备采集大量的 CIR 信号,建立数据集。其次,将建立好的数据集输入到 TANSSSA-CNN-BiLSTM-Attention 模型中,根据 CIR 信号特征,预测误差估计距离,再用原始距离减去误差估计距离,得到缓解后的距离,从而达到缓解 UWB 测距误差的目的。

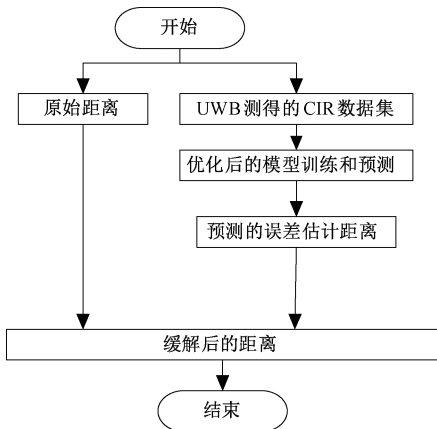


图 3 UWB 测距误差缓解方法流程

Fig. 3 Flowchart of UWB ranging error mitigation method

3 实验验证及结果分析


3.1 实验环境

本文选取一个实际工作间作为实验场景进行实验。工

作间宽 1 m,长 2 m。实验采用的计算机处理器为 Intel(R) Core(TM) i7-11800H @ (2.30 GHz),内存大小为 16 G,装载有 NVIDIA GeForce RTX 3060 Laptop GPU 6 GB 的显卡。CNN-BiLSTM-Attention 模型的基本参数设置如下:最大训练轮数为 30,初始学习率为 0.01,正则化参数为 0.001,梯度阈值为 1。TANSSSA 算法优化 CNN-BiLSTM-Attention 模型的参数设置如下^[14]:初始种群规模为 pop=30,最大进化代数为 maxgen=10。优化参数的下限设置为:学习率为 0.001,BiLSTM 神经元个数为 10,注意力机制键值和查询通道为 128,正则化参数为 0.000 1。优化参数上限设置如下:学习率为 0.01,BiLSTM 神经元个数为 50,注意力机制键值和查询通道为 256,正则化参数为 0.001。

3.2 CIR 特征提取实验

实验选取基于 Decawave 公司 DW1000 芯片研发的高精度 UWB 设备来采集 CIR 数据,具体方法如下:首先,在场景如图 4(a)所示的 UWB 基站节点和标签节点之间放置铁皮作为障碍物,基站和标签之间的距离为 1 m,对 CIR 信号特征和距离值进行 1 000 次采集,得到 NLOS 情况下的 CIR 数据集。接着,在场景如图 4(b)所示的 UWB 基站和标签之间不放置任何物品,按照前述方法进行 CIR 数据采集,得到 LOS 情况下的 CIR 数据集。



(a) 铁皮作为障碍物的测试环境
(a) Testing environment with iron sheet as obstacle



(b) 视距测试环境
(b) Line of sight test environment

图 4 不同场景测试环境

Fig. 4 Different scenario test environments

选取 RSSI、FPPL、RT 3 个 CIR 信号特征,分析 CIR 信号特征是否与测距误差存在关联^[15]。

图 5 所示为不同环境下 CIR 离散采样点的幅值对比图,信号特征如表 1 所示。

通过观察图 5 可以看出,NLOS 条件下的最大幅值明显小于 LOS 条件下的最大幅值。这说明在 NLOS 情况下,




图 5 CIR 离散采样点幅值对比图

Fig. 5 CIR discrete sampling point amplitude comparison chart

表 1 LOS 和 NLOS 情况下 CIR 信号特征

Table 1 CIR signal characteristics in LOS and NLOS situations

测试情况	RSSI/dBm	FPPL/dBm	RT/ns
LOS	-78.51	-81.28	3
NLOS	-79.06	-92.11	7

基站接收的第一路径信号是经反射或折射后的信号。这也表明经过反射或折射后的 RSSI 会略微衰减。表 1 中, LOS 情况下上升时间为 3, 而 NLOS 情况下上升时间为 7。NLOS 条件下 FPPL 的值也明显小于 LOS 条件下的 FPPL 值。CIR 的这 3 个信号特征从不同程度上反映了 NLOS 的程度。因此基于 CIR 信号特征来缓解 UWB 的测距误差是可行的。

3.3 TANSSSA 算法对比实验及分析

基准测试函数一般分为单峰和多峰测试函数^[16]。本文选取较为典型的单峰基准函数和多峰基准函数各两组作为测试函数。单峰测试函数的形式如式(20)和(21)所示。多峰测试函数的形式如式(22)和(23)所示。

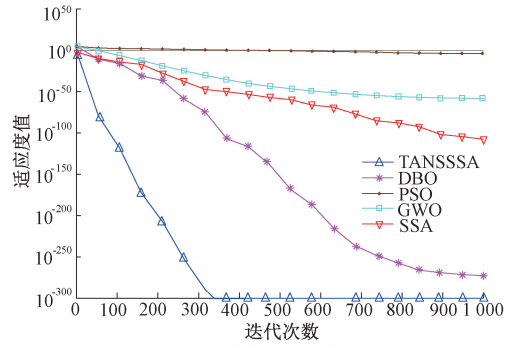
$$f_1(x) = \sum_{i=1}^{30} x_i^2, \quad x_i \in [100, 100] \quad (20)$$

$$f_7(x) = \sum_{i=1}^{30} ix_i^4 + \text{random}[0, 1), \quad x_i \in [-1.28, 1.28] \quad (21)$$

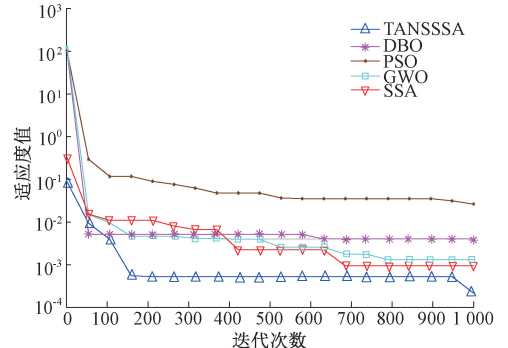
$$f_8(x) = \sum_{i=1}^{30} -x_i \sin(\sqrt{|x_i|}), \quad x_i \in [-500, 500] \quad (22)$$

$$f_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^{30} x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^{30} \cos(2\pi x_i)\right) + 20 + e, \quad x_i \in [-32, 32] \quad (23)$$

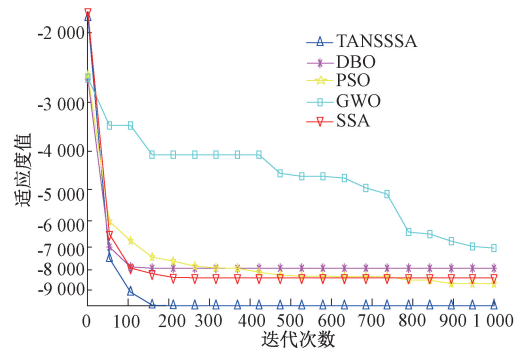
为了全面分析并评价 TANSSSA 算法的性能, 本文将其优化结果与当前几种主流优化算法进行对比, 包括蜣螂优化算法 (dung beetle optimizer, DBO)^[17], 粒子群算法 (particle swarm optimization, PSO)^[18], 灰狼优化 (grey wolf optimizer, GWO)^[19] 以及麻雀搜索算法。上述算法的种群数量都设置为 30, 最大迭代次数都为 500, 确保实验的准确性。算法收敛结果的对比图如图 6 所示。




(a) 单峰测试函数 F1
(a) Unimodal test function F1



(b) 单峰测试函数 F7
(b) Unimodal test function F7



(c) 多峰测试函数 F8
(c) Multi-peak test function F8



(d) 多峰测试函数 F10
(d) Multi-peak test function F10

图 6 基准测试函数上各算法收敛效果对比图

Fig. 6 Comparison of convergence effects of various algorithms on benchmark functions

图 6 中 TANSSSA 在不同测试函数下与其他各个优化算法的收敛曲线对比说明了 TANSSSA 在处理单峰测试函数和多峰测试函数时有着较好的收敛特性。TANSSSA 在初始阶段的适应度值就低于 SSA,说明本文采用 Tent 混沌映射策略改进后的麻雀初始化种群质量更高。TANSSSA 的收敛速度也比 SSA 更快,这表明引入的螺旋飞行机制使得麻雀种群能扩大搜索范围并且迅速接近最优位置。TANSSSA 的最终适应度值比 SSA 更好,说明引入的自适应调整策略和北方苍鹰算法能够平衡局部开发和全局搜索,提高算法全局搜索能力。总体看来,和其他优化算法对比,TANSSSA 的收敛速度,最终适应度值,寻优和探索能力也明显更为优异。因此,实验验证了 TANSSSA 算法在处理优化参数问题时的优势。

3.4 TANSSSA-CNN-BiLSTM-Attention 模型性能验证实验及分析

本文采用 TANSSSA 算法优化 CNN-BiLSTM-Attention 模型,构建 TANSSSA-CNN-BiLSTM-Attention 模型。首先通过对比实验确定 CNN 的最佳卷积层数,表 2 展示了不同卷积层的 CNN 对数据特征提取的准确率。最大池化层(x, y)表示具有 x 池大小, y 步长的最大池化层。卷积层(a, b)表示具有 a 个过滤器, b 个卷积核的卷积层。从表 2 可以看出,当卷积层数为 2,卷积层分别为(10,4)和(20,4)时,CNN 特征提取准确率最高。因此,对本文所提出的 TANSSSA-CNN-BiLSTM-Attention 模型以及进行对比的 SSA-CNN-BiLSTM-Attention 模型、CNN-BiLSTM-Attention 模型、CNN-BiLSTM 模型、CNN-LSTM-Attention 模型和 CNN-LSTM 模型均采用具有 2 层卷积层的 CNN 结构。

表 2 不同卷积层的 CNN 特征提取准确率

Table 2 CNN feature extraction accuracy of different convolutional layers

卷积层层数	CNN 结构	准确率/%
1	卷积层(10,4)	58.72
	最大池化层(2,2)	
2	卷积层(10,4)	84.57
	最大池化层(2,2)	
3	卷积层(20,4)	82.56
	最大池化层(2,2)	
	卷积层(10,4)	
	卷积层(20,4)	
4	最大池化层(2,2)	75.42
	卷积层(20,4)	
	卷积层(10,4)	
	卷积层(40,4)	

为评估 TANSSSA-CNN-BiLSTM-Attention 模型的性能,本文引入了均方根误差(root mean square error, RMSE),平均绝对值误差(mean absolute error, MAE)以及决定系数(R^2) 3 种评价指标。3 个指标相应的计算方法如式(24)、(25)以及(26)所示。

$$MAE = \frac{1}{m} \sum_{i=1}^m |\hat{y} - y| \tag{24}$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y - \hat{y})^2} \tag{25}$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (y - \hat{y})^2}{\sum_{i=1}^m (y - \bar{y})^2} \tag{26}$$

式中: m 为样本数, \hat{y} 表示 t 时刻的预测值, y 表示 t 时刻的真实距离模拟值。 \bar{y} 表示平均预测值。

为确定最佳的训练集和测试集的分布情况,验证模型的泛化性,本文采用随机拆分的方式将原始数据集分别拆分为训练集和测试集的比为 9 : 1、8 : 2、7 : 3 三种情况。将其分别输入到 TANSSSA-CNN-BiLSTM-Attention、SSA-CNN-BiLSTM-Attention、CNN-BiLSTM-Attention、CNN-BiLSTM、CNN-LSTM-Attention、GRU^[6]、CNN-LSTM^[9]以及 TCN^[20]模型中进行训练。实验中,CNN 部分和 LSTM 部分的参数设置相同,均采用上述文章中采用的参数设置,通过对比实验来验证模型的泛化性。图 7 所示为不同训练集与测试集分布情况下模型的 RMSE 值。

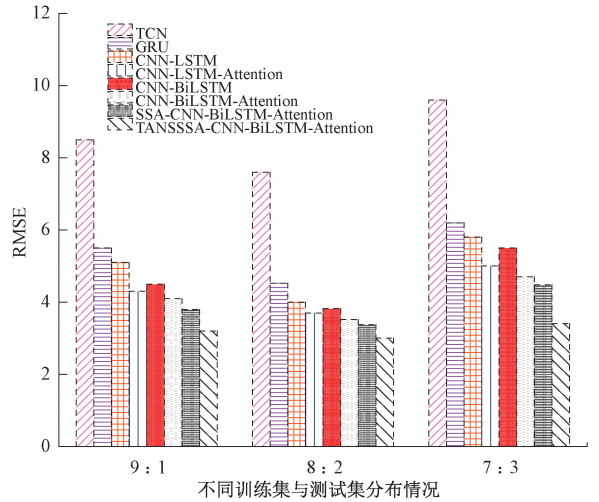


图 7 不同训练集与测试集分布情况下各模型 RMSE 值柱状图

Fig. 7 Histogram of RMSE values of each model under different distributions of training sets and test sets

由图 7 可以看出,在训练集和测试集之比为 8 : 2 的情况下,这八种模型的 RMSE 值最小。从稳定性方面来看,TANSSSA-CNN-BiLSTM-Attention 训练集和测试集之比为 9 : 1 情况下, RMSE 值为 3.2;8 : 2 情况下, RMSE 值为

3;7:3 情况下 RMSE 值为 3.4。其在不同训练集与测试集分布的情况下, RMSE 值变化幅度最小, 其 RMSE 均值为 3.2。充分证明了 TANSSSA-CNN-BiLSTM-Attention 的稳定性。在不同训练集与测试集分布的情况下, SSA-CNN-BiLSTM-Attention 的 RMSE 均值为 3.9, CNN-BiLSTM-Attention 为 4.1, CNN-BiLSTM 为 4.6, CNN-LSTM-Attention 为 4.3, CNN-LSTM 为 5.0。GRU 的为 5.4, TCN 为 8.6。通过对比, TANSSSA-CNN-BiLSTM-Attention 的 RMSE 均值最小, 验证了 TANSSSA-CNN-BiLSTM-Attention 的泛化性能。并且, 在训练集和测试集之比为 8:2 的情况下, 8 种模型的 RMSE 值最小。因此, 本文随机选择数据集中 80% 用于模型训练, 其余 20% 用于测试。

为验证 TANSSSA-CNN-BiLSTM-Attention 模型的误差缓解效果, 通过与 SSA-CNN-BiLSTM-Attention 模型、CNN-BiLSTM-Attention 模型、CNN-BiLSTM 模型、CNN-LSTM-Attention 模型、GRU 模型^[6]、TCN 模型^[20] 以及 CNN-LSTM^[9] 模型进行对比分析。将经过特征提取的 CIR 数据按照 8:2 的比例分为训练集和测试集, 输入到各个模型中。

累积分布函数(cumulative distribution function, CDF)能够完整且直观地展示出误差小于或等于某个特定值的概率累积情况。因此, 本实验采用 CDF 作为评价指标, 相关实验结果如图 8 所示。由图 8 可以看出, 当误差距离小于 6 cm 时, TANSSSA-CNN-BiLSTM-Attention 的概率为 96.75%, SSA-CNN-BiLSTM-Attention 的概率为 93.70%, CNN-BiLSTM-Attention 模型的概率为 93.00%, CNN-LSTM-Attention 模型的概率为 91.25%, CNN-BiLSTM 模型的概率 86.25%, CNN-LSTM 模型的概率为 83.50%, TCN 的概率为 63.40%, GRU 的概率为 52.33%。由此可以看出 CNN-BiLSTM-Attention 模型的收敛速度和测距误差范围均优于其他模型, 验证了 CNN-BiLSTM-Attention 模型的性能。




图 8 各模型累积函数分布图

Fig. 8 Cumulative function distribution diagram of each model

表 3 中展示了各个模型的评价指标结果以及模型的训练时间, 可以看出 TANSSSA-CNN-BiLSTM-Attention 模型的性能明显优于其他 7 种模型。对比 TCN、GRU、CNN-LSTM、CNN-LSTM-Attention、CNN-BiLSTM、CNN-BiLSTM-Attention 以及 SSA-CNN-BiLSTM-Attention 模型, 其 RMSE 值分别降低了 59.45%、32.13%、22.86%、16.76%、19.52%、12.86% 和 9.04%。其 MAE 值分别降低了 62.31%、38.31%、30.70%、20.36%、22.61%、15.77% 和 12.05%。 R^2 系数用于衡量模型的预测能力, 其值越接近 1, 表明模型预测能力越好。由表 3 可以看出, 对比其他 7 种模型, TANSSSA-CNN-BiLSTM-Attention 模型的 R^2 值最接近 1, 证明其有优越的预测能力。在训练时间方面, 由于增加了模型的复杂度, TANSSSA-CNN-BiLSTM-Attention 对比 CNN-LSTM、CNN-LSTM-Attention、CNN-BiLSTM 这几种模型, 训练时间有所提升, 但差距不大, 然而 TANSSSA-CNN-BiLSTM-Attention 模型的精度有较大的提升。TANSSSA-CNN-BiLSTM-Attention 对比 CNN-BiLSTM-Attention 和 SSA-CNN-BiLSTM-Attention 这两种模型训练时间有所下降, 说明 TANSSSA 算法对 CNN-BiLSTM-Attention 模型的优化效果较好。因此, 采用 TANSSSA 算法能够充分优化 CNN-BiLSTM-Attention 模型的超参数, 提高模型的预测能力, 提升模型对 UWB 测距误差缓解的效果。

3.5 实际环境中模型性能验证实验

实验环境在教学楼休息室的一个宽 4 m、长 5 m 的实验场地中进行, 将 B_1 、 B_2 、 B_3 三个基站节点分别放置实验场地 3 个角落, 基站 B_1 为坐标原点(0,0), 基站 B_2 坐标为(400,0)和基站 B_3 坐标为(0,500), 使用铁板、木板障碍物以及铁质桌椅搭建 NLOS 定位环境, 将标签节点放置于(50,100)、(50,150)、(50,200)、(100,150)、(100,200)、(100,250)、(200,200)、(230,200)、(230,300)、(260,300)、(290,200)、(320,300)、(400,400)、(500,300)、(500,400) 共 15 个位置进行定位测试, 总基站 B_0 。在实验场地的外围由 USB 与计算机连接, 具体放置地点如图 9 所示。对采集到的实验数据进行数据处理后, 输入到 8 种模型中, 与最小二乘法结合得到标签的定位坐标。休息室环境(230,300)处各模型散点图如图 10 所示。

如图 10 所示, TANSSSA-CNN-BiLSTM-Attention 最靠近真实位置坐标。由表 4 中的相关评价指标, 可以看出, 在实际环境中, TANSSSA-CNN-BiLSTM-Attention 对比其他七种模型, 其 RMSE 值降低了 32.31%~73.92%, MAE 值降低了 45.70%~83.82%, 其 R^2 值最接近 1。充分验证了 TANSSSA-CNN-BiLSTM-Attention 模型在实际环境中优越的预测性能。

综上, TANSSSA 算法提高了 CNN-BiLSTM-Attention 模型的参数寻优能力, 同时通过 BiLSTM 和注意力机制更容易利用输入数据中最关键的特征, 有效提高了

表 3 各模型的评价指标结果

Table 3 Evaluation index results of each model

模型	MAE/cm	RMSE/cm	R ²	训练时间/h
TCN	5.81	7.62	0.77	0.50
GRU	3.55	4.55	0.83	0.43
CNN-LSTM	3.16	4.01	0.85	0.24
CNN-LSTM-Attention	2.75	3.71	0.88	0.28
CNN-BiLSTM	2.83	3.84	0.87	0.29
CNN-BiLSTM-Attention	2.60	3.55	0.90	0.39
SSA-CNN-BiLSTM-Attention	2.49	3.39	0.92	0.37
TANSSSA-CNN-BiLSTM-Attention	2.19	3.09	0.95	0.32



图 9 休息室实验环境

Fig. 9 Lounge experimental environment




图 10 休息室环境各模型散点图

Fig. 10 Scatter plot of lounge environment models

模型的预测性能,能够有效缓解 UWB 测距误差,实现较高精度定位。

表 4 各模型的误差评价指标结果

Table 4 Error evaluation index results of each model

模型	MAE/ RMSE/		R ²
	cm	cm	
TCN	16.38	19.52	0.70
GRU	12.21	14.60	0.77
CNN-LSTM	9.86	12.70	0.80
CNN-LSTM-Attention	7.82	10.06	0.85
CNN-BiLSTM	8.98	11.10	0.83
CNN-BiLSTM-Attention	6.45	8.50	0.88
SSA-CNN-BiLSTM-Attention	4.88	7.52	0.90
TANSSSA-CNN-BiLSTM-Attention	2.65	5.09	0.94

4 结 论

针对 UWB 测距误差缓解问题,本文提出一种 TANSSSA 算法优化 CNN-BiLSTM-Attention 模型超参数的方法。首先,针对 SSA 算法易陷入局部最优的问题,提出改进的 TANSSSA 算法,扩大搜索范围,提升算法的全局搜索能力。其次,针对 LSTM 在处理序列长度较长的数据结构时记忆能力存在局限性的问题,通过引入 BiLSTM 模型,提高了模型对长数据结构的处理能力。同时引入注意力机制,提高模型对关键数据特征的选择能力,提高预测的准确性。最后,将 TANSSSA 算法用于优化 CNN-BiLSTM-Attention 模型,构建 TANSSSA-CNN-BiLSTM-Attention 模型。实验结果表明, TANSSSA-CNN-BiLSTM-Attention 模型与 TCN、GRU、CNN-LSTM、CNN-LSTM-Attention、CNN-BiLSTM、CNN-BiLSTM-Attention 以及 SSA-CNN-BiLSTM-Attention 模型相比, TANSSSA-CNN-BiLSTM-Attention 模型效果最好,能够有效缓解 UWB 的测距误差。但是,本文所提出的 UWB 测距误差缓解方法,其预测效果在一定程度上有所提高,但仍然需要一定量的数据进行训练,并且花费的时间较

多。在今后的研究中,如何进一步缩短该模型的训练时间是关键。此外,本文设计的实际环境复杂度较低,且处于静态环境,后续会针对动态障碍物,动态目标节点等动态环境做进一步分析。

参考文献

- [1] 黄琴, 兰小机, 夏益强, 等. Chan-IDW 算法在信号干扰下的 UWB 精确定位研究[J]. 电子测量技术, 2023,46(9):1-7.
HUANG Q, LAN X J, XIA Y Q, et al. Research on UWB precise positioning under signal interference based on Chan-IDW algorithm [J]. Electronic Measurement Technology, 2023,46(9):1-7.
- [2] YANG H, WANG Y, SEOW C K, et al. UWB sensor-based indoor LOS/NLOS localization with support vector machine learning[J]. IEEE Sensors Journal, 2023,23(3):2988-3004.
- [3] IMBEAULT-NEPTON T, MAITRE J, BOUCHARD K, et al. Filtering data bins of UWB radars for activity recognition with random forest[J]. Procedia Computer Science, 2022,201:48-55.
- [4] 刘万青, 魏国, 高春峰, 等. 基于深度学习的 UWB NLOS 传播影响抑制技术研究[J]. 红外与激光工程, 2023,52(12):293-301.
LIU W Q, WEI G, GAO CH F, et al. Research on UWB NLOS propagation impact suppression technology based on deep learning[J]. Infrared and Laser Engineering, 2023, 52(12): 293-301.
- [5] ANGARANO S, MAZZIA V, SALVETTI F, et al. Robust ultra-wideband range error mitigation with deep learning at the edge[J]. Engineering Applications of Artificial Intelligence, 2021, 102: 104278.
- [6] 郑宏舟, 赵宇宸, 孟飞. 基于深度学习 GRU 网络的 UWB 室内定位优化[J]. 上海理工大学学报, 2024, 46(1):78-86.
ZHENG H ZH, ZHAO Y CH, MENG F. UWB indoor positioning optimization based on deep learning GRU network[J]. Journal of University of Shanghai for Science and Technology, 2024,46(1):78-86.
- [7] KIM D, FARHAD A, PYUN J. UWB positioning system based on LSTM classification with mitigated NLOS effects[J]. IEEE Internet of Things Journal, 2022,10(2):1822-1835.
- [8] CHO S, KIM J. GNSS NLOS signal classifier with successive correlation outputs using CNN[J]. Journal of Positioning, Navigation, and Timing, 2023,12(1): 1-9.
- [9] 李大占, 宁一鹏, 赵文硕, 等. 卷积-长短期记忆神经网络超宽带定位方法[J]. 导航定位学报, 2024, 12(1):97-105.
LI D ZH, NING Y P, ZHAO W SH, et al. Ultra-wideband positioning method based on convolutional-long short-term memory neural network[J]. Journal of Navigation and Positioning, 2024,12(1):97-105.
- [10] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997,45(11):2673-2681.
- [11] 曾进辉, 苏旨音, 肖锋, 等. 基于经验模态分解和 ISSA-LSTM 的短期电力负荷预测[J/OL]. 电子测量技术, 1-7 [2024-10-21]. <http://kns.cnki.net/kcms/detail/11.2175.TN.20241018.1837.033.html>.
ZENG J H, SU ZH Y, XIAO F, et al. Short-term power load forecasting based on empirical mode decomposition and ISSA-LSTM [J/OL]. Electronic Measurement Technology, 1-7 [2024-10-21]. <http://kns.cnki.net/kcms/detail/11.2175.TN.20241018.1837.033.html>.
- [12] 张宝军, 田奇. 基于 CNN 的超宽带/惯性导航室内定位算法[J]. 传感器与微系统, 2021,40(7):114-117.
ZHANG B J, TIAN Q. Ultra-wideband/inertial navigation indoor positioning algorithm based on CNN[J]. Sensors and Microsystems, 2021, 40 (7): 114-117.
- [13] 王尔申, 王欢, 雷虹, 等. 基于麻雀搜索算法的 ARAIM 故障子集优化算法[J]. 北京航空航天大学学报, 2024,50(7):2066-2073.
WANG ER SH, WANG H, LEI H, et al. ARAIM fault subset optimization algorithm based on sparrow search algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (7): 2066-2073.
- [14] SANGEETHA J, KUMARAN U. Using BiLSTM structure with cascaded attention fusion model for sentiment analysis [J]. Journal of Scientific & Industrial Research, 2023,82(4):444-449.
- [15] LI C, TANGHE E, FONTAINE J, et al. Multistatic UWB radar-based passive human tracking using COTS devices[J]. IEEE Antennas and Wireless Propagation Letters, 2022, 21(4): 695-699.
- [16] 季坤, 张晨晨, 丁国成, 等. 粒子群优化算法在电力变压器声纹识别中的应用[J]. 沈阳工业大学学报, 2023,45(6): 643-648.
JI K, ZHANG CH CH, DING G CH, et al. Application of particle swarm optimization algorithm in voiceprint recognition of power transformers[J]. Journal of Shenyang University of Technology, 2023, 45(6): 643-648.

- [17] XUE J, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization [J]. The Journal of Supercomputing, 2023, 79 (7): 7305-7336.
- [18] MRRINI F, WALCZAK B. Particle swarm optimization(PSO). A tutorial[J]. Chemometrics and Intelligent Laboratory Systems, 2015,149:153-165.
- [19] HATTA N M, ZAIN A M, SALLEHUDDIN R, et al. Recent studies on optimisation method of Grey Wolf Optimiser (GWO): A review (2014—2017) [J]. Artificial Intelligence Review, 2019,52:2651-2683.
- [20] FAN J, ZHANG K, HUANG Y, et al. Parallel spatio-temporal attention-based TCN for multivariate time series prediction [J]. Neural Computing and

Applications, 2023,35(18):13109-13118.

作者简介

张翠, 硕士, 副教授, 主要研究方向为传感器与智能信息处理技术。

E-mail:18172686917@163.com

刘津铭, 硕士研究生, 主要研究方向为传感器与智能信息处理技术。

E-mail:2120221199@glut.edu.cn

郑新鹏, 硕士研究生, 主要研究方向为传感器与智能信息处理技术。

E-mail:2120231396@glut.edu.cn

张烈平(通信作者), 博士, 教授, 主要研究方向为传感器与智能信息处理技术。

E-mail:zlp@guat.edu.cn