复杂场景下基于卷积神经网络的 RFID 标签定位算法研究

摘　要

随着物联网的发展，射频识别（RFID）技术越来越受到人们的关注。RFID 是一种非接触式的数据自动采集技术，具有体积小、技术成熟、速度快等优点，特别是基于 RFID 的室内定位技术，在物联网应用中具有重要作用。然而，复杂的室内环境存在非视距、多径效应和阴影效应等多种干扰因素，目前的 RFID 定位算法抗干扰能力差，难以达到较高的定位精度。因此，高精度的 RFID 室内定位算法研究是迫切且具有深远意义的。

本文在分析了传统定位方法基础上，对基于卷积神经网络（CNN）的 RFID 标签定位算法展开了深入研究，本文的研究工作得到吉林省自然科学基金“复杂场景下基于位置指纹和深度学习的 RFID 多标签三维定位方法”（项目编号：20180101329JC）的资助。本文的主要工作如下：

首先，在 RFID 网络中，阅读器天线的位置会影响定位精度和覆盖范围，对此，提出了一种基于遗传算法（GA）的 RFID 阅读器二维布局优化方法，以及一种基于受限遗传算法（RGA）的 RFID 阅读器三维布局优化方法。通过 RFID 网络规划方法来优化阅读器布局。基于对接收信号强度、路径损耗特性和定位覆盖率的分析，推导了优化目标函数，并分别利用 GA 和 RGA 算法求解优化目标函数。与一般布局相比，优化布局显著改善了定位精度。

然后，针对现有指纹定位算法对数据的学习能力不够深入的问题，提出了一种复杂场景下基于 CNN 的无源 RFID 标签定位方法。在二维定位环境中，将接收信号强度（RSS）和到达相位差（PDOA）数据作为联合指纹特征来训练网络。从 RFID 阅读器接收到的信号中提取 RSS 和 PDOA 数据后，设计了一个包含三个卷积层和池化层的 CNN 模型，并将 RSS 和 PDOA 数据组合成图像作为输入训练 CNN 参数。在线阶段，根据设计的 CNN 对未知标签的位置进行预测。仿真结果表明，在结合阅读器优化布局的情况下，本文所提出的方法能够在复杂二维定位环境下对多个标签进行高精度和高稳定性的定位，优于现有的 LANDMARC 等定位方法。

最后，针对三维定位环境，提出了一种复杂场景下基于 CNN 的无源 RFID 标

签三维定位方法。通过三维空间传输模型采集数据来训练 CNN 网络，以实现良好的定位效果。对三维仿真环境进行了布局，并利用指纹数据训练 CNN 网络参数。为了便于比较，还推导了定位误差的克拉美罗下界（CRLB）。仿真结果表明，结合阅读器三维优化布局的 CNN 算法具有高的定位精度和抗噪声能力，优于 WKNN 等传统定位算法。

关键词：

射频识别（RFID），标签定位，卷积神经网络，网络规划，受限遗传算法，接收信号强度，到达相位差

Abstract

With the development of Internet of Things, radio frequency identification (RFID) technology has attracted more and more attention. RFID is a kind of non-contact data acquisition technology. It has the advantages of small size, mature technology and fast speed.In particular, RFID-based indoor positioning technology plays an important role in the application of the Internet of Things. However, complex indoor environment has a variety of interference factors such as non-line-of-sight, multipath effect and shadow effect, etc, and the current positioning algorithm has poor anti-interference ability and is difficult to achieve high positioning accuracy. Therefore, the research of high precision RFID tag location algorithm is urgent and has far-reaching significance.

Based on the analysis of traditional positioning methods, in this thesis, the RFID tag positioning algorithms are studied in-depth based on convolutional neural network (CNN) . The research work of this paper is funded by the Natural Science Foundation of Jilin Province "RFID multi-tag 3D positioning method based on location fingerprint and deep learning in complex scenes" (Project No. : 20180101329JC).The main work of this paper is as follows:

Firstly, in the RFID network, the position of the reader antenna will affect the positioning accuracy and coverage, so a two-dimensional layout optimization method of RFID reader based on genetic algorithm (GA), and a three-dimensional layout optimization method of RFID reader based on constrained genetic algorithm (RGA) are proposed in this thesis, respectively. The reader layout is optimized by RFID network planning method. By analyzing the received signal strength, path loss characteristics and positioning coverage, the optimization objective function is derived, and the optimization objective function is solved by GA and RGA algorithms respectively. Compared with the general layout, the optimized layout significantly improves the positioning accuracy.

Keywords:

RFID, tag positioning, convolutional neural networks (CNN), network planning, constrained genetic algorithms, received signal strength, phase difference of arrival

目　　录

第 1 章 绪论.....1
1.1 研究背景.....1
1.2 国内外研究现状.....3
1.3 课题研究意义.....6
1.4 本文内容安排.....7
第 2 章 RFID 室内定位技术及算法概述.....9
2.1 引言.....9
2.2 RFID 通信技术.....9
2.3 RFID 常见定位算法.....10
2.4 本章小结.....16
第 3 章 基于遗传算法的 RFID 阅读器布局优化研究.....17
3.1 引言.....17
3.2 RFID 信号传播模型.....17
3.3 阅读器二维布局优化研究.....21
3.4 阅读器三维布局优化研究.....23
3.5 遗传算法和受限遗传算法.....25
3.6 仿真结果及分析.....27
3.7 本章小结.....33
第 4 章 复杂场景下基于卷积神经网络的 RFID 标签二维定位算法研究
.....34

引言.....34
4.2 RFID 定位系统模型.....34
4.3 基于 CNN 的二维定位算法.....37
4.4 仿真结果及分析.....41
4.5 本章小结.....53
第 5 章 复杂场景下基于卷积神经网络的 RFID 标签三维定位算法研究.....54
5.1 引言.....54
5.2 基于 CNN 的三维定位算法.....54
5.3 克拉美罗下界.....57
5.4 仿真结果及分析.....58
5.5 本章小结.....62
第 6 章 总结与展望.....63
6.1 全文总结.....63
6.2 展望.....64
参考文献.....65
作者简介.....74
攻读硕士期间的研究成果.....75
致 谢.....81

第 1 章 绪论

1.1 研究背景

近年来，随着物联网（IoT）的出现，通过无线射频识别（RFID）技术[1-5]进行室内定位备受关注。RFID 是一种以空间电磁波为传输介质的非接触式数据自动采集技术[6]，它具有体积小、技术成熟、速度快、功耗低、容量大、抗干扰、寿命长、精度高等优点[7]。RFID 本地化在物流管理[8]、智能导购[9]、医疗服务[10]、公共安全[11]等多种物联网应用领域具有巨大潜力。其中，超高频（UHF）RFID 系统中的高精度三维定位对物联网设备的大规模布局起着至关重要的作用[12]。

室内定位不同于室外定位，室外定位需要全球定位系统（GPS）处理并利用视距（LOS）传输路径对目标实现位置估计。室内定位面临着复杂传播场景的巨大挑战[13][14]，如多径传播、阴影效应、非视距（NLOS）、衰落和延迟失真等[15]，导致定位性能下降。目前，室内定位技术大多采用 RFID 技术、WiFi、蓝牙和红外技术[16][17]。RFID 作为物联网的关键传感器之一，在室内定位应用中相对于其它无线通信技术具有特殊的优势。传统的 RFID 室内定位算法主要基于到达时间（TOA）、到达时差（TDOA）、到达角（AOA）和接收信号强度（RSS）[18][19]来进行定位，但在复杂的室内传播环境中，它们的定位效果不尽人意[20]。在这种情况下，基于指纹的室内定位方案可以有效地解决这些问题，提高定位精度。

指纹定位通常包括两个基本阶段：（1）离线阶段，也称为训练阶段；（2）在线阶段，也称为测试阶段[17]。离线阶段为数据库建立阶段，收集与参考标签相关的指纹数据并进行预处理。在线阶段，读取设备记录测试标签数据并使用数据库对其进行对比，然后对比输出用于测试标签的位置估计。对比方法通过搜索每个参考点来找到最匹配的目标位置。可以选择一个最匹配的参考位置作为测试标签的估计位置，另一种匹配算法是对比选择几个最接近的参考位置，每个位置具有最大的似然概率，将其作为权重，那么估计位置就是几个参考位置的加权平均。

在离线训练阶段，可以使用机器学习方法训练指纹，而不是存储所有接收到的信号强度（RSS）数据或其他指纹数据。这样的机器学习方法不仅降低了计算复杂

度，而且获得了指纹数据信息中的核心特征，从而获得了更好的位置估计性能。K近邻居算法（KNN）[18]、WKNN 和支持向量机（SVM）[16]等常用的机器学习方法已被应用于基于指纹的室内定位。

最近，深度学习已成为大数据处理领域的一项新兴技术[21-24] ，深度学习通常采用深度神经网络（DNN）[19]、深度信念网络（DBN）[25]和卷积神经网络（CNN）[26]等。与传统的指纹定位方法不同，基于深度学习的 RFID 室内定位方案有很多优点，具体如下：

（1）在离线训练阶段，将 RFID 参考标签放置在定位场景中，通过收集参考标签的通信数据建立指纹数据库。传统的指纹识别方法将所有的参考标签数据都存储在数据库中，而深度学习不仅将数据存储在指纹数据库中，还会建立神经网络学习指纹数据，来训练自身参数，神经网络在不断学习过程中可以获得提取指纹数据特征的能力，即使在指纹数据是含有噪声的情况下，也可以实现良好的训练效果。

（2）在线测试阶段，传统的指纹识别方法将收集的测试标签数据和参考标签的指纹数据进行比对，选择一个或者几个最匹配的参考标签来估计测试标签位置，而深度学习方法利用测试标签数据作为训练好的神经网络输入，来输出测试标签在每个参考点的概率分布，因此测试标签估计位置是几个概率最大的参考位置的加权平均[27]。

本文将深度学习中的卷积神经网络引入到 RFID 室内定位中，解决基于指纹定位中定位精度低、抗干扰差和多标签大数据处理问题。在 RFID 定位中，CNN 具有快速处理二维数据、深度提取和训练指纹特征、实时定位等优势。本文将 CNN 的网络结构设计为三个卷积层，三个池化层和一个全连接层。卷积层和池化层可以提取图像特征信息，减少特征维数，同时卷积层的参数共享模式减少了神经网络的参数，从而加快了 CNN 的运算时间。为了防止梯度弥散，本文在 CNN 模型中使用线性整流函数（Rectified Linear Unit，ReLU）作为激活函数[28] ，然后将最后池化层数据作为全连接层的输入，全连接层可以将多维数据转变为一维数据，最后利用 Softmax 函数输出概率分布，整个 CNN 模型类似一个分类器，训练完成后可以输出测试标签在每一个参考标签处的概率。

在许多应用中，RFID 系统阅读器的部署方式会影响定位精度。RFID 网络规划

（RFID network planning，RNP）需要解决这个问题，才能以最佳的方式运行大规模的 RFID 阅读器网络[29]，改善覆盖能力和定位精度。然而，RNP 是 RFID 技术应用中最具挑战性的问题之一，它必须满足 RFID 系统的许多要求。一般来说，RNP 的目标是通过调整系统的控制变量（如：阅读器的坐标、阅读器的数量、天线参数等）[30]，同时优化一组目标（如：覆盖、负载平衡、经济效率、阅读器之间的干扰等），因此在大规模部署环境下，RNP 问题是一个具有大量变量和不确定参数的高维非线性优化问题[31-37]。由于 RFID 阅读器可能组合的位置太多，非线性优化问题得到优化需要巨大的计算量，这就导致了探索式算法在该领域的应用[38-43]。粒子群优化算法（PSO）和遗传算法（GA）[30]通常是应用于一个群体中，通过一些算子在解空间周围搜索，直到找到最优解。实际上，许多群居网络的共同特征是团体结构，即个体有组成团体的倾向，团体内部的联系紧密，而团体之间的联系稀疏。最近的一些研究结果表明，网络在团体层面上的属性与在整个群体网络层面上的属性有很大的不同，因此专注于整个群体网络而忽略团体结构的分析可能会错过很多有用的特性。事实上，在生物种群中，同一物种的个体之间存在着持续的相互作用，也存在着与其他物种的相互作用。受团体结构聚类现象的启发，遗传算法与粒子群等相结合的算法得到了一定的应用[44]。

众所周知，无源超高频 RFID 通信有两个不同的链路：前向链路和后向链路。前向链路为无源 RFID 标签提供能量，后向链路携带标签信息。在 RFID 读写器与标签之间的通信过程中，通常会对路径损耗特性（PLC）[30]进行研究，发现 PLC 模型的导数绝对值随着阅读器与标签之间距离的增加而减小。这意味着，随着标签和阅读器之间的距离增加，不同距离处接收到的信号强度（RSS）值的差异变小。因此，阅读器在定位空间的放置会影响 RFID 定位系统的定位精度，这是值得探索的。

1.2 国内外研究现状

1.2.1 RFID 室内定位研究现状

近年来，一些基于指纹的传统 RFID 室内定位算法被提出[45]。在相关文献中，LANDMARC 提出了一种传统的基于指纹的 RFID 定位方案[46]。Mustika 等人提出了

一种新的指纹相似传感器模型，通过指纹识别和无源超高频 RFID 来定位无线机器人[47]。Phimmasea 等人提出了交叉技术来重建基于 RFID 的室内定位系统的指纹识别[48]。尽管这些方法比传统的技术更好地利用收集数据，但它们属于一类浅层学习方法，不能充分利用收集数据对大量 RFID 标签进行定位。

许多现有的室内定位系统由于其系统简单和低硬件要求而使用 RSS 作为指纹。例如，Horus 系统使用基于 RSS 数据利用概率方法进行位置估计[49]，这种基于 RSS 的方法有两个缺点。首先，由于室内环境中的多路径效应，RSS 值通常随着时间的推移对一个固定位置具有较高的可变性。如此高的变异性，即使对于静止的装置，也会带来较大的定位误差。其次，RSS 值是粗信息，它不利用正交频分复用（OFDM）中的子载波来获得更丰富的多径信息。目前可以从一些先进的 WiFi 网络接口卡（NIC）上获取信道状态信息（Channel State Information，CSI）作为指纹来提高室内定位的性能[50][51]，例如，FIFS 方案使用多个天线上 CSI 值的加权平均值来提高基于 RSS 的方法的性能[52]。此外，PinLoc 系统也利用了 CSI 信息，同时考虑了均匀分布参考点来训练数据[53]。

目前，基于深度学习和指纹定位方法已成为一种很有前途的室内定位技术。此方法通过建立具有完整现场测量数据的指纹数据库，然后利用数据库中的数据训练网络，收集新的测量数据来实现定位。Wang Xu 和 Yang Shao-Wei 等人研究了基于 WiFi 的深度学习室内定位方法，获得了较高的精度[23]。

文献[54][55]利用 RSSI 作为测量指标，提出了基于指纹的 RFID 定位方法[54][55]。另外也有相关文献讨论了基于 RSS 定位的实时性以及设备的限制性[56-58]。Z. Belhadi 等人提出了加权最近邻居（WKNN）方法[54]来提高 KNN 的定位精度。

虽然有一些文献研究了 RFID 技术的基于 RSS 的定位[59-65]，但基于 RFID 的无线定位的基本下界还未被探索。Hahnel 等人使用了一个带有 RFID 阅读器天线的移动机器人[65]，通过在墙上贴有 RFID 标签来生成室内环境的地图。映射阶段结束后，机器人可以根据最近的标签信息定位自己在建筑物内的位置。在 L.M 等人引入的 LANDMARC 定位技术中[66]，实现基于 RFID 参考标签的室内定位方法，使用已知位置的参考标签对测试标签进行定位。Zhao 等人改进了 LANDMARC 方法来处理多径效应和射频干扰[67]。另外有相关文献利用基于概率的 RFID 地图和卡尔曼滤波

技术来增强 RFID 标签的位置估计[68]。Williams 等人研究了 RFID 标签定位的另一种方法，此方法利用 RFID 标签背散射信号的相位差信息[69]。Leitinger 等人考虑多路径环境推导了基于 RFID 无线定位系统误差的 CRLB[70]，同时考虑了后向散射信道模型、多径分量和漫反射多径分量的几何特性。

目前较多文献中 RFID 传播模型通常采用简单的路径损耗模型或者自由空间路径损耗信号强度模型[71][72]。这些模型由于方向性强，无法准确捕捉 RFID 阅读器天线的辐射模式。文献中也有一些关于基于 RSS 的 UHF RFID 定位系统的实验研究。Çiftler 等人对 UHF RFID 系统进行了实验，研究了 RSS 与距离的关系[71]。基于 RSS 定位的 CRLB 考虑了频率依赖的路径损耗传播模型，此模型明确依赖于发射功率级别和发射频率[72]。另外相关文献通过仿真和实验，比较了几种定位技术在给定路径损耗模型下的定位精度。Akre 等人使用 KNN 算法根据 RSS 信息估计目标标签的位置[73][74]，对 4 个天线和 70 个标签进行了实验，结果表明，功率控制技术可以显著提高定位精度。Lieckfeldt 等人考虑了多径传播和信号散射对无源 UHF RFID 定位的影响，提出了一种利用不同标签在相同条件下 RSS 值的差异进行定位的算法，此算法的性能优于 LANDMARC[66]中使用的 KNN 算法[75]。文献[76]构建了 UHF RFID 系统的双参数路径损耗模型，表明 RFID 系统的 RSS 值比 WiFi 的 RSS 值更稳定，从而为基于 RFID RSS 的定位提供了更精确的位置估计[76]。

1.2.2 RFID 阅读器布局优化研究现状

与其他无线通信系统一样，对于 RFID 网络布局优化问题，也引起了许多研究者的兴趣。近年来，许多研究已经展开。

受生物种群进化思想的启发，探索式优化算法引起了人们的极大关注。其中，最成功的是进化算法（EA）[77]和群体智能算法（SI）[78]。进化算法（EA）是一种搜索方法，其灵感来自生物世界的自然选择和适者生存。目前在相关文献中存在几种不同类型的 EA 方法。其中包括遗传规划（GP）、进化规划（EP）、进化策略（ES）和遗传算法（GA）。群体智能是一种新颖的求解复杂优化问题的计算方法，其灵感来自于鱼群、鸟群和蚁群等社会系统的集体行为。目前，群体智能包括两种不同的算法，即蚁群算法（Ant colony optimization，ACO）和粒子群算法（PSO）。

等人提出了基于覆盖约束的最优阅读器布局方法[79][80]。Chiu 等人的研究重点是利用探索式算法解决干扰的调度问题[61]，另外文献[81]严格研究了一个负载均衡问题，并采用最小多处理器调度算法和最大网络流算法来解决负载均衡问题[81]。Chen 等人结合了主要的约束条件，提出了一个组合的措施，提出了解决 RNP 问题的整体最优解决方案[82]。

B.S 等人研究了不同天线角度对三维空间定位精度和覆盖面积的影响[7]。另外 Tuba 等人提出混合 Bat 算法来优化 RFID 网络布局[83]。Hasnan 等人提出了萤火虫算法和 MC-GPSO 算法解决 RNP 问题，并进行了比较和评估以获得最优 RNP[84]。为了克服链路预算的限制，Guerra 等人部署了几个复杂度低的类似洒水装置的发射器，以提高在多波段 RFID 配置中读取和定位标签的能力[85]。Decarli 等人设计了一种用于无源 RFID 定位的 RFID 与雷达传感器联合网络，并推导了其性能边界[86]。Godrich 等人提出了一种通过最小化 CRLB 并结合几何精度稀释（GDOP）来优化天线位置的方法，并取得了良好的效果[87]。

1.3 课题研究意义

RFID 定位是当前最热门的室内定位技术之一，然而，在复杂室内场景下，RFID 定位技术正面临巨大的挑战，比如室内的噪声、障碍物、多径和阴影效应等对定位精度带来了很大的影响，目前的定位方法难以实现满意的定位精度，同时在定位中没有考虑阅读器位置对定位的影响，主要存在如下问题：

（1）传统基于测距的定位方法（如：TOA、AOA）对于非视距、多径效应等室内复杂环境影响不具备良好的抗干扰能力，导致定位误差较大，甚至某些定位点由于非视距影响，难以实现定位。

（2）传统基于指纹的定位方法（如：WKNN、LANDMAR C 等）对指纹数据的学习能力不够，指纹数据库采集数据一般含有噪声，这类算法对噪声的鲁棒性较差。

（3）目前定位算法忽略了阅读器布局对定位精度的影响，没有以提高定位精度为目的来优化阅读器布局的研究。

因此，本文基于深度学习研究复杂场景下无源 RFID 标签的精确定位问题，具

有重要的理论和实际意义。

1.4 本文内容安排

本文重点研究复杂场景下基于卷积神经网络的RFID标签定位问题以及阅读器布局优化问题，解决目前RFID定位技术所面临的多径、非视距导致定位精度下降的问题。本文的主要内容安排如下：

第1章，阐述了课题研究背景，介绍了RFID技术的概念和应用领域、国内外RFID定位技术的发展现状，讨论了阅读器的布局问题，总结了如今RFID室内定位所面临的问题并指出本文研究的意义，最后介绍了本文的主要内容安排。

第2章，概述了现有RFID室内定位技术及算法。原理性地介绍了RFID技术的通信机制和通信频段，详细讨论了目前常见RFID定位算法的原理及优缺点。

第3章，提出了一种基于遗传算法的RFID阅读器二维布局优化方法，以及一种基于受限遗传算法的RFID阅读器三维布局优化方法。通过RFID网络规划方法来优化阅读器布局。通过分析接收信号强度、路径损耗特性和定位覆盖率，推导了优化目标函数，并分别利用遗传算法和受限遗传算法求解优化目标函数。与一般布局相比，优化布局显著改善了定位精度。

第4章，针对现有指纹定位算法对数据的学习能力不够深入的问题，提出了一种复杂场景下基于CNN的无源RFID标签定位方法。在二维定位环境中，将RSS和到达相位差（PDOA）数据作为联合指纹特征来训练网络，设计了一个包含三个卷积层和池化层的CNN模型。在线阶段，根据设计的CNN对未知标签的位置进行预测。仿真结果验证了算法的有效性。

第5章，针对三维定位环境，提出了一种复杂场景下基于CNN的无源RFID标签三维定位方法。通过三维空间传输模型采集数据训练CNN网络，以实现良好的定位效果。对三维仿真环境进行了布局，并利用指纹数据训练CNN网络参数。为了便于比较，还推导了克拉美罗下界（CRLB）。实验结果表明，结合阅读器三维优化布局的CNN算法具有高的定位精度和抗噪声能力，优于LANDMARC和WKNN等传统定位算法。

第6章，总结全文，并指出存在的问题和下一步研究方向。

本文的研究工作得到吉林省自然科学基金“复杂场景下基于位置指纹和深度学习的 RFID 多标签三维定位方法”（项目编号：20180101329JC）的资助。

第 2 章 RFID 室内定位技术及算法概述

2.1 引言

RFID 技术近年来逐渐成熟，已成为室内定位领域中常用的定位技术。本章首先对 RFID 技术的通信原理进行阐述，介绍 RFID 无线信号的常用频段。然后，重点介绍一些常见的 RFID 定位算法，例如到达时间算法（TOA）、最近邻居算法（NN）、K 最近邻居算法（KNN）、加权 K 近邻居算法（WKNN）和 DNN 算法，并对算法的优缺点进行总结。

2.2 RFID 通信技术

RFID 技术在标签与阅读器之间建立通信，利用无线信号传递信息。RFID 通信所使用的无线信号频段、通信距离和数据传输速率不相同。RFID 频段可以分为低频（LF）、高频（HF）、超高频（UHF）三种，具体信息如表 2.1 所示。

表 2.1 RFID 不同频段无线信号分类

	频段	通信距离	数据速率
低频（LF）	120-150KHz	10cm	低速
高频（HF）	13.56MHz	10cm-1m	低速到中速
超高频（UHF）	433MHz	1m-100m	中速到高速
	860MHz-960MHz	1m-12m	中速到高速
	2.45GHz/5.8GHz	1m-2m	高速

UHF RFID 通信与传统的射频通信有着本质的不同，因为它有两个不同的链路：前向链路和反向链路。前向链路为无源 RFID 标签供电，使 RFID 标签能够无电池运行，这是 RFID 系统在低功耗物联网应用中的一个主要优势。反向链路携带标签的信息。一般来说，UHF RFID 系统有两种配置：单基站配置和双基站配置。在单基站结构中，单个阅读器天线发射携带能量的无线信号，使无源标签获得能量，从而激活自身并向阅读器发射反向信号；随后阅读器天线接收标签反向散射信号，即

同一个阅读器天线实现发射信号和接收信号。在双基站结构中，传输和接收由不同阅读器天线完成，这些天线可能是同一位置（即接收和发射天线位置相同）或错位（即接收和发射天线在不同位置）。这两种配置都要明确考虑复杂的三维 RFID 传播模型，以准确地描述真实环境中的正向和反向传播信道。

2.3 RFID 常见定位算法

2.3.1 基于非指纹的 RFID 定位算法

基于非指纹的 RFID 定位方法主要包括基于到达时间定位（Time Of Arrival，TOA）、基于到达时间差定位（Time Different Of Arrival，TDOA）、基于信号到达角度定位（Angle of Arrival，AOA）和基于接受信号强度定位（Received Signal Strength，RSS）。

TOA 定位方法中，首先通过阅读器向标签发射无线信号，标签接收到信号后激活自身，向阅读器发射反向信号，基于此过程阅读器可以计算出前向链路和反向链路信号的传播时间。根据无线信号传播速度、时间和距离之间的关系，计算阅读器到标签之间的距离。假设在二维平面内想要计算出标签的坐标，只需要计算出标签与三个不在一条直线上的阅读器之间的距离，然后求解方程组即可。从 TOA 定位的过程可以看出，TOA 对时钟的同步性及精准性要求较高，同时，标签接收信号激活自身，然后发射反向信号的过程中会导致一定的误差，TOA 算法也受到室内的噪声、非直视路径等影响，不能够满足高精度的定位要求。

TDOA 定位方法和 TOA 定位方法的原理类似，TDOA 通过计算不同阅读器与标签通信的时间差来进行定位，它计算的不再是阅读器与标签之间的距离，而是标签与不同阅读器之间的距离差，进而通过距离差建立方程对待定位标签坐标进行求解。因此 TDOA 定位误差和 TOA 大致相同。

AOA 定位方法与 TOA、TDOA 定位方法有一定区别。AOA 定位方法需要测量出信号到达阅读器的角度，因此需要在阅读器上安装天线阵列。通过接收信号角度，可以预测出标签在哪一条直线上。在二维平面上，根据两条直线相交于一点的原理，只需要计算出标签到两个阅读器的角度，就可以估计待测标签的具体坐标。AOA 定

位方法所需阅读器数量比 TOA、TDOA 少，但在阅读器上增加天线整列是比较复杂的且增加了系统成本，同时室内复杂的环境（非直视路径、阴影效应）会影响定位的精度。

基于 RSS 的定位方法和 TOA 计算方式类似，也是通过测量阅读器与标签之间的距离，建立方程组求解坐标。根据 Friis 电磁波传输理论可知，接收信号强度与距离的平方成负相关，因此只需要要确定阅读器信号的发射功率及增益，根据接收信号强度与距离模型就可以实现定位。RSS 对时钟及设备要求不高，但同样基于 RSS 定位也不能克服室内复杂环境引起的较高定位误差问题，难以实现高精度定位效果。

2.3.2 基于指纹的传统 RFID 定位算法

基于指纹的传统定位技术主要包括最近邻算法（Nearest Neighbour，NN），K 近邻居算法（K Nearest Neighbours，KNN），加权 K 近邻居算法（Weighted K Nearest Neighbours，WKNN），LANDMARC 算法。

基于指纹的定位算法核心原理如图 2.1 所示。首先需要在定位场景中布置阅读器和参考标签，接着记录参考标签与阅读器通信的特征数据，一般为 RSS 或者相位信息，第 j 个参考标签的特征数据可以表示：$S_j=\left(s_1^j,s_2^j,s_3^j,...,s_M^j\right)$，其中 M 为阅读器的数量；接着将其结合标签的序号或者坐标进行存储，因为每一个参考标签位置不同，与阅读器通信过程中的 RSS 或相位信息必然不同，每一个标签信息拥有独特性，因此被称为指纹数据，由此可以建立指纹数据库。在定位阶段，首先获得测试标签的特征数据，记为：$S^t=\left(s_1^t,s_2^t,s_3^t,...,s_M^t\right)$，接着将测试标签数据与指纹数据库中参考标签的指纹数据进行对比，选取最近的或者 K 个最近的参考标签来进行位置估计，一般对比方式为计算测试标签数据与参考标签数据的欧氏距离，测试标签与第 j 个参考标签之间的欧氏距离可以表示为

$$D_j=\sqrt{\sum_{i=1}^{M}(s_i^t-s_i^j)^2},\ j=1,2,...,N \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (2.1)$$

其中，N 为参考标签数量。

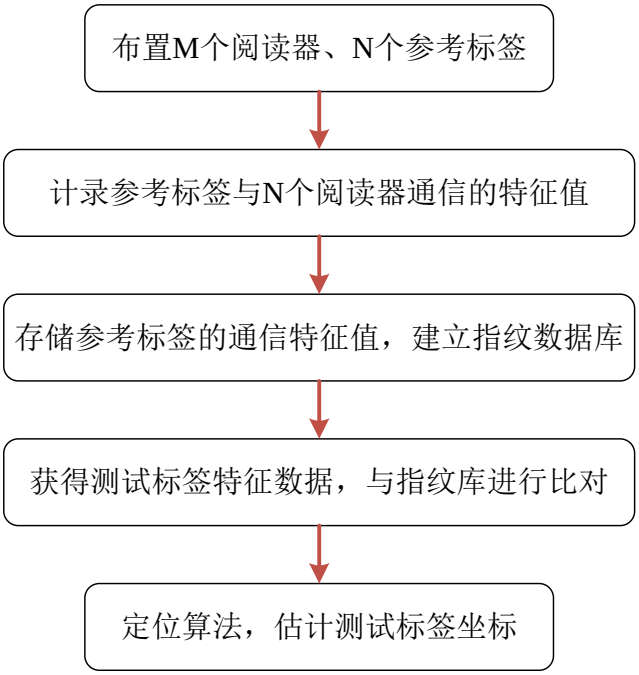


图 2.1 基于指纹的传统算法定位流程图

（1）NN 算法

最近邻居算法（Nearest Neighbour，NN）是最基本的位置指纹定位算法。最近邻居（NN）算法即选取 D_j 最小的参考标签坐标作为自己的估计位置。其定位原理是：阅读器首先获得在其工作范围内的标签发射的信号强度，针对一个标签在不同阅读器中获取接收信号强度不同，将其记为 $RSS=\left(RSS_1,RSS_2,RSS_3,\cdots\cdots,RSS_m\right)$，其中 M 为系统中阅读器个数。然后将此数据集与指纹数据库中针对参考标签所采集指纹数据 $S_n=\left(s_{n1},s_{n2},s_{n3},\cdots,s_{nM}\right)$ 进行匹配，其中 N 为参考标签数目。最近邻居算法在匹配时利用式（2.1）计算 RSS 与 S_n 之间的欧氏距离，获取与待定位标签欧氏距离最小指纹数据 S_n，并以 S_n 对应的位置坐标 $\left(x_n,y_n\right)$ 作为待定位标签的位置坐标。

$$\min\left(D_i\right),D_i=\left|\sum_{j=1}^{M}\left(RSS_j-s_{ij}\right)^2\right|^{\frac{1}{2}},\ i=1,2,\ldots\ldots N\cdots\cdots\cdots（2.2）$$

其中，D_i 为阅读器接收标签发射的信号强度 RSS 与第 i 个指纹数据 S_i 之间的欧氏距离，RSS_j 为第 j 个阅读器获取到待定位标签发射的信号强度，s_{ij} 为第 j 个阅读器

获取到的第i个参考标签发射的信号强度。

（2）KNN 算法

K 近邻居算法（K Nearest Neighbours，KNN）是在最近邻居算法的基础上做出改进。KNN 算法选取D_j最小的 K 个参考标签坐标取平均值作为自己的估计位置。主要工作原理是在指纹数据库中获取 $K(K \geq 2)$个指纹数据，并提取与这 K 个指纹数据相对应的位置坐标并计算它们的平均坐标$(\bar{x}, \bar{y})$，并将其作为待定位标签的位置坐标，即

$$D_i = \sqrt{\sum_j^n \left(RSSI_j - f_{ij}\right)^2}, i = 1, 2, \cdots\cdots, N \cdots\cdots\cdots\cdots\cdots\cdots（2.3）$$

$$(\bar{x}, \bar{y}) = \frac{1}{K}\sum_{i=1}^{K}(x_i, y_i)\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots（2.4）$$

其中，(x_i, y_i)为第i个参考标签的位置坐标。

（3）WKNN 算法

加权 K 近邻居算法（Weighted K Nearest Neighbours，WKNN）则是在 K 近邻居算法的思想上做出的更进一步改进， WKNN 和 KNN 方法类似，只不过在每个参考标签坐标之前乘以权重，不再求平均。 WKNN 将从位置指纹数据库中提取出来的 K 个参考标签的位置坐标乘以一个加权系数，然后将加权后的结果作为带定位标签的位置坐标，实现对待定位标签的定位，即：

$$\hat{l} = \sum_{i=1}^{K} \frac{1/(D_j + \varepsilon)}{\sum_{j=1}^{K} 1/(D_j + \varepsilon)} \times l_i \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots（2.5）$$

其中，ε为很小的数，防止除 0，$\hat{l}, l_i$ 分别为测试标签估计位置和第i个参考标签的位置坐标。

（4）LANDMARC 算法

LANDMARC 系统是典型的场景参考法，利用定位场景中参考标签进行辅助定位。其主要工作原理是通过比较待定位标签与参考标签之间的接收信号强度，从而

选取与待定位标签之间距离最近的 k 个参考标签，利用参考标签的位置坐标来估计待定位标签位置，从而实现定位。

LANDMARC 根据测试标签数据参照式（2.4）从参考标签中从中选取 k 个最小欧氏距离值，并提取对应参考标签坐标与权值相结合实现对待定位标签的位置估计，其位置计算方式为

$$(x,y)=\sum_{i=1}^{k} w(x_i,y_i) \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots（2.6）$$

其中， w 为每个参考标签的权重因子，可由式（2.6）获得

$$w=\frac{1/D_T^2}{\sum_{i=1}^{k} 1/D_{iT}^2} \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots（2.7）$$

其中， D_T 表示测试标签与第 T 个参考标签的欧氏距离。

从上述算法可以看出，基于指纹的定位算法不依赖于数据信息与距离或者角度的直接映射关系，而是通过指纹比对的方法来进行位置估计，因此在一定程度上减少了非直视路径、噪声等环境干扰带来的定位误差，相对于非指纹的定位算法增强了抗干扰能力，但同时可以看出，指纹定位增加了定位系统的成本以及复杂性，需要合理布局阅读器与参考标签，还要人力采集建立指纹数据库。

2.3.3 基于深度神经网络的 RFID 室内定位算法

深度神经网络（DNN）是一种多层神经网络模型，其中包含多层隐藏层。第一层是输入层，以数据库中的指纹数据作为输入，最后一层输出的是设置的目标函数，假设第 m 层的激活向量为

$$\mathbf{a}^m=\left(a_1^m,a_2^m,\cdots\cdots,a_{k_m}^m\right) \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots（2.8）$$

其中，k_m 为第 m 层隐藏层的节点数。那么相邻两层之间激活向量之间的关系可以表示为

$$\mathbf{a}^{m+1}=\varphi\left(\mathbf{W}^m\mathbf{a}^m+\mathbf{b}^m\right) \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots（2.9）$$

其中， $\mathbf{W}^m$ 为两层之间的权重矩阵， $\mathbf{b}^m$ 为两层之间的偏置向量，激活函数 $\phi(\cdot)$ 为

或者 ReLU 函数。

对于深度神经网络算法，分为两部分：首先初始化权重矩阵 $\mathbf{W}$ 和偏置向量 $\mathbf{b}$，并根据训练数据进行逐层的初始训练；然后，对测试数据进行位置估计获取位置信息。

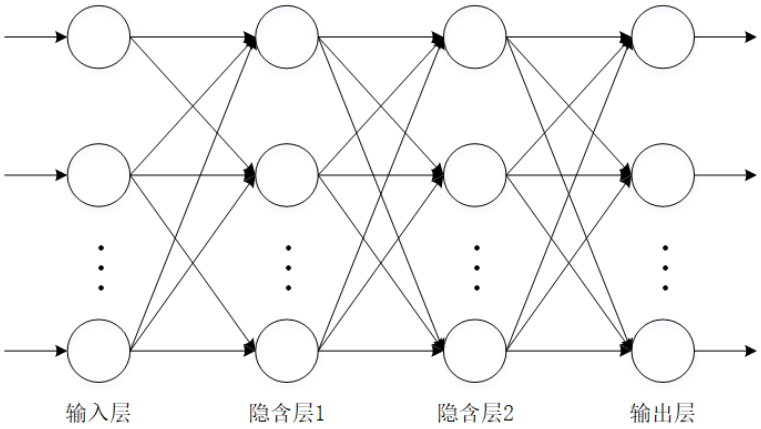


图 2.2 深度神经网络模型结构

首先对深度神经网络模型进行初始化，对各层权重矩阵 $\mathbf{W}$ 及偏置向量 $\mathbf{b}$ 进行随机赋值，获取初始深度神经网络模型。

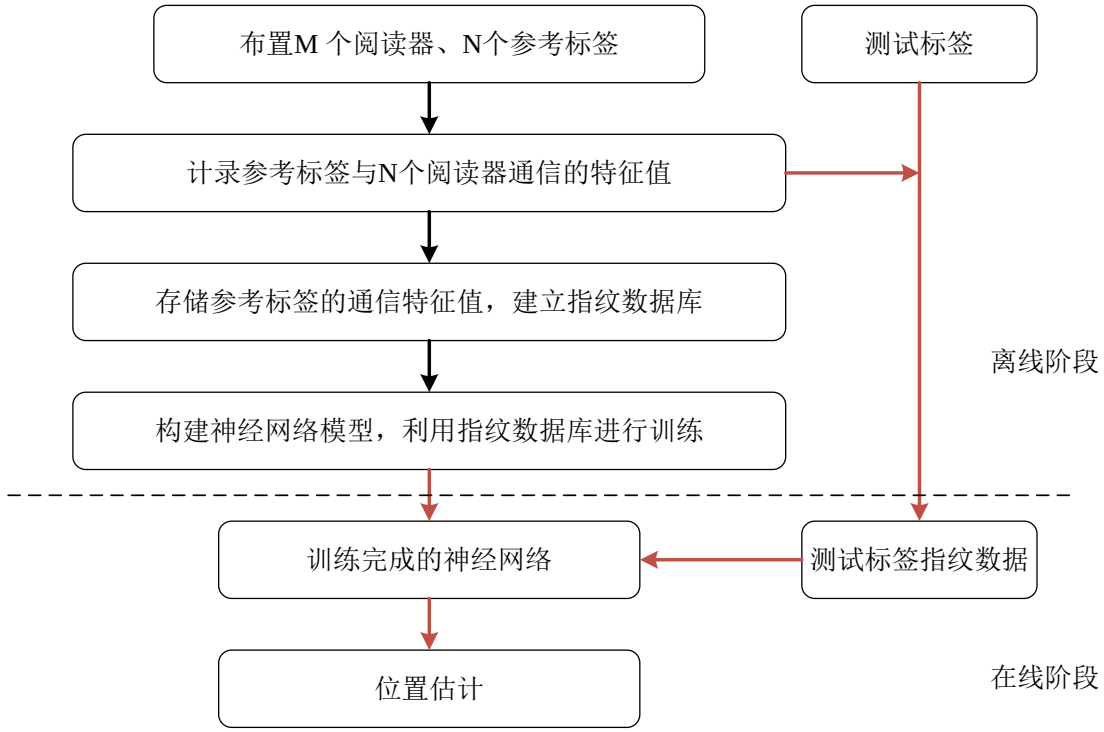


图 2.3 基于深度神经网络算法的定位流程

深度神经网络全局训练与一般神经网络训练是相同的，输入层向量是参考标签

的指纹数据，输出则是设定的目标向量，中间是各个隐藏层，并利用梯度下降算法来对各层参数进行训练，最终达到收敛的效果，获取深度神经网络模型，然后利用测试集数据即待定位标签指纹数据，通过深度神经网络对其目标向量进行预测，从而获得待定位标签位置坐标。

基于深度神经网络和位置指纹的 RFID 室内定位算法流程如图 2.3 所示。DNN 定位方法主要原理为利用神经网络来学习指纹数据，而不再是只记录指纹数据，神经网络具有深度学习能力，能够更充分的利用指纹数据特征，并具备一定的抗噪声能力，因此可以有效的提高定位精度。图 2.3 可以看出基于 DNN 的定位方法包括两个阶段，离线阶段和在线阶段。离线阶段除了要完成指纹数据库的建立，还要训练神经网络。在线阶段，获取测试标签指纹数据，送入训练完成的神经网络，即可得到测试标签的估计位置。基于指纹的神经网络算法可以深入学习指纹特征，对于室内环境中的噪声、阴影效应、非直视路径等干扰等具有良好的抵抗性，因此在定位精度和稳定性上可以获得较大提高。

2.4 本章小结

本章首先简单介绍了 RFID 通信技术，RFID 通信机制包括前向链路和反向链路，同时介绍了 RFID 常见的信号频段。然后，本章讨论了一些热点的 RFID 定位算法，大致分为非指纹算法、指纹算法和深度神经网络算法来讨论，研究了这些定位算法的原理以及存在的问题。通过原理分析可以看出，指纹算法比非指纹算法的抗噪声能力更强，指出了指纹算法定位的优势；同时阐述了神经网络的学习训练以及测试过程，指出深度神经网络比传统指纹算法具有更好的学习能力。

第 3 章 基于遗传算法的 RFID 阅读器布局优化研究

3.1 引言

在第 2 章中重点介绍了 RFID 技术原理，以及目前常用的 RFID 定位技术。在 RFID 定位技术中，阅读器布局问题是指纹定位方法的重要研究问题，因为不合理的布局会导致标签通信覆盖率下降以及会影响定位精度。本章对阅读器的优化布局进行详细的阐述，利用数学理论来分析如何合理布局来实现高定位覆盖率和高定位精度，同时利用遗传算法对阅读器优化布局目标函数进行求解，并通过 WKNN 算法验证优化布局对定位效果的影响。

3.2 RFID 信号传播模型

3.2.1 对数路径损耗模型

RFID 的通信机制是基于阅读器优先发言的半双工通信机制。与一般的无线通信方式不同，RFID 包括前向链路、反向链路和多径信道传输链路。在 RFID 通信系统中，阅读器天线向周围的无源标签发送询问信号。标签接收到发射的信号后，用信号能量激活自身，然后将信号反向散射到阅读器天线。通过测量可以从这些信号中提取 RSSI 和 PDOA 值。RFID 前向向和反向链路传播场景如图 3.1 所示。

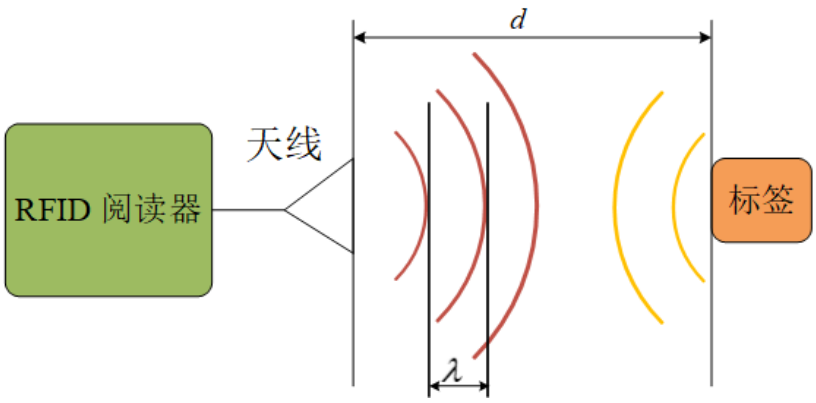


图 3.1 RFID 通信模型

在实际应用中，无线信号的传播环境非常复杂。本文利用对数路径损耗模型来模拟射频识别信号的传播。根据文献[25]RSS 可以用如下公式确定

$$RSS[dBm]=P_T[dBm]+G_t[dBi]+G_r[dBi]-P_L(f,d)[dB]+X_\sigma \cdots\cdots （3.1）$$

其中，

$$P_L(f,d)=10n\lg\left(\frac{4\pi f}{c}\right)+10n\lg(2d) \cdots\cdots （3.2）$$

其中，公式（3.1）的 P_T 为射频识别阅读器传输信号的功率。G_t 和 G_r 分别为 RFID 阅读器发射天线和接收天线的增益，$P_L(f,d)$ 表示信号频率为 f 、 RFID 阅读器与标签的距离为 d 时的路径损耗，单位为 dB。c 是光速，n 为路径损耗常数，它表示路径损耗随距离增加的速率，与周围环境和建筑材料类型有关，一般取 $n\in[2,3]$ 表示复杂的室内环境。$X_\sigma \sim \mathcal{N}(0,\sigma_1^2)$ 表示均值为 0、方差为 σ_1^2 的高斯分布噪声。

3.2.2 到达相位差模型

基于相位差的定位方法（PDOA）利用 RFID 阅读器接收到的发射信号和接收信号的相位差来进行位置估计的方法。其定位原理如图 3.1 所示。

设 RFID 标签与阅读器之间的距离为 d，阅读器发射载波信号直至接收到标签返回信号的时间为 Δt（从标签接收到发射载波信号的时间忽略不计），已知射频信号在空气中传输的速度为 c（3×10^8 m / s），速度距离公式可以表示为

$$2d=c\times\Delta t \cdots\cdots （3.3）$$

设从阅读器发射载波信号直至接收到标签的返回信号经历的相位为 φ，f 为载波频率，则 Δt 可以表示为

$$\Delta t=\frac{\theta}{2\pi f} \cdots\cdots （3.4）$$

此时可得

$$d=\frac{c\theta}{2\pi f} \cdots\cdots （3.5）$$

其中，φ 为未知，设阅读器发射的载波信号返回阅读器时，接收到的变化相位角为

φ_R，则有：$\varphi=2\pi k+\varphi_R$，$\varphi_R \in [0, 2\pi]$。但是信号在传输过程中经历的整周期数 k 是无法获取的，因此测量的相位信息不能直接用于定位。阅读器只能接收信号的相位值，而不能获得接收信号相位周期变化的次数，因此测量的相位发生了相位缠绕，要使用不同频率的载波多次测量返回信号的相位值，才可获得完整的相位变化。

在 RFID 正向和反向传播过程中，RFID 阅读器与标签之间的空间距离、硬件电路、多径信号和传输线的影响都会引入相位变化。在参考文献[25]中研究了相位解缠绕的方法，本文模型中将直接应用解缠绕的相位信息。因此可以将到达相位差模型表示为

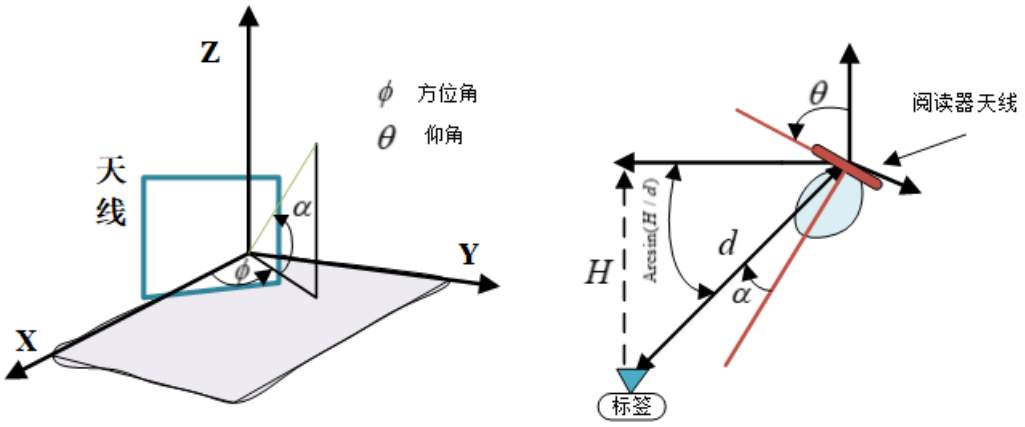
$$\begin{aligned} \varphi &= \varphi_p + \varphi_e \\ \varphi_p &= \frac{4\pi d}{\lambda} \\ \varphi_e &= \frac{4\pi d Z_\sigma}{360} \end{aligned} \quad \cdots\cdots\cdots\

在超高频（UHF）RFID 三维空间传输模型中，天线的角度，增益都会影响阅读器与标签之间的信号传播。如图 3.2 所示，本文建立一个三维 UHF RFID 辐射模型，并将 RIFD 阅读器天线设置为单基站传输模型，其中阅读器天线用于发射和接收。

假设阅读器天线 i 的坐标为 $\left(x_i^r, y_i^r, z_i^r\right)$，标签 j 的坐标为 $\left(x_j^t, y_j^t, z_j^t\right)$，当阅读器天线 i 与标签 j 进行通信时，阅读器天线 i 的反向散射接收功率为[11]

$$\tilde{P}_R(x_i^r, y_i^r, z_i^r) = \tau \mu_T \rho_L P_T G_R^{i\,2} G_T^2 \left| L(d_{ij}^f) L(d_{ij}^b) \right| h_{ij} \Big|^4 |\Gamma|^2 \quad \cdots\cdots\cdots\cdots (3.7)$$

其中，τ 为数据量化编码调制细节系数，$\mu_T \in [0,1]$ 为功率传输效率，它量化标签与天线之间的阻抗匹配程度。ρ_L 是极化损耗因子，表示阅读器天线和标签天线之间极化失配造成的损失。P_T 为 RFID 阅读器天线的有效各向同性辐射功率（EIRP），G_R^i 和 G_T 分别为阅读器天线和标签天线的增益。h_{ij} 表示前向信道和后向信道的响应。Γ 表示微分反射系数。λ 为信号的波长，d_{ij}^f 和 d_{ij}^b 分别为阅读器和天线之间的正向和反向链路的传播距离。



（a）　　(b)

图 3.3 阅读器天线仰角和方位角参考图：(a) 球坐标系，(b) 天线到固定标签

对于单基站的 RFID 通信模型，d_{ij}^f 和 d_{ij}^b 相同，因此公式(3.7)可以用对数形式表示为

$$P_R\ x_i^r\ y_i^r\ z_i^r = \tau\mu_T\rho_L P_T G_T \left|h_{ij}\right| \left|\Gamma\right| + G_R^i + L\ d_{ij} \quad (3.8)$$

其中，$L\left(d_{ij}\right)$ 表示信道路径损耗，d_{ij} 表示标签和阅读器天线之间的距离，$L\left(d_{ij}\right)$ 可以根据下式来计算

$$L(d_{ij}) = \left(\frac{\lambda}{4\pi d_{ij}}\right)^2 \quad \cdots\cdots (3.9)$$

UHF RFID 系统的 EPC Gen2 协议规定[12]，RFID 阅读器天线的发射功率限制为 $2W$ 的有效辐射功率，发射功率的大小影响阅读器可通信的覆盖面积，这种情况下，RFID 阅读器的 EIRP 限制为 $35.15\,dBm$。

在 UHF RFID 通信系统中，h_{ij} 表示信道的前向链路和后向链路，参数 Γ 表示标签的微分反射系数，它是标签天线 G_T 的函数，将雷达横截面（Radar Cross Section，RCS）表示为 σ_{RCS}，Γ 可用下式来计算

$$\left|\Gamma\right|^2 = \frac{4\pi}{\lambda^2\left|G_T\right|^2}\sigma_{RCS} \quad \cdots\cdots (3.10)$$

RCS 表征了散射功率，在无源超高频 RFID 应用中，目标是最大化 RCS，同时还要保证标签接收足够的功率来激活自身。本文参考文献使用了统计模型来计算 RCS[10]和 Γ。

如图 3.3 所示，结合参考文献[8]在三维传播环境中阅读器天线 i 的修正方向增益可以表示为

$$G_R^i(\alpha_i,\phi_i) = 3.316[\tan(\alpha_i)\sin(0.5\pi\cos(\alpha_i)) \times\cos(0.5\pi\sin(\alpha_i)\sin(\phi_i))]^2 \quad \cdots\cdots (3.11)$$

其中，$\alpha_i = \theta_i - \arcsin(H/d_{ij})$，$\theta_i$ 和 ϕ_i 分别表示阅读器天线 i 的仰角和方位角。H 表示阅读器天线与标签之前的垂直距离。

3.3 阅读器二维布局优化研究

3.3.1 阅读器二维布局问题分析

网络的优化布局是 RFID 基础应用的常见问题，通常 RFID 阅读器可以连接一定数量的天线，因此研究阅读器的布局即为研究阅读器天线的布局。在常见的 RFID 应用中，阅读器天线的不合理布局不仅会导致资源浪费，还会使得有限天线数量下阅读器通信覆盖面积下降。

在 RFID 布局优化研究中，大量研究从 RFID 系统的覆盖重叠面积、标签碰撞率、经济效率、负载平衡等方面对阅读器天线位置进行合理优化。本章的二维 RFID 定位方法是从提高定位精度的角度优化天线位置。阅读器接收的 RSS 值是定位算法对测试标签进行位置估计的关键信息，由于 RSS 符合对数模型，因此随着距离的增加，RSS 的变化逐渐缓慢，不同距离之间的数值差别越来越小，也就是 RSS 随着距离的增加可区分度越来越小。考虑这一因素，可以推导优化目标函数，并利用遗传算法求取阅读器天线的位置坐标。

3.3.2 阅读器二维布局优化的目标函数

在单基站 RFID 通信系统，RFID 无源标签利用接收到的信号激活自身，然后传输反向调制信号。将路径损耗函数（3.9）写成对数的形式并对其求导得

$$\tilde{L}(d) = 20\lg(\frac{4\pi d}{\lambda}) \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.12)$$

$$\tilde{L}'(d) = -\frac{20}{\ln(10)d} \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.13)$$

在公式（3.13）中的$\tilde{L}'(d)$绝对值随着d的增加逐渐减少，这意味着$\tilde{L}(d)$随着d的增加逐渐没有明显变化。说明随着d的增加，RSS 的区别性降低，本文将这种特征定义为路径损耗特征（PLC），并将d_e定义为有效可区分距离。

考虑到阅读器天线与标签的距离越小，RSS 的可辨别性越好，因此将第i个阅读器天线的总回报定义为

$$R_{Li} \triangleq \sum_{j=1}^{N} W(d) \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.14)$$

其中，$W(d)$定义为

$$W(d) = \begin{cases} c_0 \tilde{L'}(d) & d \le d_e \\ 0 & else \end{cases} \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.15)$$

其中，c_0是常数。定义M个阅读器天线之间的距离矩阵为$\mathbf{D}_{M\times M}$。需要注意的是，如果天线距离太近，会导致天线覆盖区域重叠，这种不合理的布局不仅会造成资源的浪费，而且在天线有限的情况下，还会降低定位精度。因此需要设置天线之间的有效干扰距离d_p，并定义一个折扣矩阵$\mathbf{A}_{M\times M}$来避免这种情况

$$A_{ij}=\begin{cases}1 & i\le j \ or \ D_{ij}>d_p\\ D_{ij}/c_1 & else\end{cases} \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.16)$$

其中，c_1是常数。定义一个折扣系数矩阵$\boldsymbol{\gamma}_j=\prod_{j=1}^{M}\mathbf{A}_{ij}$。综上，以定位精度作为阅读器天线优化布局的参考因素，给出总奖励函数为

$$R=R_L\boldsymbol{\gamma}^T \quad \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.17)$$

因此当总奖励函数R越大时，阅读器天线的布局越为合理，将R作为优化目标函数，带入到优化算法中进行求解即可，本章将采用遗传算法进行求解。

3.4 阅读器三维布局优化研究

3.4.1 阅读器三维布局问题分析

上一节中讨论了阅读器布局对定位的影响，但是仅限于二维平面，忽略了天线方向以及覆盖率问题。因此本章从三维环境出发，重点考虑定位精度及定位覆盖面积两个方面进行优化。首先阅读器的覆盖面积是影响定位精度的关键因素，因为无效覆盖位置会导致标签无法被定位，进而影响整体的定位精度，因此需要在天线之间增加一个折扣因子来提高覆盖面积。

综合以上两个关键优化因素，可以对天线的空间坐标以及天线的辐射角度进行优化，相对于二维定位环境，三维环境下优化参数过多，遗传算法难以得到收敛的效果，因此本章添加了遗传算法的限制条件，提出了受限遗传算法。

3.4.2 阅读器三维布局优化的目标函数

在单基站 RFID 通信系统，RFID 无源标签利用接收到的信号激活自身，然后传输反向调制信号。假设标签 j 位于$\left(x_j^t,y_j^t,z_j^t\right)$，标签要想激活自身，接收到的阅读器天线信号强度必须大于一个下限值，这个下限值就是标签天线灵敏度，目前最

先进的标签天线灵敏度能够低至-20 dBm[15]。标签接收到的阅读器天线信号可以表示为

$$P_R'(x_j^t, y_j^t, z_j^t) = 10\log_{10}(\rho_L P_T G_T G_R^i \left|h_{ij}\right|^2 \left|L(d_{ij})\right|) \cdots\cdots\cdots\cdots \quad (3.18)$$

同时，如果 RFID 阅读器想要正确接收后向散射信号，$P_R'(x_j^t, y_j^t, z_j^t)$ 必须大于 -20 dBm，公式(3.8)中的接收信号强度 $P_R\left(x_i^r, y_i^r, z_i^r\right)$ 必须大于阅读器天线的灵敏度。

假设在定位场景中布置 M 个阅读器天线和 N 个标签参考点。建立矩阵 $\mathbf{G}_{N\times M}$ 来判断第 i 个阅读器能否与第 j 个位置的标签建立通信，表示为

$$\mathbf{G}_{ij} = \begin{cases} 1 & P_R^{'} > -20dBm \text{ and } P_R > -75dBm \\ 0 & otherwise \end{cases} \cdots\cdots\cdots\cdots \quad (3.19)$$

其中，$P_R^{'}$ 为标签接收到的功率。

定义一个标签 j 能建立通信的阅读器天线数量的检测矩阵 $\mathbf{I}_{1\times N}$，可由如下公式计算

$$I_j = \sum_{i=1}^{M} G_{ij} \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.20)$$

在 RFID 通信过程中，一般认为标签至少可以与三个阅读器天线通信才可以被定位，因此用矩阵 $\mathbf{L}_{1\times N}$ 表示标签 j 是否可以被定位，表示为

$$\mathbf{L}_j = \begin{cases} 1 & if\ I_j \geq 3 \\ 0 & otherwise \end{cases} \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.21)$$

考虑到位置区域内有足够多的标签参考点均匀分布，利用如下公式表示定位覆盖率

$$l_p = \frac{\sum_{j=1}^{N} \mathbf{L}_j}{N} \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.22)$$

三维定位环境下的定位精度回报同公式（3. 17）。综上，以定位覆盖率和定位精度作为阅读器天线优化布局的参考因素，给出总奖励函数为

$$R = \omega_1 R_L \boldsymbol{\gamma}^T + \omega_2 c_2 l_p \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \quad (3.23)$$

其中，ω_1+ω_2=1，c_2 是常数。

3.5 遗传算法和受限遗传算法

3.5.1 遗传算法

对于 3.3 节中的二维阅读器优化布局问题，本节利用遗传算法进行优化求解。遗传算法（GA）是一种随机搜索算法，适用于求解复杂的非线性优化问题。

遗传算法包括种群初始化、适应度函数、选择操作、交叉操作、变异操作、非线性寻优 6 个计算步骤。

（1）种群初始化：遗传算法不能直接处理问题空间的参数，因此需要将所需问题的可行解编码到遗传空间中的染色体或个体，常用的编码方式包括二进制编码、实数编码、多级参数编码等，本文采用二进制编码方案。

（2）适应度函数：适应度函数是用来区分群体中个体好坏的标准。在本文中，选择了回报价值作为适合度。适合度越大，个体就越好，它可以表示为

$$F = R(\mathbf{l}^{R_2}) \cdots\cdots (3.24)$$

其中，$\mathbf{l}^{R_2}{}_{M\times 2}$ 表示二维阅读器天线的位置信息，包括二维定位环境中的坐标 x, y。

（3）选择操作：根据适应度函数得到的信息，选择操作会有较大概率选择适应度大的个体组成新的种群来繁殖下一代，选择操作有锦标赛法和轮盘赌法等，根据适应度大小的比例来选择的操作为轮盘赌法，本文采用此种方法，个体 i 被选中的概率可以表示为

$$p_i = \frac{F_i}{\sum_{j=1}^{N_g} F_j} \cdots\cdots (3.25)$$

其中，N_g 表示每一代种群的数量。

（4）交叉操作：交叉操作是从种群中随机选择两个个体，将父代的优良特性传递给子串，计算方法为

$$\begin{aligned} a_{kj} &= a_{kj}(1-b) + a_{lj}b \\ a_{lj} &= a_{lj}(1-b) + a_{kj}b \end{aligned} \cdots\cdots (3.26)$$

其中，公式（3.26）表示了第 k 个染色体 a_k 和第 l 个染色体 a_l 在 j 位置的交叉操作。

（5） 变异操作：变异操作的主要目的是保持种群的多样性。第i个个体中第j个基因a_{ij}的突变方法如下：

$$a_{ij}=\begin{cases}a_{ij}+(a_{ij}-a_{\max})*\eta(g) & r\geq 0.5\\ a_{ij}+(a_{\min}-a_{ij})*\eta(g) & r<0.5\end{cases} \cdots\cdots\cdots\cdots\cdots\cdots \text{（3.27）}$$

其中

$$\eta(g)=r_0(1-g/g_{\max}) \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \text{（3.28）}$$

其中，r_0为随机数，g和$g_{\max}$分别为当前遗传代数和最大遗传代数，$a_{\max}$和$a_{\min}$分别为a_{ij}的最大值和最小值，r为[0,1]内的一个随机数。

（6）非线性寻优：当遗传算法完成一次迭代之后，会采用线性规划函数寻求局部最优解，并将该最优解作为新的个体进行下次迭代，进而完成整个进化过程。

3.5.2 受限遗传算法

本文在 3.5.1 节中详细介绍了遗传算法的优化过程，但是当优化参数过多时，遗传算法难以较好的收敛，导致优化结果不尽人意，因此需要对优化的参数加以限制，减少参数或者缩小参数的取值范围。本章提出了一种限制性遗传算法（RGA）来实现三维 RFID 阅读器天线布局优化求解，以优化阅读器天线的部署。

在三维定位中，所优化的阅读器天线位置信息与二维不同，它包括三维坐标、仰角以及方位角，因此遗传算法的适应度函数写为

$$F=R(\mathbf{l}^{R_3}) \cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots\cdots \text{（3.29）}$$

其中，$\mathbf{l}^{R_3}{}_{M\times 5}$表示三维阅读器天线的位置信息，包括三维空间中的坐标x,y,z，仰角θ和方位角ϕ。

RFID 阅读器天线在布置过程中，往往会安置在天花板以及墙壁的上方，另外定位物体也往往在室内的下半部分。针对实际定位场景中读写器天线高度固定等情况，本章对遗传算法的求解加上限制条件，提出了一种受限遗传算法（RGA）来限制阅读器天线的坐标、仰角和方位角，从而通过遗传算法快速找到最优解。并给出了 RGA 的优化约束条件

$$R\rightarrow\begin{cases} z_i^r = c & q \\ \theta \quad \leq \theta_i \leq \dfrac{\pi}{} & q \\ \vec{\mu}\ \phi_i \cdot \vec{v}\ x \quad y \quad = & q \end{cases} \tag{3.30}$$

其中，q_1表示读写器天线的高度为常数c_3。q_2表示天线的仰角之间只能在$\theta_{\min}$和$\pi/2$之间旋转, 其中，$\theta_{\min}$表示第i个天线与高度为H_m的最远标签之间的夹角。$\vec{\mu}(\phi_i)$代表$X-Y$平面定位中心(x_0, y_0)与天线的中心连线的向量，$\vec{v}(x_0, y_0)$表示天线在$X-Y$平面上的投影向量。q_3表示在$X-Y$平面上$\vec{\mu}(\phi_i)$与$\vec{v}(x_0, y_0)$之间的垂直关系。

3.6 仿真结果及分析

3.6.1 仿真参数设置

仿真实验在 Micro-Star GF63 计算机上进行，使用 Matlab、PyCharm2018.2 平台和 Python3.6 完成仿真，使用路径损耗模型和三维空间传输模型分别对二维和三维阅读器布局进行优化。

二维优化布局仿真用一个面积为$12m\times12m$的平面来模拟室内环境，通过设置路径损耗因子和高斯噪声来模拟复杂室内场景。并设置 8 个阅读器天线和 625 个标签参考点。标签参考点为均匀分布，标签参考点和阅读器的位置是已知的，并将阅读器标记为$\{0，1，2，3，4，5，6，7\}$以此来计算优化回报函数。

三维优化布局环境设定一个$10m\times10m\times3m$的房间，选择 8 个 RFID 阅读器天线作为优化对象，编号为$\{1，2，3，4，5，6，7，8\}$；并将H_m设置为$2.5m$，在定位空间选取 2646 个空间参考点，均匀分布在$10m\times10m\times2.5m$的空间中，以用来计算定位覆盖面积和回报函数。实验中 RFID 系统的参数如表 3.1 所示。

表 3.1 RFID 定位系统的参数

参数	参数值
载波频率 （ f ）	920 MHz
发射功率（ P_T ）	33 dBm
调制效率（ τ ）	0.5
极化损耗系数（ ρ_L ）	0.5
功率传输效率（ μ_T ）	1
微分反射系数（ $\left\|\Gamma\right\|^2$ ）	0 到 1
标签发射天线增益（ G_T ）	0 dBi
标签天线灵敏度	-20 dBm
阅读器天线灵敏度	-75 dBm
阅读器天线高度（ c_3 ）	3 m
二维仿真环境长宽	$12m \times 12m$
房间的长宽	$10m \times 10m$
阅读器数量（ M ）	8
二维标签参考点	625
三维标签空间参考点数量	2646

3.6.2 仿真结果分析

（1）阅读器二维布局优化结果分析

图 3.4 为遗传算法的奖励函数曲线，其输出即为优化之后的$\mathbf{l}^{R_2}$。可以看到，在 200 代进化过程中，遗传算法的回报曲线增加的较快，之后奖励函数开始收敛，最终稳定在一定范围内。

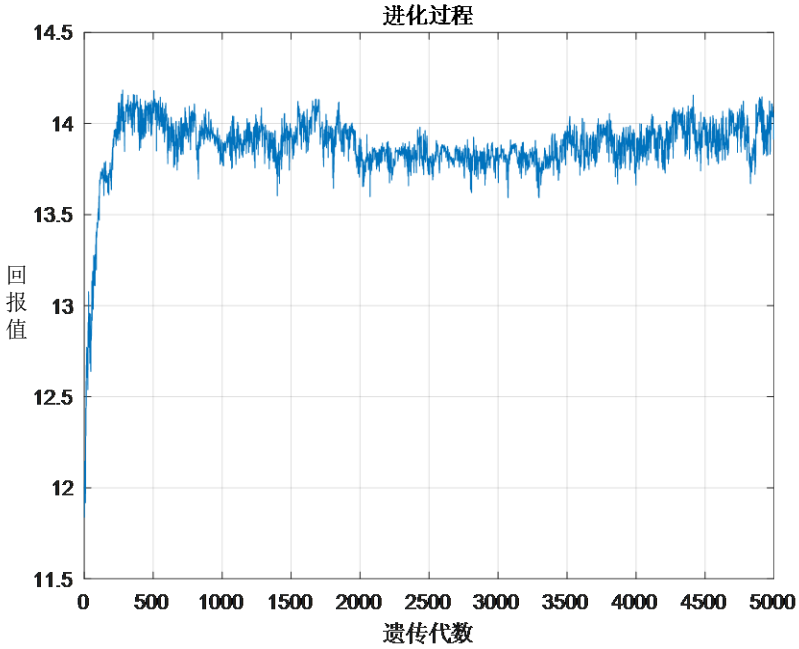


图 3.4 遗传算法的优化过程

8 种阅读器天线的最佳 RNP 结果如图 3.5 所示，图中以遗传算法最后 30 代的解作为最终解。

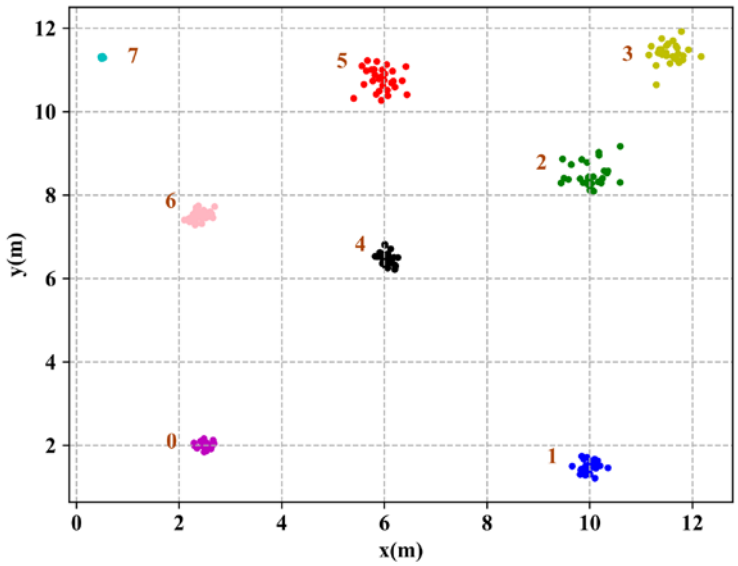


图 3.5 阅读器天线的最佳 RNP 坐标结果

从图 3.5 可以看出，得到的每个阅读器天线 30 代的坐标都集中在一个固定点附近，验证了遗传算法解的有效性。另外，8 个天线在定位平面上大致均匀分布，周围 7 个阅读器天线环绕中间 1 个阅读器天线。

为了验证遗传算法优化解的有效性，本节利用 WKNN 进行验证，根据图 3.5 的

优化结果对阅读器天线进行布局。首先将遗传算法求解的坐标定义为优化布局，并取 8 个阅读器坐标（[0,0],[6,0],[12,0],[0,6],[12,6],[0,12],[6,12],[12,12]）定义为一般布局，利用 WKNN 算法研究其优化布局对定位精度的影响。

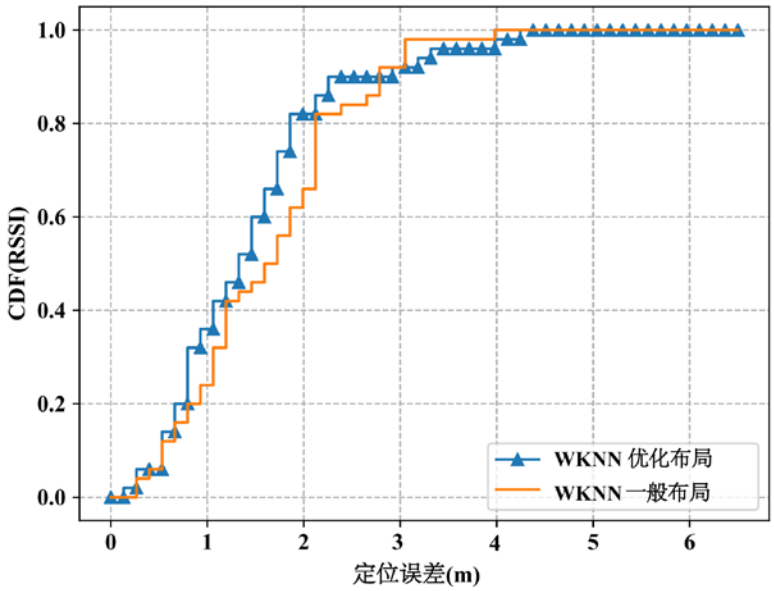


图 3.6 不同布局下 WKNN 的定位误差

RFID 二维定位误差的累积分布函数（CDF）如图 3.6 所示。从图中可以看到优化布局定位效果明显优于一般布局。优化布局可以保证 81%的测试标签误差在 2m 以内，而一般布局只能保证 65%左右的测试标签误差在 2m 以内，和优化布局差距较大，说明优化后的布局更具优势。因此，优化布局在定位效果上有显著提高。

另外，对于采用优化布局后 CNN 算法精度的提高效果，本文将在后续（4.4.2）节进行仿真验证。

（2）阅读器三维布局优化结果分析

图 3.7 为 RGA 遗传代数的奖励函数曲线。为了保证$\mathbf{I}^{R_3}$的计算成功，仿真中将代数设置为 3000。可以看到，在开始 100 代进化过程中，遗传算法的回报曲线增加的较快；在 100 代至 1300 代中，出现了一个较慢的进化过程，整体上回报曲线一直再增加，说明整个群体朝着优化的方向进化；在经过 1300 代后，奖励函数开始收敛，最终稳定在一定范围内。

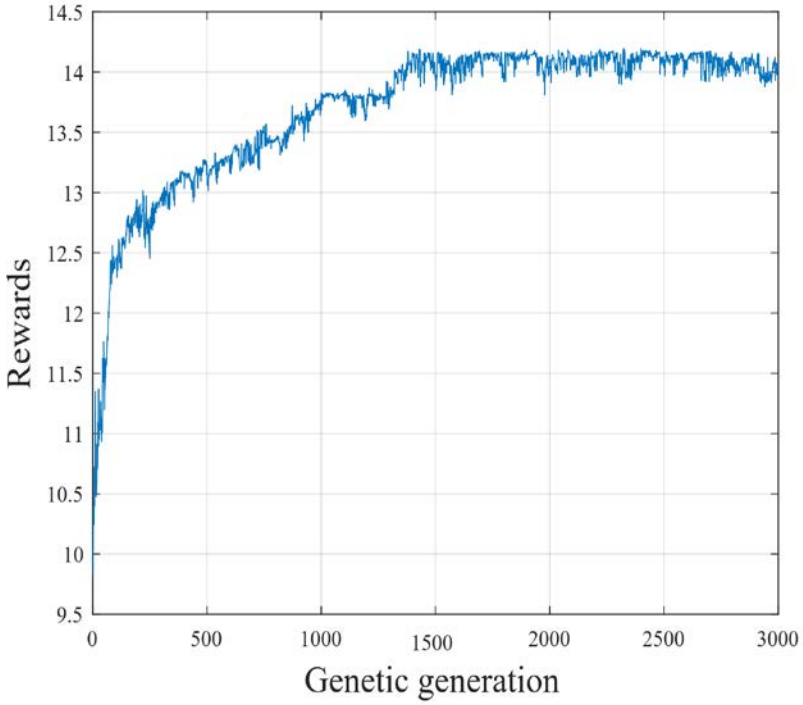


图 3.7 受限遗传算法的优化过程

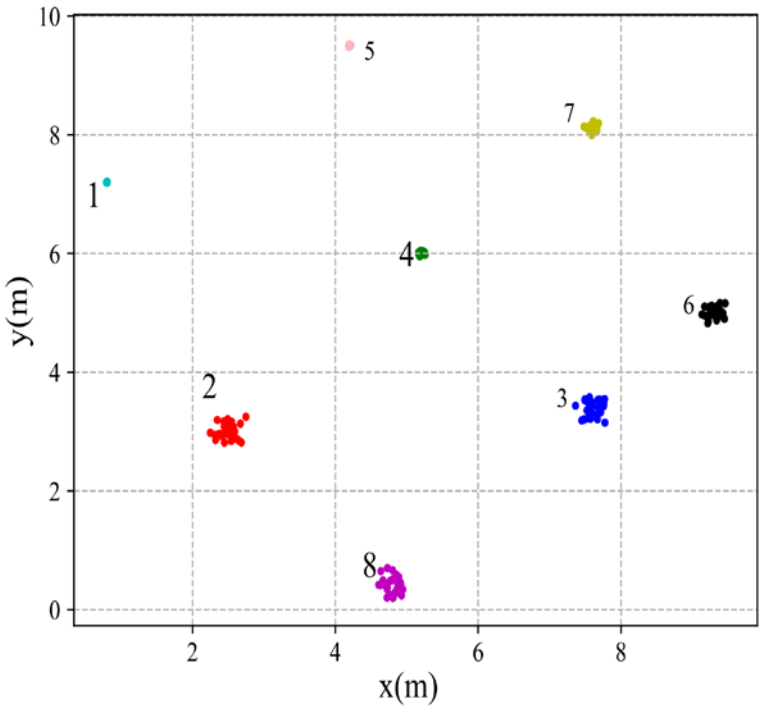


图 3.8 阅读器天线的最佳 RNP 坐标结果

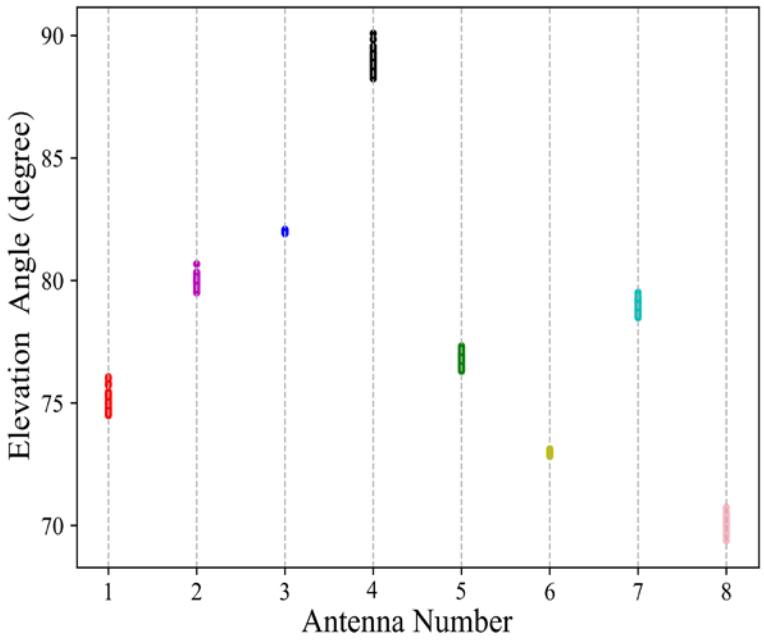


图 3.9 阅读器天线的最佳 RNP 仰角结果

8 种阅读器天线的最佳 RNP 结果如图 3.8 和图 3.9 所示，图中以 RGA 最后 30 代的解作为最终解。从图 3.8 可以看出，得到的每个阅读器天线最后 30 代的坐标都集中在一个固定点附近，验证了 RGA 解的有效性。另外，定位区域内部有 4 个阅读器天线，边缘附近有 4 个，说明 8 个天线在 X-Y 平面上大致均匀分布，近似一个环形。图 3.9 为 8 个阅读器天线的最佳仰角分布。可以看出，8 个天线的仰角均在 70° ~ 90° 之间，靠近边缘的天线角度小于内部天线的角度。

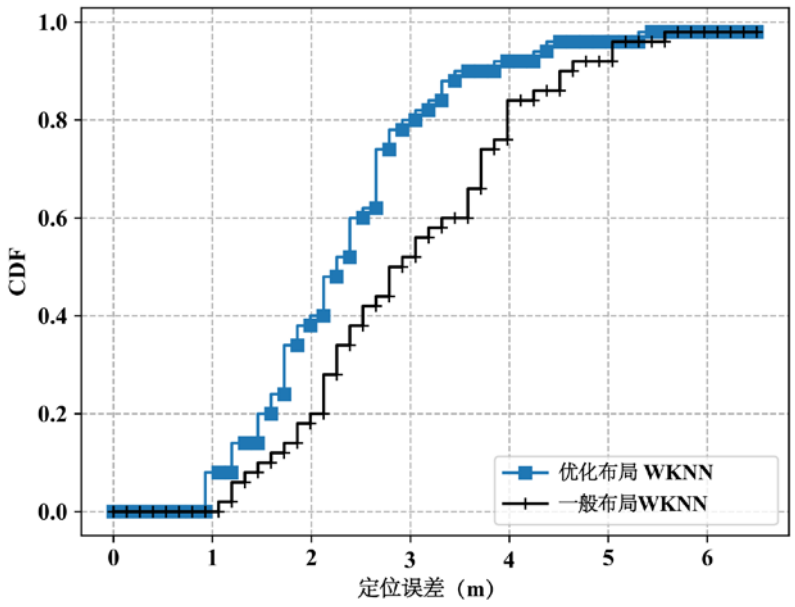


图 3.10 不同布局下定位算法的定位误差

为了验证 RFID 三维优化布局的有效性，与二维仿真验证类似，利用 WKNN 算法研究其优化布局对定位精度的影响。仿真实验考虑了两种不同的阅读器布局: 优化布局和一般布局。优化布局是使用最后 30 代的解的平均值。一般布局将阅读器天线 2、4、7 的坐标修改为（3,0）、（8,0）、（8,10），将所有阅读器天线的仰角调整为70°。方位角满足公式（3.30）中的（q3）。

RFID 三维定位误差的累积分布函数（CDF）如图 3.10 所示。从图中可以看到优化布局定位效果明显优于一般布局。优化布局可以保证 80%的测试标签误差在 3m 以内，而一般布局只能保证 57%左右的测试标签误差在 3m 以内，和优化布局差距较大，说明优化后的布局更具优势。因此，优化布局在定位效果上有显著提高。另外对于 CNN 算法精度提高效果，本文在（5.4.2）节进行了详细介绍。

3.7 本章小结

通过 RFID 进行室内定位具有精度高、硬件要求低的特点。本章首先详细介绍了 RFID 信号传输模型，包括对数路径损耗模型、到达相位差模型、三维空间传输模型。在这些模型的基础上，提出了二维和三维定位环境下的阅读器布局问题，在 RFID 网络中，阅读器天线的位置会影响定位精度和覆盖范围。

对于二维布局优化，通过分析对数路径损耗模型，得出关于定位精度回报的优化目标函数；接着利用遗传算法对二维优化目标函数进行求解，最后进行仿真分析，求解了优化布局的阅读器位置信息。并利用 WKNN 算法对优化布局效果进行了验证，证明了优化布局可以提高定位精度。

对于三维布局优化，在本章中提出一种新的 RFID 网络规划（RNP）方法来优化阅读器天线的部署，以实现精确的三维定位。首先，通过无源超高频 RFID 系统的三维天线辐射模式，给出了天线辐射范围的计算方法；然后，分析了接收信号强度（RSS）和路径损耗特性（PLC），提出了受限遗传算法（RGA）来求解 RNP 的最优解，并给出了 RGA 的奖励函数和约束条件。最后通过仿真计算出了阅读器天线位置信息。并利用 WKNN 算法对优化布局效果进行了验证，证明了优化布局可以提高定位精度。

第 4 章 复杂场景下基于卷积神经网络的 RFID 标签二维定位算法研究

4.1 引言

第 3 章对 RFID 的信号传播模型进行了分析，同时给出了计算 RSS 数据的对数路径损耗模型和三维空间传播模型，也讨论了到达相位差模型。同时，基于这些模型讨论了阅读器优化布局问题。基于这些模型，衍生了很多定位技术，包括基于非指纹的（TOA、TDOA 等）、基于指纹的（KNN、WKNN）还有深度学习的方法。这些方法都存在一定的缺陷，在复杂的室内环境下，由于多径效应、阴影效应、障碍物等影响很难达到较高的定位效果，另外基于深度神经网络的方法，由于其网络参数庞大，导致训练速度很慢。本章提出了一种基于卷积神经网络（CNN）的 RFID 标签二维定位方法，在二维的仿真环境下通过构建 RSS/PDOA 联合指纹数据库对 CNN 网络进行训练，使得它具有良好的分类效果，来实现较高的定位效果。同时验证了阅读器天线的优化布局方法的定位效果。

4.2 RFID 定位系统模型

4.2.1 RFID 定位系统

本文研究的基于卷积神经网络的 RFID 定位系统分为三大部分：指纹数据库建立模块、离线训练模块和在线测试模块。

如图 4.1 所示，首先，通过构建路径损耗模型和到达相位差模型来模拟 RFID 信号的通信过程，并从 RFID 阅读器和参考标签通信过程中提取包括接收信号强度（RSS）和到达相位差（PDOA）的指纹特征。并对参考标签的 RSS/PDOA 的测量值进行采集和归一化。然后，将指纹数据制成一定尺寸的图像作为 CNN 的输入，CNN 通过深度学习图像的特征来训练网络参数。本文为了进行比较不同指纹数据的定位效果，分别生成了 RSS、PDOA 和 RSS/PDOA 三种指纹数据集，并使用 BP 算法对 CNN 网络参数进行训练。在在线阶段，采集并归一化相同的三种测试数据集，并使用训练好的 CNN 分类模型来估计测试标签在每一个参考

标签处的概率，利用概率结合定位算法对测试标签进行位置估计。

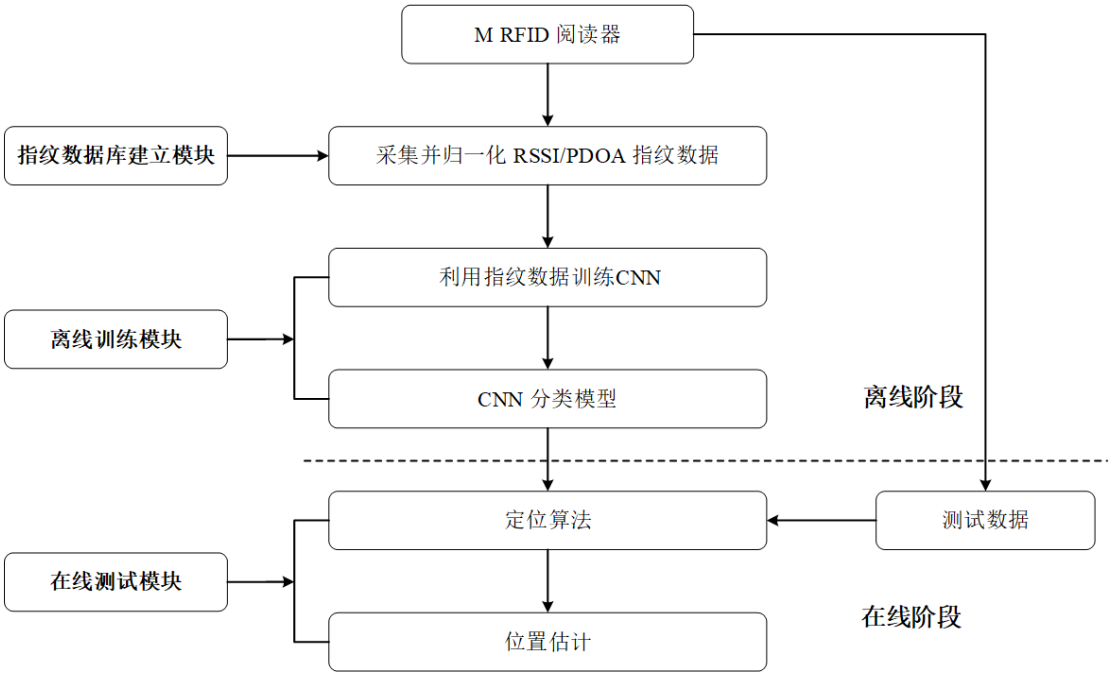


图 4.1　RFID 定位系统流程图

4.2.2 RFID 指纹获取

通过模拟射频识别信号的室内环境传播过程完成 RSS 和 PDOA 数据的采集和处理。应用公式（3.1）对数路径损耗模型和公式（3.6）到达相位模型来获得原始的 RSS 和 PDOA 指纹数据，并对其进行归一化处理。在这个过程中，RFID 阅读器和标签不需要时钟同步。

设定阅读器的数量为 M，参考标签的数量为 N，在标签 j 与阅读器建立通信过程中，通过采集 M 个阅读器处的 RSS 和 PDOA 数据，可以得到标签 j 的指纹数据，可将标签 j 的 RSS 和 PDOA 指纹数据分别表示为 $s^j=(s_1^j,s_2^j,s_3^j,\cdots s_M^j)$ 和 $\varphi^i=(\varphi_1^j,\varphi_2^j,\varphi_3^j\cdots,\varphi_M^j)$，由于 RFID 信号经过多次反射和衍射，RSS 和 PDOA 数据可以代表标签的位置特征。从而实现基于指纹的 RFID 定位。

在实际应用中，采集训练样本时，需要同时记录参考标签的坐标与原始的 RSS、PDOA 数据。完成 N 个参考标签的数据采集之后，为了便于模型的训练，防止训练过程中的不平衡，需要对原始数据进行归一化操作，本文利用下式将指

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：https://d.book118.com/517100053013006131