

# 结合BiGRU与Bahdanau注意力机制的超宽带室内定位系统研究

奚壮<sup>1</sup>, 苗之轩<sup>1</sup>, 邹惺辰<sup>1</sup>, 魏鸿扬<sup>2</sup>

<sup>1</sup>上海理工大学管理学院, 上海

<sup>2</sup>上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2025年1月13日; 录用日期: 2025年2月7日; 发布日期: 2025年2月14日

## 摘要

超宽带(Ultra Wide Band, UWB)技术因其高精度和强抗干扰能力, 在室内定位领域中有着广泛的应用。然而, 在复杂的室内环境中, UWB信号易受多径效应和非视距条件的影响, 使得定位精度下降。为此, 文章提出了一种基于深度学习的UWB室内定位方法。通过引入双向门控循环单元(Bidirectional Gated Recurrent Unit, BiGRU)与Bahdanau注意力机制的结合模型, 充分挖掘UWB信号的时序特征和关键信息。BiGRU利用其在时序数据处理中的优势, 有效捕捉UWB信号的动态特征, 而Bahdanau注意力机制通过动态权重分配, 增强模型对关键特征的关注, 从而提高定位精度。实验结果表明, 文章提出的模型平均定位误差为6.9 cm, 相较于传统的循环神经网络(Recurrent Neural Network, RNN)、长短时记忆(Long Short-Term Memory, LSTM)网络和门控循环单元(Gated Recurrent Unit, GRU), 误差减少了约29.59%至42.98%。研究结果表明, 结合BiGRU与Bahdanau注意力机制的深度学习模型在复杂环境下具有更高的鲁棒性和定位精度。

## 关键词

超宽带室内定位, 双向门控循环单元, Bahdanau注意力机制

# Research on Ultra Wide Band Indoor Positioning System Combining BiGRU and Bahdanau Attention Mechanism

Zhuang Xi<sup>1</sup>, Zhixuan Miao<sup>1</sup>, Xingchen Zou<sup>1</sup>, Hongyang Wei<sup>2</sup>

<sup>1</sup>Business School, University of Shanghai for Science and Technology, Shanghai

<sup>2</sup>School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Jan. 13<sup>th</sup>, 2025; accepted: Feb. 7<sup>th</sup>, 2025; published: Feb. 14<sup>th</sup>, 2025

文章引用: 奚壮, 苗之轩, 邹惺辰, 魏鸿扬. 结合 BiGRU 与 Bahdanau 注意力机制的超宽带室内定位系统研究[J]. 应用数学进展, 2025, 14(2): 50-61. DOI: 10.12677/aam.2025.142051

## Abstract

Ultra Wide Band (UWB) technology is widely used in indoor positioning due to its high accuracy and strong anti-interference capability. However, in complex indoor environments, UWB signals are susceptible to multipath effects and non-line-of-sight conditions, which degrade positioning accuracy. To address this issue, this paper proposes a deep learning-based UWB indoor positioning method. By introducing a combined model of the Bidirectional Gated Recurrent Unit and Bahdanau attention mechanism, the method effectively exploits the temporal features and key information of UWB signals. BiGRU leverages its advantages in handling sequential data to capture the dynamic characteristics of UWB signals, while the Bahdanau attention mechanism enhances the model's focus on critical features through dynamic weight allocation, thus improving positioning accuracy. Experimental results show that the average positioning error of the proposed model is 6.9 cm, which represents a reduction of approximately 29.59% to 42.98% compared to traditional Recurrent Neural Network, Long Short-Term Memory Network, and Gated Recurrent Unit. The results demonstrate that the deep learning model combining BiGRU and the Bahdanau attention mechanism offers higher robustness and positioning accuracy in complex environments.

## Keywords

Ultra Wide Band Indoor Positioning, Bidirectional Gated Recurrent Unit, Bahdanau Attention Mechanism

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

在室内环境中,全球定位系统(Global Positioning System, GPS)受建筑物遮挡而无法进行有效定位。相比之下,超宽带技术因具有高精度、强穿透力和良好的抗多径与抗干扰能力等优势,成为室内定位的理想选择[1]。UWB是一种频带宽度大于500 MHz的无线通信技术,能够在较短距离内提供高分辨率的定位服务,并且在多障碍物环境下仍能保持较好的性能。由于其出色的定位精度和可靠性,UWB在室内定位应用中表现优异,广泛用于智能家居、物流追踪等领域。目前,UWB定位的常见方法包括基于信号到达时间(Time of Arrival, TOA)、基于信号到达时间差(Time Difference of Arrival, TDOA)、基于信号到达角度(Angle of Arrival, AOA)以及基于接收信号强度(Received Signal Strength Indication, RSSI)[2]。其中,TOA算法因其低功耗、低成本和稳定可靠的运行特点,成为UWB定位的主流方法。

在室内环境中,UWB定位的测距误差主要受到多径效应、多址干扰、时钟同步误差和非视距(Non-Line-of-Sight, NLOS)误差等因素的影响[3]。现有研究已探讨了多种提升UWB定位精度的方法,涵盖了惯性测量单元[4]、Wi-Fi[5]、卡尔曼滤波[6]和多传感器融合[7]等技术的应用。此外,深度学习方法也被广泛用于提高定位精度。例如,文献[8]提出了一种用于视距(Line-of-Sight, LOS)和非视距NLOS识别的前馈神经网络(Feedforward Neural Network, FNN)方法,该方法能够有效减轻受限空间和各种障碍物对定位造成的负面影响。文献[9]结合UWB技术和卷积神经网络(Convolutional Neural Networks, CNN)的定位方法,通过RGB图像估计发射器位置,提升了室内定位精度与鲁棒性。文献[10]提出了一种基于LSTM的深度学习方法,通过利用UWB的TOA距离数据来预测用户位置,有效提升了室内定位精度。文献[11]

提出一种基于时空注意力图神经网络的 UWB 定位方法, 通过多标签测距建模提升几何关系捕捉能力, 在非视距环境下表现出更高的定位准确性和鲁棒性。文献[12]提出了一种基于注意力机制的 UWB 测距误差补偿算法, 通过重新评估信道特征的重要性, 提升了 UWB 测距的精度。

尽管现有研究已显著提升了 UWB 室内定位系统的精度, 但定位精度仍有进一步优化的空间。为此, 本文提出了一种新的 UWB 室内定位方法, 将双向门控循环单元 BiGRU 与 Bahdanau 注意力机制相结合。BiGRU 在处理时序数据方面具有优势, 能够有效捕捉 UWB 信号的动态特征, 而 Bahdanau 注意力机制通过动态分配权重, 有效加强了模型对关键信号特征的关注。两者的结合使模型在复杂环境下能够更加精准地提取和处理 UWB 信号特征, 从而有效提升室内定位的精度并减少定位误差。实验结果表明, 本文提出的模型显著提高了 UWB 室内定位的精度, 并有效减少了定位误差。

## 2. UWB 定位方法

传统的 UWB 室内定位方法常用 TOA 定位方法来进行位置估计。TOA 定位法是一种通过测量信号从发射源到接收器的传播时间, 进而计算信号传播距离的测距方法。在 UWB 通信中, 由于信号带宽极宽, UWB 信号的短脉冲能够在空间上被很好地分辨, 从而准确测量信号到达接收器的时间。

TOA 定位法的基本原理是通过测量发射信号到达接收器的时间差来确定发射源与接收器之间的距离。具体而言, 当发射信号从发射源出发并经过一定的传播路径到达接收器时, 接收器内的时钟信号会记录下信号到达的时间。通过已知的信号传播速度和发射信号与接收器的时钟信号之间的时间差, 可以计算出信号传播的距离。

如图 1 所示为 TOA 定位法原理图。在时间同步后, 未知标签发送 UWB 信号至各个定位基站所消耗的时间, 从而完成测距。假设未知标签的坐标为  $P(x, y)$ , 定位基站的坐标为  $R_i(x_i, y_i)(i=1, 2, 3)$ , 未知标签  $P$  发出的信号到达三个定位基站的时间分别为  $t_1, t_2, t_3$ , 则距离的计算公式为:  $d_i = ct_i (i=1, 2, 3)$ 。

在获取未知标签到定位基站的距离后, 传统 UWB 室内定位系统利用三边测量法来计算未知标签的具体位置。然而, 实际情况中, 由于多径效应、多址干扰、时钟同步误差和非视距误差的影响, 三边测量法最终计算出的结果往往仅为一个近似值。

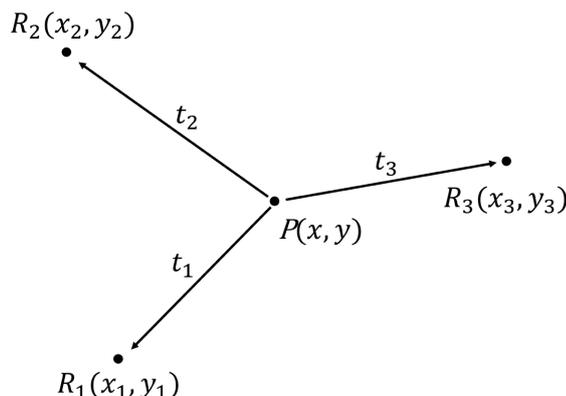


Figure 1. Principle diagram of TOA-based localization method  
图 1. 基于 TOA 定位法的原理图

### 三边测量法

三边测量法是指通过得到三个以上的定位基站与未知标签之间的估计距离后, 再通过相关方法来确定未知标签的位置坐标。图 2 显示了三边测量法的原理图。

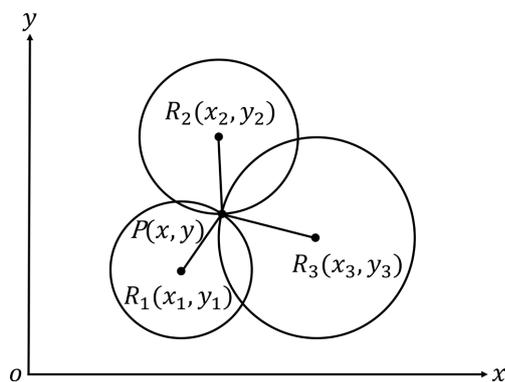


Figure 2. Trilateration principle diagram  
图 2. 三边测量法原理图

UWB 未知标签  $P(x, y)$  与定位基站  $R_i(x_i, y_i)$  之间的距离  $d_i$  表示为:

$$d_i^2 = (x_i - x)^2 + (y_i - y)^2 \tag{1}$$

$i$  取值为 1、2、3, 将式(1)展开, 得到:

$$d_i^2 = x_i^2 + x^2 - 2x_ix + y_i^2 + y^2 - 2y_iy \tag{2}$$

考虑  $i = k$ , 式(2)可以写成:

$$d_k^2 = x_k^2 + x^2 - 2x_kx + y_k^2 + y^2 - 2y_ky \tag{3}$$

式(2)减去式(3), 得到:

$$d_i^2 - d_k^2 + x_k^2 + y_k^2 - x_i^2 - y_i^2 = 2(x_k - x_i)x + 2(y_k - y_i)y \tag{4}$$

考虑  $i = 1$ , 变指数  $k = 2, 3$ , 可以得到:

$$\begin{bmatrix} 2(x_2 - x_1) & 2(y_2 - y_1) \\ 2(x_3 - x_1) & 2(y_3 - y_1) \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} d_1^2 - d_2^2 + x_2^2 + y_2^2 - x_1^2 - y_1^2 \\ d_1^2 - d_3^2 + x_3^2 + y_3^2 - x_1^2 - y_1^2 \end{bmatrix} \tag{5}$$

通过求解上述方程组, 可以得到 UWB 未知标签的坐标  $P(x, y)$ 。式(5)可以看作  $Ax = b$ , 表示线性方程组的  $A$ 、 $x$ 、 $b$  值:

$$A = \begin{bmatrix} 2(x_2 - x_1) & 2(y_2 - y_1) \\ 2(x_3 - x_1) & 2(y_3 - y_1) \end{bmatrix} \tag{6}$$

$$x = \begin{bmatrix} x \\ y \end{bmatrix} \tag{7}$$

$$b = \begin{bmatrix} d_1^2 - d_2^2 + x_2^2 + y_2^2 - x_1^2 - y_1^2 \\ d_1^2 - d_3^2 + x_3^2 + y_3^2 - x_1^2 - y_1^2 \end{bmatrix} \tag{8}$$

线性方程组的解应该使得如下定义的  $\delta$  最小为:

$$\delta = (Ax - b)^T (Ax - b) \tag{9}$$

$$x = \begin{bmatrix} x & y \end{bmatrix}^T \tag{10}$$

运用最小均方误差(MMSE)方法, 可以解得  $x$  为:

$$x = (A^T A)^T A^T b \tag{11}$$

关于三边测量法实现的更多细节，可以参考文献[13]。

### 3. 结合 Bahdanau 注意力机制的 BiGRU 模型的结构设计

#### 3.1. 双向门控循环单元

在时间序列数据建模中，传统的循环神经网络(RNN)常常面临梯度消失和爆炸的问题，限制了其对长时间序列的学习能力。为了解决这些问题，门控循环单元 GRU 引入了更新门和重置门的机制，从而改善了传统 RNN 的结构，能够更有效地捕捉长短期依赖关系。GRU 由重置门  $R_t$ 、更新门  $Z_t$  组成，GRU 结构图如图 3 所示。重置门  $R_t$  是由隐藏状态  $H_{t-1}$  与输入  $X_t$  拼接后与权重矩阵  $W_r$  相乘，再通过 Sigmoid 函数将数据维持在 0~1，如公式(12)所示。更新门接收的数据与重置门是一样的，由输入  $X_t$  和隐藏状态  $H_{t-1}$  负责  $t$  时刻更新门的输入，如公式(13)所示。

$$R_t = \sigma(W_r \cdot [H_{t-1}, X_t]) \tag{12}$$

$$Z_t = \sigma(W_z \cdot [H_{t-1}, X_t]) \tag{13}$$

候选隐藏状态  $\tilde{H}_t$  是由输入  $X_t$  拼接重置门  $R_t$  与隐藏状态的 hadamard 乘积(矩阵相同位置上的元素进行乘积)，再乘以权重矩阵  $W_h$ ，通过激活函数 tanh 将值固定在-1~1 的范围，如公式(14)所示。

$$\tilde{H}_t = \tanh(W_h [R_t \circ H_{t-1}, X_t]) \tag{14}$$

真正的  $t$  时刻隐藏状态  $H_t$  是由更新门  $Z_t$  与  $t-1$  时刻隐藏状态  $H_{t-1}$  的 hadmard 乘积加上  $(1-Z_t)$  与候选隐藏状态  $\tilde{H}_t$  的 hadamard 乘积。考虑极端情况，当门控单元  $Z_t$  为 1 时， $H_t$  等价于  $H_{t-1}$ ，网络过滤掉了输入  $X_t$ ， $t$  时刻状态完全等于  $t-1$  时刻状态，当门控单元  $Z_t$  为 0 时， $H_t$  等价于  $\tilde{H}_t$ ，忽视了之前隐藏层的状态。更新记忆表达式如公式(15)所示。

$$H_t = Z_t \cdot H_{t-1} + (1-Z_t) \cdot \tilde{H}_t \tag{15}$$

总体来看，GRU 模型与循环神经网络(RNN)在可学习参数数量上是相同的，但其可学习的权重矩阵是 RNN 的三倍。与 LSTM 相比，GRU 结构更加简化，减少了一个门的数量，从而显著降低了参数总数。因此，本研究采用双向门控循环单元(BiGRU)模型，能够同时从前向和后向处理输入序列，以获取更全面的上下文信息。这一结构使得模型在处理 UWB 信号到达时间(TOA)数据时，可以充分利用前向和后向的信息，从而提高特征提取能力。尤其是在应对 UWB 定位中的非线性特征时，这种能力能够显著减少定位误差。

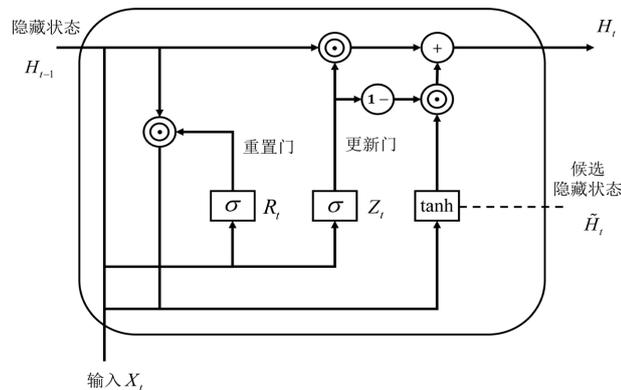


Figure 3. GRU architecture diagram  
图 3. GRU 结构图

双向门控循环单元(BiGRU)是 GRU 的扩展变体,其结构图如图 4 所示。它在序列数据的两个方向上进行信息传递和捕捉,进一步增强了模型对序列数据的建模能力。

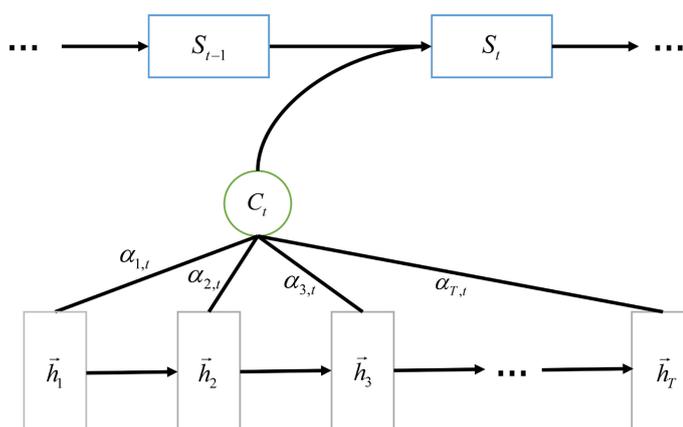


Figure 4. BiGRU architecture diagram  
图 4. BiGRU 结构图

### 3.2. Bahdanau 注意力机制

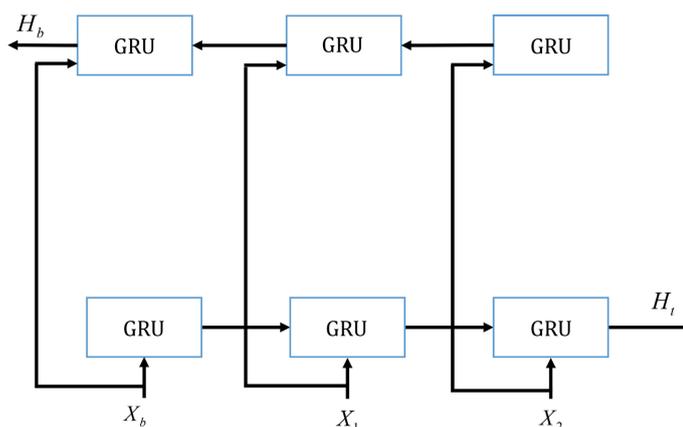


Figure 5. Bahdanau attention mechanism  
图 5. Bahdanau 注意力机制

Bahdanau 注意力机制通过动态加权输入序列的各个部分,增强神经网络在处理序列数据时对重要信息的关注能力,使模型能够专注于与当前任务最相关的信息,如图 5 所示。在 UWB 定位任务中,由于信号受到多路径效应和非视距环境的影响,不同时间步长的信号对定位结果的贡献各不相同。因此,该机制通过计算输入序列中每个时间步的重要性,并结合当前的隐藏状态,动态调整模型的注意力焦点,从而提升定位精度和模型表现。其核心在于计算注意力权重,该过程由当前的隐藏状态与所有时间步的输出结合,形成注意力得分。具体来说,注意力得分是通过将当前隐藏状态  $s_{t-1}$  与每个时间步的输出  $h_t$  拼接后,通过权重矩阵  $W_a$  进行线性变换,并传递给激活函数  $\tanh$  计算得出,如公式(16)所示:

$$e_{i,t} = v_a^T \cdot \tanh(W_a \cdot [h_i; s_{t-1}] + b_a) \tag{16}$$

其中,  $v_a$  是可学习的参数,  $b_a$  是偏置项。计算出的注意力得分通过  $\text{softmax}$  函数进行归一化,得到注意力权重  $a_{i,t}$ , 这些权重反映了每个时间步对当前输出的重要性,如公式(17)所示:

$$\alpha_{i,t} = \frac{\exp(e_{i,t})}{\sum_{k=1}^T \exp(e_{k,t})} \quad (17)$$

使用归一化后的注意力权重  $\alpha_{i,t}$  对输入序列的输出进行加权求和, 生成上下文向量  $c_t$ 。上下文向量汇集了序列中重要的信息, 对当前预测至关重要, 如公式(18)所示:

$$c_t = \sum_{i=1}^T \alpha_{i,t} h_i \quad (18)$$

在最终的输出层, 生成的上下文向量  $c_t$  将与当前的隐藏状态结合, 提供额外的信息用于生成输出。通过这种动态权重分配机制, 模型能够在复杂环境下更好地聚焦于关键信号, 从而提升定位精度。

### 3.3. 定位模型算法步骤

结合 Bahdanau 注意力机制的 BiGRU 模型在处理 UWB 的 TOA 数据时具体算法步骤如下:

输入: UWB 基站接收到的 TOA 数据

输出: 模型输出的目标位置坐标

步骤一: 数据准备

收集 UWB 系统的 TOA 数据及其对应的基站坐标, 确保数据的完整性和准确性。并且将 TOA 数据与基站坐标整合为适合模型输入的格式。对输入特征进行标准化处理, 以消除不同特征间的尺度差异, 确保模型训练的有效性和收敛速度。

步骤二: 构建模型

构建 BiGRU 网络, 并且引入 Bahdanau 注意力机制, 通过计算隐藏状态与输入序列中各时间步的关联性来动态分配注意力权重。在注意力机制输出的基础上, 设计全连接层用于生成最终的预测位置坐标。

步骤三: 模型训练与评估

不断调整参数, 确定模型的最佳参数, 并且在验证集上对模型拟合能力进行验证。

通过以上步骤, 结合 Bahdanau 注意力机制的 BiGRU 模型能够有效处理 UWB 的 TOA 数据, 提升室内定位的准确性, 并在复杂的多路径和非视距环境中表现出良好的鲁棒性。

## 4. 实验与结果分析

### 4.1. 模型训练及参数选择

为了验证所提模型的有效性, 本文实验使用的数据集来源于文献[14]。该数据集在一个  $6.5 \text{ m} \times 2.5 \text{ m}$  的实验区域内布置了 4 个定位基站, 基站坐标分别为  $(0 \text{ m}, 0 \text{ m})$ 、 $(6.5 \text{ m}, 0 \text{ m})$ 、 $(6.5 \text{ m}, 2.5 \text{ m})$ 、 $(0 \text{ m}, 2.5 \text{ m})$ 。实验过程中, 一个移动锚点沿预定轨迹在实验区域内移动, 模拟实际使用场景中的移动目标。使用超宽带和运动捕捉系统同步采集定位数据, 以保证数据的一致性和同步性。

该数据集包含 3200 个样本, 每个样本包括 4 个距离值以及对应的移动锚点的  $x$  和  $y$  坐标值。实验中, 将 80% 的数据样本用于训练模型, 20% 的数据样本用于测试模型。结合 Bahdanau 注意力机制的 BiGRU 模型使用 4 个输入神经元来获取移动锚点的 4 个距离值, 并使用 2 个输出神经元来预测移动锚点的  $x$  和  $y$  位置。本文从学习率、优化器、批量大小、隐藏神经元数量、BiGRU 网络层数、损失函数等多个方面, 分析了结合 Bahdanau 注意力机制的 BiGRU 模型的损失值随训练轮数的变化情况。

首先, 分析不同学习率对模型性能的影响, 对于较大的学习率, 模型在训练过程中往往不稳定, 在较小的学习率下, 模型在训练过程中可能导致收敛缓慢, 甚至可能无法训练模型。从图 6 可以看出, 学习率取 0.01 时, 模型在兼顾收敛速度的同时也更加稳定。因此, 本模型选择学习率为 0.01。

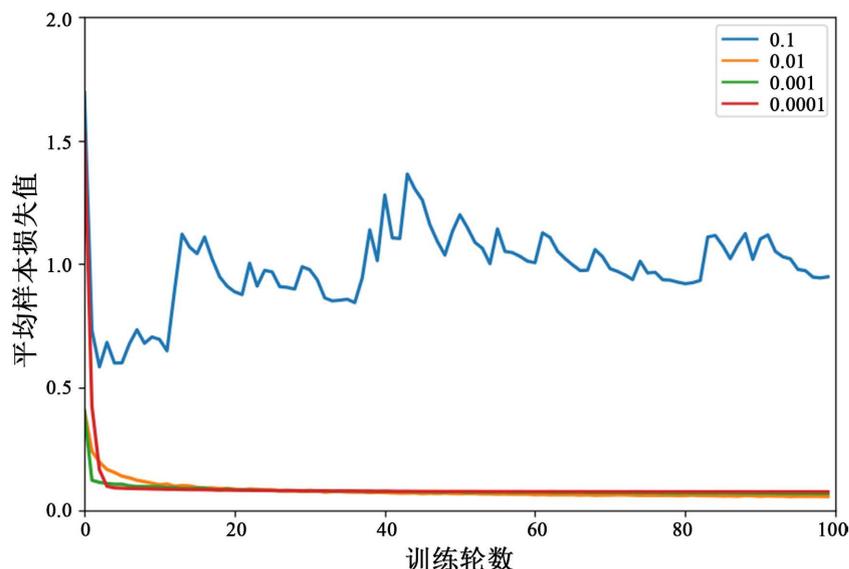


Figure 6. Training loss curves at different learning rates

图 6. 不同学习率的训练损失曲线

其次，分析不同优化器对模型性能的影响，优化器在提高模型精度方面起着至关重要的作用。当我们使用神经网络进行定位时，随着能量通过网络层传播，神经网络可能会出现梯度消失或梯度爆炸的现象。随着网络的复杂性增加，这些问题会变得更加严重，进而影响网络性能。为了避免梯度消失和梯度爆炸的问题，选择合适的优化器至关重要。从图 7 可以看出，在使用 NAdam 优化器的情况下，模型收敛速度快且平稳。因此，本模型选择优化器为 NAdam。

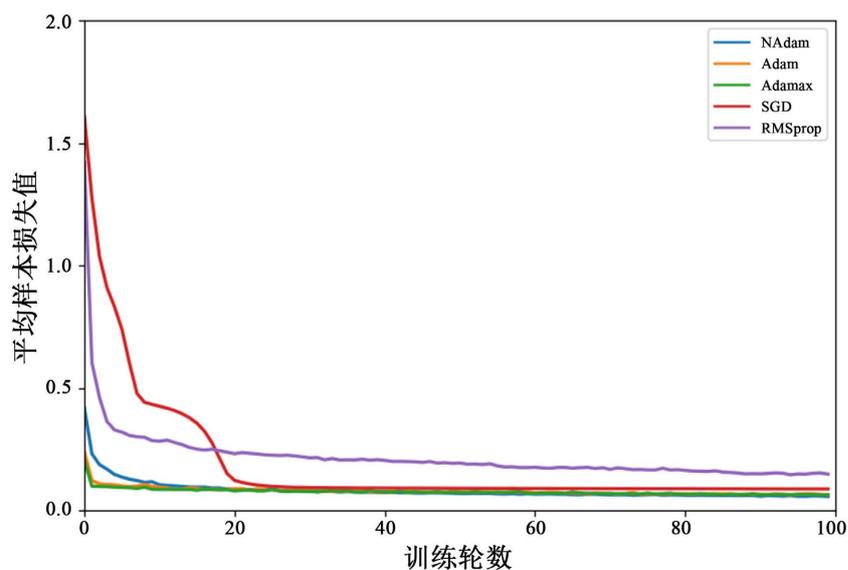


Figure 7. Training loss curves for different optimizers

图 7. 不同优化器的训练损失曲线

再次，分析不同批量大小对模型性能的影响，对于较大的批量大小，计算速度将显著提高。然而，较大的批量大小可能会导致模型的泛化能力下降，并且学习过程的收敛速度也可能减慢。相反，批量大

小过小则会导致模型训练时间过长,影响整体效率。从图 8 可以看出,当批量大小设置为 32 时,模型在收敛速度和稳定性方面表现最佳。因此,本模型选择批量大小为 32。

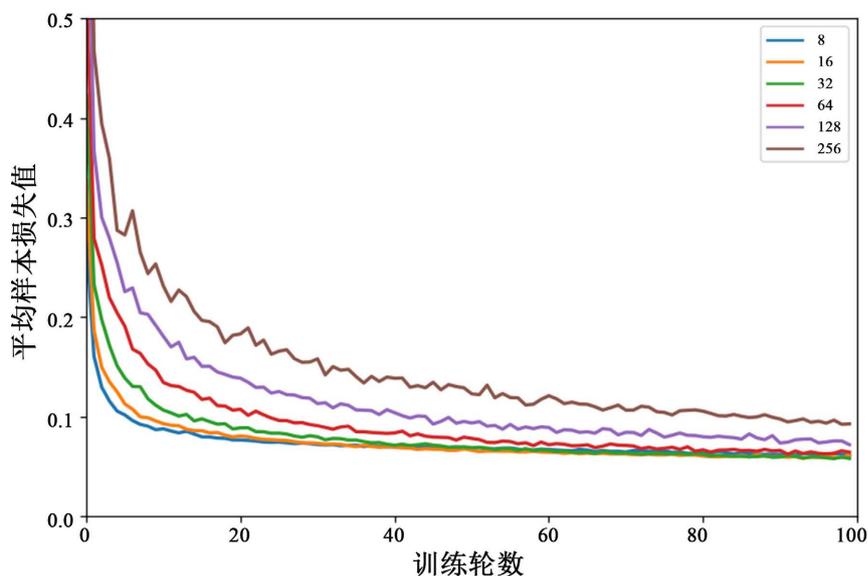


Figure 8. Training loss curves for different batch sizes

图 8. 不同批量大小的训练损失曲线

然后,分析不同隐藏神经元数量对模型性能的影响,隐藏神经元数量过多会导致模型过于复杂,容易过拟合。同时,隐藏神经元过多也会显著增加计算负担,降低训练速度。相反,隐藏神经元数量过少则会导致模型容量不足,无法有效捕捉数据中的复杂特征,导致欠拟合,模型从训练数据中学不到足够的模式,预测精度下降。从图 9 可以看出,隐藏神经元数量为 128 时,模型既能快速收敛,又能有效避免过拟合问题。因此,本模型选择隐藏神经元数量为 128。

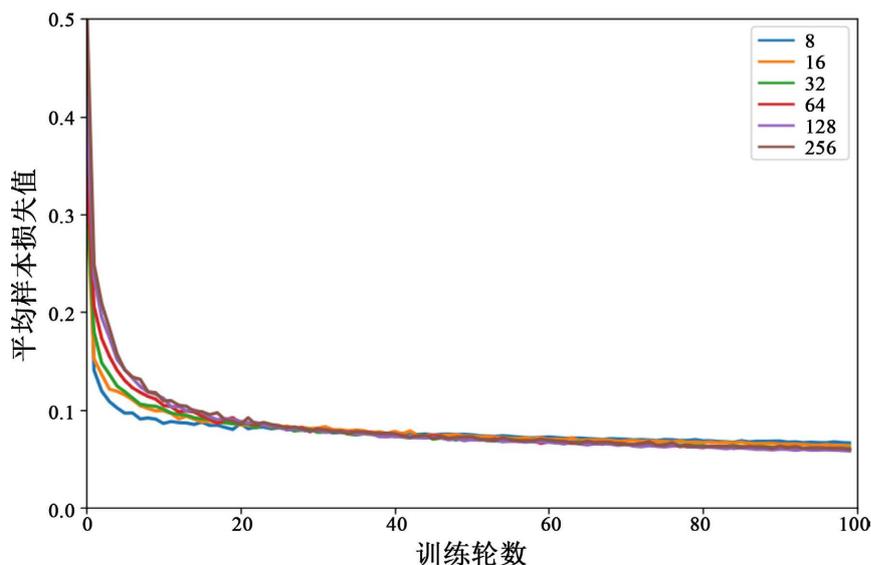


Figure 9. Training loss curve with different number of hidden neurons

图 9. 不同隐藏神经元数量的训练损失曲线

最后, 分析不同网络层数对模型性能的影响, 图 10 显示了在不同 BiGRU 网络层数下, 模型的平均定位距离误差。从图 10 可以看出, 随着 BiGRU 网络层数的增加, 模型的平均定位误差也随之减小, 导致模型性能提高。但当网络层数增加到 4 层及以上时, 模型的平均定位误差也随之增加, 导致模型性能下降。因此, 本模型选择网络层数为 3 层。

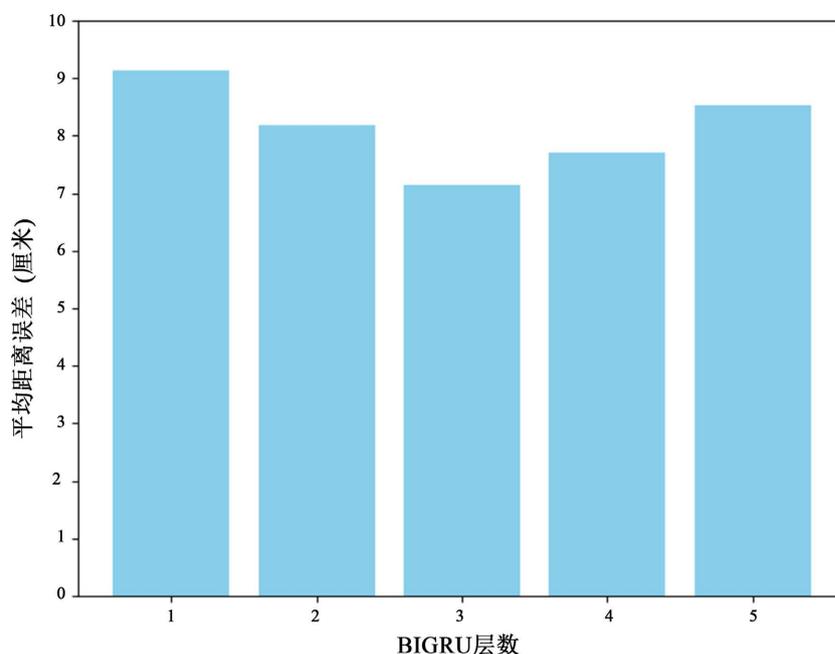


Figure 10. The average distance error of different BiGRU layers

图 10. 不同 BiGRU 层数的平均距离误差

本文选择平方根均方误差(RMSE)损失函数作为模型的损失函数。因此, 根据调整不同参数得到的训练结果, 本文所选择的各参数的值如表 1 所示。

在确定最佳参数后, 使用表 1 所示的参数来验证模型对测试集的效果, 并使用平均定位误差 A (模型在测试集上的总误差除以测试集中的样本数量)来观察模型的预测效果。

$$A = \frac{1}{n} \sum_{i=1}^n \left( (x_i^{\text{true}} - x_i^{\text{est}})^2 + (y_i^{\text{true}} - y_i^{\text{est}})^2 \right)^{0.5} \quad (19)$$

式中  $(x_i^{\text{true}}, y_i^{\text{true}})$  为 UWB 标签的实际位置,  $(x_i^{\text{est}}, y_i^{\text{est}})$  为本文提出的定位方法计算出的 UWB 标签的估计位置。n 值表示用于定位的数据样本总数, 在本文中,  $n = 640$ 。

通过对模型进行多次训练, 计算测试集上的平均误差, 可以得到训练后的模型在测试集上的平均误差为 6.9 cm。

Table 1. BiGRU neural network parameter value

表 1. BiGRU 神经网络参数值

BiGRU 神经网络参数	值
样本数	3200
训练样本数与总体样本数的比率	0.8

续表

训练轮数	100
批量大小	32
隐藏神经元数量	128
优化器	NAdam
学习率	0.01
网络层数	3
损失函数	RMSE

## 4.2. 不同算法对比

为了验证所提模型的优越性, 本文将结合 Bahdanau 注意力机制的 BiGRU 模型与传统的 GRU、LSTM 和 RNN 算法进行了详细对比。表 2 总结了不同循环神经网络在 UWB 室内定位模型上的训练和预测时间。从表 2 可以看出, 结合 Bahdanau 注意力机制的 BiGRU 模型在训练时间上多于其他循环神经网络。但是定位精度高于其他循环神经网络, 本模型在可接受的时间范围内给出了较高的精度。

综合实验结果表明, 结合 Bahdanau 注意力机制的 BiGRU 模型在定位精度上优于其他循环神经网络, 能够为 UWB 室内定位提供更好的定位效果。

**Table 2.** Training and prediction times of different recurrent neural networks  
**表 2.** 不同循环神经网络的训练和预测时间

模型	训练时间/s	预测时间/s	误差/cm
RNN	2.76	0.02	12.1
LSTM	2.99	0.03	10.9
GRU	2.87	0.03	9.8
本文模型	9.42	0.02	6.9

## 5. 结束语

在本文的研究中, 将结合 Bahdanau 注意力机制的 BiGRU 模型应用于 UWB 室内定位, 提出了一种新的室内定位方法。该方法以定位标签到基站的信号到达时间 TOA 作为网络输入, 从学习率、优化器、批量大小、网络层数、隐藏神经元数量和损失函数六个方面系统分析了不同参数对模型性能的影响, 并确定了模型的最优参数配置。实验结果表明, 结合 Bahdanau 注意力机制的 BiGRU 模型在 UWB 室内定位中的应用效果显著。与其他循环神经网络模型相比, 该模型的定位误差减少了 29.59%~42.98%。这表明, 随着深度学习技术的不断发展, 结合注意力机制的神经网络在复杂环境下的鲁棒性和精度优势将更加突出, 未来在室内定位领域的应用将更加广泛和深入。

## 参考文献

- [1] Xu, H.L. and Yang, L.Q. (2008) Ultra-Wideband Technology: Yesterday, Today, and Tomorrow. 2008 *IEEE Radio and Wireless Symposium*, Orlando, 22-24 January 2008, 715-718. <https://doi.org/10.1109/rws.2008.4463592>
- [2] 周军, 魏国亮, 田昕, 等. 融合 UWB 和 IMU 数据的新型室内定位算法[J]. 小型微型计算机系统, 2021, 42(8): 1741-1746.
- [3] Schmid, L., Salido-Monzu, D. and Wieser, A. (2019) Accuracy Assessment and Learned Error Mitigation of UWB TOF

- Ranging. 2019 *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Pisa, 30 September-3 October 2019, 1-8. <https://doi.org/10.1109/ipin.2019.8911769>
- [4] Zwirello, L., Li, X.Y., Zwick, T., Ascher, C., Werling, S. and Trommer, G.F. (2013) Sensor Data Fusion in UWB-Supported Inertial Navigation Systems for Indoor Navigation. 2013 *IEEE International Conference on Robotics and Automation*, Karlsruhe, 6-10 May 2013, 3154-3159. <https://doi.org/10.1109/icra.2013.6631016>
- [5] Li, X., Wang, H., Chen, Z., Jiang, Z. and Luo, J. (2024) UWB-Fi: Pushing Wi-Fi Towards Ultra-Wideband for Fine-Granularity Sensing. *Proceedings of the 22nd Annual International Conference on Mobile Systems, Applications and Services*, Tokyo, 3-7 June 2024, 42-55. <https://doi.org/10.1145/3643832.3661889>
- [6] Wang, F. and Lv, T.J. (2008) An Improved Kalman Filter Algorithm for UWB Channel Estimation. 2008 *3rd International Conference on Communications and Networking in China*, Hangzhou, 25-27 August 2008, 50-54. <https://doi.org/10.1109/chinacom.2008.4684967>
- [7] Guo, X., Ansari, N., Hu, F., Shao, Y., Elikplim, N.R. and Li, L. (2020) A Survey on Fusion-Based Indoor Positioning. *IEEE Communications Surveys & Tutorials*, **22**, 566-594. <https://doi.org/10.1109/comst.2019.2951036>
- [8] Olejniczak, A., Blaszkiewicz, O., Cwalina, K.K., Rajchowski, P. and Sadowski, J. (2020) Deep Learning Approach for LOS and NLOS Identification in the Indoor Environment. 2020 *Baltic URSI Symposium (URSI)*, Warsaw, 5-7 October 2020, 104-107. <https://doi.org/10.23919/ursi48707.2020.9253757>
- [9] Tan Anh Nguyen, D., Lee, H., Joung, J. and Jeong, E. (2020) Convolutional Neural Network-Based UWB System Localization. 2020 *International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju, 21-23 October 2020, 488-490. <https://doi.org/10.1109/ictc49870.2020.9289326>
- [10] Poulouse, A. and Han, D.S. (2020) UWB Indoor Localization Using Deep Learning LSTM Networks. *Applied Sciences*, **10**, Article No. 6290. <https://doi.org/10.3390/app10186290>
- [11] He, S., Yang, B., Liu, T. and Zhang, H. (2024) Multi-Tag UWB Localization with Spatial-Temporal Attention Graph Neural Network. *IEEE Transactions on Instrumentation and Measurement*, **73**, 1-12. <https://doi.org/10.1109/tim.2024.3462984>
- [12] He, X., Mo, L. and Wang, Q. (2023) An Attention-Assisted UWB Ranging Error Compensation Algorithm. *IEEE Wireless Communications Letters*, **12**, 421-425. <https://doi.org/10.1109/lwc.2022.3229104>
- [13] Poulouse, A., Kim, J. and Han, D.S. (2019) A Sensor Fusion Framework for Indoor Localization Using Smartphone Sensors and Wi-Fi RSSI Measurements. *Applied Sciences*, **9**, Article No. 4379. <https://doi.org/10.3390/app9204379>
- [14] Raza, U., Khan, A., Kou, R., Farnham, T., Premalal, T., Stanoev, A., *et al.* (2019) Dataset: Indoor Localization with Narrow-Band, Ultra-Wideband, and Motion Capture Systems. *Proceedings of the 2nd Workshop on Data Acquisition to Analysis*, New York, 10 November 2019, 34-36. <https://doi.org/10.1145/3359427.3361919>