

分类号: TP242.6

密 级: 公开

学校代码: 10363

学 号: 2210330162



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 基于改进智能优化算法的
盲源分离方法研究

论文作者 吴宸之

校内导师 李炜 副教授

校外导师 沈权 高级工程师

专业学位类别 电子信息 (085400)

研究方向 (领域) 智能信息处理及应用

论文提交日期: 2024 年 5 月 31 日

分类号: TP242.6

单位代码: 10363

密 级: 公开

学 号: 2210330162

题 目 基于改进智能优化算法的盲源分离方法研究

题 目 Research on Blind Source Separation Methods Based on
Improved Intelligent Optimization Algorithm

学生姓名: 吴宸之

校内导师: 李炜（副教授）

校外导师: 沈权（高级工程师）

专业学位类别: 电子信息

研究方向（领域）: 智能信息处理及应用

论文答辩日期: 2024 年 05 月 15 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律结果由本人承担。

学位论文作者签名：吴宸之

日期：2024年5月30日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 ____ 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：吴宸之

指导教师签名：李伟

日期：2024 年 5 月 30 日

日期：2024 年 5 月 30 日

基于改进智能优化算法的盲源分离方法研究

摘要

盲源分离 (Blind Source Separation, BSS) 最早是由 Jutten 和 Hérault 两位科学家通过研究信号分离问题而提出的一种处理混叠信号的方法。该方法的实质是, 在源信号及其传输通道等各参数属性未知情况下, 将独立源信号从混叠的信号中较为完好的分离出来。

独立成分分析 (Independent Component Analysis, ICA) 是一种解决线性瞬时 BSS 问题的传统方法。ICA 根据源信号的独立性并借助优化算法, 将观测信号分解为若干个尽可能独立或完全统计独立的信号成分, 将其作为源信号的一种近似估计。在此基础上, 各国专家学者又相继提出了梯度算法、最小互信息算法和固定点算法等。但此类 ICA 算法通常存在计算量较大、算法不稳定、精度不够高等问题。近年来, 诸多学者受到自然界各物种行为的启发, 提出了一系列的智能优化算法对目标函数寻优, 并将其融入 BSS 领域中, 以提高算法性能。

针对传统智能优化算法在解决 BSS 问题时所存在的诸多缺陷, 本文在对正、欠定 BSS 混合模型进行深入研究的基础上, 将改进的优化算法与 ICA 算法融合, 用于求解 BSS 问题, 所做工作如下所述:

(1) 将改进鲸鱼优化算法 (Improved Whale Optimization Algorithm, I-WOA) 应用于正定 BSS 领域。首先, 该方法针对传统

鲸鱼算法在种群迭代初期存在随机搜索范围较局限的问题，采用混沌反向学习策略对种群进行初始化操作，提高种群丰富度；其次，引入莱维飞行策略对种群位置进行扰动，避免过早收敛现象的发生；最后，将算法得出的最优解用于调整梯度算法的步长，一定程度上减小 ICA 算法的稳态误差。仿真结果表明，改进策略对提高优化算法的收敛速度及全局寻优能力具有显著优势。

(2) 为解决欠定盲分离问题中存在的观测信号稀疏性不足的缺陷，提出一种基于小波包混合优化的欠定 BSS 方法。该方法首先采用小波包变换将观测信号分解扩维，利用互相关系数剔除冗余的信号分量。接着，使用贝叶斯信息准则下的奇异值分解方法估计源信号数目，并通过白化过程进行降维。最后，引入鲸鱼优化算法中的螺旋位置更新方式与莱维飞行策略对灰狼优化算法进行改进，并将改进后的算法与 ICA 算法融合，实现重构正定白化信号的分离。仿真实验结果验证所提方法的可行性和有效性。

关键词：盲源分离，智能优化算法，鲸鱼优化算法，灰狼优化算法，小波包变换

Research on Blind Source Separation Method Based on Improved Intelligent Optimization Algorithm

ABSTRACT

The Blind Source Separation (BSS) was first proposed by two scientists, Jutten and Héroult, as a method of dealing with aliased signals by studying the problem of signal separation. The essence of the method is to separate the independent source signals from the aliased signals in a relatively intact manner, when both the properties of the source signals and the transmission channel parameters are unknown.

Independent Component Analysis (ICA) is a conventional algorithm to solve linear transient BSS problems. ICA is based on the independence of the source signals and with the help of optimization algorithms, ICA decomposes the observed signal into a number of signal components that are as independent as possible or completely statistically independent, based on the independence of the source signal and with the help of an optimization algorithm, which is used as an approximate estimate of the source signal. On this basis, experts and scholars from various countries have proposed gradient algorithms, minimum mutual information algorithms, fixed point algorithms and so on. However, such ICA algorithms often suffer from problems such as high computational effort, unstable algorithms, and lack of accuracy. In recent years, many scholars,

inspired by the behaviours of various species in nature, have proposed a series of intelligent optimization algorithms solved for the optimal value of the objective function. And integrated them into the field of BSS to improve the performance of the algorithms.

Aiming at the many shortcomings of traditional intelligent optimization algorithms in solving BSS problems, the paper integrates the improved optimization algorithm with the ICA algorithm for solving BSS problems based on an in-depth study of the mixed model of positive and underdetermined BSS, as described in the following:

(1) The Improved Whale Optimization Algorithm (I-WOA) is applied to the field of BSS. Firstly, the method addresses the problem that the traditional whale algorithm has a more limited random search range at the beginning of the population iteration, and adopts a chaotic inverse learning strategy to perform initialization operations on the population to improve the population richness; Secondly, a Lévy flight strategy is introduced to perturb the position of the population to avoid the phenomenon of premature maturation convergence; Finally, the optimal solution derived from the algorithm is used to adjust the step size of the gradient algorithm, which somewhat reduces the steady state error of the ICA algorithm. Simulation results show that the improved strategy has significant advantages in improving the convergence speed and global optimization finding ability of the optimization algorithm.

(2) In order to solve the defect of insufficient sparsity of observed signals in the underdetermined BSS problem, an underdetermined BSS method based on wavelet packet hybrid optimization is proposed. The method first decomposes and expands the observed signals using wavelet packet transform, and removes the redundant signal components using the value of interrelationships. Next, the number of source signals is estimated using the singular value decomposition method under the Bayesian information criterion and dimensionality reduction is performed through a whitening process. Finally, the spiral position updating method in the whale optimization algorithm and the Lévy flight strategy are introduced to improve the grey wolf optimization algorithm, and the improved algorithm is fused with the ICA algorithm to achieve the separation of reconstructed positive definite whitening signals. Simulation experiment results verify the feasibility and effectiveness of the proposed method.

Chenzhi Wu (Electronic Information)

Supervised by Wei Li

KEY WORDS: Blind Source Separation; Intelligent Optimization Algorithm; Whale Optimization Algorithm; Gray Wolf Optimization Algorithm; Wavelet Packet Transform

目录

摘要.....	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 研究背景和意义.....	1
1.2 研究现状及发展趋势.....	2
1.2.1 盲源分离研究现状.....	2
1.2.2 智能优化算法研究现状.....	4
1.3 本文主要内容与章节介绍.....	6
第 2 章 盲源分离基础理论.....	8
2.1 经典盲源分离模型.....	8
2.2 观测信号的预处理.....	9
2.3 分离原理.....	10
2.3.1 互信息.....	10
2.3.2 负熵.....	10
2.3.3 峰度.....	11
2.4 盲源分离的性能判断指标.....	12
2.4.1 混合矩阵估计误差的判断指标.....	13
2.4.2 源信号的判断指标.....	13
2.4.3 分离信号的判断指标.....	14
2.5 正定盲源分离算法.....	14
2.5.1 独立成分分析.....	15
2.5.2 传统优化算法.....	15
2.6 欠定盲源分离算法.....	16
2.6.1 稀疏分量分析.....	16
2.6.2 小波变换.....	17
2.7 本章小结.....	18

第 3 章 基于改进鲸鱼优化算法的盲源分离.....	19
3.1 鲸鱼优化算法.....	19
3.1.1 传统的鲸鱼优化算法.....	19
3.1.2 改进的鲸鱼优化算法.....	20
3.1.3 改进的鲸鱼优化算法仿真实验.....	22
3.2 基于改进智能优化算法的盲源分离方法.....	25
3.2.1 目标函数的构建.....	25
3.2.2 算法步骤.....	26
3.2.3 盲源分离实验.....	28
3.3 本章小结.....	31
第 4 章 基于小波包混合优化的欠定盲源分离.....	32
4.1 灰狼优化算法.....	32
4.1.1 传统的灰狼优化算法.....	32
4.1.2 改进的灰狼优化算法.....	33
4.1.3 混合灰狼优化算法实验.....	34
4.2 基于小波包混合优化的欠定盲源分离方法.....	36
4.2.1 小波包变换.....	36
4.2.2 欠定问题的转化.....	37
4.2.3 源数估计.....	38
4.2.4 观测信号正定问题的转化.....	39
4.2.5 算法步骤.....	40
4.2.6 小波包分选及分离性能测试实验.....	41
4.2.7 混合矩阵估计和源信号分离性能对比实验.....	46
4.2.8 故障信号测试实验.....	48
4.3 本章小结.....	50
第 5 章 总结与展望.....	51
5.1 总结.....	51
5.2 展望.....	52
参考文献.....	53

攻读学位期间发表的学术论文目录.....	58
致谢.....	59

第1章 绪论

1.1 研究背景和意义

伴随着信息化时代的到来,信息技术在不断更迭发展,相应地,人们对于所获取到数据信息的高效性和准确性有了更高的需求。在传统领域里,在已知源信号和传输通道的情况下,使用滤波器进行滤波处理的方式可以实现信号的部分分离任务。然而,外界环境中存在一些无法避免的噪声干扰,导致源信号与背景噪声耦合在一起。介于有限的认知水平和复杂的外界环境条件,需要采用有效的信号分离技术,将源信息从观测到的信号中恢复出来,常用的方法有:小波变换,经验模态分解,变模态分解,联合对角化,自然梯度等算法。而在有不同的源含有相似或者相关频率的状况下,上述算法可能失效。BSS 作为信号处理研究中的一个重要方向,可以在信号的传输信道特性未知的情况下,从观测信号中即可提取出所需的有效信息。该算法能够在生产实践中发挥关键性作用,且在生物医疗、数字通信、通信雷达、机械诊断等领域中应用广泛。

此外,因受实际场景限制,源信号数目与观测信号数目很难保持一致。在传感器的数量通常少于源信号的数量状况下,盲信号的识别问题成为解决欠定盲源分离(Underdetermined Blind Source Separation, UBSS)的主要问题。另外,如果源信号的数目低于传感器的数量,所要解决的即为超定盲源分离(Overdetermined Blind Source Separation, OBSS)问题。

ICA 是为解决 BSS 问题而逐渐发展起来的一种经典方法,因其结构简单,分离范围大而应用广泛。该算法旨在寻找到一个线性变换矩阵,将观测到的混合信号分解成为一系列统计独立的成分,将各成分之间统计独立的输出信号作为源信号的近似估计。但是,传统 ICA 大多过度依赖梯度信息,导致算法求解速度变慢,容易造成稳态误差。另外,ICA 的全局收敛性能不理想,使得算法的收敛速度较慢且精度不够高。因此,后续诸多学者使用智能优化算法应用于 BSS 领域,并对优化算法进行相应地改进,以提高信号分离能效。

智能优化算法为近年来诸多学者受自然界各物种行为的启发,而提出的一

类基于仿生学算法。该类算法在用于解决目标函数最优解的求取问题时，不依赖于解空间中的梯度信息，且对所求目标函数连续性等约束条件没有要求，因此具有更广泛的应用范围。

但在实际求解中，传统智能优化算法所存在的收敛速度慢、易陷入局部最优等缺点有待改进。将改进后的智能优化算法应用于盲源领域，可以有效增强 BSS 算法的寻优性能，提高分离效果。

1.2 研究现状及发展趋势

1.2.1 盲源分离研究现状

有关 BSS 的探讨始于二十世纪，Jutten, Hérault 等人^[1]联合发表关于 BSS 的经典文章，并提出 BSS 的基本概念，成功利用神经网络实现语音信号的盲分离。同年，Tong L, Liu R 等人^[2]提出了基于二阶和四阶统计量分布的两种盲识别算法，在非白源信号情形下进行算法对比实验，研究解决与 BSS 相关的问题。1994 年 Comon P^[3]对瞬时信号分离问题进行求解，并将神经网络中的主成分分析(Principle Component Analysis, PCA)进行扩展，提出 ICA 算法的基本概念；且证明出通过恢复出混合信号中各分量间的统计独立性，就能够实现对源信号的分离。在此之后，涌现了一大批优秀的 BSS 算法。

Bell 和 Sejnowski 两位美国学者^[4]基于信息最大化准则，对目标函数进行构建，将 ICA 算法理论同信息论的知识相结合，分离出超高斯信号，且于 1995 年提出信息最大化方法。Amari 等学者结合信息几何学的有关知识，在黎曼流形空间中研究优化问题，并基于互信息最小与熵最大化的在线学习算法，于 1996 对随机梯度算法进行改进，提出经典的自然梯度算法^[5]，将其应用于非线性混合信号的分离。次年，芬兰的两位学者 Oja 和 Hyvarinen 提出了快速固定点算法，该算法以峭度为目标函数，采用近似牛顿迭代法解出目标函数的最优值。

然而，在实际应用中传感器数目往往会小于源信号数目，传统 ICA 算法不能适应于直接解决欠定情形。2000 年 Lewicki 等人^[6]针对解决 UBSS 问题，基于信号的稀疏特性，提出著名的稀疏分量分析算法，该算法同 ICA 算法一样具有划时代意义。次年，Bofill 和 Zibulevsky^[7]在此基础上提出“两步法”思路用以

解决欠定情况下混合矩阵估计与源信号的重构问题。2006 年, Dohono 等人针对欠定线性系统提出压缩感知^[8]用于解析稀疏源信号, 该方法可以有效避免数据丢失问题。2007 年, Mitianoudis 等人^[9]利用改进的离散余弦变换对观测信号进行稀疏表示, 提出了一种用于求解 UBSS 问题的分批拉普拉斯混合模型法, 并利用硬判决或软判决方案进行分离。该方法可以推广到动态变化环境下的 UBSS 问题中, 但其对拉普拉斯混合模型的初始化参数敏感, 会降低源信号的分离性能。

国内对处理 BSS 问题的研究比国外稍晚, 但也取得丰硕的成果。1996 年, 凌變亭^[10]根据 Hebbian 自学习算法的动态学习方程, 利用神经网络的方法实现信号分离。由此, 国内诸多学者逐渐投入到 BSS 问题的研究中。

1998 年, 刘琚等人^[11]基于独立性的假设, 利用最大化信息传输和输出互信息最小化的理论判据, 构造 BSS 新准则函数, 完成源信号的分离。后又于 1999 年基于信息论原理构建目标函数, 并根据信号的非平稳特性, 得到网络权系数的训练规则^[12], 再利用所提出的规则进行训练后得到分离矩阵从而实现对源信号的恢复。该训练算法有效避免矩阵求逆, 对后面 BSS 问题研究起到一定的借鉴作用。2001 年, 张洪渊等人^[13]结合随机变量的概率密度函数及高斯核函数构造目标函数, 提出一种对超、亚高斯信号均适用的高效盲分离算法。该方法能够自动根据任意种类混合信号对应的统计特性高效还原出源信号。2003 年, 杨俊安^[14]利用多宇宙量子交叉提高量子遗传算法全局收敛性, 提出一种改进的快速独立成分分析算法; 并用其优化求解以负熵为基础构造的目标函数, 算法适用于解决非线性瞬时混叠的 BSS 模型; 通过仿真实验证实新方法比常规遗传算法对处理 BSS 问题时的效率更高。

2007 年, 杨小牛等人^[15]基于最大似然估计的目标函数, 结合最优步长筛选的思路, 提出一种改进自然梯度算法的步长迭代方法。通过对干信比的数值定量结果的比较分析可知, 改进后算法的收敛速度得到一定的提升, 且依然能保持良好的稳定性。但固定的步长使得传统 ICA 方法收敛速度较慢, 源信号恢复效果较差。2012 年, 张银雪等人^[16]提出的基于改进粒子群优化 ICA 算法能够较为有效解决传统梯度算法稳态误差失调问题, 进一步提高收敛速度。2018 年, 张天骐、马宝泽等人^[17]通过动态调整原始粒子群算法中每个粒子的惯性权重的

方法提高优化算法的收敛速度，并将其与遗传算法结合起来，用以求解 BSS 问题。使用的策略能够有效降低算法的复杂度、提高效率，且在实际的动态混合轴承信号应用中，能够快速检测出内圈和外圈故障。同年，褚鼎立、陈红等人^[18]提出用鲸鱼优化算法代替传统粒子群算法求解目标函数，并引入自适应权重以提高优化算法的收敛速度，成功的将源信号从混合信号分离开来。

针对 UBSS 领域，李宏坤等人^[19]将观测信号与经验模式分解(Empirical Mode Decomposition, EMD)的结果进行组合，构成虚拟的多通道观测信号，实现信号的升维。该方法有效避免传统稀疏估计的方法在解决 UBSS 问题时，对观测信号高稀疏性的要求所导致使用范围受限的缺陷。然而，EMD 算法具有端点效应，导致分离结果不理想，影响算法精度。2014 年，李志农，张芬等人^[20]利用小波分析对观测信号进行分解，利用小波分解后的小波系数对原观测信号重构，实现 UBSS 问题的转换，接着利用核典型相关分析方法对新观测信号进行分离；该方法有效解决了非线性 UBSS 问题。而小波变换在时域中的分解尺度按二进制变化，对信号高频段部分的频率分辨率较低。

1.2.2 智能优化算法研究现状

智能算法依据群体间信息交流的方式搭建相应的数学模型，通过模拟不同种群的不同行为机制建立适当的目标函数，对解空间中的最优值进行搜寻。该类算法具有较强的稳定性和有效性，且因其不涉及复杂的数学计算，结构简单、易于实现而被普遍应用。近年来，智能算法在优化领域内仍旧在不断发展。

遗传算法(Genetic Algorithm, GA)^[21]是一种最为经典的智能优化算法。该算法起源于二十世纪七十年代，鉴于 Darwin 进化论中的自然选择和 Mendel 遗传学定律理论知识，美国科学家 John Holland 模拟基因的遗传、交叉、变异过程；通过不断迭代至种群收敛，最终寻找到最优个体进行遗传操作。自此之后，智能优化算法在业界得到大量认可，由此引发学者提出更多种智能算法用以解决优化问题。

蚁群优化算法(Ant Colony Optimization, ACO)^[22]基于蚁群地面信息素的投放及食物的最短路径选择行为研究提出的一种概率型算法，该算法采用正反馈机制，能够进行并行计算，可以在较少的迭代次数内快速收敛。但在解决实际大

规模复杂场景下的优化问题时，该算法的寻优能力直接取决于信息素相关因子的取值，会使得对参数进行调整和重置成本代价过大。为提高优化算法的收敛性、扩大搜索空间、增强其优化能力，1995 年，Kenney 和 Eberhart 两位科学家在美国心理学家 James Heppner 构建的鸟群聚集模型基础上，提出粒子群优化算法^[23]。该算法通过迭代更新粒子的速度和位置快速获取种群最优值，是解决优化问题的一种经典智能优化算法。

传统的粒子群优化（Particle Swarm Optimization, PSO）算法在实际应用中容易陷入搜索空间的局部最优，诸多学者对此进行研究，以此衍生出一系列的算法，能够较为有效地增强算法的全局搜索能力。2008 年，Kao 和 Zahara 将 PSO 粒子更新方式与 GA 结合起来，对初始种群进行处理，并对一系列基准多模态函数进行测试比较；提出的 GAPSO 算法^[24]能够提高种群搜索能力，可以有效解决各种连续优化问题。另外，Sun^[25]等人提出基于量子力学角度的粒子群算法，对种群粒子设置不同的运动形式。该算法可以有效增强种群的全局搜索能力，与原始粒子群算法相比，具有量子行为的粒子群算法有效地扩大种群的搜索范围。但在搜索空间中，如若出现适应度数值较高的某一粒子时，其它粒子仍会向该粒子靠近，容易导致过早熟现象的发生。针对该算法容易陷入局部最优陷阱的缺陷，2014 年，Seyedali Mirjalili 等人提出灰狼优化算法，将支配关系^[26]介入优化算法中。对于初始化初期阶段种群部署范围不均匀的缺陷，Heidari 等人将莱维飞行策略引入灰狼优化算法^[27]；同时将其与贪婪算法相结合，最终得到全局范围内的最优选择，且传感器节点分布更加均匀的分布。在诸多智能优化算法中，鲸鱼优化算法已被多次证实具有更迅速的收敛速度和更简单的结构。鲸鱼优化算法最初是由 Seyedali Mirjalili, Andrew Lewis 等^[28]科学家，从鲸鱼个体的泡沫网狩猎方式激发得灵感，提出一种基于自然界物种行为特征的优化算法。该算法可以在高维复杂的实际系统中达到较高的解精度。伴随着智能优化算法的出现，目前越来越多的专家将智能算法应用于 BSS 领域中。与传统算法相比，基于智能优化算法的 BSS 方法在迭代次数较少的情形下，能够以一个较快的速度在全局范围内寻得目标函数的最优解。

2003 年，Yang 等人^[29]提出的一种多宇宙并行遗传算法，并将其与 ICA 结合，将其用于实现盲信号的分离。该算法对搜索空间中的个体进行量子交叉处

理，涉及使用量子旋转门和旋转角度旋转两种种群位置更新机制；算法根据搜索空间现有群体的拓扑结构，划分空间中的子群体，并利用遗传算法将信号的非线性混合度最小化。实验表明，改进的算法效果优于遗传算法及量子遗传算法，能够较为有效地提高算法的效率和适用性。2018 年，苏彬、苏皓然等人^[30]在粒子群算法的研究基础上，提出一种改进 PSO 的 UBSS 方法。该方法结合 K-means 算法，通过引入 ACO 信息素的概念对 PSO 算法进行优化，能够在较短时段里得出理想的聚类结果。

1.3 本文主要内容与章节介绍

本文主要围绕着智能优化算法（灰狼优化算法、鲸鱼优化算法）开展研究工作，并针对智能优化算法在处理 BSS 问题时表现出来的缺陷进行相应地改进。通过算法对比分析验证改进的智能优化算法在处理混叠信号分离问题上能够达到很好的分离效果；且通过选取不同的测试函数，针对不同的智能优化算法进行对比分析，验证加入的策略对寻优性能的有效性影响。将改进后的灰狼优化算法、鲸鱼算法与 BSS 中的 ICA 算法相结合，用于处理语音信号，并使用工程中的复合故障振动信号对改进算法的实用性进行验证。

本文分为 5 章，主要内容如下：

第 1 章：绪论部分。主要对 BSS 当前研究的发展情形进行概述，论述 BSS 研究背景及意义；归纳总结 BSS 及智能优化算法的国内外研究情况；并对本文的主要内容和各章节的内容进行简要概括。

第 2 章：基础理论部分。对 BSS 的相关理论知识及相关基础算法进行详细介绍；阐述 BSS 经典模型，观测信号中心化、白化的预处理过程，BSS 分离原理中各度量工具。

第 3 章：改进的鲸鱼优化算法在 BSS 问题中的使用方法。该方法基于互信息构建目标函数，并使用优化方法对其进行迭代求解。于迭代初期引入混沌反向学习策略，对原始的鲸鱼优化算法进行改进，以提高种群丰富度；于算法迭代后期，引入莱维飞行策略，有效提高算法的寻优能力。通过不断迭代判断收敛条件，寻得最优解作为步长，更新分离矩阵，提取分离信号。由仿真结果分析可知，改进的鲸鱼优化算法优于传统的优化算法，分离精度更优，收敛速度

得到明显提升。

第 4 章：改进的小波包算法在 UBSS 问题中的使用方法。该方法采用小波包变换将观测信号分解，将观测信号的维数进行扩展，利用互相关系数剔除冗余的信号分量，UBSS 问题得到转化。接着，使用贝叶斯信息准则下的奇异值分解方法估计源信号数目，通过白化过程对信号降维。然后，将鲸鱼优化算法中的螺旋泡网狩猎行为与莱维飞行策略结合使用，对传统优化算法进行改进。最后，将改进后的混合灰狼优化算法与 ICA 相结合，实现重构正定白化信号的分离，最终得到源信号的近似估计。通过仿真实验对算法性能进行测试，结果验证所提方法的可行性和有效性。

第 5 章：总结部分。对本文在 BSS 领域中所做的工作进行总结，并针对尚未解决的盲源问题进行展望。

第2章 盲源分离基础理论

2.1 经典盲源分离模型

BSS 指在源信号及其传输通道等各信息均未知的情况下，仅凭借观测到的信号提取出所需有效信息的一种常用的信号处理方法。盲信号分离问题的解决大多采用 ICA 的方法。根据源信号的独立性，选用相应适合的优化算法，将接收到的观测信号分解成为若干个相互之间尽可能统计独立的信号成分，将其作为源信号的一种近似估计。

假设 n 维源信号 $\mathbf{S}(t)=[s_1, s_1, \dots, s_n]^T$ ， m 维噪声信号 $\mathbf{E}(t)=[e_1, e_1, \dots, e_m]^T$ ，一般线性瞬时混合模型如下：

$$\mathbf{X}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_m(t) \end{bmatrix}, t=1, 2, \dots, T \quad (2-1)$$

在无噪声情况下，瞬时 BSS 的时域模型表示为 $\mathbf{X}(t) = \mathbf{A}\mathbf{S}(t)$ 。其中， $\mathbf{A}$ 为 $m \times n$ 维混合矩阵，当 $m < n$ ，混合系统为欠定；当 $m = n$ ，为正定系统；当 $m > n$ ，为超定系统。 $\mathbf{X}(t)=[x_1, x_2, \dots, x_m]^T$ 表示 m 个观测信号， t 为时间采样点。式(2-1)中的 $a_{ij} (1 \leq i \leq m, 1 \leq j \leq n)$ 表示矩阵 $\mathbf{A}$ 的第 i 行、第 j 列的元素。

ICA 算法旨在寻得分离矩阵 $\mathbf{W}$ ，将源信号 $\mathbf{S}(t)$ 从观测信号 $\mathbf{X}(t)$ 中分离出来，其过程为：

$$\mathbf{Y}(t) = \mathbf{W}\mathbf{X}(t) \quad (2-2)$$

$$\mathbf{G} = \mathbf{W}\mathbf{A} \quad (2-3)$$

式中， $\mathbf{Y}(t)$ 为输出源信号的估计信号， $\mathbf{G}$ 表示整个系统的全局矩阵， $\mathbf{W}$ 表示为一个线性分离矩阵。当全局矩阵 $\mathbf{G}$ 近似为单位矩阵时， $\mathbf{Y}(t) \rightarrow \mathbf{S}(t)$ ，即信号的独立成分被算法分离。

2.2 观测信号的预处理

接收到的观测信号不能直接进行分离处理，通常需要先对其进行中心化和白化操作。ICA 算法源信号的预处理过程如图 2-1 所示。




图 2-1 ICA 算法预处理过程

Fig.2-1 ICA algorithm preprocessing process

经过预处理后的信号具备一定的约束性条件，可以有效降低盲信号分离问题的复杂度，提高算法性能，从而达到更好的分离效果。

（1）中心化过程

中心化又称为零均值化，观测信号经过中心化处理，将源信号的各个信号成分简化为零均值向量，数据变得简单，易于处理。该过程表示为：

$$\mathbf{C}(t) = \mathbf{X}(t) - E\{\mathbf{X}(t)\} = \mathbf{A}\mathbf{S}(t) - E\{\mathbf{A}\mathbf{S}(t)\} \quad (2-4)$$

其中， $\mathbf{C}(t)$ 为观测信号去均值后的零均值信号。

（2）白化过程

白化利用线性变换消除混合信号中各成分之间的线性相关性，该过程可以有效简化后续 ICA 提取信号成分的过程。经过白化处理后，信号各矢量的协方差矩阵均为单位阵。该过程表示为：

$$\mathbf{Z}(t) = \mathbf{B}\mathbf{C}(t) \quad (2-5)$$

式中， $\mathbf{Z}(t)$ 为白化处理后的信号， $\mathbf{B}$ 表示白化矩阵，通常采用特征值分解求得。分解过程如下：

$$E(\mathbf{C}\mathbf{C}^T) = \mathbf{E}\mathbf{D}\mathbf{E}^T \quad (2-6)$$

$$\mathbf{B} = \mathbf{E}\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T \quad (2-7)$$

$$\mathbf{D}^{-\frac{1}{2}} = \text{diag}(d_1^{-\frac{1}{2}}, d_2^{-\frac{1}{2}}, \dots, d_n^{-\frac{1}{2}}) \quad (2-8)$$

其中， $D = \text{diag}(d_1, d_2, \dots, d_n)$ 为 $E(CC^T)$ 经过特征分解后得到的对角矩阵。

2.3 分离原理

使用 ICA 求取混合矩阵前，应先确定衡量输出信号独立性的判据标准，再加以适配的优化算法，从而能够得到准确度高的分离矩阵，即为解混矩阵。最终，输出信号和源信号具有较高的相似度，以此达到分离的目的。

根据信息论的相关知识，其一般选用互信息、负熵、峰度等作为判据指标。通常依据信号的非高斯性来衡量其独立性，选用合适的度量工具构造目标函数以评估或解决连续及离散问题。常选用如下方式对信号的非高斯性进行量化。

2.3.1 互信息

互信息作为衡量输出信号成分间独立性的一个重要指标，通过密度函数计算以衡量随机变量间的依赖关系。

根据微分熵定义，如式(2-9)所示，定义为：

$$I(y) = KL[p(y), \prod_{i=1}^n p(y_i)] = \int p(y) \log \frac{p(y)}{\prod_{i=1}^n p(y_i)} dy = \sum_{i=1}^n H(y_i) - H(y) \quad (2-9)$$

其中， y 表示一个多维向量， y_i 为其第 i 个分量， $p(y)$ 表示 y 的联合密度， $H(y_i) = -E \cdot \log(p_{y_i}(y_i))$ ， $H(y) = -E \cdot \log(p_y(y))$ 为源信号的熵， E 为期望算子。若 $I(y) = 0$ ，则说明 y_i 之间统计独立。

2.3.2 负熵

负熵用以描述变量的随机性能，常作为 BSS 问题中所需的目标函数。对于随机变量 $Y = \{y_1, y_2, \dots, y_i, \dots\}$ ，定义熵为：

$$H(Y) = -\sum P(Y = y_i) \log P(Y = y_i) \quad (2-10)$$

对于任意连续变量 y_i ，其熵的定义为：

$$H(y_i) = -\int p_{y_i}(\xi) \log(p_{y_i}(\xi)) d\xi \quad (2-11)$$

由信息论的观点可知，在方差相等的随机变量中，高斯信号的熵值最大，用高斯信号成分的熵值与其他信号成分的熵值作差，可以有效度量两信号成分间的独立性^[31]。模型如下：

$$J(y_i) = H(y_{i,G}) - H(y_i) \quad (2-12)$$

$$H(y_{i,G}) = \frac{1}{2} \log |\det \Sigma| + \frac{n}{2} (1 + \log 2\pi) \quad (2-13)$$

其中 $y_{i,G}$ 是一个高斯随机变量，其协方差与 y_i 相同。 n 为变量的维数， Σ 表示为协方差矩阵，变量 y_i 呈高斯分布时， $J(y_i)$ 为零；一般而言，负熵非负。

然而，负熵的理论计算还依赖于变量的先验概率密度等不准确的信息，通常使用变量的高阶统计量和密度多项式展开对负熵进行近似估计。

$$J(y_i) \approx \frac{1}{12} k_3^2(y_i) + \frac{1}{48} k_4^2(y_i) + \frac{7}{48} k_3^4(y_i) - \frac{1}{8} k_3^2(y_i) \cdot k_4(y_i) \quad (2-14)$$

其中， $k_\lambda(\bullet)$ 表示为 λ 阶累积量， y_i 概率分布对称的情况下，累积量计算公式如下：

$$k_3(y_i) = 0 \quad (2-15)$$

$$k_4(y_i) = E\{y_i^4\} - 3E^2\{y_i^2\} \quad (2-16)$$

简化负熵公式为：

$$J(y_i) \approx \frac{1}{48} k_4^2(y_i) \quad (2-17)$$

通过使用高阶累积量对负熵进行近似估计的方式，能够有效避免对概率密度进行估计，有效降低算法的复杂度。

2.3.3 峰度

非高斯信号的存在性是 ICA 应用于 BSS 的基础，峰度是测量随机信号非高斯性的一种经典初始条件判据。

一般，随机信号 y 的峰度定义如下式所示：

$$kurt(y) = E\{y^4\} - 3 \cdot E^2\{y^2\} \quad (2-18)$$

对采样信号进行中心化和白化处理^[32]，归一化后随机信号 y 的方差为 1，故

而峰度可以简化为:

$$kurt(y_i) = E\{y_i^4\} - 3 \quad (2-19)$$

对于超高斯、亚高斯及高斯三种类型的信号，对应的峰度值为正、负数与零的情况。下图 2-2 为三种信号分布的概率密度函数曲线，反映三种信号的分布规律。




图 2-2 概率密度函数曲线图

Fig.2-2 Probability density function plot

由图 2-2 分析可知，三种信号的期望均为零，概率总和为 1，高斯信号的概率密度曲线分布尖锐标准差较大。在实际应用中，满足高斯分布的信号极为稀缺，在此情况下，使用峰度作为独立性判据，能够很好反映出亚、超高斯分布信号的分离。

2.4 盲源分离的性能判断指标

在处理 BSS 问题的过程中，往往需要使用一定的判断指标比较使用策略对算法性能的提高程度，进而衡量算法的优劣性。评判方法可分为主观和客观两种形式。

主观评判法是人类借助自身感官，直观感受所估计的源信号与分离信号间的相似度。因其不确定因素较多，结论存在一定的局限性，通常还需结合客观评判法对算法策略进行定量分析。

客观评判法是借助数理公式，计算得出实验结果，对算法进行定量判断，杜绝人为因素的干扰，更具说服力。在 BSS 中，对于源信号、观测信号及混合矩阵三者的估计误差，通常选用相似系数、信干比、串音误差、相关系数、归

一化均方根误差及角度偏差等加以评判。通过客观测量得出相应的数据结果，有效衡量使用策略的优劣程度。

2.4.1 混合矩阵估计误差的判断指标

(1) 归一化均方根误差 (NMSE)，参见式 (2-20) 所示：

$$NMSE(\mathbf{A}, \mathbf{A}_x) = 10 \lg \left[\frac{\sum_{i=1}^M \sum_{j=1}^N (a_{x,ij} - a_{ij})^2}{\sum_{i=1}^M \sum_{j=1}^N a_{ij}^2} \right] \quad (2-20)$$

(2) 角度偏差 (ANG) 计算式为：

$$ANG(\mathbf{A}, \mathbf{A}_x) = \frac{180}{\pi} \arccos \left(\frac{\langle \mathbf{A}, \mathbf{A}_x \rangle}{\|\mathbf{A}\| \cdot \|\mathbf{A}_x\|} \right) \quad (2-21)$$

式中， M 和 N 分别表示矩阵的行与列数， $\mathbf{A}_x$ 表示算法估计的混合矩阵， $\mathbf{A}$ 为原始的混合矩阵， $a_{x,ij}$ 和 a_{ij} 分别对应算法估计的混合矩阵和混合矩阵的第 i 行第 j 列上的元素。仿真运行出的标准化均方误差和角度偏差值数越小，表明算法的稳定性越高。

2.4.2 源信号的判断指标

(1) 相似系数常用做衡量两类信号之间的邻近度，其值数越接近 1，表明两类信号越相似，其表达式为：

$$\zeta_i = \frac{\sum_{t=0}^{N-1} y_i(t) s_i(t)}{\sqrt{\sum_{t=0}^{N-1} y_i^2(t) \sum_{t=0}^{N-1} s_i^2(t)}}, \quad i = 1, \dots, n \quad (2-22)$$

式中， s_i 为源信号， y_i 为分离信号， N 为观测信号的长度。通常使用相似系数的平均值 $\bar{\zeta}_i$ 用来评判分离性能，其值越接近 1，表明源信号与分离信号越接近，分离精度越高。

(2) 信干比 $R_{SN}(y_i)$ 表达式为：

$$R_{SN}(y_i) = 10 \log \frac{E(|s_i|^2)}{E(|y_i - s_i|^2)}, \quad i = 1, \dots, n \quad (2-23)$$

$R_{SN}(y_i)$ 数值越大，表明分离效果越好。

2.4.3 分离信号的判断指标

(1) 串音误差作为衡量信号分离的性能指标，其数学表达式为：

$$Cte(t) = \frac{1}{n} \left\{ \sum_{i=1}^n \left(\sum_{j=1}^n \frac{|G_{ij}(t)|}{\max_k |G_{ik}(t)|} - 1 \right) + \sum_{j=1}^n \left(\sum_{i=1}^n \frac{|G_{ij}(t)|}{\max_k |G_{kj}(t)|} - 1 \right) \right\} \quad (2-24)$$

公式(2-24)中， G_{ij} 表示全局矩阵 G 的第 i 行第 j 列的元素； $\max_k |G_{ik}(t)|$ 表示矩阵 G 的第 i 行元素绝对值中的最大值； $\max_k |G_{kj}(t)|$ 表示矩阵 G 的第 j 列元素绝对值中的最大值。串音误差数值越接近 0，表明分离性能越佳。

(2) 相关系数是用做描述信号属性特征的一种常用度量指标，用其可以有效衡量表示信号间的线性相关性。相关系数的数值越大，表明两信号越线性相关。其值介于 -1 和 1 之间，且 $|R|$ 越接近 1，信号越相似。计算公式如(2-25)所示：

$$R = \frac{\sum_{k=0}^{N-1} [X(k) - \bar{X}(k)][Y(k) - \bar{Y}(k)]}{\sqrt{\sum_{k=0}^{N-1} [X(k) - \bar{X}(k)]^2 \sum_{k=0}^{N-1} [Y(k) - \bar{Y}(k)]^2}} \quad (2-25)$$

其中，样本点的总数为 N ， $X(k)$ 和 $Y(k)$ 表示为所衡量两信号，且：

$$\begin{cases} \bar{X}(k) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) \\ \bar{Y}(k) = \frac{1}{N} \sum_{k=0}^{N-1} Y(k) \end{cases} \quad (2-26)$$

2.5 正定盲源分离算法

传统 BSS 方法易受到传感器数量的限制，观测信号的数量通常大于源信号的数量。在此正定情况下，有效的解决方案为，使用合适的算法将所观测到混合信号进行分解，使分离分量间保持一定的独立性，进而实现信源信号恢复。

2.5.1 独立成分分析

ICA 是用来解决 BSS 问题的一种传统方法，寻找一种线性变换，尽可能得到各分量之间相互统计独立的输出信号。使用 ICA 对盲信号进行分离前，首先，需选择合适判据，构建出相应的目标函数，对信号成分的独立性进行判别。其次，使用优化算法对构建的目标函数进行迭代求解，通过逐步逼近的方法求得函数的最优值，获取独立性最强的分离矩阵，最终得到源信号的最佳估计。

对信号进行 ICA 之前，需要源信号具备的条件^[33]：

(1) 独立性：两个连续型信号成分相互独立满足 $P_{xy}(xy) = P_x(x) \cdot P_y(y)$ ，即两信号成分的概率密度乘积等于其联合密度函数；

(2) 非高斯性：信号分布具有高斯性，其成分中至多含有一个呈高斯分布，否则信号的累积量为零，不利于信号的获取；

(3) 非平稳特性：在 ICA 基于信号的二阶累积量时，信号的频谱统计特性随时间呈现一定变化；

(4) 非白特性：在 ICA 基于信号的二阶累积量时，信号有此特性，分量之间线性不相关。

另外，ICA 还具有不确定因素：

(1) 经过 ICA 处理后信号分量的方差不确定；

(2) 经过 ICA 处理后信号分量的输出次序不确定。

2.5.2 传统优化算法

传统的优化算法往往适用于理想约束状态下的最优解的求取，通常要求约束条件完备，如理想的函数、以及目标函数连续可微等。常用优化算法如下：

(1) 梯度下降法：该算法利用当前位置的负梯度下降^[34]的方向作为求解优化问题最优解的搜索方向，通过迭代次数的增加，离目标最优的距离越近，步长越小，搜索进度越缓慢。过程表示如下：

$$\nabla_{\omega} F(\omega) = \frac{\partial F(\omega)}{\partial \omega} = 0 \quad (2-27)$$

$$\omega(n+1) = \omega(n) - \eta(n) \frac{\partial F(\omega)}{\partial \omega} \Big|_{\omega=\omega(n)}, n = 0, 1, 2, \dots \quad (2-28)$$

其中, $\frac{\partial F(\omega)}{\partial \omega}$ 取在 $\omega(n)$ 点的值, $\eta(n)$ 为算法的学习率; 训练步长的控制是由当前点的斜率和学习率。但是, 该算法的收敛程度受到其步长影响, 当样本点数较多时会耗费大量的时间成本。

(2) 牛顿法: 是一种多阶迭代优化算法, 常用于求解函数最小值问题。牛顿迭代公式为:

$$y_{n+1} = y_n - \frac{F(y_n)}{F'(y_n)} \quad (2-29)$$

该方法在求解多项式根时, 能够在较短的时间快速收敛, 常用于解决无约束下的优化问题。然而, 由于其迭代依赖于初值, 当初值质量较差时, 可能会存在迭代发散状况的发生。

(3) 共轭梯度法: 针对牛顿法计算复杂度高, 梯度算法收敛慢的缺陷, 依据一阶导数的数据信息, 提出的能够快速收敛的一种算法。

(4) 拉格朗日乘子法: 利用拉格朗日算子^[35]将多个约束条件转化为无约束条件下的多变量问题进行求解。

传统的优化算法收敛速度较快, 可以在较短时间内获得比较精确的最优解; 但在高维、复杂的解空间中, 在对目标函数不断迭代、寻找最优解过程时, 传统的优化算法呈线性收敛, 其收敛速率和稳定性受到迭代步长制约; 而智能优化算法无需进行复杂的求导, 收敛效果较好。

2.6 欠定盲源分离算法

2.6.1 稀疏分量分析

稀疏分量分析(Sparse Component Analysis, SCA)^[36]算法主要适用于 BSS 中混合信号数目小于源信号的欠定情况下, 对源信号做一定的稀疏性要求的状况。

SCA 主要研究内容包括两个步骤: 第一, 利用已知混合信号的稀疏性进行估计。信号的稀疏性是指信号仅在少数瞬间有较明显的幅度值, 而在大部分时刻采样结果为零或趋近零, 满足高斯性及一定的拉普拉斯分布; 利用这一性质可以解决 UBSS 问题。第二, 基于信号的稀疏表示对源信号恢复, 即著名的“两步法”。SCA 是在传感器数量有限的情况下, 解决欠定问题的一种经典算法。

针对 UBSS 问题在实际中的应用，为增强观测信号的稀疏性，通常选用短时傅里叶变换(short-time Fourier transform, STFT)^[37]对信号进行线性变换，将观测信号从时域映射到时频域，以提高稀疏度。

对三路观测信号使用 STFT 处理后时频域散点分布如图 2-3 所示：




图 2-3 三路观测信号时频域散点图

Fig.2-3 Scatterplot of three observed signals in time-frequency domain

经过 STFT 处理后，信号的散点图呈现出清晰的方向性，稀疏特性得到一定程度地提升，相应地，SCA 算法对信号的提取效果得以提高。

2.6.2 小波变换

小波变换作为一种线性变换，也是常用的信号提取方式之一，其基本原理是将信号分解为高低两部分后，再对信号的低频部分进行分层分解。使用小波变换对观测信号进行分解，并通过对小波分解后的小波系数与原观测信号重构，可以实现 UBSS 问题的转换。

对于一个给定的观测信号 $x(t)$ ，进行小波分解后，得到若干个离散的系数 $a_j(k)$ 和 $d_j(k)$ 。两类离散系数递推关系^[38]如下：

$$a_j(k) = \sum_{n=-\infty}^{\infty} a_{j-1}(n)h_0(n-2k) = a_{j-1}(k) * \bar{h}_0(2k) \quad (2-30)$$

$$d_j(k) = \sum_{n=-\infty}^{\infty} a_{j-1}(n)h_1(n-2k) = a_{j-1}(k) * \bar{h}_1(2k) \quad (2-31)$$

式中， $a_j(k)$ 和 $d_j(k)$ 表示从 $j=1$ 级空间尺度开始分解，得到的逼近系数与细节

系数, $h_0(k)$ 和 $h_1(k)$ 表示为低频和低频分解滤波器。

通常, 将逼近系数与原观测信号进行排列后重组, 构造出新的观测信号, 达到信号维数的提升。

2.7 本章小结

本章主要介绍了有关 BSS 的基础理论知识, 包括经典的 BSS 数学模型、观测信号的预处理过程、信号的分离原理及其判断指标; 之后, 对正定和欠定 BSS 的相关算法进行阐述。

第3章 基于改进鲸鱼优化算法的盲源分离

针对第 2 章所提传统优化算法在解决 BSS 问题时，由其固定步长造成的稳态误差问题，本章基于互信息最小化准则构造目标函数，将改进后的鲸鱼算法应用于 BSS 领域。首先，针对传统鲸鱼算法在种群迭代初期存在随机搜索范围较局限的问题，采用混沌反向学习策略对种群进行初始化操作，以提高种群丰富度，增加算法的精确度。其次，引入莱维飞行策略，对种群位置进行扰动，避免在迭代后期陷入局部最优，产生过早收敛现象。最后，将改进的鲸鱼优化算法得出的全局最优解，迭代调整 ICA 的步长，进而实现信号的分离。改进的鲸鱼优化算法优于传统优化算法，分离精度更优，收敛速度得到明显的提升。

3.1 鲸鱼优化算法

3.1.1 传统的鲸鱼优化算法

鲸鱼优化算法（Whale Optimization Algorithm, WOA）最初由 Seyedali Mirjalili, Andrew Lewis 等^[28]科学家，受到座头鲸的气泡网狩猎行为的启发，根据鲸鱼个体行为特征，针对优化问题所提出的一种智能算法。WOA 模拟的鲸鱼群体捕食行为，算法概括为开发和搜寻两阶段。在开发阶段，包括两种狩猎机制：收缩包围和螺旋位置更新；在搜寻阶段，采用随机搜寻位置更新的方式。

（1）收缩包围：

在“包围狩猎”阶段初期，由于鲸鱼个体间未知猎物的具体位置，故假设当前群体中最佳个体位置作为目标猎物的位置，并通过式(3-1)进行位置更新，朝向最佳位置靠近。种群位置更新的数学模型建立如下：

$$\mathbf{X}_{i+1} = \mathbf{X}_{\text{best},i} - A \cdot |C \cdot \mathbf{X}_{\text{best},i} - \mathbf{X}_i| \quad (3-1)$$

式中， i 表示当前种群迭代次数， $\mathbf{X}_i$ 为当前鲸鱼个体的位置， $\mathbf{X}_{i+1}$ 为下一时刻个体位置； $\mathbf{X}_{\text{best},i}$ 为当前时刻最佳鲸鱼个体位置。另外，参数 A 和 C 为系数变量，其计算公式为：

$$A = 2 \cdot a \cdot r_1 - a \quad (3-2)$$

$$C = 2 \cdot r_2 \quad (3-3)$$

$$a = 2 - \frac{2i}{I_m} \quad (3-4)$$

式中 r_1 和 r_2 为 $[0,1]$ 范围内取值的两个随机数，它们为种群位置提供了随机性； I_m 为最大迭代次数；收敛因子 a 在迭代过程中从 2 线性递减至 0。

种群群体通过式(3-2)和(3-3)平衡开发和搜寻行为。

(2) 螺旋位置更新：

根据座头鲸沿螺旋状运动模拟鲸鱼靠近猎物的狩猎方式，螺旋位置更新模型如式(3-5)表示：

$$X_{i+1} = X_{\text{best},i} + e^{bl} \cdot \cos(2\pi l) \cdot |X_{\text{best},i} - X_i| \quad (3-5)$$

式中， b 为定义的对数螺旋形状常数， l 为 $[-1,1]$ 范围内取值的一个随机数。

在鲸鱼以螺旋状游走的方式逼近猎物的同时，也必须收缩以包围猎物。因此在位置优化过程中，通过相同概率选择收缩包围机制和螺旋更新机制来模拟该群体行为。即在每次迭代时以 50% 的概率作为阈值选择两种机制。数学模型概括为：

$$X_{i+1} = \begin{cases} X_{\text{best},i} - A \cdot |C \cdot X_{\text{best},i} - X_i|, & p < 0.5 \\ X_{\text{best},i} + e^{bl} \cdot \cos(2\pi l) \cdot |X_{\text{best},i} - X_i|, & p \geq 0.5 \end{cases} \quad (3-6)$$

(3) 随机搜寻

在开发阶段，鲸鱼个体狩猎的收缩包围和螺旋更新策略实现局部最优。为得到更大空间范围内的猎物捕获，鲸鱼在搜寻阶段，根据系数 A 的数值，随机搜索目标。当 A 超过 $[-1,1]$ 范围，鲸鱼种群为提高捕获能力，采用随机搜索的方式进行位置更新。数学模型可以表示为：

$$X_{i+1} = X_{\text{rand},i} - A \cdot |C \cdot X_{\text{rand},i} - X_i| \quad (3-7)$$

式中， $X_{\text{rand},i}$ 为当前鲸鱼个体的随机位置向量。

3.1.2 改进的鲸鱼优化算法

WOA 相比于传统智能优化算法效率更高，具有更高的勘探能力。但 WOA

在处理复杂函数优化问题时，往往会出现较低的收敛速度，易出现陷入局部最小等缺陷，造成寻优精度低，得出的解偏离理想最优解。因此，在 WOA 迭代更新位置前引入混沌反向学习策略，增加种群多样性；在迭代后期引入莱维飞行策略，增强算法的全局寻优能力。

（1）混沌反向学习策略

传统鲸鱼优化算法利用伪随机数来引导种群搜索食物源的位置变换。但该初始化种群方式不能使得种群分布的足够均匀，可能导致鲸鱼个体在搜寻食物的初期阶段出现无效更新次数的增加，进而影响收敛速度。本节基于智能优化算法在初始阶段对种群有一定程度的丰富度需求，将伯努利混沌映射与反向学习^[39]相结合，使种群分布更加均匀，为后期的全局搜索奠定基础。

首先利用伯努利混沌映射将位置信息映射到混沌变量空间中，混沌映射的具体表达式为：

$$Z_{n+1} = \begin{cases} Z_n / (1 - \lambda), & 0 < Z_n \leq 1 - \lambda \\ (Z_n - 1 + \lambda) / \lambda, & 1 - \lambda < Z_n < 1 \end{cases} \quad (3-8)$$

式中， n 表示混沌迭代次数， Z_n 为经过伯努利映射迭代 n 次得到的混沌序列当前值，参数 λ 为混沌参数，控制混沌轨道状态值范围为(0,1)。一般，参数 λ 取 0.4 能够获得较好的遍历性，初始混沌序列 Z_0 取 0.152。

将混沌映射融入种群位置迭代更新过程，如下所示：

$$X_i = Lb + (Ub - Lb) \times Z_i \quad (3-9)$$

$$OX_i = Lb + Ub - X_i \quad (3-10)$$

式(3-9)中 X_i 为第 i 个鲸鱼经过伯努利映射在空间中的个体位置， OX_i 为经过反向学习后鲸鱼种群的反解， Lb 和 Ub 为搜索区域的下边界和上边界。接着，将得到的两个种群集合取并集，找到适应度较高的鲸鱼个体作为初始种群，并保存最佳个体位置。

（2）莱维飞行策略

通过对传统鲸鱼优化算法的深入研究发现，随着迭代次数的增加，种群会向当前最佳位置靠拢，这样很容易造成迭代后期种群狩猎搜索范围变窄，使算法陷入局部最优。因此，引用莱维飞行策略进行鲸鱼位置扰动，进一步更新鲸

鱼群体的位置并更新最优值。经过扰动后的鲸鱼优化算法的可搜索性进一步提高，并且能够防止算法陷入局部最优解。位置更新公式如下：

$$\mathbf{X}_i^L = \mathbf{X}_i + \alpha \oplus \text{Levy}(s, \gamma) \quad (3-11)$$

式中， $\mathbf{X}_i^L$ 为经过莱维变化后种群的位置， α 为控制因子， $\oplus$ 表示为点积。

$\text{Levy}(\bullet)$ 表示莱维分布函数，计算式^[40]为：

$$\text{Levy}(s, \gamma) = \frac{\gamma \cdot \Gamma(\gamma) \cdot \sin(\frac{\pi\gamma}{2})}{\pi s^{1+\gamma}} \quad (3-12)$$

其中， γ 为概率系数取 1.5， $\Gamma(\bullet)$ 为伽马函数。 s 为莱维飞行的步长，计算式为：

$$s = \frac{u}{|v|^{1/\gamma}} \quad (3-13)$$

另外， u 、 v 服从数学期望为 0，方差分别为 σ_u^2 、 σ_v^2 的正态分布：

$$\begin{cases} u \sim N(0, \sigma_u^2) \\ v \sim N(0, \sigma_v^2) \end{cases} \quad (3-14)$$

其中，标准差 σ_u 和 σ_v 定义为：

$$\begin{cases} \sigma_u = \left[\frac{\Gamma(1+\gamma) \cdot \sin(\pi\gamma/2)}{\Gamma[(1+\gamma)/2] \cdot \gamma \cdot 2^{(1+\gamma)/2}} \right]^{1/\gamma} \\ \sigma_v = 1 \end{cases} \quad (3-15)$$

3.1.3 改进的鲸鱼优化算法仿真实验

为验证 I-WOA 的有效性和可行性，选择 Sphere、SumSquare、Rosenbrock 和 Ackley 四个基准函数对改进的 WOA 进行性能测试。所选取的四个基准函数信息如表 3-1 所列，I-WOA 的实验参数设置如表 3-2 所示。

表 3-1 算法测试所用的四种基准函数

Table3-1 The four benchmark functions used to test the algorithm

基准函数名称	搜索范围	函数类型	理论最优值
Sphere	[-100,100]	单峰函数	0
SumSquare	[-10,10]	单峰函数	0
Rosenbrock	[-5,10]	多峰函数	0
Ackley	[-50,50]	多峰函数	0

其中，Sphere 和 SumSquare 为单峰基准函数，只有一个峰值，Rosenbrock

和 Ackley 为多峰基准函数，在搜索区间内有多个谷底和多个峰值^[41]。所有基准函数在搜索空间内均有极值，该极值即为最优解。

表 3-2 I-WOA 的参数

Table3-2 I-WOA parameters

参数	含义	取值
N	种群规模	50
I_m	最大迭代次数	600
b	对数螺旋参数	1
λ	混沌参数	0.4
γ	概率系数	1.5

在实验过程中，我们选用传统的鲸鱼优化算法(WOA)、基于混沌反向学习策略的鲸鱼优化算法(c-WOA)、基于莱维飞行策略的鲸鱼优化算法(levy-WOA)和改进的鲸鱼优化算法(I-WOA)进行实验，并对表 3-3 及图 3-1 呈现的实验结果进行对比分析。

为使实验结果具有普遍性，表 3-3 是对四种算法均进行 30 次的独立运行，取均值作为寻优结果。改进后的 I-WOA 在四个测试函数实验中曲线呈快速收敛，在迭代初期就能收敛至目标函数的最优。

表 3-3 4 种算法对 4 个测试函数的寻优结果比较

Table3-3 Comparison of the performance of the four algorithms on four test functions

函数	指标	WOA	c-WOA	levy-WOA	I-WOA
Sphere	最优解	1.16×10^{-1}	1.98×10^{-1}	1.59×10^{-2}	1.24×10^{-5}
	最差解	3.017	1.032	2.36×10^{-2}	6.63×10^{-4}
	平均值	1.357	5.10×10^{-1}	1.23×10^{-2}	2.03×10^{-4}
	标准差	9.44×10^{-1}	1.087	1.04×10^{-1}	3.13×10^{-4}
SumSquare	最优解	4.22×10^{-1}	1.44×10^{-1}	5.91×10^{-4}	4.78×10^{-6}
	最差解	6.10×10^{-1}	1.835	9.16×10^{-3}	7.45×10^{-5}
	平均值	4.92×10^{-1}	1.028	3.83×10^{-3}	2.91×10^{-6}
	标准差	1.17×10^{-1}	8.72×10^{-1}	3.97×10^{-3}	3.81×10^{-6}
Rosenbrock	最优解	6.80×10^{-1}	2.28×10^{-7}	3.57×10^{-8}	2.42×10^{-9}
	最差解	9.86×10^{-1}	2.68×10^{-6}	2.58×10^{-7}	2.62×10^{-9}
	平均值	1.24×10^{-1}	2.85×10^{-6}	8.93×10^{-8}	2.55×10^{-9}
	标准差	8.17×10^{-1}	9.01×10^{-7}	3.23×10^{-7}	0.12×10^{-11}
Ackley	最优解	6.65×10^{-7}	9.03×10^{-12}	3.34×10^{-12}	0
	最差解	1.414	1.92×10^{-11}	1.55×10^{-11}	9.18×10^{-12}
	平均值	9.22×10^{-6}	1.03×10^{-11}	1.58×10^{-12}	4.34×10^{-16}
	标准差	1.34×10^{-5}	6.01×10^{-12}	6.32×10^{-12}	8.81×10^{-16}

在 Rosenbrock 函数的性能测试中，I-WOA 解量级达到了 10^{-9} ，十分接近目标函数的理论最优数值 0。由四个测试函数值的寻优结果可得，与其他三个算法比较，I-WOA 的算法平均值均接近最优值，表明该算法具有良好的寻优能力。从均方差来看，I-WOA 算法也小于其它三个函数具有良好的稳定性。综上结果

可知，与 WOA、c-WOA 和 levy-WOA 相比，I-WOA 的寻优精度最高，说明经过混沌反向学习、莱维飞行策略的改进后，算法的综合能力得到了一定程度的提升。改进后的算法更能均衡地进行全局搜索和局部开发，趋于理论极值点的能力得到了提高。




图 3-1 算法对 4 个基准函数的寻优收敛曲线比较

Fig.3-1 Comparison of convergence curves of four algorithms for optimization of four benchmark functions

从寻优收敛曲线图 3-1 中可知，WOA 在迭代过程中曲线均处于较平直的状态，说明传统的 WOA 的寻优精度较差，无法得到较好的最优解。这是由于传统的鲸鱼算法存在的收敛速度慢和分离精度差等缺陷，在迭代过程中陷入局部最优。由两个单峰函数的性能测试收敛图 3-1(a)和图 3-1(b)知，对比于 c-WOA、levy-WOA 算法，I-WOA 算法收敛曲线的斜率更大，曲线更平滑，说明改进的

算法在均衡全局搜索和局部开发能力、跳离局部最优的能力方面得到了改善。而仅从初始阶段或者迭代后期对种群进行扰动不能高效提高算法的寻优能力。通过两个多峰函数的寻优收敛曲线图 3-1(c)和图 3-1(d)的比较, I-WOA 可以在 60 次迭代内达到问题的最优解, 而其余算法由于改进的较为单一, 均未达到该效果。

实验表明, I-WOA 在四种测试函数的整体收敛速度与整体稳定性最优。另外, c-WOA 和 levy-WOA 有较为明显的跳跃特征, 表明改进的算法比传统 WOA 跳离局部最优位置的能力更高, 搜索空间范围更大, 收敛精度得到一定程度的提高。

3.2 基于改进智能优化算法的盲源分离方法

传统智能优化算法在解决 BSS 问题时, 固定的步长使得传统 ICA 算法收敛速度较慢, 源信号恢复效果较差。本节根据中心极限定理, 基于互信息构造目标函数, 利用 I-WOA 对构建的目标函数进行优化求解, 将迭代求得的全局最优解动态更新 ICA 的步长, 最后实现源信号的有效恢复。

3.2.1 目标函数的构建

根据中心极限定理, 非高斯度量和非高斯假设常被用来揭示隐藏在数据中的独立成分。选用基于互信息的目标函数以衡量信号分量间的非高斯性。

利用互信息和信息熵的关系, 构造基于互信息的 BSS 算法的目标函数:

$$I(y) = \sum_{i=1}^n H(y_i) - \lg|\det \mathbf{W}| - H(x) \quad (3-16)$$

式中, $H(x) = -\int p(x) \log p(x) dx$ 表示为 x 的联合微分熵, 仅与观测信号有关, 而与解混系统的参数无关, 故优化分离矩阵时, 可将其作为常数。 $H(y_i) = -\int p(y_i) \log p(y_i) dy_i$ 表示 y 的边缘微分熵, 将 $H(y_i)$ 用高阶累积量 (偏度和峰度) 来近似估计:

$$H(y_i) \approx \frac{\ln(2\pi e)}{2} - \left[\frac{1}{12} kurt^2(y_i) + \frac{1}{48} skewn^2(y_i) \right] \quad (3-17)$$

式中, $kurt(\cdot)$ 表示信号的峰度, $skewn(\cdot)$ 表示信号的偏度, 常数 $\frac{\ln(2\pi e)}{2}$ 用于调整边缘微分熵的近似估计。对采样信号进行归一化处理, 处理后的峰度和偏度表示为:

$$kurt(y_i) = E\{y_i^4\} - 3 \quad (3-18)$$

$$skews(y_i) = E\{y_i^3\} \quad (3-19)$$

根据互信息最小化的 BSS 准则, 如果 $I(y) = 0$, 则说明 y_i 之间相互独立。因此, 选用与互信息相关的表达式作为 I-WOA 算法中种群的适应度函数:

$$Fit_i = I(y) \quad (3-20)$$

$I(y)$ 越小, 表明对源信号的分离效果越明显。通过寻找(3-20)式中 Fit_i 的最小值, 能够反映分离的状态。

传统 ICA 采用梯度算法利用(3-21)迭代公式^[42]对分离矩阵 W 进行迭代更新。

$$W(i+1) = W(i) + \mu_i \cdot W(i) \cdot [I - F(y(i)) \cdot y(i)] \quad (3-21)$$

式中, i 为迭代次数, $\mu_i > 0$ 为时变步长, $W(i)$ 为第 i 次迭代的分离矩阵, $F(y(i))$ 为非线性函数, 选取 $F(y(i)) = 2 \tan(y(i))$ 。

传统梯度算法易受固定步长的影响, 导致 ICA 算法的收敛速度受到限制, 进而影响源信号的恢复效果。因此采用 I-WOA 算法对步长 μ_i 进行调整, 根据输出信号分量间的独立性寻找最优值作为步长, 通过(3-21)更新分离矩阵。改进的算法能够降低传统 ICA 的稳态误差, 有效提高信号的恢复质量。

3.2.2 算法步骤

利用上述改进的鲸鱼优化算法寻找目标函数最优解作为 ICA 步长, 通过迭代更新分离矩阵 W , 减小算法稳态误差, 提高传统 ICA 算法的收敛速度。以互信息为目标函数, 将 I-WOA 算法应用于 BSS 问题的算法步骤如下:

步骤 1: 读取观测信号并进行预处理操作。

步骤 2: 初始化分离矩阵 W , 载入观测信号 $X(t)$; 初始化 I-WOA 算法参数,

包括鲸鱼种群规模大小 N ，最大迭代次数 L_m ，对数螺旋形状参数 b 等。

步骤 3：根据式(2-2)计算，得出输出信号 $Y(t)$ 。

步骤 4：通过公式(3-9)和(3-10)对初始种群进行初始混沌反向学习操作。计算种群适应度 Fit_i ，找出适应度值最小的个体作为最佳种群位置。

步骤 5：进入种群位置更新阶段。在 $p < 0.5$ 的情况下，当 $|A| < 1$ 根据式(3-1)来更新当前位置。当 $|A| \geq 1$ 则在种群中随机搜索目标，用式(3-7)更新位置。在 $p \geq 0.5$ 的情况下，采用螺旋更新机制式(3-5)更新种群位置。

步骤 6：所有种群搜索结束后，按照适应度值进行排序，对排序后的鲸鱼种群按照公式(3-11)进行莱维飞行扰动运算。

步骤 7：再次计算种群的适应度值，若新解的适应度更高，则替换旧解，否则不更新种群位置。

步骤 8：确定最佳鲸鱼个体位置 $X_{best,i}$ 并判断是否满足终止条件(找到适应度最小的种群位置或者达到迭代次数)。若满足终止条件则停止迭代，输出最优解，否则返回步骤 4。

步骤 9：输出 I-WOA 算法寻得的最优解作为步长 μ_i 。

步骤 10：通过(3-21)更新分离矩阵 W ，迭代得到 $W(i+1)$ 。

步骤 11：对分离矩阵归一化操作：
$$W(i+1) = \frac{W(i+1)}{\|W(i+1)\|}$$

步骤 12：参数 ε 为一个非常小的正数，将其设置为收敛值。判断 W 是否满足收敛条件，即 $|W(i+1) - W(i)| < \varepsilon$ ，算法收敛，输出 $W(i+1)$ 作为 W ，否则返回步骤 3。

步骤 13：根据式(2-2)恢复出源信号，算法结束。




图 3-2 基于 I-WOA 算法的 BSS 方法流程图

Fig.3-2 Flowchart of BSS method based on I-WOA algorithm

3.2.3 盲源分离实验

为验证改进算法的有效性，本节选用三路语音信号进行分离实验仿真并进行相应分析。选取的采样点为 5×10^4 ，采样频率为 4kHz，随机选择混合矩阵 A 如下：

$$A = \begin{bmatrix} 0.6797 & 0.11890 & 0.3404 \\ 0.6551 & 0.4984 & 0.5853 \\ 0.1626 & 0.9597 & 0.2238 \end{bmatrix}$$

混合后的语音信号分别用 I-WOA、WOA 和 ICA 算法进行处理，结果如图 3-3 所示。




图 3-3 语音信号分离效果

Fig.3-3 Speech signals separation Effect

图 3-3(e)为 ICA 算法分离信号图，与图 3-3(c)与图 3-3(d)比较可知，传统 ICA 算法分离效果不够理想。伴随着 WOA 的融入，ICA 的分离效果得到提高，但依然存在一定的混叠现象。I-WOA 融入 ICA 分离效果较为明显，与源信号波形基本相同，源信号的特性蕴含在分离信号中，取得较好的分离结果。另外需要指出的是，无论是传统 ICA 算法还是改进后的 ICA 算法，恢复信号与源信号相比，幅值和排列顺序^[43]均存在变化，这是盲信号分离的固有特性。

为进一步验证 I-WOA 融入 ICA 对处理 BSS 问题的效果，选用相似系数^[44] ς_i 和信干比^[45] R_{SN} 两种指标对算法的分离性能进行定量评判。二者定义如下：

$$\varsigma_i = \frac{\left| \sum_{t=0}^{N-1} y_i(t) s_i(t) \right|}{\sqrt{\sum_{t=0}^{N-1} y_i^2(t) \sum_{t=0}^{N-1} s_i^2(t)}}, \quad i = 1, \dots, n \quad (3-22)$$

$$R_{SN}(y_i) = 10 \log \frac{E(|s_i|^2)}{E(|y_i - s_i|^2)}, i = 1, \dots, n \quad (3-23)$$

式中， s_i 为源信号， y_i 为分离信号。式(3-22)中， N 为观测信号的长度。平均值 $\bar{\zeta}_i$ 用来评判分离性能，其值越接近 1，表明源信号与分离信号越接近，分离精度越高。信干比 $R_{SN}(y_i)$ 越大，分离效果越好。表 3-4 和表 3-5 给出了 ICA，WOA，I-WOA 三种算法对三路源信号分离的相似系数均值、信干比的数值结果。实验独立运行 50 次，样本数目为 500。

表 3-4 相似系数比较

Table 3-4 Similarity coefficient comparison

相似系数	ICA	WOA	I-WOA
$\bar{\zeta}_1$	0.9193	0.9571	0.9918
$\bar{\zeta}_2$	0.9714	0.9693	0.9935
$\bar{\zeta}_3$	0.9356	0.9873	0.9991

表 3-5 算法的信干比数值比较

Table 3-5 Numerical comparison of signal-to-density ratio of algorithms

信干比	ICA	WOA	I-WOA
$R_{SN}(y_1)$	79.9034	80.8531	85.6698
$R_{SN}(y_2)$	45.0113	47.8820	82.8113
$R_{SN}(y_3)$	30.5417	33.2582	78.2485

通过对表中的结果比较，三种算法中使用 I-WOA 得到的相似系数均值最接近 1、信干比最高。从而说明 I-WOA 比于 ICA 算法和 WOA，对源信号恢复效果更好。

图 3-4 是算法的串音误差^[46]与迭代次数之间的关系，直观反映出 I-WOA 对传统梯度算法改进的有效性。作为衡量信号分离的性能指标，串音误差 $Cte(t)$ 的数学表达式为：

$$Cte(t) = \frac{1}{n} \left\{ \sum_{i=1}^n \left(\sum_{j=1}^n \frac{|G_{ij}(t)|}{\max_k |G_{ik}(t)|} - 1 \right) + \sum_{j=1}^n \left(\sum_{i=1}^n \frac{|G_{ij}(t)|}{\max_k |G_{kj}(t)|} - 1 \right) \right\} \quad (3-24)$$

公式(3-24)中， G_{ij} 表示全局矩阵 G 第 i 行第 j 列的元素； $\max_k |G_{ik}(t)|$ 表示矩阵 G 的第 i 行元素绝对值中的最大值； $\max_k |G_{kj}(t)|$ 表示矩阵 G 的第 j 列元素绝对值中的最大值。在较少的迭代次数下，串音误差 $Cte(t)$ 数值越快速收敛至 0，表明算法性能越高。




图 3-4 两种算法的 Cte 收敛曲线

Fig.3-4 Cte convergence curves of two algorithms

由图 3-4 可知，两种算法在多次寻优迭代后，均达到收敛，但是传统梯度算法由于受到步长影响较大，收敛速度受到限制，大约 135 次左右收敛；而基于 I-WOA 的步长算法在运行 50 次后呈现迅速呈现收敛趋势；故而基于 I-WOA 的步长算法收敛速度较快，且算法的性能没有因为收敛速度的加快而恶化。综合分析得出，基于 I-WOA 优化 ICA 的方法拥有较高的收敛速度，且能够得出较好的收敛结果。

3.3 本章小结

本章为提高智能优化算法在处理 BSS 问题上的使用性能，将 I-WOA 应用于 BSS 领域。通过在鲸鱼种群初始化阶段引入混沌反向学习策略，使得种群在迭代前期扩大搜索范围，提高收敛速度。另外，在 I-WOA 迭代后期阶段引入莱维飞行策略，增强算法的全局寻优能力。通过四个测试函数对算法进行性能测试实验得出，改进的算法在解的精度和收敛速度方面均能表现出良好的优势。最后，通过对语音信号的分离仿真验证算法的有效性。实验结果表明，所提出的改进算法相比于传统算法，可以快速分离出原始语音信号且能有效降低传统 ICA 梯度算法带来的稳态误差。

第4章 基于小波包混合优化的欠定盲源分离

针对第 2 章所提实际求解 UBSS 时，观测信号的数量少于源信号的数量所导致的欠定混合系统不可逆情形中，SCA 算法对观测信号有足够稀疏的需求。在观测信号缺乏稀疏性的情况下，常规 ICA 算法难以直接求解问题，本章提出一种基于小波包混合优化的 UBSS 方法。该方法使用小波包变换将观测信号分解扩维，将欠定问题进行转化，并将灰狼优化算法与 ICA 算法结合，引入螺旋泡网狩猎行为及莱维飞行策略对优化算法进行改进。改进策略可以有效平衡算法的全局搜索与局部搜索能力，避免传统灰狼优化算法陷入局部最优解。

4.1 灰狼优化算法

4.1.1 传统的灰狼优化算法

灰狼优化(Grey Wolf Optimization, GWO)算法是由 Mirjalili 等人受灰狼狩猎行为启发提出的一种智能优化算法。在灰狼狩猎群体中，每只狼均有其特定位置和作用。狼群捕食过程可以分为包围、狩猎和攻击^[47]三个阶段。

在包围猎物阶段，灰狼根据猎物的位置对其在搜索空间内的位置进行实时更新，灰狼个体狩猎行为的数学模型如下：

$$\mathbf{X}_{i+1} = \mathbf{X}_{p,i} - A \cdot |C \cdot \mathbf{X}_{p,i} - \mathbf{X}_i| \quad (4-1)$$

式中， i 为当前迭代次数； $\mathbf{X}_i$ 为当前灰狼位置向量， $\mathbf{X}_{p,i}$ 为当前猎物的位置向量； A 和 C 为系数变量，定义为：

$$A = 2 \cdot a \cdot r_1 - a \quad (4-2)$$

$$C = 2 \cdot r_2 \quad (4-3)$$

$$a = 2 - \frac{2i}{Iter_{\max}} \quad (4-4)$$

其中， r_1 和 r_2 为 [0,1] 范围内取值的两个随机数， $Iter_{\max}$ 为最大迭代次数，收敛因

子 a 随迭代次数 i 的增加线性递减。据此，灰狼能识别猎物的位置并进行包围行为。通过对目标函数的计算，选出适应度值最小个体的最优解、优解和次优解分别作为三个领导者 α ， β 和 δ 位置 $X_{\alpha,i}$ ， $X_{\beta,i}$ 和 $X_{\delta,i}$ 。

在种群的狩猎阶段，由领导者引导种群进行位置更新的模型如下：

$$\begin{cases} X_{1,i} = X_{\alpha,i} - A_1 \cdot |C_1 \cdot X_{\alpha,i} - X_i| \\ X_{2,i} = X_{\beta,i} - A_2 \cdot |C_2 \cdot X_{\beta,i} - X_i| \\ X_{3,i} = X_{\delta,i} - A_3 \cdot |C_3 \cdot X_{\delta,i} - X_i| \end{cases} \quad (4-5)$$

$$X_{i+1} = \frac{X_{1,i} + X_{2,i} + X_{3,i}}{3} \quad (4-6)$$

式(4-5)中向量系数 A_1 ， A_2 ， A_3 和 C_1 ， C_2 ， C_3 为扰动因子，由式(4-2)和(4-3)计算得到。 X_{i+1} 表示灰狼个体在领导者进行引导后的位置。在确定猎物的位置后，狼群会根据猎物的位置估计更新自身的状态。随着狼群慢慢靠近猎物，狩猎的包围圈也会逐渐收缩，导致了GWO算法容易陷入种群局部极小值的停滞。

4.1.2 改进的灰狼优化算法

为避免传统GWO算法陷入局部最优，提高全局搜索能力，引入概率因子 p ，将灰狼优化算法与鲸鱼优化算法中的螺旋位置更新进行融合，提出一种混合灰狼优化算法(Hybrid Grey Wolf Optimization, HGWO)。

在WOA中，座头鲸以螺旋状运动的方式不断靠近猎物的狩猎方式，位置更新的模型通过式(4-7)表示：

$$X_{q+1} = X_{\text{best},i} + e^{bl} \cdot \cos(2\pi l) \cdot |X_{\text{best},q} - X_q| \quad (4-7)$$

式中， q 表示当前迭代次数， X_q 为当前个体的位置， b 对数螺旋形状常数， l 为数值在 $[-1,1]$ 取值随机数。鉴于WOA中座头鲸位置更新的数学模型，当 $p \geq 0.5$ 时，灰狼种群根据当前最优个体领导者 α 的位置，采用引入莱维飞行策略，并结合WOA中的螺旋泡网狩猎行为进行位置更新。数学模型概括为：

$$X_i = X_{\alpha,i} + e^{bl} \cdot \cos(2\pi l) \cdot |X_{\alpha,i} - X_i| \times \overline{Levy} \quad (4-8)$$

由蒙特卡洛方法生成随机向量 $\overline{Levy}$ 计算公式为：

$$\overrightarrow{Levy} = [s_1, s_1, \dots, s_n] \quad (4-9)$$

$$s_i = \frac{u}{|v|^{1/\gamma}} \quad (4-10)$$

其中，参数 γ 取 1.5， u 、 v 服从标准差分别为 $\sigma_u = \left[\frac{\Gamma(1+\gamma) \cdot \sin(\pi\gamma/2)}{\Gamma[(1+\gamma)/2] \cdot \gamma \cdot 2^{(1+\gamma)/2}} \right]$ 和 $\sigma_v = 1$ 的正态分布， $\Gamma(\cdot)$ 表示为伽马函数。

当 $p < 0.5$ 时，灰狼个体按照传统 GWO 算法进行包围狩猎，位置更新采用式 (4-6)。

4.1.3 混合灰狼优化算法实验

为验证混合灰狼优化算法的寻优性能，本节选用表 4-1 所示的四种基准函数 (Sphere、Quartic、Apline、Ackley) 对混合灰狼优化算法，鲸鱼优化算法和灰狼优化算法这三种算法进行对比测试。为使实验结果具有普遍性，实验均独立运行 30 次，每次总迭代次数为 600 次，种群数量均为 30。并将最优解数值、寻优精度的平均值以及标准差作为测试函数的寻优结果评价指标，能够有效反映算法的准确性及稳定性。HGWO 算法的实验参数设置如表 4-2 所示。

表 4-1 算法测试所用的四种基准函数

Table 4-1 The four benchmark functions used to test the algorithm

基准函数名称	搜索范围	函数类型	理论最优值
Sphere	[-100,100]	单峰函数	0
Quartic	[-1,1]	单峰函数	0
Apline	[-5,10]	多峰函数	0
Ackley	[-32,32]	多峰函数	0

表 4-2 HGWO 的参数

Table 4-2 HGWO parameters

参数	含义	取值
N	种群规模	30
$Iter_{\max}$	最大迭代次数	600
b	对数螺旋参数	1
γ	概率系数	1.5

由表 4-3 分析可知，无论是在单峰还是多峰函数的测试下，改进的算法得到适应度值的平均值和标准差均低于原始的 WOA 和 GWO 算法，更接近于理论最优值；表明无论从寻优精度还是算法的鲁棒性角度，HGWO 算法均优于原始算

法。其中在 Ackley 函数测试中，虽然 WOA 和 GWO 算法中最优解的量级达到 10^{-7} 和 10^{-9} ，十分接近理论最优数值 0，但是由于二者是以小概率达到的局部最优且无法在 300 次的迭代范围内跳出，从而导致平均值、标准差的数值不相上下。而对于 HGWO 算法则可以迅速跳出局部最优，并且能够快速寻找到全局最优解，解的量级达到了 10^{-12} ，十分接近理论最优数值 0。在 Sphere 和 Quartic 两种函数实验中，收敛至全局最优解 0，表明改进策略在均衡局部开发和全局搜索中能够达到预期效果。综合结果可知，HGWO 能够有效提升算法克服陷入局部最优的能力，且寻优精度较高。

表 4-3 3 种算法对 4 个测试函数的寻优结果比较

Table4-3 Comparison of optimization results of the three algorithms on four benchmark functions

函数名称	指标	WOA	GWO	FGWO
Sphere	最优解	1.16×10^{-1}	3.17×10^{-3}	0
	平均值	1.3567	6.35×10^{-3}	3.58×10^{-6}
	标准差	9.4×10^{-1}	1.01×10^{-5}	8.73×10^{-7}
Quartic	最优解	5.38×10^{-1}	2.87×10^{-2}	0
	平均值	9.46×10^{-1}	5.13×10^{-2}	5.68×10^{-4}
	标准差	4.15×10^{-2}	3.09×10^{-3}	1.47×10^{-5}
Apline	最优解	8.56×10^{-3}	2.86×10^{-4}	5.17×10^{-5}
	平均值	1.69×10^{-2}	7.53×10^{-4}	6.38×10^{-4}
	标准差	8.42×10^{-3}	2.74×10^{-5}	2.65×10^{-6}
Ackley	最优解	6.65×10^{-7}	9.78×10^{-9}	1.77×10^{-12}
	平均值	9.22×10^{-6}	4.53×10^{-9}	8.31×10^{-12}
	标准差	1.34×10^{-5}	1.42×10^{-10}	6.15×10^{-14}

为更直观感知 HGWO 算法的寻优效果，图 4-1 给出了三种算法在四个测试函数下的收敛曲线图，纵坐标将测试结果取对数。

由收敛曲线分析可知，相比于原始的 WOA 和 GWO 算法，HGWO 算法收敛曲线的斜率更大，曲线更平滑；表明改进后的算法整体的收敛效果明显优于原始算法。由单峰函数 4-1(a)和 4-1(b)收敛曲线可知，HGWO 在迭代前期算法曲线较为陡峭，而 WOA 和 GWO 算法在迭代中后期才能缓慢收敛至最优值，且量级较小；说明改进策略增强了算法搜索性能，且能够有效提高算法精度。由多峰函数曲线图 4-1(c)和 4-1(d)的收敛趋势可以看出，HGWO 算法能够迅速收敛至全局最优值，而 GWO 和 WOA 在迭代后期收敛曲线陷入停滞；表明 HGWO 算法具备跳出局部最优的能力。综上可知，改进策略能够有效提高算法的寻优性能及准确性。




图 4-1 四种算法对 4 个基准函数的寻优收敛曲线比较

Fig.4-1 Comparison of convergence curves of four algorithms for optimization of four benchmark functions

4.2 基于小波包混合优化的欠定盲源分离方法

4.2.1 小波包变换

大部分语音信号不能达到足够的稀疏性，因此，使用组建虚拟多通道的方法实现信号升维。常用的信号提取方式是小波变换，其基本原理为将信号分解为高频和低频两部分，再对低频部分进行分层分解，该方式会使得信息中的高频部分的有用信息丢失。小波包变换针对其缺陷，对信号的高频部分同样逐层进行分解，保留高频部分的有用信息，从而提高信号的准确程度，使得信号可

以更好的恢复出来。通过小波包变换的方法增加对高频信号的处理，对于在小波变换中未分解的高频部分继续分解，得到更多有关混合信号的高频信息，避免有效信息的丢失问题。

小波包变换的分解和重构算法的数学表达^[48]如式(4-11)和(4-12)所示：

$$\begin{cases} d_k^{j+1,2z} = \sum_m h_{m-2k} \cdot d_m^{j,z} \\ d_k^{j+1,2z+1} = \sum_m g_{m-2k} \cdot d_m^{j,z} \end{cases} \quad (4-11)$$

$$d_k^{j,z} = \sum_m h_{k-2m} \cdot d_m^{j+1,2z} + \sum_m g_{k-2m} \cdot d_m^{j+1,2z+1} \quad (4-12)$$

其中， $d_k^{j+1,2z}$ 和 $d_k^{j+1,2z+1}$ 为小波包系数， $d_k^{j,z}$ 表示经过小波包变化后的重构小波包系数， j 为分解尺度， k 与 m 为平移参数， z 为频率参数， h 为低通滤波器系数、 g 为高通滤波器系数。

小波包分解的具体过程如下图4-2所示。从图中可以看出，随着分解层数的增加，信号的整个频带逐渐被不断细分（A 表示低频，D 表示高频，下标表示分解层数）。




图 4-2 小波包算法的三层分解结构图

Fig.4-2 Structural graph of the three-layer wavelet packet decomposition

4.2.2 欠定问题的转化

利用小波包对观测信号 $X(t)$ 的低频和低频部分进行同时刻分解，充分提取频带分量的有用信息。经过小波包变换后，可以获得若干个信号分量 $imf_i(t)$ ，信号分量需要借助有效的评判指标对其进行分选，以有效实现对观测信号的扩维。

在时域范围内，除了能量对数、范数，熵等评判指标外，通常选用互相关系数^[49]以度量两组信号相关程度。信号及其分量间的互相关系数计算式如下：

$$r[X(t), imf_i(t)] = \frac{\left| \frac{M \sum_{t=1}^M imf_i(t)X(t) - \sum_{t=1}^M imf_i(t) \sum_{t=1}^M X(t)}{\sqrt{M \sum_{t=1}^M imf_i^2(t) - \left[\sum_{t=1}^M imf_i(t) \right]^2} \sqrt{M \sum_{t=1}^M X_i^2(t) - \left[\sum_{t=1}^M X_i(t) \right]^2}} \right|}{(4-13)}$$

其中， $X(t)$ 表示算法分解前的原观测信号， $imf_i(t)$ 表示经过小波包变换后所得到的第 i 个信号分量， M 为采样点数。互相关系数的数值越大，表明原观测信号与其分量间的相关性越高，即对应的子频带信号中能够代表原观测信号的成分占比越大；反之，系数值越小，冗余信号分量占比越大。

通过互相关系数对小波包变换所得分量进行分选，剔除了一些互相关系数数值明显较小的冗余分量。保留的信号分量作为有效分量，可以充分描述原观测信号。分量筛选结束后，将分选出的信号分量与第 g 个原观测信号 $X_g(t)$ 组合在一起，以重新组合成 P 维新的观测信号 $X_{g,new}(t)$ ，建立的数学模型表示为：

$$X_{g,new}(t) = [imf_1(t), \dots, imf_{p-1}(t), X_g(t)]^T \stackrel{\text{def}}{=} [f_1(t), \dots, f_p(t)]^T = F(t) \quad (4-14)$$

经过小波包变换和分量分选后，UBSS 问题转换成为 OBSS 问题。

4.2.3 源数估计

在分离观测信号前应该获取源信号的数目，本节采用奇异值估计^[50]的方法对源信号数目进行估计。其基本思想是，先通过样本协方差矩阵的奇异值分解获得特征值，然后通过特征值的分布来确定源数。具体步骤如下：

(1) 计算新观测信号 $F(t) = [f_1(t), \dots, f_p(t)]^T$ 的协方差矩阵：

$$R_{FF} = E\{F(t), F^H(t)\} \quad (4-15)$$

其中 $\cdot^H$ 表示矩阵的共轭转置。

(2) 对 R_{FF} 进行奇异值分解，将所获主特征值降序排列，得到主奇异值特征向量 S_{main} ；消除 S_{main} 中特征值为 0 的零元素，重构出长度为 L 的特征向量。

(3) 根据奇异值分解所得的特征值，结合贝叶斯信息准则^[51]估计出源信号的数目。贝叶斯信息准则模型公式表示为：

$$\begin{cases} BIC(k) = \left(\prod_{j=1}^k \lambda_j \right)^{-\frac{L}{2}} \cdot \sigma_k^{\frac{L(L-k)}{2}} \cdot L^{\frac{d_k+k}{2}} \\ \sigma_k^2 = \frac{\sum_{j=1}^L \lambda_j}{L-k} \\ d_k = Lk - \frac{k(k+1)}{2} \end{cases} \quad (4-16)$$

其中， $1 \leq k \leq L$ ， $j=1, 2, \dots, L$ ，通过寻找比率差的最大值 $(BIC(k))_{MAX}$ 找出对应最大序号值，即为所估计的源信号的数目 m ，作为 BSS 中独立分量的个数。

4.2.4 观测信号正定问题的转化

白化过程将新观察到的信号的维数减小到与源信号相同的维数，OBSS 问题由此转换成正定 BSS 问题。白化的具体步骤如下：

(1) 对公式(4-15)中的方差矩阵 $\mathbf{R}_{FF}$ 进行特征分解

$$\mathbf{R}_{FF} = \mathbf{H} \mathbf{A} \mathbf{H}^T \quad (4-17)$$

其中 $\mathbf{H} = [h_1, h_2, \dots, h_m]$ ， $\mathbf{A} = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_m]$

(2) 计算白化矩阵 $\mathbf{W}'$

$$\mathbf{W}' = \mathbf{A}' \mathbf{H}'^T \quad (4-18)$$

其中，

$$\begin{cases} \mathbf{A}' = \text{diag}[(\lambda_1 - \sigma^2)^{-\frac{1}{2}}, (\lambda_2 - \sigma^2)^{-\frac{1}{2}}, \dots, (\lambda_n - \sigma^2)^{-\frac{1}{2}}] \\ \mathbf{H}' = [h_1, h_2, \dots, h_n] \\ \sigma^2 = \frac{1}{m-n} \sum_{i=n+1}^m \lambda_i \end{cases} \quad (4-19)$$

(3) 白化信号 $\mathbf{z}(t) = [z_1(t), z_2(t), \dots, z_n(t)]^T$ 的获取：

$$\mathbf{z}(t) = \mathbf{W}' \mathbf{x}_{new}(t) \quad (4-20)$$

将白化后的正定矩阵 $\mathbf{z}(t)$ 作为独立成分分析算法的输入信号，通过寻找最优分离矩阵 $\hat{\mathbf{W}}$ ，从而得到源信号的近似估计，即：

$$\hat{s}(t) = \hat{W}z(t) \quad (4-21)$$

负熵的精准计算较复杂，因此选用多项式函数逼近的方式对其进行估计：

$$J(\hat{W}) \stackrel{\text{def}}{=} [E\{G(\hat{W}z)\} - E\{G(v_{Gauss})\}]^2 \quad (4-22)$$

式中， $E(\cdot)$ 表示均值运算， $G(\cdot)$ 表示非线性函数，选取 $G(y) = \log_2 \cosh(y)$ ， v_{Gauss} 表示高斯信号。

基于负熵的 ICA 算法寻优的目标函数记为：

$$Fit_i = \frac{1}{J(\hat{W}) + \varepsilon} \quad (4-23)$$

其中， ε 为随机取得的一个很小的实数，防止分母为 0 的情况。通过寻找目标函数 Fit_i 的最小值，找到最优分离矩阵，从而实现源信号的恢复。

4.2.5 算法步骤

基于小波包混合优化的 UBSS 方法的步骤如下。

步骤 1：输入观测信号，进行小波包变换；

步骤 2：将小波包分解得到的信号分量与原观测信号计算互相关系数，并进行分量分选，将筛选出的信号分量与原观测信号重新组合成新的观测信号；

步骤 3：利用奇异值分解方法寻找 BIC 最大值，估计源信号的数目；

步骤 4：对新的观测信号进行白化操作，使观测信号维数等于源信号数；

步骤 5：读取重构的正定白化信号；

步骤 6：初始化灰狼种群位置及 HGWO 算法各参数；

步骤 7：根据式(4-23)计算适应度，目标函数值最小的三个值，记为 $\bar{X}_{\alpha,i}$ ， $\bar{X}_{\beta,i}$ 和 $\bar{X}_{\delta,i}$ ，并进入种群位置更新阶段；

步骤 8：随机生成概率因子 p 。当 $p \geq 0.5$ 时，采用式(4-8)进行位置更新；当 $p < 0.5$ 时，位置更新采用式(4-6)；

步骤 9：再次计算种群个体的适应度值，并与原个体位置最优值进行对比。保存并记录适应度值较小的个体位置；

步骤 10：更新迭代次数，判断是否达到最大迭代次数。如果满足，进入下

一步，否则返回步骤 7；

步骤 11：输出 HGWO 全局最优解，将其作为分离矩阵 $\hat{W}$ ，并通过式(4-21)恢复出源信号。




图 4-3 基于小波包混合优化的 UBSS 方法流程图

Fig.4-3 Flowchart of UBSS method based on wavelet packet hybrid optimization

4.2.6 小波包分选及分离性能测试实验

选取图 4-4(a)所示的三路语音信号作为仿真源信号，经过一个 2×3 维混合矩阵 A ，得到图 4-4(b)所示的观测信号，其中混合矩阵 A 为：

$$A = \begin{bmatrix} 0.9030 & 0.6117 & 0.3955 \\ 0.0162 & 0.2368 & 0.6736 \end{bmatrix}$$




图 4-4 语音源信号和观测信号波形图

Fig.4-4 Waveform diagrams of speech source signal and observation signal

为比较不同小波包分解层数下的分选效果以及不同分选标准下的分选性能，采用信干比^[52]作为评价指标验证算法的有效性，并判别小波包算法分选性能。

$$SNR = 10 \lg \frac{\|X(t)\|}{\|X(t) - \overline{imf}(t)\|} \quad (4-24)$$

其中， $X(t)$ 表示原观测信号， $\overline{imf}(t)$ 为根据分选标准选出的最佳信号分量的均值。

由公式(4-24)可知，信干比越高，分选性能越好。




图 4-5 四种分选指标下信号的信干比折线图

Fig.4-5 Line chart of signal's SNR under four kinds of sorting index

图 4-5 反映在不同小波包分解层数下，能量对数、范数，熵和互相关系数四种分选指标^[53]下信号的信干比折线图。通过计算小波包不同分解层数的输出信号的信干比，可以更直观的描述算法的性能。由图分析可知，在分解层数为 3 时信干比达到最大，且随着分解层数的不断增加，输出信噪比的值在下降。由数据显示，三层小波包的分选性能最佳，且相比于其他分选指标，互相关系数指标下能够达到很好的效果。

经过小波包分解后可以同时得到信号的高频率分量和低频率分量。采样频率设置为 6kHz，根据小波包分解原理，经过三层小波包分解后，每个子频宽带为 750Hz (6000/8)。由此可知，基于语音信号实现最佳效果的分选指标下，设置不同的频带宽度对小波包分解层数的选取，最佳分选层数会随之改变。将两路观测信号进行三层小波包分解，得到八个频段范围内的小波包节点。

表 4-4 各子频带信号与原观测信号的互相关系数

Table4-4 The number of interrelations between each sub-band signal and the observed signal

子频带编号	频率范围/Hz	互相关系数	
		观测信号 1	观测信号 2
$imf_{3,0}$	0~750	0.7074	0.8123
$imf_{3,1}$	750~1500	0.7852	0.6545
$imf_{3,2}$	1500~2250	0.5348	0.7319
$imf_{3,3}$	2250~3000	0.7721	0.5386
$imf_{3,4}$	3000~3750	0.6382	0.5256
$imf_{3,5}$	3750~4500	0.3243	0.0013
$imf_{3,6}$	4500~5250	0.0571	0.2245
$imf_{3,7}$	5250~6000	0.1682	0.0534

由表 4-4 可知，经过三层小波包分解得到的八个子频带随着频带范围的增加，与原观测信号的相关程度呈现出变低的趋势。观测信号 1 和 2 的 $imf_{3,5}$ 、 $imf_{3,6}$ 和 $imf_{3,7}$ 与原信号的相关性很小，筛选后剔除。其余分量的互相关系数值较

高，能够较好地反映原观测值的绝大部分信息。将筛选后的信号分量作为补充观测信号分量，与原观测信号重新组合，构成新的观测信号，UBSS问题得到转化。

图 4-6 给出结合贝叶斯信息准则的奇异值估计方法的源信号数量估计。在测试中，将文献[54]中提出的 Top-SVD 和 SVD 算法作为对比方法，与使用的结合贝叶斯信息准则的奇异值估计方法(BIC-SVD)进行比较。图 4-7 给出估计信号源个数成功率的仿真结果。




图 4-6 信号的 BIC 数值

Fig.4-6 BIC value of the signal




图 4-7 不同算法的检测成功率

Fig.4-7 Success rate of different algorithms

通过结合贝叶斯信息准则的奇异值估计方法得到 k 个 BIC 值，如图 4-6 所示。由图分析可知， k 为 3 时 BIC 值达到最大，表明估计的独立分量数目为 3，符合预设的三路原始语音信号的实际情况，即该方法可以正确估计出源信号的数目。由图 4-7 所示算法比率值的比较可知，改进的算法有效性更高，可以快速且准确地估计出源数。

重构后的三路信号的波形如下图 4-8 所示，使用融合 HGWO 算法的 ICA 方法对重构信号进行分离，分离信号的波形如图 4-9 所示。




图 4-8 三路重构信号

Fig.4-8 Three-way of reconstruction signal




图 4-9 三路分离信号

Fig.4-9 Three-way of separation signal

通过对仿真结果的比较可知，重构后的信号不仅在数目上与源信号维数一致，还能更为充分地反映原信号的特征信息；且经过改进算法得到的分离信号更加完整平滑，能够较好地实现原始信号的提取；源信号波形恢复效果较为理想。

为进一步分析基于小波包混合优化算法对处理 BSS 问题的效果，使用观测信号及分离信号与源信号的相关系数^[55]对分离效果进行评估，结果如表 4-5 所示。使用的相关系数指标计算公式如下：

$$R = \frac{\left| \sum_{k=0}^{N-1} [X(k) - \bar{X}(k)][Y(k) - \bar{Y}(k)] \right|}{\sqrt{\sum_{k=0}^{N-1} [X(k) - \bar{X}(k)]^2 \sum_{k=0}^{N-1} [Y(k) - \bar{Y}(k)]^2}} \quad (4-25)$$

其中，样本点的总数为 N ， $X(k)$ 和 $Y(k)$ 表示为所衡量两信号，且：

$$\begin{cases} \overline{X(k)} = \frac{1}{N} \sum_{k=0}^{N-1} X(k) \\ \overline{Y(k)} = \frac{1}{N} \sum_{k=0}^{N-1} Y(k) \end{cases} \quad (4-26)$$

相关系数数值介于 0 和 1 之间，且 R 越接近 1，信号越相似。

表 4-5 源信号与观测及分离信号之间的相关系数

Table 4-5 Correlation coefficients between source, observed and separated signals

源信号	观测信号 1	观测信号 2	分离信号
源信号 1	0.3170	0.6130	0.9127
源信号 2	0.5658	0.5612	0.8431
源信号 3	0.2925	0.2766	0.9075

由表 4-5 中各路信号的相关系数值分析可知，经过改进后算法得到的分离信号和源信号的相关系数值相比于观测信号，也有明显的提高。实验表明，通过改进的算法能够有效分离出原始信号且分离效果较好。

4.2.7 混合矩阵估计和源信号分离性能对比实验

为进一步验证小波包混合优化方法的有效性，选取小波包结合独立成分分析(WP-ICA)、小波包结合灰狼优化算法的独立成分分析(WP-GWO-ICA)和小波包混合优化(WP-HGWO-ICA)三种算法对混合矩阵进行估计。使用的标准化均方误差(Normalized Mean Square Error, NMSE)^[56]以及角度偏差(Angular Deviation, ANG)^[57]两种指标的定义如下：

$$NMSE(\mathbf{A}, \mathbf{A}_x) = 10 \lg \left[\frac{\sum_{i=1}^M \sum_{j=1}^N (a_{x,ij} - a_{ij})^2}{\sum_{i=1}^M \sum_{j=1}^N a_{ij}^2} \right] \quad (4-27)$$

$$ANG(\mathbf{A}, \mathbf{A}_x) = \frac{180}{\pi} \arccos \left(\frac{\langle \mathbf{A}, \mathbf{A}_x \rangle}{\|\mathbf{A}\| \|\mathbf{A}_x\|} \right) \quad (4-28)$$

式中， $\mathbf{A}_x$ 表示算法的估计混合矩阵， $\mathbf{A}$ 为原始矩阵， M 和 N 分别表示矩阵的行数与列数， $a_{x,ij}$ 和 a_{ij} 为相应算法估计的混合矩阵和混合矩阵的第 i 行第 j 列上的元素。仿真运行出的标准化均方误差和角度偏差值越小，表明算法的稳定性越高。

由混合矩阵的估计得到三种算法的估计混合矩阵分别为：

$$A_{WP-ICA} = \begin{bmatrix} 0.9124 & 0.6201 & 0.3862 \\ 0.0271 & 0.2299 & 0.6722 \end{bmatrix}$$

$$A_{WP-GWO-ICA} = \begin{bmatrix} 0.9041 & 0.6109 & 0.3974 \\ 0.0254 & 0.2303 & 0.6854 \end{bmatrix}$$

$$A_{WP-HGWO-ICA} = \begin{bmatrix} 0.9028 & 0.6105 & 0.3922 \\ 0.0213 & 0.2417 & 0.6731 \end{bmatrix}$$

表 4-6 算法的评价指标对比

Table 4-6 Comparison of evaluation metrics for algorithms

算法	角度偏差/ $^{\circ}$			NMSE
	$ANG(A, A_1)$	$ANG(A, A_2)$	$ANG(A, A_2)$	
WP-ICA	0.6735	0.8202	0.5403	-36.5182
WP-GWO-ICA	0.5815	0.5066	0.3136	-38.3468
WP-HGWO-ICA	0.3238	0.4365	0.1907	-44.7174

通过表 4-6 的评价指标对比表明，小波包混合优化算法所得出的矩阵更接近混合矩阵。另外，通过数值比较可知，WP-HGWO-ICA 算法所得的指标数值均小于其它两种算法，说明估计混合矩阵的精度优于其它两种算法。综合可知，小波包混合优化算法稳定性更强，有效性更高。

选取 4.2.6 中的三路语音信号，通过基于小波包算法的 BSS 方法对信号重构，使用 WP-ICA、WP-GWO-ICA 和 WP-HGWO-ICA 三种算法得到分离信号，时域波形如图 4-10 所示。




图 4-10 三种算法下分离信号波形图

Fig.4-10 The three algorithms separate the signal waveforms

通过对分离信号的时域波形图分析可知，与 WP-ICA 和 WP-GWO-ICA 算法相比，改进后的算法的分离效果明显优于其它两种算法。WP-HGWO-ICA 算法能够捕获大部分的有用信息，分离出的信号与原始信号基本吻合。综合可知，

采用小波包混合优化算法的 BSS 方法可以较为准确地分离出原始信号，且能够达到较好的效果。

为进一步比较三种算法对处理 BSS 问题的效果，使用相似系数^[58]将三种算法的分离性能进行测试，以衡量源信号与分离信号之间的相似程度。相似系数指标定义如下：

$$\rho_i = \frac{\left| \sum_{k=0}^{N-1} y_i(k) s_i(k) \right|}{\sqrt{\sum_{k=0}^{N-1} y_i^2(k) \sum_{k=0}^{N-1} s_i^2(k)}}, \quad i = 1, \dots, n \quad (4-29)$$

式中， $y_i(k)$ 表示分离信号， $s_i(k)$ 表示为源信号。其值越接近 1，表明源信号与分离信号越相似，分离精度越高。实验独立运行 50 次，表 4-7 给出 3 种算法相似系数结果。

表 4-7 3 种算法的相似系数数值比较

算法	相似系数	分离信号 1	分离信号 2	分离信号 3
WP-ICA	$i = 1$	0.6109	0.7041	0.7577
	$i = 2$	0.8565	0.8753	0.5931
	$i = 3$	0.6929	0.607	0.6090
WP-GWO-ICA	$i = 1$	0.8447	0.7472	0.7451
	$i = 2$	0.9004	0.8289	0.5308
	$i = 3$	0.8980	0.7557	0.5467
WP-HGWO-ICA	$i = 1$	0.9483	0.9764	0.9591
	$i = 2$	0.9661	0.9275	0.9908
	$i = 3$	0.9352	0.9185	0.9872

通过对表 4-7 结果的分析，小波变换下，结合灰狼优化算法的 BSS 方法分离出的三路信号与源信号的相似系数数值均有所增加，分离效果得到了一定的改善。HGWO 与 ICA 算法结合后，分离信号的相似系数值更接近于 1，表明改进后的算法提取效果明显优于其他两种方法。综合分析可知，改进的算法提高了分离精度，且能更好地实现信号的分离。

4.2.8 故障信号测试实验

为进一步测试小波包混合优化算法的实用性，选取轴承试验台使用双列圆锥滚子轴承采集到的复合故障信号作为分析对象，采用 20kHz 频率对信号进行采样。其中，实验使用的轴承转速为 1500r/min。该信号的时域和频域谱如图 4-

11 和图 4-12 所示。由观测信号的频域波形可知，两路源信号互相干扰混合在一起，一般方法难以有效提取出源信号的特征信息。

分别采用小波算法和改进算法对信号进行分解及分量筛选，并使用混合优化算法的 ICA 方法对重组信号进行盲分离以验证所提算法的可行性。分离得到的两路源信号频谱图如 4-13(a)和 4-13(b)所示。




图 4-11 故障信号时域波形图

Fig.4-11 Time domain waveform of fault signal





图 4-12 故障信号频域波形图

Fig.4-12 Frequency domain waveform of fault signal



(a) 小波算法恢复两路源信号频谱图

(b) 改进算法恢复两路源信号频谱图

(a) Recovered signals by wavelet algorithm

(b) Recovered signals by improved algorithm

图 4-13 小波算法与改进方法的分离结果

Fig.4-13 Separation results of wavelet algorithm and improved methods

由图 4-13(a)的频谱分析可知, 所得的两路分离信号频谱图中无法反映出原始信号的故障特征, 因此小波算法下的信号分离方法性能不佳; 而改进的方法采用小波包混合优化算法可以对原始信号的高低频域进行细分, 提取出源信息的主要特征。算法的有效性反映在频谱图 4-13(b)中: 经小波包混合优化算法得到的两路信号频谱中可以迅速找到故障频率。在图 4-13(b)中的第一路恢复信号中, 基频 256.4Hz 及故障频率 1275.8Hz 比较突出, 在 1532.2Hz 处也可以看到一个小的峰值, 对应于故障频率的一倍基频; 在图 4-13(b)中的第二路恢复信号中, 基频、故障频率以及故障频率的倍频可以从频谱图中清晰地反映出。综合可知, 提出的小波包融合优化算法对于混合故障信号有着很好的分离效果, 可以较为准确的提取故障特征成分。

4.3 本章小结

针对 BSS 中的欠定问题, 在现有的研究基础上, 本章提出一种小波包变换与混合优化的 ICA 相结合的方法。该方法通过小波包变换, 将观测信号的高低频进行分解, 剔除相关系数较小的冗余分量后, 与原观测信号重新组合为新的多路观测信号。再使用基于奇异值分解寻找贝叶斯信息准则最大值的方法来估计源信号数目, 利用白化过程降低新观测信号的维度, 使处理后的新观测信号维数与预估的源信号在数目上保持一致。最后将改进的 HGWO 算法与 ICA 算法结合, 用以重构信号的分离。仿真实验结果表明, 在三层小波包分解下使用互相关系数指标对信号分量的分选效果较好。本章提出的基于小波包混合优化算法的 UBSS 方法能够有效解决欠定问题, 重构后的信号更接近源信号, 能够与其在整体特征上基本保持一致; 改进的 HGWO 算法能有效避免群体陷入局部最优, 比于原始算法寻优速度更快, 精度更高; 且改进后的优化算法相比于原始算法, 分离性能更佳, 收敛速度以及精度均有提升, 能够更好识别实测信号的故障特征。

第5章 总结与展望

5.1 总结

本文简要介绍了有关 BSS 的相关理论知识及相应算法；对于传统优化算法在迭代求解过程中存在易受到初值、固定步长等影响收敛精度和速度的问题进行优化求解；并针对传统智能优化算法在解决 BSS 问题中存在的不足进行改进；将改进的智能优化算法与 ICA 算法结合使用，用以解决正、欠定 BSS 问题。

本文的主要研究工作如下：

为解决传统智能优化算法在处理 BSS 问题时存在的诸多缺点，提出一种基于 I-WOA 的 BSS 方法。该方法根据中心极限定理，基于互信息构造目标函数，在算法迭代更新位置前引入混沌反向学习策略，提高种群丰富度；在迭代后期引入莱维飞行策略，避免算法陷入局部最优。利用改进优化算法得出的全局最优解作为 ICA 步长，迭代更新分离矩阵，减小传统 ICA 稳态误差，改善算法的收敛速度，进而达到较好的分离效果。并且通过四个基准函数进行算法性能测试，检验出改进策略的有效性和可行性。在使用算法对语言信号进行分离处理实验可分析得出，改进后的智能算法在 BSS 中的应用效果较好，可有效还原出源信号。

鉴于传统时间频域分析的算法在解决 UBSS 问题时，所表现出对稀疏度有较高要求，而导致使用范围受限的局限性缺陷，提出了一种基于小波包混合优化的 UBSS 方法。首先利用小波包算法分解观测信号，并依据互相关系数对信号分量进行分选，采用重组的方法将 UBSS 转化成超定问题。其次结合贝叶斯信息准则，利用奇异值分解的方法估计源信号数目，通过白化过程进行降维处理，使得重构信号与源信号数目保持一致，超定 BSS 问题进而转化为正定问题。最后，针对基本 GWO 算法易陷入局部最优的缺点，引入螺旋泡网狩猎行为及莱维飞行策略对灰狼优化算法进行改进；并将改进的 HGWO 算法与 ICA 算法结合，用于分离重构的正定白化信号，从而得到源信号的近似估计。实验结果表明，在三层小波包分解下使用互相关系数指标对信号分量的分选效果较好。

本文采用的方法在处理 UBSS 问题时，有效性更高，分离性能更佳，且改进的 HGWO 算法相比于原始优化算法，收敛精度和稳定性有了一定程度的提高。

5.2 展望

目前有关智能优化算法及其改进算法在 BSS 中的应用还处在逐步探索阶段，仍存在广泛的发展前景，未来研究工作可以围绕以下内容进行展开：

处理盲分离问题在多数情况下依旧在理想环境中进行，对于有噪声干扰的情形，本文的算法效果会受到一定的制约。如在分离结束后，源信号与噪声信号排列顺序不定，导致无法确定源信号个数。另外，噪声的存在会增加运算复杂度，造成运算时间增加。且在噪声干扰下，对源信号的识别率会有所下降，进而导致信号的恢复质量降低。因此，增加信号判别算法，区分噪声信号与有用信号等相关去噪声算法在 BSS 中的应用值得继续研究。

有关分离信号序列模糊问题，存在着幅值、次序的不确定性。尤其对于欠定情况下的盲分离问题，检测算法恢复源信号性能受限。后期算法针对源信号与分离信号增加排序环节方面可以加以进一步的研讨。

在仿真实验中，本文选取语音信号以及故障信号等进行分离处理，验证改进智能优化算法的有效性。在其后研究中，可以增加生物医疗、通信雷达等一系列复杂场景中对各类语音、图像信号的处理，应用于解决更高维度、更加复杂的实际场所。

参考文献

- [1] Ehsandoust B, Babaie-Zadeh M, Rivet B, et al. Blind source separation in nonlinear mixtures: separability and a basic algorithm[J]. IEEE Transactions on Signal Processing, 2017, 65(16): 4339-4352.
- [2] Tong L, Liu R, Soon V. Indeterminacy and identifiability of blind identification[J]. IEEE Transactions on Circuits and Systems, 1991, 38(5): 499-509.
- [3] Brendel A, Haubner T, Kellermann W. A unifying view on blind source separation of convolutive mixtures based on independent component analysis[J]. IEEE Transactions on Signal Processing, 2023, 71: 816-830.
- [4] Bell A J, Sejnowski T J. An information-maximization approach to blind separation and blind deconvolution[J]. Neural Computation, 1995, 7(6): 1129-1159.
- [5] Ji J Q, Kong X J, Zhang Y J, et al. A new adaptive variable step size natural gradient BSS algorithm[J]. Journal of Intelligent & Fuzzy Systems, 2021, 41(1): 57-68.
- [6] Fu W, Bai X, Shi X, et al. Mixing matrix estimation algorithm for underdetermined blind source separation[J]. IEEE Access, 2021, 9: 136284-136291.
- [7] Bofill P, Zibulevsky M. Underdetermined blind source separation using sparse representations[J]. Signal processing, 2001, 81(11): 2353-2362.
- [8] Huang S S, Li Z N, Wang C J. Core consistency blind source separation based on compressive sensing trilinear decomposition[J]. Measurement Science and Technology, 2024, 35(5): 56116-56125.
- [9] Yin W, He K J, Xu D, et al. Adaptive low light visual enhancement and high-significant target detection for infrared and visible image fusion[J]. The Visual Computer, 2023, 39(12): 6723-6742.
- [10] 凌燮亭. 近场宽带信号源的盲分离[J]. 电子学报, 1996, 24(7): 87-92.
- [11] 刘琚, 梅良模, 何振亚. 一种盲信号分离的信息理论方法[J]. 山东大学学报(自然科学版), 1998, 33(4): 40-45.
- [12] 刘琚, 梅良模, 王太君, 等. 一种基于非平稳特性的前馈神经网络盲源分离方法

- [J]. 山东大学学报(自然科学版), 1999, 34(3): 298-303.
- [13]张洪渊, 史习智. 一种任意信号源盲分离的高效算法[J]. 电子学报, 2001, 29(10): 1392-1396.
- [14]杨俊安. 基于量子遗传算法的盲源分离算法研究[D]. 中国科学技术大学, 2003.
- [15]付卫红, 杨小牛. 改进的基于步长自适应的自然梯度盲源分离算法[J]. 华中科技大学学报(自然科学版), 2007, 35(10): 18-20.
- [16]张银雪, 田学民. 基于改进 PSO-ICA 的地震信号去噪方法[J]. 石油地球物理勘探, 2012, 47(1): 56-62.
- [17]张天骐, 马宝泽, 强幸子, 等. 基于 GA-AW-PSO 的动态盲源分离轴承故障检测研究[J]. 系统仿真学报, 2018, 30(6): 2306-2314.
- [18]褚鼎立, 陈红, 宣章健. 基于改进鲸鱼优化算法的盲源分离方法[J]. 探测与控制学报, 2018, 40(5): 76-81.
- [19]李宏坤, 张学峰, 徐福健, 等. 基于时频分析的欠定信号盲分离与微弱特征提取[J]. 机械工程学报, 2014, 50(18): 14-22.
- [20]李志农, 张芬, 何旭平. 基于小波-KCCA 的非线性欠定盲分离方法研究[J]. 仪器仪表学报, 2014, 35(3): 601-606.
- [21]Sohail A. Genetic algorithms in the fields of artificial intelligence and data sciences[J]. Annals of Data Science, 2023, 10(4): 1007-1018.
- [22]Chandrashekar C, Krishnadoss P, Kedalu P V, et al. HWACOA scheduler: hybrid weighted ant colony optimization algorithm for task scheduling in cloud computing[J]. Applied Sciences, 2023, 13(6): 3433-3456.
- [23]Gad A G. Particle swarm optimization algorithm and its applications: a systematic review[J]. Archives of computational methods in engineering, 2022, 29(5): 2531-2561.
- [24]Kao Y T, Zahara E. A hybrid genetic algorithm and particle swarm optimization for multimodal functions [J]. Applied soft computing, 2008, 8(2): 849-857.
- [25]Chen Q D, Sun J, Palade V, et al. An improved Gaussian distribution based quantum-behaved particle swarm optimization algorithm for engineering shape design problems[J]. Engineering Optimization, 2022, 54(5):743-769.
- [26]Hardy L. Quantum mechanics, local realistic theories, and Lorentz-invariant

- realistic theories[J]. *Physical Review Letters*, 1992, 68(20): 2981-2984.
- [27]Chen Y, Xi J, Wang H, et al. Grey wolf optimization algorithm based on dynamically adjusting inertial weight and levy flight strategy[J]. *Evolutionary Intelligence*, 2023, 16(3): 917-927.
- [28]Rajmohan S, Elakkiya E, Sreeja S R. Multi-cohort whale optimization with search space tightening for engineering optimization problems[J]. *Neural Computing and Applications*, 2023, 35(12): 8967-8986.
- [29]Yang J, Li B, Zhuang Z Q. Multi-universe parallel quantum genetic algorithm its application to blind source separation[C]//*International Conference on Neural Networks & Signal Processing*. Nanjing, China: IEEE Press, 2003: 393-398.
- [30]苏彬, 苏皓然, 刘肖. 基于粒子群算法的欠定盲源分离方法改进[J]. *科学技术与工程*, 2018, 18(15): 123-128.
- [31]Tripathi N, Singh R, Pandey U. Effective independent component analysis algorithm (EICA) for blind source separation of mixed images for biomedical applications[M]//*Proceedings of Trends in Electronics and Health Informatics: TEHI 2021*. Singapore: Springer Nature Singapore, 2022, 311-327.
- [32]Gopi E S, Palanisamy P. Maximizing Gaussianity using kurtosis measurement in the kernel space for kernel linear discriminant analysis[J]. *Neurocomputing*, 2014, 144(20): 329-337.
- [33]李巧燕. 基于改进 PSO 的重力固体潮信号独立成分分析及潮汐谐波提取[D]. 昆明理工大学, 2016.
- [34]Tang M, Ren C, Xin Y. Efficient resource allocation algorithm for underwater wireless sensor networks based on improved stochastic gradient descent method[J]. *Adhoc and Sensor Wireless Networks*, 2021, 49(16): 207-222.
- [35]Guastadisegni L, Cagnone S, Moustaki I, et al. Use of the Lagrange multiplier test for assessing measurement invariance under model misspecification[J]. *Educational and Psychological Measurement*, 2021, 82(2): 254-280.
- [36]Ourdou A, Ghazdali A, Laghrib A, et al. Blind separation of instantaneous mixtures of independent/dependent sources[J]. *Circuits, Systems, and Signal Processing*, 2021, 40(9): 4428-4451.

- [37]Lu J T, Cheng W, He D, et al. A novel underdetermined blind source separation method with noise and unknown source number[J]. Journal of Sound and Vibration, 2019, 457(29): 67-91.
- [38]迟捷, 邹华, 林荣恒. 融合小波分解的 Lasso 光伏净负荷预测方法[J]. 电力信息与通信技术, 2023, 21(5): 9-16.
- [39]Joshi S K. Chaos embedded opposition based learning for gravitational search algorithm[J]. Applied Intelligence, 2023, 53(5): 5567-5586.
- [40]薛田良, 王一诺, 曾阳阳. 一种改进的差分进化算法与电解电容器参数辨识[J]. 电子测量技术, 2021,44(22): 56-61.
- [41]张霓, 曾乐襄, 何熊熊, 等. 基于滚动时域粒子群优化的视频去雾算法[J]. 控制与决策, 2021, 36(9): 2218-2224.
- [42]孙远, 杨峰, 郑晶, 等. 基于膜计算与粒子群算法的盲源分离方法[J]. 振动与冲击, 2018, 37(17): 63-71.
- [43]张贤达, 保铮. 盲信号分离[J]. 电子学报, 2001, 29(21): 1766-1770.
- [44]Liu S, Wang B M, Zhang L Y. Blind source separation method based on neural with bias term and maximum likelihood estimation criterion[J]. Sensors, 2021, 21(3): 973-999.
- [45]何鹏举, 刘刚易, 折廷廷. 单通道 AE 信号盲分离的飞机构件监测方法研究[J]. 仪器仪表学报, 2018, 39(8): 34-42.
- [46]吴佳佳, 行鸿彦, 孙江. 一种雨声信号的盲源分离处理方法[J]. 电子测量与仪器学报, 2019, 33(9):144-153.
- [47]Ahmadi B, Younesi S, Ceylan O, et al. An advanced grey wolf optimization algorithm and its application to planning problem in smart grids[J]. Soft Computing, 2022, 26(8): 3789-3808.
- [48]Nanmaran R, Thirugnanam G and Mangaiyarkarasi P. Wavelet packet transform-based medical image multiple watermarking with independent component analysis extraction[J]. International Journal of Medical Engineering and Informatics, 2020, 12(4): 322-335.
- [49]Li H, Lin W, Zhao D. A single-channel BSS method based on ICEEMDAN and FastICA and its application in EMI analysis[C]. IEEE International Conference on

- Computer Science & Education (ICCSE). 2019: 780-784.
- [50] Yi C, Lv Y, Xiao H, et al. Research on the blind source separation method based on regenerated phase-shifted sinusoid-assisted EMD and its application in diagnosing rolling-bearing faults[J]. Applied sciences, 2017, 7(4): 414-432.
- [51] Huang L, Xiao Y, Liu K, et al. Bayesian information criterion for source enumeration in large-scale adaptive antenna array[J]. IEEE transactions on vehicular technology, 2015, 65(5): 3018-3032.
- [52] 宋立业, 周乐, 刘昕明. 基于邻域相关性多阈值新函数寻优法的小波降噪分析[J]. 信息与控制, 2019, 48(1): 57-64.
- [53] 杨晓飞, 李志农, 何况. 基于小波包—VBICA 的欠定盲源分离方法研究[J]. 设备管理与维修, 2019, 17(9): 154-155.
- [54] Sun H, Guo J, L, Fang L. Improved singular value decomposition (TopSVD) for source number estimation of low SNR in blind source separation[C]. IEEE Access, 2017: 26460-26465.
- [55] 曹伟, 孙红梅, 贾瑞生, 等. 基于小波包分解重构的微地震信号降噪方法[J]. 电子测量与仪器学报, 2018, 32(4): 134-143.
- [56] Li Y, Nie W, Ye F, et al. A mixing matrix estimation algorithm for underdetermined blind source separation[J]. Circuits, Systems, and Signal Processing, 2016, 35(4): 3367-3379.
- [57] Ma B, Zhang T. Underdetermined blind source separation based on source number estimation and improved sparse component analysis[J]. Circuits, Systems, and Signal Processing, 2021, 40(2): 3417-3436.
- [58] He P J, Liu G Y, She T T. Research on monitoring of aircraft structural components based on blind separation of single channel AE signal[J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 34-42.

攻读学位期间发表的学术论文目录

- [1] 吴宸之, 李炜, 房琪, 等. 基于小波包混合优化的欠定盲源分离方法[J]. 电子测量与仪器学报, 2023, 37(09):213-224.
- [2] Wu Chenzhi, Li Wei and Qi Yu, et al. Blind Source Separation Method Based on the Improved Whale Optimization Algorithm, 2023 42nd Chinese Control Conference (CCC), Tianjin, China, 2023, pp. 3127-3132.

致谢

行文至此，毕业在即。我将与为期二十年的学生时代告别，回顾求学这些年，虽不及古人寒窗之苦读，却也略感曲折坎坷。

感谢国家。读研三年，经历疫情高潮到放开，在这场没有硝烟的战争中，伟大的祖国竭尽所能为我们提供一个相对稳定的学习和生活环境。

感谢导师。随着课题研究的深入，我深感李炜老师是一名治学严谨、循循善诱、德才兼备的人民教师。在老师全方位的教导下，我受益良多。

感谢师姐师兄。是他们抽取宝贵的休息时间，予我以莫大的帮助和鼓励，给我以家人般的温暖。他们宝贵经验让我少走很多弯路，似灯塔般指引我方向，让我深切体会到做学术是一件非常快乐的事情。

感谢室友、同学、学弟学妹及朋友们。有你们相伴成长是我的幸运。

感谢爸爸妈妈。关注我的每个成长阶段，尊重我的选择和决定，是他们给我无限的底气，让我可以更勇敢地向前奔跑。

感谢那个在看不见前路为何时，守得住本心，心向美好；在跌倒摔伤后，擦干血与汗，继续前行，不服输的自己。

在研究生生活期间，我历经很多绚丽的事情，带给我全新的体验；教会我很多，收获了很多，让我能够更加沉稳自信地面对未知的将来。

凡是过往，皆为序章。前路漫漫，万事可期。

尚德敏学 唯实惟新

