



同濟大學

TONGJI UNIVERSITY

硕士学位论文

## 基于 SCE 算法的结构系统识别

(国家自然科学基金项目资助 编号: 50708076)

姓 名: 李鹏飞

学 号: 0720020340

所在院系: 土木工程学院

学科门类: 土木工程

学科专业: 风工程

指导教师: 薛松涛 教授

副指导教师: 唐和生 副研究员

二〇一〇年五月



同濟大學  
TONGJI UNIVERSITY

A thesis submitted to  
Tongji University in conformity with the requirements for  
the degree of Master of Science

## **Structural System Identification Based on SCE Algorithm**

(Supported by the National Natural Science Foundation of China  
under Grant No.50708076)

Candidate : Pengfei Li

Student Number : 0720020340

School/Department : School of Civil Engineering

Discipline : Civil Engineering

Major : Wind Engineering

Supervisor : Prof. Song-Tao Xue

Associate Prof. He-Sheng Tang

May, 2010

基于SCE算法的系统识别研究

李鹏飞

同济大学

5cm 左右

5cm 左右

# 学位论文版权使用授权书

本人完全了解同济大学关于收集、保存、使用学位论文的规定，同意如下各项内容：按照学校要求提交学位论文的印刷本和电子版；学校有权保留学位论文的印刷本和电子版，并采用影印、缩印、扫描、数字化或其它手段保存论文；学校有权提供目录检索以及提供本学位论文全文或者部分的阅览服务；学校有权按有关规定向国家有关部门或者机构送交论文的复印件和电子版；在不以赢利为目的的前提下，学校可以适当复制论文的部分或全部内容用于学术活动。

学位论文作者签名：

年 月 日

---

## 同济大学学位论文原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师指导下，进行研究工作所取得的成果。除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人创作的、已公开发表或者没有公开发表的作品的内容。对本论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。本学位论文原创性声明的法律责任由本人承担。

学位论文作者签名：

年 月 日



## 摘要

结构参数识别在土木工程中的应用,特别是在健康监测领域中发挥着重要的作用,许多智能算法被研究并应用于结构参数识别中。

本文将参数识别问题转化为优化问题,从而提出了基于 SCE 算法 (Shuffled Complex Evolution) 的结构参数识别方法。研究工作主要包括以下内容:

1) 简要回顾了系统识别领域的研究现状,针对以往识别方法在处理识别问题时的诸多限制,提出了基于 SCE 算法的结构参数识别方法。通过对七种工况的数值分析,结果表明该方法在质量已知和质量未知、测量信息不完备、输入输出噪声干扰等情况下,均具有识别速度快、识别精度高、使用方便等特点。同时将 SCE 算法与 PSO 算法 (Particle Swarm Optimization)、CLPSO 算法 (Comprehensive Learning Particle Swarm Optimization)、和 DE 算法 (Differential Evolution) 等三种智能算法进行分析对比。结果表明 DE 算法和 SCE 算法具有很好的优势。

2) 简要介绍了结构参数识别问题中的不确定性来源和分析方法,并针对测量信息引起的识别参数不确定性问题,提出基于 SCEM 算法 (Shuffled Complex Evolution) 的参数不确定性分析方法。通过数值分析证明,无论测量信息是否完备、质量是否已知,该法均能有效评估结构系统识别问题中的参数不确定性。

3) 针对实际工程中不同自由度的信息量饱满程度的差异性,提出基于信息熵的 SCE 参数识别方法。通过对测量信息的信息熵计算,按照熵值大小赋予不同自由度的测量信息不同权重,从而使目标函数更精确地描述系统特征。通过数值分析对比,结果证明该方法能够有效提高结构识别参数的精度。

**关键词:** 结构参数识别, SCE, SCEM, 信息熵

## ABSTRACT

Structural parameter estimation plays a key role in the practical application of civil engineering, especially the field of Structural Health Monitoring. As a result, many Artificial Intelligent algorithms are adopted to solve parameter estimation problem.

In this thesis, parameters estimation problem is treated as an optimization problem and a new structural parameter estimation method based on SCE algorithm (Shuffled Complex Evolution) is proposed. The main work is shown as follow:

1) The main research topics in the realm of System Identification are briefly reviewed. To avoid the strict restrictions that tradition method imposed on the parameter estimation problems, a novel parameter estimation method based on SCE algorithm is developed. According the numerical analysis results of seven different case studies, the method proposed is stably efficient, accurate and easy implementing, which is undependent on the mass parameters' knowability, measure datas' completeness, or the I/O noise pollution level. Meanwhile, three Artificial Intelligent algorithms, PSO (Paricle Swarm Optimization), CLPSO (Comprehensive Learning Particle Swarm Optimization) and DE (Differential Evolution) are introduced as comparisons to SCE. The study result shows that the DE and the SCE outperform the other algorithms.

2) The thesis discusses the origin of the uncertainty and reviews the classical uncertainty analysis methods in the structural parameter estimation problem. To appropriately evaluate the parameter uncertainty specifically introduced by measurement uncertainty, a new parameter uncertainty assessment method based on SCEM algorithm (Shuffled Complex Evolution Metropolis) is presented. Several case studies demonstrated that the method proposed is effective to assess the parameter uncertainty in different cases in which the measurement is full and partial and the mass parameters are known and unknown.

3) Regard the significant differences in quantity of effective information among different DOFs (Degree Of Free), a SCE algorithm based parameter estimation method using the comentropy theory is presented. In this method, each DOF's output is weighed according the computing result of the data's comentropy. Thereby, the object function is improved to better present the system characters. Numerical



computing of parameter estimation is presented and the study result shows that it is an effective way to improve the accuracy of the structural parameters identified.

**Key Words:** structural parameter estimation, SCE, SCEM, comentropy

## 目录

|   |    |
|---|----|
| 第 1 章 绪论.....                             | 1  |
| 1.1 课题背景.....                             | 1  |
| 1.2 结构参数识别的研究现状和问题.....                   | 5  |
| 1.2.1 结构参数识别的研究现状.....                    | 5  |
| 1.2.2 结构参数识别存在的问题.....                    | 9  |
| 1.3 本文的研究目的和主要研究内容.....                   | 10 |
| 1.3.1 研究目的与研究意义.....                      | 10 |
| 1.3.2 主要研究内容.....                         | 10 |
| 第 2 章 基于SCE算法的结构参数识别方法.....               | 12 |
| 2.1 引言.....                               | 12 |
| 2.2 SCE算法基本原理.....                        | 12 |
| 2.2.1 算法流程.....                           | 13 |
| 2.2.2 局部进化策略.....                         | 14 |
| 2.2.3 参数选择.....                           | 17 |
| 2.3 基于SCE算法的结构参数识别方法.....                 | 19 |
| 2.3.1 问题描述.....                           | 19 |
| 2.3.2 数值模型.....                           | 21 |
| 2.3.3 质量已知系统的参数识别.....                    | 23 |
| 2.3.4 质量未知系统的参数识别.....                    | 26 |
| 2.4 其他智能算法比较.....                         | 30 |
| 2.4.1 PSO、CLPSO、DE算法原理简介.....             | 30 |
| 2.4.2 数值分析.....                           | 32 |
| 2.5 本章小结.....                             | 41 |
| 第 3 章 基于SCEM算法的参数不确定性分析方法.....            | 42 |
| 3.1 引言.....                               | 42 |
| 3.2 结构参数识别的不确定性来源及分析方法.....               | 42 |
| 3.2.1 结构参数识别的不确定性来源 <sup>[71]</sup> ..... | 42 |
| 3.2.2 结构参数识别的不确定性研究方法.....                | 43 |
| 3.3 SCEM算法介绍.....                         | 47 |
| 3.3.1 参数后验概率密度计算方法.....                   | 47 |
| 3.3.2 SCEM算法基本原理.....                     | 48 |
| 3.3.3 SCEM算法流程.....                       | 49 |
| 3.3.4 SEM核心算法.....                        | 51 |
| 3.3.5 参数选择.....                           | 54 |
| 3.4 基于SCEM算法的参数不确定性分析方法.....              | 54 |
| 3.4.1 算法描述.....                           | 54 |
| 3.4.2 数值模型.....                           | 55 |
| 3.4.3 质量已知系统的参数不确定性分析.....                | 55 |
| 3.4.4 质量未知系统的参数不确定性分析.....                | 60 |
| 3.5 本章小结.....                             | 67 |

|                             |    |
|-----------------------------|----|
| 第 4 章 基于信息熵的SCE参数识别方法.....  | 68 |
| 4.1 引言 .....                | 68 |
| 4.2 多目标优化问题及解法.....         | 69 |
| 4.2.1 多目标优化问题的解.....        | 69 |
| 4.2.2 多目标优化问题的解法.....       | 70 |
| 4.2.3 结构参数识别解法.....         | 71 |
| 4.3 信息熵基本原理及计算方法.....       | 71 |
| 4.3.1 信息熵的基本原理.....         | 72 |
| 4.3.2 信息熵的计算方法.....         | 72 |
| 4.4 基于信息熵的SCE参数识别方法.....    | 74 |
| 4.4.1 算法描述.....             | 74 |
| 4.4.2 数值分析.....             | 74 |
| 4.5 本章小结.....               | 78 |
| 第 5 章 总结与展望.....            | 79 |
| 5.1 本文工作总结.....             | 79 |
| 5.2 本课题继续研究展望.....          | 79 |
| 致谢 .....                    | 81 |
| 参考文献.....                   | 83 |
| 个人简历、在读期间发表的学术论文与研究成果 ..... | 87 |



## 第1章 绪论

### 1.1 课题背景

伴随着科技的迅猛发展以及人类物质生活和精神追求的不断升华,结构物的形式及功能越来越丰富多样,并日趋大型化、复杂化。然而这些大型复杂结构在各种突发性外在因素的影响以及复杂的服役环境中将受到设计荷载的作用而面临结构的损伤积累及退化问题。

首先,近些年的自然灾害和恐怖活动对重要结构的损伤和破坏日益增多。例如进入 2008 年以来,中国大地相继发生雪灾、地震、台风等灾害,许多重大土木工程结构,如电力设施、水坝、桥梁、高层建筑及高耸结构等在灾后的健康状态与人民生命财产息息相关。及时地对这些灾后建(构)筑物的健康状况做出正确评估是非常必要的<sup>[1,2]</sup>。





图1.1 2008年雪灾地震台风对构筑物造成的破坏

其次，在已有的建（构）筑物中，旧有建筑仍然占有很大比例。随着时间的推移，将有大量建筑物达到或超过其设计基准周期。针对我国基础设施建设中存在的严重质量问题，如何通过一定的技术手段对土木工程结构的健康状况做出合理科学的评估和监控，并采取对应的措施以保证病害结构的安全运行，已经成为了一个急待解决的问题。

因此，为了保障结构的安全性、耐久性和使用性，必须采取必要手段，对使用中的结构性能进行检查、评估或监测。当大型结构发生突发性损伤时，如果能够及时做出判断和警报，采取相应应急处理措施，就可以防止损伤进一步发展和引发其它事故；对于长期在役的重要结构，如果能够定期对其累积损伤的程度做出正确评估，就可以充分掌握结构的工作状态，确保结构的安全。

在全球经济和科学技术高速发展的今天，上述这些构想已经逐步成为重要工程的必然要求，因此结构健康监测<sup>[4-6]</sup>应运而生，并成为土木工程学科发展的一个重要领域。结构健康监测，就是采用现场的无损传感技术和结构特性分析手段（包括结构响应）来探测和揭示结构状态退化或损伤发生的一个过程<sup>[7]</sup>。通过结构健康监测技术来获取有关结构状态的信息，可以为工程结构的设计验证、施工控制、安全运营和维修决策提供有力的技术保障，对评价结构生命过程的安全性、完整性、耐久性和适用性具有极其重要的意义<sup>[2]</sup>。

一个完整的结构健康监测系统主要包括监测、诊断和状态评估三个部分。其中，诊断部门的一个重要环节就是对待监测系统的识别问题。




图1.2 结构系统识别在健康监测中的作用

系统识别, Astrom 和 Eykhoff 给出如下定义: 根据实际系统测试中的输入输出信息, 在一组预先给定的系统参数集合 $\{S\}$ , 中找到合适的  $\theta \in \{S\}$ , 使之与实际系统等价<sup>[7]</sup>。一般的分析问题是已知系统的数学模型, 根据系统输入  $u$  求解系统输出  $Y$ ; 而系统识别问题是依据系统输入  $u$  和系统输出  $Y$  来推求数学模型或者其中的参数。通常定义前一类问题为正分析问题, 而后一类的系统识别问题属于反分析问题<sup>[8]</sup>。

系统识别研究最初起源于现代控制理论。在控制理论中, 被控对象的数学模型往往是未知的, 因此需要按状态方程或高阶差分方程形式给出模型类, 然后根据观测数据建立具体的模型和参数。其中, 确立模型的工作称为模型类识别; 确立模型中参数的工作称为参数识别<sup>[8]</sup>。

土木工程结构系统属于动力学系统。由于动力学系统在外力作用下的运动规律遵循牛顿力学定律, 因此系统的基本数学模型一般是已知的, 需要识别的仅是系统的特征参数 (一般包括物理参数和动力特性参数)。只有当动力学系统内部的某些物理机制(如非线性恢复力模型)不清楚时才需进行模型类的识别<sup>[8]</sup>。由此, 土木工程结构系统识别问题通常归结为参数识别问题。

结构参数识别是在实际结构系统输入、输出的观测数据基础上, 通过对模型预测数据和系统观测数据进行参数相关性研究, 从一组给定的模型类中确定一个与所测系统等价的数学模型。结构参数识别的目标是结构的特征参数, 包括结构

模态参数（固有频率、阻尼比、振型、传递函数等）和结构物理参数（刚度、阻尼参数等）。

根据识别目标的不同，结构参数识别分为结构模态参数识别和结构物理参数识别<sup>[8]</sup>。其中，结构物理参数是结构物理性态的直观表述；结构模态参数反映结构的质量和刚度分布，因此能够间接反映出结构物理性态的变化。此外，结构特征参数的识别可以依据不同类型的响应信号：频域法基于结构的传递函数、频率响应函数或实测结构的模态参数等，一般是首先将测得的响应与激励的时间历程信号转换到频率域后再进行识别；时域法是直接基于结构响应的时间历程进行识别。结构参数识别算法大致可分为四类：

- 1、结构模态参数的频域识别；
- 2、结构模态参数的时域识别；
- 3、结构物理参数的频域识别；
- 4、结构物理参数的时域识别<sup>[9]</sup>。

以上四类结构参数识别算法，它们各自有不同的原理和特征，为此也有不同的适用范围。针对某个具体的识别问题，应当通过对各类识别方法的性能进行对比，从而确定应当优先采用哪一类方法。

首先对比频域与时域识别方法。由于频域内模态信息可由有限多个频率、模态形状和模态阻尼率等表示，因此频域法中待处理的数据量小；另外，频域法不必获取所有自由度的模态信息。但是，频域法需要先通过傅立叶变换将时域内的响应测量数据转化到频域内，再进行参数识别，这样的数据转换必然存在截断误差、噪音等，导致频域法所得结果的精度受到影响。此外，频域法不能采用时变模型，因为其相当于对时间信息作了平均；如果要考虑时变，即参数随时间的衰减，必须使用时域方法。

再对比模态参数与物理参数识别方法。当识别目标是模态参数时，首先不能评价结构单元的个体行为。因为模型是针对整个结构的，因而仅给出整个结构的全局的效应，相当于对各单元取了平均。以前的一些研究也表明，局部损坏对结构的模态特性影响不大。其次，对于大型复杂结构，求得的高阶模态不可靠，所以很难确定需要计算多少阶模态以准确或尽可能准确地计算结构参数。最后，模态参数只是结构性态的间接指标，虽然模态参数的变化可以在一定程度上反映结构的退化、缺陷等，但是难以使人确定导致这些变化的原因。例如结构刚度下降可能是裂缝、单元质量变化或是材料腐蚀等原因导致的。如果原因不明，将对加固等措施的实施缺乏指导意义。相比之下，直接识别结构的物理参数能够弥补以上方面的不足，不过该类方法目前尚存在计算量巨大、效率不高等因素的制约。



## 1.2 结构参数识别的研究现状和问题

### 1.2.1 结构参数识别的研究现状

近几十年来,随着计算机科学的迅猛发展,原先被认为无法人工实现的具有计算量巨大,识别效率低下的结构参数识别得到了长足的发展。在综合了计算技术与土木工程结构理论基础后,许多结构系统识别算法得以提出,并广泛应用于结构参数识别中,得到许多世人瞩目的科研成果。本文将其中最主要的几类识别算法和其应用成果列举如下。

#### (1)、最小二乘法类识别算法

最小二乘估计方法最早由高斯(K.F.Gauss)于1795年在星体运动轨道研究中提出,但是直到20世纪60年代才被用于动态系统参数识别问题中。这种参数估计的特点是算法简单,在使用之前不必预先知道与被估计参量以及观测量有关的任何统计信息;但在另一方面,该方法对于扰动有时很敏感<sup>[10]</sup>。

最小二乘估计方法的直观意义是,未知参数的最优估计将使实际量测响应与模型理论计算响应之间的误差的累计平方和达到最小。已经证明,如果噪声与模型输入统计无关,可以得到参量的无偏估计;进一步地,如果是白噪声过程,即零均值的平稳随机过程,将得到参量的一致估计。然而在实际工程中,这两个条件几乎无法达到,因此最小二乘估计的结果既不是无偏估计也不是一致估计。不过文献<sup>[8]</sup>中已经指出,当观测序列长度趋于无穷大时,估计参数依概率收敛于真实值。即只要观测时刻和获得的量测数据足够多,就可以应用最小二乘方法进行参数识别。

最近几十年来,在经典最小二乘方法的基础上,还进一步发展起了加权最小二乘、递推最小二乘、遗忘因子算法等。特别在现代控制理论中,还发展起了增广最小二乘、广义最小二乘、多级最小二乘、限定记忆法等多种修正算法。上述各算法可以归为一类最小二乘类识别算法。

这类算法在目前的参数识别技术中占据了相对主要的地位。此外,若干近年来新发展的识别算法实质上也都建立在最小二乘类识别方法的基础上,例如文献<sup>[11]</sup> Halдар A 中提出的 ILS—UI 方法、以及文献<sup>[12]</sup> Li J 中提出的统计平均算法都基于迭代最小二乘方法。

#### (2)、极大似然类识别算法

极大似然法是现代识别的参数估计方法<sup>[13]</sup>之一。它是由Fisher发展起来的,其基本思想可以追溯到高斯(1809年)。这种估计方法用于动态系统识别,可以获得良好的估计效果。但是它需要构造一个以测量数据和未知参数有关的似然函

数, 并通过极大化这个函数获得模型的参数识别。据此, 极大似然法通常要求具有能够写出输出量的条件概率密度函数的先验知识, 因此计算工作量较大, 可能得到的是损失函数的局部极小值。

### (3)、卡尔曼滤波类识别算法<sup>[14-19]</sup>

卡尔曼滤波类算法适用于线性和非线性参数系统识别。1960年由R.E.Kalman首次提出的卡尔曼滤波(Kalman Filter)方法是一种递推最小方差估计(sequential least-squares estimation), 尚不能处理非线性问题。1970年Jazwinski<sup>[15]</sup>提出了扩展卡尔曼滤波(Extended Kalman Filter, 简称EKF), 通过在滤波估计值附近作线性化处理, 即将观测方程用泰勒级数展开并忽略二阶以上的小量, 解决了非线性滤波问题。EKF方法的基本思想是: 把系统参量作为增广状态向量, 利用系统参量对时间的导数为零, 将其并入卡尔曼滤波的状态方程与测量方程中; 然后在对系统的动态测量数据进行滤波、估计的同时, 得到系统参数的估计值。

为了使EKF的结果更快速地收敛于稳定值, Hoshiya M.<sup>[16]</sup>提出将EKF与一个带目标函数的全局加权迭代过程相结合的方法, 即EK—WGI(EKF with weighted global iteration), 并在文献<sup>[17]</sup>中应用该方法在未知输入条件下识别了梁上的移动荷载。Koh C. G.在文献<sup>[18]</sup>也使用EK—WGI方法并结合子结构方法识别了多层剪切型结构、多层框架结构与平面桁架桥。尚久铨在文献<sup>[19]</sup>进一步提出了缩减变量型EKF(即REKF), 仅选取结构的未知状态参量为待识别的物理参数, 不再识别结构的运动参数(如位移、速度)。该方法可以减少待估计的参量数目, 从而降低矩阵运算的阶数, 并省去了计算传递矩阵, 使计算精度和效率都得到一定程度的提高。鉴于卡尔曼滤波类方法抵抗一定程度的噪声或者扰动的能力, 以及其处理非线性系统的能力, 其在土木工程识别领域中是很有应用前景的。

### (4)、启发式随机搜索算法

20世纪60年代以来, 作为一类新颖的优化算法, 启发式随机搜索算法到长足发展。这些算法独特的优点和机制, 引起了国内外学者的广泛重视并掀起了该领域的研究热潮, 且在诸多领域得到了成功应用。启发式算法(heuristic algorithm)是相对于最优化算法提出的。一个问题的最优算法求得该问题每个实例的最优解。而启发式算法可以这样定义: 一个基于直观或经验构造的算法, 在可接受的花费(指计算时间和空间)下给出待解决组合优化问题每一个实例的一个可行解, 该可行解与最优解的偏离程度不一定事先可以预计。

目前, 启发式随机搜索算法结构参数识别已经成为国内外学者的研究热点。该类算法中, 在结构参数识别中的研究热点主要包括遗传算法(Genetic Algorithm)、蚁群算法(Ant Colony Optimization)、粒子群算法(Particle Swarm Optimization)和微分演化算法(Differential Evolution)。

## 遗传算法

遗传算法 (Genetic Algorithm, 简称GA) 是一种借鉴生物界自然选择和自然遗传机制的空间多维搜索算法, 最早于20世纪60年代提出。遗传算法作为一种优化方法, 在电子、自动控制、工业工程等工程领域已得到了广泛应用, 但是将其用于土木工程参数识别问题是近十几年才开始的, 因此其属于一种非经典参数识别方法。GA方法执行全局搜索策略, 并使用群对群搜索取代点对点搜索, 避免陷入局部最优; 此外, 使用GA方法进行结构参数识别是进行正分析, 可以避免反分析问题的病态性和复杂的运算。不过, 普通的GA方法需要依靠计算机强大的计算能力, 通常效率比较低, 尤其对于大自由度结构体系。

为解决效率问题, Koh C.G. 在文献<sup>[31]</sup>提出一种Modal GA算法, 即依据结构响应的时程观测数据, 在模态域内执行搜索, 再利用模态正交性由模态参数推求物理参数, 文中识别了一个含有50个自由度的层间剪切型结构。此外, 近年来还发展起了若干种旨在改善基本遗传算法的识别性能的变形 (或改进) 遗传算法, 如Koh在文献<sup>[32,33]</sup>等提出的算法。

遗传算法目前已经在结构参数识别问题中得到较广的应用。Doyle 在文献<sup>[34]</sup>中使用 GA 方法识别了梁上横向裂缝的位置与大小。Dunn 在文献<sup>[35]</sup>中应用 GA 方法识别了含有 3 个待估参量的有限元模型, 并定义目标函数为频率响应函数。Chou 则在文献<sup>[36]</sup>中在一般的 GA 算法中引入了弦代表策略(String Representation Scheme), 改进了算法的搜索能力, 可以主动识别出结构可能的损伤单元, 也可以同时识别出材料属性与未测量结构自由度的位移响应。Carlin 等人<sup>[37]</sup>用测量频率误差和振型误差的目标函数作为适应度准则, 讨论了种群大小、交叉频率、变异频率、遗传算法的交点等因素对损伤识别的影响, 并对不同的数值模型进行损伤识别。Koh 等<sup>[38]</sup>采用局部搜索的遗传算法, 通过测定激励和响应来决定结构参数, 该法通过全局和局部阶段自适应调整局部搜索尺寸的偏差, 具有很强的抗噪性。易伟健和刘霞<sup>[39]</sup>采用遗传算法处理试验得到的动力信息, 提出了多父体变量杂交和变量微调等新的改进措施, 应用于固端梁、连续梁和框架等多个结构的损伤识别, 取得了不错的效果。

## 蚁群算法

蚁群算法也称蚂蚁算法 (Ant Colony Optimization, 简称 ACO), 是在 20 世纪 90 年代初由意大利学者 M.Dorigo 提出的<sup>[40]</sup>。它是根据蚂蚁觅食原理而设计的一种群体智能算法。蚁群算法结合了分布式计算、正反馈机制和贪婪式搜索, 具有强鲁棒性和优越的搜索最优解的能力, 是一种求解复杂困难的系统优化问题的算法。蚁群算法自提出以来, 已成功应用于许多领域, 如 TSP、重建通讯路由、连续系统优化等许多领域。

### 微粒群算法

微粒群算法 (Particle Swarm Optimization, 简称 PSO) 是由 J.Kennedy 与 R.Eberhart 等于 1995 年开发的一种演化计算技术, 来源于对一个简化社会模型的模拟<sup>[41]</sup>。算法模拟鸟群飞行觅食的行为, 通过鸟之间的集体协作使群体达到最优。与遗传算法类似, 它也是基于群体迭代, 但没有交叉、变异算子。群体在解空间中追随最优粒子进行搜索。

微粒群算法已经广泛应用于结构动力系统问题。例如, Elegbede<sup>[42]</sup>应用微粒群算法对结构进行可靠性评估; Perez 和 Behdinan<sup>[43]</sup>将微粒群算法应用于优化设计领域中; Coelho 和 Krohling 等<sup>[44]</sup>将微粒群算法应用于结构物理参数识别。唐和生、<sup>[45]</sup>等提出将微粒群算法应用于系统识别和损伤定位, 并做了大量的研究工作。

然而, 微粒群算法同样存在一些缺陷。如容易出现停滞现象, 即搜索进行到一定程度后, 所有个体所发现的解完全相同, 不能对解空间进一步搜索, 不利于发现更好的解。

为了提高微粒群算法的解空间搜索能力, 张伟在文献<sup>[46]</sup>中, 对微粒群中加入了称为“综合学习”的策略来保持群体的多样性, 进而促使粒子可以持续保持探索未知区域的能力, 以达到对自由度数目较多结构的参数的有效识别, 该种算法也称为 CLPSO。文献同时将 CLPSO 算法应用于结构参数识别中。该法具有比微粒群更强的稳健性和鲁棒性。

### 微分演化算法

微分演化算法 (Differential Evolution, 简称 DE) 最先由 Storn 和 Price 于 1995 年提出<sup>[47]</sup>。DE 具有很多和其它演化算法例如遗传算法 (GA) 和进化策略 (ES) 相同的特点, 如系统用随机分布的一个群体初始化, 并通过演化代的更新来寻找最优解。但是与 GA 相比, DE 算法具有以下优点:

(1) 变异基于群体的差异, 由于早期群体差异度通常较大, 使得早期探索能力较强, 而随着代数的增加, 差异度变小, 这有利于后期进行精细搜索, 这类似于一个退火过程;

(2) 利用交叉率 CR 控制个体参数的各维对交叉的参与程度, 以及全局与局部搜索能力;

(3) 利用贪婪策略选择产生新一代个体, 类似于排挤模型, 有助于加快收敛速度。

作为一种新颖的演化计算技术, DE 算法以其概念简单、易于执行、鲁棒性强及收敛迅速等特点得到了大量的关注及应用。例如, Hesheng T.<sup>[48]</sup>将 DE 算法运用于结构参数识别问题, 并与 PSO 算法进行算例比较, 得到很好的结果; A

Kyprianou<sup>[49]</sup>运用 DE 算法解决了滞后系统的识别问题；W. Cheng<sup>[50]</sup>使用 DE 算法成功进行了结构系统参数的识别。

### 1.2.2 结构参数识别存在的问题

土木结构的参数识别问题本身具有许多独特的困难和技术堡垒。该领域的早期研究主要是基于在机械、航空、航天等领域的丰富的理论和应用成果来开展的。但是土木工程的结构系统，作为独特的复杂“建造”系统，与机械、飞行器等“制造”系统在许多方面存在根本区别。根据以往的研究成果和历史资料，学者们已经将结构参数识别领域的主要关键性问题总结如下<sup>[51-53]</sup>：

(1)、观测噪声：在结构控制实验或长期监测中，仪器设备的精度、环境的干扰、人为的误差都不可避免地会使观测数据受到噪声的“污染”；

(2)、建模误差：产生模型误差的原因主要是材料特性的离散、本构关系的不准确、建造过程的不确定、边界条件的简化、分布式结构系统的离散误差、非结构构件(外装饰、内墙等)的不正确建模等；

(3)、观测数据不完整：土木工程结构通常体积巨大、形式复杂，受现场条件和测试仪器的限制；

(4)、局部损伤不敏感：损伤通常发生在结构的局部区域，只对某些关键楼层的输出相应有影响，对距离较远的楼层则影响很小；

(5)、工作环境及运行荷载变化：即使处于正常状态的结构，也会由于温度、湿度等环境条件的变化以及荷载等运行状态的变化，造成观测数据在一个较宽的范围内变化。

同时，目前所采用的计算方法均有一定的局限性。目前的一般识别方法普遍具有以下缺陷：

(1)、大多数识别方法对目标函数都有较强的强制性限制，如连续、可微、单峰等。这些限制对于实际结构系统识别问题是很苛刻的。

(2)、大多数识别方法都需要先验信息。先验信息的确定主要是依靠以往的实验数据和经验，具有明显的不准确性，并容易出现错误。

(3)、需要完备的测量信息。实际中的工程结构是一个无限自由度的系统，其识别模型是通过一定的简化过程得以确定的，这也从根本上决定了模型测量信息是不完备的，与实际工程有差异；现实情况中出于技术、环境和经费等限制也不能提供传统方法所需要的全部测量信息。

(4)、算法结果一般与初始值的选取有较大的关系，不同的初始值可能导致不同的结果。初始值的选取较大地依赖于识别者对问题背景的认识及所掌握的知

识和经验。

(5)、算法缺乏简单性与通用性。针对一个问题，识别方法的使用者需要有相当的知识去判定使用哪一种识别方法较为合适。

(6)、对有些约束识别问题较难处理，要求解空间为凸集。

## 1.3 本文的研究目的和主要研究内容

### 1.3.1 研究目的与研究意义

由于土木结构自身复杂性和以往识别方法的局限性，开发一种可允许系统先验信息和测量信号不完备，同时对噪声具有良好的鲁棒性的识别方法是十分重要的。

1992 年，Duan 等在求解概念性降雨径流模型参数自动率定优化问题时，针对问题的非线性、多极值、没有具体的函数表达式、区间型约束等特点，提出了 SCE 算法 (Shuffled Complex Evolution, 简称 SCE)<sup>[55]</sup>。该算法结合了单纯形法、随机搜索和遗传算法中生物竞争进化的思想等方法的优点，可以一致、有效、快速地搜索到水文模型参数全局最优解。

2003 年，Jasper A. Vrugt 和 Hoshin V. Gupta<sup>[59]</sup>在 SCE 优化算法的基础上，基于 MCMC 法的思想，提出 SCEM 算法 (Shuffled Complex Evolution Metropolis)，并将其应用于水域模型参数的不确定性分析中。SCEM 算法除了继承了 SCE 算法收敛快、信息利用充分、空间搜索能力强等特点外，还具备不确定性分析能力。

本文通过将结构参数识别问题转化成特定优化问题，提出基于 SCE 的结构系统识别方法，并在此基础上分别提出基于 SCEM 算法的参数不确定性分析方法和基于信息熵的 SCE 参数识别方法。

### 1.3.2 主要研究内容

本文主要研究内容如下：

1. 本文提出基于 SCE 算法的结构参数识别方法，将结构参数识别问题转化为优化问题，从而使用 SCE 算法对结构模型进行识别。文中将采用数值分析验证该方法的有效性，并和另外三种智能算法 (PSO 算法 (Particle Swarm Optimization)、CLPSO 算法 (Comprehensive Learning Particle Swarm Optimization)、和 DE 算法 (Differential Evolution)) 的识别结果进行比较分析。
2. 针对实际应用中由测量信息引起的参数识别不确定性，本文提出基于

---

SCEM 算法的参数不确定性分析方法，并对数值结构模型参数识别进行不确定性分析。

3. 考虑实际工程中不同自由度上信息量饱满程度的差异性，本文提出基于信息熵的 SCE 参数识别方法。通过信息熵计算，对具有不同信息量的自由度的测量信息加以不同权重，使目标函数更好地描述系统特征，最终提高识别精度。文中将通过数值分析和对比，验证该法有效性。

## 第2章 基于SCE算法的结构参数识别方法

### 2.1 引言

美国亚利桑那大学 Duan Q., Sorooshian S., 和 Gupta V. [54-57] 于 20 世纪 90 年代开始研究水力学中的萨克拉门托模型参数优化问题。过程中, 由于模型参数识别存在着高度非线性、多极值、没有具体的函数表达式, 且具有区间型约束等难题, Duan 等提出了单纯形下山进化算法 Shuffled Complex Evolution (简称 SCE), 并且将其应用于研究中, 使问题得到了很好的解决。

SCE 标准算法结合了四种成熟的优化算法理念:

- (1)、确定性方法与不确定性方法的结合;
- (2)、群集思想;
- (3)、全空间分区域的系统演化;
- (4)、竞争性进化策略。

SCE 算法在竞争进化的策略中, 采用的是遗传算法中生物竞争进化的思想。同时通过对各个复合形的定期洗牌重组, 来确保每个复合形获得的信息能在整个问题空间中得到共享, 从而使算法快速收敛于全局最优解的同时, 避免陷入局部最优和早熟现象的出现<sup>[55]</sup>。

相对于其他智能优化算法, SCE 算法更有利于求解复杂、非线性、不可导、非凸的高维优化问题。Kuczera, Tanakamaru 和 Burges 给出了 SCE 算法收敛率与模型计算次数的相对关系<sup>[63,64]</sup>。Kuczera<sup>[63]</sup>研究成果显示, 在大部分的有限元模型计算中, SCE 算法的表现优越于遗传算法。Tanakamaru 和 Burges<sup>[66]</sup>指出, 如果给定的模型计算次数大于 2000 次, SCE 算法的计算结果和效率将胜过大多数其他优化算法。有 9 篇文献<sup>[55,66,61-67]</sup>对 SCE 算法在水域模型的计算结果进行分析, 发现在收敛后或者达到非常大的模型计算次数 (通常大于 10000) 后, SCE 算法的优化结果十分出色。尤其是在维数为 10 维或以上的问题中, SCE 算法的表现将优于一般算法<sup>[68]</sup>。

### 2.2 SCE算法基本原理

SCE算法是一种基于种群进化思想的算法, 它将全局搜索视为自然演化的过程。随机产生 $s$ 个 (样本点的个数) 解向量, 即组成了一个群体。将这个群体分



为几个族群（即复杂形），每个族群可以独立地竞争进化（即复杂形在不同方向上进行空间搜索），并淘汰最差个体。达到一定的代数之后，族群进行更新融合。在重新混合的过程中，组成新的族群。这样的过程可以使每个族群独立演化得到的信息完全得以共享，从而更快地进化。

算法中， $n$  个变量用一个  $n$  维向量表示，即一个样本点。 $\theta \in R^n$  为预估的问题搜索空间。从而，在每一次迭代中，SCE 算法采用  $s$  个  $n$  维向量  $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in \theta, i=1, 2, \dots, s$  来表示整个种群，也称为算法的一个子代。

### 2.2.1 算法流程

用 SCE 算法求解最小化问题的具体步骤如下<sup>[56]</sup>：

*Step1*: 初始化。假定待优化问题是  $n$  维问题，选取参与进化的复合形个数  $p$  ( $p \geq 1$ ) 和每个复合形所包含的顶点数目  $m$  ( $m \geq n + 1$ )，计算样本点数目  $s = p \times m$ 。

*Step2*: 产生样本点。在可行域内随机产生  $s$  个样本点  $x_1, \dots, x_s$ ，分别计算每一点  $x_i$  的函数值  $f_i = f(x_i), i=1, \dots, s$ 。

*Step3*: 样本点排序。把  $s$  个样本点  $(x_i, f_i)$  按函数值升序排列，排序后仍记为  $((x_i, f_i), i=1, \dots, s)$ ，其中  $f_1 \leq f_2 \leq \dots \leq f_s$ ，记  $D = \{(x_i, f_i), i=1, \dots, s\}$ 。

*Step4*: 划分复合形群体。将  $D$  划分为  $p$  个复合形  $A_1, \dots, A_p$ ，每个复合形含有  $m$  个顶点，其中

$$A^k = \{(x_j^k, f_j^k) | x_j^k = x_{k+m(j-1)}, f_j^k = f_{k+m(j-1)}, j=1, \dots, m\}, k=1, 2, \dots, p$$

*Step5*: 复合形进化。按 Complex Competitive Evolution（简称 CCE 算法）分别进化各个复合形。

*Step6*: 复合形混合。把进化后的每个复合形的所有顶点组合成新的点集，再次按函数值  $f_i$  升序排列，排序后不妨仍记为  $D$ ，再对  $D$  按目标函数的升序进行排列。

*Step7*: 终止条件判断。如果满足终止条件则停止，否则返回第四步。

终止条件通常选用为给定某一精度或者循环最大次数等。

SCE 算法流程图如下：




图2.1 SCE 算法流程示意图

### 2.2.2 局部进化策略

SCE 算法的关键部分是确保演化竞争性的复合形进化算法 (Complex Competitive Evolution, 简称 CCE)。在 CCE 算法中, 每个复合形的顶点都是潜在的父辈, 都有可能参与产生下一代群体的计算。每个复合形的作用如同父辈。通过随机方式构建新的复合形使得算法在可行域中的搜索更加彻底。

CCE 算法的演化竞争性是通过使用三角形概率分布来赋予不同个体权重来得以实现的。根据算法, 适应值越高的父辈, 也即更加优秀的个体, 将会有更高的概率来产生子代。

子代的产生方式采用 Nelder 和 Mead 的单纯型下山算法<sup>[58]</sup>。这种算法通过综合复合形里每个顶点的信息，确定复合形的形心位置，从而来给出最劣点进化的方向。

为了确保算法不会陷入局部最优区域，在特定情况下，某些子代会通过随机的方式在全部解空间中产生。这部分类似于遗传算法中的变异算子。

最后，每个复合形产生的新顶点将取代该复合形中最差的顶点，而不是整个群体中最差的顶点。这个做法可以保证每个父辈在被取代之前都至少有一次机会参与子代的复制过程。从而保证所有样本里有利于进化的信息都不会被遗漏。

CCE 算法的具体步骤如下<sup>[55]</sup>：

*Step1*: 初始化。选择  $q$ ， $\alpha$  和  $\beta$ ，其中， $2 \leq q \leq m$ ， $\alpha \geq 1$ ， $\beta \geq 1$ 。

*Step2*: 赋予权重。为  $A^k$  加上一个三角形概率分布的权重。 $p_i = 2(m+1-i)/m(m+1)$ ， $i=1, \dots, m$ 。 $x_1^k$  点具有最高的概率， $p_1 = 2/(m+1)$ 。 $x_m^k$  具有最低的概率， $p_m = 2/m(m+1)$ 。

*Step3*: 选择父辈。按照三角形随机概率分布，从  $A^k$  中随机选择  $q$  个顶点  $u_1, \dots, u_q$ 。将这些点存储到数组  $B = \{u_i, v_i, i=1, \dots, q\}$ ，其中  $v_i$  是点  $u_i$  的函数值。 $A^k$  的点的编号可用于构件  $B$ ，因此，将  $A^k$  的编号存储在  $L$  中。

*Step4*: 产生子代。

- (1) 对数组  $B$  和  $L$  进行排序，使  $q$  个顶点按照函数值升序的顺序排列。

用式子  $g = [1/(q-1)] \sum_{j=1}^{q-1} u_j$  计算父辈顶点的中心位置。

- (2) 计算新顶点  $r = 2g - u_q$ ，即顶点  $u_q$  对中心位置做中心对称映射。（映射步）
- (3) 如果  $r$  还在  $\theta$  解空间中，则计算该点函数值  $f$ ，并进行（4）步计算；否则，计算含有  $A^k$  的最小超立方体  $H \in R^n$ （在每个维度上的边长均正交），而后，在该正方体内随机地产生一个点  $z$ ，并计算函数值  $f_z$ ，令  $r=z$ ，并令  $f_r = f_z$ 。（变异步）。
- (4) 如果  $f_r < f_q$ ，则用  $r$  取代  $u_q$ ，并转向（6）步；否则，计算  $c = (g + u_q)/2$ 。即在中




图2.2 CCE 算法流程示意图

心点与父辈点中取折中点。(收缩步)

(5) 如果  $f_c < f_q$ ，则用  $c$  点取代  $u_q$  点，并转向 (6) 步；否则，在  $H$  超立方体中随机产生点  $z$ ，并计算函数值  $f_z$  (变异步)。并用  $z$  点取代  $u_q$  点。

(6) 重复 (1) 步到 (5) 步  $\alpha$  次，其中  $\alpha$  是一个可以由用户指定的大于等于 1 的参数。

*Step5:* 用子代替父辈。用  $L$  中存储的  $A^k$  原始编号，用  $B$  取代  $A^k$  中的父辈。然后按照函数值升序排列  $A^k$ 。

*Step6:* 迭代。从第一步到第五步，重复  $\beta$  次。其中  $\beta$  是一个可以由用户指定的大于 1 的参数。这个参数决定了会产生多少个子代 (每个复合形会进化到怎样的程度)。

### 2.2.3 参数选择

根据 Duan 等的研究<sup>[54]</sup>, SCE 算法(包括 SCE1 和 SCE2)中 SCE2 参数取值较优。

SCE 算法的参数缺省取值为  $m=(2n+1)$ ,  $q=n+1$ ,  $\alpha=1$ ,  $\beta=2n+1$ 。其中  $n$  是变量的个数,  $m$  是单纯形中点的个数,  $q$  是每个孩子单纯形中点的个数 ( $n+1$  是 Nelder 和 Mead 推荐的单纯型标准规模),  $\alpha$  为每个单纯形进化运算的步骤数,  $\beta$  是每个孩子单纯形进化后产生的连续后代的个数。

$p$  是单纯形的个数, 是参数率定时唯一需要确定的参数, 在实际计算的过程中要是单纯形的个数选择多了, 则会增加计算量, 要是选择少了, 则达不到优化的效果。

本文采用 Hartman 函数进行  $p$  值调试。数值测试中, 随机测试 100 次。

Hartman 函数为:

$$f(x) = 3.32 - \sum_{i=1}^4 c_i \exp \left[ - \sum_{j=1}^n \alpha_{ij} (x_j - p_{ij})^2 \right]$$

$$x = (x_1, \dots, x_6)^T, \quad p_i = (p_{i1}, \dots, p_{i6})^T, \quad \alpha_i = (\alpha_{i1}, \dots, \alpha_{i6})^T$$

$$c_i > 0, \quad i = 1, \dots, 4, \quad 0 \leq x_j \leq 1, \quad j = 1, \dots, n$$

1 和表 2.2 为当  $n=6$  时,  $\alpha_{ij}$ ,  $c_i$ ,  $p_{ij}$  在  $i = 1, \dots, 4$  和  $j = 1, \dots, 6$  时的值。

全局最小值为 0, 最优解为 (0.201, 0.150, 0.477, 0.275, 0.311, 0.657)。其中在可行域内有 4 个局部最优值。

表2.1 Hartman 函数  $\alpha_{ij}$  和  $c_i$  的值

| $i$ | $\alpha_{1i}$ | $\alpha_{2i}$ | $\alpha_{3i}$ | $\alpha_{4i}$ | $\alpha_{5i}$ | $\alpha_{6i}$ | $c_i$ |
|-----|---------------|---------------|---------------|---------------|---------------|---------------|-------|
|-----|---------------|---------------|---------------|---------------|---------------|---------------|-------|

|   |       |       |       |       |       |       |     |
|---|-------|-------|-------|-------|-------|-------|-----|
| 1 | 10.00 | 3.00  | 17.00 | 3.50  | 1.70  | 8.00  | 1.0 |
| 2 | 0.05  | 10.00 | 17.00 | 0.10  | 8.00  | 14.00 | 1.2 |
| 3 | 3.00  | 3.50  | 1.70  | 10.00 | 17.00 | 8.00  | 3.0 |
| 4 | 17.00 | 8.00  | 0.05  | 10.00 | 0.10  | 14.00 | 3.0 |

表2.2 Hartman 函数  $p_i$  的值

| $i$ | $p_{1i}$ | $p_{2i}$ | $p_{3i}$ | $p_{4i}$ | $p_{5i}$ | $p_{6i}$ |
|-----|----------|----------|----------|----------|----------|----------|
| 1   | 0.1312   | 0.1696   | 0.5569   | 0.0124   | 0.8283   | 0.5886   |
| 2   | 0.2329   | 0.4135   | 0.8307   | 0.3736   | 0.1004   | 0.9991   |
| 3   | 0.2348   | 0.1451   | 0.3522   | 0.2883   | 0.3047   | 0.6650   |
| 4   | 0.4047   | 0.8828   | 0.8732   | 0.5743   | 0.1091   | 0.0381   |

表2.3 Hartman 函数测试结果

| $p$ | 1   | 2   | 3   | 4   | 5   | 6    | 7    | 8    | 10   | 12   | 15   | 20   | 25   |
|-----|-----|-----|-----|-----|-----|------|------|------|------|------|------|------|------|
| NF  | 32  | 45  | 41  | 40  | 41  | 43   | 26   | 20   | 22   | 16   | 16   | 8    | 4    |
| AFE | 329 | 415 | 608 | 756 | 971 | 1125 | 1329 | 1603 | 1982 | 2306 | 2946 | 3984 | 4989 |

$p$ : 复杂型个数

NF: (Number of Failures) 每 100 次运算中失败的次数。

AFE: (Average Number of Function Evaluation) 平均函数调用次数。




图2.3 复杂形个数  $p$  参数试验结果

由试验结果可以发现，平均函数调用次数（AFE）与复杂型个数基本成正比关系。而计算失败次数（NF）则与复杂型个数基本成反比关系。并且，复杂形

个数  $p < 7$  时,  $p$  值增加对于结果的改善并不明显。这也与 Hartman 函数自身特性有一定关系。

通过数值试验,基本可以认为,随着复杂形个数  $p$  的增加,平均函数调用次数 (AFE) 线性增加, SCE 对于全局优化的效率也是线性提增的。

考虑本文中系统识别数值模型较为复杂,为了尽量减少计算量,在质量已知的工况下,取复杂形个数  $p=2$ ,在质量未知的工况下,取复杂形个数  $p=4$ 。

## 2.3 基于SCE算法的结构参数识别方法

### 2.3.1 问题描述

结构系统识别的关键在于如何给出系统等价的标准,通常,在结构系统识别方法中,这个标准是通过定义一个标量误差函数来实现的,即

$$V = V(X_a(\theta), X_m) \quad (2.1)$$

其中,  $V$  代表误差函数,  $X_a$  为分析模型的输出 (输入) 或其它特征,  $X_m$  为实际结构即本原系统的实际输出 (输入) 或其它特征。

这里  $\theta$ 、 $\{S\}$ 、 $X$  和  $V$  的选择没有一个统一的标准,在很大程度上取决于结构参数识别的目的和设计者对于结构模型的预先了解或称先验知识。

此外,有时在系统识别过程中还要引入一些约束条件,如刚度和质量矩阵的正交性、对称性条件等等。这些约束可通过一定方式与误差函数一起构成目标函数 (或目标泛函), 也称评价函数, 表示如下:

$$J = V(X_a(\theta), X_m) + \sum_{i=1}^n a_i M_i \quad (2.2)$$

其中  $J$  代表目标函数 (目标泛函),  $M_i$  代表由第  $i$  个约束方程所产生的标量误差,  $a_i$  表示权系数。

当目标函数 (目标泛函) 选定后, 结构参数识别问题最后实际上就归结为一个约束优化问题, 即寻找合适的  $\theta \in \{S\}$ , 使得目标函数 (目标泛函)  $J$  取极小值, 优化模型如下所示:

$$\min J(\theta) \quad s.t. \theta \in \{S\} \quad (2.3)$$

由上述结构系统参数识别原理所形成的识别过程可由图2.4 描述。




图2.4 结构参数识别过程示意图

假设工程结构本原系统用图 2.4 (a)表示，分析模型可用图 2.4 (b)表示，图中 $u(t)$ 、 $e(t)$ 分别表示系统输入、输出， $n$ 表示噪声， $y(t)$ 则表示包含噪声后的系统输出。将此两图合并后并补充识别算法和识别准则两个基本环节，即构成了图 2.4 (c)所示的结构参数识别的过程<sup>[9]</sup>。

不失一般性，考虑一结构系统如下：

$$y(k) = f(u(k), \theta) \quad (2.4)$$

其中  $y \in R^q$  表示系统输出， $u \in R^p$  表示系统输入， $\theta = (\theta_1, \theta_2, \dots, \theta_n)$  为需要估计的系统参数， $k$  为系统离散时间点， $k = 0, 1, \dots, T$ 。  $T$  为采样时间终点。

为了得到一个精确的系统参数识别过程，备选分析模型系统必须对任意的输入激励都能精确地产生输出数据。因此，问题归结为最小化实测真实结构输出与备选分析模型系统输出之间的误差范数，例如式 (2.5) 所示的均方误差函数：



$$F(\theta) = \frac{1}{T} \sum_{k=1}^T \|y(k) - \hat{y}(k)\|^2 \quad (2.5)$$

其中  $\hat{y}(k) = f(u(k), \hat{\theta})$  为备选分析模型的输出,  $\| \cdot \|$  表示矢量的欧几里德范数。形式上, 优化问题要求找到一个向量  $\theta \in R^n$  以满足某种质量判据, 即使得误差范数  $F(\bullet)$  最小化。  $F(\bullet)$  即为式 (2.5) 所定义的目标函数或评价函数。

因而识别问题可以转化成 (2.6) 所示的一个线性约束、多维非线性优化问题:

$$\begin{aligned} \min F(\theta), \theta = (\theta_1, \theta_2, \dots, \theta_n) \\ \text{s.t.} \quad \theta \in R^n \mid \theta_{\min,i} \leq \theta_i \leq \theta_{\max,i} \quad \forall i = 1, \dots, n \end{aligned} \quad (2.6)$$

其中  $\theta_{\max}$  和  $\theta_{\min}$  分别表示  $n$  个参数取值的上限和下限。

本文通过 SCE 算法对该识别问题转化成的优化问题进行求解。基于 SCE 算法的结构参数识别方法主要流程如下:

1. 给定初始规模, 定义 SCE 算法的初始参数, 并随机散布于可行域空间中;
2. 划分复合形群体;
3. 采用 CCE 策略进行复合形进化;
4. 进行复合形洗牌;
5. 判别是否满足终止条件, 如是则接步骤 6, 否则回转步骤 3 继续群体的更新;
6. 按照全局最优解, 确定相应系统参数的识别值。

算法具体实施的流程图类似于图 2.4。

### 2.3.2 数值模型

为了验证基于 SCE 算法的结构系统识别方法的有效性, 本文利用 SCE 算法对如图 2.5 所示的一个 8 层剪切型框架结构模型进行结构系统参数识别。

算例采用的结构模型为一个二维 8 层剪切型框架结构模型。结构布置如图 2.5 所示。




图2.5 8 自由度结构示意图

基本动力方程如下：

$$M\ddot{x} + C\dot{x} + Kx = u(t) \quad (2.7)$$

$$C = \alpha M + \beta K$$

$$\zeta_r = \frac{\alpha}{2\omega_r} + \frac{\beta\omega_r}{2} \quad (2.8)$$

其中， $M$ 、 $C$  和  $K$  分别为质量、阻尼和刚度矩阵， $x$  为位移向量， $u$  为输入力向量；结构的质量聚集在每一楼层平面上。Rayleigh 阻尼矩阵  $C$  (公式 (2.8)) 的模态阻尼比( $\zeta_r$ )取前两阶振型中( $r = 1, 2$ )的阻尼比。

结构模型的物理参数特性如表 2.4 所示。8 自由度系统的结构特性

|                  |         |
|------------------|---------|
| <i>刚度 (kN/m)</i> |         |
| 1 层              | 5.529e3 |
| 2-8 层            | 2.723e3 |
| <i>质量 (kg)</i>   |         |
| 1-7 层            | 49.48   |
| 8 层              | 45.06   |
| <i>阻尼比</i>       |         |
| 第 1 阶            | 0.01    |
| 第 2 阶            | 0.03    |

算例中，采用 El Centro 地震波作为输入，输入时间历程纪录 40s，采样间隔

为 0.02 s。时程分析采用 Newmark-beta 积分法。

在实际结构中，数据信号的采集往往受到噪声的干扰。因此，本文对数据信号加入一定的噪声，以便符合实际工程情况，同时验证不同噪声影响水平下，对 SCE 算法识别结果的影响。

在考虑噪声影响的工况下，输入和输出信号（I/O）加入零均值的高斯白噪声序列。其中，噪声大小的设置如式（2.9）所示。

$$ratio = \frac{\sigma_{noise}}{\sigma_s} \times 100\% \quad (2.9)$$

其中 ratio 表示噪声水平， $\sigma_{noise}$  为高斯白噪声的标准差， $\sigma_s$  则为测试信号的标准差。

算例中将考察无噪声和包含 5%、10% 噪声 3 种情形下的参数识别。

在实际工程应用中，由于建筑结构的复杂性，传感器的布置困难和本身仪器的有限性，真实结构中不可能做到信息完全已知。

为此，本文中的数值模拟计算考虑分析测量信息的不完备性。在本节中，将分别采用以下 2 种系统响应输出数据。

方式 1：全部楼层加速度（1-8 层）完全可测，即输出信息完全可知，则输出矢量可定义为

$$y(t) = (\ddot{x}_1(t), \ddot{x}_2(t), \dots, \ddot{x}_8(t))$$

方式 2：仅有 2 层，5 层，8 层加速度可测，即输出信息部分可知，则输出矢量可定义为

$$y(t) = (\ddot{x}_2(t), \ddot{x}_5(t), \ddot{x}_8(t))$$

同时，在算例分析中，将分为质量已知和质量未知两类情况。质量已知时，仅识别刚度系数和阻尼参数；质量未知时，识别结构系统的所有参数，包括质量、刚度系数和阻尼参数。所有参数的搜索空间均取为 0.8 倍~1.2 倍的真实值。

### 2.3.3 质量已知系统的参数识别

在本类工况中，假设结构质量已知，仅识别刚度系数和阻尼系数。

结构系统动力响应模型可由以下一系列待识别参数完全描述

$$\theta = (k_1, k_2, \dots, k_8; \zeta_1, \zeta_2) \quad (2.10)$$

本节将验证 SCE 算法对刚度和阻尼系数的识别效果，并分别考察输出数据不完备和数据噪声污染对于识别效果的影响。

SCE 参数设置如下：适应值函数计算最大次数= 20000（终止条件之一）， $p=2$

(复杂形个数)。


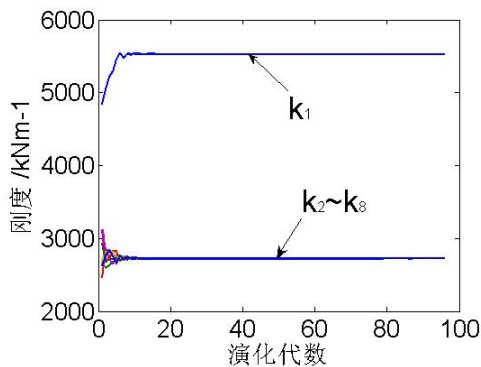
本节设置了 4 个工况。

- 1、 无噪声干扰下，输出信息完全已知的结构物理参数识别。
- 2、 无噪声干扰下，输出信息部分已知的结构物理参数识别。
- 3、 输出信息部分已知的情况下，输出信息受到 5% 噪声干扰的结构物理参数识别。
- 4、 输出信息部分已知的情况下，输出信息受到 10% 噪声干扰的结构物理参数识别。

以上 4 个工况均经过 5 次的独立运算后取平均值作为最终识别结果，并列于表 2.5 和表 2.6 中。无噪声干扰下，输出信息完全已知的工况 1 的目标函数及参数的部分典型收敛过程则如图 2.6 所示。10% 噪声干扰下，仅有部分输出信息已知的工况 4 的目标函数及参数的部分典型收敛过程如图 2.7 所示。

表2.5 质量已知，不同识别方式的模拟识别对照结果

| 参数                             | 真实值       | 方式 1 识别结果 |      |      | 方式 2 识别结果 |      |      |
|--------------------------------|-----------|-----------|------|------|-----------|------|------|
|                                |           | 识别值       | 相对误差 | 标准偏差 | 识别值       | 相对误差 | 标准偏差 |
| $K_1/\text{kN} \cdot \text{m}$ | 5.529E+03 | 5.529E+03 | 0%   | 0    | 5.529E+03 | 0%   | 0    |
| $K_2/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $K_3/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $K_4/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $K_5/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $K_6/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $K_7/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $K_8/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0%   | 0    | 2.723E+03 | 0%   | 0    |
| $\zeta_1$                      | 0.01      | 0.01      | 0%   | 0    | 0.01      | 0%   | 0    |
| $\zeta_2$                      | 0.03      | 0.03      | 0%   | 0    | 0.03      | 0%   | 0    |








图2.6 8 自由度结构质量已知、输出完全已知、无噪声的典型识别结果示意图

表 2.5 中的数据显示，在无噪声的情况下，无论输出数据完备或不完备的情况下，相对误差均为零。并且从图 2.6 中的参数演化曲线和目标函数收敛图中可以发现，无噪声干扰时，SCE算法能够非常迅速地找到全局近似最优解。并且，虽然适应值函数值很小，但通过使用对数坐标系后可以发现，SCE算法是以指数的速率收敛到最优解。

表2.6 质量已知，不同噪声下的模拟识别对照结果

| 参数                             | 真实值       | 5%噪声下识别结果 |       |           | 10%噪声下识别结果 |       |           |
|--------------------------------|-----------|-----------|-------|-----------|------------|-------|-----------|
|                                |           | 识别值       | 相对误差  | 标准偏差      | 识别值        | 相对误差  | 标准偏差      |
| $K_1/\text{kN} \cdot \text{m}$ | 5.529E+03 | 5.524E+03 | 0.10% | 8.324E-05 | 5.521E+03  | 0.15% | 1.385E-04 |
| $K_2/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.726E+03 | 0.10% | 5.752E-05 | 2.723E+03  | 0.01% | 8.313E-05 |
| $K_3/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.725E+03 | 0.08% | 5.732E-05 | 2.721E+03  | 0.07% | 1.290E-04 |
| $K_4/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0.01% | 2.922E-05 | 2.722E+03  | 0.05% | 8.253E-05 |
| $K_5/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.717E+03 | 0.20% | 1.210E-04 | 2.728E+03  | 0.19% | 9.137E-05 |
| $K_6/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03 | 0.01% | 2.168E-05 | 2.725E+03  | 0.08% | 1.279E-04 |
| $K_7/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.726E+03 | 0.12% | 7.300E-05 | 2.721E+03  | 0.09% | 7.919E-05 |
| $K_8/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.722E+03 | 0.04% | 4.906E-05 | 2.721E+03  | 0.07% | 1.367E-04 |
| $\zeta_1$                      | 0.01      | 1.002E-02 | 0.24% | 1.091E-09 | 9.801E-03  | 1.99% | 3.231E-09 |
| $\zeta_2$                      | 0.03      | 2.999E-02 | 0.03% | 8.191E-10 | 3.003E-02  | 0.09% | 8.637E-10 |






图2.7 8 自由度结构质量已知、输出完全已知、10%噪声的典型识别结果示意图

在考虑不同程度的噪声污染下，表 2.6 的识别结果中，5%噪声的工况下，刚度的相对误差相对较小，从 0.01% 到 0.20% 不等，而阻尼比的相对误差稍高，从 0.03% 到 0.24%；10%噪声下，识别结果的平均误差比 5%噪声工况的稍大。其中，刚度的相对误差从 0.01% 到 0.15%，阻尼比相对误差从 0.09% 到 1.99%。

由上数值分析可以看出，SCE 算法无论在无噪声、有噪声，以及在测量信息不完备的情况下，均能得到很好的结果。虽然随着噪声干扰对输入输出信号影响的加大，SCE 算法对于结构模型参数识别的误差也在逐渐增大，但误差范围一直控制在 2% 以内。其中，最大的相对误差总是出现在第一阶阻尼比上。这一现象主要是因为阻尼比对于整体响应的贡献相对较小，在适应值函数中，阻尼比的灵敏度相对较小，所以通常相对较难以准确识别。

### 2.3.4 质量未知系统的参数识别

为了在复杂困难的情况下验证基于 SCE 算法的结构系统识别方法的有效性，本节将分析结构质量未知情况下的识别问题。其中识别变量个数由 10 个增加为 18 个。

结构系统动力响应模型可由以下一系列待识别参数完全描述

$$\theta = (m_1, m_2, \dots, m_8; k_1, k_2, \dots, k_8; \zeta_1, \zeta_2) \quad (2.11)$$

SCE 参数设置如下：适应值函数计算最大次数= 20000（终止条件之一）， $p=2$ （复杂形个数）。

本节设置了 3 个工况。

- 1、 无噪声干扰下，输出信息完全已知的结构物理参数识别。
- 2、 无噪声干扰下，输出信息部分已知的结构物理参数识别。
- 3、 输出信息部分已知的情况下，输出信息受到 10%噪声干扰的结构物理

参数识别。

以上三种识别方式均经过五次的独立运算后取平均值作为最终识别结果，分别列于表 2.7 和表 2.8。输出完全已知、无噪声干扰（工况 1）和输出部分已知、10%噪声干扰下（工况 3）的识别过程（目标函数及参数的部分典型收敛过程）如图 2.8 ~图 2.9 所示。

表 2.7 无噪声，不同识别方式的模拟识别对照结果

| 参数                             | 真实值       | 方式 1 识别结果 |       |       | 方式 2 识别结果 |       |       |
|--------------------------------|-----------|-----------|-------|-------|-----------|-------|-------|
|                                |           | 识别值       | 相对误差  | 标准偏差  | 识别值       | 相对误差  | 标准偏差  |
| $M_1/\text{kg}$                | 4.948E+01 | 4.963E+01 | 0.30% | 0.40  | 4.935E+01 | 0.26% | 0.36  |
| $M_2/\text{kg}$                | 4.948E+01 | 4.963E+01 | 0.30% | 0.40  | 4.932E+01 | 0.33% | 0.43  |
| $M_3/\text{kg}$                | 4.948E+01 | 4.963E+01 | 0.31% | 0.41  | 4.931E+01 | 0.35% | 0.45  |
| $M_4/\text{kg}$                | 4.948E+01 | 4.963E+01 | 0.31% | 0.41  | 4.933E+01 | 0.31% | 0.41  |
| $M_5/\text{kg}$                | 4.948E+01 | 4.963E+01 | 0.30% | 0.40  | 4.921E+01 | 0.55% | 0.65  |
| $M_6/\text{kg}$                | 4.948E+01 | 4.963E+01 | 0.29% | 0.40  | 4.900E+01 | 0.96% | 1.05  |
| $M_7/\text{kg}$                | 4.948E+01 | 4.962E+01 | 0.29% | 0.40  | 4.915E+01 | 0.67% | 0.77  |
| $M_8/\text{kg}$                | 4.506E+01 | 4.520E+01 | 0.32% | 0.37  | 4.548E+01 | 0.93% | 1.05  |
| $K_1/\text{kN} \cdot \text{m}$ | 5.529E+03 | 5.545E+03 | 0.29% | 44.74 | 5.516E+03 | 0.23% | 38.96 |
| $K_2/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.30% | 22.40 | 2.714E+03 | 0.33% | 25.36 |
| $K_3/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.30% | 22.38 | 2.712E+03 | 0.39% | 31.47 |
| $K_4/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.30% | 22.35 | 2.713E+03 | 0.36% | 27.10 |
| $K_5/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.30% | 22.24 | 2.716E+03 | 0.27% | 16.26 |
| $K_6/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.31% | 22.53 | 2.726E+03 | 0.10% | 23.50 |
| $K_7/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.732E+03 | 0.32% | 22.50 | 2.731E+03 | 0.28% | 18.54 |
| $K_8/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.30% | 22.36 | 2.706E+03 | 0.62% | 54.51 |
| $\zeta_1$                      | 1.000E-02 | 1.010E-02 | 0.11% | 0.00  | 9.967E-03 | 0.33% | 0.00  |
| $\zeta_2$                      | 3.000E-02 | 3.002E-02 | 0.10% | 0.00  | 3.002E-02 | 0.10% | 0.00  |

在表 2.7 中，在无噪声的情况下，两种信息采集方式的参数平均误差分别为从 0.10%到 0.32%和从 0.10%到 0.96%。而在表 2.8，输出信息不完备且带有 10%噪声下的识别结果平均相对误差从 0.11%到 4.21%不等。

此外，在所有的计算中，SCE 算法均能搜索得到近似最优解。最大相对标准偏差仅为 4%。质量未知系统的识别目标函数是一个高度的多峰非线性函数。这类问题比质量已知系统的识别问题困难。然而，即使在 10%噪声干扰下，SCE 算法的最大识别误差也仅仅只有 4.21%。

表 2.7 数据中同时显示，在无噪声污染的情况下，输出信息数据量缩减 62.5%（即 8 层中仅有 2、5、8 层输出信息已知）的情况下，SCE 算法对模型结构物理参数识别结果，平均相对误差由 0.28%上升至 0.41%；平均相对标准偏差由 0.72%上升至 1.04%。表 2.8 中的计算结果则表明，在仅有 37.5%的输出信息数据已知的情况下，当噪声干扰由 0%上升至 10%时，识别结果的平均相对误差由 0.41%上

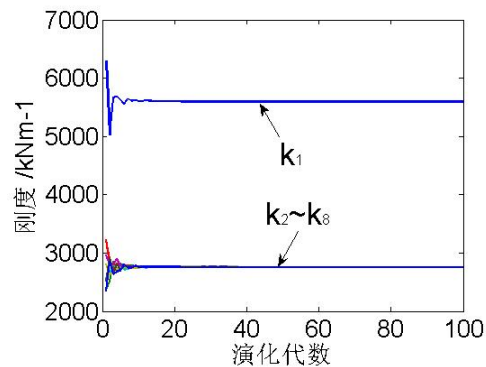

升至 1.13%；平均相对标准偏差由 1.04% 上升至 1.88%。

可见，当输出信息数据量大幅锐减时，SCE 算法对模型结构参数的识别仍能保持相对稳健，表现出良好的信息处理能力。

影响结构系统参数识别精度的最主要原因来自于输入输出信号的噪声污染。当噪声干扰水平上升时，识别结果误差剧烈上升。这和系统问题本身具有高维多峰非线性的特点不无关联。而 SCE 算法在误差显著上升的同时，很好地控制了相对标准偏差的上升，即很好地控制候选方案的区间范围，体现出了良好的稳健性。

表2.8 2、5、8层加速度输出，无噪声与 10%噪声下的模拟识别对照结果

| 参数                             | 真实值       | 无噪声识别结果   |       |       | 10%噪声识别结果 |       |        |
|--------------------------------|-----------|-----------|-------|-------|-----------|-------|--------|
|                                |           | 识别值       | 相对误差  | 标准偏差  | 识别值       | 相对误差  | 标准偏差   |
| $M_1/\text{kg}$                | 4.948E+01 | 4.935E+01 | 0.26% | 0.36  | 4.967E+01 | 0.38% | 0.38   |
| $M_2/\text{kg}$                | 4.948E+01 | 4.932E+01 | 0.33% | 0.43  | 4.966E+01 | 0.37% | 0.37   |
| $M_3/\text{kg}$                | 4.948E+01 | 4.931E+01 | 0.35% | 0.45  | 4.990E+01 | 0.84% | 0.83   |
| $M_4/\text{kg}$                | 4.948E+01 | 4.933E+01 | 0.31% | 0.41  | 5.000E+01 | 1.04% | 1.03   |
| $M_5/\text{kg}$                | 4.948E+01 | 4.921E+01 | 0.55% | 0.65  | 4.948E+01 | 0.35% | 0.01   |
| $M_6/\text{kg}$                | 4.948E+01 | 4.900E+01 | 0.96% | 1.05  | 4.882E+01 | 1.34% | 1.32   |
| $M_7/\text{kg}$                | 4.948E+01 | 4.915E+01 | 0.67% | 0.77  | 4.951E+01 | 0.06% | 0.06   |
| $M_8/\text{kg}$                | 4.506E+01 | 4.548E+01 | 0.93% | 1.05  | 4.696E+01 | 4.21% | 3.80   |
| $K_1/\text{kN} \cdot \text{m}$ | 5.529E+03 | 5.516E+03 | 0.23% | 38.96 | 5.542E+03 | 0.24% | 26.89  |
| $K_2/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.714E+03 | 0.33% | 25.36 | 2.735E+03 | 0.44% | 23.77  |
| $K_3/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.712E+03 | 0.39% | 31.47 | 2.742E+03 | 0.70% | 38.26  |
| $K_4/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.713E+03 | 0.36% | 27.10 | 2.734E+03 | 0.39% | 21.16  |
| $K_5/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.716E+03 | 0.27% | 16.26 | 2.764E+03 | 1.50% | 81.59  |
| $K_6/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.726E+03 | 0.10% | 23.50 | 2.797E+03 | 2.71% | 147.48 |
| $K_7/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.731E+03 | 0.28% | 18.54 | 2.787E+03 | 2.35% | 127.88 |
| $K_8/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.706E+03 | 0.62% | 54.51 | 2.705E+03 | 0.65% | 35.20  |
| $\zeta_1$                      | 1.000E-02 | 9.967E-03 | 0.33% | 0.00  | 9.737E-03 | 2.63% | 0.00   |
| $\zeta_2$                      | 3.000E-02 | 3.002E-02 | 0.10% | 0.00  | 3.003E-02 | 0.11% | 0.00   |








图2.8 8自由度结构质量未知、输出完全已知、无噪声的典型识别结果示意图




图2.9 8自由度结构质量未知、输出部分已知、10%噪声的典型识别结果示意图

从图2.8中可以发现,虽然SCE算法能在100代内迅速地收敛到最优解的相对小的邻域中,但后期的改善比较缓慢,无法重现质量已知系统识别过程中指数型的收敛速度。这可能是由于后期最优区域已经很小,而按照全局区间随机产生子代的变异方式已经很难提供有利于进化的优秀基因,因此后期的收敛速度明显放缓。不过也正是由于这种全局变异的策略,SCE算法保证了优化结果的全局最优性和计算结果的稳定性。

## 2.4 其他智能算法比较

为了进一步说明基于 SCE 算法的结构系统识别方法的有效性，本节将分析比较该算法与其他几种智能算法的识别结果，包括 PSO 算法（Particle Swarm Optimization）、CLPSO 算法（Comprehensive Learning Particle Swarm Optimization）、和 DE 算法（Differential Evolution）。

### 2.4.1 PSO、CLPSO、DE 算法原理简介

近年来，智能算法的研究突飞猛进，不断有新算法、新成果在科学领域问世。

#### PSO 算法（Particle Swarm Optimization）

作为群集智能算法的一种主要方法，PSO 算法最早是在 1995 年由美国社会心理学家 James Kennedy 和电气工程师 Russell Eberhart 共同提出的<sup>[46]</sup>，其基本思想是受他们早期对许多鸟类的群体行为进行建模与仿真研究结果的启发。

PSO 算法的程序流程为：

(1) 对每个粒子初始化，设定群体规模  $S$ ，给出  $S$  个  $n$  维初始向量作为各粒子的初始位置，另给出  $S$  个  $n$  维向量作为各粒子的初速度；

(2) 根据当前位置和速度按式 (2.12) 和式 (2.13) 产生各粒子的新的位置；

*Do*

(3) 计算每个粒子新位置的适应值；确定各粒子的个体最好位置  $p_i$  以及全局最好位置  $p_g$ ；

(4) 更新各粒子速度，并限制在  $v_{\max}$  内；

(5) 更新各粒子位置。

*Until* 满足算法终止条件

其中，初始化粒子的初始位置  $x_i(0)$  时，一般在  $[x_{\min}, x_{\max}]$  内服从均匀分布随机产生  $S$  个初始位置向量，亦可以在指定位置生成  $x_i(0)$ ；而初始化速度  $v_i(0)$  时，可以在  $[v_{\min}, v_{\max}]$  内服从均匀分布随机产生  $S$  个初始速度向量，若初始位置是由随机生成，则初始速度亦可全部置零。粒子根据如下的公式更新粒子当前速度和位置：

$$v_i^d(t+1) = v_i^d(t) + c_1 r_1^d(t)(p_i^d(t) - x_i^d(t)) + c_2 r_2^d(t)(p_g^d(t) - x_i^d(t)) \quad (2.12)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (2.13)$$

#### CLPSO 算法（Comprehensive Learning Particle Swarm Optimization）

为了有效阻止粒子群体的早熟收敛，张伟采用一种称为综合学习（Comprehensive Learning）<sup>[99, 138]</sup>的策略来保持群体的多样性，进而促使粒子可以

持续保持探索未知区域的能力，以达到对自由度数目较多结构的参数的有效识别，该种算法也称为CLPSO。

在综合学习策略中，粒子的速度更新公式改为

$$v_i^d(t+1) = w \times v_i^d(t) + c \times r_i^d(t) \times (p_{f_i(d)}^d(t) - x_i^d(t)) \quad (2.14)$$

其中  $f_i = [f_i(1), f_i(2), \dots, f_i(D)]$  定义了粒子  $i$  在各个维度上将要学习的最佳经验的来源，也就是说粒子  $i$  在第  $d$  个维度上将要向第  $f_i(d)$  个粒子的最佳经验学习。在综合学习策略中，对于  $D$  维问题，随机选取  $m$  个维度向群体最佳经验学习，而在剩下的  $D-m$  个维度中，此时的学习范本  $p_{f_i(d)}^d(t)$  有可能是任意一个粒子包括第  $i$  个粒子本身的  $p^d$ ，而决定的依据则有赖于被定义为学习概率的因子  $Pc$ ，对于不同的粒子而言，可以有不同的学习概率。对于粒子  $i$  的每一个维度，都将产生一个随机数，如果该随机数大于  $Pc_i$ ，则在该维度上将向粒子自身的最佳经验学习，否则在此维度上将学习其它粒子的最佳经验。粒子  $i$  在  $D-m$  中的维度  $d$  上选择粒子  $f_i(d)$  作为学习范本的具体方式描述如下：

- (1) 首先从速度尚未更新的群体中随机选取两个粒子。
- (2) 比较这两个粒子的个体最佳适应值并选择其中适应值较好的粒子。
- (3) 使用被选择出来的粒子的个体最佳经验作为当前粒子  $i$  在维度  $d$  上的学习范本，如果粒子在所有维度上学习的范本恰巧都来自于本身的个体最佳经验，则任意选取其中一维向其它粒子的个体最佳经验学习。

#### DE 算法 (Differential Evolution)

作为一项突破性的计算技术，自从Storn和Price在1995年<sup>[47]</sup>引入了DE算法之后，DE算法在解决复杂的优化问题上得到了很多关注。

DE算法<sup>[47]</sup>是一种基于实数编码的演化算法，将  $n$  个参数用一个  $n$  维向量代替，让  $S \in \mathbb{R}^n$  做为问题的搜索空间，利用  $NP$  个  $n$  维向量  $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in S, i = 1, 2, \dots, NP$  作为每一迭代的数量，称为算法的一个进化。在DE算法中，向量个数  $NP$  在起始是随机初始化的，通过突变，交叉和选择过程来寻找优化解。

DE的突变过程方程如下：

$$v_i^{(G+1)} = x_i^{(G)} + F_1(x_{best}^{(G)} - x_i^{(G)}) + F(x_{r1}^{(G)} - x_{r2}^{(G)}) \quad (2.15)$$

交叉过程为：

$$u_{ij}^{(G+1)} = \begin{cases} v_{ij}^{(G+1)}, & \text{if } (rand(j) \leq CR) \text{ or } (j = randn(i)) \\ x_{ij}^{(F)}, & \text{if } (rand(j) > CR) \text{ or } (j \neq randn(i)) \end{cases} \quad (2.16)$$

选择过程为：

$$x_i^{(G+1)} = \begin{cases} v_{ij}^{(G+1)}, & \text{if } (f(u_i^{(G+1)}) < f(x_i^{(G)})) \\ x_i^{(G)}, & \text{otherwise} \end{cases} \quad (2.17)$$

## 2.4.2 数值分析

结构模型为 10 层剪切型框架结构如图 2.5 所示。结构参数如表 2.9 中所示。

表 2.9 10 自由度系统的结构特性

| 刚度 (kN/m) |      |
|-----------|------|
| 1-4 层     | 5000 |
| 5-8 层     | 4000 |
| 9-10 层    | 3000 |
| 质量 (kg)   |      |
| 1-5 层     | 6000 |
| 6-10 层    | 4200 |
| 阻尼比       |      |
| 第 1 阶     | 0.05 |
| 第 2 阶     | 0.05 |

计算模型中，输入力为方差为 1000N 的高斯白噪声，5 层和 10 层各设置一个激励点。输出时间历程为 5s，采样间隔为 0.01s。

考虑质量已知和质量未知两类情况。质量已知时，仅识别刚度系数和阻尼比系数；质量未知时，识别结构系统的所有参数，包括质量、刚度系数和阻尼比系数。所有参数的搜索空间均取为 0.5 倍~2.0 倍的真实值。

### 质量已知系统的参数识别

在本类工况中，假设结构质量已知，仅识别刚度系数  $K$  和阻尼比系数  $\alpha$  和  $\beta$ 。因此，系统共有 12 个未知数。可由以下一系列参数完全描述：

$$\theta = (k_1, k_2, \dots, k_{10}; \alpha, \beta)$$

输出信息采用部分已知。其中 2, 4, 7, 10 层的加速度时程信息可知。则输出矢量定义为

$$y(t) = (\ddot{x}_2(t), \ddot{x}_4(t), \ddot{x}_7(t), \ddot{x}_{10}(t),)$$

为了便于各算法比较，均采用目标函数调用次数 20000 次作为结束准则。

对于本算例，文献 [69] 也分别采用 SGA 算法 (Simple Genetic Algorithm)、MAGMAS 算法 (Modified Genetic Algorithm based on Migration and Artificial Selection) 和 SSRM 算法 (Search Space Reduction Method) 对相同的数值模型进行了相同的参数识别。本文将参数设置和计算结果一并列于表 2.10 和表 2.12

中。

表2.10 各算法参数设置表<sup>[69]</sup>

|      | SGA <sup>[69]</sup> | MGAMAS <sup>[69]</sup> | SSRM <sup>[69]</sup> | PSO      | CLPSO   | DE         | SCE      |
|------|---------------------|------------------------|----------------------|----------|---------|------------|----------|
| 样本数  | 113                 | 9×3                    | 9×3                  | 100      | 100     | 30         | 8×13     |
| 代数   | 176                 | 741                    | 82                   | 392      |         |            |          |
| 数据长度 | 500                 | 500                    | 500                  | 500      | 500     | 500        | 500      |
| 时间步长 | 0.01                | 0.01                   | 0.01                 | 0.01     | 0.01    | 0.01       | 0.01     |
| 重复制  |                     | 2                      | 2                    | Wmax=0.9 |         | Weight=0.8 | $\rho=8$ |
| 重引入  |                     | 30                     | 30                   | Wmin=0.3 |         | Cr=0.85    |          |
| 算法参数 | 转移                  | 0.05                   | 0.05                 | 0.05     | C1=1.85 | C1=1.50    |          |
|      | 交叉                  | 0.96                   | 0.80                 | 0.80     | C2=1.3  | C2=1.50    |          |
|      | 变异                  | 0.05                   | 0.05                 | 0.20     |         |            |          |

每一种算法均经过 5 次的独立运算后取平均值作为最终识别结果,并列于表 2.11。表中同时给出了识别值以及识别的相对误差。表 2.12 给出了各种算法的识别最大误差和平均误差。目标函数和参数部分典型收敛过程如图 2.10 与图 2.11 所示。图 2.12 则为各算法在质量已知系统中的刚度识别结果误差对照。

表2.11 质量已知, PSO, CLPSO, DE, SCE 的模拟识别对照结果

| 参数                                | 真实值      | PSO      |      | CLPSO    |      | DE       |      | SCE      |      |
|-----------------------------------|----------|----------|------|----------|------|----------|------|----------|------|
|                                   |          | 识别值      | 误差   | 识别值      | 误差   | 识别值      | 误差   | 识别值      | 误差   |
| $K_1/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.09E+03 | 1.81 | 5.00E+03 | 0.06 | 5.00E+03 | 0.00 | 5.00E+03 | 0.00 |
| $K_2/\text{kN} \cdot \text{m}$    | 5.00E+03 | 4.91E+03 | 1.76 | 5.00E+03 | 0.04 | 5.00E+03 | 0.00 | 5.00E+03 | 0.00 |
| $K_3/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.02E+03 | 0.44 | 5.00E+03 | 0.04 | 5.00E+03 | 0.00 | 5.00E+03 | 0.00 |
| $K_4/\text{kN} \cdot \text{m}$    | 5.00E+03 | 4.96E+03 | 0.83 | 5.00E+03 | 0.05 | 5.00E+03 | 0.00 | 5.00E+03 | 0.00 |
| $K_5/\text{kN} \cdot \text{m}$    | 4.00E+03 | 4.00E+03 | 0.09 | 4.00E+03 | 0.00 | 4.00E+03 | 0.00 | 4.00E+03 | 0.00 |
| $K_6/\text{kN} \cdot \text{m}$    | 4.00E+03 | 4.07E+03 | 1.85 | 4.00E+03 | 0.05 | 4.00E+03 | 0.00 | 4.00E+03 | 0.00 |
| $K_7/\text{kN} \cdot \text{m}$    | 4.00E+03 | 3.95E+03 | 1.13 | 4.00E+03 | 0.07 | 4.00E+03 | 0.00 | 4.00E+03 | 0.00 |
| $K_8/\text{kN} \cdot \text{m}$    | 4.00E+03 | 4.04E+03 | 1.11 | 4.00E+03 | 0.03 | 4.00E+03 | 0.00 | 4.00E+03 | 0.00 |
| $K_9/\text{kN} \cdot \text{m}$    | 3.00E+03 | 2.99E+03 | 0.36 | 3.00E+03 | 0.00 | 3.00E+03 | 0.00 | 3.00E+03 | 0.00 |
| $K_{10}/\text{kN} \cdot \text{m}$ | 3.00E+03 | 3.00E+03 | 0.04 | 3.00E+03 | 0.00 | 3.00E+03 | 0.00 | 3.00E+03 | 0.00 |
| $\alpha$                          | 1.09E-02 | 1.07E-02 | 1.26 | 1.09E-02 | 0.12 | 1.09E-02 | 0.00 | 1.09E-02 | 0.00 |
| $\beta$                           | 1.84E-01 | 1.82E-01 | 0.78 | 1.84E-01 | 0.02 | 1.84E-01 | 0.00 | 1.84E-01 | 0.00 |

注:表中误差均为百分比相对误差%。

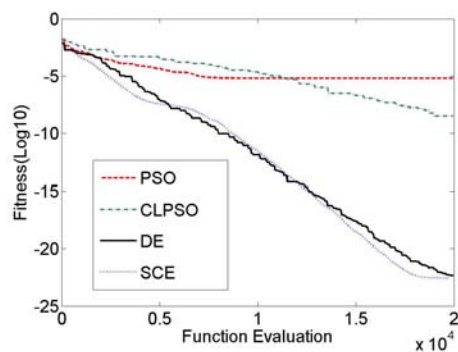
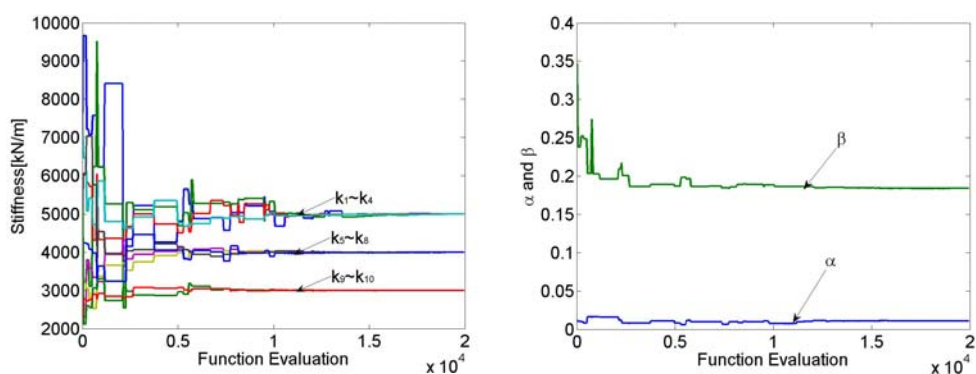




图2.10 质量已知情况下各算法目标函数收敛曲线示意图




CLPSO 的典型识别过程



PSO 的典型识别过程



DE 的典型识别过程



SCE 的典型识别过程

图2.11 质量已知系统中各算法参数部分的典型识别过程示意图

表2.12 各算法的模拟识别结果误差对照表

|                   | SGA <sup>[69]</sup> | MGAMAS <sup>[69]</sup> | SSRM <sup>[69]</sup> | PSO  | CLPSO | DE   | SCE  |
|-------------------|---------------------|------------------------|----------------------|------|-------|------|------|
| Mean Err- $k$ (%) | 4.22                | 1.36                   | 0.43                 | 0.94 | 0.03  | 0.00 | 0.00 |
| Max Err- $k$ (%)  | 12.36               | 4.22                   | 1.21                 | 1.75 | 0.06  | 0.00 | 0.00 |
| Mean Err- $c$ (%) | 12.33               | 5.68                   | 1.56                 | 1.02 | 0.07  | 0.00 | 0.00 |
| Max Err- $c$ (%)  | 20.76               | 10.10                  | 2.76                 | 1.16 | 0.11  | 0.00 | 0.00 |

注：表中误差均为百分比相对误差%。




图2.12 质量已知情况下各算法的刚度识别误差对照图

考虑到阻尼参数  $\alpha$  对于总响应的贡献非常小，因此  $\alpha$  值总是很难得到精确识别。然而，这并不影响最后的所需的识别结果。因为阻尼矩阵主要是由刚度部分决定的（ $\alpha$  约为  $\beta$  值的 1/10），因而，作为质量部分的比例系数  $\alpha$ ，在识别过程中存在误差对最终的阻尼矩阵并没有很大的影响。从实际应用的角度来看，最关键的部分应该是刚度的识别值和所用的计算时间。

从计算结果来看，CLPSO、DE、SCE三种算法的精度均好于M.J.Perry和C.G.Koh在文献<sup>[69]</sup>中的SGA、MGAMAS和SSRM三种算法的识别结果。

然而，从识别结果误差对照表及典型识别过程曲线进行对照观察，不同的算法表现出的收敛速度及搜索能力有较大的差异。PSO 算法在目标函数计算 7000 次的时候陷入了局部最优解，并在后期无法脱离该区域，因而在目标函数收敛曲线上，后 13000 次的目标函数计算也未能产生更优的解。在识别参数的典型过程曲线上体现出了早熟的特征，并在最终的识别结果中为个别参数带来了 2% 的识别误差。CLPSO 算法是 PSO 算法的改进算法。该算法的收敛速度相较 PSO 算法慢。但是收敛的进程十分稳健，从目标函数收敛曲线上容易发现，目标函数的收敛呈直线，即指数收敛。然而由于计算效率偏低，在以确定目标函数计算次数为收敛准则的前提下，该算法无法实现零误差。不过，由于良好的全局搜索性能，该算法很好地将误差控制在 0.1% 内。在本算例中，SCE 算法和 DE 算法表现最好，实现了精度与计算效率的统一。在目标函数计算 20000 次后。两个算法均达到了计算机精度（即零误差）。并且从目标函数收敛曲线上可以发现，二者的计算速度不但呈指数收敛，并且收敛效率远高于其他算法。

#### 质量未知系统的参数识别

为了在复杂困难的情况下，实现各类算法识别结果的差异化，本节将就质量未知系统的参数识别进行分析。在对质量已知系统的参数识别过程中，质量将参与做为未知数，因此，系统共有 22 个未知数。可由以下一系列参数完全描述：

$$\theta = (m_1, m_2, \dots, m_{10}; k_1, k_2, \dots, k_{10}; \alpha, \beta)$$

采用输出部分已知的情况，即 1, 2, 4, 6, 8, 10 层的加速度时程信息可知，则输出矢量定义为

$$y(t) = (\ddot{x}_1(t), \ddot{x}_2(t), \ddot{x}_4(t), \ddot{x}_6(t), \ddot{x}_8(t), \ddot{x}_{10}(t),)$$

为了便于各算法比较，均仍然采用目标函数调用次数 20000 次作为结束准则。同时，在设置的两个工况中，分别在输入输出加入 5% 和 10% 的高斯白噪声，以验证算法的鲁棒性和稳定性。各算法参数仍同表 2.10 所示。

本文四种算法均经过 5 次的独立运算后取平均值作为最终识别结果，两种工况的识别结果分别列于表 2.13 和表 2.15。表 2.14 和表 2.16 分别给出了两种工况下各种算法识别最大误差和平均误差。10% 噪声情况下的目标函数和部分参数典型收敛过程如图 2.13 与图 2.14 所示。



表2.13 质量未知, 5%噪声下, PSO, CLPSO, DE, SCE的模拟识别对照结果

| 参数                                | 真实值      | PSO      |       | CLPSO    |       | DE       |       | SCE      |       |
|-----------------------------------|----------|----------|-------|----------|-------|----------|-------|----------|-------|
|                                   |          | 识别值      | 误差    | 识别值      | 误差    | 识别值      | 误差    | 识别值      | 误差    |
| $M_1/\text{kg}$                   | 6.00E+03 | 6.51E+03 | 8.53  | 7.55E+03 | 25.80 | 5.96E+03 | 0.59  | 6.07E+03 | 1.16  |
| $M_2/\text{kg}$                   | 6.00E+03 | 8.72E+03 | 45.26 | 7.66E+03 | 27.60 | 6.02E+03 | 0.27  | 6.49E+03 | 8.11  |
| $M_3/\text{kg}$                   | 6.00E+03 | 8.15E+03 | 35.77 | 6.17E+03 | 2.90  | 6.04E+03 | 0.69  | 6.38E+03 | 6.27  |
| $M_4/\text{kg}$                   | 6.00E+03 | 6.66E+03 | 11.06 | 7.19E+03 | 19.82 | 6.00E+03 | 0.03  | 5.99E+03 | 0.16  |
| $M_5/\text{kg}$                   | 6.00E+03 | 5.84E+03 | 2.64  | 6.77E+03 | 12.79 | 5.99E+03 | 0.17  | 5.94E+03 | 1.05  |
| $M_6/\text{kg}$                   | 4.20E+03 | 4.73E+03 | 12.52 | 4.91E+03 | 16.87 | 4.12E+03 | 1.91  | 3.97E+03 | 5.41  |
| $M_7/\text{kg}$                   | 4.20E+03 | 3.86E+03 | 8.09  | 4.66E+03 | 10.91 | 4.17E+03 | 0.76  | 4.20E+03 | 0.07  |
| $M_8/\text{kg}$                   | 4.20E+03 | 5.10E+03 | 21.48 | 4.37E+03 | 3.97  | 4.11E+03 | 2.17  | 4.10E+03 | 2.31  |
| $M_9/\text{kg}$                   | 4.20E+03 | 4.65E+03 | 10.68 | 4.40E+03 | 4.65  | 4.28E+03 | 1.87  | 4.29E+03 | 2.23  |
| $M_{10}/\text{kg}$                | 4.20E+03 | 4.20E+03 | 0.01  | 4.20E+03 | 0.04  | 4.20E+03 | 0.07  | 4.20E+03 | 0.08  |
| $K_1/\text{kN} \cdot \text{m}$    | 5.00E+03 | 6.83E+03 | 36.66 | 6.70E+03 | 34.05 | 4.95E+03 | 1.06  | 5.03E+03 | 0.54  |
| $K_2/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.02E+03 | 0.40  | 5.25E+03 | 5.02  | 4.95E+03 | 0.95  | 5.04E+03 | 0.87  |
| $K_3/\text{kN} \cdot \text{m}$    | 5.00E+03 | 6.72E+03 | 34.44 | 6.30E+03 | 25.91 | 5.05E+03 | 0.90  | 5.43E+03 | 8.61  |
| $K_4/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.89E+03 | 17.71 | 5.30E+03 | 6.06  | 5.01E+03 | 0.27  | 5.31E+03 | 6.18  |
| $K_5/\text{kN} \cdot \text{m}$    | 4.00E+03 | 4.09E+03 | 2.36  | 5.05E+03 | 26.31 | 4.01E+03 | 0.36  | 3.98E+03 | 0.62  |
| $K_6/\text{kN} \cdot \text{m}$    | 4.00E+03 | 4.51E+03 | 12.75 | 4.87E+03 | 21.83 | 3.93E+03 | 1.82  | 3.76E+03 | 5.97  |
| $K_7/\text{kN} \cdot \text{m}$    | 4.00E+03 | 4.37E+03 | 9.23  | 4.07E+03 | 1.86  | 3.94E+03 | 1.57  | 3.93E+03 | 1.68  |
| $K_8/\text{kN} \cdot \text{m}$    | 4.00E+03 | 5.47E+03 | 36.64 | 3.94E+03 | 1.44  | 4.00E+03 | 0.04  | 3.96E+03 | 0.95  |
| $K_9/\text{kN} \cdot \text{m}$    | 3.00E+03 | 3.20E+03 | 6.60  | 3.29E+03 | 9.79  | 2.96E+03 | 1.35  | 2.97E+03 | 1.17  |
| $K_{10}/\text{kN} \cdot \text{m}$ | 3.00E+03 | 3.10E+03 | 3.38  | 3.04E+03 | 1.42  | 2.98E+03 | 0.52  | 2.98E+03 | 0.51  |
| $\alpha$                          | 1.09E-02 | 1.57E-02 | 44.55 | 8.97E-03 | 17.57 | 1.21E-02 | 11.07 | 1.33E-02 | 22.16 |
| $\beta$                           | 1.84E-01 | 1.73E-01 | 5.62  | 1.69E-01 | 8.09  | 1.85E-01 | 0.92  | 1.85E-01 | 0.51  |

注：表中误差均为百分比相对误差%。

表2.14 5%噪声下各算法的模拟识别结果误差对照表

|                   | PSO   | CLPSO | DE   | SCE  |
|-------------------|-------|-------|------|------|
| Mean Err- $m$ (%) | 15.60 | 12.37 | 0.85 | 2.69 |
| Max Err- $m$ (%)  | 45.26 | 26.17 | 2.17 | 8.11 |
| Mean Err- $k$ (%) | 16.02 | 13.00 | 0.88 | 2.71 |
| Max Err- $k$ (%)  | 36.66 | 26.41 | 1.82 | 8.61 |
| Mean Err- $c$ (%) | 10.00 | 6.09  | 0.86 | 2.81 |
| Max Err- $c$ (%)  | 28.96 | 11.07 | 1.87 | 9.16 |

注：表中误差均为百分比相对误差%。

表2.15 质量未知，10%噪声下，PSO，CLPSO，DE，SCE 的模拟识别对照结果

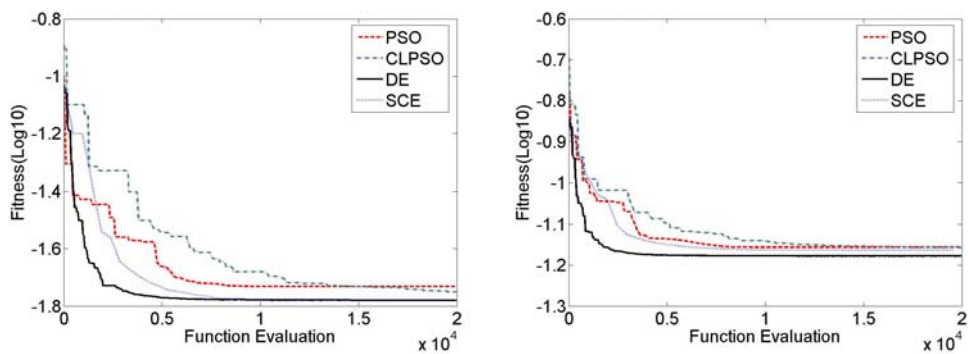
| 参数                                | 真实值      | PSO      |       | CLPSO    |       | DE       |       | SCE      |       |
|-----------------------------------|----------|----------|-------|----------|-------|----------|-------|----------|-------|
|                                   |          | 识别值      | 误差    | 识别值      | 误差    | 识别值      | 误差    | 识别值      | 误差    |
| $M_1/\text{kg}$                   | 6.00E+03 | 6.00E+03 | 0.04  | 6.13E+03 | 2.24  | 5.98E+03 | 0.36  | 6.85E+03 | 14.18 |
| $M_2/\text{kg}$                   | 6.00E+03 | 7.80E+03 | 29.98 | 7.57E+03 | 26.17 | 6.19E+03 | 3.12  | 6.63E+03 | 10.58 |
| $M_3/\text{kg}$                   | 6.00E+03 | 8.60E+03 | 43.38 | 7.28E+03 | 21.36 | 6.19E+03 | 3.23  | 6.63E+03 | 10.49 |
| $M_4/\text{kg}$                   | 6.00E+03 | 6.83E+03 | 13.91 | 7.46E+03 | 24.30 | 6.02E+03 | 0.40  | 5.71E+03 | 4.78  |
| $M_5/\text{kg}$                   | 6.00E+03 | 4.38E+03 | 26.97 | 6.65E+03 | 10.87 | 5.97E+03 | 0.55  | 6.05E+03 | 0.91  |
| $M_6/\text{kg}$                   | 4.20E+03 | 5.30E+03 | 26.09 | 4.87E+03 | 15.98 | 4.00E+03 | 4.76  | 4.07E+03 | 3.14  |
| $M_7/\text{kg}$                   | 4.20E+03 | 7.14E+03 | 69.99 | 4.24E+03 | 1.05  | 4.15E+03 | 1.29  | 4.64E+03 | 10.42 |
| $M_8/\text{kg}$                   | 4.20E+03 | 6.15E+03 | 46.41 | 4.91E+03 | 16.95 | 4.02E+03 | 4.30  | 4.24E+03 | 0.88  |
| $M_9/\text{kg}$                   | 4.20E+03 | 5.19E+03 | 23.49 | 4.02E+03 | 4.39  | 4.35E+03 | 3.62  | 3.81E+03 | 9.27  |
| $M_{10}/\text{kg}$                | 4.20E+03 | 4.19E+03 | 0.18  | 4.22E+03 | 0.40  | 4.19E+03 | 0.14  | 4.22E+03 | 0.39  |
| $K_1/\text{kN} \cdot \text{m}$    | 5.00E+03 | 3.92E+03 | 21.59 | 5.08E+03 | 1.61  | 4.94E+03 | 1.15  | 5.72E+03 | 14.46 |
| $K_2/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.72E+03 | 14.33 | 5.76E+03 | 15.14 | 4.94E+03 | 1.23  | 5.78E+03 | 15.62 |
| $K_3/\text{kN} \cdot \text{m}$    | 5.00E+03 | 8.46E+03 | 69.12 | 6.32E+03 | 26.39 | 5.20E+03 | 4.07  | 5.50E+03 | 10.08 |
| $K_4/\text{kN} \cdot \text{m}$    | 5.00E+03 | 6.34E+03 | 26.87 | 5.69E+03 | 13.90 | 5.13E+03 | 2.62  | 5.50E+03 | 9.96  |
| $K_5/\text{kN} \cdot \text{m}$    | 4.00E+03 | 2.91E+03 | 27.33 | 5.06E+03 | 26.41 | 4.03E+03 | 0.77  | 3.78E+03 | 5.39  |
| $K_6/\text{kN} \cdot \text{m}$    | 4.00E+03 | 3.44E+03 | 14.01 | 4.84E+03 | 21.10 | 3.81E+03 | 4.84  | 3.85E+03 | 3.70  |
| $K_7/\text{kN} \cdot \text{m}$    | 4.00E+03 | 6.46E+03 | 61.53 | 4.29E+03 | 7.21  | 3.87E+03 | 3.22  | 4.29E+03 | 7.14  |
| $K_8/\text{kN} \cdot \text{m}$    | 4.00E+03 | 5.69E+03 | 42.26 | 4.51E+03 | 12.67 | 3.97E+03 | 0.75  | 3.98E+03 | 0.42  |
| $K_9/\text{kN} \cdot \text{m}$    | 3.00E+03 | 4.28E+03 | 42.55 | 3.10E+03 | 3.35  | 2.92E+03 | 2.70  | 2.88E+03 | 3.89  |
| $K_{10}/\text{kN} \cdot \text{m}$ | 3.00E+03 | 3.14E+03 | 4.76  | 3.07E+03 | 2.26  | 2.97E+03 | 0.92  | 2.99E+03 | 0.40  |
| $\alpha$                          | 1.09E-02 | 1.25E-02 | 15.11 | 1.04E-02 | 4.79  | 1.30E-02 | 19.61 | 1.26E-02 | 15.58 |
| $\beta$                           | 1.84E-01 | 1.96E-01 | 6.56  | 1.61E-01 | 12.14 | 1.87E-01 | 1.75  | 1.70E-01 | 7.29  |

注：表中误差均为百分比相对误差%。

表2.16 10%噪声下各算法的模拟识别结果误差对照表

|                   | PSO   | CLPSO | DE   | SCE   |
|-------------------|-------|-------|------|-------|
| Mean Err- $m$ (%) | 28.04 | 12.53 | 2.18 | 6.50  |
| Max Err- $m$ (%)  | 69.99 | 27.60 | 4.76 | 14.18 |
| Mean Err- $k$ (%) | 32.43 | 13.37 | 2.23 | 7.11  |
| Max Err- $k$ (%)  | 69.12 | 34.05 | 4.84 | 15.62 |
| Mean Err- $c$ (%) | 37.15 | 7.63  | 2.26 | 6.55  |
| Max Err- $c$ (%)  | 80.21 | 16.10 | 5.90 | 12.29 |


注：表中误差均为百分比相对误差%。




5%噪声下质量未知系统识别收敛曲线

10%噪声下质量未知系统识别收敛曲线


图2.13 质量未知系统中各算法识别目标函数收敛曲线图




采用 CLPSO, 10%噪声下 10DOFS 结构系统识别过程



采用 PSO, 10%噪声下 10DOFS 结构系统识别过程



采用 DE, 10%噪声下 10DOFS 结构系统识别过程



采用 SCE, 10%噪声下 10DOFS 结构系统识别过程

图2.14 质量未知系统中 10%噪声干扰下各算法参数部分的典型收敛曲线图

在本系列的数值模拟试验中，输入输出均遭受了不同程度的噪声污染。因而识别结果的相对误差必然有所上升。

表 2.13 和 表 2.15 结果中显示，全局搜索性能较差的 PSO 算法在对质量未知结构系统的物理参数识别中，出现了较大误差。其中，5% 噪声干扰下识别的质量和刚度的平均相对误差分别达到 15.6% 和 16.02%；在 10% 噪声干扰下，质量和刚度的平均相对误差分别达到更是达到了 28.04% 和 32.43%。个别参数的最大误差甚至达到 80.21%。从目标函数收敛过程中可以看出，当目标函数计算到 7000 次左右时，PSO 算法便已陷入局部最优解。后期的变异策略无法再为算法提供更优的子代。因而，在参数部分的收敛曲线中，PSO 算法呈现水平直线。

而 CLPSO 算法在本算例中，平均相对误差均控制在 12% 左右，且随着噪声干扰水平的加大，识别结果的误差上升幅度较小。这一现象表明，CLPSO 算法具有良好的抗噪性。误差的产生主要来自于质量未知系统识别问题高维多峰的特点。从目标函数收敛曲线上可以发现，CLPSO 算法采用综合学习策略后，算法具有更好的稳健性，即便在计算的末期，算法仍可产生新的优秀子代，使目标函数值逐步接近最优值。不过，由于算法本身计算效率较低，在 20000 的目标函数

计算次数的限制下, CLPSO 算法仍然造成了相当的误差。在 5% 噪声干扰下, 最大误差达到 26%, 在 10% 噪声干扰下, 最大误差达到 34%。

SCE 算法在质量未知系统的物理参数识别中, 展现了较高的识别效率。计算速度仅次于 DE 算法。在计算精度上, 在 5% 噪声干扰下, 质量和刚度的平均相对误差分别达到 2.69% 和 2.71%; 在 10% 噪声干扰下, 质量和刚度的平均相对误差分别达到 6.50% 和 7.11%。从识别的典型收敛曲线上不难发现, 相较于 PSO 算法和 CLPSO 算法的曲线均匀分布, SCE 算法的各条参数曲线具有明显的收敛倾向。并且, 在计算的后期, 算法仍然在产生新的优秀子代, 即随着目标函数计算次数的增加, 算法识别结果仍有提高精度的可能。

在本次算例中, 性能最为优越的为 DE 算法。在 5% 噪声干扰下, 质量和刚度的平均相对误差分别为 0.85% 和 0.88%; 在 10% 噪声干扰下, 质量和刚度的平均相对误差分别为 2.18% 和 2.23%, 最大误差也仅为 5.90%。这一结果胜过其他所有算法。不仅如此, 在计算效率上, DE 算法也表现出极高的收敛效率。在目标函数计算了 4000 次左右时, DE 算法已经收敛至最优值附近。

## 2.5 本章小结

本章通过将结构系统识别问题转化成优化问题, 提出了基于 SCE 算法的结构系统识别方法。SCE 算法采用了 CCE 算法的竞争进化方式来确保每个个体信息的充分利用, 并通过洗牌重组复合型的方式保证算法在全局解空间上的遍历搜索。SCE 算法使用方便, 使用时只需调整一个参数。

通过考察不同工况下的数值模拟识别, 本文验证了 SCE 算法在结构系统识别问题中的适用性。数值模拟结果说明, 该方法对结构输出信息的可测数目没有特别要求, 质量已知或质量未知时均可对系统做出正确识别。即使所有的结构特性均未知, 该方法仍能在存在噪声干扰的情况下得到很好的识别结果。同时, SCE 方法算法简洁易于实现且计算时占用资源和内存较少。

另外, 本章通过与其他几种智能算法, 如 PSO 算法、CLPSO 算法和 DE 算法等, 进行了比较分析, 结果表明: 几种算法中, DE 算法和 SCE 算法识别效果最佳, CLPSO 算法次之, PSO 算法效果最差。特别是在质量未知、测量信息不完备且输出受到 10% 噪声干扰下的情况, DE 算法和 SCE 算法表现出很好的优势。SCE 算法作为新引入结构系统参数识别的算法, 计算效率和识别精度上基本与 DE 算法相接近, 表现出良好的鲁棒性和抗噪性, 同时积极的全局搜索策略和通过定时洗牌而提高的信息利用效率也在数值分析中得以充分体现。

## 第3章 基于SCEM算法的参数不确定性分析方法

### 3.1 引言

实际工程中，测量信息和结构分析模型均存在一定的不确定性，从而导致结构系统识别参数也具有一定的不确定性。

本章将分析研究结构参数识别的不确定性来源及分析方法，利用 Vrugt 等基于 SCE 算法开发的 SCEM 算法（Shuffled Complex Evolution Metropolis）对结构系统识别问题进行参数不确定性分析。

### 3.2 结构参数识别的不确定性来源及分析方法

#### 3.2.1 结构参数识别的不确定性来源<sup>[71]</sup>

在大量的工程结构中，由于材料的误差或结构在制造安装过程中的误差，使结构的物理和几何参数带有一定程度的不确定性，从而使结构的刚度、质量和阻尼成为不确定参数的函数。而对于结构健康监测而言，结构的输入输出也存在着不同程度的噪声干扰。如何正确估计这些不确定参数对结构的振动特性和响应特性的影响，对于工程设计实践具有十分重要的指导意义。而为了正确估计这些不确定性参数，首先就必须分析和研究结构参数识别的不确定性来源问题。

##### (1)、资料或信息误差问题

A、结构输入输出的信息空间随机分布特性与数学期望(均值)的代表性问题。例如结构响应信息的信息空间随机分布的变动性，导致每次试验测量的加速度时程信息误差的变动性。

B、输入输出信息的时程随机分布特性的均化问题。输入输出信息的时程变化总是连续的，而计算时的采样总是离散的，从而导致信息在时段内的均化，并带来模型计算的误差。

C、测量仪器自身的观测误差。

##### (2)、模型不确定性问题

A、现实的工程结构中，材料、施工方法等的不确定性，造成结构物中的物

理或几何参数都具有非均匀性和异质性。因此现有模型的框架结构不可能真实地体现现实中的大型工程结构模型。

B、大型工程结构内部各物理参数之间的确定性联系很复杂，而模型往往用大量简化的有限元模型去近似地模拟其联系。例如，目前所有的模型还无法真实准确地模拟结构的阻尼系数。

C、许多模型没有考虑环境变化对结构物理参数带来的影响。例如，大多数模型均不考虑结构物理参数随时间历程发生的变化。

D、真实的结构物往往带有不同程度的非线性。现有模型对非线性过程的模拟还无法精细化。

### (3)、结构参数的不确定性

A、在结构物理参数的识别模型中，模型参数反映了结构模型的物理特征，既有物理意义，又有推理概化的成分。例如阻尼，目前并没有具体测量真实值的实际方法，参数本身的衡量便带有不确定性。

B、优选意义下的“最优参数”依赖于所选用的优化方法与率定目标，不同的优化方法与率定目标可能得到多组不同的结果。

C、目前多数模型参数只能由设计资料和参数识别推理得到。而设计资料为估计值，与实际施工成果的情况并不一定吻合。而参数识别依赖于输入输出的测量信息。这些信息本身误差不可避免，因此，利用观测数据进行模型参数识别时所获得的“最优解”必然存在着不确定性。

## 3.2.2 结构参数识别的不确定性研究方法

第二章的数值分析中，由于测量信息不确定性的存在，在采用 PSO 算法、CLPSO 算法、DE 算法和 SCE 等算法进行结构系统模型物理参数优选时，总是可以搜索到几组或者很多组不同的参数值，使得模型的目标函数(比如加速度时程的均方根误差)达到一样或者几乎一样的水平，即所谓的异参同效(equifinality)现象。异参同效现象的存在使得在最终选择一组最优参数值时具有很大的不确定性，同时也给结构物理参数识别产生的模型输出带来很大的不确定性。

此外，不同的结构系统物理参数的识别模型具有不同的结构，但都是对现实工程的结构识别的概化，因此还存在着模型结构的不确定性。这些不确定性都加大了物理参数识别的难度，增加了利用结构物理参数识别进行结构健康监测的风险，所以，研究结构系统物理参数的识别模型的不确定性问题具有十分重要的理论与现实意义，正逐步成为近年来系统健康监测研究的热点问题。

目前，针对土木结构的系统识别不确定性，主要采用统计的系统识别方法。

其中,最主要统计系统识别方法主要包括 Bayes 模型修正、随机有限元模型修正和马尔可夫链蒙特卡罗方法。

### 随机有限元模型修正<sup>[70]</sup>

在模型修正中必须考察根据有限观测数据所得到的系统模型参数的统计特性,而这可以通过对模型参数和观测数据摄动的随机模拟来实现。正是基于这种思想,一些学者建立了结构损伤识别的随机有限元模型修正方法。但是在很多时候,在求解摄动有限元模型时,计算各种协方差矩阵非常困难。

### Bayes模型修正<sup>[70]</sup>

Bayes 模型修正方法利用了统计推断中著名的 Bayes 原理,将确定性的结构模型嵌入一组可能的概率模型中,使结构模型能够预测模型和观测的不确定性。这种方法中的模型不确定性并不是可重复事件,因此,方法中将概率解释为基于非完整信息的不确定性推理的多值逻辑关系。为了定量描述一组模型的不确定性,基于给定信息使用概率分布可以给出每一个模型不确定性的度量。

Bayes 模型修正的基本思想就是:结构模型的不确定性由模型参数的概率分布定量描述,根据观测数据可以更新每个可能模型描述的结构初始不确定性,也就是说,根据观测数据给定的信息可以修正不同初始模型的相对不确定性。

Bayes 模型修正方法与经典统计推断方法的最大不同在于充分利用了有关结构模型和预测响应的先验信息,实质上是通过结构响应的观测把模型参数的先验概率密度函数  $p_0(\theta|M)$  转化为模型参数的后验概率密度函数  $p_D(\theta)$ 。

例如,如果  $h(\theta)$  是所选择的结构响应,根据全概率定理,度量系统预测性能的代价函数就可以表示成

$$R_D = \int h(\theta)p_D(\theta)d\theta \quad (3.1)$$

由于土木工程结构模型修正问题的复杂性,待识别参数后验概率流形的维数较高,采用一般的随机抽样策略导致的计算复杂性和计算时间令人无法接受。如何使用高效的搜索策略来准确刻画后验概率密度函数  $p_D(\theta)$  的流形,是 Bayes 统计模型修正法能否突破计算复杂性“瓶颈”的关键。

### 马尔可夫链蒙特卡罗方法<sup>[72]</sup>

#### (1) 蒙特卡罗模拟

蒙特卡罗模拟(Monte Carlo Simulation)也称为随机模拟、统计试验,其理论基础是概率统计,其基本手段是随机抽样。蒙特卡罗模拟要求进行大量重复抽样,计算量非常大。随着现代计算机的发展,它在实际中得到日益广泛的应用。蒙特卡罗模拟可避免决策分析过程中不确定因素之间的相互干扰而使决策发生偏差情况的发生,使在复杂情况下的决策分析更为合理和准确。蒙特卡罗模拟可以直接处理决策因素的不确定性:将不确定性以概率分布的形式表示,建立决策的随



机模型,对随机变量抽样试验,模拟结果分析,不仅能得出决策目标输出、期望值等多种统计量,也可给出概率分布。

就数学特征而言,随机模拟方法可追溯到 1777 年法国学者布冯随机投针实验求值的问题。1946 年,为解决原子弹研制工作中,裂变物质的中子随机扩散问题,美国数学家冯·诺伊曼和乌拉姆等提出蒙特卡罗模拟方法。由于当时工作是保密的,就给这种方法起了一个代号叫蒙特卡罗,即摩纳哥的一个赌城的名字。现在,蒙特卡罗已成为数字模拟试验的专用术语。由于此方法在中子的随机行为和飞机轰炸任务的效能研究中应用非常成功,所以被普遍传播,成为一个重要的运筹学技术。

蒙特卡罗模拟的实质是利用服从某种分布的随机数来模拟现实系统中可能出现的随机现象。由于每次模拟试验只能描述所考察系统可能出现的一次情况,在进行了大量次数的模拟试验后,根据概率论中心极限定理和大数定理,即可得出有价值的统计结论。由于计算机的发展,蒙特卡罗模拟已成为一种实用有效的决策分析方法。

根据大数定理,设  $x_1, x_2, \dots, x_n$  是  $n$  个独立的随机变量,若它们来自同一个母体的相同分布,且具有相同的有限均值和方差,分布用  $\mu$  和  $\sigma^2$  表示,则对于任意  $\varepsilon > 0$ , 有

$$\lim P\left(\left|\frac{1}{n} \sum_{i=1}^n x_i - \mu\right| \geq \varepsilon\right) = 0 \quad (3.2)$$

蒙特卡罗法是从同一母体中抽取简单子样来做抽样试验。根据简单子样的定义,  $x_1, x_2, \dots, x_n$  是  $n$  个具有相同分布的独立随机变量,当  $n$  足够大时,  $\sum x_i/n$  以概率 1 收敛于  $\mu$ , 而频率  $m/n$  以概率 1 收敛于  $P(A)$ , 这就是蒙特卡罗法的理论基础。

使用蒙特卡罗方法必须解决从母体中抽取简单子样的问题。通常,把从有已知分布的母体中产生的简单子样,称为由已知分布的随机抽样,简称为随机抽样。从  $[0,1]$  区间上有均匀分布的母体中产生的简单子样称为随机数序列  $(r_1, r_2, \dots, r_n)$ , 而其中的每一个个体称为随机数,产生随机数的方法很多,如随机数表法、物理方法、数学方法等。在计算机上用数学方法产生随机数,是目前使用较广,发展较快的一种方法,它是利用数学递推公式来产生随机数,通常把这种随机数称为伪随机数。因为这种办法具有半经验的性质,所以得出的数只是近似地具备随机性质。

由于蒙特卡罗模拟是通过大量简单重复抽样来实现,受条件限制影响较小,故该方法简单灵活,易于实现和改进,不受状态函数是否非线性、随机变量是否非正态分布等条件限制,只要模拟次数足够多就可得到比较精确的统计特征值。

且模拟估计的标准误差及收敛速度与所解决问题的维数具有较强的独立性,适用于多变量、多时间阶段的高维问题,并且模拟误差容易确定。

蒙特卡罗模拟的局限性:

(a) 对一些复杂问题,要想达到较高的模拟精度需要进行较多的模拟次数,消耗大量的计算资源,否则就可能产生较大的误差。

(b) 结果给出的是具有概率特征的置信区一,即得到统计层面上近似的结果(趋势),而不是对于特定结果的精确的数据描述

## (2) 马尔可夫链蒙特卡罗 (MCMC) 方法

马尔可夫链-蒙特卡罗方法 (Markov Chain Monte Carlo, 简称 MCMC) 是与统计物理有关的一类重要随机方法,广泛使用在贝叶斯推断和机器学习中。广义贝叶斯体系的一个基本目标是计算高维概率分布  $P(x_1, x_2, \dots, x_n)$  的期望值。其中  $x_i$  是模型参数或隐变量或观测数据。MCMC 涉及的两个基本思想比较简单。第一个基本思想是采用蒙特卡罗方法估计期望值

$$E(f) = \sum_{x_1, \dots, x_n} f(x_1, x_2, \dots, x_n) P(x_1, x_2, \dots, x_n) \approx \frac{1}{T} \sum_{t=1}^T f(x_1^t, x_2^t, \dots, x_n^t) \quad (3.3)$$

对于较大的  $T$ , 根据  $P(x_1, x_2, \dots, x_n)$  采样得到  $x_1^t, x_2^t, \dots, x_n^t$ 。要从这个分布中采样,就要用第二个基本思想,即构建一条马尔可夫链,使其极限分布为  $P$ 。然后对这条马尔可夫链模拟并对其极限分布采样。MCMC 只是对理想的贝叶斯推断过程的一种近似,依赖于给定样本  $D$  计算出的  $P(E(f)|D)$  值。

在上个世纪的最后十年,在计算统计学领域,出现了MCMC方法的研究热潮,一些因为计算量太大而被认为是不可解决的问题都用MCMC方法得到了解决,获得了令人满意的结果。现在MCMC方法在理论物理、人工智能、金融统计、电信等领域的应用方面均取得了很大的成功<sup>[73]</sup>。

MCMC 法可以在参数空间中,通过一个固定的概率分布,以稳定的频率产生最优解。对于任何一个给定的问题,可以通过根据情况变换采样器或者概率分布,来确保算法能够收敛到目标概率分布,从而得到一个可行的 MCMC 采样器。

MH 法(Metropolis Hastings Algorithm),是最早也是应用最广泛的 MCMC 采样器。MH 法需要选择一个合适的概率分布来定义马尔科夫链中的传递规则。如果选择的概率分布与目标概率分布非常接近,产生的马尔科夫链就会很快地搜寻参数空间,并且很快得到目标样本。反之,马尔科夫链就会收敛的非常慢,并且即使目标概率分布已经得到,也无法确认是否收敛。

在参数识别中,对于参数空间中高概率区域的先验知识一般是缺乏的,而采用 MCMC 法时,预先提出的概率分布就会充满初始不确定性,从而使得收敛非

常缓慢。

因此，使用 MCMC 法，就必须设计一个合适的采样器，使得算法不仅能在参数空间中快速收敛到全局最优解，而且能够充分兼顾空间中低后验概率密度区，防止早熟现象的产生。

Vrugt 等人在 SCE 算法的基础上开发了一种叫做 SCEM (Shuffled Complex Evolution MeortpoliS algorithm) 的高效的自适应 MCMC 进化算法。该算法结合了 Metropolis 算法、控制随机搜索、生物竞争进化以及分区混和洗牌的优点，在进化过程中根据马尔可夫链获得的历史样本信息自适应的调整转移概率，从而使算法快速的收敛到后验分布，更加适合模型具有较多参数的情况。SCEM 算法的退火特性避免了算法收敛到单一的最优点，分区间的信息交换避免算法收敛到参数空间的局部最优区间，使得结果更加可靠。

### 3.3 SCEM算法介绍

2003 年，Jasper A. Vrugt 和 Hoshin V. Gupta<sup>[59]</sup> 注意到，对于水域参数的自动率定算法，不能仅限于寻找单一最优参数解，而应该针对现实情况，对参数做出不确定性分析。因为测量误差和模型本身无法真实代表现实系统，参数识别总是有比较大的误差，因此，在参数空间中找到一个能很好模拟现实情况的最优点基本是不可能的。甚至，在预先给定的参数空间中，可能根本就不存在这样一个很好的收敛区域。

虽然 SCE 全局最优算法可以有效地在参数空间中找到全局最优点，但是，在寻找单一的最优参数集时，有时也是很困难，甚至不可能的。而哪怕是找到的这些参数，也可能和测量值相差甚远。而这些糟糕的识别参数，可能会为后续模型计算带来更大的不确定性。

为了解决以上问题，Jasper A. Vrugt 和 Hoshin V. Gupta 在 SCE 优化算法的基础上，利用了 MCMC 法的思想，提出了一种新型的 SCEM 算法。

#### 3.3.1 参数后验概率密度计算方法

SCEM 算法中，采用了参数估计中参数后验概率密度的计算方法。这里，假设模型的数学结构是基本预先确定下来并且固定不变的。故，设

$$\hat{y} = \eta(\xi|\theta) + e \quad (3.4)$$

其中  $\hat{y}$  为模型估计出的  $N \times 1$  维向量， $\xi$  为输入变量的  $N \times n$  维矩阵， $\theta$  包

含  $n$  个未知参数的向量,  $y$  为样本数据,  $e$  是一个具有零均值和固定方差的独立误差随机向量。

在求解系统识别问题的方法中, 优化算法的目标通常设定为找到最合适解  $\theta$  使得误差向量  $E(\theta) = \hat{y}(\theta) - y = \{e_1(\theta), e_2(\theta), \dots, e_N(\theta)\}$  尽可能地接近于零。

那么, 有如下优化目标函数

$$\min_{\theta} SLS = \sum_{j=1}^N e_j(\theta)^2 \quad (3.5)$$

如果假设残差相互独立且服从拽数幂分布, 那么据文献<sup>[15]</sup>, 下式成立:

$$p(\theta|y, \gamma) = \left[ \frac{\omega(\gamma)}{\sigma} \right]^N \exp \left[ -c(\gamma) \sum_{j=1}^N \left| \frac{e_j(\theta)}{\sigma} \right|^{2/(1+\gamma)} \right] \quad (3.6)$$

其中,  $p(\theta|y, \gamma)$  为参数  $\theta$  后验概率密度函数

$$\omega(\gamma) = \frac{\{\Gamma[3(1+\gamma)/2]\}^{1/2}}{(1+\gamma)\{\Gamma[(1+\gamma)/2]\}^{3/2}} \quad (3.7)$$

$$c(\gamma) = \left\{ \frac{\Gamma[3(1+\gamma)/2]}{\Gamma[(1+\gamma)/2]} \right\}^{1/(1+\gamma)} \quad (3.8)$$

在上式中,  $\gamma$  表示了残差的分布模型。若  $\gamma=0$ , 则表示残差服从正态分布; 若  $\gamma=1$ , 则为双指数分布; 若  $\gamma=-1$ , 则为均匀分布。

如果假设先验概率密度函数  $p(\theta|y, \gamma) \propto \sigma^{-1}$

则  $p(\theta|y, \gamma) \propto [M(\theta)]^{-N(1+\gamma)/2}$  成立。

其中,  $M(\theta) = \sum_{j=1}^N |e_j(\theta)|^{2/(1+\gamma)}$

以上, 说明了参数估计中参数后验概率密度的计算方法。

### 3.3.2 SCEM算法基本原理

SCEM 算法是一种自适应 MCMC 采样器。算法中采用的马尔可夫链策略使用后验概率分布来抽取样本, 并且每一代的样本抽取仅仅只和上一代样本和转移概率分布有关。而 MCMC 采样器在构造马尔可夫链上, 具有良好的各态历经性和收敛性。在实际应用中, 这意味着, 采用马尔可夫链法抽取的样本将会按照目

标后验概率密度按照稳定的频率进行分布。从这些产生的伪随机点中，可以提取所有关心的概率特性，例如概率密度函数和后验概率分布的随机特征值等等。

SCEM 算法改编自 SCE 单目标优化算法，并结合了 SCE 算法自身收敛快、解空间信息探索能力强等优点，融合了控制随机搜索，竞争进化，和复合洗牌等原理，对 MCMC 采样器中的预设分布进行持续的进化，并将采样器最终演化为目标后验概率分布。

SCEM 算法中采用了 Metropolis-annealing 策略，从而避免 SCEM 算法像 SCE 算法一样向单个区域收敛的趋势，同时，信息交换（洗牌）允许算法向更好的解集区域进行重点采样。

采用 SCEM 算法进行参数不确定性分析时，只需要设置参数的初始范围，通过算法自身的运行寻找到各参数的高后验概率密度区域，以算法收敛后的参数进行预报，从而进行参数的不确定性分析与预报不确定性区间计算。

### 3.3.3 SCEM算法流程

为了更好地理解 SCEM 算法的本质和实现步骤，现将 SCEM 算法的实现流程介绍如下。

SCEM算法的外围算法流程图如图 3.1 所示。该全局流程将完成除演化每一个马尔可夫链序列以外的工作。包括采样、混合、洗牌、排序等工作。

SCEM 算法流程介绍如下

*Step1* 初始化。选择样本群大小参数  $s$  和复合形数目  $q$ 。那么每个复合形中样本数目  $m = s/q$ ;

*Step2* 产生  $s$  个样本，计算每个样本点的后验概率密度;

*Step3* 将样本点按后验概率密度递减方式排序，存储在数组  $D[1:s, 1:(n + 1)]$  中，其中  $n$  为估计参数个数，数组中最右一列存储各样本点的后验概率密度;




图3.1 SCEM 算法流程示意图

Step4 初始化  $q$  个并行序列  $S^1, S^2, \dots, S^q$  的起始点, 即  $S^k$  为  $D[1:s, 1:(n+1)]$ , 此处  $k = 1, 2, \dots, q$ 。将  $D[1:s, 1:(n+1)]$  划分为  $q$  个复合形  $C^1, C^2, \dots, C^q$  每个复合形含有  $m$  个样本点, 使得第一个复合形包含次序为  $q(j-1)+1$  的点, 第二个复合形包含次序为  $q(j-1)+2$  的点, 等等, 此外  $j = 1, 2, \dots, m$ ;

Step5 选择参数  $L, T, T_{\min}, c_n$ 。对于每个复合形  $C^k$ , 调用 SEM 算法, 运行  $L$  次;

*Step6* 将所有复合形放入数组  $D[1:s, 1:(n + 1)]$ ，并将各样本点依后验概率密度递减排列；

*Step7* 检查 Gelman - Rubin (GR) 收敛准则，如果符合收敛条件则计算结束，否则转第 4 步。

在 SCEM 算法中，大量初始随机样本点的使用，可以使算法更好地搜索解空间，从而加大寻找到最优目标概率分布的可能。采用大量不同出发点的平行序列使得各自的搜索更加独立，从而可以允许待优化的问题具有更多的局部最优区域，同时也才可能使用启发式测试来判断序列是否收敛到极限分布。复杂形的使用，则确保能够获取演化过程中每一个单独序列所搜索到的空间的信息。这些复杂形的洗牌则通过全局信息共享，使得各个平行序列更能收敛到极限分布。

SCEM 算法采用的 GR 收敛准则是 1992 年由 Gelman 和 Rubin 提出的数量收敛准则，该准则主要通过马尔可夫链中或马尔可夫链间的方差计算得到。

$$\sqrt{SR} = \sqrt{\frac{g-1}{g} + \frac{q+1}{q \cdot g} \frac{B}{W}} \quad (3.9)$$

其中， $g$  是马尔可夫链的循环次数， $B$  是  $q$  个马尔可夫链均值的方差， $W$  是各个参数链内方差的均值。因此，当  $\sqrt{SR}$  接近于 1 的时候，马尔可夫链就接近于收敛。然而，因为  $\sqrt{SR}$  很难到达 1 这个数值，Gelman 和 Rubin 建议当数值小于 1.2 的时候，就认为马尔可夫链已经收敛于稳定的概率分布了。

### 3.3.4 SEM核心算法

SCEM算法的核心算法为序列演化算法 (Sequence Evolution Metropolis, 简称SEM算法) [59]。

如同在全局算法流程中的第五步中提到的，SEM算法在每一个平行的马尔可夫链序列  $S^k$  中，通过使用复杂形  $C^k$  中的信息，使用一个自适应的转移概率分布，产生新的候选点。SEM的算法流程图如图 3.2 所示。




图3.2 SEM 算法流程示意图

SEM 算法如下:

Step1 计算  $C^k$  中各参数均值  $\mu^k$  和协方差矩阵  $\Sigma^k$ , 并将复合形  $C^k$  中  $m$  个样本点依后验概率密度递减排列;



Step2 计算  $\alpha^k$ , 即  $C^k$  中  $m$  个点与  $S^k$  中最后产生的  $m$  个点的平均后验概率密度比值。

Step3 如果  $\alpha^k \leq T$ ,  $T$  为预先定义的相似度比例, 则根据  $\theta^{(t+1)} = N(\theta^{(t)}, c_n^2 \Sigma^k)$  产生后代  $\theta^{(t+1)}$ , 其中  $\theta^{(t)}$  具有后验概率密度  $p(\theta^{(t)}|y)$  且只依赖  $\theta^{(t-1)}$ ,  $c_n = 2.4 / \sqrt{n}$ , 转至 Step5, 否则转 Step4;

Step4 根据  $\theta^{(t+1)} = N(\mu^k, c_n^2 \Sigma^k)$  产生后代  $\theta^{(t+1)}$ ;

Step5 计算  $p(\theta^{(t+1)}|y)$ , 如果  $\theta^{(t+1)}$  在可行域之外, 令  $p(\theta^{(t+1)}|y)$  为 0;

Step6 计算比率  $\Omega = p(\theta^{(t+1)}|y) / p(\theta^{(t)}|y)$ , 并计算  $Z$ 。Z 为在区间[0,1]中按均匀分布产生的随机数;

Step7 如果  $Z \leq \Omega$ , 接受产生的后代, 否则令  $\theta^{(t+1)} = \theta^{(t)}$ ;

Step8 将  $\theta^{(t+1)}$  添加到  $S^k$ ;

Step9

(a) 利用  $S^k$  中后一半的点, 计算接受率系数  $T^k$  ( $T^k$  计算公式为  $S^k$  中接受的后代个数除序列长度);

(b) 如果  $T^k < T_{\min}$  就以  $\theta^{(t+1)}$ , 代替  $C^k$  中最坏的点, 否则, 转(c);

(c) 如果  $T^k \geq T_{\min}$  且  $Z \leq \Omega$ , 取代  $C^k$  中最优点。

Step10 重复 Step1~8L 次。

在 SEM 算法中, 候选点是采用自适应的多维正态转移概率分布来产生的。该转移概率的期望值等于当前序列本子代的均值; 协方差均值与复杂形  $k$  中的  $m$  点的数据结构相对应。

然而, 当第  $k$  个序列的最后  $m$  个产生点中, 后验概率密度的均值远小于对应的复杂形  $k$  的  $m$  个点的概率密度均值时, 转移概率分布的期望值将临时转移至复杂形的点的中心位置。SEM 的这个特点 (Step6), 将显著地避免个别序列停滞于局部最优值, 从而大幅度改善序列间的交叉性质。

在产生了一个新的候选点之后, 算法将计算该点处的后验概率密度值。Metropolis-Annealing 准则将被采用, 以验证该点是否应该被留在序列中。

最后, SEM 算法将考虑目前复杂形  $k$  中的哪一个点应该被取代。当候选点被接受时,  $\theta^{(t+1)}$  将自动取代复杂形中的点。

然而, 当候选点被否决后,  $\theta^{(t+1)}$  自动取代复杂形  $k$  中最差的点的时候,  $\theta^{(t+1)}$  后验概率密度值将比复杂形  $k$  中最差点的概率密度值要高。所以, 当  $T^k$  比一些预定义的大数 (例如  $T > 105$ ) 要大时, 将有充分的理由相信转移概率的方差已经

太大了，以至于复杂形  $k$  中仍有一些具有很低概率的点。在这种特殊情况下，将复杂形  $k$  中的最差点替换掉，将有利于序列收敛于目标概率分布。

和传统的 MCMC 采样器相比，SCEM 算法是一种自适应的采样器。它的转移概率分布的期望和方差都是根据序列演化的历史过程中的采样信息来进行更新的。并且，通过大量的试验研究证明，SCEM 算法采用的自适应的转移概率分布产生的序列是各态历经的序列。采样器能渐进地产生和目标概率分布的核心概率特性相同的样本。

### 3.3.5 参数选择

SCEM 算法包含两个需要人工选定的算法参数。

- (1)、复杂形个数（序列数） $q$ ;
- (2)、样本点数  $s$ 。

以上两个参数将共同决定每个复杂形中的点数 ( $m=s/q$ )。

对于非相关或者相关的高斯分布的简单问题，样本点数和复杂形个数可以较小。文献中建议  $s<100$ ， $q<5$  就已经足够了。然而对于待识别的后验概率分布形状比较复杂的问题，文献中建议给出一个相对较大的参数设置，如样本点数  $s>250$ ，大量的平行序列数  $q>10$ 。这样的参数下，算法产生的样本点才能够足够精细地描绘出数据结构复杂的随机性状。

本文中，由于结构系统物理参数识别模型具有非线性多峰值高维的特点，故采用较保守的参数设置。分别为  $q=10$ ， $s=300$ 。

另外，SEM 算法包含三个算法参数。分别为  $L=(m/10)$ ， $T=10^6$ ，以及跳转率  $c_n = 2.4/\sqrt{n}$ 。文献<sup>[59]</sup>中对 SCEM 算法的算法参数进行了灵敏度试验。试验结果表明，这些参数的选值可以在很大的范围内使用。为了简单易用起见，本文中 SEM 参数均采用该参数设置。

## 3.4 基于 SCEM 算法的参数不确定性分析方法

### 3.4.1 算法描述

本章提出的基于 SCEM 算法的参数不确定性分析方法，基于 MCMC 法的概念，构造多条马尔可夫链，对结构模型识别参数进行取样。当马尔可夫链稳定收敛于目标概率分布后，通过对获得的样本点进行随机分析，得到结构模型识别参数的随机特征值和概率特性。

在本章提出的参数不确定性分析方法中, SCEM 算法优化的参数将是转移概率分布的均值和方差。而每一代的转移概率分布均为多维正态概率分布。通过不断地演化, 转移概率分布将逐渐稳定并收敛于目标概率分布。

该方法中对结构模型识别参数的评判将通过计算参数的后验概率密度来实现。在 2.3.1 节中, 通过最小化实测真实结构输出与备选分析模型系统输出之间的误差范数, 将结构参数识别问题转化为一个特定的优化问题, 从而得到一个优化目标函数, 如式 (2.6) 所示。本章将利用式 (2.6) 的目标函数式, 通过 3.3.1 节中的后验概率密度计算方法, 计算每一个粒子点 (参数向量) 上的后验概率密度, 从而为粒子点的选取提供依据。

基于 SCEM 算法的参数不确定性分析方法主要流程如下:

1. 给定初始规模, 定义 SCEM 算法的初始参数, 并随机散布于可行域空间中;
2. 计算每一个点上的后验概率密度值;
3. 划分复合形群体;
4. 采用 SEM 算法进行转移概率分布的演化;
5. 采用 Metropolis-Annealing 策略选取下一子代的点;
6. 进行复合形洗牌;
7. 判别是否满足终止条件, 如是则接步骤 7, 否则回转步骤 2 继续群体的更新;
8. 对马尔可夫链中稳定后的转移概率分布产生的点进行随机分析。

### 3.4.2 数值模型

为了将 SCEM 算法的计算结果与 SCE 算法的计算结果进行对比, 本章采用的数值模型将和图 2.5 中的模型保持一致。

其中, 结构模型特征一致; 在不同工况中, 分别在输入输出中加入 0% 和 10% 零均值高斯白噪声; 并考虑测量信息完备性的影响, 分为输出完全已知 (1~8 层加速度时程信息完全已知) 和输出部分已知 (2、4、8 层加速度可测) 两种情况。同时, 初始值取为 0.5~1.5 倍真实值。

### 3.4.3 质量已知系统的参数不确定性分析

在本类工况中, 假设结构质量已知, 仅对刚度系数和阻尼系数进行不确定性分析。

结构系统动力响应模型可由以下一系列参数完全描述

$$\theta = (k_1, k_2, \dots, k_8; \zeta_1, \zeta_2) \quad (3.10)$$

本节将采用 SCEM 算法对数值结构模型的刚度和阻尼系数不确定性进行分析。SCEM 参数设置如下：在无噪声干扰时，适应值函数计算最大次数= 40000，在有噪声干扰时，适应值函数计算最大次数= 70000（终止条件之一）， $q=10$ （复杂形个数）。

本节设置了 4 个工况。

- 1、 无噪声干扰下，输出信息完全已知的结构物理参数识别。
- 2、 无噪声干扰下，输出信息部分已知的结构物理参数识别。
- 3、 输出信息完全已知的情况下，输出信息受到 10% 噪声干扰的结构物理参数识别。
- 4、 输出信息部分已知的情况下，输出信息受到 10% 噪声干扰的结构物理参数识别。

以上 4 个工况的最终计算结果并列于表 3.1 和表 3.2。表中同时给出了识别的相对误差以及标准偏差。图 3.3 中为四种工况的 SR（Scale-Reduction factor）收敛曲线图。当 SR 值低于 1.2 时，便可认为马尔可夫链已经收敛至极限概率分布。图 3.4 为工况四中各参数马尔可夫链。




图3.3 质量已知情况下四种工况的 SR 曲线收敛示意图

表3.1 无噪声下不同识别方式的模拟识别结果样本随机特征值

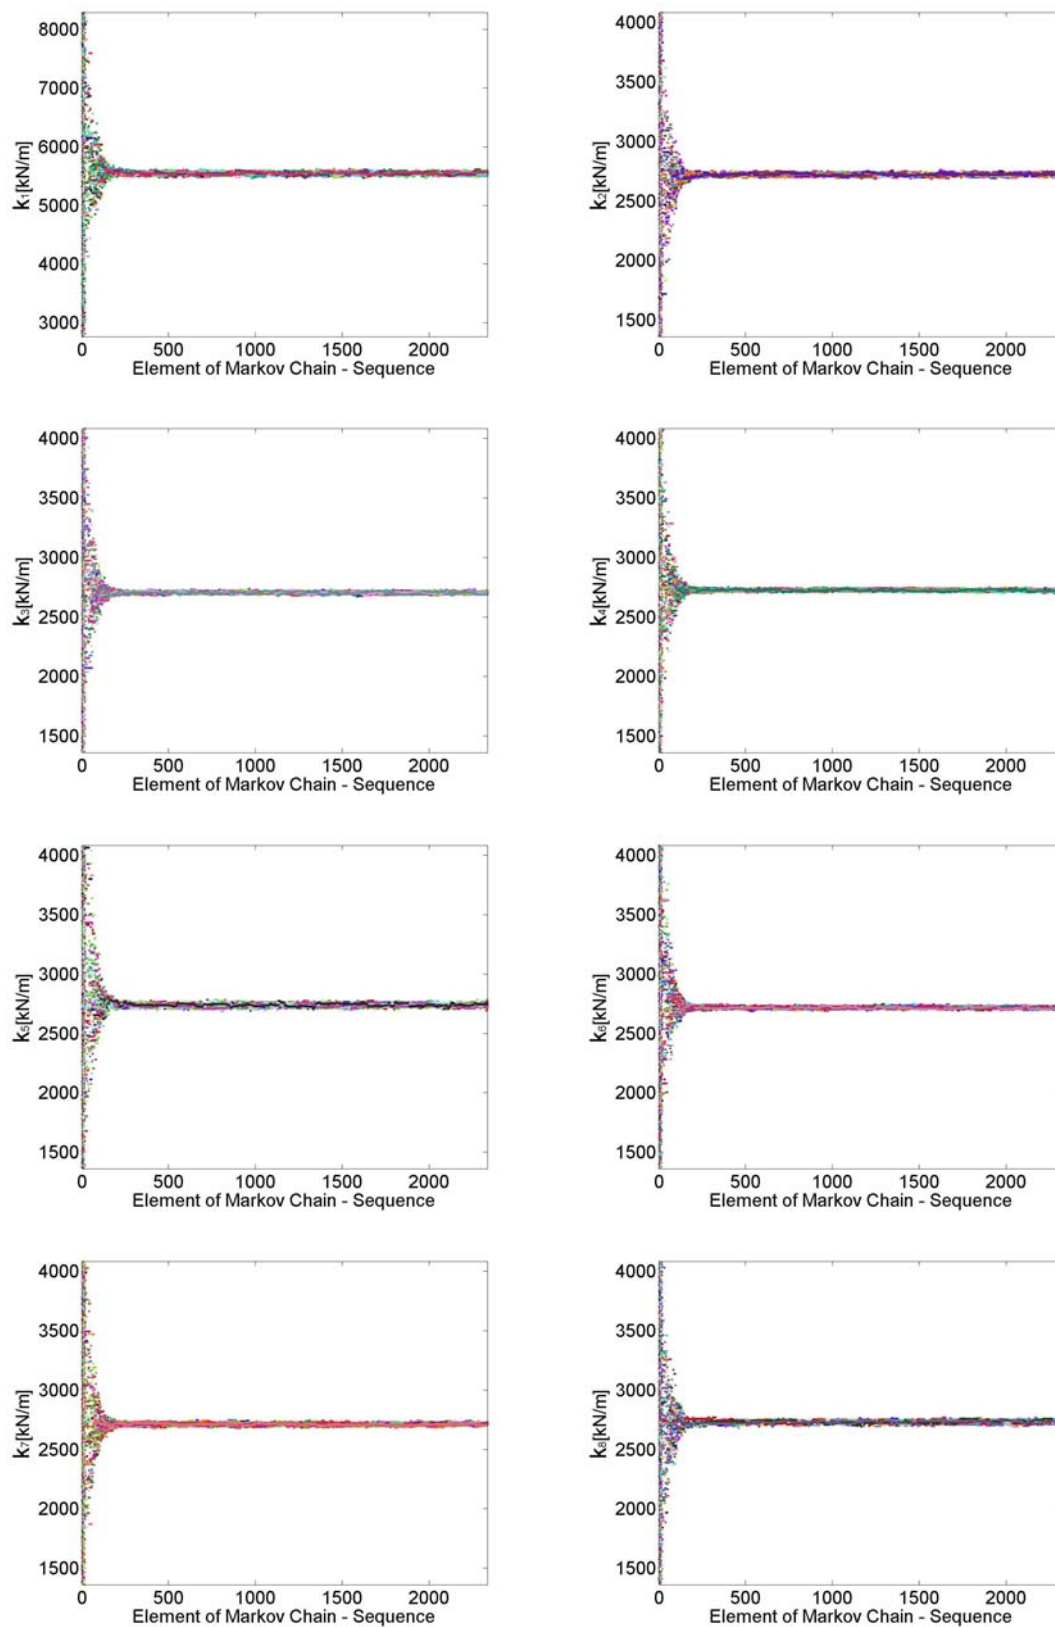
| 参数                             | 真实值       | 方式 1 识别结果 (工况 1) |      |      | 方式 2 识别结果 (工况 2) |      |      |
|--------------------------------|-----------|------------------|------|------|------------------|------|------|
|                                |           | 期望值              | 标准偏差 | 相对误差 | 期望值              | 标准偏差 | 相对误差 |
| $K_1/\text{kN} \cdot \text{m}$ | 5.529E+03 | 5.529E+03        | 0    | 0%   | 5.529E+03        | 0    | 0%   |
| $K_2/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $K_3/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $K_4/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $K_5/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $K_6/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $K_7/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $K_8/\text{kN} \cdot \text{m}$ | 2.723E+03 | 2.723E+03        | 0    | 0%   | 2.723E+03        | 0    | 0%   |
| $\zeta_1$                      | 0.01      | 0.01             | 0    | 0%   | 0.01             | 0    | 0%   |
| $\zeta_2$                      | 0.03      | 0.03             | 0    | 0%   | 0.03             | 0    | 0%   |

从这个算例中可以发现，SCEM 算法的计算结构是期望值和标准偏差均为零。在本工况中，系统为质量已知的结构系统，为线性模型，不存在异参同效的可能。并且用于识别的模型精确地描述了待识别模型的所有特征，因而模型为确定性模型，不含随机性。其次，输入输出未带高斯白噪声，也就是输入输出均为确定性输入输出，未受随机性干扰，因此输入输出也不含随机性。因而，本算例的此两种工况下，参数识别结果未带不确定性。

同时，从确定性的模型试验中，由于最后的结果可精确描述为确定性结果，可以证明 SCEM 算法本身并未带入算法随机性，对于参数不确定性的描述是足够精确的。

表3.2 10%噪声下不同识别方式的模拟识别结果样本随机特征值

| 参数                             | 方式 1 识别结果 (工况 3) |       |          |       | 方式 2 识别结果 (工况 4) |       |          |       |
|--------------------------------|------------------|-------|----------|-------|------------------|-------|----------|-------|
|                                | 期望值              | 相对误差  | 标准偏差     | 相对偏差  | 期望值              | 相对误差  | 标准偏差     | 相对偏差  |
| $K_1/\text{kN} \cdot \text{m}$ | 5.54E+03         | 0.28% | 8.81E+00 | 0.16% | 5.55E+03         | 0.30% | 2.55E+01 | 0.46% |
| $K_2/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.14% | 4.39E+00 | 0.16% | 2.72E+03         | 0.06% | 9.55E+00 | 0.35% |
| $K_3/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.12% | 3.60E+00 | 0.13% | 2.71E+03         | 0.67% | 8.72E+00 | 0.32% |
| $K_4/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.18% | 4.27E+00 | 0.16% | 2.72E+03         | 0.07% | 6.56E+00 | 0.24% |
| $K_5/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.02% | 7.49E+00 | 0.28% | 2.73E+03         | 0.42% | 1.51E+01 | 0.55% |
| $K_6/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.29% | 4.56E+00 | 0.17% | 2.72E+03         | 0.28% | 7.30E+00 | 0.27% |
| $K_7/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.07% | 5.44E+00 | 0.20% | 2.71E+03         | 0.42% | 8.81E+00 | 0.32% |
| $K_8/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.36% | 6.37E+00 | 0.23% | 2.73E+03         | 0.41% | 1.03E+01 | 0.38% |
| $\zeta_1$                      | 9.66E-03         | 3.52% | 1.64E-04 | 1.64% | 1.05E-02         | 4.58% | 2.63E-04 | 2.63% |
| $\zeta_2$                      | 3.00E-02         | 0.13% | 5.80E-05 | 0.19% | 3.02E-02         | 0.59% | 1.09E-04 | 0.36% |






图3.4 质量已知 10%噪声且部分输出已知时各参数的马尔可夫链

在工况 3 和工况 4 的计算中,模型的输入和输出加入了 10%的零均值高斯白噪声,为参数识别带来了一定的不确定性。

从表 3.2 中的结果来看,在输出加速度时程信息完全已知的情况下,刚度部分的标准偏差在 0.27%真实值以内,期望值误差在 0.29%以内;阻尼比部分中,第一阶阻尼比的标准偏差较大,期望值和真实值的相对误差达到 3.52%。




图3.5 结构质量已知系统 10%噪声下各层刚度相对标准偏差对比图

各楼层的刚度标准偏差可见图 3.5。其中以第五层相对标准偏差最大,即在输入激励位于第一层时,第五层刚度值对于结构总体输出的影响较小。也就是说,在同样的加速度时程误差均方根下,相同概率下第五层刚度值的变化范围较大。

在采用部分输出数据进行分析的时候,即工况 4,各参数的不确定性均有所增大,期望值和方差均增大。从图 3.3 的 SR 曲线可以发现马尔可夫链已经收敛。而图 3.4 中更可以清晰看出各马尔可夫链的演化情况和各个参数样本点的基本概率统计信息。相对不确定性最大的参数为第一阶阻尼比。而刚度的相对标准偏差从平均 0.19% 上升至平均 0.36%,期望值的相对误差也从 0.18% 上升至 0.33%。在图 3.4 中表现为样本的区域相对扩大。这一结果表明,输出信息的数量的减

少会加大参数识别的不确定性。

而从图 3.5 的各层刚度相对偏差的对比结果也可以发现，输出信息的不完备不会从很大程度影响参数识别不确定性的相对排序，但会扩大每一个参数的概率分布的标准偏差。

### 3.4.4 质量未知系统的参数不确定性分析

质量未知的结构系统的参数识别具有非线性、维数高、局部最优区域多等特点，因而参数的不确定性较质量已知系统大。为了进一步考察由于测量信息不确定性导致的结构系统参数识别不确定性，本节将利用 SCEM 算法识别结构质量未知系统模型，从而对参数不确定性进行分析和研究。在质量未知系统中，识别参数个数由 10 个增加为 18 个。

结构系统模型可由以下一系列待识别参数完全描述

$$\theta = (m_1, m_2, \dots, m_8; k_1, k_2, \dots, k_8; \zeta_1, \zeta_2) \quad (3.11)$$

SCEM 参数设置如下：在无噪声干扰时，适应值函数计算最大次数= 40000，在有噪声干扰时，适应值函数计算最大次数= 70000（终止条件之一）， $q=10$ （复杂形个数）。

本节设置了 4 个工况。

- 1、 无噪声干扰下，输出信息完全已知的结构物理参数识别。
- 2、 无噪声干扰下，输出信息部分已知的结构物理参数识别。
- 3、 输出信息受到 10%噪声干扰，输出信息完全已知的情况下的结构物理参数识别。
- 4、 输出信息受到 10%噪声干扰，输出信息部分已知的情况下的结构物理参数识别。

四种工况的 SR 曲线收敛图如图 3.6 所示。所有四种工况的 SR 值均小于 1.2，因此所有马尔可夫链最终都收敛于极限分布。质量未知系统中，无噪声下的不同测量信息完备性的对比工况计算结果列于表 3.3。10%噪声下的不同测量信息完备性的对比工况计算结果列于表 3.4。输入包含 10%零均值高斯白噪声且输出部分已知的工况 4 的各参数的马尔可夫链如图 3.7 所示。

由图 3.6 可见，四种工况均成功收敛于极限分布。然而四种工况的收敛曲线又略有区别。从收敛曲线来看，SCEM 算法构造的马尔可夫链的收敛难度由简单到困难依次为工况 1，工况 2，工况 3，工况 4。曲线的收敛图形说明，在结构系统的参数识别问题中，输入输出中的随机白噪声对马尔可夫链收敛性有较大的影响。信息的部分缺失（算例中，信息缺失 62.5%）基本未对 SCEM 算法构造马



尔可夫链产生影响。




图3.6 质量未知情况下四种工况的 GR 曲线收敛示意图

表3.3 无噪声不同识别方式的模拟识别结果样本随机特征值

| 参数                             | 方式 1 识别结果 (工况 1) |       |          |       | 方式 2 识别结果 (工况 2) |       |          |       |
|--------------------------------|------------------|-------|----------|-------|------------------|-------|----------|-------|
|                                | 期望值              | 相对误差  | 标准偏差     | 相对偏差  | 期望值              | 相对误差  | 标准偏差     | 相对偏差  |
| $M_1/\text{kg}$                | 4.94E+01         | 0.07% | 1.93E-02 | 0.04% | 4.94E+01         | 0.12% | 3.59E-02 | 0.07% |
| $M_2/\text{kg}$                | 4.94E+01         | 0.06% | 6.28E-03 | 0.01% | 4.95E+01         | 0.05% | 1.22E-02 | 0.02% |
| $M_3/\text{kg}$                | 4.94E+01         | 0.10% | 7.58E-03 | 0.02% | 4.95E+01         | 0.01% | 2.01E-02 | 0.04% |
| $M_4/\text{kg}$                | 4.95E+01         | 0.04% | 8.92E-03 | 0.02% | 4.95E+01         | 0.03% | 1.49E-02 | 0.03% |
| $M_5/\text{kg}$                | 4.95E+01         | 0.01% | 7.87E-03 | 0.02% | 4.95E+01         | 0.01% | 1.56E-02 | 0.03% |
| $M_6/\text{kg}$                | 4.95E+01         | 0.13% | 1.11E-02 | 0.02% | 4.95E+01         | 0.01% | 1.45E-02 | 0.03% |
| $M_7/\text{kg}$                | 4.95E+01         | 0.02% | 1.52E-02 | 0.03% | 4.95E+01         | 0.00% | 1.67E-02 | 0.03% |
| $M_8/\text{kg}$                | 4.51E+01         | 0.06% | 9.24E-03 | 0.02% | 4.51E+01         | 0.00% | 9.51E-03 | 0.02% |
| $K_1/\text{kN} \cdot \text{m}$ | 5.52E+03         | 0.25% | 2.90E+00 | 0.05% | 5.51E+03         | 0.38% | 9.42E+00 | 0.17% |
| $K_2/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.04% | 1.43E+00 | 0.05% | 2.72E+03         | 0.07% | 2.29E+00 | 0.08% |
| $K_3/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.13% | 8.39E-01 | 0.03% | 2.73E+03         | 0.15% | 1.09E+00 | 0.04% |
| $K_4/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.10% | 7.15E-01 | 0.03% | 2.72E+03         | 0.07% | 1.49E+00 | 0.05% |
| $K_5/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.03% | 9.13E-01 | 0.03% | 2.72E+03         | 0.04% | 2.09E+00 | 0.08% |
| $K_6/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.05% | 6.46E-01 | 0.02% | 2.72E+03         | 0.01% | 1.61E+00 | 0.06% |
| $K_7/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.09% | 1.28E+00 | 0.05% | 2.73E+03         | 0.11% | 1.51E+00 | 0.06% |
| $K_8/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.00% | 1.33E+00 | 0.05% | 2.72E+03         | 0.08% | 1.09E+00 | 0.04% |
| $\zeta_1$                      | 1.00E-02         | 0.27% | 1.81E-05 | 0.18% | 9.96E-03         | 0.43% | 5.05E-05 | 0.51% |


|           |          |       |          |       |          |       |          |       |
|-----------|----------|-------|----------|-------|----------|-------|----------|-------|
| $\zeta_2$ | 3.00E-02 | 0.11% | 9.32E-06 | 0.03% | 3.00E-02 | 0.07% | 9.51E-06 | 0.03% |
|-----------|----------|-------|----------|-------|----------|-------|----------|-------|


表 3.3 中的数据表明，在无噪声干扰的情况下，质量未知结构系统参数识别在无外加随机性的工况 1 中，仍表现出一定的标准偏差。除第一阶阻尼比外，其余参数的相对标准偏差均在 0.05% 以内。在输出信息不完备的工况 2 中，标准偏差有所上升，其中最大偏差仍然出现在第一阶阻尼比，相对标准偏差达到 0.51%。

表3.4 10%噪声不同识别方式的模拟识别结果样本随机特征值

| 参数                             | 方式 1 识别结果 (工况 3) |       |          |       | 方式 2 识别结果 (工况 4) |       |          |       |
|--------------------------------|------------------|-------|----------|-------|------------------|-------|----------|-------|
|                                | 期望值              | 相对误差  | 标准偏差     | 相对偏差  | 期望值              | 相对误差  | 标准偏差     | 相对偏差  |
| $M_1/\text{kg}$                | 4.95E+01         | 0.06% | 1.14E-01 | 0.23% | 4.96E+01         | 0.31% | 3.64E-01 | 0.74% |
| $M_2/\text{kg}$                | 4.95E+01         | 0.01% | 6.07E-02 | 0.12% | 4.94E+01         | 0.19% | 1.22E-01 | 0.25% |
| $M_3/\text{kg}$                | 4.96E+01         | 0.31% | 6.55E-02 | 0.13% | 4.94E+01         | 0.06% | 1.91E-01 | 0.39% |
| $M_4/\text{kg}$                | 4.95E+01         | 0.06% | 9.22E-02 | 0.19% | 4.94E+01         | 0.20% | 1.95E-01 | 0.39% |
| $M_5/\text{kg}$                | 4.97E+01         | 0.35% | 6.13E-02 | 0.12% | 4.96E+01         | 0.17% | 1.19E-01 | 0.24% |
| $M_6/\text{kg}$                | 4.94E+01         | 0.17% | 6.55E-02 | 0.13% | 4.94E+01         | 0.14% | 1.51E-01 | 0.31% |
| $M_7/\text{kg}$                | 4.95E+01         | 0.05% | 8.25E-02 | 0.17% | 4.95E+01         | 0.00% | 1.75E-01 | 0.35% |
| $M_8/\text{kg}$                | 4.51E+01         | 0.10% | 6.87E-02 | 0.15% | 4.52E+01         | 0.25% | 9.74E-02 | 0.22% |
| $K_1/\text{kN} \cdot \text{m}$ | 5.54E+03         | 0.17% | 2.00E+01 | 0.36% | 5.56E+03         | 0.64% | 7.62E+01 | 1.38% |
| $K_2/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.10% | 5.93E+00 | 0.22% | 2.74E+03         | 0.73% | 1.49E+01 | 0.55% |
| $K_3/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.35% | 6.84E+00 | 0.25% | 2.71E+03         | 0.57% | 1.19E+01 | 0.44% |
| $K_4/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.15% | 6.25E+00 | 0.23% | 2.71E+03         | 0.46% | 1.48E+01 | 0.54% |
| $K_5/\text{kN} \cdot \text{m}$ | 2.72E+03         | 0.14% | 8.54E+00 | 0.31% | 2.72E+03         | 0.10% | 2.08E+01 | 0.76% |
| $K_6/\text{kN} \cdot \text{m}$ | 2.73E+03         | 0.11% | 5.72E+00 | 0.21% | 2.71E+03         | 0.62% | 1.27E+01 | 0.47% |
| $K_7/\text{kN} \cdot \text{m}$ | 2.74E+03         | 0.65% | 7.86E+00 | 0.29% | 2.72E+03         | 0.20% | 1.13E+01 | 0.41% |
| $K_8/\text{kN} \cdot \text{m}$ | 2.71E+03         | 0.42% | 5.32E+00 | 0.20% | 2.74E+03         | 0.63% | 1.33E+01 | 0.49% |
| $\zeta_1$                      | 9.85E-03         | 1.51% | 1.36E-04 | 1.36% | 9.54E-03         | 4.87% | 2.51E-04 | 2.51% |
| $\zeta_2$                      | 2.99E-02         | 0.24% | 6.63E-05 | 0.22% | 3.00E-02         | 0.05% | 8.71E-05 | 0.29% |

在表 3.4 中的两个工况，输入输出均加入了 10% 的高斯白噪声，参数样本的期望值和标准偏差均相较表 3.3 中的结果有一定幅度的上升。其中，在信息完全已知的工况 3 中，各楼层质量的期望值相对误差平均值上升至 0.14%，刚度期望值相对误差平均值上升至 0.26%；而测量信息不完备的工况 4 中，这两个数字分别上升为 0.16% 和 0.50%。第一阶阻尼比的期望值相对误差分别上升至 1.51% 和 4.87%。而各参数样本的平均相对标准偏差则放大到 0.27% 和 0.60%，其中第一阶阻尼比的标准偏差分别从 0.18% 和 0.51% 上升至 1.36% 和 2.51%。








图3.7 质量未知系统 10%噪声且部分输出已知时各参数的马尔可夫链

图 3.7 中对马尔可夫链的描述很清晰地表明在 10% 噪声干扰下，同时测量信息不完备时，各个参数识别结果的不确定性。并且也从一个侧面反映，SCEM 算法构造的马尔可夫链最后稳定地收敛在目标概率分布。




图3.8 质量未知各层刚度相对标准偏差对比图

图 3.8 的结果显示，在质量已知时，当无噪声影响输出的加速度时程时，也就是工况 1 和工况 2 下，刚度的不确定性非常小。但当输出信息加入 10% 高斯白噪声时，第五层和第一层的不确定性大幅增加。

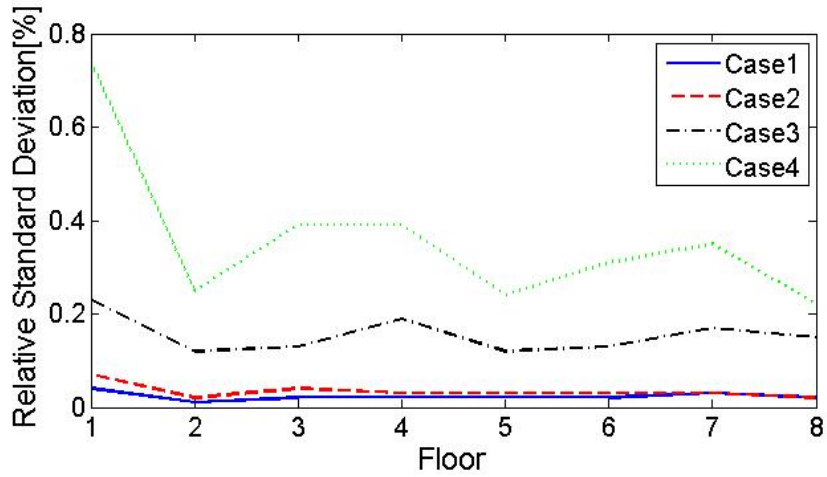



图3.9 质量未知各层质量相对标准偏差对比图

而在图 3.9 中，各楼层质量参数的不确定性分布与刚度不完全一样。第一层识别出的质量参数具有较大的相对标准偏差。其次第三、四、七层的质量参数识别结果也具有较大的相对标准偏差。

图 3.10 展示了在不确定性最大的工况 4 中，6 个具有较大相对标准偏差的参数的边缘概率分布图，包括  $m_1$ ， $m_4$ ， $k_1$ ， $k_5$  及两个阻尼比的边缘概率分布情况。






图3.10 结构质量未知系统 10%噪声下个别边缘概率分布图

从图 3.10 中可以明显看出，这 6 个参数的样本点分布基本为正态分布。而这 6 个参数的边缘分布的方差比较大。另外，可以明显地发现，相较之下， $k_5$  虽然方差较大，但概率分布连续性较好。体现在表 3.4 中为相对期望值误差较小。而第一阶阻尼比的样本点不仅分散比较均匀，而且呈现很多明显的局部峰值，在这些峰值的边缘概率值比较大。这也就意味着在第一阶阻尼比的真实值周围具有很多具有异参同效性的局部最优值。这说明，噪声对阻尼比识别结果影响很大，导致了阻尼比识别不确定性很大。

### 3.5 本章小结

由于在实际工程中，测量信息不可避免存在一定的不确定性，这样会导致参数识别结果的不确定性。针对此问题，本文提出一种基于 SCEM 算法的结构系统识别参数不确定性分析方法，并通过几组数值分析，验证了该方法的有效性。

结果表明，SCEM 算法作为新颖的启发式的 MCMC 采样器，能够构造具有强收敛性的马尔可夫链。它不但兼备了 SCE 算法收敛快、信息利用充分、解空间的探索能力强的优点，同时还具备不确定性分析能力。该方法对测量信息完备性没有严格要求，质量已知和质量未知时均可对识别参数进行不确定性分析，给出参数识别结果的概率分布随机特征值。




## 第4章 基于信息熵的SCE参数识别方法

### 4.1 引言

在以往的结构参数识别中，常用的目标函数（或适应值函数）通常采用所有自由度输出误差的平均误差。这样所有自由度的信息量的重要性都是一样的。然而，实际工程中的结构，在同一输入的情况下，不同自由度输出的信息量是不一样的，同时，不同位置的测量信息误差也是不一样的。因此每一个自由度信息对最后目标函数的贡献程度也不同。简单地将每一个自由度的测量信息权重设为相同，可能导致目标函数最后的识别结果偏离真实值。

以 2.4 节中的数值分析模型为例。以误差最大，问题最复杂的工况 3（质量未知、带有 10% 噪声干扰且测量信息不完备）为例，取最好的识别结果，代入数值结构模型，得到一个多点输出结果。将预测的加速度时程与真实的加速度时程相减，则可得到时程曲线的绝对误差（如图 4.1 所示）。



质量未知信息不完

备 10% 噪声下各层输出误差图

从图 4.1 中可以发现，每一层的加速度时程与预测值的平均绝对误差并不是每一层都相同的，在图形中甚至可以发现他们之间最多可相差 10 多倍。第 1、2 层的绝对误差值较小，而第 4、6、8 层的绝对误差值较大。如果按照文献中和第二章模型目标函数的设置办法，简单将这些绝对误差进行平方加和，第 1、2 层对目标函数的影响将会大幅减弱。换言之，当算法搜索到可以大幅减小第 1、2 层绝对误差而同时对其他层影响不明显的参数解时，目标函数值并不会有明显



的变化。按照优化算法的原理，这样的参数集将会被抛弃。而这种情况并不总是正确的。




图4.2 双目标下的 Pareto 前沿图

将第 1、2 层的均方根误差设为目标 1 即 F1，将第 4、6、8 层的均方根误差设为目标 2 即 F2。设置选取 100 个方案，即可得如图 4.2 的 Pareto 前沿图。这证明了，当 F1 最优的时候，F2 并不一定是最优的。不同楼层的识别目标是有矛盾的。这矛盾，主要来源于不同位置的信息含量是不一样的，对目标函数的贡献也是不一样的，而且不同位置的误差达到最小，并不能说明其他位置的预测误差也能同时达到最小。

因此，有必要考虑不同位置信息量的重要性以改进目标函数，实现所有位置的信息得到最优配置。

## 4.2 多目标优化问题及解法

1896 年，法国经济学家 Pareto 提出了多目标最优化问题，从政治经济学的角度将许多不好比较的问题归纳成多目标优化问题<sup>[74]</sup>。

多目标优化问题涉及的范围及其广泛。其中最为核心的问题就在与多目标优化的解和多目标优化问题的解法。

### 4.2.1 多目标优化问题的解

如何衡量多目标函数的好坏，是多目标优化的核心问题。

对于单目标规划来说，对任意的  $\theta_1$  和  $\theta_2$ ，从可以通过比较  $F(\theta_1)$  和  $F(\theta_2)$  的大小就可以唯一地确定哪个解更优。

然而，在多目标优化问题中，各目标函数之间互相制约，而且这些目标函数值是  $n$  维空间点，往往没有一个解比其他所有解绝对最优。因此问题的解通常并不唯一，解的性质也十分复杂。

通常，多目标优化问题所指的有效解(也称非劣解或 Pareto 解)，是位于 Pareto 前沿上的解(Pareto Front)解。

设结构系统物理参数多目标优化问题可表示为：

$$\min F(\theta) = [F_1(\theta), F_2(\theta), \dots, F_n(\theta)]^T \quad (4.1)$$


(4.1) 式中： $F_i(\theta)$  为第  $i$  个目标函数； $\theta$  为优化参数。

根据定义，Pareto 解集中的  $\theta_p$  具有以下特性：

(1) 对于任意非 Pareto 解  $\theta_d$ ，必存在一  $\theta_p$ ，使得  $F_k(\theta_p) < F_k(\theta_d)$ ， $k=1,2,\dots,n$

(2) 在 Pareto 解集中不存在最优解  $\theta_p^*$ ，使得  $F_k(\theta_p^*) < F_k(\theta_p)$ ， $k=1,2,\dots,n$

为便于说明 Pareto 解的概念，以一个双参数的两目标优化问题为例，点 A 与点 B 为相应各目标  $F_1$  与  $F_2$  各自取得最小值时的解，连接 A 与 B 的实线 AB 上的点便是 Pareto 解集 (Pareto 前沿)， $y$  为多目标意义下优于  $\delta$  的解，见图 4.3。



Pareto 解的参数空间示意图

Pareto 解的目标函数空间示意图

图4.3 Pareto 解集及目标函数空间示意图

#### 4.2.2 多目标优化问题的解法

从 4.2.1 节中对多目标优化问题的解的介绍中可以发现，多目标优化问题的解不仅不唯一，甚至是有无数个。这无数个的解均位于一个边界，即 Pareto 前沿上。因而，求解多目标优化问题的解是一个困难的问题。从 1896 年 Pareto 提出多目标优化问题至今，对 Pareto 前沿的求解仍然没有得到较好的解决方案。

目前，世界上对于求解多目标优化问题解的解法主要分为两类：间接法和直接法。

间接法包括转化成单目标的解法、非同一模型解法。

直接法（有效解法）包括合适等约束法、自适应法和智能离散逼近法。

转化成单目标的解法因其方法简单、概念清晰，求解速度快等特点，成为目前多目标优化问题的最主要的解法。

转化成单目标法按照转化方式不同，主要分为：主要目标法、线性加权和法、极大极小法、理想点法、安全法、评价函数法等。

实际应用中最为广泛的为：1、线性加权或效用系数和法；2、有效解（非劣解）法。

#### 1、线性加权和法

所谓线性加权和法就是按照  $n$  个目标  $F_i(\theta)$  ( $i=1,2,\dots,n$ ) 的重要程度，分布乘以一组权系数  $\lambda_i$  ( $i=1,2,\dots,n$ )，然后相加作为目标函数，再对此目标函数在约束集合上求最优解。即构造如下的单目标问题

$$\min_{x \in R} U(x) = \sum_{i=1}^n \lambda_i f_i(x) \quad (4.2)$$

求此单目标问题的最优解，并把它叫做线性加权和意义下的最优解。

#### 2、有效解（非劣解）法

有效解法不会产生像线性加权和法那样的局限性。它将找出有效解（Pareto解）。但非劣解法表面上看起来很吸引人，但在实际应用中却有许多局限性。在大多数具有实际意义的问题中，非劣解是如此之多以至于难以一一将其解出。

事实上，当前许多智能优化算法力图采直接法进行Pareto前沿逼近。如NSGA<sup>[75]</sup>、SPEA等多目标优化算法，结合博弈选优理论和遗传算法的进化思想，将有限的子代向理论的Pareto前沿逼近。研究表明，这些算法已经具有能够描述Pareto前沿的能力。然而由于采用离散点进行逼近，给出的仅仅是有限个解决方案。

### 4.2.3 结构参数识别解法

分析表明结构参数识别问题在输出受到噪声干扰下，以不同楼层输出均方根误差为目标的问题是存在 Pareto 前沿的。

由于线性加权和法具有概念清晰，使用简单，计算快捷，结果精确等特点，本文将主要采用线性加权和法对结构参数多目标识别问题进行求解，并采用信息熵理论对各目标进行加权。

## 4.3 信息熵基本原理及计算方法

### 4.3.1 信息熵的基本原理

信息是各种相互联系的客观事物在运动变化中通过一定传递形式而揭示的一切有特征性的内容。信息科学将信息定义为一个有普遍性意义的哲学范畴,认为它不是物质,而是物质的普遍属性,它的内容取决于信源,它的作用、价值与信源有关,与信宿也有关。对信息的质,历史上有许多不同的表述,意大利学者朗格(G·Longo)认为,信息是事物之间的差异,而不是事物的本身;而信息论的奠基者申农(C·E·Shannon)认为,信息是用来消除随机不定性的东西;控制论的创始人维纳(N·Wiener)则指出,信息就是信息,既不是物质也不是能量。还有人认为,信息是物质和能量在时空中分布的不均匀性<sup>[77]</sup>。如果信息的质是针对信息内容的描述的话,信息量的大小则取决于事物的差异度或不确定性程度或减少的不确定性程度<sup>[76]</sup>。

在信息论中,熵是系统无序状态的度量。按照熵思想,人们在决策中获得信息的多少和质量,是决策精度和可靠性大小的决定因素之一。熵权,反映了各目标向决策者提供的有用信息量。

1948年申农正式提出了“熵公式”。申农用统计平均信息的形式来度量信息的概率分布,即认为任何一种事物只要知道它的各个可能独立状态的概率分布,就可以求出它的熵值,算出它所提供的信息量。对于信息源各种状态地位不平等时,信息熵(又称申农熵)的函数表达式为

$$H = -\sum_{i=1}^n P_i \log P_i \quad \left( \sum_{i=1}^n P_i = 1 \right) \quad (4.3)$$

即信息量的大小取决于信息内容的不确定性程度,依赖于信息内容的随机概率大小。通俗的表述,就是信息内容所含噪声干扰程度的大小。

对于信源各种状态都是平等机会出现时,将 $P_i = \frac{1}{n}$ 代入 $H = -\sum_{i=1}^n P_i \log P_i$ ,信息熵表达式则变为:

$$H = \log n \quad (4.4)$$

即此时信息量的大小取决于信源的差异度 $n$ 。

可见信息熵同时揭示了信息的本质:事物(信源)各状态越是不确定,信息量越大;事物的差异度越大,信息量也越大;越能消除信宿的不确定性,信息量也越大<sup>[78]</sup>。

### 4.3.2 信息熵的计算方法

**第一步：** 设各方案的目标特征值矩阵  $X$  为

$$X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{pmatrix} = (X_{ij}) \quad (4.5)$$

式中,  $x_{ij}$  为方案  $j$  目标  $i$  的特征值;  $i = 1, 2, \dots, m$ ,  $j = 1, 2, \dots, n$

**第二步：** 为消除  $m$  个目标特征值量纲不同的影响, 需要将矩阵  $X$  按式 (4.6) 和式 (4.7) 进行规格化处理。

对于越大越优型指标

$$r_{ij} = (x_{ij} - x_{i,\min}) / (x_{i,\max} - x_{i,\min}) \quad (4.6)$$

对于越小越优型指标

$$r_{ij} = (x_{i,\max} - x_{ij}) / (x_{i,\max} - x_{i,\min}) \quad (4.7)$$

将矩阵  $X$  转化为目标相对优属矩阵  $R = (R_{ij})$

$$R = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ r_{m1} & r_{m2} & \cdots & r_{mn} \end{pmatrix} = (R_{ij}) \quad (4.8)$$

式中:  $r_{ij}$  为方案  $j$  目标  $i$  对优的相对隶属度, 简称目标相对优属度。

由矩阵  $R$  知, 方案  $j$  的目标相对优属度向量

$$r_j = (r_{1j}, r_{2j}, \dots, r_{mj})^T$$

**第三步：** 采用熵权法计算数学权重

1、构建  $n$  个可行方案,  $m$  个评价目标的特征矩阵, 如式(4.5)所示, 即  $X = (x_{ij})_{m \times n}$ 。

2、应用规格化公式(4.6)、(4.7)将评价目标特征值矩阵  $X = (x_{ij})_{m \times n}$  进行归一化处理, 得矩阵  $R = (r_{ij})_{m \times n}$

3、根据熵的定义, 确定评价目标  $i$  的熵值

$$H_i = -\frac{1}{\ln n} \left( \sum_{j=1}^n f_{ij} \ln f_{ij} \right) \quad (4.9)$$

式中:

$$f_{ij} = \frac{r_{ij}}{\sum_{j=1}^n r_{ij}}$$

第四步：设  $m$  个目标具有不同的权重，设权向量为

$$w = (w_1, w_2, \dots, w_m)^T$$

满足：  $\sum_{i=1}^m w_i = 1$

利用熵值计算评价目标  $i$  的熵权

$$w_{ei} = \frac{1 - H_i}{m - \sum_{i=1}^m H_i} \quad (4.10)$$

## 4.4 基于信息熵的SCE参数识别方法

### 4.4.1 算法描述

本文提出基于信息熵的 SCE 结构参数识别方法，利用信息熵对各目标进行加权，从而对目标函数进行改进，进而提供算法识别精度。

方法流程如下所示：

- 1、 计算各层真实输出信息的特征值。
- 2、 将各层信息的特征值归一化。
- 3、 计算各层信息特征值的信息熵。
- 4、 根据信息熵的大小对各层的误差均方根（RMSE）目标加以权重。
- 5、 使用加入权重的目标函数进行基于 SCE 算法结构参数识别。

基于信息熵的 SCE 结构参数识别方法利用信息熵来衡量各层输出信息含量。当某层的输出加速度时程无序性较强，即乘以一个较小的权重；若输出的加速度时程有序性较好，则信息熵值较小，则乘以一个较大的权重。从而，改善目标函数，最终改善结构模型的参数识别效果。

### 4.4.2 数值分析

本节将采用第二章中采用的结构模型进行数值分析，以验证基于信息熵的 SCE 系统识别结果。本文将仅分析 2.4 节中质量未知系统的参数识别中的两种工况。在质量已知的情况下，待解问题共有 22 个未知数。可由以下一系列参数完

全描述:

$$\theta = (m_1, m_2, \dots, m_{10}; k_1, k_2, \dots, k_{10}; \alpha, \beta) \quad (4.11)$$

输出信息采用部分已知的工况, 其中 1, 2, 4, 6, 8, 10 层的输出信息可知。则输出矢量定义为

$$y(t) = (\ddot{x}_1(t), \ddot{x}_2(t), \ddot{x}_4(t), \ddot{x}_6(t), \ddot{x}_8(t), \ddot{x}_{10}(t),) \quad (4.12)$$

两种算法仍然采用目标函数调用次数 20000 次作为结束准则。同时, 在设置的两个工况中, 分别在输入输出加入 5% 和 10% 的高斯白噪声, 以验证算法的鲁棒性和稳定性。

根据结构系统参数识别问题的实际情况, 目标函数的物理概念是真实系统响应和模型系统响应的均方根误差。对目标函数加入权重的意义在于提高已有信息的挖掘和利用程度。因此信息熵主要由真实系统的输出信息计算得出。

按照 4.3 节中信息熵的计算方法, 方案目标特征值  $X_{ij}$  为真实系统的输出信息。 $i$  为第  $i$  个目标, 实际物理意义为第  $i$  层输出;  $j$  为第  $j$  个时间点, 物理意义为第  $0.01*j$  个时间节点上采样的输出。因此, 按照信息量, 方案目标特征值  $X_{ij}$  应为一个  $10*500$  的矩阵。

对  $X_{10,500}$  进行规格化处理得到  $R_{10,500}$ 。这里, 由于输出信息并不存在根据大小判定优越性的问题。为了统一目标起见, 按照越小越优的规格化公式 (4.7) 进行处理。

而后, 对规格化后的方案目标特征值矩阵  $R_{10,500}$  使用公式 (4.9) 计算各目标的信息熵  $H_i$ 。

最后, 根据信息熵  $H_i$  值对每一层的输出加速度信息进行权重分配。按照信息熵的定义和原理, 熵值越小, 混乱度越大, 信息差异度越大, 信息含量也越饱满, 故而所应分配的权重也较大。这里的权重分配方式采用公式 (4.10), 即以熵值进行线性分配。

对于 5% 噪声和 10% 噪声干扰下的真实系统输出信息计算出的信息熵和各自应当分配的权重如下表 4.1 表 4.2 所示

表4.1 5%噪声下各楼层真实输出的信息熵和目标权重表

| 楼层    | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 权重 w  | 0.15  | 0.12  | 0.10  | 0.05  | 0.06  | 0.13  | 0.13  | 0.11  | 0.10  | 0.06  |
| 信息熵 H | 0.969 | 0.975 | 0.978 | 0.989 | 0.987 | 0.973 | 0.972 | 0.977 | 0.980 | 0.987 |


表4.2 10%噪声下各楼层真实输出的信息熵和目标权重表

|         |       |       |       |       |       |       |       |       |       |       |
|---------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 楼层      | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    |
| 权重 $w$  | 0.14  | 0.12  | 0.10  | 0.05  | 0.06  | 0.14  | 0.13  | 0.10  | 0.10  | 0.06  |
| 信息熵 $H$ | 0.973 | 0.977 | 0.980 | 0.989 | 0.987 | 0.973 | 0.974 | 0.979 | 0.980 | 0.987 |


明显地，从熵值和目标权重的计算结果中可以发现，在不同程度的噪声干扰下，信息熵值略有变化，但幅度不大。10%噪声下的信息熵值要大于 5%噪声干扰下的信息熵。这主要是因为噪声的影响加大了输出信息的无序化程度，最终体现在信息熵的增大。

在这两个工况中，信息熵值最小，权重最大的输出信息位于第 1、2、6、7 层。而信息熵值最大，权重较小的输出信息位于第 4、5、10 层。并且，除了第 4、5、10 层外，其余楼层权重相差不大，均为 0.10~0.15 左右。而第 4、5、10 层的权重剧烈缩减为 0.06 以下。说明这三个楼层的可用信息量小于其余楼层。

这里还应当注意到的是，第 5、10 层是输入激励点。根据以往传统的结构系统识别的人为经验累积认为，激励层的输出信息一般不作为参照标准。也就是说，按照过去的识别计算结果，科研工作者们已经发现，激励层对于结构物理参数识别的贡献较小，因此往往不会将采集激励点的输出信息。而这一特点，在信息熵计算中得以充分的体现。




第二层输出信息



第四层输出信息





第五层输出信息

图4.4 5%噪声干扰下真实系统各层输出加速度时程曲线

按照表4.1表4.2中计算的各目标权重值将10个目标加权为一个目标函数,采用基于SCE算法的结构系统识别方法对结构模型进行识别。数值分析结果如表4.3所示。

表4.3 质量未知5%和10%噪声下识别对照结果

| 参数                                | 真实值      | SCE(5%)  |        | SCE(10%) |        |
|-----------------------------------|----------|----------|--------|----------|--------|
|                                   |          | 识别值      | 误差 (%) | 识别值      | 误差 (%) |
| $M_1/\text{kg}$                   | 6.00E+03 | 6.13E+03 | 2.22   | 6.16E+03 | 2.62   |
| $M_2/\text{kg}$                   | 6.00E+03 | 6.26E+03 | 4.38   | 6.40E+03 | 6.72   |
| $M_3/\text{kg}$                   | 6.00E+03 | 6.31E+03 | 5.17   | 6.36E+03 | 6.05   |
| $M_4/\text{kg}$                   | 6.00E+03 | 6.01E+03 | 0.18   | 5.95E+03 | 0.81   |
| $M_5/\text{kg}$                   | 6.00E+03 | 5.95E+03 | 0.79   | 5.95E+03 | 0.83   |
| $M_6/\text{kg}$                   | 4.20E+03 | 4.05E+03 | 3.59   | 3.99E+03 | 5.06   |
| $M_7/\text{kg}$                   | 4.20E+03 | 4.22E+03 | 0.36   | 4.25E+03 | 1.30   |
| $M_8/\text{kg}$                   | 4.20E+03 | 4.08E+03 | 2.91   | 4.00E+03 | 4.74   |
| $M_9/\text{kg}$                   | 4.20E+03 | 4.26E+03 | 1.40   | 4.34E+03 | 3.30   |
| $M_{10}/\text{kg}$                | 4.20E+03 | 4.20E+03 | 0.08   | 4.19E+03 | 0.14   |
| $K_1/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.08E+03 | 1.51   | 5.09E+03 | 1.85   |
| $K_2/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.11E+03 | 2.19   | 5.07E+03 | 1.37   |
| $K_3/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.25E+03 | 5.02   | 5.34E+03 | 6.82   |
| $K_4/\text{kN} \cdot \text{m}$    | 5.00E+03 | 5.21E+03 | 4.24   | 5.28E+03 | 5.64   |
| $K_5/\text{kN} \cdot \text{m}$    | 4.00E+03 | 3.98E+03 | 0.39   | 3.96E+03 | 0.91   |
| $K_6/\text{kN} \cdot \text{m}$    | 4.00E+03 | 3.84E+03 | 4.12   | 3.77E+03 | 5.64   |
| $K_7/\text{kN} \cdot \text{m}$    | 4.00E+03 | 3.95E+03 | 1.29   | 3.93E+03 | 1.76   |
| $K_8/\text{kN} \cdot \text{m}$    | 4.00E+03 | 3.95E+03 | 1.24   | 3.96E+03 | 1.11   |
| $K_9/\text{kN} \cdot \text{m}$    | 3.00E+03 | 2.95E+03 | 1.51   | 2.93E+03 | 2.18   |
| $K_{10}/\text{kN} \cdot \text{m}$ | 3.00E+03 | 2.98E+03 | 0.71   | 2.97E+03 | 0.97   |
| $\alpha$                          | 1.09E-02 | 1.24E-02 | 14.19  | 1.26E-02 | 16.04  |
| $\beta$                           | 1.84E-01 | 1.85E-01 | 0.60   | 1.86E-01 | 1.11   |

表4.4 5%噪声下识别结果误差对照表

|                   | 单目标  | 多目标  |
|-------------------|------|------|
| Mean Err- $m$ (%) | 2.69 | 2.11 |
| Max Err- $m$ (%)  | 8.11 | 5.17 |
| Mean Err- $k$ (%) | 2.71 | 2.22 |
| Max Err- $k$ (%)  | 8.61 | 5.02 |
| Mean Err- $c$ (%) | 2.81 | 2.02 |
| Max Err- $c$ (%)  | 9.16 | 5.41 |

表4.5 10%噪声下识别结果误差对照表

|                   | 单目标   | 多目标  |
|-------------------|-------|------|
| Mean Err- $m$ (%) | 6.50  | 3.16 |
| Max Err- $m$ (%)  | 14.18 | 6.72 |
| Mean Err- $k$ (%) | 7.11  | 2.82 |
| Max Err- $k$ (%)  | 15.62 | 6.82 |
| Mean Err- $c$ (%) | 6.55  | 2.68 |
| Max Err- $c$ (%)  | 12.29 | 8.00 |

从表 4.4 和表 4.5 中对照结果可以看出，基于信息熵的SCE结构系统参数识别进一步提高了参数识别精度。这主要得益于对各层目标函数权重的重新修正，信息熵权重的设置进一步加强对信息量饱满的楼层输出信息的利用程度。

10%噪声的精度提升效果略微明显于 5%噪声干扰下的工况。这主要是因为信息熵引入是用于衡量信息中无序状态，而对输出信息加入高斯白噪声，无疑会加大信息的无序化程度。并且，由于噪声对于每层信息的干扰程度略有不同，信息熵权重的引入在一定程度上规避了受噪声干扰严重楼层，从而减小噪声对于目标函数的影响。因而这一方面的改善程度，将随噪声的增大而增大。

## 4.5 本章小结

针对以往结构系统识别方法中未考虑不同自由度输出信息饱满程度的差异性问题的，本章提出了一种基于信息熵的 SCE 参数识别方法，利用信息熵基本原理，对不同自由度上的输出信息进行加权，提高目标函数对待识别系统的特征描述，从而加强对输出信息的利用，最终提高结构参数识别精度。

本章中的数值分析证明，该方法概念清晰，使用简单，计算快捷，有效提高了结构系统识别的精度。

## 第5章 总结与展望

### 5.1 本文工作总结

本文通过将结构参数识别问题转化为优化问题，提出了一种基于 SCE 算法的结构参数识别方法。延续该思想，本文又分别提出了基于 SCEM 算法的参数不确定性分析方法和基于信息熵的 SCE 参数识别方法。其中主要工作主要包括以下几个方面：

(1)、提出了基于 SCE 算法的结构参数识别方法，并分别针对输入输出噪声干扰、测量信息不完备、质量已知和质量未知等情况对数值结构模型进行参数识别。识别结果证明，该方法具有识别速度快、识别精度高、识别条件要求不高等特点。文中同时将 SCE 算法与 PSO 算法、CLPSO 算法、DE 算法等三种智能算法进行数值分析和对比。结果表明：几种算法中，DE 算法和 SCE 算法识别效果最佳，CLPSO 算法次之，PSO 算法效果最差。特别是在质量未知、测量信息不完备且输出受到 10% 噪声干扰下的情况，DE 算法和 SCE 算法表现出很好的优势。

(2)、针对实际工程中由测量信息不确定性引起的参数识别不确定性，提出了基于 SCEM 算法的参数不确定性分析方法，并通过数值分析验证了该方法的有效性。分析结果表明，该方法对测量信息完备性没有严格要求，质量已知和质量未知时均可成功对识别参数进行不确定性分析。

(3)、针对实际工程中不同自由度上信息量饱满程度的差异性，提出基于信息熵的 SCE 参数识别方法。通过对测量信息的信息熵计算，按照不同自由度赋予不同权重，从而使目标函数更精确地描述系统特征。通过数值分析对比，结果证明该方法能够有效提高参数识别的精度。

### 5.2 本课题继续研究展望

SCE 算法是一类新兴的智能启发式演化算法，以其洗牌、混合、复杂形进化等有效的信息共享和演化策略而著称。但无论是算法，还是结构参数识别问题，均还有大量的研究工作需要继续深入研究和拓展。

(1)、基于 SCE 算法的时变结构系统参数识别方法的研究。本文虽对结构系统物理参数的识别进行了初步研究，但研究对象均为时不变系统，如何使用

SCE 算法对时变结构参数实现识别需要进一步研究。

(2) 基于改进 SCE 算法的结构参数识别研究。SCE 算法具有执行简单, 运行快捷等特点, 但与 DE 算法相比, 仍然具有速度和精度上的劣势。如何结合 SCE 算法与不同智能算法之间的优点进行识别, 尤其是 DE 算法的演化策略, 使之更适应更为复杂结构的参数及损伤识别, 可以作为下一阶段的研究方向。

(3) 基于 DE 算法的参数不确定性分析方法研究。沿用基于 SCEM 算法的参数不确定性分析方法的思路, 综合 DE 算法的演化策略和 Metropolis 策略, 提出基于 DE 算法的参数不确定分析算法。笔者已经进行了初步探索, 但由于时间所限, 还未能达到预期效果, 故未列入本文中。

(4) 对本文所提出的参数识别方法的目标函数进行进一步改良和完善。在本文中, 虽然提出了基于信息熵的 SCE 参数识别方法, 但这仅仅只是目标函数改进的其中一个方向。对于目标函数的改良, 可以有多种思路和解决方案。

A、采用多目标优化算法, 列举出所有可能方案, 再在方案中进行多种加权取优, 形成多目标两阶段识别法。

B、对权重计算的方法多样化。本文仅采用信息熵作为计算权重的标准。事实上, 每一种计算标准只能衡量一个方面的指标。还有诸如标准离差法、投影寻踪法等计算权重的方法。如何综合考量多种权重的组合, 最终订立最优权重, 将有助于目标函数本身的优化设计。

C、对加权方式的多样化。本文仅采用线性加权和。如何选取加权方式, 并比较各种加权方式的识别结果, 都有待更多的计算机试验和计算结果进行支撑。

D、对于目标的选择可采用其他角度。可采用不同的误差指标作为目标分类标准。例如最大绝对值误差作为目标一, 均方根误差作为目标二等等。这样的目标分类也有助于提高输出信息的利用程度。

总而言之, 后期的研究工作仍有很大的空间值得后续学者继续努力。

## 致谢

随着这本论文的收尾,在同济的求学生涯也将结束,两年多的时光虽然短暂,但却足以使同济严谨、务实的名校作风以及同舟共济、自强不息的同济精神在我今后的人生道路上烙下深刻印记。有幸在此求学,是我毕生的荣耀;而两年多以来风雨兼程中所体会到的关怀与支持,更使我终生难忘。

首先衷心地感谢导师薛松涛教授和唐和生副导师。薛老师名扬海外,但却平易近人;谈笑风生中的诙谐与幽默,蕴藏着乐观的人生态度和宽松的治学理念;叮咛教诲里的提点与温情,更是饱含着对学生无限的关怀与爱护。白驹过隙的两年半,薛老师给学生的,不仅是一份知遇之恩、一份感动,更是荡涤人生的一份胸怀和一种气魄。唐老师,是朝夕相处的前辈和榜样。如果说认真、自强是唐老师交给学生的开启知识宝库的黄金钥匙,那么务实、勤奋便是唐老师身体力行传达给学生人生至宝。唐老师在这个课题上倾注太多心血。无数次的解释,数不清的推敲,几年的辛勤汗水和智慧结晶,终于凝聚成这薄薄一册论文纸。这里区区几行浅词拙句又怎能道尽学生心中对两位如慈父如兄长的导师的深深谢意和无限感恩呢!

还要感谢研究室的陈镕教授和王远功教授,两位老前辈求实的治学态度无时无刻不深深影响着教研室中的每一位求学者。陈镕老师的课,严肃中不乏一丝活泼,平凡中蕴含着一份深刻。黑板上密密麻麻的公式正是陈老师几十年如一日辛勤耕耘的写照。与其说陈老师教授我科学宝库中的知识点,倒不如说陈老师是传递一种精神,一份对科学的执着与热爱。已退休弄儿饴孙的王远功老师,虽然不曾授课与学生,但老师先前的传奇仍然在师兄弟间代代相传,对教研室的影响仍源源不断。陈老师和王老师用一生努力为教研室的发展奠定下良好基础,用非同寻常的人格魅力和勤勤恳恳的治学精神不断地鼓舞和激励着学生在学术和人生道路上奋勇向前。

同时也要感谢建工系的谢强副教授和教研室的谢立宇老师。两位老师的创新精神常令学生耳目一新,与他们的交谈往往使学生茅塞顿开,受益匪浅。这里衷心感谢他们为学生提供的良好创意。他们也将永远是学生学习的光辉榜样。

这里也非常感谢美国亚利桑那大学 Hoshin Gupta 和 Jasper A. Vrugt 教授对算法的认真而详细的解释和部分程序代码的无私提供。他们一直十分热心地将研究成果介绍给我,使我在研究中一直能得到当今科学界最新的科研成果的支持,从而保证了本文的顺利完成。而在彼此邮件的沟通交流中,也结下了深厚的友谊。在此,对他们的无私贡献和坦诚相待表示衷心的感谢。

感谢结构工程与防灾研究所曹阳老师对我学习事务上的耐心帮助和热情鼓励。

感谢师兄张伟、李峰二位博士、申道明、许锐、范德伟、胡长远四位博士生以及同门周进、王兆亮和师弟柴林峰、石家武、仲诚、王泽新、赵伟屹、于骁勇在论文写作过程中给我的无私帮助和巨大支持。

感谢结构所的兄弟们,和你们在一起的岁月充满了欢乐。

感谢我的父母和家人,他们对我常年在外求学毫无保留的付出和关爱,并给予了我最坚定的支持,向我的家人表达深深的歉意和最深的谢意!

最后，谨向所有帮助过我的老师、同学、朋友们表示衷心的感谢！

李鹏飞  
2010年3月

## 参考文献

- [1] 杨晓楠. 基于贝叶斯统计推理的结构损伤识别方法研究: [博士学位论文]. 上海: 同济大学, 2007
- [2] 邸小坛, 周燕. 旧有建筑物的检测加固与维修. 北京: 地震出版社, 1991
- [3] 冯新. 土木工程中结构识别方法的研究: [博士学位论文]. 大连: 大连理工大学, 2002
- [4] 谢强, 薛松涛. 土木工程结构健康监测的研究状况与进展. 中国科学基金, 2001, Vol.111(5): 285~288
- [5] 欧进萍. 重大工程结构的智能监测与健康诊断. 工程力学, 2002, (增刊): 44~53
- [6] 欧进萍. 重大工程结构损伤累积、健康监测与安全评定. 见: 国家自然科学基金委员会工程与材料科学部 ed 学科发展战略研究报告(2006年~2010年)土木工程卷: 科学出版社, 2006
- [7] Zadeh L. A., From circuit theory to system theory, Proc. IRE., 1962, Vol.50 (5):856-865.
- [8] 李杰. 随机结构系统——分析与建模. 北京: 科学出版社, 1996
- [9] 李国强, 李杰. 工程结构动力检测理论与应用. 北京: 科学出版社, 2002
- [10] Ibrahim S R., Double least square approach for use in structural modal identification. AIAA, 1986, 24:499~503
- [11] Wang D. & Haldar A., Element-level system identification with unknown input information, J. Eng. Mech., 1994, Vol.120 (1): 159~176.
- [12] Li J. & Chen J., A statistical average algorithm for the dynamic compound inverse problem, Computational Mech., 2003, Vol.30 (2) :88~95.
- [13] Campillo F. & Mevel L., Recursive maximum likelihood estimation for structural health monitoring: tangent filter implementations. C. Proc. of the 44th IEEE Conference on Decision and Control and European Control Conference (CDC-ECC'05), 2005
- [14] 付梦印, 邓志红, 张继伟, Kalman 滤波理论及其在导航系统中的应用, 北京: 科学出版社, 2003.
- [15] Jazwinski A. H., Stochastic processes and filtering theory, New York: Academic Press, 1970.
- [16] Hoshiya M. & Saito E., Structural identification by extended kalman filter, J. Eng. Mech., 1984, Vol.110 (12):1757~1772.
- [17] Hoshiya M., Maruyama O., Identification of running load and beam system, J. Eng. Mech., 1987, Vol.113 (6):813~824.
- [18] Koh C. G., See L. M. & Balendra T., Estimation of structural parameters in time domain: a substructure approach, Earthquake Eng. & Struct. Dynamics, 1991, Vol.20 (8):787~801.
- [19] 尚久铨, 卡尔曼滤波法在结构动态参数估计中的应用, 地震工程与工程振动, 1991, Vol.11 (2):62-72.
- [20] Hera A. & Hou Z. Application of Wavelet Approach for ASCE Structural Health Monitoring Benchmark Studies. Journal of Engineering Mechanics, 2004, Vol.130 (1): 96~104
- [21] 李洪泉, 董亮, 吕西林. 基于小波变换的结构损伤识别与试验分析. 土木工程学报, 2003, Vol.36(5): 52-57
- [22] Melhem H. & Kim H. Damage Detection in Concrete by Fourier and Wavelet Analyses. Journal of Engineering Mechanics, 2003, Vol.129 (5): 571~577

- [23] Kim H. & Melhem H. Fourier and wavelet analyses for fatigue assessment of concrete beams. *Experimental Mechanics*, 2003, Vol.43 (2): 131~140
- [24] 唐和生, 薛松涛, 陈镭等. 基于小波多分辨滤波特性的结构损伤识别. *力学季刊*, 2004, Vol.25(1): 152-155
- [25] 徐丽娜. 神经网络控制. 哈尔滨:哈尔滨工业大学出版社, 1999.
- [26] 何玉彬, 李新忠. 神经网络控制技术及其应用. 北京:科学出版社, 2000.
- [27] 周西峰. 系统辨识与建模的一种新方法. *信息与控制*, 2000, Vol.4 (2):131-138.
- [28] Krzyzaka. NonParametric estimation and classification using radial basis function nets and empirical risk minimization[J]. *IEEE Trans. On Neural Networks*, 1996, Vol.7 (2):475~487.
- [29] Narfndraks & Parthasarathy K. Identification and control of dynamical system using neural networks. *IEEE Trans. On Neural Networks*, 1990, Vol.1 (1):4~27.
- [30] James K. & Russell C. E., *Swarm intelligence*, New York:AcademicPress, 2009
- [31] Koh C.G, Hong B. & Liaw C.Y., Parameter identification of large structural systems in time domain, *J. Struct.Eng.*, 2000, Vol.126 (8):957~963.
- [32] Koh C.G, Chen Y. F. & Liaw C.Y., A hybrid computational strategy for identification of structural parameters. *Computers and Structures*, 2003, Vol.81:107~117.
- [33] Koh C.G, Hong B. & Liaw C.Y., Substructural and progressive structural identification methods. *J. Eng.Struct.*, 2003, Vol.25:1551~1563.
- [34] Doyle J.F., Determining the size and location of transverse cracks in beams. *Experimental Mech.*, 1995, Vol.35:272~280.
- [35] Dunn S.A., The use of genetic algorithms and stochastic hill-climbing in dynamic finite element model identification. *J. Comp. and Struct.* 1998, Vol.66 (4):489~497.
- [36] Chou J.H. & Ghaboussi J., Genetic algorithm in structural damage detection. *J. Comput. & Struct.* 2001, Vol.79:1335~1353.
- [37] Carlin R A & Garcia E. Parameter optimization of a genetic algorithm for structural damage detection. in: *Proc. of 14<sup>th</sup> International Modal Analysis Conference*. Dearborn, 1996. 1292~1298
- [38] Koh C G, Zhao S L & Chen Y F. Non-destructive parameter identification of structures. in: *Newport Beach, CA, United States: The International Society for Optical Engineering*, 2002, 20~27
- [39] 易伟健, 刘霞. 结构损伤诊断的遗传算法研究. *系统工程理论与实践*, 2001, Vol.(5): 114-118
- [40] Dorigo M., Maniezzo V. & Colorni A. Ant system: optimization by a colony of cooperation agents. *IEEE Trans. on System, Man, and Cybernetics-Part B*, 1996, Vol.26(1)29~41.
- [41] Kennedy J. & Eberhart R. C. Particle Swarm Optimization. In: *Proc. of IEEE International Conference on Neural Networks*. Perth, Australia, 1995, 1942~1948.
- [42] Elegbede, C. Structural reliability assessment based on swarm optimization, *J. Struct. Safety*, 2005, Vol.27: 171~186
- [43] Perez R. & Behdinan K. Particle swarm approach for structural design optimization, *J. Comput. & Struct.* 2007, Vol.85 (19~20): 1579~1588
- [44] Coelho L. S. & Krohling, R. A. Nonlinear system identification based on B-spline neural network and modified particle swarm optimization, in: *Proc. IEEE World Conference on Computational Intelligence (WCCI), Int. Joint-Conf. on Neural Networks*, Vancouver,



- Canada, 2006
- [45] 张伟, 唐和生, 薛松涛. 基于粒子群优化的结构系统识别. 燕山大学学报, 2009, Vol.33(1), 103-112
- [46] 张伟. 基于粒子群优化算法的结构参数及损伤识别: [博士学位论文]. 上海: 同济大学, 2008.
- [47] Storn R. & Price K. Differential evolution-A simple and efficient adaptive scheme for global optimization over continuous spaces. *J. Global Optimization*, 1997, Vol.11(4):341~359
- [48] Hesheng T., Songtao X. & Cunxin F., Differential evolution strategy for structural system identification. *J. Comput. & Struct*, 2008, 2004~2012.
- [49] Kyprianou A., Worden K. & Pane T. M. Identification of hysteretic systems using the differential evolution algorithm. *J. Sound & Vibration*, 2001, Vol.11 (4):241~255.
- [50] Chang W. D. Parameter identification of Chen and Lü systems: a differential evolution approach *Chaos, J. Solitons & Fractals*, 2007, Vol.26 (1):29~41.
- [51] 孙鸿敏, 李宏男. 土木工程结构健康监测研究进展. 防灾减灾工程学报, 2003, Vol.85 (19): 1579-1588
- [52] 王术新, 姜哲. 基于结构振动损伤识别技术的研究现状及进展. 振动与冲击, 2003, Vol.23 (4): 99-102.
- [53] 刘济科, 汤凯. 基于振动特性的损伤识别方法的研究进展. 中山大学学报, 2004, Vol.43 (6): 57-61.
- [54] Duan Q. Global Optimization for Watershed Model Calibration. *J. Mol. Water Sci. Appl.* 2003 Vol.6:89~104.
- [55] Duan Q., Gupta V.K. & Sorooshian S.: Effective and Efficient Global Optimization for Conceptual Rainfall Runoff Models. *J. Water Resour. Research.* 1992, Vol.28:1015~1031.
- [56] Duan Q., Gupta V.K. & Sorooshian S.: Shuffled Complex Evolution Approach for Effective and Efficient Global Minimization. *J. Optim. Theory Appl.* 1993, Vol.76:501~521.
- [57] Duan Q., Sorooshian S. & Gupta V.K.: Optimal Use of the SCE-UA Global Optimization Method for Calibrating Watershed Models. *J. Hydrol.*, 1994, Vol.158:265~284.
- [58] Nelder J.A. & Mead R.: A Simplex Method for Function Minimization. *Comput. J.* 1965, Vol.7:308~313.
- [59] Jasper A. V., Hoshin V. G., Willem B. & Soroosh S., A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. *J. Water Resour. Research.* 2003, Vol.39:1201~1215.
- [60] Raido P., Zoran K., Dragan S., & Tiit K. Probabilistic Leak Detection in Pipe Networks Using the SCEM-UA Algorithm. In:Proc. 8th WDSAS. 2006:1103~1112.
- [61] Stefan C. D. & Willem B., Identification of rainfall interception model parameters from measurements of throughfall and forest canopy storage. *J. Water Resour. Research.* 2003, Vol.39:1251~1260.
- [62] Gong Z. & Aldeen M., Stabilization of decentralized control systems. *J. Math.Sys. Estimation & Contrl.* 1997:35~51.
- [63] Kuczera G, Efficient subspace probabilistic parameter optimization for catchment models, *Water Resour. Res.*, 1997, Vol.33:177~185.
- [64] Luce C. H. & Cundy T. W., Parameter-identification for a runoff model for forest roads, *Water Resour. Res.*, 1994, Vol.30:1057~1069.

- [65] Sorooshian, S., Duan Q. Y. & Gupta V. K., Calibration of rainfall-runoff models — Application of global optimization to the Sacramento Soil-Moisture Accounting Model, *Water Resour. Res.*, 1993, Vol.29:1185~ 1194.
- [66] Tanakamaru H. & Burges S. J., Application of global optimization to parameter estimation of the tank model. In: *International Conference on Water Resources and Environment Research*, Water Resour. Cent., Kyoto Univ., Kyoto, Japan, 1996:29~31.
- [67] Thyer M., Kuczera G. & Bates B. C., Probabilistic optimization for conceptual rainfall-runoff models: A comparison of the shuffled complex evolution and simulated annealing algorithms, *Water Resour. Res.* 1999, Vol.35:767~ 773.
- [68] Tolson B. A., Automatic calibration, management and uncertainty analysis: Phosphorus transport in the Cannonsville watershed, Ph.D. thesis, Cornell Univ., Ithaca, N. Y., 2005.
- [69] Perry M.J., Koh C.G. & Choo Y. S., Modified genetic algorithm strategy for structural identification, *J. Comput. & Struct.* 2006, Vol.84: 529~540.
- [70] 冯新, 李国强, 周晶. 土木工程结构健康诊断中的统计识别方法综述. *地震工程与工程振动*, 2005, Vol.25(2):105-114.
- [71] 刘冀, 径流分类组合预报方法及其应用研究. [博士学位论文]. 大连: 大连理工大学, 2008.
- [72] 李向阳. 水文模型参数优选及不确定性分析方法研究. [博士学位论文]. 大连: 大连理工大学, 2008.
- [73] Metropolis N., Rosenbluth A. W. & Rosenbluth M. N. Equations of state calculations by fast computing machines. *J. Chem. Phy.* 1953, Vol.21:1087~1092.
- [74] 林铨云, 董加礼, 多目标优化的方法与理论, 吉林:吉林教育出版社, 1992.
- [75] Deb K., Pratap A., Agarwal S. & Meyarivan T. A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE Trans. Evolutionary Computation*, 2002, Vol.6 (2):182~197.
- [76] 王彬. 熵与信息. 西安: 西北工业大学出版社, 1994.
- [77] 孟庆生. 信息论. 西安: 西安交通大学出版社, 1989.
- [78] 吴乃龙. 袁素云. 最大熵方法长沙: 湖南科学技术出版社, 1991.

## 个人简历、在读期间发表的学术论文与研究成果

### 个人简历:

李鹏飞, 男, 1984 年 12 月生。

2007 年 7 月毕业于清华大学土木工程专业 获学士学位。

2007 年 9 月入同济大学读硕士研究生。

### 已发表论文:

[1] Pengfei L., Hesheng T., Zhaoliang W., Parameter estimation using a SCE Strategy.

Neural Information Proceeding. (5864), 2009, 107~113.

[2] Zhaoliang Wang, Hesheng Tang, Pengfei Li, Optimum Design of Truss Structures

Based on Differential Evolution Strategy. In:2009 ICIECS, 2009, 1576~1580.