

Algorithms in intelligent  
control systems of

# aerocrafts 飞行器

## 智能控制系统中的算法

柯芳 聂吾希宾 K A 著



四川大学出版社

责任编辑:毕 潜  
责任校对:张 阅  
封面设计:墨创文化  
责任印制:李 平

### 图书在版编目(CIP)数据

飞行器智能控制系统中的算法 / 柯芳, (俄罗斯) 聂吾希宾著. —成都: 四川大学出版社, 2011.6  
ISBN 978-7-5614-5311-7  
I. ①飞… II. ①柯… ②聂… III. ①飞行控制系统—智能控制—算法 IV. ①V249.122

中国版本图书馆 CIP 数据核字 (2011) 第 105608 号

### 内容简介

本书是作者将“功能—智能系统”用于飞行器控制的研究成果的总结, 内容主要包括飞行器“功能—智能”控制系统的概念综合、实现行动感知器的预测算法和非线性控制算法。书中提供了大量的数学仿真结果, 以证实所研制的预测及控制算法的有效性。为了使读者对智能控制系统能有较全面的认识, 开篇就给出了飞行器智能控制系统研制进展的综述, 还简要列举了广泛采用的传统智能组件, 并对建模中采用的自组织方法作了专门介绍。

本书读者对象为大学自动控制专业高年级学生、研究生和从事智能控制系统研究的科技工作者及工程技术人员。

### 书名 飞行器智能控制系统中的算法

---

著 者 柯 芳 聂吾希宾 K A  
出 版 四川大学出版社  
地 址 成都市一环路南一段 24 号 (610065)  
发 行 四川大学出版社  
书 号 ISBN 978-7-5614-5311-7  
印 刷 郫县犀浦印刷厂  
成品尺寸 185 mm×260 mm  
印 张 11  
字 数 247 千字  
版 次 2011 年 7 月第 1 版 ◆ 读者邮购本书, 请与本社发行科  
印 次 2011 年 7 月第 1 次印刷 联系。电 话: 85408408/85401670/  
定 价 28.00 元 85408023 邮政编码: 610065

---

版权所有◆侵权必究

◆本社图书如有印装质量问题, 请寄回出版社调换。  
◆网址: www.scupress.com.cn

## 序 言

在现代科学技术飞速发展的今天，控制科学与技术学科面临巨大的机遇与挑战，传统控制理论也正遭遇前所未有的困难。与此同时，控制论、信息论，特别是在人工智能研究中的成果衍生了进行复杂非线性控制系统建模、控制及优化的一些新的手段。在这样的背景下，在现代控制理论、人工智能、神经网络及微电子学等学科的交叉发展趋势中，形成并积极发展了研究开发的新领域——智能控制。智能控制系统是目前解决复杂对象控制问题的最好手段。

现代智能控制系统建立在多种概念和理论之上，目前还没有建立智能控制系统的标准体系结构。其中，于 20 世纪 90 年代初由前苏联提出并发展的，基于功能系统理论的智能系统成为最具发展前景的智能系统之一。现代飞行器作为复杂的非线性动态对象，正是基于功能系统理论的智能系统发挥作用的重要领域。作者的研究工作正是在这一背景下开展的，即进行基于功能系统理论的飞行器智能控制系统的概念综合，重点是研究飞行器智能控制系统中的预测和控制算法。在预测上，作者提出了依靠自组织算法实现的改进型 Demark 趋势项来建立预测模型，并在此基础上建立了智能系统中的行动感知器；在控制手段上，作者采用微分几何理论，实现了基于对象模型精确线性化的继电调节器。

为充分验证所研制算法的有效性，作者进行了大量的数学仿真工作，并在仿真中使用了对实际产品进行半实物仿真和实物试验中获得的数据。作者将提出的改进型 Demark 趋势项算法用于惯性导航系统输出参数误差的预测与修正和导航综合系统最优结构的选择，提高了惯导系统输出参数的精度和导航综合系统的参数测量精度。将基于对象模型精确线性化的继电调节器用于发动机推力矢量/气动力复合控制的导弹对机动目标的制导，在运用传统的比例导引律的情况下，在垂直平面内达到了满意的制导精度。

上述预测及控制算法的构想不仅具有独创性，而且均针对飞行器控制的实际要求，即高度机动性、实现紧凑快速及高精度。因此，无论作为未来新一代飞行器智能控制系统中的算法，还是在当前系统中可独立使用的智能组件，均具有一定的理论指导及现实意义。

作者衷心希望书中介绍的算法和实现的思路能为相关领域的研究人员带来启发，并为基于功能系统理论的智能控制系统研究在中国的发展起到推动作用。由于作者学识水平所限，书中错误和疏漏在所难免，恳请读者批评指正。

柯 芳 聂吾希宾 K A

2011 年 5 月

## 前 言

各种飞行器的控制由控制系统实现。通常，飞行器控制系统都是建立在使用周围环境的先验信息基础之上的，系统目标的概念退化为解决由系统处理某个规划好的信号的任务，只是在某些时候才引入对某种变化条件具有适应功能的系统元件。事实上，系统工作的所有智能部分由人来完成，他们将控制系统的运行转化为实现他们所制定的固定的算法。实际应用中系统工作的环境在改变，系统自身状态的特性也在发生变化，而要在预先固定好的算法中考虑到所有这些变化，事实上是不可能的。因此，上述控制系统的精度会降低，在某些实际应用场所甚至完全不可能使用这样的系统来完成任务。客观情形要求用新的观点来建立系统。

当前飞行器用于完成非常复杂的任务时，要求它们在飞行中进行行动目标的综合，考虑自身和外部环境状态的各种不同因素来采取最优行动决策，并精确执行这些决策。现代飞行器的这些功能可以借助新一类的控制系统——智能系统来实现。

我们将智能系统理解为由信息过程连接起来的技术设备和软件的综合体，它可以与人（或人的集体）一起或独立工作，能够在使用信息和知识的基础上，在存在动机的条件下综合出目标、制定行动决策并找到达到目标的合理方式。

我们可以依据各种不同的原则建立智能系统。其中，于 20 世纪 90 年代初在前苏联提出并发展的，基于功能系统理论的智能系统成为最具发展前景的智能系统之一。功能系统理论是由前苏联科学家阿诺辛（Анохин Р К）奠定的，其基本思想认为在外界环境变化的条件下，人体是具有选择性地连接各个功能模块而使整体具有有益适应特性的一个完整的系统。他将这一系统称为功能系统，而功能系统又由若干子功能系统构成。将功能系统理论用于复杂动态对象控制，可以使整个系统建立在多个功能系统共生的基础上，包括目标综合模块、行动感知器、动态专家系统、决策与控制，共同保证有益目标的实现，使其本质上具有对自身及外界环境变化的适应能力。现代飞行器作为复杂的非线性动态对象，正是基于功能系统理论的智能系统发挥作用的重要领域。

在这一背景下，作者提出了研究工作的目标，即基于功能系统理论的飞行器智能控制系统的概念综合，并具体实现行动感知器（建立预测模型）和控制算法。本着这一目标，作者取得了以下的研究成果：

(1) 提出了具有上、下两级控制层次的飞行器智能控制系统结构框图。该结构充分运用了功能系统理论的思想，在行动感知器的预测模型基础上，可以综合出飞行器运行最佳场景并实现该场景，使其从根本上优于已有的不含目标综合的系统，并具体指明了目标综合和目标实现环节的算法保障措施。

(2) 提出了用自组织方法对 Demark 趋势项进行修正的改进型算法，用该算法建立了飞行器参数预测模型，实现了智能控制系统中的行动感知器。运用这一算法对高度机动飞行器导航系统误差进行预测，提高了导航参数确定的精度。

(3) 采用基于微分几何理论的反馈线性化方法对飞行器进行控制，实现了发动机推力矢量/气动力复合控制导弹对机动目标的制导，达到了满意的制导精度。

飞行器智能控制系统研制是复杂、多层次的任务，适宜于分步骤解决，因而作者所实现的预测和控制算法无论是作为飞行器智能控制系统中的重要组成部分，还是作为在传统控制系统中可独立使用的智能性组件，均具有重要的理论和现实意义，它们是基于功能系统理论的智能系统在飞行器控制中取得的最新成果。

本书正是对上述研究成果的详细介绍，核心是飞行器智能控制系统中的算法。书中给出了：

(1) 飞行器智能控制系统研究进展综述。

(2) 基于功能系统理论的飞行器智能控制系统结构框图。

(3) 建立在 Demark 趋势项和自组织方法相结合基础上的实现预测模型的紧凑算法。

(4) 基于微分几何理论的智能系统的反馈线性化控制算法。

(5) 在对返回大气层式无人飞行器系统生成分析基础上得到的无人飞行器智能控制系统行动感知器算法保障的结构。

(6) 将建立的预测算法用于惯性导航系统参数误差修正和导航系统最优结构选择的数学仿真结果。

(7) 将建立的控制算法用于发动机推力矢量/气动力复合控制导弹对机动目标制导的仿真结果。

(8) 返回大气层式无人飞行器系统生成三个阶段中实行动感知器的仿真结果。

开展的研究和所得成果的科学创新点在于对现有飞行器智能控制系统的系统分析、最有前景的飞行器智能控制系统结构选择的论证和作为飞行器智能控制系统重要组成部分的预测和控制算法的建立。这些算法是独创性的。其中：预测算法是借助自组织方法对 Demark 趋势项进行直接改型；控制算法基于微分几何理论，允许实现非线性调节器到与之符合的线性调节器的继电切换。

本书工作成果的实用价值在于：第一，给出了建立惯性导航系统误差预测数学模型的算法，该算法具有紧凑性特点，可适用于高度机动的飞行器，既保证了较高的精度，又满足快速性要求。第二，将建立的控制算法应用于发动机推力矢量/气动力复合控制导弹，实现了对垂直平面内高度机动目标的制导，达到了满意的制导精度。此外，依靠在飞行器运行的一定区域从非线性调节器切换到线性调节器，可以大大简化飞行器智能控制系统中控制过程的实现。在这些区域中，向线性空间的切换可以在不损失精度的条件下进行。第三，在对无人飞行器智能控制系统生成进行分析的基础上，实现了无人飞行器运行的每一阶段控制系统算法保障的选择，这大大地节约了计算资源，并提高了系统的快速性。

书中得到的结果及结论的可靠性由所获得的数学模型与从实验室半实物仿真实验结

果中获得的惯性导航系统误差变化的实际过程具有足够的吻合度来保证；在控制算法的仿真中使用了由风洞吹风试验获得的对象气动参数，且所获得的结果与该领域发表的相关数据的一致性也提供了可信度的证据。

基于书中介绍的研究成果已公开发表了 17 篇论文，其核心内容也在相应的国际会议上进行了公布和报告，主要有：

- (1) “第二届控制问题国际会议”，俄罗斯，莫斯科，2003 年 6 月。
- (2) “2003 智能自动化大会”，中国，香港，2003 年 12 月。
- (3) “第六届国际研讨会：智能系统”，俄罗斯，萨拉托夫，2004 年 6 月。
- (4) “国际科学实践大会：电子设备和控制系统”，俄罗斯，托蒙斯克，2004 年 9 月。
- (5) “第二十九届宇航学术会议”，俄罗斯，莫斯科，2005 年 1 月。

本书篇章结构由前言、7 个章节、结论和参考文献组成，其中第 1、4、5、6、7 章为核心章节，集中反映了基于功能系统理论的飞行器智能控制系统概念综合的思想以及作者建立的预测和控制算法。

第 1 章进行了飞行器智能控制系统研究进展的分析与综述，简要回顾了基于动态专家系统的飞行器自适应控制系统和当今广泛采用的飞行器建议控制系统；在分析智能系统发展趋势的基础上，推荐了建立在阿诺辛提出的功能系统理论基础上的最具发展前景的智能系统（以下简称“功能—智能系统”），给出了结构框图，介绍了该智能系统核心模块的预测算法、控制算法、目标综合和动态专家系统的构建问题，重点放在目标综合模块上。为了使读者在开篇就能对本书有概貌性的认识，在该章中还简要介绍了作者将功能系统理论用于飞行器控制取得的最新成果，着重描述了功能—智能控制系统结构框图和关键部分的实现过程。在对智能控制系统的功能结构及其算法保障进行分析的基础上，给出了在实际应用中建立工作有效、性能良好的智能系统的建议。

第 2 章回顾了广泛采用的传统智能组件，即人工神经网络、进化计算、专家系统和模糊控制，对它们的基本工作原理、主要特点及研究发展的新方向进行了简要介绍。由第 1 章的分析结果表明，传统智能组件及其融合技术将用于功能—智能系统中各子功能系统的独立实现。

第 3 章对自组织方法理论作了专门的介绍，给出了自组织建立的原则和自组织算法实现的主要步骤。自组织方法是一种智能性的数学建模方法，是作者建立预测模型所依据的主要理论基础。该章的内容能使读者更好地理解作者提出的预测算法的数学基础，也是深入掌握自组织方法的入门性知识。

第 4 章是关于无人飞行器智能控制系统的行动感知器的研制。该章介绍了作者提出的建立预测模型的独创性算法，是本书的核心章节之一。预测模型是行动感知器的基础，预测算法的紧凑性和快速作用性是对无人飞行器智能控制系统算法保障的特殊要求，这是无人飞行器运行的特点所决定的。根据这些要求，对自组织和短时间序列的建模方法进行了分析。考虑到这些要求，选择了使用 Demark 趋势项建立算法。Demark 趋势项的特点是实现简单、紧凑，其建立要求的时间最少。但是传统的 Demark 趋势项精度不高，很难运用在无人飞行器高度机动的情况下。因此，在实际应用中，Demark

趋势项只可以在无人飞行器接近直线的飞行段使用。为了适用于高度机动的飞行器，作者提出了用非线性项对 Demark 趋势项进行修正，而非线性修正项用自组织算法获得，这样就得到了 Demark 趋势项与自组织算法相结合的改进型算法。改进型算法提高了预测模型建立的精度，同时又满足紧凑性和快速性要求，可以在无人飞行器机载数字计算机计算时间和机器存储容量有限的条件下建立预测模型。

第 5 章介绍了研制的无人飞行器智能控制系统的体系结构以及上层控制中的目标综合算法和下层控制中的目标实现算法，是本书的又一核心章节。目标的综合是实现场景选择的决策算法，决策依据评价函数实现，在评价函数中包含了适合于具体任务的总准则，它们按照技术系统决策方法的经典理论来选择。而下层控制保证以最优方式实现上层控制所选出的最优场景，为此系统采用了极大值原理和变分法。但即使对于线性被控对象，非线性控制算法的实现也非常复杂，对高阶的非线性对象，更是难以实现，因此，提出了削减计算量而不损失精度的任务。作者采用基于微分几何理论的反馈线性化方法实现了控制对象模型的精确线性化，从而在无人飞行器运行的过程中划分出使用线性数字模型和对应非线性调节器的区域，这些线性模型与原非线性模型完全吻合，因而不损失精度。在此基础上，设计了飞行器运动控制的继电调节器，使得最优控制的算法可以针对对象的线性化模型设计。分别针对采用主发动机推力控制和推力矢量/气动力复合控制的导弹，应用上述反馈线性化方法，得到了两种控制方案，将其用于对机动目标的制导，达到了良好的制导精度。

第 6 章介绍了对返回大气层式无人飞行器控制系统的算法组成的研究结果。通过对无人飞行器智能控制系统的系统生成的分析，可以对无人飞行器生命周期的各个阶段算法保障的使用给出建议。作者研究了返回大气层式无人飞行器运行的三个基本阶段，对每个阶段运行的特殊性进行了分析，在分析的基础上实现了行动感知器中特殊算法保障的选择。

第 7 章是关于作者所研制算法的仿真结果，是算法有效性的直接证明。所给出的结合 Demark 趋势项和自组织算法的改进型预测算法的有效性，以惯性导航系统误差预测任务和无人飞行器智能控制系统行动感知器中飞行器测量系统结构的选择任务为例进行了演示，并进行了改进型算法与传统的自组织算法和传统的线性算法的比较分析。除了数学仿真外，还使用从实际批量生产的导航系统的半实物试验中获得的数据进行了仿真。将无人飞行器智能控制系统行动感知器在系统生成的三个基本阶段的预测算法的仿真结果与自组织方法和线性趋势项的预测结果进行了比较。此外，还进行了发动机推力矢量/气动力复合控制导弹对垂直平面内机动目标实施制导过程的仿真，达到了良好的制导精度，验证了所提出的基于微分几何理论的反馈线性化算法的有效性。以上各项仿真的结果共同证实了所研制的预测及控制算法具有足够高的精度，可以将它们用于飞行器功能—智能控制系统中。

结论部分对作者所取得的主要创新工作成果再次进行了总结。

# 目 录

第1章 飞行器智能控制系统研究进展	( 1 )
1.1 引言	( 1 )
1.2 飞行器控制系统中智能控制的前期应用	( 3 )
1.2.1 带预测模型的专家系统	( 3 )
1.2.2 神经元网络自适应系统	( 4 )
1.2.3 咨询式智能系统	( 6 )
1.3 “功能—智能系统”的概念综合	( 7 )
1.3.1 “功能—智能系统”结构	( 7 )
1.3.2 目标综合模块	( 8 )
1.3.3 动态专家系统	( 10 )
1.3.4 实现行动感知器的预测算法	( 12 )
1.3.5 智能系统中的非线性控制算法	( 14 )
1.4 “功能—智能系统”在飞行器控制中实现的最新成果	( 15 )
1.4.1 系统实现框图	( 15 )
1.4.2 上级控制中的目标综合算法	( 15 )
1.4.3 下级控制中的控制算法	( 16 )
1.4.4 仿真研究结果	( 17 )
1.4.5 结论	( 18 )
1.5 本章内容小结	( 19 )
第2章 传统智能组件	( 20 )
2.1 人工神经网络	( 20 )
2.1.1 神经网络结构及学习方法	( 21 )
2.1.2 神经网络的工作方式	( 23 )
2.1.3 前向神经网络数学模型	( 23 )
2.1.4 神经网络发展趋势	( 26 )
2.2 进化计算	( 27 )
2.2.1 遗传算法的基本思想和特点	( 27 )
2.2.2 遗传算法的基本原理	( 28 )
2.2.3 遗传算法的设计与实现	( 29 )
2.3 专家系统	( 35 )

2.3.1 专家系统的基本结构 .....	( 35 )
2.3.2 专家系统的知识表示法 .....	( 36 )
2.3.3 专家系统的推理机制 .....	( 38 )
2.4 模糊控制 .....	( 40 )
2.4.1 模糊理论基础 .....	( 41 )
2.4.2 模糊模型 .....	( 45 )
2.4.3 模糊控制器 .....	( 46 )
2.5 传统智能组件融合技术研究 .....	( 49 )
2.6 本章内容小结 .....	( 50 )
<b>第3章 预测及模型自组织方法</b> .....	( 51 )
3.1 预测和预测的方法 .....	( 51 )
3.1.1 预测任务的提出 .....	( 51 )
3.1.2 以控制理论的术语来提出预测的任务 .....	( 51 )
3.1.3 短期预测和长期预测 .....	( 52 )
3.1.4 预测的试验方法 .....	( 53 )
3.1.5 需要的先验信息 .....	( 53 )
3.2 启发式自组织 .....	( 54 )
3.3 “自组织”术语的其他应用.....	( 54 )
3.4 模型自组织的基本原则 .....	( 55 )
3.4.1 数学模型自组织 .....	( 55 )
3.4.2 模型自组织算法 .....	( 63 )
3.4.3 基函数形式和方程类型的选择 .....	( 71 )
3.4.4 筛选的准则 .....	( 75 )
3.4.5 正规性准则形成方法 .....	( 84 )
3.4.6 МГУА 理论的基本状况 .....	( 87 )
3.5 本章内容小结 .....	( 90 )
<b>第4章 飞行器智能控制系统中行动感知器的建立</b> .....	( 92 )
4.1 自组织方法建模的应用 .....	( 92 )
4.2 短时间序列建模的应用 .....	( 96 )
4.2.1 时间序列的描述 .....	( 96 )
4.2.2 专家判断 .....	( 97 )
4.3 改进型 Demark 趋势项建模 .....	( 99 )
4.4 本章内容小结 .....	( 102 )
<b>第5章 飞行器智能控制系统控制算法的研制</b> .....	( 103 )
5.1 控制算法的体系结构 .....	( 103 )
5.2 体系上层中的决策 .....	( 104 )
5.3 体系下层中的控制回路结构 .....	( 108 )
5.4 体系下层中的最优控制律 .....	( 109 )

5.5 基于微分几何理论的对象模型精确线性化 .....	(111)
5.6 飞行器控制继电调节器的研制 .....	(117)
5.7 本章内容小结 .....	(121)
<b>第6章 返回大气层式无人飞行器智能控制系统的“系统生成” .....</b>	<b>(122)</b>
6.1 问题的提出 .....	(122)
6.2 返回大气层式无人飞行器智能控制系统的运行过程 .....	(122)
6.3 智能系统“系统生成”的基本阶段 .....	(124)
6.4 返回大气层式无人飞行器运动的各阶段行动感知器的运行过程 .....	(125)
6.5 本章内容小结 .....	(126)
<b>第7章 算法的仿真研究.....</b>	<b>(128)</b>
7.1 用改进型 Demark 趋势项建立惯性导航系统误差预测模型的数学 仿真 .....	(128)
7.1.1 惯性导航系统输出速度参数及误差修正 .....	(129)
7.1.2 惯性导航系统输出速度参数误差的预测模型 .....	(129)
7.1.3 仿真结果 .....	(130)
7.2 基于改进型 Demark 趋势项进行导航系统结构选择的数学仿真 .....	(134)
7.3 返回大气层式无人飞行器“系统生成”三个阶段中行动感知器实现的 数学仿真 .....	(135)
7.4 发动机推力矢量/气动力复合控制导弹对机动目标实施制导的数学 仿真 .....	(138)
7.4.1 导弹动力学模型 .....	(138)
7.4.2 导弹数学模型的反馈线性化及控制律设计 .....	(139)
7.4.3 仿真中对系统实际条件的考虑 .....	(140)
7.4.4 仿真结果 .....	(141)
7.4.5 结论 .....	(151)
7.5 本章内容小结 .....	(152)
<b>结论.....</b>	<b>(153)</b>
<b>参考文献.....</b>	<b>(155)</b>

# 第1章 飞行器智能控制系统研究进展

## 1.1 引言

在现代科学技术飞速发展的今天，控制科学与技术学科面临巨大的机遇与挑战。传统控制理论正遭遇前所未有的困难，主要体现在以下几个方面：第一，对象的复杂性、高度非线性和不确定性导致系统辨识和建模的困难，在控制系统中总存在未建模动力学，它需要通过学习过程或者实时地获得缺失信息来解决建模问题；第二，线性系统控制理论在解决复杂的对象特性和复杂的控制任务时面临困难；第三，在一系列的情况下控制问题中的函数关系经常不能被解析地表达，往往需要利用专家判断、经验和知识、定性、逻辑、语言等新途径来解决问题。

与此同时，控制论、信息论，特别是在人工智能研究中的成果衍生了进行复杂非线性控制系统建模、控制及优化的一些新的手段。在这样的背景下，在现代控制理论、人工智能、神经网络及微电子学等学科的交叉发展趋势中，形成并积极发展了研究开发的新领域——智能控制。智能控制系统是目前解决复杂对象控制问题的最好手段。

与许多先进学科的概念一样，智能控制系统直到目前都没有一个公认的明确定义，人们根据它的技术特征和发展历程给出了一个定义：智能控制系统是能够在复杂、不确定环境中，自主地运用定性与定量相结合的方法，实行信息处理、决策优化与控制优化，从而能够有效地解决复杂与不确定任务的系统。其主要特点有：①智能控制通常是一个混合的控制过程，建立在数学和非数学的模型基础上，能更充分地使用关于对象和环境的知识，以预定的准则进行可靠的控制，如已知期望的轨迹、控制品质泛函、目标集合等；②智能控制是综合利用现代控制理论、人工智能、专家经验、神经网络、进化算法和计算机科学等新兴技术来协调解决复杂过程控制问题。

大约从 20 世纪 80 年代开始，传统上属于人工智能的思想开始在控制理论及实践中得到运用，文献 [1] 对此进行了总结。进入控制系统中的对应研制部分，通常被称为控制系统的智能手段，文献 [2] 列举了被广泛认可的传统智能组件，即神经网络、进化算法、专家系统、逻辑推理机制、模糊控制等。在文献 [3, 4] 中详细介绍了神经网络算法的类型及其在机器人学、工艺过程控制、远程通讯、人工视觉系统（图像处理）、航空航天等领域的应用。将进行决策的神经元机制与逻辑机制相结合，可以使智能系统的功能更为强大。文献 [5~11] 介绍了得到广泛应用的各种进化算法及其在移动机器人运动路线布局和实时控制任务中的应用。其中，文献 [9] 指出，进化算法与神经元

网络具有高并行性，其结果是更高的快速性，这对于实时完成辨识和控制任务而言是非常重要的。不过，文献 [10] 也指出了其局限性：当前的人工神经网络所模拟的“眼睛的功能多于大脑的功能”；类似的，进化算法模拟的是达尔文类型的自然现象的组织，却还不是创造性过程。文献 [12] 给出了专家系统的定义。文献 [13~18] 比较系统地介绍了在专家系统中为表示知识和解决问题，通常使用的基于规则和逻辑推理的有关机制，其中较有前景的是使用对象—逻辑语言、框架逻辑和逻辑编程的基于知识的系统。由于保存在知识库中且决策基于的大量信息是不准确、不完全或者不完全可靠的，因此，带模糊逻辑的专家系统得到越来越广泛的应用。文献 [19] 介绍了基于模型和分析方法的现代模糊控制，常用的有 Mamdani 模型和 T-S 模型。

现代智能控制系统建立在多种概念和理论之上，还没有建立智能控制系统的标准体系结构。早在几十年前，在维纳（Винер Н）的著作中就出现了有关智能机雏形的概念。随着用信息量来评价的系统复杂度水平的增加，应该尝试使用、建立和发展智能化水平更高的系统和控制组件。在文献 [28~30] 中提出了建立智能控制系统的五种原则：①信息交换的原则：系统与变化的外部世界相互作用（世界模型），获得信息，补充知识，用于决策；②用于自学习和自组织的智能控制系统的开放性原则：在获得知识的过程中系统的智能组件形成充分符合实际环境的模型；③预测变化的原则：在各种假设前提下，对世界（环境和系统）变化的动态行为进行预测，以评价和挑选最可取的控制；④智能化程度降低而精度增长的原则：存在多级结构，随着系统中控制级别的提高而提高智能化程度和降低对精度的要求；⑤局部性递减原则：在工作中如果较高级别的控制受到破坏，应允许部分损失系统的性能。

文献 [1] 中将智能系统划分为四类，即辨识控制系统、自适应控制系统（带自调整的系统）、不含目标综合的智能控制系统和带目标综合的智能控制系统，其智能化程度逐步增加。其中，带目标综合功能的智能控制系统是智能程度最高的，本质上区别于前三类的智能控制。对于这种智能程度较高的系统，按照前面给出的原则④，可考虑智能控制的三个级别：①控制上级：目标综合；②控制中级：寻找达到上级中给定的目标的途径；③控制下级：实现中级所选定的途径（以求达到上级所给定目标）的方法。

在文献 [22, 26, 27] 中讨论了上级、中级和下级控制中的算法，并提及了由机载计算机所支持的传统机载算法和指示保障的结构的局限性。

在现在和最近的将来，基于这三个级别的智能控制系统将按照下列方式工作：

(1) 提出确定的工作目标。从具体的标准情景的确定集合中选择一个情景，目标综合任务的解决完全放在操作员身上，机载算法和指示保障的设计者仅为操作员建立外部状况的信息模型，并在机舱的控制区域安放信号引入的专门机构。

(2) 分析达到目标的可能方式，并从中选择最可取的方式。中级控制任务的解决由对应标准情景的机载快速建议专家系统完成，该系统下一步发展的趋势是使用逻辑推论的方法。

(3) 按选择的方法执行操作以实现目标。下级控制任务的完成在硬件上主要由传统的结构支持，尽管在这一级别应用智能组件也是可能和适宜的。

相应于智能系统建立的上述原则和发展趋势，20 世纪 90 年代，在阿诺辛提出的功

能系统理论基础上，前苏联建立了一种智能系统的概念，即“功能—智能控制系统”。该智能系统综合了动态专家系统，用于预测的自组织方法、决策，非线性自适应控制和估计，以及目标形成算法，并将其连接起来置于功能系统的框架中，成为了最具发展前景的智能系统之一，代表了智能控制系统发展的一个重要方向。对智能系统的理论和实践而言，使用功能系统理论的主要优点是功能系统的通用体系结构，以及被进化所磨砺的功能系统的机制。

飞行器是非线性、多变量和不确定性复杂对象，是智能控制发挥潜力的重要领域。本章主要对俄罗斯学者和作者在这个领域的研究成果及发表文献进行综述，也介绍了一些中国学者和欧美学者的研究成果。在本章的最后，简要介绍了作者将“功能—智能系统”用于飞行器控制所取得的最新成果，以使读者在开篇就能对全书的核心内容有概貌性的认识。

## 1.2 飞行器控制系统中智能控制的前期应用

飞行器智能系统的综合是一项复杂而艰巨的任务，适宜于分步骤解决。前期阶段是在已有的自适应控制系统研制成果的基础上进行的，主要是把专家系统用于飞行器控制。为了建立动态对象的专家模型，考虑过使用各种智能技术，如模糊逻辑的方法、逻辑推论的方法、神经元控制和进化模拟算法等。

这里介绍的控制式智能系统和咨询式智能系统已在实践中获得应用，它们展示了实现不同智能化级别的飞行器智能系统的一系列观点。

### 1.2.1 带预测模型的专家系统

在文献[20]中，给出了使用专家系统来建立自适应控制系统的例子。在运行的过程中，控制对象和全系统的动态性能可能随机地改变，这将导致系统动态品质和控制精度降低，因此需要使用预测模型，其算法要使用参数估计的“在线”程序。预测模型可以用各种方式实现，实现方式之一是使用各周期时刻的统计信息和由研制者预先确定的最优模型选择准则，在系统运行的各种条件下获得适宜的预测模型。这些模型的组合形成了动态专家系统中控制对象的模型库。对于每个预测模型，可以找到满足控制品质指标的调节器参数调整的对应组合。这样可以建立调节器调整库，它们随预测模型进行切换。

在系统的控制主回路中带有自调整、自适应比例积分调节器，带有控制对象模型的隐含参数估计和调节器参数的专家调节。控制对象是飞行器机电驱动装置。在通用软件 Matlab—simulink 环境中进行的仿真结果表明，用该类型专家系统建立起来的自动控制系统，在控制对象有实质性参数扰动的条件下，具有令人满意的静态和动态品质性能。系统的结构框图如图 1-1 所示。图中： $K_1$ ， $K_2$  为比例积分调节器的调节值； $g(t)$ ， $u(t)$ ， $y(t)$  分别为输入控制对象的参考信号、控制作用以及控制对象的输出信号； $\Theta$  为调节器参数调整库中的任一组合； $\Theta^*$  为对应于最佳预测模型的调节器最佳调整组

合;  $\Theta_1, \Theta_2, \dots, \Theta_N$  为对应于预测模型组合之中的模型 1, 模型 2, …, 模型 N 的比例积分调节器的调节矢量;  $n^*_M$  为在系统运行的具体时刻最佳预测模型的下标; Index<sub>P</sub> 为上述时刻在调节器调整库中选出的序数。

自适应回路的工作算法可以表示成逻辑规则组的形式: 若  $n^*_M = \text{argmin}(I_n)$ , 则 Index<sub>P</sub> =  $n^*_M$ ; 若找到 Index<sub>P</sub>, 则  $\Theta^* = \Theta_{\text{Index}_P}$ 。其中,  $I_n$  为预测模型符合度评价准则。

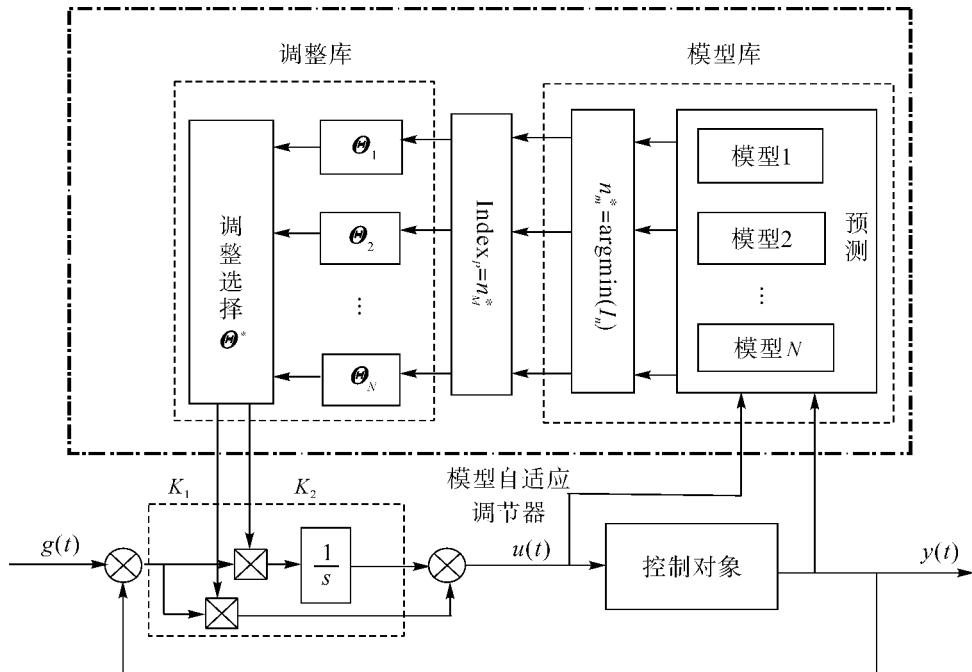


图 1-1 参数自调整专家系统结构框图

### 1.2.2 神经网络自适应系统

在控制系统中, 使用智能组件的另一个尝试是将神经网络与基于知识的系统(专家系统)结合使用。神经网络与专家系统并行工作, 在起始时刻, 专家系统被全面启动并负责控制。随着时间的推移, 神经网络从专家系统和测量中学习, 进而接管控制, 保证了更高的质量。专家系统保证运行的鲁棒性, 而神经网络保证对对象特有条件的确精调节, 而这些条件是不能预先以足够的精度把握的。如果条件发生剧烈的改变, 那么系统重新将控制转交给专家系统, 并且重新开始学习的过程。

在这个系统中, 专家系统保证了更高的智能程度, 但从另一方面来看, 它的准确度更低。神经网络在低智能水平上可产生更准确的控制, 如引言中的原则④。文献 [21] 对神经网络自适应系统控制飞行器进行了阐述。

图 1-2 给出了使用自适应神经网络控制系统的体系结构。在自适应控制系统中包括基控制系统、对基控制系统参数实现实时辨识的神经网络、具有期望性能指标的系统自适应基准模型(AEM)、包含基于基控制系统参数辨识对 AEM 参数实施调整算法的逻辑计

算单元 (БЛВ) 和实时自适应单元。图中:  $u_0$ ,  $u_{ad}$ ,  $u$  分别为来自基调节器的控制信号、来自自适应单元的补充校正信号、总和控制信号;  $y_0$ ,  $\hat{y}_0$ ,  $y_r$  分别为控制对象输出信号、输出信号辨识值、来自 АЭМ 的期望值;  $\hat{e}$ ,  $e$  分别为基系统和神经元辨识器间的误差信号、基控制系统和基准模型响应间的偏差;  $r$  为输入信号。

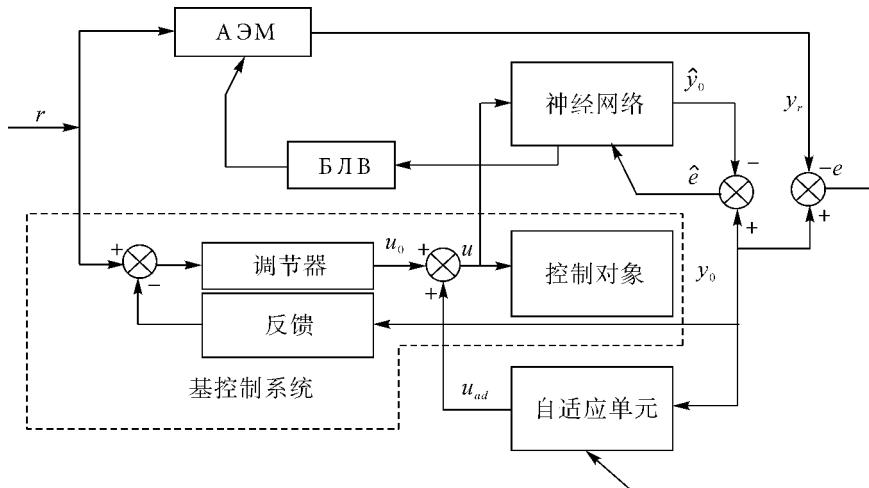


图 1-2 带有神经元自适应的控制系统

在系统工作条件改变时, 控制对象的动态性能参数将具有大范围的分散性, 这样就不能够使用具有定常基准模型的基控制系统。可以使用如图 1-2 所示的带有自适应基准模型的控制系统, 模型的参数在逻辑计算单元中得到估计, 逻辑计算单元使用了神经元辨识器实时获得的结果。基控制系统参数的辨识由具有单层静态神经网络体系结构的神经元辨识器实现, 静态神经网络由具有线性激活函数的 4 个神经元构成。在学习阶段 (离线), 神经元辨识器在权系数调整过程中按照学习指标最小化形成对给定学习数据的最优逼近。在辨识阶段 (在线), 神经元辨识器在每个时间间隔上适应控制系统动态性能的改变。在系统工作时, 包含多层神经元网络和补偿器的自适应单元形成校正信号, 补偿在设计时不可能预先考虑到的控制系统的不确定性和非线性。自适应单元根据基系统和基准模型响应间的误差信号工作, 不要求离线学习。该自适应控制系统保留了基控制系统的现有结构, 技术实现简单, 系统构造的原则可以使用在现有的和未来的控制系统中。

用上述方法设计了飞行器纵向运动自适应控制系统, 其有效性已由在 Matlab-simulink 环境中进行的仿真得到验证。

综上所述, 可以得出以下结论:

- (1) 在实现自适应控制时最有前景的技术是基于使用智能控制系统概念的技术。
- (2) 上述智能系统具有模块化的结构, 允许在总体上不改变信息—算法布局的条件下对其进行改变和扩展, 这样就不会对多处理器计算网络的组织和计算元件本身提出额外的要求。

(3) 所提出的算法可以采用并行处理的各种方法来组织, 这满足了实际应用中对算法快速性原则的要求, 包括计算程序的并行性、功能—算法结构的并行性、算法层次结构的并行性。

### 1.2.3 咨询式智能系统

在文献 [22~25] 中介绍了机载快速建议专家系统, 它是咨询式智能系统的代表之一, 工作于实际的机载信息环境, 并针对外界环境改变的可能场景的实际条件给出建议, 其目的是提高战斗机的有效性。高级和中级水平的机载快速建议专家系统应致力于在机载算法中建立逻辑推论和假设产生的操作程序, 它们符合人对推断正确性的表示, 以及在机上形成的信息环境中对推断进行的可能性的表示。

20世纪80年代, 欧美开始大力研制咨询式智能系统, 除了完善飞机的空气动力学、发动机和机载设备的性能外, 还将很大一部分的力量放在航空综合体“系统组成核心”的智能成分的完善上。该智能成分在机载算法中得以实现, 并与传统的算法一起建立功能上完整的“机组—机载仪器—飞行器”综合体, 以解决首要的任务——战斗机的出击。已有的机载快速建议专家系统的研究原型基本上处于中级和低级控制水平。在上述文献中, 从系统的观点分析了实际有用的机载快速建议专家系统, 并考虑了它们知识库的结构。

标准情景机载快速建议专家系统的机载算法保障及指示保障设备的建立通常按下列步骤实现: ①在应用领域的概念化基础上划分出标准情景和按照原因—结果关系排序的相应标准情景的问题子情景; ②构造知识库和研制机载智能系统的基本模板; ③在模拟仿真系统中完善知识库。

设计者在机载算法保障和指示保障设备中应用人工智能和专家系统的元素时, 给自己提出的任务是将其应用在“选择达到给定目标的方法”和“实现解决当前问题子情景的方法”的水平上。对每个标准情景, 将有对应的机载快速建议专家系统、机载测量和执行机构的专家系统在进行工作, 它们保证最大程度地完整获得当前时刻关于外部环境和机载设备状态的必要信息, 最大程度地准确执行系统做出的决策。

智能系统的有效性及其研制的适宜性在很大程度上取决于知识库的结构、符合度和完全度。对标准情景的每个子情景, 需要建立其知识库。对标准情景的每个子情景, 列出对象—活动者和有用事件的清单。将这一标准情景的每个子情景用数学模型的集合表示, 该集合描写了子情景参与者们的空间位置, 预测位置的时间变化, 并确定有用事件可能到达的时刻。该集合即对应标准情景的子情景的场景。

通常要求用一系列数学模型对子情景进行预先研究, 这些模型是以最优控制、博弈论的数学问题和决策的各种问题的形式来表述的。将结果中获得的或者在模拟数学仿真中挑选出的子情景的“合理解决方案”放入数学模型, 这些数学模型就是机载快速建议专家系统知识库的模块之一。对外界和机载环境进行分析, 并借助于同样放置在快速建议专家系统知识库中的产生式规则, 为飞行员提供相应的建议。这样机载快速建议专家系统工作所需的知识以规则和数学模型的形式放置, 并按照不同场景集结在一起。

用模糊关系矩阵的方法获取知识在建立知识库的过程中最常采用。在知识获取后形

成知识库，在知识库基础上逻辑推论的机制根据模拟操作产生动作，并指向基于规则的自动推论过程。

## 1.3 “功能—智能系统”的概念综合

### 1.3.1 “功能—智能系统”结构

功能系统理论是阿诺辛于1935年提出的。该理论认为人体是具有对外界环境和自身变化适应能力的一个完整的功能系统，它又由若干子功能系统组成，系统间相互协调工作，共同保证有益目标的实现。

按照功能系统理论，将现代复杂控制系统作为带有其固有的适应效应的功能系统来研制。在这一概念下综合出的现代复杂系统，本质上具有对外界条件及自身状态变化等不确定因素的适应性。其突出特点是，促成实现目标的任一结果均是在自调整原则下达到的，与复杂度无关，并且具有一致的组成环节，即传入性目标综合、行动决策、行动感知器。

实现了上述机制的现代控制系统就是智能系统，即由信息过程连接而成的技术设备及软件的综合体，它们可自主工作或者有人参与工作，利用先验信息和当前测量信息，在一定的动机驱使下综合出目标，产生行动决策，并寻找达到目标的合理方式。

基于功能系统理论的智能系统具有如图1-3所示的结构。

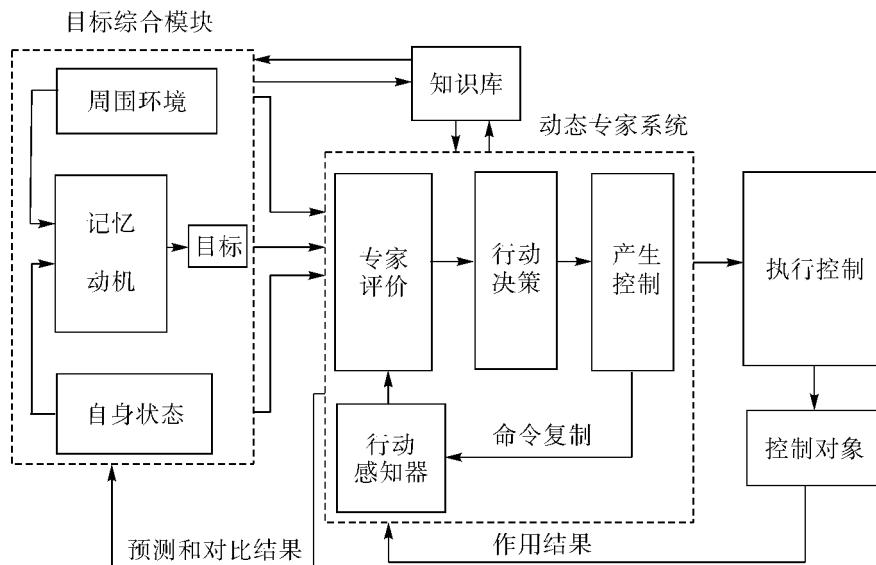


图1-3 “功能—智能系统”结构框图

该系统在实现时可以利用传统智能组件。和其他系统的最大不同在于，功能系统理论遵循了自然界生物进化原则，并将各智能组件连接起来置于统一的系统框架之下。此

外，实际系统具有统一的体系结构，系统中的各个环节是另一层次上的功能系统，均可独立选择不同研究领域中的成熟算法及相关技术，包括各种智能化信息处理手段，保证整个智能系统可实现，并具有紧凑、简单可靠、行动快速的特点。

智能系统的行动感知器包括建立预测模型的算法、对将来结果参数的预测和实际得到的结果参数与这些参数预测值的比较。获得的预测数据以及与实际状态参数的对比结果传递到专家系统和目标综合模块中，用于形成运行的目标，并供控制决策使用。

目标的综合考虑了外界信息、智能系统自身的状态、动机以及已有的记忆，综合出的当前目标提供给专家系统，动态专家系统给出的评价又作为决策的基础，进一步实现控制。当行动结果与预测状态不一致时，将产生新的专家估计，做出另外的决策，并产生新的控制作用。当一致性不可能达到时，将发生智能系统目标的改变。如果行动的结果与预测状态吻合，即对应控制作用的选择成功，则认为达到了智能系统的目标。

这个结构具有通用性，可作为各种动态对象控制系统综合的基础，其中包括飞行器。由于目标综合、行动感知器、动态专家系统和控制产生是“功能—智能系统”中的4个核心模块，因此以下分专题对它们的构建进行详细讨论。

### 1.3.2 目标综合模块

我们将系统任务的形式化描述理解为目标。在智能系统中，目标综合是最复杂的过程。在具有如图1-3所示结构的“功能—智能系统”的实现中，目标综合的机制建立在两个基本模块的相互作用下，即动机模块和记忆模块。

记忆模块是数据库控制算法和信息选择算法。数据库在专家系统的框架下实现，而选择算法用于从数据库中及时地提取所需要的信息，并且要考虑到信息的更新，测量老化效应，根据重要度、有益度、可信度、容量及其他判据对信息进行整理。控制算法用于寻找必需的数据库或者数据库集合，确定信息提取所建立的顺序等。

记忆模块的实现没有实质上的困难，现在已有一系列的研制成果，对它们做少量的修改就可作为智能系统记忆模块的基础。

在智能系统目标综合模块中主要的问题是建立动机模块。在发表的文献中提出的概念性观点是将各种动机理论运用于目标综合模块的研制中。鉴于动机模块的综合尚处于发展初期，应以在现代机载计算机中能够紧凑实现的、功能上最简单的方法进行研究。在文献[37]中，建议借鉴1909年由泰勒创立的“科学管理理论”中的“动机论”，该理论认为工人做工的“动机”是为了获得薪酬，其积极性同对薪酬的预期呈正相关关系。仿照此理论，应预估各个方案中飞行器运行的结果（对应“薪酬”），再按照预选的评价函数对各个方案赋予权值（对应“积极性”）。权值最大的方案就是“动机最强”的方案。评价的方法可采用运筹学中的层次分析法，在文献[32]中称为塔式方法。简言之，动机模块把优先权指定给具有最大权值的飞行器运行场景。下一步在实现第六代飞行器智能系统动机模块中最可能使用的是基于有机体生物学过程的方法，也可能是符合实现可能性的其他一些原则。

按照泰勒的经典动机理论，飞行器运行目标综合的具体操作如下：预测飞行器运行的结果，并且按照所选定的评价函数，事先对每一种方案赋予权值，选择具有最大权值

的飞行器最佳运行方案用于实现。为了减少错误决策的数量和尽量避免混乱的情景，必须将飞行器的预测状态最大程度地细节化。飞行器的每个状态表示为飞行器基础状态及它们所固有的权值的层次结构形式。采用塔式方法，在对飞行器基础状态的有效性评价的基础上进行更高层次状态的评价。在每个基础单元里都有飞行器基础状态的权值。在下一层，即更高的权衡水平上，每个单元表示对飞行器中间状态有效性的总评价。在“塔”顶我们获得飞行器状态的权值，在它的基础上做出采用飞行器这个或者另一个有效状态的决策，该决策即对应于飞行器运行的最佳场景。

所建议的方法（或称为飞行器状态计算方法），由满足机载计算机计算量最小的目标所决定。

对飞行器运行的场景以及对应于场景的飞行器状态进行预测，而对飞行器的基础状态不预测，这样可大大地节约机载计算机的计算时间和负荷。

由此便建立起动机的最简单的概念——优先权属于具有最大权值的飞行器运行场景。这种简单的动机模块在飞行器运行的场景数量有限，且只有在整个运行时间段内单个场景与其他场景有本质区别的前提下才是有效的。如果在飞行器运行中有大量的相似场景，立刻做出单值选择是不可能的，有时也不需要，那么就可以使用另外的方法，如建议使用反向加强模拟代替正向加强模拟。

在智能系统中，借助挑选出明显不可接受的飞行器状态来实现反向加强的分析，这些状态也有相应的权系数。权系数越小，对挑选出的飞行器运行场景的惩罚就越高。这样，所建议的场景越差（更小的权值或更小的多指标泛函值），就应以更大的搜索范围实现下一时刻场景的综合。在存在大量的、不可接受的运行场景下，也采用这样的搜索方法。在这种情况下，还使用了确定可接受与不可接受场景的专门指标，这个指标确定了飞行器可能运行场景的搜索范围。

无论使用正向加强还是反向加强方法，当出现相似情景时，在情景分析的第一阶段应选择在以前情景中带来成功经验的飞行器行为策略。相似情景及对应策略均保存在动态数据库中，它们是对人的经验的模拟，这样就实现了学习过程。

根据动机的定义，动机被解释为个性的状态，它决定人在一定的情景下以什么样的积极程度和什么方向性行动。应用到智能系统中，方向性借助于上面所描述的方法中提到的指标来确定。积极程度的数值也可借助简单的指标给定：飞行器所给出的任务完成的精度越低，表明越积极地实现智能系统最优解的搜索。在所研究的智能系统的框架下，积极程度的提高是通过将预测模型复杂化来实现的，即依靠扩大基函数组来实现，这将导致时间和机载计算机负荷的增加。

智能系统动机模块的这种简化表示具有无可争议的重要的优点，即实现简单且可靠性高。当然，所描写的动机模块还只是第一步，还应进一步将指标复杂化和提高它们的数量。

在动机模块的指标中，使用了有待比较的动态预测参数或预测模型。预测模型的比较不仅根据预测结果的精度（只有在获得补充测量的条件下实现），还应进行简单度、紧凑度、线性度、模型建立时间等指标的比较。

飞行器运行场景的选择是这样实现的：①划分出或者剔除所有明显不可接受的场

景；②从剩下的场景组中选择几个好的场景，将它们进行排列，并采用它们中最好的一个用于实现；③以获得新的测量为标志，选择的过程重复进行，并根据指标集从较好的场景中选择最好的场景来实现；在选择中仍然像以前一样留下几个场景，这样符合冈博（Габор Д）的保留选择自由度原则。

在实现了第一个飞行任务之后，在智能系统的动态数据库中保留了获得的经验信息（正面的和反面的）。这一经验在完成后续的飞行任务中被使用，并用于智能系统的学习。

在智能系统所选择的所有场景都具有较低的权系数情况下（低于预先所选定的阈值），进行从考虑完成具体飞行任务的途径到搜索最优的可能替代任务的转换，该替代任务有可能被有效地完成，并且与飞行器的使命不矛盾。这样就选择了飞行器运行的新目标，而这一目标的选择是在更高的层次水平上进行的。可将目标分为三类：①全局目标或者智能系统的使命；②第二级目标或者综合出的场景；③辅助目标。

如果在当前时刻不可能实现某个第二级目标，那么就实现飞行器可有效达到的另外第二级目标或者辅助目标的转换。在达到目标之后，返回到尝试找到和实现达到前一目标的场景，如果还不能有效地达到，则重复寻找。

### 1.3.3 动态专家系统

“功能—智能系统”的实现框图如图 1-4 所示。这里，从实现的角度将智能系统划分为两大部分，即目标综合模块和目标实现模块。在第一个模块中，在对从传感器系统获得的信息积极评价的基础上，在存在动机和知识下综合目标并做出行动决策。信息的积极评价在启动信号作用下实现，对周围环境和包含控制对象在内的系统自身状态的信息进行积极评价的同时，在对达到目标的各方案进行对比下可以做出行动决策。在第二个模块中，动态专家系统在有关周围环境和智能系统自身状态的当前信息基础上，在存在目标和知识的前提下预测行动的结果，并将它与实际的结果比较，实现专家评价，做出控制决策并产生控制。以编码方式表示的控制变换为物理信号并到达执行装置。控制对象接收来自执行装置的信号，实现各种动作，表示为参数形式的动作结果沿反馈回路 2 来到动态专家系统与预测的结果进行比较。同时按照目标性能解释和进入模块 1 的动作结果参数对达到的结果进行评价。如果所有参数目标都达到了，那么控制得到加强；反之，产生修正控制。应该注意到，在周围环境、控制对象或者系统整体的状态出现突然改变时，可能综合出新的目标并组织其实现。

可用以下的数学模型描述在智能系统中发生的过程：

$$\begin{aligned}
 T \times X \times S &\xrightarrow{\alpha_1} M \times T \\
 T \times M \times S &\xrightarrow{\alpha_2} C \times T \\
 C \times T \times X \times S &\xrightarrow{\alpha_3} R \times T \\
 T \times \dot{X} &= (\mathbf{A} \times T)X \times T + (\mathbf{B} \times T)U \times T \\
 T \times Y &= (\mathbf{D} \times T)X \times T
 \end{aligned}$$

$$T \times R \times Y \xrightarrow{\alpha_4} C \times T$$

式中,  $T$  为时刻的集合;  $X, S, M, C, R, Y$  分别为系统状态、周围环境状态、动机状态、目标状态、预测的结果状态和实际的结果状态;  $A, B, D$  为参数矩阵;  $\alpha_1 \sim \alpha_4$  为使用知识的智能变换算子;  $U$  为控制输入。

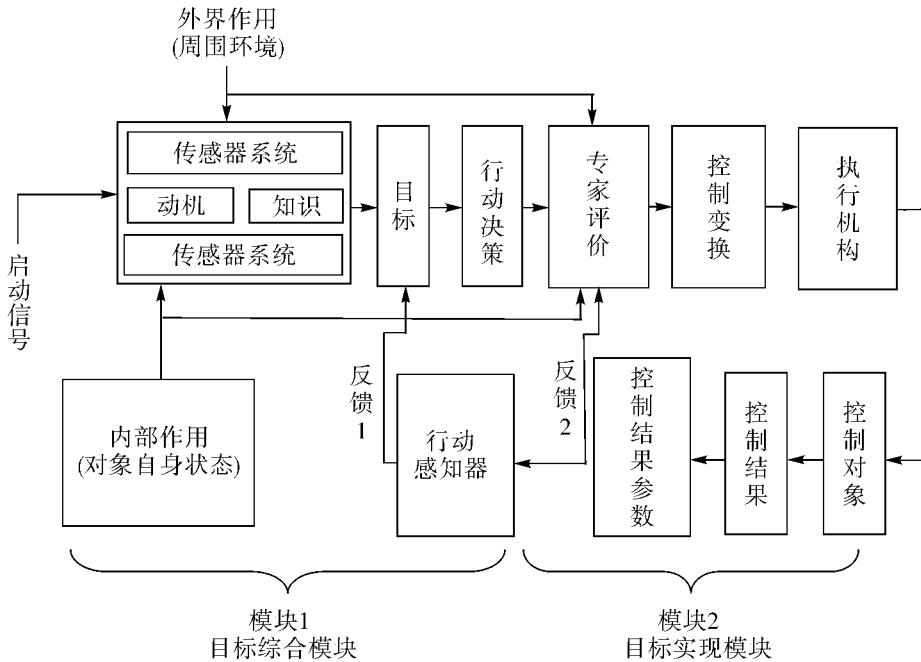


图 1-4 “功能—智能系统” 实现框图

实现概念的感知、表示、形成、认识过程中的判断和推理的智能算子, 是进行信息和知识处理, 以及决策的形式化工具。所有这些方面都应该作为拥有知识库和支配任务解决方法的动态专家系统构建的基础。除此以外, 动态专家系统的功能还应包括任务结果的评价、动作的未来结果参数的预测、控制决策、产生控制和实际结果与期望结果的参数比较。一般情况下, 动态专家系统的结构如图 1-5 所示。

在这个结构中结合了两类的动态专家系统。第一类动态专家系统用于寻找最优解, 并建立在严格的数学方法和优化模型之上。第二类动态专家系统针对性地解决难以表述的任务, 并且在缺少完整和准确信息的条件下, 使用建立在专家知识和解搜索的启发式方法基础上的专家模型。在将第一类和第二类的动态专家系统结合成的计算—逻辑动态专家系统中, 知识库结合了用严格的数学公式描写模型和基于专家信息及相应的非严格的启发式方法的数学方法。

在动态专家系统的研制中, 需要解决下列问题: ①确定知识库的组成及其形成; ②研制新的和使用已知的理论与方法描写智能系统中的信息过程; ③建立知识的表示和知识的使用组织的方法; ④使用“软”逻辑(柔性逻辑)开发带并行处理的算法和软件; ⑤寻找合适的计算环境用于形成动态专家系统时实现并行算法。

动态专家系统应具有对动态问题领域的自适应性，具有在情景描写中引入新元素和联系的能力，具有在决策过程中改变对象运行的规则和策略的能力，具有产生控制的能力，具有处理不完全、模糊和矛盾的信息的能力等，其主要特点是它的动态性和智能性。动态性在于专家系统的性能可能随着知识库中知识的积累而改变；智能性表现为任务的解不是按预先规定的算法来进行，而是根据库中拥有的知识来产生。

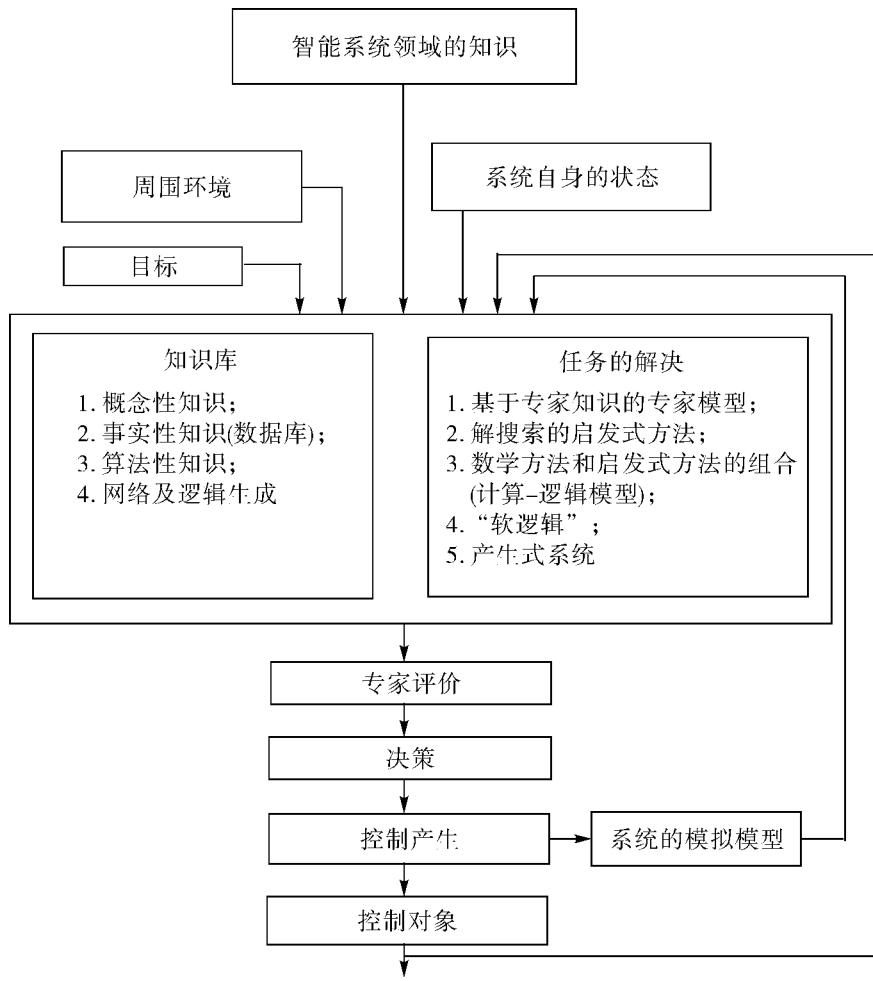


图 1—5 动态专家系统结构

#### 1.3.4 实现行动感知器的预测算法

行动感知器是智能系统运转的基础，其中包含建立预测模型的算法，在文献 [40] 中建议采用自组织算法。自组织算法是一种基于数学归纳的智能性建模方法，20世纪 60 年代由前苏联科学家伊万赫年科（Ивахненко А Г）提出。它允许在最少先验信息的条件下建立研究过程的预测模型，能够按照设计者构造的指标集，通过多步的选择，从含有噪声的观测数据中自动获得具有最优复杂度的对象模型。通过特殊的方式划分观测

样本，针对具体的任务构造专门的指标集，采用交叉组合的方法增加模型的复杂度，并且对竞争模型做出人工选择，使得用自组织方法建立的模型可预测控制对象未来的状态，且具有良好的噪声稳定性。这些特点就是该方法有别于传统的插值建模方法和回归算法而具有预测能力的原因，也是其智能性的重要体现。

文献[41]中用自组织方法建立了飞行器智能控制系统中导航参数误差预测模型，在飞行器平稳运动状态下可以有效地预测导航参数误差。

传统自组织算法依靠庞大的选择过程来实现，特别是当采用竞争模型的完全组合来产生过程模型时，对计算资源的要求急剧增长，即必须保证机载数字计算机具有高计算速度和大存储容量。除此以外，为了达到一定的模型精度，对样本的长度也有相应的要求。

在动态对象高度机动的情况下快速做出可靠的决策，并产生相应控制，是对智能控制系统的迫切要求，也是决定智能控制系统能否在实际中应用的关键因素。在动态对象具有高度机动性，且计算资源有限的情况下，使用传统的自组织算法建模是不可行的。鉴于此，在文献[42]中又研究了一种改进型建模算法，以满足实现时对模型的紧凑度、简单度及快速性的具体要求。这种算法是将自组织算法与文献[43]建议的Demark 趋势项相结合的一种改进型算法。Demark 趋势项是根据划分为几组的观测数据建立的线性预测模型，其特点是简单并能快速确定研究过程的变化趋势，且不需要长的测量样本。当获得了足够的样本后，用自组织的方法对线性趋势项进行修正，使其更加逼近实际过程，以此提高预测的精度。利用改进型算法建立的紧凑的预测模型既具有快速响应对象机动变化的能力，又保证了适当的预测精度。在样本长度有限，甚至是传感器信息缺失的条件下研究出的模型可以有效预测控制对象的状态。将该改进型算法用在高度机动的飞行器上，可有效地预测导航参数的误差。

除自组织算法外，还可采用各种时间序列的方法来建立预测模型。文献[45]中提出了短时间序列的预测方法，它将统计信息和专家推断结合到统一的模型中用于预测。这种方法在两个方面优于其他方法：①它们使用对每个研究领域的专家都方便的专家命题的形式；②所有的方法都基于统一的模型，在模型中结合了所有有关研究过程的各种实质性信息。文献[46]在对足够广泛领域内的不同机理的现象进行预测分析的基础上得到了这样的结论，即参数间为下列线性关系：

$$F(t, \boldsymbol{\theta}) = (\boldsymbol{\theta}, \boldsymbol{\varphi}(t))$$

式中， $t=1, \dots, m, m+1, \dots, m+n$ ，为离散时间序列； $\boldsymbol{\theta}=(\theta_1, \theta_2, \dots, \theta_K)$ ，是参数矢量； $\boldsymbol{\varphi}=(\varphi_1, \varphi_2, \dots, \varphi_K)$ ，是矢量函数，通常的情况下其分量为非线性函数； $(\boldsymbol{\theta}, \boldsymbol{\varphi}(t)) = \sum_{i=1}^k \theta_i \varphi_i(t)$  为标量积，可以作为趋势项模型，其中  $k$  是模型中非线性函数的数量。在正确选择  $k$  和  $\varphi_i$  的情况下，此模型可以描述足够复杂的时变现象，同时，当使用在预测程序中时它又足够简单。 $\varphi_i$  可以使用线性的、平方的、多项式的、级数的函数等。应特别指出，实践中最常遇到的是两参数的模型，即

$$F(t, \theta_1, \theta_2) = \theta_1 \varphi_1(t) + \theta_2 \varphi_2(t)$$

### 1.3.5 智能系统中的非线性控制算法

由于复杂的动态对象都是非线性对象，这就使得非线性控制算法的运用成为智能控制系统的重要特征。

反馈线性化方法是在非线性导弹控制和制导系统中用得较多的非线性设计方法，其基本思想是先用代数变换将一个非线性系统的动态特性变换成线性的动态特性，再用传统的线性控制理论进行设计。它和经典控制中小扰动近似线性化的根本区别是不损失原非线性系统的状态信息，因而是精确线性化。而微分几何方法和动态逆方法是实现反馈线性化的两条有效途径。微分几何方法是在线性系统几何方法的状态空间概念基础上引入微分几何的数学概念发展而来的。它利用局部坐标变换和非线性状态反馈将非线性系统化为解耦的积分器串联的正则标准型，从而采用简单的状态反馈来实现跟踪。动态逆方法的基本思想是对给定的动力学系统，先用对象的模型生成一个可用反馈方法实现的原系统的“ $\alpha$  阶积分逆系统”，作为控制律串接在原系统的前面，将原系统补偿为具有线性传递关系且已经解耦的一种规范化系统——伪线性系统，然后再用线性系统的设计理论来完成伪线性系统的综合。但反馈线性化方法依赖于系统精确的非线性模型，对建模误差敏感，且不能处理动态系统的未知变化。为了增强对建模误差的鲁棒性，又出现了自适应的和鲁棒的反馈线性化方法。

文献 [49] 针对单输入单输出 (SISO) 状态反馈可线性化的具有可控标准型的连续时间非线性系统，提出了一种基于多层前向神经网络的反馈线性化控制器，用于使系统获得要求的跟踪性能。文献 [50] 将多层前向神经网络用于多输入多输出 (MIMO) 仿射非线性系统的鲁棒自适应反馈线性化。文献 [51] 针对一类未知标称系统模型和已知标称系统模型的 MIMO 仿射非线性系统，提出了一种神经网络自适应反馈线性化 (NNBAFL) 方法，给出并证明了用该方法所设计的 NNBAFL 系统的稳定性定理。该方法在利用已知系统标称模型的基础上，进一步利用模糊小脑模型 (FCMAC) 神经网络对系统实际模型与系统标称模型之间的偏差进行实时建模，有效克服了反馈线性化方法需要对被控对象精确建模的局限性。文献 [52] 将倾斜转弯 (BTT) 导弹动力学从时间尺度上分成快变的体系角速度动力学和慢变的纵向加速度与角度动力学两部分，然后分别对快变动力学和慢变动力学进行非线性动态逆控制设计。文献 [53] 提出利用不同的优化目标训练神经网络，以逼近非线性动态逆，并利用径向基函数 (RBF) 逼近模拟的高性能飞机的动态逆。上述成果代表了非线性控制的反馈线性化方法发展的前沿，它们已经或将在飞行器智能控制系统算法综合中得到应用。

另外，变结构控制也是目前非线性控制系统中较普遍的一种控制方法。所谓变结构控制系统，就是系统在工作时可以根据某种规则，在若干个控制器之间来回切换，以改善系统的动态性能。构造变结构控制器的核心是滑动模态的设计，即切换函数的选择算法。滑动模态控制（简称滑模控制）有许多优点：①只要切换面是可达的，一旦系统的相点到达切换面后，系统的运行方式就只决定于切换面的方程，与系统原来的参数无关；②滑模控制可以实现对任一连续变化的输入信号的跟踪；③滑模控制对外部干扰具有较强的鲁棒性。但滑模控制也存在一些不足，主要是当切换开关不理想时，会产生高

频颤动，除此以外，为实现滑模控制，必须得到系统全部状态变量的信息，这常常是比较困难的。

变结构控制在某种意义上体现了一定的智能功能，具有较好的发展前景。

## 1.4 “功能—智能系统”在飞行器控制中实现的最新成果

近年来，“功能—智能系统”在飞行器控制的应用中取得了一系列的成果。

在文献[32]中提出了基于“功能—智能系统”结构的飞行器准智能测量综合体。该综合体由惯导系统和GPS等其他外部测量系统构成，按照可观测度数值指标进行外部测量系统的切换，可保证在每一时刻综合体使用的是可信度最高的外部信息源，在此基础上进行惯导输出信号误差校正，从而提高了惯导系统输出信号精度。在文献[20]中研究了在复杂动态对象智能系统中信息—算法保障的结构，讨论了一种带有结构—参数自适应的控制系统组织原则。文献[21]将使用神经网络的自适应系统用于控制飞行器，提高了被控参数的精度。文献[33]研究了“功能—智能系统”中进化算法的使用问题。文献[34]研究了运载火箭运动智能控制系统中的智能组件。文献[35]研究了返回大气层式无人飞行器智能系统的控制算法。文献[61]详细讨论了在智能系统中综合使用鲁棒、模糊神经元和自适应控制技术的特殊性问题。在文献[63]中讨论了广义动态对象的智能控制系统设计问题。文献[57]对智能系统的最新发展方向进行了详细论述。文献[58]总结了飞行器控制中采用的各种现代方法和手段。文献[64]讨论了飞行器控制系统中的信息处理算法。文献[65]给出了提高导航系统精度的一系列措施。文献[36]将“功能—智能系统”用于飞行器的控制，给出了系统实现框图，并具体研究了飞行器智能控制系统中实现行动感知器的预测算法和产生控制的非线性算法，并对系统性能进行了仿真研究。

文献[36]的工作集中体现了“功能—智能系统”理论的智能系统概念综合的思想，并成功运用复杂系统建模及控制的手段实现了智能系统中的两个核心模块，具有一定代表性。下面对文献[36]中取得的主要研究结果进行简要介绍。

### 1.4.1 系统实现框图

文献[36]综合出的飞行器智能控制系统具有两个层次，即控制体系中的上级和下级。在上级中进行目标综合，完成飞行场景的选择；在下级中通过控制作用实现所选择的场景。系统结构框图如图1-6所示。

### 1.4.2 上级控制中的目标综合算法

体系的上级控制算法是在目标综合模块中实现场景选择的决策算法，采用了1.3.2中介绍的方法。系统设计时，将精度作为第一准则。在评价函数中包含了适合于具体任务的总准则，它们按照技术系统决策方法的经典理论来选择，依据评价函数实现决策。图1-6中， $a_1, a_2, a_3, a_4, \dots, a_N$ 表示1到N个不同准则的权系数。按照总准则

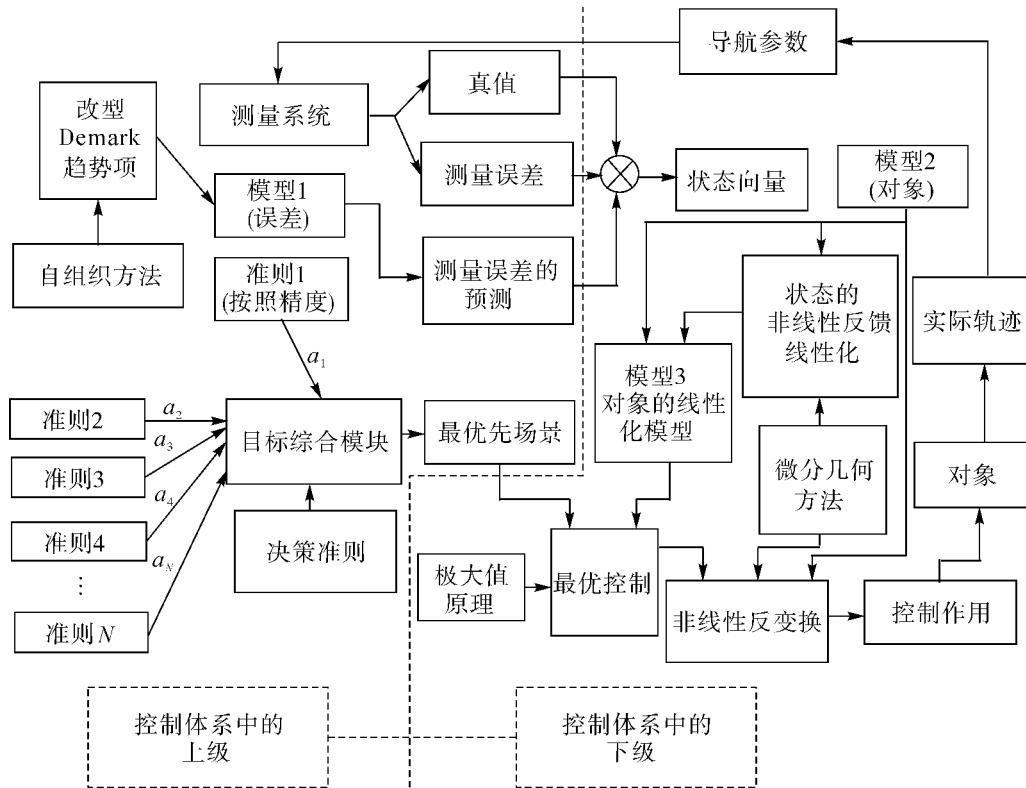


图 1-6 飞行器智能控制系统两级体系结构框图

来确定决策的评价函数的值。决策时应排除不确定性的影响，这在选择不同的评价函数时应考虑到。

在文献 [36] 中，目标综合的过程考虑了下列的动态性能指标和外部条件：①飞行器位置确定的误差；②飞行器终点脱靶量确定的误差；③飞行器速度确定的误差；④飞行器定向确定的误差；⑤飞行区域主动干扰的强度；⑥完成任务的概率；⑦存活率；⑧燃料消耗。每一外部条件的权系数根据实际的设想来选择。上列清单并未穷尽工作中所考虑的所有情况。

#### 1.4.3 下级控制中的控制算法

体系的下级保证以最优方式实现上级所选出的轨迹，即按照某个目标泛函用最优控制的方法使得实际轨迹与最优轨迹间的偏差最小，为此采用了最优控制方法，利用了极大值原理和变分法。由于采用最优控制的系统为复杂的非线性系统，对非线性控制对象实现最优控制算法将具有很大的工作量，甚至不能在机载条件下得以实现。为了减少计算消耗又不降低精度，文献 [36] 研究了对象模型的全局线性化问题。通过运用 1.3.5 中所述的微分几何理论，实现了飞行器动力学模型的全局线性化。在此基础上设计了飞行器运动控制的继电调节器，使得最优控制的算法可以针对对象的线性化模型设计，其特点为可靠、简单，在飞行器控制实践中已得到良好的开发应用。

由此，建立在功能系统理论基础上的飞行器智能控制系统的综合主要利用了自组织方法实现行动感知器，建立预测模型，获得对象状态参数，保证目标综合和目标实现。此外，利用微分几何方法实现了控制模型的全局线性化，使得控制算法能够有效实现。在这一概念下综合出的智能控制系统本质上具有对外界环境和自身状态不确定性的适应能力，并能在现有的机载条件下实现。

#### 1.4.4 仿真研究结果

文献[36]还进行了用改进型自组织方法建立飞行器运动参数误差预测模型和基于微分几何方法实现控制的仿真，仿真结果证明了所采用的算法的有效性。

在飞行器智能控制系统中，其参数测量系统为基准导航系统与GPS、多普勒导航等其他系统的组合，基准导航系统为惯性导航系统。控制过程建立在对导航参数的预测基础上，预测采用与Demark趋势项相结合的改进型自组织算法进行，仿真了导航系统对飞行器运动速度的预测过程，在短期、中期及长期预测中获得的速度参数的预测误差在表1-1中给出。

表1-1 在短期、中期及长期预测中用改进型自组织算法获得的导航系统输出速度参数预测误差

测量样本 预测长度\ E <sub>11</sub>	E <sub>12</sub>	E <sub>13</sub>	E <sub>14</sub>	E <sub>15</sub>	E <sub>2</sub>	
短期预测	8.4%	15%	12.6%	8.9%	12.6%	12%
中期预测	11.2%	10%	11.3%	12.5%	11%	11%
长期预测	20%	21%	35%	38.5%	22.5%	27%

$E_{11} \sim E_{15}$ 表示使用不同起始时刻的测量数据计算得到的预测误差值， $E_2$ 为它们的平均值。仿真时从导航系统的实际要求出发，选择速度测量的噪声水平为50 m/min。

仿真结果表明，在所有的预测周期中，采用改进型自组织算法可以达到满意的预测精度，获得的数据可以用于惯性导航系统输出参数的校正，以保证获得可靠的对象运动参数。

基于微分几何理论，实现了发动机推力矢量/气动力复合控制的导弹动力学模型的反馈线性化，在此基础上设计了解耦控制律，并对该型导弹攻击垂直平面内进行蛇形机动的目标的制导过程进行了仿真，结果达到了较高的制导精度。

仿真中导弹发射的初始状态为：高度4000 m，速度266 m/s，发射角和发射时弹体俯仰角分别为5°和10°，采取尾追方式攻击机动目标；同时考虑了目标距导弹初始水平距离小于1000 m的情况。将发射时刻分别位于导弹上方和下方的机动目标实施制导过程中导弹和目标的运动轨迹表示在图1-7和图1-8中。在这两种情况下均实现了有效制导，且制导精度小于0.5 m。

综上所述，在文献[36]中解决的与行动感知器的综合（建立预测模型）和控制算法的研制相联系的问题是重要和迫切的，因为它不仅实现了智能系统中的两个关键机制，而且作为传统的批量生产的飞行器控制系统中可独立使用的智能组件，也具有重要的现实意义。

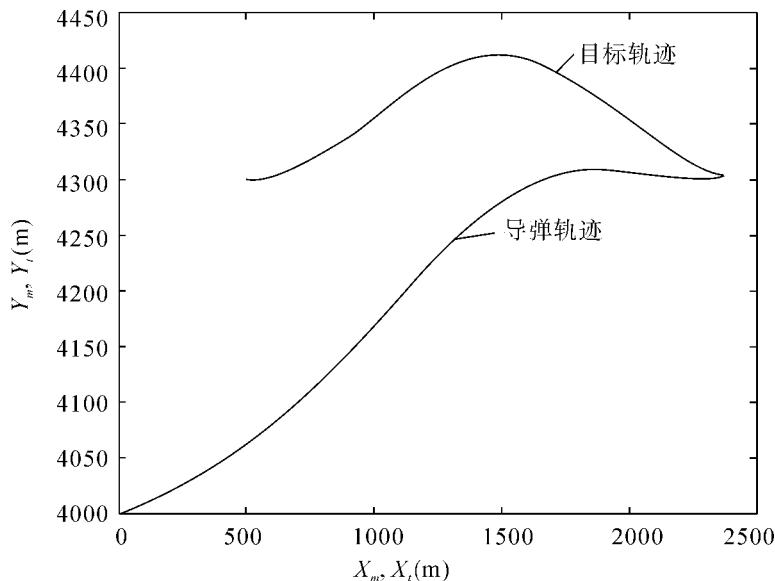


图 1-7 导弹和目标运动轨迹（目标位于导弹上方）

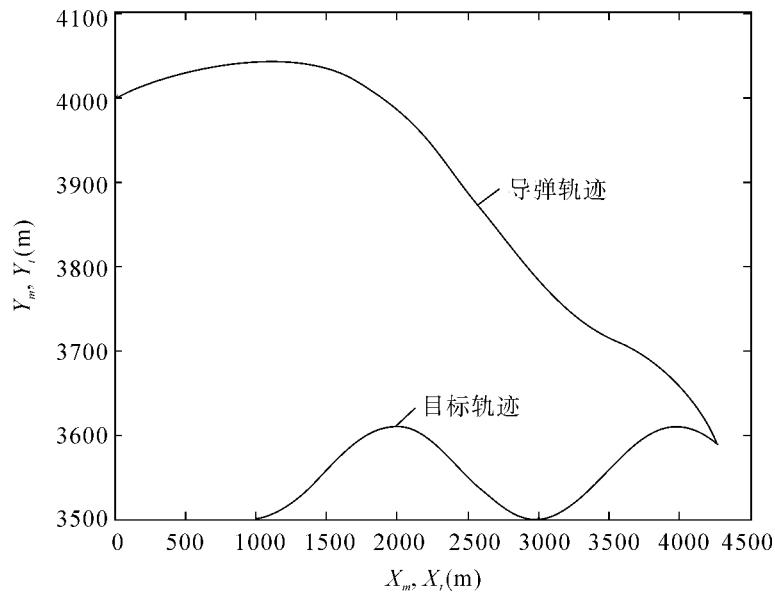


图 1-8 导弹和目标运动轨迹（目标位于导弹下方）

图中： $X_m$  为导弹飞行的水平距离； $X_t$  为目标飞行的水平距离；  
 $Y_m$  为导弹飞行的高度； $Y_t$  为目标飞行的高度。

#### 1.4.5 结论

通过对俄罗斯和其他国家近 20 年来在现代飞行器控制领域的研究成果和现代智能

控制系统研究的理论成果的分析，可以对飞行器控制任务使用的智能系统的研制问题给出以下的建议：

(1) 智能系统综合的较有前景的方向之一是动态专家系统、决策、自组织方法、非线性自适应控制和估计，以及目标形成算法的共生，并将其连接起来置于功能系统的框架中，即“功能—智能系统”。

(2) 在“功能—智能系统”中，行动感知器的综合可采用与 Demark 趋势项相结合的改进型自组织算法来建立被控对象将来发展状态的预测模型，该算法具有紧凑、可靠和实现简单的特点。同时，基于时间序列的预测方法也可能获得应用。

(3) 以基于反馈线性化的控制和变结构控制为代表的现代非线性控制方法将在智能控制系统中得到应用。而微分几何方法是实现反馈线性化的有力途径。

(4) 在上述的智能系统综合的概念下，合理的实现方法之一是混合系统。按照智能化的程度，它具有两级结构，即基于知识库的专家系统的上级部分和使用了模拟及控制的智能组件的下级部分。在外界环境及对象自身不确定条件下，专家系统保证了系统工作的鲁棒性。随着时间的推移，当系统的外围部分搜集到更详细和准确的信息时，就能对控制和对象模型做出修正，同时对知识库加以补充和更新。

(5) 在专家系统中使用不同的推理机制。主要的机制是基于规则的推理方法和逻辑推论的方法。自动推理的有效性取决于在知识库中合理选择知识表示的方法。知识可以表示成规则、谓词逻辑、语义网络或者框架的形式，这些由所研究领域的具体性能来确定。由于在具体领域的知识通常具有模糊和不确定的形式，为获取知识常常使用模糊关系矩阵，以便从语言表达中得到定量的评价，并可以使用基于模糊规则的控制。

(6) 神经元控制和进化算法用于在智能系统中通过知识库同专家系统交换信息过程中的建模、精确控制和做出合理的决策。

(7) 所研究的智能系统预计使用在类似美国生产的 X-45、“猛禽”等第 5 代飞行器和无人飞行器上。智能系统载机的原型是类似“F-22 猛禽”的飞行器。在决策支持系统中和共同工作模式下，可以使用带机组人员的智能系统，而正在研究的智能系统是自主式智能系统。

## 1.5 本章内容小结

进行了飞行器智能控制系统研究进展的分析与综述。简要回顾了基于动态专家系统的飞行器自适应控制系统和当今广泛采用的飞行器建议控制系统；在对智能系统发展趋势分析的基础上，推荐了建立在阿诺辛提出的功能系统理论基础上的最具发展前景的智能系统，即“功能—智能系统”，给出了其结构框图，介绍了作为该型智能系统中核心模块的预测算法、控制算法、目标综合和动态专家系统的构建问题，重点放在目标综合模块上。为了使读者在开篇就能对本书有概貌性的认识，在本章中还简要介绍了作者将功能系统理论用于飞行器控制取得的最新成果，着重描述了“功能—智能系统”结构框图和关键部分的实现过程，以及主要的仿真结果。

## 第 2 章 传统智能组件

控制理论学科经历了从经典控制理论到现代控制理论，再到目前的智能控制理论的发展过程，其主要研究对象也从单输入单输出的常系数线性系统，发展为多输入多输出的复杂非线性控制系统。智能控制是一门交叉学科，它的建立和发展是以众多学科特别是许多新兴学科为基础的，它的内容广泛而多样，融合了人工智能、自动控制、运筹学、模糊集合论、生命科学、神经生理学、认知科学、人类工程学、计算机科学、系统论、信息论、协同论、混沌学等多学科知识。被公认的在智能控制系统中得到广泛应用的传统智能组件有人工神经网络、进化计算、专家系统及模糊控制。

以下对上述四种智能组件的基本工作原理和主要特点作简要的介绍。

### 2.1 人工神经网络

人工神经网络是在现代神经生物学研究成果的基础上发展起来的一种模拟人脑信息处理机制的网络系统，它不但具有处理数值数据的一般计算能力，而且具有处理知识的思维、学习和记忆能力，是计算智能和机器学习研究的最活跃的分支之一。人工神经网络是从人脑的生理结构出发，探讨人类智能活动的机理。从 1943 年 McCulloch 和 Pitts 首先提出 MP 神经元数学模型开始，人工神经网络的研究大致经过了 1947—1969 年的初创期，1970—1986 年的低潮过渡期和 1987 年至今的蓬勃发展期。目前，人工神经网络由于其大规模并行处理、容错性、自组织和自适应能力，以及联想功能等特点，已成为解决问题的有力工具，对突破现有科学技术的瓶颈，更深入地探索非线性问题等复杂现象起到了重大作用，并广泛应用于许多科学领域。

神经网络的主要特点如下：

- (1) 分布式存储信息。它是利用大量人工神经元间的连接及对连接权值的分析表示特定信息，使得人工神经网络同时具有较强的鲁棒性和高度的容错能力，即使局部的网络受损，也不至于整体瘫痪。
- (2) 并行处理。使得快速进行大量运算成为可能。
- (3) 自组织自学习能力。人工神经元的学习就是通过一定的训练数据，不断调整自身权值，使得整个网络的信息处理能充分逼近任意复杂的非线性关系的过程。这种自学习过程是对人的形象思维方法的模拟。
- (4) 信息综合能力。人工神经网络能处理定量和定性的信息，并协调多种信息之间的联系。

神经网络控制是研究和模拟人脑的某些结构机理以及人的知识和经验对系统进行控制。采用人工神经网络，控制问题可以看成模式识别问题，被识别的模式是映射成“行为”信号的“变化”信号。人们普遍认为，神经网络控制系统的智能性、鲁棒性均较好，能处理高维、非线性、强耦合和不确定性的复杂工业生产过程的控制问题，其显著特点是具有学习能力，能不断修正神经元之间的连接权值，并离散存储在连接网络中，因而对非线性系统、难以建模的系统具有良好的映射能力，可将权值的修正看成是对映射的修正，以达到希望的目标函数。

一般来说，人工神经网络用于控制有两种方法：一种是用来实现建模，一种是直接作为控制器使用。具体可分为以下几个方面：

(1) 系统建模。对于系统的输入输出数据，利用神经网络在带有严重非线性特性的系统中建立其输入输出映射，比传统的线性系统辨识更为有效。多数神经网络建模是和控制器一起实现的。

(2) 直接自校正控制。神经网络首先离线学习被控对象的逆动力学特性，然后作为对象的前馈控制器，并在线继续学习逆动力学特性。如果神经网络充分逼近对象的逆动力学特性，则从神经网络的输入端至对象的输出端的传递函数近似为1。

(3) 间接自校正控制。自校正调节器的目的是在被控系统参数变化的情况下，自动调节控制器的参数，消除扰动的影响，以保证系统的性能指标。在这种控制方式中，神经网络用做过程参数或某些非线性函数的在线估计器。

(4) 神经网络模型参考自适应控制。神经网络控制器根据输出误差来修正权值，使得偏差趋近于零。当系统结构已知时，可用常规的控制方法取代神经网络控制器；当系统结构未知时，可用神经网络控制器的逼近能力来完成控制。

(5) 神经网络内模控制 (IMC)。神经网络 IMC 是一种非线性控制，为了获得更好的控制效果，通常在控制器前加一个常规的滤波器，神经网络控制器不直接学习被控系统的逆动力学映射关系，而是由神经网络状态估计器来训练学习，以减轻神经网络控制器的负担。

### 2.1.1 神经网络结构及学习方法

神经网络的性质主要取决于两个因素：一个是网络的拓扑结构，另一个是网络的学习方式，两者相结合，构成神经网络的主要特征。

#### 2.1.1.1 神经网络结构

通常根据连接方式的不同，从结构上将神经网络分为层状和网状两大类。层状结构的神经网络由若干层组成，每层中包含一定数量的神经元，同层的神经元之间不能连接，相邻神经元单向连接；网状结构的神经网络中，任意两个神经元之间都可能双向连接。典型的拓扑结构有以下四种：

(1) 前馈网络。神经元分层排列，组成输入层、隐含层和输出层，每层只能够接受前一层神经元的输入，并且该层的输出送给下一层的各个神经元，输入信息经各层的顺序传递后，直接由输出层输出。

(2) 反馈网络。从输出层到输入层存在反馈，任意一个节点既可接收来自前一层各节点的输入，也可接收来自后面任一节点的反馈输入。另外，由输出节点引回到其本身的输入而构成的自环反馈也属于反馈输入。

(3) 相互结合型网络。这种类型的网络属于网状结构，任意两个神经元之间都可能有双向连接，所有神经元既作输入，也作输出。

(4) 混合型网络。混合型网络是层状结构网络和网状结构网络的一种结合。

目前，具有代表性的神经网络模型有：

(1) BP 网络。它是一种多层前馈网络，采用最小均方差的学习方式，使用最为广泛，可用于语言识别、自适应控制等。其缺点是仅为有导师训练，训练时间长，易于陷入局部极小。

(2) RBF 网络。它是一类非常有效的多层前馈网络，其神经元基函数具有仅在微小局部范围内才产生有效非零响应的局部特性，因而可以获得高速化学习过程。缺点是由于高斯函数的特性，该网络难以学习映射的高频部分。

(3) BAM 双向联想记忆网络。它是由相同神经元构成的双向联想式单层网络，具有学习功能。其缺点是存储度低，且需要编码。

(4) Hopfield 网络。它是最典型的反馈网络模型，是目前人们研究得最多的模型之一。它是由相同的神经元构成的单层网络，并且是不具学习功能的自联想网络，需要对称连接。该网络可完成有约束优化和联想记忆等功能。

(5) SOM 自组织特征映射模型。这种模型可以在一维或二维的处理单元阵列上形成输入信号的分布拓扑图。

(6) ART 自适应共振理论网络。它是一种无导师学习的自组织网络模型，能够较好地协调适应性、稳定性和复杂性的问题，主要用于模式识别，不足之处是对于转换、失真和规模变化较敏感。

(7) CMAC 小脑神经网络。它是根据小脑的生物模型提出的一种联想网络模型，对每一输出只有少部分神经元与之相关，其最大特点是它的联想具有局部泛化能力，并有学习速度快、无局部极小点等特点。

(8) 量子神经网络。它是在量子计算机或量子器件基础上构造的神经网络，它充分利用了量子计算超高速、超并行、指数级容量的特点来改进神经网络的结构和性能。

### 2.1.1.2 神经网络学习方法

随着网络结构的不同，网络权值的学习算法也不同，常见的主要有以下的学习方法：

(1) 死记式学习。网络的连接权值根据某种特殊的记忆模式设计而成，其值不变。在网络输入相关信息时，这种记忆模式被回忆起来。Hopfield 网络作联想记忆和优化计算时就属于这种情况。

(2) 有导师学习。学习的结果，即网络的输出有评价标准，网络将实际输出和评价标准进行比较，根据误差信号决定连接权值的调整。评价标准是由外界提供给网络的。

(3) 无导师学习。无导师学习是一种自组织学习，也是自我调整的过程，不存在外

部环境的示教和来自外部环境的反馈，可以实现主分量分析、聚类、编码以及特征映射的功能。

(4) 有导师与无导师的混合学习。混合学习过程结合两者的优点，事先用无导师学习抽取输入数据的特征，然后将这种内部表示提供给有导师学习进行处理，以达到输入输出的某种映射。

### 2.1.2 神经网络的工作方式

神经网络的工作过程主要由两个阶段组成：①工作期，此时各连接权值固定，计算单元状态要发生变化，以求达到稳定状态，该阶段完成较快，各单元的状态称为短期记忆；②学习期，此时各计算单元状态不变，各连接权值可修改，该阶段完成较慢，权值及连接方式称为长期记忆。

将神经网络看做一个高维动力学系统，可以将其工作过程用动力学模型描述。

权值固定，神经网络状态随时间变化的行为称为状态动力学，用公式(2-1)表示如下：

$$\frac{dx_i}{dt} = F_i(\mathbf{x}, w_{i1}, w_{i2}, \dots), \quad \mathbf{x} = (x_1, x_2, \dots, x_n)^T \quad (2-1)$$

神经元状态固定，连接权值随时间变化的行为称为权值动力学，用公式(2-2)表示如下：

$$\frac{dw_{ij}}{dt} = G_{ij}(w, \mathbf{x}) \quad (2-2)$$

动力学公式(2-1)、(2-2)分别表示神经网络的记忆和学习过程，它们是神经网络具有智能性的关键。联立公式(2-1)、(2-2)就构成一个高度复杂的神经动力学耦合系统，它反映了神经网络的动力学行为。但对于这个系统的任何解析解都是不可能的，它们可以采用如下的离散形式用计算机模拟求解：

$$x_i(t+1) = x_i(t) + F_i(\mathbf{x}(t), w_{i1}, w_{i2}, \dots) \quad (2-3)$$

$$w_{ij}(k+1) = w_{ij}(k) + G_{ij}(w(k), \mathbf{x}) \quad (2-4)$$

记忆过程用 $t$ 表示，学习过程用 $k$ 表示，对迭代得到的权值，令其在式(2-3)中保持不变一直到式(2-3)收敛于平稳态后，再由迭代式(2-4)，得 $w_{ij}(k+1)$ ，然后再返回式(2-3)重复迭代。式(2-3)、(2-4)可看为离散型神经网络。

### 2.1.3 前向神经网络数学模型

#### 2.1.3.1 人工神经元结构模型

受人的神经元工作机制的启发，人工神经元的结构模型如图2-1所示。

神经元的基本单元具有 $n$ 个输入 $x_i$  ( $i=1, 2, \dots, n$ )，每个输入通过一个适当的权值 $w_i$  ( $i=1, 2, \dots, n$ )连接到神经元的节点上，在这里进行加权求和运算，得到 $\alpha = \sum_i w_i x_i$ ， $\alpha$ 作为激活函数 $f$ 的输入，激活函数的另一个输入是神经元的阈值 $\theta$ ，

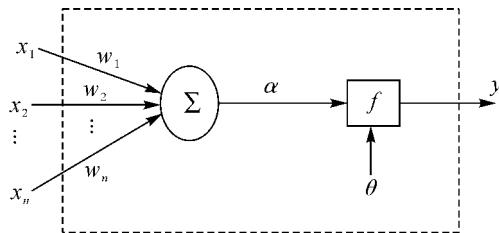


图 2-1 人工神经元结构模型

输出函数  $y = f(\alpha, \theta)$ 。由此可见，神经元的基本运算包括权值学习、阈值处理、求和运算和映射函数四个步骤。

常用的激活函数有以下几种。

(1) 线性函数

$$f(x) = \alpha x$$

(2) 带限的线性函数

$$f(x) = \begin{cases} \gamma, & x \geq \gamma \\ x, & |x| < \gamma \\ -\gamma, & x \leq -\gamma \end{cases}$$

式中， $\gamma$  为神经元的最大输出值。

(3) 阈值型函数

$$f(x) = \begin{cases} 1, & x \geq \theta \\ 0, & x < \theta \end{cases}$$

式中， $\theta$  为神经元阈值。

(4) Sigmoid 函数

$$f(x) = \frac{1}{1 + e^{-x}}$$

### 2.1.3.2 单层前向神经网络模型

神经网络是由若干基本神经元按照一定的方式连接而成的，单层前向神经网络对信息流的处理过程可用以下的数学模型描述，它是理解其他类型神经网络工作原理的基础。

定义网络的输入列向量  $\mathbf{X}$  为

$$\mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{bmatrix} = [x_1 \ x_2 \ \cdots \ x_i \ \cdots \ x_n]^T \quad (2-5)$$

神经元节点的连接权重表示为权重矩阵  $\mathbf{W}$ ，权重矩阵  $\mathbf{W}$  的行数等于输出神经元节

点数  $m$ , 列数等于输入神经元节点数  $n$ 。 $\mathbf{W}$  的  $j$  行是神经元节点  $j$  的权重向量  $\bar{\mathbf{W}}_j$  (行向量), 即

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1i} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2i} & \cdots & w_{2n} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{j1} & w_{j2} & & w_{ji} & & w_{jn} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{m1} & w_{m2} & \cdots & w_{mi} & \cdots & w_{mn} \end{bmatrix}_{m \times n} = \begin{bmatrix} \bar{\mathbf{W}}_1 \\ \bar{\mathbf{W}}_2 \\ \vdots \\ \bar{\mathbf{W}}_j \\ \vdots \\ \bar{\mathbf{W}}_m \end{bmatrix} \quad (2-6)$$

阈值  $\boldsymbol{\theta}$  为

$$\boldsymbol{\theta} = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_j \\ \vdots \\ \theta_m \end{bmatrix} = [\theta_1 \ \theta_2 \ \cdots \ \theta_j \ \cdots \ \theta_m]^T \quad (2-7)$$

神经元节点的净输入  $\mathbf{s}$  为

$$\mathbf{s} = \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_j \\ \vdots \\ s_m \end{bmatrix} = [s_1 \ s_2 \ \cdots \ s_j \ \cdots \ s_m]^T \quad (2-8)$$

则有

$$\mathbf{WX} + \boldsymbol{\theta} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1i} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2i} & \cdots & w_{2n} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{j1} & w_{j2} & & w_{ji} & & w_{jn} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{m1} & w_{m2} & \cdots & w_{mi} & \cdots & w_{mn} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{bmatrix} + \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_j \\ \vdots \\ \theta_m \end{bmatrix} = \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_j \\ \vdots \\ s_m \end{bmatrix} = \mathbf{s} \quad (2-9)$$

式中,

$$s_j = \sum_{i=1}^n w_{ji} x_i + \theta_j \quad (2-10)$$

若引入矩阵符号

$$\boldsymbol{\Gamma} = \begin{bmatrix} f(\cdot) & & 0 \\ & f(\cdot) & \\ & & \ddots \\ 0 & & f(\cdot) \end{bmatrix}_{m \times n} \quad (2-11)$$

来表示转移函数对神经元节点净输入的转移作用，则

$$\boldsymbol{\Gamma} \mathbf{S} = \begin{bmatrix} f(\cdot) & & & 0 \\ & f(\cdot) & & \\ & & \ddots & \\ 0 & & & f(\cdot) \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_m \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix} = \mathbf{Y} \quad (2-12)$$

所以

$$\mathbf{Y} = \boldsymbol{\Gamma}[\mathbf{W}\mathbf{X} + \boldsymbol{\theta}] \quad (2-13)$$

即

$$y_j = f(s_j) = f\left(\sum_{i=1}^n w_{ji}x_i + \theta_j\right) \quad (2-14)$$

对多层前馈网络，将信息流在网络中的传递过程简化为图 2-2 所示。

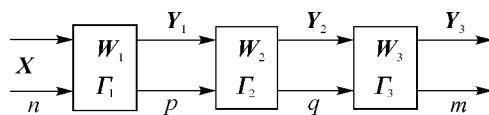


图 2-2 多层前馈网络简化流程

多层网络对信息流的处理与单层前馈网络相同，其向量形式表示如下：

第一层输出：

$$\mathbf{Y}_1 = \boldsymbol{\Gamma}_1[\mathbf{W}_1\mathbf{X}_1 + \boldsymbol{\theta}_1]$$

第二层输出：

$$\mathbf{Y}_2 = \boldsymbol{\Gamma}_2[\mathbf{W}_2\mathbf{X}_2 + \boldsymbol{\theta}_2]$$

第三层输出：

$$\mathbf{Y}_3 = \boldsymbol{\Gamma}_3[\mathbf{W}_3\mathbf{X}_3 + \boldsymbol{\theta}_3]$$

#### 2.1.4 神经网络发展趋势

神经网络是一门活跃的边缘性交叉学科，研究它的发展过程和前沿问题具有重要意义。近十年来，神经网络理论与实践有了巨大的进展，它再一次拓展了计算概念的内涵，使神经计算、进化计算成为新的学科，使神经网络的软件模拟得到了广泛应用。尽管神经计算机、光学神经计算机和生物计算机等研制工作具有艰巨性和长期性的特点，但可以相信其巨大的潜力。展望未来，今后神经网络的研究趋势将主要侧重于以下几个方面：

(1) 增强对智能和机器关系问题的认识。对于智能和机器的关系，应该从进化的角度，把智能活动看成动态发展的过程，并合理地发挥经验的作用。今后智能理论发展的方向是把基于联结主义的神经网络理论、基于符号主义的人工智能专家系统理论和基于进化论的人工生命理论这三大研究领域，在共同追求的总目标下，自发而有机地结合起来。

(2) 发展神经计算和进化计算的理论与应用。20世纪80年代以来，神经网络理论

在计算理论方面取得了引人注目的成果，形成了神经计算和进化计算新概念。未来离散符号计算、神经计算和进化计算相互促进，统一起来将会产生新的概念和方法。

(3) 扩大神经网络结构和神经元芯片的作用。神经网络结构体现了算法和结构的统一，是硬件和软件的混合体。未来的研究将主要针对信息处理功能体，将系统、结构、电路、器件和材料等方面的知识有机结合起来，构建有关的新概念和新技术。

(4) 神经网络与其他智能方法融合而得到的混合系统已成为一大研究热点，如与模糊技术、遗传算法、专家系统等相结合，发挥各自的优势，形成了所谓的“混合神经网络”。未来神经网络与各种智能信息处理方法的有机结合将具有很大的发展前景。

## 2.2 进化计算

对优化问题的求解是人工智能的一个重要应用领域，许多科学与工程问题都可以转化为优化问题。自从生物进化的理论被人们接受之后，关于进化的研究得到了很大的发展。虽然对进化的机制还没有完全搞清楚，但进化的一些特征已被人们所认识。生物学上这样的一些进展和研究成果在优化问题上的渗透就是进化计算。进化计算的研究始于20世纪50年代，其思想是将自然界中的进化过程引入工程研究领域，以解决工程中的优化问题。在用进化思想求解优化问题时，使用了进化过程中的遗传、选择等概念和思想，并且把它们作为算子参与优化。

20世纪60年代，Rechenberg提出进化策略，并将该方法用于优化实值函数；同一时期，Fogel, Owens 和 Walsh提出了进化规划，该方法把给定的问题描述成有限状态机，通过施加进化算子，从而达到优化的目的；Holland也在该时期提出了遗传算法，由于该算法简单易用，且对很多优化问题能够较容易地给出令人满意的解，所以得到了广泛应用，其影响也越来越大。进化策略、进化规划和遗传算法三者一起构成了进化计算的主要框架，在发展过程中，三者之间的差异越来越小。下面将对在理论上得到充分研究，在实际中得到广泛应用的遗传算法的基本原理作简要介绍，从中可以体现进化计算的主要思想。

### 2.2.1 遗传算法的基本思想和特点

遗传算法是模拟生物在自然环境中的遗传和进化过程而形成的一种自适应全局优化概率搜索算法，它是一种宏观意义上的仿生算法，体现了“优胜劣汰，适者生存”的竞争机制。

生物进化过程本质上就是生物群在其生存环境约束下通过个体的竞争、选择、杂交和变异等方式所进行的一种优胜劣汰的自然优化过程。遗传算法的基本思想正是体现了这一过程，从随机生成的初始种群作为父代群体开始进行搜索，将群体中的每个个体即问题的一个解看成染色体，算法通过染色体的“适应值”来作为父代中个体适应环境能力的度量，经优胜劣汰选择，再经杂交和变异产生新的子代染色体重新进行选择，如此反复进行迭代，使个体的适应能力不断提高并收敛于最好的染色体，该染色体就是问题的最优解。

和传统的优化算法，如单纯形法、梯度法、动态规划法等方法相比，遗传算法具有以下特点：

(1) 遗传算法处理的对象是参数集的代码，而非参数本身，与具体领域无关，因而可直接对诸如集合、序列、矩阵、树、图、链、表等各种一维、二维甚至多维结构形式的对象进行操作，具有广泛的应用领域。此外，对决策变量的编码处理方式，使得在优化计算过程中可以借鉴生物学中染色体和基因等概念，以模仿自然界中生物的遗传和进化等机理，也使得可以方便地应用遗传操作算子。

(2) 遗传算法是非单点搜索算法，具有全局搜索能力。传统的优化算法往往是从解空间中的一个初始点开始最优解的迭代搜索过程，搜索效率不高，有时甚至陷于局部最优解。而遗传算法的优化过程是从点集开始对搜索空间中的多个解进行适应值评估和染色体进化。这种机制使得遗传算法易于并行化，且搜索不易陷入局部极值点。特别是当算法中有保证群体多样性的措施时，可有效保持搜索空间的多样性，并使其具有较强的鲁棒性。

(3) 遗传算法直接以目标函数值作为搜索信息。传统的优化算法不仅要利用目标函数值，往往还需要目标函数的导数值等一些信息才能确定搜索方向。遗传算法仅使用由目标函数值变换得到的适应度函数值，就可确定进一步的搜索方向和搜索范围，无需目标函数的导数值等其他辅助信息，这就避免了目标函数导数不存在或无法获得带来的限制，扩大了优化问题可解的范围。此外，直接利用目标函数值或个体适应度，可以把搜索范围集中到适应度较高的部分搜索空间中，提高了搜索效率。

(4) 遗传算法使用概率搜索技术。传统的优化算法往往使用确定性的搜索方法，搜索点间的转移具有确定的关系，这种确定性往往有可能使搜索永远达不到最优点，因而限制了算法的应用范围。而遗传算法属于一种自适应概率搜索技术，其选择、交叉、变异等运算都是以一种概率的方式进行，增加了搜索过程的灵活性。实践和理论都证明了在一定条件下遗传算法总是以概率 1 收敛于问题的最优解。

## 2.2.2 遗传算法的基本原理

### 2.2.2.1 遗传算法的基本术语

- (1) 染色体。染色体是遗传物质的主要载体，指多个遗传因子的集合。
- (2) 个体。染色体中带有特征的实体称为个体。
- (3) 种群。染色体中带有特征个体的集合称为种群，该集合内的个体数称为种群的大小。
- (4) 编码。从表现型到遗传子型的映射称为编码。
- (5) 适应度。各个个体各自适应环境的程度称为适应度。
- (6) 选择。以一定的概率从群体中选择若干对个体的操作称为选择。
- (7) 交叉。把两个染色体换组的操作称为交叉，又称重组。
- (8) 变异。让遗传因子以一定的概率变化的操作称为变异。
- (9) 解码。从遗传子型到表现型的映射称为解码。

### 2.2.2.2 遗传算法的基本原理与流程

遗传算法是从代表问题可能潜在解集的一个种群开始，而种群则由经过基因编码的一定数目的个体组成，每个个体是染色体中带有特征的实体，染色体作为遗传物质的主要载体，即多个基因的集合，其内部表现为遗传子型，它决定了个体形状的外部表现。因此，首先需要实现从表现型到遗传子型的映射，即编码工作，通常采用简化的二进制编码方法。初代种群产生之后，按照优胜劣汰和适者生存的原理，逐代演化产生出越来越好近似解。在每一代，根据问题域中个体的适应度大小挑选个体，并借助于自然遗传学的遗传算子进行组合交叉和变异，产生出代表新的解集的种群。这个过程导致种群像自然进化一样，后生代种群比前代更加适应环境，末代种群中的最优个体经过解码，就可以作为问题的近似最优解。

计算开始时，设一定数目个体（父个体1，父个体2，父个体3，父个体4，…，父个体N），即种群随机地初始化，并计算每个个体的适应度函数，第一代即初始代就产生了。如果不满足优化准则，开始计算产生新一代。为了产生下一代，按照适应度选择个体，重组基因以产生子代。所有的子代按一定概率变异，然后子代的适应度被重新计算，子代被插入到种群中取代父代，构成新一代（子个体1，子个体2，子个体3，子个体4，…）。循环执行这个过程，直到满足优化准则为止。

对需要进行优化计算的实际问题，可按下述步骤构造求解问题的遗传算法：

- (1) 确定决策变量及其各种约束条件，即确定出个体的表现型X和问题的解空间。
- (2) 建立优化模型，即确定目标函数的类型及其数学描述形式或量化方法。
- (3) 确定表示可行解的染色体编码方法，即确定出个体的遗传子型Y及遗传算法的搜索空间。
- (4) 确定解码方法，即确定出由个体遗传子型Y到个体表现型X的对应关系或转换方法。
- (5) 确定个体适应度的量化评价方法，即确定出由目标函数值 $f(x)$ 到个体适应度 $F(x)$ 的转换规则。
- (6) 设计遗传算子，即确定出选择、交叉、变异运算等遗传算子的具体操作方法。
- (7) 确定遗传算法的有关运行参数。

在图2-3中表示了遗传算法的基本流程。

### 2.2.3 遗传算法的设计与实现

由不同的编码方法和不同的遗传算子构成了不同的遗传算法，但它们具有共同的特点，即通过对生物遗传和进化过程中选择、交叉、变异机理的模仿，来完成对问题最优解的自适应搜索过程。因此，编码方式、适应度函数、遗传算子和遗传算法运行参数构成了遗传算法设计与实现中的基本要素。

#### 2.2.3.1 染色体编码方法

利用遗传算法进行问题求解时，首先确定问题的目标函数和变量，然后对其进行编

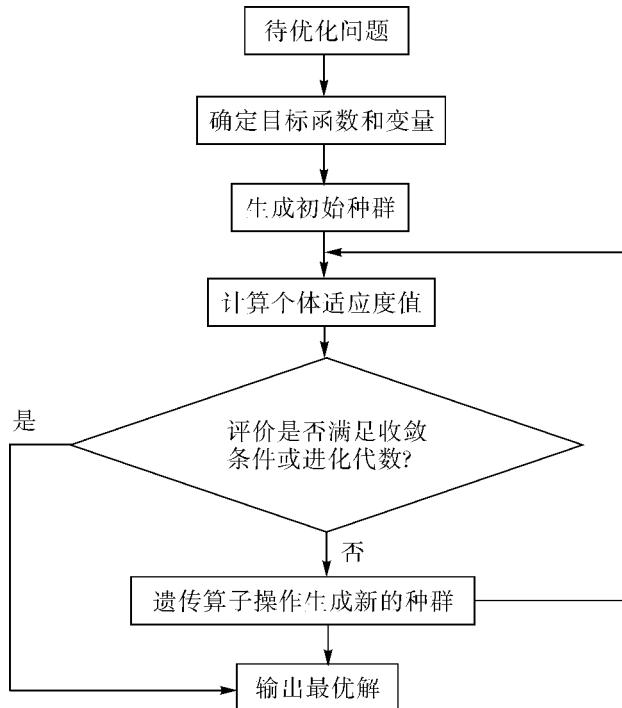


图 2-3 遗传算法基本流程图

码，常用的有二进制编码和浮点数编码。二进制编码是遗传算法中最常用的一种编码方法，即将原问题的解映射成 0、1 组成的位串，然后在位串空间上进行遗传操作。其优点是编码方式简单、操作方便，符合最小字符集编码原则，但具有 Hamming 悬崖缺陷，降低了遗传算子的搜索效率。为了克服二进制编码对于一些多维、有高精度要求的连续函数优化问题的不利之处，可以直接采用浮点数进行编码。这种编码方法是指个体的每个基因值用某一范围内的一个浮点数来表示，个体的编码长度等于其决策变量的个数，其特点是在变异操作上能够保持更好的种群多样性。

#### 2.2.3.2 适应度函数

遗传算法中使用适应度的概念来度量种群中每个个体在优化计算中有可能达到、接近于或有助于找到最佳解的寻优过程，适应度较高的个体遗传到下一代的概率较大。度量个体适应度的函数称为适应度函数，它的选取至关重要，直接影响到遗传算法的收敛速度以及能否找到最优解。在设计适应度函数时应满足单值、连续、非负、最大化等条件，还要兼顾计算量、通用性等要求。适应度函数设计时通常采用以下几种方法。

##### (1) 目标函数映射成适应度函数。

在许多问题的求解过程中，其目标函数是求函数  $g(x)$  的最小值，而非最大值。由于遗传算法要对个体适应度比较排序，并在此基础上确定选择概率，因此，要保证适应度值的非负性，可采用以下方法进行转换：

$$f(x) = \begin{cases} C_{\max} - g(x), & g(x) < C_{\max} \\ 0, & \text{其他} \end{cases} \quad (2-15)$$

式中,  $C_{\max}$  可以是一个合适的输入值, 也可以采用迄今为止进化过程中在所有取值范围内  $g(x)$  的最大值。

如果  $g(x)$  非负, 也可以采用如下转换:

$$f(x) = \frac{1}{g(x)} \quad (2-16)$$

当待求解问题是求  $g(x)$  的最大值时, 适应度函数的非负性可用如下变换保证:

$$f(x) = \begin{cases} C_{\min} + g(x), & C_{\min} + g(x) > 0 \\ 0, & \text{其他} \end{cases} \quad (2-17)$$

式中, 系数  $C_{\min}$  可以是合适的输入值, 也可以是当代或前  $k$  代中在所有取值范围内  $g(x)$  的最小值。

## (2) 适应度函数调整。

应用遗传算法时, 对于未成熟收敛现象, 应设法降低某些异常个体的竞争力, 这可通过缩小(扩大)相应的适应度函数值来实现。这种适应度的缩放称为适应度调整, 它是保持进化过程中竞争水平的重要技术之一, 其方式主要有线性调整和幂调整两种。

①线性调整。设原适应度函数为  $f(x)$ , 调整后的适应度函数为  $\tilde{f}(x)$ , 则线性调整可用下式表示:

$$\tilde{f}(x) = af(x) + b \quad (2-18)$$

式中, 系数  $a, b$  的选择要满足如下两个条件:

条件 1: 调整后的适应度平均值要等于原适应度平均值。

条件 2: 调整后适应度函数的最大值  $\tilde{f}_{\max}(x)$  要等于原适应度函数平均值所指定的倍数, 即

$$\tilde{f}_{\max}(x) = Cf_{\text{avg}}(x) \quad (2-19)$$

式中,  $C$  是为得到所期待的最优个体的复制数。实验表明, 对于一个不太大的种群而言,  $C$  可在 1.2~2.0 范围内取值。

条件 1 的提出是为了保证在以后的选择处理中平均每个群体的个体可产生一个期待的后代; 条件 2 的提出是为了控制原适应度最大的个体产生后代的数目。

②幂调整。该调整方式可定义为

$$\tilde{f}(x) = f^k(x) \quad (2-20)$$

式中, 指数  $k$  与待求问题有关, 在算法过程中可按需要进行修正。

### 2.2.3.3 遗传算子

选择算子、交叉算子和变异算子是三种最基本的遗传算子。

#### (1) 选择算子。

选择是从群体中挑选优良个体并淘汰劣质个体的操作过程, 它建立在适应度评估的基础上, 常用的选择策略有以下几种。

①适应度比例方法。适应度比例方法是目前遗传算法中最基础也是最常用的选择方法，也称为轮盘赌选择方法。在该方法中，每个个体的选择概率和其适应度值成比例。

设群体大小为  $n$ ，其中个体  $i$  的适应度值为  $f_i$ ，则被选择的概率  $P_{Si}$  为

$$P_{Si} = \frac{f_i}{\sum_{j=1}^n f_j} \quad (2-21)$$

累计概率为

$$q_i = \sum_{j=1}^i P_{Sj} \quad (2-22)$$

概率  $P_{Si}$  反映了个体的适应度在整个的个体适应度总和  $\sum_{j=1}^n f_j$  中所占的比例。

②最佳个体保存方法。该方法是把群体中适应度最高的个体不进行配对交叉而直接复制到下一代中。该方法的优点是进化过程中某一代的最优解可不被交叉和变异操作破坏，但该方法的全局搜索能力差，局部最优个体的遗传基因会急速增加而使进化有可能陷于局部解，所以，该方法一般都与其他选择方法结合使用。

③期望值方法。为了克服在适应度比例方法中当个体数不太多时有可能存在统计误差的缺陷，即适应度高的个体有可能被淘汰，期望值方法采用了如下思想：

a) 计算群体中每个个体在下一代的生存期望数目，即

$$M = \frac{f_i}{\bar{f}} = \frac{n f_i}{\sum f_i} \quad (2-23)$$

b) 若某个个体被选中并要参与配对和交叉，则它在下一代中的生存期望数目减去 0.5；若不参与配对和交叉，则该个体的期望数目减 1。

c) 在 b) 的两种情况中，若一个个体的期望值小于零，则该个体不参与选择。

④排序选择法。该方法以标准化几何分布规律随机对种群中染色体进行选择，以最佳染色体的选择概率  $p_s$  作为基本参数，按染色体的排列序号确定其选择概率。该方法的优点是既保证适应值较大的染色体获得高选择概率，同时又阻止某些超级染色体过快地控制遗传过程。

在算法过程中，首先需要根据最佳染色体选择概率计算标准分布值，算式如下：

$$t = \frac{p_s}{1 - (1 - p_s)^n} \quad (2-24)$$

然后，根据式 (2-24) 计算染色体选择概率，即

$$p_k = t(1 - p_s)^{N(k)-1}, \quad k = 1, 2, \dots, n \quad (2-25)$$

式中， $N(k)$  为第  $k$  个染色体的适应值在种群中由大到小排列的序号。

最后，计算染色体的累计选择概率值，即

$$q_k = \sum_{j=1}^k p_j, \quad k = 1, 2, \dots, n \quad (2-26)$$

(2) 交叉算子。

交叉是指把两个父串个体的部分结构加以替换重组生成新个体的操作。在遗传操作中，交叉操作因其全局搜索能力而成为主要算子，其作用在于它不仅使得原来种群中的

优良个体的特性能够在一定程度上得以保持，而且其探索新的基因空间的能力使得种群中的个体具有多样性，是遗传算法中获取优良个体的最重要手段。

①二进制交叉运算。交叉操作是按一定概率  $p_c$  在配对库中随机地选取两个个体进行的，交叉的位置也是随机确定的。其二进制编码操作可分为单点交叉、两点交叉和多点交叉。

单点交叉为在个体中随机地选定一个交叉点，两个个体在该点前后进行部分互换，以产生新的个体。

两点交叉与单点交叉类似，只是随机设置两个交叉点进行部分互换，以产生新的个体。

多点交叉即前述两种交叉方法的推广。

②浮点数编码的交叉运算。该交叉运算为线性交叉，也称为算术交叉，即两个父代以线性组合的方式产生子代。该方法在种群中均匀随机选取两条染色体  $v_{1l}, v_{2l}$  ( $l = 1, 2, \dots, n_c$ ) 作为交叉双亲，然后在  $[0, 1]$  区间内产生随机数  $r_l$ ，对染色体按交叉次数进行如下操作：

$$\begin{cases} v'_{1l} = v_{1l}r_l + v_{2l}(1 - r_l) \\ v'_{2l} = v_{1l}(1 - r_l) - v_{2l}r_l \end{cases} \quad (2-27)$$

式中， $v'_{1l}, v'_{2l}$  为产生的新染色体。

### (3) 变异算子

变异算子的基本内容是对群体中的个体串的某些基因位置上的基因值作变动，一般来说，变异算子操作的基本步骤为：①在群体中所有个体的码串范围内随机地确定基因位置；②以事先设定的变异概率  $p_m$  对这些基因位置的基因值进行变异。

遗传算法中，交叉算子因其全局搜索能力而作为主要算子，变异算子因其局部搜索能力而作为辅助算子，遗传算法通过交叉和变异这一对相互配合又相互竞争的操作而使其具备兼顾全局和局部的均衡搜索能力。遗传算法中使用变异算子使得遗传算法有局部的随机搜索能力，且维持群体的多样性。变异算子主要有基本变异算子和浮点数变异算子两种。

①基本变异算子。基本变异算子是针对二进制基因链码而言，其具体操作是：对群体中基因链码随机挑选  $c$  个基因位置，并对这些基因位置的基因值以变异概率  $p_m$  取反，即 0 变成 1，1 变成 0。

②浮点数变异算子。对浮点数编码方式，常用的有均匀变异和非均匀变异等手段，其主要的目的就是构造一个变异，扩大染色体基因值的取值范围。

a) 均匀变异。设种群中有染色体  $v_l = (v_1, v_2, \dots, v_k, \dots, v_m)$ ，先在染色体  $v_l$  中选择一个分量  $v_k$ ，然后在一个定义区间  $[b_l, b_r]$  中均匀地选取一个数  $v'_k$  代替  $v_k$ ，由此得到新的染色体为  $v'_l = (v_1, v_2, \dots, v'_k, \dots, v_m)$ 。

b) 非均匀变异。各代中参与变异操作的染色体的变异量是非均匀变化的，变异量  $d(v_l)$  的函数表达式为

$$d(v_l) = y \left[ r \left( 1 - \frac{g_c}{g_m} \right) \right]^b \quad (2-28)$$

式中,  $g_c$  为当前进化代数;  $g_m$  为最大进化代数;  $r$  为  $[0, 1]$  区间均匀产生的随机数;  $b$  为形状系数;  $y$  为参与变异操作的染色体到取值区域边界的距离, 按如下公式计算:

$$y = \begin{cases} b_r - v_l, & \text{sign} = 0 \\ v_l - b_l, & \text{sign} = 1 \end{cases} \quad (2-29)$$

式中, sign 随机产生 0 或 1。

#### 2.2.3.4 遗传算法运行参数的选择

遗传算法设计所涉及的参数主要有种群规模、交叉率、变异率和进化代数等。另外, 选择具体算子时, 还会涉及选择与算子相关的参数。遗传算法参数选择合理与否直接关系到算法的收敛速度和精度。

##### (1) 种群规模。

种群规模是遗传算法首先需要确定的参数。种群规模选得过小, 容易使算法陷入局部最优解; 种群规模选得过大, 会增加计算量, 减缓算法的进化速度。因此, 针对具体的问题, 种群的规模与以下影响因素有关:

①问题的内在规律。在问题空间内目标函数的极值点越多, 要求的种群规模越大; 目标函数的变化越平滑, 要求的种群规模越小。

②问题空间的范围。问题空间的取值范围越大, 要求的种群规模越大。

③交叉率、变异率的选择。交叉率和变异率较大时, 要求的种群规模较小; 反之, 要求的种群规模较大。

##### (2) 交叉率。

交叉率是指各代中交叉产生的后代数与种群规模之比, 遗传算法的性能在很大程度上取决于所采用的交叉算子和交叉率的大小。交叉运算不断产生新个体, 拓展搜索空间, 较高的交叉率可以搜索更大的解空间, 从而降低停在非优解的机会; 但如果交叉率太高, 则会因搜索了不必要的解空间而耗费大量的计算时间。常用的交叉率取值范围为 0.2~0.5。

##### (3) 变异率。

变异率是指种群中变异的基因数占总基因数的百分比, 它是遗传操作中的重要参数, 直接影响到算法的收敛性和最终解的性能。变异率控制着新基因引入的比例, 若变异率太大, 随机的变化就大, 那么后代就可能失去从双亲继承下来的好特性, 同时也影响算法的收敛性; 若变异率太小, 一些有用的基因就没有机会产生。因此, 在实际操作中, 算法常用的变异率数量级范围为 0.001~0.1; 或者在进化初期选择一个较大的值, 而在进化后期变异率随之减小。

##### (4) 进化终止条件。

进化计算的终止可以从两方面进行控制: 一是预先设定进化代数, 二是以种群的进化程度进行控制。种群的进化程度是指种群的当前代最大适应值与种群的平均适应值的比例关系。

## 2.3 专家系统

专家系统是人工智能的一个重要分支。专家系统的奠基人 Feigenbaum 认为：“专家系统是一种智能的计算机程序，它运用知识和推理步骤解决只有专家才能解决的复杂问题。”也就是说，专家系统是一个智能程序系统；具有相关领域内大量的专家知识；能应用人工智能技术模拟人类专家求解问题的思维过程进行推理，解决相关领域内的难题，并且达到该领域专家的水平。它的突出特点在于它一般解决的是没有算法可解的问题，并且经常要在不完全、不精确或不确定的信息基础上做出结论。

专家系统产生于 20 世纪 60 年代，主要是在逻辑论和通用问题求解程序上取得的成果；20 世纪 70 年代进入成熟阶段，关于专家系统通用性研究的骨架系统和通用表示语言的思想在此阶段形成；20 世纪 80 年代为发展阶段，人们把专家系统看做一种解决问题的实用工具，求解内容也向复杂问题深入；20 世纪 90 年代为兴起阶段，专家系统的数目迅速发展，并与其他智能环节进行融合。

### 2.3.1 专家系统的基本结构

专家系统的主要功能取决于大量知识，专家系统的关键是知识表达和知识的运用。一般专家系统由知识库、数据库、推理机、解释器及知识获取器五部分组成，它的基本结构如图 2-4 所示。

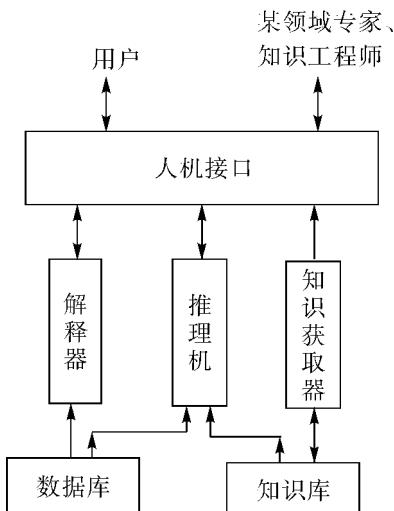


图 2-4 专家系统的基本结构

#### (1) 知识库。

知识库用于存放某领域的专门知识，包括事实和规则等。知识是系统进行推理的依据，领域知识通过一定的知识表示形式存放在知识库中，知识库中的知识可以通过不断从外界获取新知识来进行更新。

### (2) 推理机。

推理机根据一定的推理方式和控制策略，利用知识库中的知识推导出结论。推理机是专家系统能够运转的关键所在，一般分为控制和推理两部分，控制部分控制规则的触发顺序，推理过程则是应用规则匹配形成所需的结论。

### (3) 解释器。

解释器用于专家系统与用户之间的人机接口，根据用户的提问，对系统的结论、求解过程以及系统当前的求解状态提供说明。解释器由一组程序组成，它能跟踪并记录推理过程，其功能是向用户解释系统的行为，具体包括咨询理解和结论解释。为完成这些工作，通常要利用数据库中的中间结果、中间假设和知识库中的知识。

### (4) 数据库。

数据库用来存放系统推理过程中用到的控制信息、中间假设和中间结果。数据库的内容是不断变化的，开始求解问题时，用来存放用户提供的初始事实；推理过程中，存放每一步推理所得的结果，是推理机不可缺少的工作场地，又为推理机提供回答用户咨询的依据。

### (5) 知识获取器。

知识获取是知识工程师接受和消化某领域专家的经验和知识的途径。知识获取是专家系统的瓶颈，是建造和设计专家系统的关键，其基本任务是把知识输入到知识库，并负责维护知识的一致性和完整性，建立起良好的知识库。在不同的系统中，知识获取的功能及实现方法差别较大，有的系统首先由知识工程师向某领域专家获取知识，然后再通过相应的知识编辑软件把知识送入到知识库中；有的系统自身具有部分学习功能；有的系统直接与某领域专家对话获取知识，或者通过系统的运行实践归纳、总结出新的知识。

## 2.3.2 专家系统的知识表示法

知识是人类进行一切智能活动的基础，Feigenbaum 认为，专家系统的知识是“经过剪裁、塑造、解释、选择和转换了的信息”，而知识表示是指将知识符号化并输入给计算机的过程和方法。它包含两层含义：①用给定的知识结构，按一定的原则、组织表示知识；②解释所表示知识的含义。

就形式而言，知识表示是为描述世界所作的一组约定，是知识符号化的过程。知识表示是关于各种数据结构及其解释过程的结合，而知识表示方法是研究各种数据结构的设计，以及把一个问题领域的各种知识通过这些数据结构结合到计算机系统的程序设计过程中。传统专家系统中，知识的表示方法很多，它们虽然采用不同的结构和组织形式描述知识，但都是将知识转换成计算机可以存储的形式存入知识库，当推理时，再依据匹配算法到知识库中搜索。这种知识的存储是局域性存储。

目前，专家系统通常有下面五种知识表示法。

### (1) 命题逻辑表示法。

在特定的情况下具有“真”、“假”含义的对客观事物的描述，在逻辑上称为“命题”，研究命题之间关系的符号逻辑系统为命题逻辑。

在命题逻辑中，表示单一意义的命题称为“原子命题”。“原子命题”可以通过连接词构成“复合命题”。在命题逻辑系统中定义了五种连接词，即否定、合取、析取、条件和双条件。用符号  $P$ ,  $Q$  等表示不具有固定具体含义的命题，称为“命题变元”，“复合命题”可利用变元构成“合式公式”，然后就可用命题逻辑表示简单的逻辑推理。

命题逻辑可以用来表示知识，但无法把所描述的客观事物的结构和逻辑特征反映出来，也不能表示事物的共同特征，为弥补其局限性，在它的基础上又发展了谓词逻辑。

#### (2) 谓词逻辑表示法。

谓词逻辑是一种形式语言，也是到目前为止能够表达人类思维活动规律的一种最精确的语言。在谓词逻辑中，将“原子命题”分解为谓词与个体两部分，个体是指可以独立存在的物体，谓词用于刻画个体的性质、状态或个体间的关系。

谓词的一般形式是  $P(x_1, x_2, \dots, x_n)$ 。其中， $P$  是谓词， $x_i$  是第  $i$  个个体。谓词中包含的个体数目称为谓词的元数，个体可以是常量、变量或函数。为刻画谓词与个体的关系，在谓词逻辑中引入了两个量词，即全称量词 ( $\forall x$ ) 和存在量词 ( $\exists x$ )。

在用谓词表示客观事物时，谓词的词义都是由使用者根据需要人为定义的，即同一谓词有可能语义不同。当谓词的变量用特定的个体取代时，谓词就具有一个确定的逻辑值 T 或 F。

谓词逻辑适合于表示事物的状态、属性、概念等事实性的知识，也可方便地表示事物间的因果关系，即规则。事实通常用“合式公式”（用合取符号及析取符号连接起来的公式）的“与/或”形式表示，规则通常用蕴涵式表示。用谓词公式表示知识时，首先需要定义谓词，指出每个谓词的确切含义，然后再用连接词把有关的谓词连接起来，形成一个谓词公式，表达一个完整的含义。

谓词逻辑表示法具有自然性、描述性、精确性、严密性、易于模块化等特点，但它不能表示不确定的知识，容易形成组合爆炸，效率低。

#### (3) 产生式表示法。

基于规则的产生式表示法目前已成为人工智能中应用最多的一种知识表示模式。它的提出是根据客观世界中各客体之间存在依赖关系的实质而形成的。该方法表示知识准确灵活，易于被有关领域专家理解，有充分的能力表达领域相关的推理规则和行为。产生式通常用于表示具有因果关系的知识，其一般形式为

if 条件 1 and 条件 2 and … 条件  $n$ , then 结论或动作

式中的条件、结论或动作可以是自然语言或某种数学表达式。对于一个和时间无关的静态知识，可直接使用上述形式的规则进行表达；为了表达随时间变化的动态知识，需引进一个时间因子嵌入在规则的条件或结论部分。

把一组产生式放在一起，让它们相互配合、协同作用，一个产生式生成的结论可供另一个产生式作为已知事实使用，以求得问题的解决，这样的系统称为产生式系统，它由规则库、数据库和推理机三部分组成。

产生式表示法具有一般性，可用来模拟大量的计算或求解过程，常用于表示有关领域中各个不同状态间的关系，但是不能表达具有结构性的知识。

#### (4) 框架表示法。

框架表示法的基本观点是人脑已经存储有大量的典型情景，当人面临新的情景时，就从记忆中选择一个称作框架的基本知识结构，这个框架是以前记忆中的一个知识空框，而其具体内容依据新的情景而改变，以对这个空框的细节加工修改和补充，形成的对新情景的认识又记忆于人脑中。框架理论将框架视作知识的单位，将一组有关的框架连接起来便形成框架系统。系统中不同框架可以有共同节点，系统的行为由系统内部框架的变化来表现，推理过程是由框架之间的协调来完成的。

用框架表示知识就是将有关对象、时间和状况等内容的知识组织起来构成一个结构化整体。框架由框架名和一些槽组成，每个槽可以拥有若干个侧面，而每个侧面可以拥有若干个值。一个框架的一般结构如下：

```
<框架名>
  <槽 1><侧面 11><值 111>...
    <侧面 12><值 121>...
    :
  <槽 2><侧面 21><值 211>...
    :
  <槽 n><侧面 n1><值 n11>...
```

框架表示法最突出的特点是便于表达结构性知识，是一种结构化的知识表达方法。另外，在框架网络中，下层框架可以继承上层框架的槽值，也可以通过将槽值作为另一框架的名字而实现框架间的联系，建立起表示复杂知识的框架网络。

#### (5) 语义网络表示法。

语义网络是通过概念及其语义关系来表示知识的一种网络图，它是一个带标注的有向图。其中，有向图的各节点用来表示各种概念、事物、属性、情况、动作、状态等；用弧表示各种语义联系，指明它所连接的节点间的某种语义关系。节点和弧都必须带有标识，以便区分各种不同对象以及对象间各种不同的语义联系。每个节点可以带有若干个属性以表征所代表对象的特性。在语义网络中，节点还可以是一个语义子网络，这样它可以形成多层次的嵌套结构。

语义网络既可以表示事实性知识，又可以表示事实性知识之间的复杂联系，还可以用来表示规则性知识。用语义网络表示知识的一般步骤如下：

①确定问题中的所有对象及对象的属性。

②确定所讨论对象间的关系。

③语义网络中，若节点的联系是 isa/ako，则下层节点对上层节点的属性具有继承性。整理同一层节点的共同属性，并抽出这些属性，加入上层节点中，以免造成属性信息的冗余。

④将各对象作为语义网络的一个节点，而各对象间的关系作为网络中各节点的弧，连接形成语义网络。

### 2.3.3 专家系统的推理机制

知识的表示是问题求解的前提，从问题的表示到问题解决的过程就是推理过程，知

识推理就是使问题从初始状态转移到目标状态的方法和途径。常用的推理机制有下面五种类型。

#### 2.3.3.1 正向推理机制

正向推理是以已知事实作为出发点的一种推理，又称为数据驱动推理、前馈推理或前件推理等。正向推理的基本思想是从用户提供的初始已知事实出发，在知识库中找到当前可用的知识，构成可用知识集，然后按某种冲突消解策略，从可用知识集中选出一条知识进行推理，并将推出的新事实加入到数据库中作为下一步推理的已知事实。在此之后，再在知识库中选取可用的知识进行推理，如此重复，直到得到所求的解，或者知识库中再无适用的知识为止。

正向推理机制的主要优点在于它能充分利用用户或者实时系统提供的信息，因此，系统可以快速响应这些初始信息。缺点是知识的启用与执行漫无目标，推理过程效率低。减少盲目推理的方法是选择合适的控制策略，常用的有宽度优先搜索策略和深度优先搜索策略。

#### 2.3.3.2 反向推理机制

反向推理是以某个假设目标作为出发点的一种推理，又称为目标驱动推理、反向链推理或后件推理等。反向推理的基本思想是首先选定一个假设目标，然后寻找支持该假设的证据，若所需的证据都能找到，则说明原假设成立；若找不到所需证据，则说明原假设不成立，此时需要另作新的假设。如果目标明确，使用反向推理方式效率就较高，所以该方式经常被采用。

反向推理机制的一个显著优点是不用寻找和使用那些与假设目标无关的信息和知识，推理过程的方向性很强，是在专家系统中比正向推理更常用的一种策略，在解空间较小的问题求解环境下尤为合适。这种策略的主要不足在于初始目标的选择比较盲目，因此，在解空间较大，而且需要迅速响应用户的的数据输入的问题领域，反向推理策略难以接受。

#### 2.3.3.3 正反混合推理机制

既有正向又有反向的推理称为正反混合推理，是指先根据给定的原始数据或证据向前推理，得出可能成立的诊断结论，然后，以这些结论为假设，进行反向推理，寻找支持这些假设的事实或证据。

#### 2.3.3.4 启发式推理机制

以上讨论的各种推理机制的共同点是它们的搜索路线是事先定好的，没有利用被求解问题的任何特征信息，因而具有较大的盲目性，搜索效率较低。而利用待求解问题自身的某些特性信息来指导搜索，使其朝最有利于问题求解方向发展，提高搜索效率的搜索策略就是启发式搜索。

在启发式搜索过程中要根据启发信息估计各节点的重要性，使用估计函数来挑选最

优搜索节点。最优搜索又分为局部最优搜索和全局最优搜索。

局部最优搜索的思想是：当某一个节点扩展之后，对它的每一个后继节点计算估价函数  $f(x)$  的值，并在这些后继节点的范围内，选择一个  $f(x)$  的值最小的节点，作为下一个要考察的节点。若把深度界限  $d_m$  当成估价函数  $f(x)$ ，则深度优先搜索是局部最优搜索的一个特例。

全局最优搜索类似于宽度优先搜索，所不同的是：在确定一个扩展节点时，以与问题特性密切相关的估价函数  $f(x)$  为标准，在 open 表中的全部节点里选择一个  $f(x)$  值最小的节点作为下一个被考察的节点，因而是全局的。它是对宽度优先搜索的一种扩展。

为了解决深度优先搜索不完备的问题，出现了有界深度优先搜索方法，其基本思想是：对深度优先搜索方法引入搜索深度的界限 ( $d_m$ )，当搜索深度达到了深度界限，而尚未出现目标节点时，就换一个分支进行搜索。

#### 2.3.3.5 演绎推理和归纳推理

根据问题求解的推理过程中特殊和一般的关系，知识推理方法可分为演绎推理和归纳推理。

##### (1) 演绎推理。

演绎推理是指由一组前提必然地推导出某个结论的过程，它是从全称判断推出特称判断或单称判断的过程，即从一般到个别的推理。三段论法是演绎法的核心，归结原理是演绎推理的典型实例。三段论法包括以下三段：

①大前提。它描述的是关于一般的知识。

②小前提。它描述的是关于个体的判断。

③结论。它描述的是由大前提推出的适合于小前提的新判断。

##### (2) 归纳推理。

归纳推理是以某命题为前提，推出与其有归纳关系的其他命题的过程。归纳推理一般包括由特殊到一般的归纳、由特殊到特殊的归纳和统计三段论的方法。

归纳推理是从足够多的实例中归纳出一般性结论的推理过程，常用的归纳推理有简单枚举法和类比法。简单枚举法只根据一个个事例的枚举来进行推断，缺乏深层次分析，故可靠性较差。类比法推理的基础是相似原理，当两个或两类事物在许多属性上都相同的条件下，可以推出它们在其他属性上也相同。类比法的可靠程度取决于两类事物的相同属性与所推导出的属性之间的相关程度。

## 2.4 模糊控制

由于客观世界的千变万化、错综复杂，人们对客观世界的认识及语言表达不像逻辑推理那么定性和精确化，使得“模糊概念”更适合人们对事物的认识、理解和决策，这也更符合于客观现象和事物的模糊性。模糊控制理论正是基于这种思想由美国学者 Zadeh 于 1965 年首先提出来的，它是以模糊数学为基础，用语言规则描述知识和经验，

并结合先进的计算机技术，通过模糊推理进行判断的一种高级控制策略。

模糊控制是以模糊集合论、模糊语言变量及模糊逻辑推理为基础的计算机智能控制，它不需要精确的数学模型，是解决不确定性系统控制的一种有效途径。与常规控制相比，模糊控制主要具有以下优点：

(1) 模糊控制采用人类思维中的模糊量，而控制量由模糊推理导出，推理过程模仿人的思维过程，是一种反映人类思维的智能控制。模糊控制的核心是控制规则，这些规则以人类语言表达，易于接受。

(2) 模糊逻辑比常规逻辑更接近人直观的思维方式，控制系统的设计不要求掌握受控对象精确的数学模型，只需要提供现场操作人员的经验知识及操作数据；经常选用的隶属函数都比较简单，而所需要的控制规则不会过多，从这些简单的建造模块出发，系统可以完成非常复杂的任务。

(3) 模糊控制器易于构造和修改，模糊控制器以语言变量代替常规的数学变量，易于形成专家系统的知识，开始时可以用某些近似的隶属集合和规则，控制过程中再对参数重新定义，并不断对系统进行优化。模糊推理的各种成分都是独立地对函数进行处理，所以系统可以较容易地被修改。

(4) 模糊控制系统的鲁棒性强，对过程参数的变化不敏感，对系统参数变化的适应性强，在所有工作点上都能做到较稳定的控制。常规的基于数学模型的控制系统倾向于是一个相互依赖的整体，如果一个方程失败，或者物理系统的条件改变使得模型不再有效，则整个控制过程有可能崩溃。而模糊逻辑含有大量功能独立的元素与规则，模糊输出是多个规则影响的合并，所以即使一个规则失败了，其他的规则往往可以补偿。此时的系统可能不是最佳控制，但是仍然会正常工作。

在1990年以前的模糊控制可以称为经典模糊控制。模糊控制器的隶属度函数、控制规则是根据经验预先总结确定的，控制过程中没有对规则的修正功能，不具有学习和适应能力。此外，由于没有被控对象的模型，在投入运行之前就很难进行稳定性、鲁棒性等闭环分析，这也妨碍了传统控制理论在模糊控制中的应用。目前，众多学者对传统模糊控制进行了许多改进，发展成为多种形式的模糊控制，出现了模糊模型及辨识、模糊自适应控制，并在稳定性分析、鲁棒性设计等方面取得了进展。基于模型和分析方法的模糊控制可以称为现代模糊控制，这给模糊控制带来了活力，使其成为智能控制的重要分支。

#### 2.4.1 模糊理论基础

**定义2.1** 设 $X$ 为论域或全集，论域 $X$ 上的模糊集合用隶属函数 $\mu_A(x)$ 来表征， $\mu_A(x)$ 为实值函数，它的取值范围是 $[0, 1]$ 。

模糊集合：论域 $X$ 中的模糊集 $A$ 用一个在区间 $[0, 1]$ 上取值的隶属函数 $\mu_A$ 来表示，即 $\mu_A: X \rightarrow [0, 1]$ 。 $\mu_A(x)=1$ ，表示 $x$ 完全属于 $A$ ； $\mu_A(x)=0$ ，表示 $x$ 完全不属于 $A$ ； $0 < \mu_A < 1$ ，表示 $x$ 部分属于 $A$ 。

正确地确定隶属函数是运用模糊集合理论解决实际问题的基础。然而，目前确定隶

属函数还没有一种成熟有效的方法，一般是根据经验或模糊统计的方法来确定。因为隶属函数的确定并不是唯一的，把神经网络与模糊逻辑相结合，通过对神经网络的训练，由神经网络直接自动地生成隶属函数是解决这一问题的有效方法。在实际控制问题中，根据既能满足一般要求，又可简化计算的原则，一般选用的隶属函数有三角形、梯形、钟形（正态形）、Z形、S形和单点形等多种。

模糊集合通常采用 Zadeh 表示法来表示。对离散论域  $X = \{x_1, x_2, \dots, x_n\}$ ,  $X$  上的模糊集合  $A$  的 Zadeh 表示法可表示为

$$A = \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \dots + \frac{\mu_A(x_n)}{x_n} \quad (2-30)$$

对连续论域  $X \in \mathbf{R}$ , 其上的模糊集合可表示为

$$A = \int_{x \in X} \frac{\mu_A(x)}{x} dx \quad (2-31)$$

此外，还有将论域  $X$  中的元素  $x_i$  与其对应的隶属函数值  $\mu_A(x_i)$  组成序偶  $(x_i, \mu_A(x_i))$  来表示模糊子集  $A$  的序偶表示法，即

$$A = \{(x_1, \mu_A(x_1)), (x_2, \mu_A(x_2)), \dots, (x_n, \mu_A(x_n))\} \quad (2-32)$$

向量表示法是单纯地将论域  $X$  中的元素  $x_i$  所对应的隶属函数值  $\mu_A(x_i)$  按顺序写成矢量形式来表示模糊子集  $A$ ，即

$$A = \{\mu_A(x_1), \mu_A(x_2), \dots, \mu_A(x_n)\} \quad (2-33)$$

模糊逻辑是普通二值逻辑的推广，在其中，任何陈述都以一定程度的真实性表示，其取值可以是 0 到 1 之间的任意实数。对模糊集合的运算有：

并集	$\mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x) = \max(\mu_A(x), \mu_B(x))$
交集	$\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x) = \min(\mu_A(x), \mu_B(x))$
补集	$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$
代数积	$\mu_{A \cdot B}(x) = \mu_A(x) \times \mu_B(x)$
代数和	$\mu_{A+B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x)$
有界和	$\mu_{A \oplus B}(x) = (\mu_A(x) \times \mu_B(x)) \wedge 1 = \min(A(x) + B(x), 1)$
有界差	$\mu_{A \ominus B}(x) = (\mu_A(x) - \mu_B(x)) \vee 0$
有界积	$\mu_{A \otimes B}(x) = (\mu_A(x) + \mu_B(x) - 1) \vee 0 = \max(0, A(x) + B(x) - 1)$

式中， $\max$  为取大值运算， $\min$  为取小值运算。

模糊集合  $A$  本身是一个没有确定边界的集合，但如约定，凡  $x$  对  $A$  的隶属度到达或超过某个水平者才算是  $A$  的成员，那么模糊集合  $A$  就变成了普通集合  $A_\lambda$ 。

**定义 2.2** 设  $A \in F(x)$ , 任取  $\lambda \in [0, 1]$ , 设  $A_\lambda = \{x \in X; A(x) \geq \lambda\}$ , 称  $A_\lambda$  为  $A$  的  $\lambda$  截集，其中  $\lambda$  称为阈值或置信水平。又记  $A_{\lambda+} = \{x \in X; A(x) > \lambda\}$ , 称  $A_{\lambda+}$  为  $A$  的  $\lambda$  强截集。

下面的分解定理说明任何一个模糊集均可由一类普通集合套来表示。

**定义 2.3** 设  $A$  是普通集合， $\lambda \in [0, 1]$ , 进行数量积运算得到一个特殊的模糊集合  $\lambda_A$ , 其隶属函数为  $\mu_{\lambda_A}(x) = \begin{cases} \lambda, & x \in A \\ 0, & x \notin A \end{cases}$ 。

分解定理：设  $A$  为论域  $X$  上的模糊集合， $A_\lambda$  是  $A$  的截集，则有

$$A = \bigcup_{\lambda \in [0,1]} \lambda A_\lambda, \quad \lambda \in [0,1]$$

这个定理也说明了模糊性的成因，大量的、甚至无限多的清晰集叠加在一起，总体上就形成了模糊事物。

#### 2.4.1.1 模糊条件语句

在模糊系统建模时常用下面几种条件语言的形式表示。

(1) 简单模糊条件语句。

最简单的 if-then 规则的形式是：“如果  $x$  是  $A$ ，则  $y$  是  $B$ ”。

在模糊情形，有命题  $A(x)$ ， $x \in X$ ， $B(y)$ ， $y \in Y$ ，则  $A \rightarrow B$  是  $X \times Y$  上的一个二元模糊关系，其隶属函数为

$$\mu_R(x,y) = \mu_{A \rightarrow B}(x,y) = (1 - \mu_A(x)) \vee (\mu_A(x) \wedge \mu_B(y))$$

(2) 多重简单模糊条件语句。

由多个简单模糊条件语句并列组成的语句称为多重简单模糊条件语句，句型为：“if  $A$  then  $B$  else  $C$ ”。

定义如下 Mamdani 模糊蕴涵关系：

$$R = (A_1 \times B_1) \cup (A_2 \times B_2) \cup \dots \cup (A_n \times B_n) = \bigcup_{i=1}^n (A_i \times B_i) = \bigcup_{i=1}^n R_i$$

其隶属函数为

$$\mu_R(x,y) = \bigcup_{i=1}^n (\mu_{A_i}(x) \wedge \mu_{B_i}(y))$$

(3) 多维模糊条件语句。

句型为：“if  $A$  and  $B$  then  $C$ ”。

若  $A \in F(X)$ ， $B \in F(Y)$ ， $C \in F(Z)$ ，采用 Mamdani 定义，则有如下的三元模糊关系  $R$ ：

$$R = (A \times B) \rightarrow C$$

其隶属函数为

$$\mu_R(x,y,z) = [\mu_A(x) \wedge \mu_B(y)] \wedge \mu_C(z) = \mu_A(x) \wedge \mu_B(y) \wedge \mu_C(z)$$

(4) 多重多维模糊条件语句。

由多个多维模糊条件语句并列组成的语句称为多重多维模糊条件语句，其句型为：“if  $A_i$  and  $B_i$  then  $C_i$ ”，其中， $i=1, 2, \dots, n$ ，表示  $i$  重二维模糊条件语句。这种模糊蕴涵关系为  $(A \wedge B) \rightarrow C$ ，根据 Mamdani 蕴涵定义，其关系  $R$  为

$$\begin{aligned} R &= (A_1 \times B_1 \times C_1) \cup (A_2 \times B_2 \times C_2) \cup \dots \cup (A_n \times B_n \times C_n) \\ &= \bigcup_{i=1}^n (A_i \times B_i \times C_i) \end{aligned}$$

#### 2.4.1.2 模糊推理

在模糊控制中应用较多的有四种推理，分别是 Mamdani 推理、Larsen 推理、Tsukamoto 推理、Takagi-Sugeno 推理（也称为 T-S 模型）。

以两条模糊控制规则为例说明推理方法，其结论可推广到  $n$  条模糊规则的情况。

对于前三种推理，设有如下模糊控制规则：

$$R_1: \text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } z \text{ is } C_1$$

$$R_2: \text{if } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } z \text{ is } C_2$$

则对于模糊控制规则的前件来说，有推理强度  $\alpha_1, \alpha_2$  如下：

$$\alpha_1 = \mu_{A_1}(x) \wedge \mu_{B_1}(y)$$

$$\alpha_2 = \mu_{A_2}(x) \wedge \mu_{B_2}(y)$$

对于第  $i$  条控制规则，有控制量  $C_i$ ，对于不同的推理机理，它的隶属函数分别如下所述。

(1) Mamdani 推理。

最终的模糊控制量  $C$  的隶属函数为

$$\mu_C(z) = [\alpha_1 \wedge \mu_{C_1}(z)] \vee [\alpha_2 \wedge \mu_{C_2}(z)]$$

这种推理是采用最大、最小运算符  $\wedge, \vee$ ，故而也称为 max-min 推理。

(2) Larsen 推理。

它采用最大-乘运算符，故而也称为 max-product 推理。

最终的模糊控制量  $C$  的隶属函数为

$$\mu_C(z) = [\alpha_1 \cdot \mu_{C_1}(z)] \vee [\alpha_2 \cdot \mu_{C_2}(z)]$$

(3) Tsukamoto 推理。

这种推理用于控制规则中的模糊量  $A, B, C$  为单调隶属函数的情况，是 Mamdani 推理的一种简化方法。由于后件模糊量  $C_i$  是单调模糊量，所以把推理强度  $\alpha_i$  作用于  $C_i$ ，可得出对于  $\alpha_i$  的元素  $z_i$ ，则有

$$C_1(z_1) = \mu_{A_1}(x) \wedge \mu_{B_1}(y)$$

$$C_2(z_2) = \mu_{A_2}(x) \wedge \mu_{B_2}(y)$$

最终的控制作用是由所有的控制规则得出的，故结果控制量由加权平均法求得，即

$$Z = \frac{\alpha_1 z_1 + \alpha_2 z_2}{\alpha_1 + \alpha_2}$$

(4) Takagi-Sugeno 推理。

它的后件由多项式表示，考虑以下两条规则：

$$R_1: \text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } z = f_1(x, y)$$

$$R_2: \text{if } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } z = f_2(x, y)$$

则对于模糊控制规则的前件来说，有推理强度如下：

$$\alpha_1 = \mu_{A_1}(x) \wedge \mu_{B_1}(y)$$

$$\alpha_2 = \mu_{A_2}(x) \wedge \mu_{B_2}(y)$$

推理结果为

$$Z_1 = \alpha_1 f_1(x, y)$$

$$Z_2 = \alpha_2 f_2(x, y)$$

最后总结果是精确数  $Z$ ，它是由所有的控制规则推理结果共同作用产生的，并由下式决定：

$$Z = \frac{\alpha_1 f_1(x, y) + \alpha_2 f_2(x, y)}{\alpha_1 + \alpha_2}$$

#### 2.4.2 模糊模型

随着研究的深入，越来越多的研究者在模糊控制模式中引入了模糊模型的概念，出现了模糊模型，控制器就可根据模型采用现代控制理论方法进行设计，将定量知识和定性知识较好地融合在一起。模糊模型如图 2-5 所示。

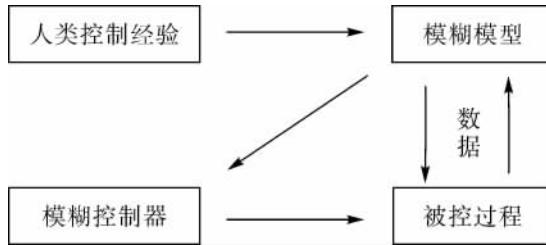


图 2-5 模糊模型

模糊模型使用 if-then 形式的规则表示控制系统的输入输出关系。现已发表的模糊模型主要有 Mamdani 模型和 T-S 模型。

在 Mamdani 模型中，图 2-5 表示的系统映射可以写成

$$\begin{aligned} R_i : & \text{if } y(k) \text{ is } A_{i1} \text{ and } y(k-1) \text{ is } A_{i2} \text{ and } \cdots \text{ and } y(k-n+1) \text{ is } A_{in} \\ & \text{and } \mu(k) \text{ is } B_{i1} \text{ and } \mu(k-1) \text{ is } B_{i2} \text{ and } \cdots \text{ and } \mu(k-m+1) \text{ is } B_{im} \\ & \text{then } y(k+1) \text{ is } C_i \end{aligned} \quad (2-34)$$

按 Mamdani 推理，采用质心法进行模糊判决，则系统总的推理输出为

$$y(k+1) = \frac{\sum_{i=1}^N \bar{C}_i \mu_i}{\sum_{i=1}^N \mu_i} \quad (2-35)$$

式中， $\mu_i$  为前提条件的模糊蕴含； $\bar{C}_i$  为第  $i$  条规则输出模糊集合的中心点。已经证明这种带模糊判决和取小蕴含运算的 Mamdani 模型是对连续函数的一种完备映射。

Takagi 和 Sugeno 于 1985 年提出了一种区别于 Mamdani 模型的 T-S 模糊模型。T-S 模型在前提部分与 Mamdani 模型有相同的结构，而结论部分代替了原来的模糊集合，用一个前提部分变量的多项式表示，是前提出量的线性函数，对于式 (2-34)，有如下结构：

$$\begin{aligned} R_i : & \text{if } y(k) \text{ is } A_{i1} \text{ and } y(k-1) \text{ is } A_{i2} \text{ and } \cdots \text{ and } y(k-n+1) \text{ is } A_{in} \\ & \text{and } \mu(k) \text{ is } B_{i1} \text{ and } \mu(k-1) \text{ is } B_{i2} \text{ and } \cdots \text{ and } \mu(k-m+1) \text{ is } B_{im} \\ & \text{then } y(k+1) = g_i(*) = p_0^i + p_1^i y(k) + \cdots + p_n^i y(k-n+1) + \\ & \quad p_{n+1}^i u(k) + \cdots + p_{n+m}^i u(k-m+1) \end{aligned} \quad (2-36)$$

也可表示为状态方程的形式，即

$$\begin{cases} x(k+1) = A_i x(k) + B_i \mu(k) \\ y(k) = C_i x(k) \end{cases} \quad (2-37)$$

这种控制系统的结构如图 2-6 所示。T-S 模糊模型可以看成是系统在不同工况时的局部模型。基于 T-S 模型，可以充分利用现代控制理论知识对各个局部模型分别设计控制器。由于它们在前提条件中对应不同的隶属度  $\mu_i$ ，所以系统总的输出仍可以按式 (2-37) 进行模糊判决。

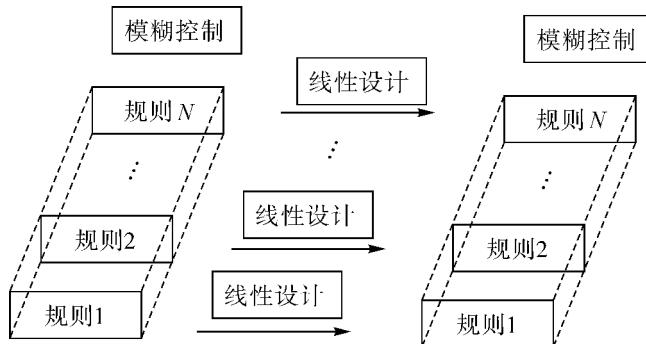


图 2-6 T-S 模糊控制器的设计

模糊模型除具有连续函数的映射能力外，还具有以下优点：

- (1) 集成专家控制经验，以 if-then 规则的形式表示，具有知识表达的特点。
- (2) 局部线性化模型可以采用现代控制理论（极点配置、状态反馈、预测控制等）方法进行系统设计和分析。
- (3) Mamdani 和 T-S 模型都可以根据系统的输入输出进行辨识，具有定量和定性知识集成的特点。

#### 2.4.3 模糊控制器

模糊控制器是模糊控制系统的核，一个模糊控制系统性能的优劣，主要取决于模糊控制器的结构、所采用的模糊规则、合成的推理算法以及模糊决策的方法等。由于在模糊控制器中采用的模糊控制规则是由模糊理论中模糊条件语句来描述的，因此，模糊控制器是一种语言型控制器。

以人类自然语言变量的概念作为描述手动控制策略的基础来实现模糊控制，必须解决三个基本问题：①经传感器的精确输入量至模糊控制器后，要转换成模糊集合的隶属函数，称为精确量的模糊化，其目的是把传感器的输入转换成知识库可以理解和操作的变量格式；②根据有经验的操作者或专家经验制定出模糊控制规则，并进行模糊逻辑推理，其目的是得到一个模糊输出集合，即一个新的模糊集合隶属函数，这一步称为模糊控制规则形成和推理，其目的是用模糊输入值去适配控制规则，为每个控制规则确定其适配的程度，并且通过加权计算合成那些规则的输出，得到输出控制模糊集合；③根据模糊逻辑推理得到输出模糊集合的隶属函数，用恰当的方法找一个具有代表性的精确值作为控制量，这一步称为模糊输出量的解模糊判决，其目的是把分布范围概括合并成单

点的输出值，加到执行器上实现控制。

模糊控制的基本原理可由图 2-7 表示，图中虚线框中部分为模糊控制器。模糊控制器的流程为：计算机经中断采样获取被控量的精确值，与给定值比较得到偏差信号  $e$ ；一般选偏差信号  $e$  作为模糊控制器的一个输入量，并对其模糊化得到模糊量；将模糊量用相应的模糊语言表示，得到  $e$  的模糊语言集合的一个子集；再由模糊子集和模糊控制规则（模糊关系）进行模糊推理，得到模糊控制量  $u = E' \circ R$ ，式中， $u$  为一个模糊量。为了对被控对象施加精确的控制，还需要将模糊量转换为精确量，这一步称为解模糊（也称清晰化）。得到精确的数字控制量后，变换为精确的模拟量送至执行机构，如此循环，实现对被控对象的模糊控制。综上所述，模糊控制过程可概括为下述四个步骤：

- (1) 根据本次采样得到的系统输出值，计算和选择系统的输入变量。
- (2) 将输入变量的精确值变为模糊量。
- (3) 根据输入变量（模糊量）及模糊控制规则，按照模糊推理合成规则推理计算输出控制量（模糊量）。
- (4) 由上述得到的控制量（模糊量）计算精确的输出控制量，并作用于执行机构。

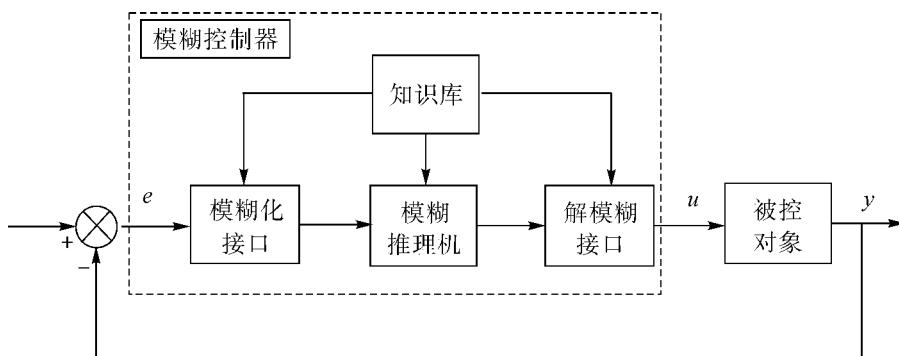


图 2-7 模糊控制器基本原理图

根据单变量模糊控制器输入量的个数，模糊控制器通常可分为一维、二维和三维。一维模糊控制器的输入变量仅仅采用受控变量的实测值与给定值之间的偏差，很难反映受控对象的动态特性品质，因此，一般仅用于一阶被控对象。二维模糊控制器的两个输入基本上选用偏差  $e$  和偏差变化率  $e'$ ，由于它能够比较严格地反映受控系统中输出变量的动态特性，因此得到广泛采用。三维模糊控制器比二维模糊控制器增加了偏差变化的变化率  $e''$  作为输入量。理论上讲，模糊控制器的维数越高，控制越精细。但维数过高，模糊控制规则变得过于复杂，控制算法的实现相当困难，因此，在实际系统中，通常不采用多维模糊控制器。

输入量必须先被转换成模糊集合的隶属函数。每一个输入值都可以对应一个模糊集合，对应某一范围连续变化的值可有无限多个模糊集合，这在工程实践中是无意义的。为了便于工程实现，通常把输入变量范围人为地定义成离散的若干级，所定义级数的多少取决于所需输入量的分辨率。输入量可由模糊器模糊化，常用的有单值模糊器、高斯

模糊器和三角模糊器。一般来说，对于任意可能采用模糊 if—then 规则的隶属度函数类型，单值模糊器可以大大简化模糊推理机的计算，但高斯模糊器和三角模糊器能克服输入变量中包含的噪声。如果模糊 if—then 规则中的隶属度函数分别为高斯隶属度函数或者三角隶属度函数，则高斯模糊器和三角模糊器也能简化模糊推理机的计算。

为了实现模糊控制器的标准化设计，目前在实际中常用的是 Mamdani 提出的处理方法，即把偏差  $e$  的变化范围设定为  $[-6, +6]$  区间连续变化量，使之离散化，构成含 13 个整数元素的离散集合： $\{-6, -5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5, 6\}$ 。在现实生活中，人们习惯将事物分成几个等级，而在工程中，对于控制量和误差常采用“正大 (PB)”、“正中 (PM)”、“正小 (PS)”、“正零 (PO)”、“负零 (NO)”、“负小 (NS)”、“负中 (NM)”、“负大 (NB)” 8 个语言变量值（模糊子集）来描述。语言论域上的模糊情况由隶属函数  $\mu(x)$  来描述， $\mu(x)$  可以通过总结操作者的经验或采用模糊统计方法来描述。

模糊规则库是模糊控制器设计的关键，模糊控制规则主要由以下途径获得：①将专家知识或操作者经验直接转换为模糊语言规则；②根据对模糊控制器控制过程的监督进行归纳和总结；③用模糊集合理论对被控制过程（生产过程）进行建模；④在控制系统运行中，实现规则的自组织。模糊规则通常由一系列的关系词连接构成，如 if—then、else、and、or 等，这些关系词必须经过翻译才能将模糊规则数值化。规则库就是用来存放全部模糊控制规则的，在推理时推理机提供控制规则。规则条数与语言变量的模糊子集划分有关，由规则库和数据库这两部分组成整个模糊控制器的知识库。

推理机在模糊控制器中是根据输入的模糊量，由模糊控制规则完成模糊推理以求解模糊关系方程，并获得模糊控制量的功能部分。模糊推理是模糊逻辑理论中研究的最基本问题，在模糊控制器中考虑到推理的时间和实时性，通常采用推理运算比较简单的方法，其中最基本的就是 Zadeh 近似推理，它分正向推理和逆向推理两类。正向推理常用于模糊控制中，相当于控制器的输入（已知），根据模糊关系  $R$  求其输出控制量；而反向推理一般用于知识工程学领域的专家系统中，如模糊诊断系统，根据事物表现出的症状，通过模糊关系  $R$  去推知引起症状的原因。

通过模糊推理得到的结果是一个模糊集合或者隶属函数，但在实际使用中，特别是在模糊逻辑控制中，必须用一个确定的值才能控制伺服机构。在推理得到的模糊集合中，取一个相对最能代表这个模糊集合的单值的过程称为解模糊判决。解模糊判决可以采用不同的方法，用不同的方法所得到的结果也是不同的。理论上用重心法比较合理，但计算比较复杂，故在实时性要求较高的系统中不采用这种方法。最简单的是最大隶属度方法，这种方法取所有模糊集合或者隶属函数中隶属度最大的那个值作为输出，但是这种方法未顾及其他隶属度较小的那些值的影响，代表性不好，所以它经常用于简单的系统。介于这两者之间的还有各种平均法，如加权平均法、隶属度限幅元素平均法等。典型的解模糊方法主要有重心法、最大隶属度法和取中位数判决法。

所谓重心法，又称加权平均法，就是取模糊隶属度函数曲线与横坐标轴围成的图形面积的重心作为代表点。采用一种折中方案，即用计算输出范围内整个采样点（即若干离散值）的重心来代替计算输出范围内一系列连续点的重心，这样在花费较少时间的情

况下，用足够小的取样间隔提供所需要的精度，即

$$u = \frac{\sum x_i \mu_N(x_i)}{\sum \mu_N(x_i)} \quad (2-38)$$

该方法不仅充分利用了模糊子集提供的信息量，而且根据其隶属度值确定其提供信息的大小，因此该方法的应用最为普遍。

最大隶属度法最简单，只要在推理结论的模糊集合中取隶属度最大的那个元素作为输出量即可。但要求这种情况下其隶属度函数曲线一定是正规凸模糊集合，如果该曲线是梯形平顶的，就要对所有取最大隶属度的元素求其平均值。

取中位数判决法的原则是：充分利用输出模糊集合所包含的信息，利用数学方法将描述输出模糊集合的隶属度函数曲线与横坐标围成面积的均分点所对应的论域值作为判决结果。

## 2.5 传统智能组件融合技术研究

信息科学与生命科学的相互交叉、相互渗透和相互促进是现代科学技术发展的一个显著特点，各种传统智能组件相互融合技术的研究成为当今智能技术研究的热点。

在目前广泛研究的多层前馈神经网络中普遍采用的误差反向传播算法，基于梯度指导学习过程，本质上是局部寻优算法，这种算法收敛速度慢，且常受局部极小点的困扰，存在学习精度与学习速度之间的矛盾，而采用遗传算法则可摆脱这一困境。遗传算法是一种借鉴自然界自然选择和进化机制发展起来的高度并行、随机、自适应的搜索算法。由于其思想简单、易于实现以及表现出来的健壮性，使它在问题求解、优化和搜索、机器学习、智能控制、模式识别和人工生命等应用领域取得了令人鼓舞的成就。由于遗传算法是一种基于生物进化过程的随机搜索的全局优化方法，它通过交叉和变异大大减少了初始状态的影响，使搜索得到最优结果不停留在局部最小处，其在神经网络中的应用主要反映在网络的学习、网络的结构设计和网络的分析三个方面，使用遗传算法可以把神经网络的结构优化和权值学习合并起来一起求解。

作为智能化信息处理的方法和手段，模糊技术和神经网络技术有各自的优势。模糊技术抓住了人类思维中模糊性的特点，以模仿人的模糊信息处理能力和综合判断能力的方式来处理常规数学方法难以解决的模糊信息处理难题，使计算机的应用得以扩展到那些需要借助人的经验才能完善解决的问题领域，并在描述高层知识方面有其长处。而神经网络技术则以生物神经网络为模拟基础，以非线性大规模并行处理为主要特征，可以以任意精度逼近紧致集上的任意实连续函数，在模式识别、聚类分析及计算机视觉等方面发挥着不可替代的作用，并在自适应和自学习方面显示出了新的前景。两者相结合就构成了模糊神经网络，这些研究主要包括三方面的内容：将模糊逻辑用于神经网络，用模糊技术提高神经网络的学习性能；将神经网络用于模糊系统，一是利用神经网络的学习能力实时扩展知识库，在线提取模糊规则或调整检测模糊规则参数，从而改善系统的控制性能，二是用神经网络实现一个已知的模糊系统，以完成其并行的模糊推理；模糊

系统和神经网络全面结合，构造完整意义上的模糊神经网络模型和算法。

专家系统与神经网络两种技术都试图模仿人类的思维方式来解决实际问题。专家系统是通过运用计算机的符号处理能力来模拟人的逻辑思维，建立在对知识的符号表示和处理用符号表示的知识的基础上。而神经网络是通过大规模集成简单信息处理单元来模拟人脑对信息的处理，建立在不同的连接关系基础上。由于两种技术自身的特点，它们都侧重于人类思维方式的某一方面，在复杂问题的处理上不能相互替代。所以，专家系统与神经网络除了依靠自身的不断发展与完善外，更要依靠两种技术的不断结合以获得更大的应用。

## 2.6 本章内容小结

本章对人工神经网络、进化计算、专家系统、模糊控制四种在智能控制领域得到广泛应用的传统智能组件的基本工作原理和主要特点进行了简要介绍，在此基础上指出了传统智能组件研究发展的新方向，即智能组件融合技术研究。正如第1章综述中的介绍，传统智能组件在飞行器控制领域也获得了应用，取得了一系列理论和实践成果，成为飞行器早期智能控制系统的代表。有理由相信，智能组件融合技术的研究将在飞行器智能控制系统中找到新的发展前景。

# 第3章 预测及模型自组织方法

## 3.1 预测和预测的方法

### 3.1.1 预测任务的提出

预测就是对我们所关心的对象将来的状态进行科学地、有根据地估计。预测应该能指出，对象状态的变化是什么时候和以什么样的顺序发生的，以及对象状态将怎样影响到该对象所要完成的任务。预测是任何科学研究不可或缺的组成部分。为了对对象进行数学描述，使用了来自不同领域的、不同规律形式的信息，在建模时应根据对象所面临任务，从它的所有性能中抽象出其本质性能。比如，在对摆锤的摆动建模时，没必要考虑它的价格和颜色等。所有本质的性能和相互间的联系将用来对对象加以认知和预测其中发生的过程，外界环境对对象的某些不定期的影响可看做随机作用。更本质性的、决定过程的定性变化的是外部扰动作用（其中包括在控制过程中被改变的控制作用）。在预测时需要已知外部扰动作用的变化，以获得所谓的“标准化预测”。一系列这样的预测按照“如果—那么”原则组成将来的场景的集合，专家们所要做的是从场景集合中选择一个能最大程度地满足对象所要完成的任务的场景。获得预测最简单的方式，是从这样的假设出发，即一切皆按照到目前为止的情况发生。“标准化预测”通常具有标准化场景的形式，该集合中的每一个场景将对应控制和扰动作用改变的一种方案。

### 3.1.2 以控制理论的术语来提出预测的任务

根据使用预测的科学技术领域的不同，有许多预测的定义：

- (1) 服务于社会有益目标的机器和设备，将来的发明创造、技术性能指标和功能可能性的预测。
- (2) 对将来的技术性能指标、形式和参数的概率性预测。这种预测是建立在对定量关系和逻辑的分析之上的，而不是对对象本质的直觉理解。
- (3) 以一定的置信度，对给定的时间区间内对象的科学技术性能的预测。
- (4) 对科学技术发展的可能途径和成就的概率的估计，以及为达到它所必需的资源和组织措施的估计。
- (5) 对将以高概率出现的未来技术改变的估计。

(6) 在不变的环境条件下或在其缓慢变化过程中所建立起来的关于将来的足够确定的命题。

(7) 对超前于规划的未来，必须选择首要的目标，并将其展开为目标和任务的体系。预测是重新形成将来情景的基础，从预测中确定系统状态的重要性，从中显现出活动的目标。

从这些定义中可以看出，预测概念中属本质范畴的是时间、目标、结构、周围环境、资源，与自动控制理论中所采用的那些概念相同。因此，预测变量  $y$  在通常情况下可以表示为某个控制系统的状态变量和输出变量，在其输入端有相应的输入和控制量  $u$ ，并处于对应的噪声  $s$  作用之下，如图 3-1 所示。

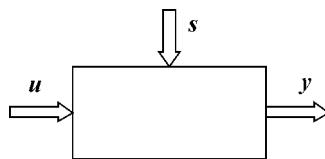


图 3-1 与预测模型类似的控制对象框图

所研究的对象在通常情况下是动态的和随机的控制系统，这时，预测任务可以这样来描述：给定处于随机作用之下的动态系统（或者是研究对象），观测的结果获得实现样本  $y_t$ ,  $t \in N$  和  $u$ ,  $t \in N$ 。关于系统的结构仅具有一般性能的先验信息，寻找模型，能够预测在超前区间  $t \in P$  中的输出变化  $y_t$ （以下将实现的总体  $y_t$ ,  $u$ ,  $t \in N$  称为观测表中的点）。

如果预测的超前区间不大，那么就需要能反映对象机理的模型（物理模型）。如果提出的是长期预测的任务，那么就需要更简单的非物理模型。

将所指示的预测变量的水平值在整个预测的超前区间内达到  $\pm 10\%$  的精度的预测称为定量预测（或区间性预测）；而定性预测不要求这样的精度，它将过程用概率性，或者用更常见的文字性的表达来描述。

需要区分用于定量预测（准确）和定性预测（模糊）的方法。不受外界作用明显影响的确定性机械系统能得到最好的精确预测。对有人参与的系统，其目标定向活动不可能有精确的计算，这时，正如前面指出过的，可借助于“标准化预测”的手段，这种手段考虑将来当控制作用发生给定改变时，以一系列场景形式出现的预测。这些场景的基本任务显然不是提供定量信息，而是揭示出可以对控制方案进行不同选择的那些时刻。在实践中最常遇到的是需要对拥有显著确定性分量（过程的趋势项）的随机过程进行预测，正是对这样的过程，使用本书中介绍的元素的分组考虑法（МГУА）。

### 3.1.3 短期预测和长期预测

可用适时性和预测超前的时间来确定预测的名称。通常把短期预测认为是超前 1~2 年（或步）的预测，另一些情况下把超前时间等于对象观测持续时间的 10%~20% 的预测称为短期预测。而长期预测是超前时间超过 10 年（或步）或者是等于或超过观测

时间的预测。

对于定常过程，可以将超前时间与相关时间进行比较，超前时间不可能超过相关时间  $T_k$ 。这时将具有单调下降的相关函数  $R_y(\tau)$  的定常随机过程  $y_t$  的相关时间理解为从它开始相关函数（或者它的包络）与零的偏差不大于 5% 的时间。这就意味着，完全不能预测白噪声 ( $T_k^* = 0$ )，而对确定性信号 ( $T_k^* = \infty$ )，可以预测任意长的区间。

由于相关函数与谱密度函数间的单值对应关系，可以给出对应于相关时间的边界频率  $\omega_{np}$ 。显然，短期预测考虑的仅仅是高次谐波，而长期预测考虑的是低频或极低频谐波。因此，按 МГУА 方法选择出的最优复杂度预测模型对短期和长期预测而言是不同的。用于辨识对象性能的模型和短期预测的模型是相吻合的，并且在低噪声水平下这种模型通常是物理模型，即符合对象作用的机理。这样的模型完全不适用于长期预测，对它而言，最优的是非物理的近似模型。

### 3.1.4 预测的试验方法

自组织方法属于预测的一种试验方法。假设过程发展的所有基本趋势反映在观测表中，过程的本质惯性有助于试验方法的使用，而当过程的趋势或基本方向为不可预料时，使用试验方法是不太有效的。

借助于试验方法，在过去信息的基础上解决预测问题，并且给出的预测，仅仅在当研究对象中没有产生任何原则上的（结构性）改变，且外界影响因素在同过去一样的边界内变化的时候，会与将来过程的实际发展相吻合，在这种情况下，在过去的有关信息基础上所获得的数学模型在整个预测的区间内可以保证提供丰富的信息。

### 3.1.5 需要的先验信息

可以根据预测所需的先验信息量的大小来区分不同的预测方法，这些先验信息是关于研究对象、可测量和不可测量的性能参数、状态和它周围环境的变化。

确定性方法假设所有的信息事先已具备或者可以以足够的精度获得；随机性方法考虑了干扰因素和噪声的影响，并且将感兴趣的性能指标考虑为随机量，它们的概率参数借助样本实现来获得。无论确定性方法还是随机性方法，均要求在原始数据表中存在完全的信息基，即所有显著的因素均应该考虑到，各因素测量的精度应足够高。

自组织的方法从根本上与上述方法有别：它所需的先验信息量是最小化的，并且可以在不考虑一系列本质因素，干扰超过有益信号几倍的情况下建立模型。比如，取决于 50 个本质因素的小麦的产量，能够借助于总共考虑 2~3 个因素的局部模型成功地预测出。这可以解释为在复杂对象中，各因素间是彼此相互影响的，其中每一个因素可以表达出整个参数组的影响。自组织的有趣性还在于，因素间的这种联系被用于筛选，而不在于它们仍然是未知的。用自组织方法建模（自组织模拟）的方法论基础是假设，存在于被建模系统的本质变量之间的所有有关信息，即关于系统结构和功能的信息包含在被称为数据样本的被建模对象的不大的观测表和给定的模型选择准则中。因此，自组织首先可以看做尽一切可能减小关于对象的先验信息的方法。在进行自组织时，模型的设计

者只需要提出用于选择最优复杂度模型的外部准则集。数学模型的自组织解决这一问题不需要预先指出被研究对象的规律性。

### 3.2 启发式自组织

对于只有极少量先验信息的复杂系统，乌克兰科学院控制论研究所提出来的启发式自组织方法是有效的，在许多国家得到了推广。

根据影响因素和感兴趣的系统输出变量的已有样本，在计算机上产生大量的模型，并根据相应的选择准则选择最优复杂度模型。建模者面临的任务是合理地组织、逐一筛选，并向计算机给出筛选的准则、基函数的可能类型和产生竞争模型的算法。

自组织的必要条件是：观测数据原始表（称为样本）；模型结构逐级复杂化规律和在给定的基函数范围内获得不同复杂度的竞争模型的指示；阈值选择；确定建模目标的筛选的启发式准则。根据给定的选择唯一的最优复杂度模型的外部准则集，在计算机上逐一挑选竞争模型集合时，上述条件决定了实现模型自组织所必需的先验信息的最小量。应注意到预先选择输出变量集合、基函数和模型方案逐级复杂化的必要性，以及根据建模任务提出选择准则的必要性。

通常尽力实现在可靠的先验信息基础上的指定选择。输入变量的集合包含该领域的专家所利用的所有变量。比如，经济学家知道在研究这种或那种经济对象中所使用的变量清单；生物学家以一定的时间离散度（一月一次或一季一次）年复一年地测量变量。而 МГУА 的算法可以从这样的变量清单中仅仅保留那些保证准则达到最小指标的实质性变量。

所使用的基函数集合是不大的，如果抄录近年来所有发表的预测方程，则很容易确信这一点。能够组织一系列的对基函数的逐一挑选，以保证模型选择的准则达到更深度的最小。实际中得以应用的是代数、多项式模型，线性的或非线性的，线性微分方程用它们的有限差分相似项代替，只在极少数的情况下要求使用非线性差分方程。

МГУА 的基本准则是偏移最小准则和各种平衡准则（包括不变量）。但是正如在后面将看到的，这些准则给出多值选择（即指出几个模型）并对噪声敏感。针对上述的情形，有研究开创了使用由吉洪诺夫（Тихонов А Н）研制的非完全问题解的整修理论的可能性。根据该理论，МГУА 的基本准则应当同某些辅助准则或者整修准则结合使用，以保证最优复杂度模型选择的单值性和对噪声不敏感。由此可以解释，为什么在 МГУА 中常常建议在两个准则的平面上来选择模型。

### 3.3 “自组织”术语的其他应用

本章中研究以对象辨识和其输出变量改变的长期预测为目的的模型自组织方法。术语“自组织”可理解为在由多个元素组成的系统中，在外部环境作用下发生的系统中序列或者组织的自发（随意的）增长过程。但是“自组织”这一术语常常用于其他的含义，下面给出自组织概念的其他定义。

自组织可看做是复杂系统自适应综合的方法。如果预先的不确定性只涉及给定结构下的系统参数，那么就可以应用已知的参数适应和学习的算法。如果结构也是不确定的，那么就需要用结构辨识的自组织算法。

自组织可理解为在自治闭合系统中组织的自发产生，为达到自组织，必须满足3个条件：①存在初始组织（基函数集合）；②具有随机改变（变异）这个组织（竞争模型的集合）的机制；③具有选择的机制，借助于它，这些变异能够根据它们对组织改善的有益度的大小得到评价（自组织算法）。

自组织的过程与熵的减小相联系，从这一意义上讲，自组织的原则是广泛研究的主题。在称为“协同学”的新学科中，从广泛意义的角度来讲，自组织可理解为由多个元素构成，并处在周围环境作用影响之下的系统中序列或组织性的自发增长过程。在竞争模型的集合中进行最优复杂度模型的自组织（选择），在数学上表达为熵的降低和信息量的增长，这些信息是作为秩序、组织、逆熵的尺度变量。在下一节将详细研究数学模型自组织算法的几种结构。

## 3.4 模型自组织的基本原则

### 3.4.1 数学模型自组织

#### 3.4.1.1 插值问题

在计算机帮助下，数学模型自组织方法的运用不仅仅局限于预测模型，该方法也是解决下列问题的通用途径：①插值和短期预测的任务；②长期预测的任务；③模式识别的任务。

(1) 辨识问题的提出。

给出一系统，其中  $\mathbf{u}$  为输入矢量，而  $\mathbf{y}$  为输出变量。观测的结果是我们可以支配输入变量  $u_t$  和输出变量  $y_t$ ,  $t \in N$  的有限大小实现的样本。寻求形如“输入—输出”类型的数学描述，通常的情况下它可以用下列函数变换的形式来得到：

$$\mathbf{y}(t) = \mathbf{F}(\mathbf{u}(t)), \quad t_0 < t < t_1$$

作为模型输出  $y_t^M$  和观测输出  $y_t$  间符合性度量的手段是品质准则  $Q(y_t, y_t^M)$ 。对动态系统使用沃特拉（Вольтерра）级数，得到以高莫戈罗夫—冈博（Колмогоров—Габор）多项式表达的离散相似项，即

$$y_t^M = a_0 + \sum_{i=0}^{n_1} a_i x_{it} + \sum_{i=0}^{n_2} \sum_{j=0}^{n_3} x_{it} A_{ij} x_{jt} + \dots \quad (3-1)$$

式中， $x_{it} = u(t-i)$ 。

观测  $(u_t, y_t)$  就可以确定方程 (3-1) 的系数向量和矩阵，它们对应于品质系数的最优值。

## (2) 短期和长期预测任务的提出。

给出变量  $v$ , 它影响变量  $w$  或者与其相关。观测的结果是我们获得有限量的实现, 即  $w_t, v_t, t \in N$  的样本, 为研究变量  $w_{t+\tau}$  在预测区间  $\tau \in P$  上的行为, 为此, 需要实现下列形式的预测:

$$w_{t+\tau} = f(w_t, w_{t-1}, \dots, w_{t-k}, v_t, v_{t-1}, \dots, v_{t-k})$$

作为模型输出  $w_{t+\tau}^M$  和观测输出  $w_{t+\tau}$  的符合度评价指标是品质准则  $Q(w_{t+\tau}, w_{t+\tau}^M)$ , 用  $y_t = w_{t+\tau}, x_{it} = (w_{t-i}, v_{t-i})$  来表示, 根据观测  $w_t, v_t$ , 确定方程 (3-1) 的系数矢量和矩阵, 该准则保证了品质指标达到最优。在  $P \leq 3 \sim 10$  时, 预测是短期的; 当  $P > 10$  时, 预测是长期的。

## (3) 模式识别任务的提出。

模式识别可以看做插值问题。给出带有构成矢量标志  $x_i$  ( $i=1, \dots, m$ ) 的对象的种类  $O = \{O_j \mid j \in J, J = J_A \cup J_B\}$ , 对象的标志也应彼此有差别, 以使样本  $A, B$  是可区分的 (紧凑性假说)。在学习阶段提出带有标志的实现  $x_{ik}$  的一系列图像, 并且借助于选择  $y_k$  的值指定其属于  $A$  类或  $B$  类, 即  $y_k = \begin{cases} 1, & k \in J_A \\ -1, & k \in J_B \end{cases}$ 。寻找分离判别函数  $y = f(x)$ , 借助于它可以对在学习时未考虑过的新图像进行分类。如果  $y_i^M > 0$ , 则被分类的图像属于  $A$  类; 反之, 则属于  $B$  类。为此, 在给定的品质准则  $Q(y_t, y_i^M)$  下,  $f(x)$  可以近似地用多项式或其他合适的函数来逼近。这样就完成了根据观测  $y_t, x_t$  来确定对应于图像识别品质指标最优值的系数矢量和矩阵的任务。

辨识、预测和模式识别的任务可以用确定性或概率性方法解决, 也可以借助自组织方法, 即将模型逐步复杂化, 并根据外部准则对其进行评价, 准则的最小值确定了最优复杂度模型。

### 3.4.1.2 产生不同结构复杂度的竞争模型

模型结构的复杂度与在准确的数据下确定所有参数估计所必需的测量点 (实现) 的代数最小值成正比。对于多项式模型, 需要确定带有不同指数阶数的变量相加项的系数的估计值 (通常采用最小二乘法)。在进行模型自组织时, 使用了竞争模型发生器, 它给出不同复杂度的方案的结构, 其中也包括多余的。自组织 (按准则进行评价) 提供了排除多余和随机的那些关系及联系的可能性。按照莱布尼兹的说法, “如果发明的前一半艺术在于逐步增加组合的复杂性 (或者是建立提案发生器), 那么可以确信, 后一半在于自组织准则的选择”。

为了进行自组织, 产生了大量的足够多样化的不同复杂度的竞争模型, 在排除明显不合适的模型后, 对剩下的集合按品质准则进行评价并选择最优复杂度模型。自组织算法根据产生不同结构复杂度模型和准则群的方法的不同而有所差别 (单级的 (排列式的), 多级的 (阈值式的) 或者带系数归零的, 多步的, 等等)。为提高自组织算法的抗噪性, 多准则的模型选择是必要的。

完全数学归纳用单级算法实现, 而不完全数学归纳是多级的 MIGA 算法。在完全数学归纳中, 对所有可能的最基本的模型进行挑选, 且挑选的工作量可能大得不可接

受。例如，对有 14 项的两个变量  $x_1, x_2$  的 4 阶多项式，我们得到  $2^{14} = 16384$  种可能的模型方案，从中需要找出最优复杂度模型。显然，尽管现代计算机有一系列高效的功能，但在某些任务中还是有可能达到其计算能力的边界。在这种情况下，转向不完全数学归纳会起到帮助作用，因为合理选择出的基函数的组合（如根据 МГУА，即算法的多级性），使得方案的数目仍然保留在可实现的范围内。尽管根据准则十分接近的模型在挑选过程中总能被找到，但在多级算法中还是存在错过最优复杂度模型的概率。

### 3.4.1.3 自组织算法依据的原则

下面是复杂对象数学模型自组织算法所依据的基本原则。

#### (1) 模型自组织原则。

自组织的基本原则可以这样来表述：在模型结构复杂度逐步增加的情况下，外部准则值首先下降，达到最小，然后要么保持常值（在带有残差计算的算法中），要么开始增长（在无残差计算的算法中），准则的第一个最小值确定了唯一的最优复杂度模型。总是可以找到使模型结构复杂度改变的那样一些方法，使得指示出的最小值是唯一的。除此以外，如果某个准则导致选择的多值性或者对输入数据的微小改变过于敏感，那么，向它补充具有单模态特性的第二个准则（整修算子），可以保证最优复杂度模型选择的单值性。

#### (2) 外部补充原则。

插值问题属于非完全的、具有多值解的任务。为了得到它的单值解，必须要有合理选出的外部补充——外部准则。外部准则可理解为用参数估计中未使用过的信息来计算的准则。对于每个外部补充，得到对应于它的插值问题的解，即最优复杂度模型随外部补充的不同选择可能不同。

内部补充（准则）是指不使用任何补充信息的准则，在噪声存在时不可能完成最优复杂度模型选择的任务。训练序列的均方偏差随着模型复杂度的增长而单调地下降，在模型参数的数目等于样本容量大小的那一点，其值恒等于零。模型越复杂，它就越准确。

应用到模型自组织的任务上，这个原则意味着，根据已经在参数估计中使用过的训练序列的数据，在没有补充外部信息的情况下，原则上不可能找到唯一的最优复杂度模型。必须要有外部准则，它用新的实现去估计误差，即用检查序列  $N_B$  的方法。

#### (3) 模型自组织的格德尔（Гедель）方法。

外部补充的原则作为克服格德尔不完备定理后果的手段首先由比尔（Бир С）表述出来（根据数学逻辑）。该定理断言，对任一原始公理体系（一级外部补充），总是可以给出那样一个定理，为证明它，给出的公理体系是不够的，而要求有新的公理——外部补充。

二级外部补充的语言应比一级外部补充语言更通用。在格德尔的工作中，他指出了定理成立的逻辑系统范围。关于任一公理集合不完全的格德尔定理在数学逻辑中产生了真正的变革，因为在这之前认为证明由给定的公理体系产生所有定理是可能的，即可建立完全的（闭合的）几何、代数和其他科学。格德尔指出，闭合的科学是不存在的，可以指出无穷多的定理集合，为证明它要求对公理集合作相应的扩展。

应用到模型自组织，格德尔的思想可以这样来解释：根据给定的外部准则的最小值可以解决基函数、模型结构和参数选择的所有问题，除了那些涉及准则自身的使用方法和计算算法的问题以外。为了优化准则自身，可以根据通用性（模糊度）程度使用准则语言的格德尔体系。用于选择最优复杂度模型的准则，我们称为第一级外部准则，那么为了优化第一级准则，要求更通用的第二级准则。为了解决第二级准则的所有问题，要求指出更通用的第三级准则，等等。

用于控制系统，格德尔方法意味着，反馈回路稳定了所有变量，除了外部补充——给定器电压。为了稳定给定器电压，要求建立一个更宽范围、带自己第二级给定器的反馈回路，等等。

#### (4) 模型选择的外部指标。

在回归分析中，对于同一过程的不同样本会得到不同的回归系数，因此，只对单独的回归系数赋予某个值是无意义的，如果回归方程（模型）按照偏移最小准则来选择，即无矛盾性，结果有可能会发生根本的改变。根据该准则，要求基于表 A 部分获得的模型尽可能小地区别于用表 B 部分获得的模型。偏移最小准则是基本准则，因为不矛盾性（一致性）是最优模型必须要有的性能。第一个得到推广的准则，称为正规性准则，它要求表 B 部分（未使用于参数估计）的均方误差应是最小的。该准则可以当做辅助准则、整修准则，作为对偏移最小基本准则的补充而使用。

对于差分预测模型，更方便的整修指标是多步预测的精度准则，而对代数模型，则用短期预测的精度准则来代替，它也常常用于对模型逐一挑选的限制。

#### (5) 将数据表划分为几部分。

偏移最小（一致性）基本准则要求将数据表分成两个相等的部分 A 和 B。每一部分中点组成的改变通常很少影响到准则的值。辅助的整修准则在对表格划分的要求上是不同的。多步预测的精度准则完全不要求划分数据表，最复杂的是用于正规性准则计算的数据表的划分。通常，过程的原始数据表被分为 2~3 部分，即训练样本 A、检查样本 B 和考查样本 C。这时，训练样本用于获得模型参数的估计（如回归系数），检查样本用于选择模型结构。从这一意义上讲，检查样本根据实验重复性的要求用于选择最优复杂度模型。考查样本用于评价不同的模型，也可将其用于选择训练样本和检查样本的最优划分。

#### (6) 选择的假说。

在生物学中，选择的原则保证了由遗传所制约的、与外部世界相符合的物种的逐渐改变。自古以来，这一原则既成功地作用于进化中，也作用于新物种的人工培养中，它同样方便地用于复杂系统信息的处理算法中。

作为一个例子，我们来看达尔文式的选择。为了获得具有期望性能的植物，移植大量的可能具有这些品质的植物（第一次试探——选择原始元素），这些植物的第一次交叉给出了第一代，对应于自组织算法中获得成对的组合（逐级提高复杂度）。从第一代的收成中选择一部分的植物，它们或多或少地满足我们的设想（第二次试探——给出阈值，即选择用于第二代的植物的数量）。将用这种方式挑选出来的植物移栽，它们的交叉将给出第二代（对输出元素的成对组合比第一代元素表现出更大的复杂度），对第二

代又可以进行阈值的选择，等等。

将大规模选择的原则引入到控制论的基本思想中是适宜的，就像在罗森布拉特（Розенблatt Φ）的感知器理论中所阐述的一样，这时应遵循下面的基本原则。

每一代（或模型选择的每级）都存在选择组合的某个最小数目，称为选择的自由度，它保证最优复杂度模型多级选择的收敛性。过大数量的代将导致退化（信息矩阵变得不易确定），选择的任务越复杂，就要求越多的代用于获得最优复杂度模型。此外，需要启发式地确定竞争模型发生器算法；确定提高竞争模型复杂度的规则；确定选择的准则及其使用顺序；确定传递到模型下一级的数目的阈值（即选择的自由度）；确定将原始数据划分为训练、检查、考查样本的规则，并且对两个量（阈值和划分）确定最优值。可以表述为以下的定理：如果竞争模型输出的数量越多地超过设定的阈值，在筛选时将丢失最优解和得到最优解附近的一个解的概率将越小。根据这一定理，在初始的代中被排除的不太有效的组合在后续的代中不可能给出有效的组合。

根据自组织理论，在复杂度增长的情况下，数学模型的逐级组合和挑选是寻找最优复杂度模型的通用方法。当模型的复杂度等于或小于研究对象的复杂度时，存在最优解。可以证明，对于多项式形式的基函数，多级别的误差应该根据用完全和不完全数学归纳模型所获得的预测的差来找到。已有算法在每一代都补充地使用原始观测，因此不具有上述的误差。

#### （7）保留选择自由度原则。

保留选择自由度原则，也称为非决定性解原则，是自组织中最基本的原则之一，并与选择的原则有许多共同点。它以某种方式补充了目前广泛流传的“固定”解原则（或称为固定规划），即在每次决策时都不留下任何选择的自由度。根据这个原则，最优化通过逐级解来达到，选择的自由度这样来保证：向下一个筛选级传递的不是一个解，而是在上一级中选出来的几个最好的解。

冈博（Габор Δ）详尽地阐述了这个原则：在当前时刻应该这样做决策，使得在下一时刻同样需要做决策时保留有决策选择的自由度。他的工作还包括引入决策自由度的度量尺度的尝试。在相空间中为此可以使用  $D$  相域，但是对使用来说更方便的是作用半径  $R$ 。

在数学模型自组织中保留选择自由度原则在两种情况下找到了应用：①在研制多级 МГУА 算法时；②在逐级使用一系列准则用于最优模型的选择时。保留选择自由度原则要求，在算法每一级进行逐级决策的过程中要选择一定数量的  $F$  个最优解，且  $F$  应该这样来选择，即进一步增大它不会使选择结果有实质性的改善。只有在最后一级，当达到了选择准则的最小值，才选择一个最优的解——最优复杂度模型。

在控制、规划和模式识别问题中，如果在每一级都确定唯一的解，则称为固定式或确定性方案。如果每次决策时选择了一定数量的解，这些解根据某个选择准则接近最优，那么这就对应多级性原则。多级性和在每级选择后存在选择的自由度是自组织原则最基本的性能。

#### （8）启发式方法的应用。

自组织同启发式方法紧密联系，因此在早期的文献中它常常被称为启发式自组织。

虽然对实际的目的而言是充分的，但作为一种未经充分论证的、用启发式方法获得的结果，不能使具有确定性思维的人感到满意。这些概念还未得到充分严格的定义，但可以将启发式方法理解为基于概括了解决问题的个人的所有以前经验的规则、方法和简化的一种方法。

建模结果的精度不仅取决于数学手段（计算程序）的完善，还取决于对品质准则的恰当的选择和使用这一手段的技术。模型自组织的启发式特点主要表现在选择局部描写的基函数（形成模型方案）、模型筛选准则、整修方式、变量规范化方式、顺序提高竞争模型复杂度的具体实现等方面。在阈值筛选中使用的阈值，可以试探性地给定，并借助于带矢量比较的计算多次重复来进一步确定。

#### 3.4.1.4 最优复杂度模型的选择

使用 3.4.1.3 中列举的各项原则，就可以在计算机上实现数学模型的自组织。

根据使用不完全数学归纳和多级筛选程序的自组织原则，在给定的基函数类型下得到一系列模型的方案，在一般情况下，在筛选的每一级获得系数间关系为线性的模型；而使用完全数学归纳将导致产生所谓的单级组合式算法。

为计算的简便，用训练序列估计系数时可以采用最小二乘法。随着复杂度（即变量数目或模型方案，多项式的阶数）的增长，用训练序列得到的逼近变得越来越好，即均方偏差一直减小。根据自组织原则，随着模型复杂度的增长，外部指标（如用检查样本计算的均方偏差  $\sigma_B^2$ ）通过了最小值。为了保证选择的自由度，在筛选的每一级（每一代）需要选出一定数目的最好的模型，这时借助筛选所建立的模型的最好方案数目，根据选择自由度原则，远远大于 1。如果进一步增加选择的级数不带来外部准则的改善，那么这意味着获得了最优复杂度模型。

自组织的基本算法假设，预先要给出模型复杂化规则、基函数组、选择的准则和相应的整修方法。

#### 3.4.1.5 自组织和先验信息的使用

从各种作用和使我们感兴趣的系统变量的已有集合出发，在计算机上建立大量的竞争模型，借助相应的选择筛选出所谓的最优复杂度模型。建模者向计算机提供挑选的准则、基函数的类型和模型产生的算法，以及整修的手法。这种方法在文献中称为模型自组织的归纳方法，因为所求的最优复杂度模型是在完全或不完全地对可能方案进行合理的逐一挑选结果下得到的。一般情况下，因为品质准则与模型复杂度间的关系是未知的，因而对于根据给定的品质准则获得最优复杂度模型这一非线性最优化任务，不可能借助演绎的数学方法来解析地解决。

用归纳的方法可以做到建立的模型具有一定的客观性，并且要求最小量的先验信息，但这并不意味着完全不使用已有的关于研究对象的信息。在实际应用中，应尽力做到将建模的确定性演绎方法和归纳方法相结合。越少使用先验信息，就需要越多地形成竞争模型，以从中选出最优复杂度模型。

以上所述的自组织原则用于根据输入输出变量的实现在计算机上进行数学模型的自

组织。这时自组织对先验信息仅提出了较小的要求，即不大数目的观测和建模目标的文字表述。在完全不确定性情况下，根据著名的罗森布拉特第二定理，即无穷多个感知器要能够自己学会模式识别，必须进行无穷多个数目的模型方案的筛选。

类似地，在纯粹归纳的方法和完全缺少先验信息的条件下，将要求有无法实现的多个数目的竞争模型，因此，应尽力寻求旨在减少按埃什比（Эшиби У Р）定律所必需的多样性，并基于这样的组合式方法建模：如果人准确地已知了什么，那么他就应该向计算机隐瞒这点。

此外，自组织的归纳方法不应该看做是建模演绎方法的一种替代品。在使用组合式的建模方法时，模型既借助于系统分析和公理体系的方法，也借助于自组织来得到。自组织的使用使得可以削减所需的先验信息，并限制在仅仅了解几个实质性的可靠的条件内，比如：

- (1) 昨天、今天和明天的模型应是同一个，预测应尽可能准确。
- (2) 一定的规律性在给定的时间段内保持了其作用。
- (3) 给定了模型所属的系统类型（如线性的、非线性的、静态的、动态的时间变量，时间不变量，等等）。

我们能以什么程度成功地将这些文字表述转化为形式化的外部准则，并借助于基函数的选择和逐步提高复杂度的规则获得所求的结构，选择出的模型就会达到相应的程度。应该强调，自组织对于吸引任何的先验信息都是开放的，并且像上面指出的，任何准确的已知信息都不应该向计算机隐瞒。先验信息改善模型的自组织。如果我们拥有关于系统结构、输出变量、系统的记忆等信息，那么在寻找最优复杂度模型时所需的方案的数目就大大减少，必要的计算得到简化，并且最主要的是提高了问题解的精度（即辨识和预测的精度）。

计算试验表明，预先地指出被研究系统特征方程根的特点（实根或复根），将大大提高获得最优复杂度模型的抗干扰性。准确的先验信息量的增加提高了自组织的抗干扰性。

### 3.4.1.6 借助自组织获得的模型的应用领域

自组织属于经验性的建模方法（后天的），这些方法在其应用领域内同理论性（先验的）和半经验性（如模拟的）的建模方法相比有一定的优点。当我们观测所关心的对象的参数，但是不知道复杂系统的结构和元素间相互作用的机理，而观测参数的值由系统的行为来确定，这时自组织的方法是建立预测模型的唯一可靠的手段。借助于自组织，在其他方法不能得到结果的情况下，可以找到解。正如已经指出的，借助自组织获得的模型具有自己特定的应用领域，并且对于长期预测是特别有效的。基于研究对象类的数学理论得到的物理模型仅仅可以实现一定的认识目标（辨识和短期预测）。每种模型都有自己的特殊性和所能解决任务的局限范围。任何一个模型都不可能同时完成所有的任务，这正是富列什曼（Флейшман Б С）所指出的结果，即模型不可能同时完成预测的功能和理论构建的功能，其中包括短期预测和长期预测的模型在结构、自变量和参数估计上的不同。

一方面，在对象辨识中，用理论解析法建立物理模型可能具有优点，但是，如对定量预测的目的而言，在存在噪声时物理模型就不合适了。另一方面，当先验信息不充分时，自组织、模拟和理论解析法建模可以很好地相互补充，而不是相互替换。借助于解析模型，可获得最初的原形和问题综合的理论概念。在理论方法下找到的规律性和原理，可以在模拟中以及在自组织时被考虑到。模拟，特别是自组织，使得可以在个别的情况下进一步明确原始的推断和分析在理论解析法中未考虑到的作用。因此，用模拟方法得到的模型的复杂度，可借助自组织获得的模型来修正。被研究对象的复杂度这时将达到这样的程度：以至于科学家或科学家的集体不拥有关于系统或其局部的任何可靠信息，因此不能够指出局部模型的结构。人的寿命与周围环境污染间的相互关系以及在亚速尔海模型中化学毒剂的衰变过程可以用做这样的例子。这就指出了依靠新的、客观的自组织方法扩大可靠建模的储备的必要性。正是由于该方法，使得对于还不具备科学依据的先验知识的部分多成分系统模型，可以提出基于可靠信息（观测、研究目标等）和借助自组织所得到的模型，以代替假设和粗略的估计。系统的复杂组分的模型可以根据非常小的观测数据样本来得到，这是实际应用中非常重要的一点。

#### 3.4.1.7 借助于自组织算法的使用排除有害的特征（或因素）

在小样本下，由于模式识别和辨识的实际系统的非完善性，还由于数据的训练序列的有限长度，信息的载体（特征、信号或因素）有可能是有益的，也可能是有害的。假如我们能拥有无限长度的样本和理想的系统，则所有特征都是有益的。排除有害因素的结果表现在：当存在噪声时，在自组织结果下得到的最优复杂度模型比完全的物理模型更简单，最优的非物理模型仅包含完全模型的部分因素。

应该注意到输出变量集合的选择，它们中仅有部分给出不矛盾的方程，这些方程对于对象观测数据表中各个部分几乎是保持不变的。这样的变量，称为主导量，它们将在把模型自组织为方程组时根据非偏移性系统准则被挑选出来。“模型”概念自身就意味着其组成方程的不矛盾性和非偏移性。

#### 3.4.1.8 模型符合性检查

辨识的最后一个阶段是检查符合性或模型校对，它由根据最终的结果检查获得的模型对所要解决的问题的适应性构成（如对借助该模型实现的控制而言）。显然，这个过程的计算量是很大的，它常常被更简单的程序替代，如检查某个中间变量的精度。在自组织时，这样的做法已经被包含到获得模型的程序中，这是通过给定的筛选准则使用整修方法来实现的。

各种各样的自组织方法与其多级性和使用选择的原则（其中包括使用冈博的选择自由度原则）一起，与已知的统计方法（步进式回归、计算所有可能的回归及其他）的区别在于：它们使用了更具适应性的、与建模目标相联系的外部准则。这时外部准则有最小值，由此将可以单值地确定最优复杂度模型。自组织的多级算法在每一级都给出局部模型，它们的参数数目远远小于训练序列中实现的数目，因此，对局部模型可以完成在数学统计中所采用的显著性检查。

模型选择的客观性基于最优复杂度模型对应于选择准则的最小值，这时选择准则的最小值可能是品质或者模型符合性的度量。具有较小的、更深度地表现出选择准则的最小值的模型是更可信和更准确的。正规性准则的最小值与费歇尔（Фишер）可信度准则成正比。对一系列例子的研究表明，如果满足以下条件，计算机借助自组织算法能够选择出所求的最优复杂度模型。

(1) 在逐渐提高模型复杂度的条件下所获得的竞争模型系列方案中包含所求的最优复杂度模型。这就意味着，越来越复杂的模型方案的形成规则、基函数组和输出变量的集合符合这个模型。

(2) 观测到的实现足够准确并且噪声不过分大。

(3) 实现的数目足够大。

通常，选择准则的最小值应该具有观测精度数量级的数值，即大约为第一级选择准则值的5%~10%。如果随着复杂度的提高没有达到明显表现出来的深度最小值，那么说明上面所述的要求被破坏了，并且自组织没有给出成功的结果，获得成功的结果需要满足上述三个条件。

### 3.4.2 模型自组织算法

#### 3.4.2.1 数学模型自组织算法的基本结构

自组织算法的基本结构由下列模块构成：

- (1) 考虑到选出的基函数集合来对观测进行预先处理（削减变量集合）。
- (2) 竞争模型集合的产生。
- (3) 作为外部补充的选择准则的计算和最优复杂度模型的挑选。

自组织的多个算法在第二个模块上是有区别的，即在形成更复杂方案模型的方法上不同。在如图3-2所示的自组织算法的通用结构框图中，包含模型形成模块（竞争模型产生器G），根据采用的提高模型方案复杂度的算法，在其输出处得到具有增长复杂度的局部模型。用于挑选的装置S根据给定的准则C选择最优复杂度模型M。由产生模型方案的方法区分出完全（单级的）和不完全（多级的）归纳的方法。

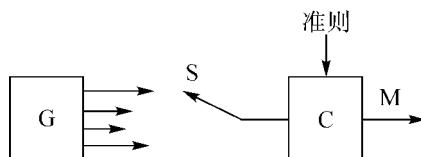


图3-2 自组织算法的通用结构框图

#### 3.4.2.2 单级（排列式）算法

完全归纳的算法也称为排列式算法，可以从给定的完全多项式通过消去相加项得到。由于要逐一挑选局部模型的所有可能方案，它需要很长的计算时间和极大的存储空

间，因此只能在自变量数目相对不大的情况下使用。

对于模型

$$y = a_0 + \sum_{i=1}^m a_i v_i$$

用  $p$  表示自变量数目， $q$  表示回归方程的阶数，我们将得到完全模型的  $C_{p+q}^q$  个项的元素，或者  $m = C_{p+q}^q - 1$ 。完全多项式在两个自变量（它的阶数不高于 2）下包含 6 项，即

$$y = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1^2 + a_4 x_2^2 + a_5 x_1 x_2$$

如果在所有的局部模型中保留了自由项  $a_0$ ，则有  $C_5^1 + C_5^2 + \dots + C_5^5 = 2^5 = 32$  个多项式等待被逐一挑选；完全多项式在 3 个自变量下（3 阶）包含 20 个相加项，将有  $2^{19}$  个多项式需要被逐一挑选；完全多项式在 4 个自变量下（4 阶）包含 70 个相加项，有  $2^{69}$  个局部多项式将被逐一挑选。可能方案的数目随着自变量数目  $p$  和完全多项式的阶数  $n$  的增大而快速地增加，即随着项数的增多而增大。而方案可能数目的上限实际上可以认为是  $2^{20}$ ，即完全多项式包含不超过 20 个相加项，这个极限值取决于使用的计算机和编程者的技巧。

(1) 含因子阶优化的相乘—相加非线性两层次 MGYA 算法。

以上所描述的 MGYA 算法按照局部描写的基函数形式可以划分为几种基本类型，这些类型可以使用取单位、整数或者非整数阶的因子的相加或相乘操作来建立。最著名的是下列类型的算法：

①具有单位阶的因子相加（多项式的）的局部描写的算法，用于挑选下列结构的模型：

$$y = \sum_{j \in J} a_j x_j, \quad J \in \{1, 2, \dots, m\}$$

②具有单位阶的因子相乘的局部描写的算法，用于寻找下列结构的模型：

$$y = \prod_{j=1}^m a_j x_j = a \cdot \prod_{j=1}^m x_j$$

③针对下列结构的综合的相乘—相加算法：

$$y = \left\{ \sum_{k=1}^c a_k \prod_{j \in J_k} x_j \right\}$$

式中， $c$  是复杂度指标。

为了得到名称相同但因子阶为整数或非整数的算法，只需将单位阶因子  $x_j$  用某个数  $p$  替代，即

$$y = \left\{ \sum_{k=1}^c a_k \prod_{j=1}^m x_j^{p_{k_j}} \right\}, \quad p_{k_j} \in \{0, \Delta h\}$$

式中， $\Delta h$  是最小的分数阶，在该算法中先验性地指出了原始因子的某个最小分数阶（如  $p = \frac{1}{2}$ ,  $p = \frac{1}{3}$ , 等等）。最优复杂度模型在这种情况下可表示为带有不高于给定阶的线性项和相乘项的和的形式。

下面描述的算法可以找到包含任意的（一般情况下为非整数的）正（负）阶数的相

乘项的模型。

### (2) 算法描述。

将最初的模型表示为给定的未知阶数的因子（自变量）相乘的形式：

$$y = a_0 x_1^{k_1} x_2^{k_2} \cdots x_m^{k_m} = a_0 \prod_{j=1}^m x_j^{k_j}$$

将表达式取对数，得到

$$\ln y = \ln a_0 + k_1 \ln x_1 + k_2 \ln x_2 + \cdots + k_m \ln x_m$$

根据变量  $y, x_1, x_2, \dots, x_m$  测量数据的样本，组成指定因子的对数值样本。然后使用一种已知的带单位阶数因子的线性局部描写的多项式 МГУА 算法，找到最优复杂度的对数模型。取其指数，得到所求的给定过程的最优（某个外部准则最小意义下）相乘模型。

为了得到综合的相乘—相加模型，通常需要根据 МГУА 算法选择在算法第二阶段作为回归因子使用的最优模型的某个数目  $F$ ，这里第二次地使用一种包含各项及其它们两两乘积的局部描写的 МГУА 算法。

### (3) 试验规划下的算法。

以上研究了对建模对象被动观测下获得的自回归模型的情况。对很多其他的对象，为了获得大量回归模型，可设立专门的试验。数据采样的方案决定哪些因子及其间方差在试验过程中保持为定常水平： $x_1 = \text{const}$ ,  $x_2 = \text{const}$ ,  $\dots$ ,  $x_n = \text{const}$ ;  $x_1 x_2 = \text{const}$ ,  $x_2 x_3 = \text{const}$ ,  $\dots$ ,  $x_{n-1} x_n = \text{const}$ 。对试验的每种布局得到带非整数阶自变量的相乘模型，对象的总模型由试验中获得的所有局部模型结果的相加来综合。这样就得到对下一步使用单级（排列式）МГУА 来说是初始的完全多项式。对试验的规划可以提高建模的精度和抗干扰能力。

#### 3.4.2.3 多级 МГУА 算法

根据模型自组织的原则，在第一级形成成对地考虑自变量的局部模型：

$$y_k^1 = \varphi(u_i, u_j), \quad i = 1, 2, 3, \dots, m; j = 1, 2, 3, \dots, m; i \neq j$$

式中， $\varphi(\cdot)$  是确定的基函数，最常用的是多项式。对第  $k$  级，在前一级中所选出的  $r$  个模型重新成对地组合，即

$$y_s^k = \varphi(y_i^{k-1}, y_j^{k-1}), \quad i = 1, 2, 3, \dots, r; j = 1, 2, 3, \dots, r; i \neq r$$

在大多数程序中选择  $m_1 = m_2 = \dots = m_k = F$ ，这里  $F$  确定了方案选择的自由度。

根据筛选的级数来研究对选择自由度值的最优选择  $F = f(k)$ 。这里  $k$  对应于第  $k$  级，它与感知器最优结构的确定相类似。这时 МГУА 算法与感知器算法的区别在于：①按照最小二乘法用训练序列对局部模型的系数的计算（代替按照随机逼近算法的自适应）；②阈值的最优选择；③根据合理选出的启发式准则（代替标量积形式的准则）对模型的挑选。

各种各样的多级 МГУА 算法根据使用的基函数种类的不同而有所区别。经常使用的是代数多项式和微分方程的差分近似形，也应用调和函数和贝叶斯公式（МГУА 的概率算法）。在 МГУА 的多级算法中，模型复杂度随着级数而增长，且由于阈值的选

择，丧失了一定数目的局部模型，而筛选出  $m$  个最好的模型，这里  $m$  是冈博提出的选择自由度。在最优（根据计算量）的情况下，局部模型是线性的，包含 2 个自变量，即在每一级实现了选择出的  $m$  个自变量的完全成对组合，这时每一级中局部模型的数目等于  $C_m^2$ 。

在构成算法时，一般情况下要决定训练序列 A 和检查序列 B 中插值点的数目  $n$  ( $n = N_A + N_B$ )、每一级中所使用的自变量数目、局部模型的形式和系数的数量  $L$ 。通常应用下列形式的局部描写：

- ①线性的： $y = a_0 + a_1x_i + a_2x_j$ ；
- ②双线性的： $y = a_1x_i + a_2x_jx_i$ ，当  $x_1 = 1$ ；
- ③平方的： $y = a_0 + a_1x_i + a_2x_j + a_3x_ix_j + a_4x_i^2 + a_5x_j^2$ 。

(1) 带有矩阵计算的多级 МГУА 算法。

为了减轻对大量模型方案逐一挑选而造成的繁重的计算量，在解代数方程时可以使用基于信息矩阵特征值的方法。在这种情况下代替自组织算法所必需的多次列解正态方程组，只要求计算一次特征向量矩阵。下面的方法给出了形成非线性代数模型的有效性。在第  $i$  级得到下列方程形式的第  $j$  个模型：

$$y_{ij} = a_{ij} + b_{ij}u_jy_{i,j-1} + c_{ij}y_{i-1,j}$$

式中， $i = 1, 2, \dots, m$ ； $j = 1, 2, \dots, m$ 。这时有可能通过  $m$  级对  $m$  个变量建立起  $m$  阶的多项式：

$$y_{mm} = \sum_{k_1=0}^m \sum_{k_2=0}^{m-k_1} \sum_{k_3=0}^{m-k_1-k_2} \cdots \sum_{k_m=0}^{m-\sum_{i=1}^{m-1} k_i} a_j \prod_{i=1}^{m-k_i} u_i$$

式中， $j = 0, 1, \dots, C_{2m-1}^m$ 。

以下作为例子给出由输出变量得到的局部模型，为减少计算时间，在每一级中仅选择 3 个最好的模型。

筛选的第 1 级： $y_{11} = a_{11} + b_{11}v_1 = f_{11}(v_1)$ ；

$$y_{12} = a_{12} + b_{12}y_{11}v_1 = f_{12}(v_1, v_1^2);$$

$$y_{13} = a_{13} + b_{13}y_{12}v_1 = f_{13}(v_1, v_1^3);$$

筛选的第 2 级： $y_{21} = a_{21} + b_{21}v_2 + c_{21}y_{11} = f_{21}(v_1, v_2)$ ；

$$y_{22} = a_{22} + b_{22}y_{21} + c_{22}y_{12} = f_{22}(v_1, v_2, v_1^2, v_2^2, v_1v_2);$$

$$y_{23} = a_{23} + b_{23}y_{22}v_2 + c_{23}y_{13}$$

$$= f_{23}(v_1, v_2, v_1v_2, v_1^2, v_2^2, v_1^3, v_2^3, v_1v_2^2, v_1^2v_2);$$

筛选的第 3 级： $y_{31} = a_{31} + b_{31}v_3 + c_{31}y_{21} = f_{31}(v_1, v_2, v_3)$ ；

$$y_{32} = a_{32} + b_{32}y_{31}v_3 + c_{32}y_{22}$$

$$= f_{32}(v_1, v_2, v_3, v_1v_3, v_2v_3, v_1v_2, v_1^2, v_2^2, v_3^2);$$

$$y_{33} = a_{33} + b_{33}y_{32}v_3 + c_{33}y_{23}$$

$$= f_{33}(v_1, v_2, v_3, v_1v_3, v_2v_3, v_1v_2, v_1v_2v_3, v_1^2v_2^2v_3^2, v_1^3, v_2^3,$$

$$v_3^3, v_1v_2^2, v_1^2v_2, v_1^2v_3, v_2^2v_3, v_2v_3^2, v_1v_3^2).$$

应该注意到顺序分离出趋势项的算法，它的使用效果较好，特别是在样本量很小的

情况下可得到下列形式的模型：

$$y^M = f_1 + \Delta_1 + \sum_{i=2}^R (\Delta_i^1 + \Delta_i^2)$$

式中，

$$\begin{aligned}\Delta_1 &= y - f_1 \\ \Delta_i^1 &= y - (f_1 + \sum_{j=1}^{i-1} (\Delta_j^1 + \Delta_j^2)) \\ \Delta_i^2 &= y - (f_1 + \sum_{j=1}^{i-1} (\Delta_j^1 + \Delta_j^2) + \Delta_i^1) \\ f_1 &= \sum_{k=0}^L a_k u_r^k, \quad \Delta = \sum_{k=0}^L b_k u_r^k\end{aligned}$$

$y^M$  是最优复杂度的幂多项式， $1 \leq r \leq m$ ， $1 \leq L \leq s$ ， $s$  为最大的阶， $R$  为最大的级数。相应地，最终的回归方程也改变了。

(2) 带有随机选择变量对的多级算法。

常常不得不放弃对变量对的完全数目的考虑，而根据大量筛选的方法使用变量对的随机选择，在一般情况下成对地实现基础模型的  $K$  个随机组合。代替算法为

$$m \rightarrow C_m^2 \rightarrow m \rightarrow C_m^2 \rightarrow \cdots \rightarrow 1$$

在随机组合时得到的算法为

$$m \rightarrow k \rightarrow m \rightarrow K \rightarrow \cdots \rightarrow 1$$

式中， $K \ll C_m^2$ 。

(3) 带残差计算的多级算法。

在第 1 级中选择出数量为  $F_1$ ，形式为  $f_{1j} = \sum_{k=0}^L a_k x_j^k$ ，对  $1 \leq j \leq m_0$  和  $0 \leq L \leq s$  的包含  $m_0$  个实质性自变量的局部描写。根据对单独数据检查样本的均方误差，对第 1 级局部描写（模型）进行估计和按大小进行排列。对最好（根据准则值）的一些模型可以根据全部观测值计算初始的偏差  $\Delta_{1i} = y - f_{1i}$ ，对它们又可以确定出  $m_0$  个实质性的自变量  $x_j$ ，当  $i = j$  时，可得到对应的最优复杂度模型为

$$\Delta_{1i}^M = \sum_{k=0}^L b_k x_j^k$$

式中， $1 \leq j \leq m_0$ ， $0 \leq L \leq s$ 。又根据对检查样本的均方误差将它们按大小排列，检查样本的均方偏差的最小值对应于第 1 级的最优模型，即

$$y^M = \sum_{k=0}^{L_1} a_k x_j^k + \sum_{k=0}^{L_2} b_k x_r^k$$

式中， $0 \leq L_1 \leq s$ ， $0 \leq L_2 \leq s$ ， $i \neq r$ 。

如果对检查样本的逼近能获得改善，在随后各级中对类似得到的偏差  $\Delta = y - y^M$  存在实质性的自变量，并且趋势项的分离要一直进行。

残差计算的算法具有这样的优点：借助于它可以直接知道引入新的变量是否对在已给出的变量集合下得到的预测有所改善。同具有最小值的通常的 MFTA 算法（不带残

差计算)相区别,在带残差计算的算法中,准则的精度随着筛选的每一级而减小。因此,带残差计算的算法导致更主观的结果,因为不得不根据左角规则选择最优复杂度模型。已经确定,所有类型的多级 МГУА 算法可以要么考虑在每级筛选后分离出残差,要么不分离残差。

#### (4) 带变量清单传递的多级算法中自由阶数的考虑。

在局部模型具有固定的结构和  $n_A > k_0$  的情况下,在每一级中有可能估计模型的系数。这里  $k_0$  为局部模型参数的数目(如线性模型  $k_0 = 3$ )。在这种情况下,在最小二乘法的意义下,系数不是最优的,这可能降低筛选过程的有效性。因此,最大可能的级数  $m$  建议这样来选择,以使训练序列点的数目  $n_A > k_m$ ,这里  $k_m$  为在第  $m$  级获得完全模型所必需的自由度的数目。局部模型包含  $k_0$  个参数,它们根据对训练序列的最小二乘法通过解由  $k_0$  个正态高斯方程构成的方程组得到。这时在每一级中使用了  $k_0$  个自由度,由于进入局部模型的所有自变量是前面各级的计算结果,因此对第  $m$  级模型得到

$$\text{的自由度为 } k_m = k_0 \sum_{i=0}^m 2^i.$$

#### 3.4.2.4 带残差平稳性检查的趋势项的顺序分离

非平稳的建模过程通常可表示为多项式或调和分量与某个随机残差(偏差)和的形式,而确定性分量又可以是两个或大量的趋势项的和。分离趋势项的运算可这样描述:

$$\Delta z(t) = \nabla_1 z(t)$$

或

$$\Delta z(t) = \nabla_1 \nabla_3 z(t)$$

式中,  $\nabla_1$  为分离一个差值的符号(算子),  $\nabla_1 \nabla_3$  为分离两个趋势项(如过程的第 1、第 3 个调和量)的算子。如果残差  $\Delta z(t)$  满足平稳性条件,即残差的平均值是定常的( $\overline{\Delta z(t)} = \text{const}$ ),残差的方差也是定常值( $D_{\Delta z} = \text{const}$ ),那么 МГУА 的算法应该只用于预测残差,过程的总预测将等于趋势项和残差预测之和。

保证筛选指标达到最小值的趋势项(趋势项之和)称为最优复杂度趋势项。

##### (1) 残差非平稳性准则。

过程可表示为幂形式的趋势项与平稳残差之和的形式。趋势项的幂应该这样选择,即使得残差尽可能完全地满足平稳性准则。自回归差分方程的解最准确地符合平稳随机过程。有时得以成功地分离幂形式的或调和的趋势项并同时使残差符合平稳过程,在另外的情况下,要求从一次残差中再分离一个趋势项。

假设根据原始数据所建立的过程曲线含有明显的周期分量(如周期具有  $T = 24$  个时间单位),那么适宜于分离出具有该周期的调和趋势项。将这记为下列形式:

$$\Delta z(t) = \nabla_T z(t)$$

式中,  $\nabla_T z(t) = z(t+T) - z(t)$ , 为滤波多项式。

分离出仅仅一个周期为  $T$  的趋势项就够了吗? 对这一问题的回答由对非平稳性准则的计算给出。随机过程平稳性的程度可以根据非平稳性准则的值来评价,它建立在数学统计中已知的过程相关函数坐标  $\Delta z(t)$  和  $z(t)$  的关系上。在平稳性情况下,对自变量的所有值都有下列关系:

$$R_{\Delta z}(h) = \frac{2R_z(h) - R_z(h-1) - R_z(h+1)}{2[1 - R_z(1)]}$$

式中,  $R_{\Delta z}(h)$ ,  $R_z(h)$  是对应于  $\Delta z(t)$  和  $z(t)$  的过程相关函数。使用这个关系, 建立非平稳性准则, 形式为

$$s = \sum_h (D(h))^2 \rightarrow \min$$

$$\text{式中, } D(h) = R_{\Delta z}(h) - \frac{2R_z(h) - R_z(h-1) - R_z(h+1)}{2[1 - R_z(1)]}.$$

准则用于评价残差的非平稳性。如果条件  $s > s_0$  ( $s_0$  根据经验选择, 其数量级为 0.05) 在任何趋势项下都不满足, 那么关于平稳性的假设应该是被否定的。实际中趋势项函数可以借助于匹配来选择, 并且在最开始由初始滤波多项式的形式经验性地给出。为此, 研究过程的及其他们的某个平均值的曲线图像常常就足以做出趋势项函数的选择。将趋势项函数的复杂度 (或者分离出的趋势项的数目) 逐渐提高, 直到残差的平稳性准则变得足够小。这样 MGYA 算法可用于对补充到已知的趋势项上 (或者是趋势项之和) 的残差建模。

①非平稳性准则计算。过程表示为下列形式的趋势项和残差和的形式:

$$q(t) = X(t) + x(t)$$

对每个残差  $x(t)$  和它的一次偏差  $\Delta x(t)$ , 有下列表达:

$$\begin{aligned} \text{cov}_x(h) &= \frac{1}{N} \sum_{t=1}^N [x(t) - \bar{x}][x(t+h) - \bar{x}] \\ \text{cov}_{\Delta x}(h) &= \frac{1}{N} \sum_{t=1}^N [\Delta x(t) - \Delta \bar{x}][\Delta x(t+h) - \Delta \bar{x}] \end{aligned}$$

在过程平稳性条件下, 从最后一个等式得到

$$\text{cov}_{\Delta x}(h) = \gamma [2\text{cov}_x(h) - \text{cov}_x(h+1) - \text{cov}_x(h-1)]$$

偏差和非平稳度准则相应地记为

$$\Delta h = \text{cov}_{\Delta x}(h) - \gamma [2\text{cov}_x(h) - \text{cov}_x(h+1) - \text{cov}_x(h-1)]$$

$$\rho_s = \sqrt{\frac{1}{N-1} \sum_{h=1}^{N-1} \Delta_h^2} \rightarrow \min$$

②顺序分离趋势项的算法。其与残差方法的区别在于: 为了分离出每个趋势项, 使用了多级 MGYA 算法; 在每一级选择最有效的自变量和趋势项的最优复杂度 (多项式阶数); 如果完全解的正规性还在上升, 趋势项的分离就一直进行。在分离出趋势项数目过大的情况下, 用检查样本  $B$  所得到的精度 (正规性准则), 从某个确定的值开始下降 (这里将单个变量的回归函数  $f_i(v_i)$  称为趋势项)。借助于趋势项, 即可得到下列求和形式的相加模型:

$$y = a_0 + \sum_{i=1}^m f_i(v_i)$$

也可得到相乘形式的模型:

$$y = a_0 \prod_{i=1}^m f_i(v_i)$$

根据顺序分离趋势项的算法，针对相加形式的模型，在筛选的第一级对所有的自变量  $x_i$  找到趋势项，并从中选择  $F$  个最好的，用训练样本  $A$  估计系数，而趋势项的品质（按正规性指标）用数据的检查样本来确定。对所有挑选出来的趋势项找到残差  $z_j = y - y_j$ 。在筛选的第二级对每个选出的趋势项计算观测实现的偏差，这些偏差又组成趋势项，从中同样需要选出第二级筛选的  $F$  个最优趋势项函数。这个过程一直进行到检查样本  $B$  的偏差达到最小值时。如果剩余的方差还太大，虽然对所有自变量的趋势项已经分离出来了，但这还是意味着该算法不适用于解决该问题，因为自变量彼此间还不够充分正交。

## (2) МГУА 的综合方法。

МГУА 的综合方法考虑了对几个趋势项的所有可能的和与乘积的逐一挑选。最优复杂度（结构）模型要么可以借助所有方案的全组合（在自变量少的情况下），要么借助多级筛选过程来得到。在对方案完全挑选的情况下，基函数越好地符合所求的依赖关系，筛选准则的输出值就越小。但是对最基本的基函数所有可能组合的扩大的全选择，实际上只可能在自变量数目相对较小的情况下实现，因此在第一步使用已知的趋势项分离算法。假设在使用顺序分离趋势项的 МГУА 算法下得到 4 个趋势项和时间函数：

$$y = f(t) + f_1(u_1) + f_2(u_2) + f_3(u_3) + f_4(u_4)$$

则综合的 МГУА 算法应考虑实现下列函数（完全多项式）的 12 种组合的挑选：

$$\begin{aligned} y &= f(t) + f_1(u_1) + f_2(u_2) + f_3(u_3) + f_4(u_4) \\ y &= f(t) + f_1(u_1) + f_5(u_2, u_3, u_4) \\ y &= f(t) + f_2(u_2) + f_6(u_1, u_3, u_4) \\ y &= f(t) + f_3(u_3) + f_7(u_1, u_2, u_4) \\ y &= f(t) + f_4(u_4) + f_8(u_1, u_2, u_3) \\ y &= f(t) + f_1(u_1) + f_2(u_2) + f_9(u_3, u_4) \\ y &= f(t) + f_1(u_1) + f_3(u_3) + f_{10}(u_2, u_4) \\ y &= f(t) + f_1(u_1) + f_4(u_4) + f_{11}(u_2, u_3) \\ y &= f(t) + f_2(u_2) + f_3(u_3) + f_{12}(u_1, u_4) \\ y &= f(t) + f_2(u_2) + f_4(u_4) + f_{13}(u_1, u_3) \\ y &= f(t) + f_3(u_3) + f_4(u_4) + f_{14}(u_1, u_2) \\ y &= f(t) + f_{15}(u_1, u_2, u_3, u_4) \end{aligned}$$

当已知进入其中的自变量是有相互作用的时候，需要考虑完全多项式的多因子分量，这一先验信息削减了挑选的数量，并提高了抗干扰性能。上述第一个多项式对应于变量  $u_1 \sim u_4$  互不作用的情况。

МГУА 的综合算法可以实现将过程最优地划分为相加和相乘的组分。预测随机过程的实际例子表明，应该将这些过程的低频组分考虑成某些自变量的函数，而高频成分看做是其他量的函数。在这种情况下，确定低频组分的自变量的数目非常小，而决定高频组分的自变量的数目通常很大。

如果趋势项函数是指数或三角函数，在拥有关于动态模型特征方程根类型的先验信

息条件下，可以做到实质性地提高抗干扰性（降低对干扰的敏感性）。例如，如果已知根的实部为零，就应该用 MGYA 的谐波算法，该算法的特点是抗干扰性强。考虑了因素间相互作用的先验信息的综合算法也具有增强抗干扰性的作用。

### (3) 局部和完全描写的正交化方法。

在多级 MGYA 算法中，经几级筛选之后形成了在第  $k$  级所使用的向量  $y_j^{k-1}$  的线性依赖关系，这时信息矩阵变得越来越不确定（奇的）。为了避免共轴性，在每一级中作为对借助于筛选挑选出的  $y_j^{k-1}$  元素的补充，可以考虑在第一级中所使用过的自变量，那么对三个扩充的自变量  $v_1, v_2, v_3$ ，得到第 1 级：

$$y_1^1 = f(v_1, v_2), \quad y_2^1 = f(v_1, v_3), \quad y_3^1 = f(v_2, v_3)$$

第 2 级：

$$y_1^2 = f(y_1^1, y_2^1), \quad y_2^2 = f(y_1^1, y_3^1), \quad y_3^2 = f(y_2^1, y_3^1)$$

$$y_4^2 = f(y_1^1, v_1), \quad y_5^2 = f(y_1^1, v_2), \quad y_6^2 = f(y_1^1, v_3)$$

$$y_{13}^2 = f(v_1, v_2), \quad y_{14}^2 = f(v_1, v_3), \quad y_{15}^2 = f(v_2, v_3)$$

排除共轴性的另一个可能性在于使用线性模型的正交化元素来代替通常的局部模型，即

$$y_i^k = a_0 + a_1 y_{j_1}^{k-1} + a_2 y_{j_2}^{k-1}$$

由此得到

$$y_i^k = y_{j_1}^{k-1} + a_2 \hat{y}_{j_2}$$

正交化

$$\sum_{t=1}^{n_A} y_{j_{1t}}^{k-1} \hat{y}_{j_{2t}} = 0$$

可以借助线性变换得到，这时

$$\begin{aligned} \hat{y}_{j_2} &= y_{j_2}^{k-1} - A y_{j_1}^{k-1} \\ A &= \sum_{t=1}^{n_A} y_{j_{1t}}^{k-1} y_{j_{2t}}^{k-1} / \sum_{t=1}^{n_A} (y_{j_{1t}}^{k-1})^2 \end{aligned}$$

在 MGYA 算法中区分了使用正交化思想的两种形式，其区别在于发生矢量正交投影的空间中的检测数目不同。这里所叙述的方法对应于多级算法中局部模型的正交化，算法也可以用于综合局部模型结果所获得的完全模型的正交化。对上述两种正交化算法还未进行过有效性的比较。

### 3.4.3 基函数形式和方程类型的选择

#### 3.4.3.1 数学描写的形式

为了将对象建模，需要有对应于它的描写语言。缺少数学描写的、关于科学工作的文章、书籍、报告等通常可能是用文字性的描写或者是用口头模型。而数学建模的目的是要以更简短的数学的形式来描写研究对象的个别特性。数学语言同文字描写相比更准确，但它的优点同时也是它使用过程中的缺点——在不太详尽、不太准确的语言中所包

含的模糊性信息在公式中难以表达出来。到目前为止，在复杂的情况下，像文字描述这种看起来不太可靠、不太准确的手段比公式更准确、更丰富。

在数学模型中，可以使用各种类型的方程和不同形式的基函数。常微分方程用于描写集总参数模型，对于这种模型，所有的数据都是在空间中一个点测量的。带偏导数的微分方程在空间模型中获得应用，如用于描述物理场，这时在观测表中包含空间许多点的测量。差分方程是带连续导数的微分方程的离散相似形。积分—微分方程可以包含所谓的断续解，它们可以应用在表示对象品质的急剧改变中。如果过程包含突然的变化，那么建模对象最好借助于积分—微分方程来描述。因此，在建模中使用差分方程时，建议向计算机提供观测的和（积分的离散相似形）。

根据对一系列变量求平均的间隔大小来对基函数进行划分显得特别重要。在以上所列举的所有基函数中使用了不同的对变量求时间平均的方式。例如，微分方程是针对变量的瞬时值列出的，而在一天、一月、一季度内求出的平均值或者是一年的平均值列入差分方程。求平均的间隔越长，建模的语言就变得越模糊，就其性质而言，越接近文字描述。

在谈到描写的各种各样的形式时，不能不提到概率—理论模型，如统计解的多级理论中用于计算单位风险的模型。在 МГУА 的多级概率算法中，使用了与贝叶斯和单位风险公式相类似的逐步复杂化表达。这样，МГУА 的算法可以用各种基函数来实现。

### 3.4.3.2 完全和局部描写的选择

显然，模型自组织的成功与否在很大程度上取决于基函数类型的选择。如果是这样一些基函数，使得对象的结构不能借助于局部模型的组合得以重建，那么即使逼近的任务总是可解，但这时所得到的结果常常只适用于预测。这种情况下得到的模型不适合进行对象辨识，因为它不是对象的物理模型。如果基函数的类型选择得充分广泛，那么对描写所选择的任务是可以解决的。在进行数学模型自组织时，原则上可以将基函数、完全和局部模型基本结构的选择交给计算机。在一般情况下，由已有的先验信息的分析可知，可以使用几种有限类型的基函数和在它们基础上所获得的模型结构。在自组织过程中，计算机通过对方案的逐一挑选而选择基函数的最优形式和方程的类型。

通常依据过程的图解表示可以对基函数给出正确选择。例如，对均值恒等于零的平稳振动，可以建议采用三角函数（如图 3-3（a）所示）；对图 3-3（b）表示的过程，首先需要去掉多项式趋势项，而残差用三角函数表示；对图 3-3（c）中的单调过程建议用多项式趋势项描写。

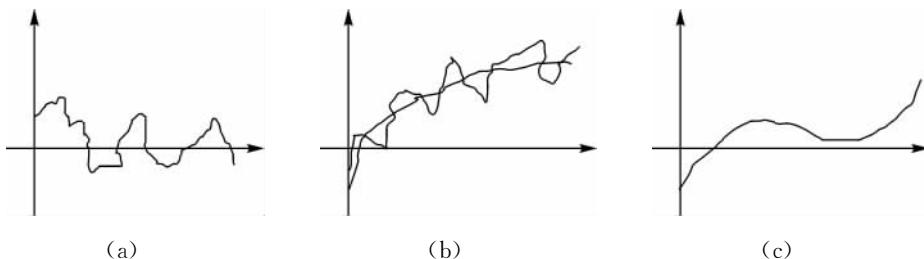


图 3-3 对基函数形式选择的图示

三角函数、幂多项式等可以作为相应的微分或差分方程的解而得到，因此，建模时也可以使用微分方程或它们的有限差分相似形。

### 3.4.3.3 MГУА 中的基函数

#### (1) 趋势项函数。

动态对象的数学描述可以要么表示为它的微分方程（或积分—微分方程），要么表示为这个方程的解。解的低频（平滑后）部分称为趋势项函数，它是下列形式动态方程的解：

$$y(t) = h(\mathbf{u}, s, t)$$

或者在相应的假设下，有

$$y(t) = f(t, \mathbf{c}) + s(t)$$

式中， $s(t)$  表示叠加的干扰；趋势项函数  $f(t, \mathbf{c})$  可以用某个基函数组来逼近，且

$$f(t, \mathbf{c}) = \sum_{i=0}^n c_i \varphi_i(t), \text{ 这里 } \varphi_i(t) \text{ 是基函数。}$$

在自组织时，包括分离基函数的算法中，下列形式的基函数得到了应用：

①幂多项式  $\varphi_i(t) = t^i$ ，用于建立模型  $y(t) = \sum_{i=0}^n c_i t^i$ 。

②三角函数

$$\varphi_{2i}(t) = \cos \omega_i t, \quad i = 0, 1, 2, \dots, m$$

$$\varphi_{2i-1}(t) = \sin \omega_i t$$

$$\text{用于形成模型 } y(t) = \sum_{i=0}^m c_i \cos \omega_i t + \sum_{i=0}^m d_i \sin \omega_i t.$$

③指数函数  $\varphi_i(t) = e^{\beta_i t}$ ，用于形成模型  $y(t) = \sum_{i=0}^m e^{\beta_i t}$ 。

如果在基函数组中同时包含几种类型，那么就得到包含幂多项式和指数函数的和或乘积形式的混合函数。非线性的相加项可以通过新的扩充变量  $v_i = \varphi_i(t)$  来重新表示，这时就得到线性回归方程，其结构和系数的估计容易由 MГУА 算法得到。

在经济学问题建模中，特别对于描述所谓的反映可相互替换的生产因素间联系的生产函数，适宜于采用带扩充的和规范化的自变量的表达：

$$v_i = \bar{u}_{i,t-j}$$

和

$$v_k = \bar{u}_{k,t-p}$$

如果采用上述的自变量构成基函数，那么借助于自组织，可以形成下列通用模型：

$$y(t) = e^{Bh(t)} \prod_{i \in J} u_i^{B_i h(t)/[h_i(t)]} (t - k_i)$$

式中， $h(t), h_i(t)$  是在相应的规范化下描述因素  $y(t), u_i(t - k_i)$  的趋势项函数的多项式； $J = \{(j_i, k_i)\}$  是  $(j_i, k_i)$  对的集合，它指明了在  $u_{j_i, t-k_i}$  ( $1 \leq j_i \leq m$ ,  $0 \leq k_i \leq K$ ) 中重要的因素。

在某些情况下产生了对非线性关系（如分数有理函数形式）建模的必要性。这种关系对两个作用量可以有以下的形式：

$$y = \frac{a_0 + a_1 u_1 + a_2 u_2 + a_3 u_1 u_2}{1 + b_1 u_1 + b_2 u_2 + b_3 u_1 u_2}$$

因为模型自组织可以使用分数多项式的基函数，对分数有理函数的系数的估计可以借助于迭代的程序得到。

(2) 借助于差分方程描写残差。

动态对象的一般模型是状态方程，它们可以用下列形式的差分方程给出：

$$\mathbf{x}_{t+1} = \mathbf{F}(\mathbf{x}_t, \mathbf{u}_t, t)$$

这时认为，其中一个状态变量对应于输出量。

方便用于单步预测的状态方程自组织的条件是状态向量的所有  $m$  个分量可以观测，相应地得到第  $m+1$  个方程：

$$\mathbf{x}_{t+1} = \mathbf{g}(\mathbf{v}_t)$$

式中， $\mathbf{v}_t = (\mathbf{x}_t, \mathbf{u}_t, t)$ 。

一般情况下，状态向量的某些分量要么是过渡性的（辅助的），要么是不可观测的。排除这样的变量，对可观测的分量得到如下方程：

$$\hat{\mathbf{x}}_{t+1} = \mathbf{f}(\hat{\mathbf{x}}_t, \hat{\mathbf{x}}_{t-1}, \dots, \hat{\mathbf{x}}_{t-k}, \mathbf{u}_t, \mathbf{u}_{t-1}, \dots, \mathbf{u}_{t-k}, t)$$

它们可能是最高阶数的微分方程。排除局部模型组中过渡性变量的结果得到通用的展开的模型，它包含了比样本中给定点数目更多的相加项。这时计算机留下重要的自变量，并借助筛选减少计划采用的系统分量的数目。

(3) 借助沃特拉级数描写对象。

对于充分广泛的一类动态对象，输入和输出变量间的关系（输入、输出矩阵）可以用沃特拉级数形式表示如下：

$$\begin{aligned} y^M(t) = k_0(t) &+ \int_{-\infty}^{+\infty} k_1(t, s) u(s) ds + \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} k_2(t, s_1, s_2) u(s_1) u(s_2) ds_1 ds_2 + \\ &\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} k_3(t, s_1, s_2, s_3) u(s_1) u(s_2) u(s_3) ds_1 ds_2 ds_3 + \dots \end{aligned}$$

这里  $k_1(t, s)$  确定了线性部分的权函数，而级数的后面各项是系统的非线性部分。如果转入系统的离散描述，并考虑到滞后变量的使用，那么我们就得到被称为高莫戈罗夫-冈博多项式的综合幂多项式：

$$y_t^M = k_0(t) + \sum_{s=0}^g a_s u(t-s) + \sum_{s_1} \sum_{s_2} a_{s_1} a_{s_2} u(t-s_1) u(t-s_2) + \dots$$

式中， $k_0(t)$  可以通过趋势项的相应函数表示， $g$  给出了滞后变量的数量（系统的记忆）。其中，对几个输入量的情况  $u_j(t), u_j(t-1), \dots, u_j(t-g_j)$ ，引入新的表示形式的因子  $v_i(t)$ ，那么就产生了完全多项式辨识任务：

$$y_t^M = \sum_{j=0}^M b_j v_{jt} + \sum_{j=1}^M \sum_{i \leq j} b_{ij} v_{it} v_{jt} + \dots = f_q(v_{1t}, v_{2t}, \dots, v_{Mt})$$

式中， $v_{0t} = k_0(t)$ ， $M = \sum_{j=1}^{m+1} g_j + m$ ， $g$  为最高的阶数。

如果完全多项式包含不多于 20 个相加项，那么为确定最优结构和估计系数使用 MGYA 的排列式算法；如果相加项更多，则使用 MGYA 的多级算法，其中完全多项式

由项数不多的局部描写来逼近。例如，局部多项式可能是这样的形式：

线性模型

$$f_1(u_{i,t-j}, u_{k,t-p}) = c_0 + c_1 u_{i,t-j} + c_2 u_{k,t-p} \quad (3-2)$$

非线性模型

$$f_2(u_{i,t-j}, u_{k,t-p}) = f_1(u_{i,t-j}, u_{k,t-p}) + c_3 u_{i,t-j}^2 + c_4 u_{k,t-p}^2 + c_5 u_{i,t-j} u_{k,t-p} \quad (3-3)$$

在根据方程 (3-3) 选择函数时，模型的复杂度一级级很快地提高。这时当第 1 级中出现了平方的描述，第 2 级中就已经包含了 4 阶项，而第 3 级中的局部模型是 8 阶多项式，第  $k$  级的最高阶就是  $2^k$ 。为了在挑选中不错过中间复杂度的多项式，使用了线性和双线性的模型（后者中仅加入了线性项和两变量的乘积），也使用带扩充自变量  $v_i, v_j$  的线性局部模型  $f_1(v_i, v_j)$ ，它们连同初始自变量及其滞后值一同包含了这些量的乘积和幂。

在施加了联系局部模型部分分量的补充严格条件下，长期预测的稳定性将提高。同选择  $c_3 = c_4 = c_5 = 0$  一起可以作为例子的是由伊哈拉 (Ихара Δ) 所提出的关系：在  $u_i, u_j$  下的系数通过关系  $f_j(u_i, u_j) = c_0 + c_1 z + c_2 z^2$  相互联系，其中  $z = Bv_i + (1-B)v_j$ 。

### 3.4.4 筛选的准则

#### 3.4.4.1 根据文字表述选择筛选的准则

从可能模型的集合中选择最优复杂度模型是多值的、非完全的数学问题，因此，在将最优复杂度模型内涵丰富的要求转换为相应的形式化的准则时产生了一定的困难。为了使模型的确定是单值的，需补充地表述对应的选择原则或整修泛函。外部补充的文字表达是最完全的和内涵丰富的（同时也是最含混的），它是获得筛选的形式化数学准则的基础。例如：

“预测应是足够准确的。”从这句话中可直接得到使用正规性准则和单步预测的收敛性准则（对差分方程）的必要性这一信息。如果模型用于试验（将来场景的演示），对预测精度的要求可以降低。

“昨天、今天和明天的模型应是同样的。”从这里得出偏移（矛盾性）最小的要求。

“变量间的依赖关系应一样——明天和今天一样。”在这种情况下，需要将变量平衡作为筛选指标使用。

用这样的方法来确定模型的最优复杂度时，专家们比较容易达成一致，即便是在对对象的规律性持不同观点的情况下。

“准则的文字表达”对模型筛选的结果就像一种综合（和解）的作用。在进行复杂过程的规划和控制时，如果使用不同程度细节化的作用语言，可以对对象产生作用，这些作用语言包括：指出详细的定量的数据（这时出现了可实现性上的困难），或者只给出通常的前提——达到所要求性能或结果的条件。在最后一种情况下，在规划和控制中使用了综合性的（一般和特定的）作用的形式。

形如“找到最准确的预测”，“最不矛盾的方程”等的准则，没有具体指明所要求的模型，而只是指出相对其他竞争模型的某些一般性能。模型自组织时，在计算机和人之间以“准则语言”进行对话，即以比具体指示的语言具有更高通用性的语言。对于词语给出的任何准则，可以设想出各种不同的数学解释，遗憾的是，它们不具有文字准则那样的模糊度和通用性。因此，为了准确反映文字准则的含义，在选择最优复杂度模型时常常需要同时使用多个公式，并使之包含文字准则中的矛盾性要求。

#### 3.4.4.2 模型选择的锐度问题

需要大量不同的最优复杂度模型的筛选准则是为了挑选出保证最锐利选择的准则，即对所求模型的准则值应该比在其复杂度轴上的相邻模型的值小得多。此外，准则的多样性对于更完全地表达出对建模结果不同方面的要求也是必需的。在自组织时，模型研制者只有通过选择筛选准则的形式来影响建模结果。所有其他形式的人机对话都要破坏模型自组织的客观特性。

#### 3.4.4.3 正规性准则 $\Delta^2(B)$

以下所表述的准则有一定共同点，即它们都是作为外部补充来使用，是在检查或考查样本基础上确定的，并在很大程度上符合结果可重复性要求。

将样本的实现 $N$ 划分为训练样本实现 $N_A$ ，用它估计模型参数，检查样本 $N_B$ 的实现，用它进行合适模型的选择。正规性准则确定了模型在检查样本上的均方偏差，即

$$\Delta^2(B) = \frac{\sum_{t \in N_B} (y_t^M - y_t)^2}{\sum_{t \in N} y_t^2} \rightarrow \min$$

如果从以下条件出发，即在整体条件不变的前提下，对过去良好的逼近保证了对最近的良好逼近，则特别推荐正规性准则用于短期预测。因为用新的实现所获得的解只给出小的偏差，而这样找到的模型将是正规的，即对原始数据小的改变是不太敏感的。这时在筛选的过程中有可能丢失重要的变量，但是它们的影响将通过其他的变量间接地被考虑到。

正规性准则可以作为相关系数被确定：

$$K_{y^M y} = \frac{\sum_{t \in N_B} y_t y_t^M}{\sqrt{\sum_{t \in N_B} y_t^2 \sum_{t \in N_B} y_t^{M^2}}} \rightarrow \max$$

或者是相关因数：

$$\rho_{y^M y} = \sqrt{1 - \sum_{t \in N_B} (y_t - y_t^M)^2 / \sum_{t \in N_B} (y_t - \bar{y}_t)^2}$$

式中， $\bar{y}_t = 1/n_B \sum_{t \in N_B} y_t$ ， $n_B$  为检查样本中的点数。

相关因数理论上的最小值等于 1，它与具体过程的特殊性的相关程度较小，因此更适合于模型的比较。

正规性准则建议作为辅助性（整修的）准则使用。这时使用的基本准则可以是偏移最小准则和变量平衡准则。在单独使用正规性准则时，使用它的对称形式：

$$\Delta^2(AB) = \sum_{i=1}^{n_B} (\hat{y}_A - y_\Phi)_i^2 + \sum_{i=1}^{n_A} (\hat{y}_B - y_\Phi)_i^2 = \Delta^2(B/C) + \Delta^2(A/B) \rightarrow \min$$

准则的对称形式提高了模型选择的抗干扰性。

#### 3.4.4.4 模型偏移最小（不矛盾性）准则 $n_{CM}^2$

将原始数据样本划分为两个相同的部分  $N_A$  和  $N_B$ ，在它们的基础上分别确定了输出为  $y_t^A$ ,  $y_t^B$ ，参数为  $C_t^A$ ,  $C_t^B$  的模型  $A$  和  $B$ 。偏移最小准则等于模型  $A$  和  $B$  对全样本 ( $t \in N$ ) 的偏差的均方值，即

$$n_{CM}^2 = \frac{\sum_{t \in N} (y_t^A - y_t^B)^2}{\sum_{t \in N} y_t^2} \rightarrow \min$$

准则可以这样理解：根据一定的观测区间或在一定的观测点上估计出的模型，应尽可能接近地与根据另外观测区间或在另外点上的数据得到的模型相吻合。准则本身表达出了非矛盾性要求。在状态空间中对于含两个变量的一种回归关系，意味着回归面  $y_t^A = f_A(u_1, u_2)$  与回归面  $y_t^B = f_B(u_1, u_2)$  充分一致。在自组织算法中使用下列两种偏移最小准则：

$$n_{CM_1}^2 = \frac{1}{n} \sum_{t \in N} (y_t^A - y_t^B)^2 \rightarrow \min$$

$$n_{CM_2}^2 = \frac{2 \sum_{t \in N} y_t^A y_t^B}{\sum_{t \in N} [(y_t^A)^2 + (y_t^B)^2]} \rightarrow \max$$

此外，还提出了基于系数分析的偏移最小准则。但是这些准则只在这样的情况下有意义：系数的数值具有相同的数量级或者借助于相应的标准化可以导致这样的结果。这里所指的表达式如下：

$$n_{CM_3}^2 = \frac{\sum_{i=1}^M (C_i^A - C_i^B)^2}{\sum_{i=1}^M [(C_i^A)^2 + (C_i^B)^2]} \rightarrow \min$$

式中， $M$  给出了用  $N_A$  和  $N_B$  所得到的模型  $C_i^A$  和  $C_i^B$  的参数的总和。可以研究基于系数分析的其他的偏移最小准则，例如：

$$n_{CM_4}^2 = \frac{\sum_{i=1}^M C_i^A C_i^B}{\sum_{i=1}^M (C_i^A + C_i^B)^2} \rightarrow \min$$

这些准则是参数的函数，它们是无量纲的、对称的，并且对小系数的差是不敏感的。

(1) 使用和或差的准则。模型参数估计的可靠性，通常与测量点的数目成正比，因此，将观测样本划分为训练样本和检查样本降低了参数估计的可靠性和准则  $n_{CM}^2$  估计的可靠性。为了克服这一困难，近年来研制出了不要求划分观测表和可以根据所有测量获得模型参数  $C_i$  的准则。将观测值的和或差作为新信息使用，由此得到估计  $C_i^s$ ,  $C_i^d$ 。

(2) 对动态系统的准则。对动态系统，与上面所描述的偏移最小准则一起使用特殊的性能参数，它们给出了带有用  $N_A$  和  $N_B$  所得到的系数的两个差分方程的单步积分结果间的差值，即

$$n_{CM}^2 = \frac{\sum_{k=1}^T [y_A(k, y_0) - y_B(k, y_0)]^2}{\sum_{t \in N} y_t^2}$$

式中， $y_A(k, y_0)$  和  $y_B(k, y_0)$  是模型的单步积分结果，这些模型的估计用  $N_A$  和  $N_B$  得到。在 MTYA 的排列式算法中，在使用这个准则时不会产生任何困难，但对多级算法而言这样的准则非常不方便，只建议将它们使用在最后一级筛选中，用于最优模型的集合中对最优模型的最终选择。

#### 3.4.4.5 用于小样本的准则

在非常短的时间序列下将观测表划分为两部分是不适合的。在这种情况下，建议与积分和微分的准则一起对整个观测表使用偏移最小准则，模型的系数第一次借助最小二乘法计算，而第二次借助正交回归计算。也可使用“取平均值的正规性准则 (YKP)”，它等于正规性指标的平均值，而这些正规性指标是将所有点逐个划分为检查样本的情况计算出来的。从观测数据中选择  $n$  个点，它们按顺序组成检查样本，那么剩下的实现用于模型自组织。对于所有可能的检查样本（等于点的数目），误差的和就是取平均值的正规性准则。对  $n$  个实现 YKP 为

$$\Delta^m(B) = \frac{1}{n} \sum_{i=1}^n \Delta_i(B) \rightarrow \min$$

(1) 偏移最小准则的极值准则。在按某种方式划分原始数据表中的点的情况下，偏移最小准则达到最大值。基于这种划分下的准则，相比其他划分方式下得到的  $n_{CM}^2$ ，是更完全的偏移最小准则。为近似获得  $n_{CM_{max}}^2$ ，算法要求对数据表划分为  $N_A$  和  $N_B$  两部分的所有可能方式作比较。借助于这个算法，可以找到数据表的最优划分和由此得出的最有效的偏移最小准则。

(2) 抗干扰方案。实际上已确认用序列  $N_A$  和  $N_B$  所得到的模型在观测的区间内较好地逼近了原始数据，这时模型特征的差  $n_{CM}^2$  可能不是本质性的。因此，在一定的噪声水平下，可能选出伪模型。为了减小对干扰的敏感性，也就是为了提高模型选择的正确性而不破坏所允许的极值噪声水平，建议在进行准则计算时不只引入插值区间，还要对  $\beta N$  ( $\beta=1.5 \sim 2.5$ ) 区间求和，因为在推区间，模型是强发散的。

(3) 组合偏移最小准则。组合准则如下：

$$n_{CM_{KOM6}}^2 = \sum_{t \in N} (y_t^A - y_t^B)^2 + \mu \left[ \sum_{t \in N_A} (y_t^A - y_t)^2 + \sum_{t \in N_B} (y_t^B - y_t)^2 \right]$$

式中,  $\mu = 0.5$ , 是连接偏移最小准则  $n_{CM}^2$  和两模型的均方误差  $\sigma^2$  的权系数。组合准则的两个分量具有相同的性能, 在所估计的结构接近最优复杂度模型时它们接近最小值。同时这两个分量又具有本质的区别:  $n_{CM}^2$  准则表达了所求的模型结构对样本  $N_A$  和  $N_B$  不矛盾性的总性能, 即在后续样本中不矛盾性将保留下来的保证;  $\sigma^2$  准则测量了相应的模型对  $N_A$  和  $N_B$  样本的逼近误差, 该准则反映了所求模型的局部性能。

将几个独立的准则使用在一个组合准则中丰富了后者的性能, 使它成为多方位的, 由此提高了准则的筛选能力和抗干扰性能。

#### 3.4.4.6 短期预测精度准则

除了将原始数据表划分为训练样本和检查样本外, 在预测模型自组织时, 建议将部分数据划分为考查样本  $N_C$ , 用于检查预测的品质。用考查样本确定借助于模型计算的值(预测的)与真值间的均方偏差:

$$RR = \Delta^2(C) = \frac{\sum_{t \in N_C} (y_t^M - y_t)^2}{\sum_{t \in N_C} y_t^2} \rightarrow \min$$

这个准则与前面所研究的准则之一组合使用。

#### 3.4.4.7 平衡准则

在综合条件保持不变且在对象结构没有被破坏的条件下, 在观测时间段内作用的规律性(特征变量间的联系)将保持到将来。根据平衡准则, 从所有得到的模型中选择在确定的时间段内与给定的规律性符合得最好的一个模型。假设  $f(u_1(t), u_2(t), \dots, u_s(t)) = 0$  为平衡函数(即联系变量  $u_i(t)$  的规律,  $i=1, \dots, s$ ), 从对变量  $u_i(t)$  的所有预测模型集合中应选择这样一个模型: 当它在外推区间这个关系以最好的方式被满足。变量平衡的破坏可以表示为

$$b_i = f(u_1(t_i), u_2(t_i), \dots, u_s(t_i))$$

式中,  $t_i$  是预测区间中的时刻。

平衡准则使得可以从可能的趋势项的扇面中为每个预测过程选择最好的预测。在很多情况下, 容易从物理概念中知道表示变量间联系的函数, 而在其他一些情况下, 变量间的相互联系可以借助元素分组考虑算法来确定。

变量的平衡准则可以用在对几个变量的同时预测中。在这种情况下, 必须要求变量间的关系是不变的, 即作用于观测区间的依赖关系同样作用于预测区间。

如果变量间的联系存在, 那么在插值区间可获得不偏移的模型:

$$u_1 = f_1(u_2, u_3, \dots, u_s)$$

$$u_2 = f_2(u_1, u_3, \dots, u_s)$$

⋮

$$u_s = f_s(u_1, u_2, \dots, u_{s-1})$$

如果给出以上直接关系的函数是可逆的, 那么右边的元素可以通过左边的元素表达

出来，从而得到如下的方程组，它的序号根据顺序重新确定：

$$\begin{aligned} u_1 &= g_1^{-1}(u_2, u_3, \dots, u_s) \\ u_2 &= g_2^{-1}(u_1, u_3, \dots, u_s) \\ &\vdots \\ u_s &= g_s^{-1}(u_1, u_2, \dots, u_{s-1}) \end{aligned}$$

式中，第  $i$  个逆函数  $g_i^{-1}$  由第  $j$  个联系 ( $j \neq i$ ) 的逆乘以  $f_j$  得到。

获得逆函数的所有可能方案中，应该认为能最好地对应于直接函数而获得的方案更好。

在外推区间的时刻  $t_i$  借助于预测模型对每个变量计算出的值

$$b_{1i} = (f_1 - g_1^{-1})^2, \quad b_{2i} = (f_2 - g_2^{-1})^2, \dots, \quad b_{si} = (f_s - g_s^{-1})^2$$

表征了在给定时刻平衡的破坏。

平衡准则

$$B_i^2 = \sum_{t \in p} \sum_{j=1}^s b_{tj} = \sum_{t \in p} \sum_{j=1}^s (f_j - g_j^{-1})^2$$

用于选择最优模型。

在某些情况下直接函数和反函数恒等，那么作为用于模型选择的平衡准则使用如下的指标：

$$B_i^N = \sum_{j=1}^s \sum_{t \in p} [(u_j(t_i) - f_j(t_i))^2 + (u_j(t_i) - g_j^{-1}(t_i))^2]$$

如果预测模型用微分方程来描述，那么外推借助单步积分来实现，这时对于基于物理现象的平衡准则将得到最好的预测。

在一维的情况下，可以人为地提高变量的数目。对于具有季节性特征的过程，既可以在插值区间，也可以在外推区域使用谐波函数。谐波最优级数的选择由平衡准则完成，这时它是谐波纵坐标平衡准则。

如果函数用区间  $t \in N$  中的三角函数的和来描述，即

$$y_t = \sum_{k=1}^m (A_k \sin \omega_k t + B_k \cos \omega_k t)$$

那么有下列的平衡关系成立：

$$b_i = y_{t+m} - \sum_{k=0}^{m-1} a_k (y_{t+k} + y_{t-k}) + y_{t-m}$$

这里系数  $a_k$  ( $k = 1, \dots, m$ ) 是方程

$$a_0 + \sum_{j=1}^{m-1} a_k \cos j \omega_k = \cos m \omega_k$$

的解。因此，对  $m=1$ ，有等式  $b_i = y_{t+1} - 2a_0 y_t + y_{t-1}$ ， $a_0 = \cos \omega$  成立；而对  $m=2$ ， $b_i = y_{t+2} - 2a_0 y_t - a_1 y_{t+1} - a_1 y_{t-1} + y_{t-2}$ ，这里  $a_1 + a_2 \cos \omega_1 = \cos 2\omega_1$ ， $a_1 + a_2 \cos \omega_2 = \cos 2\omega_2$ 。

这个准则可以应用于应该在不同的时间或不同的空间区间上确定变量时。随着求平均的区间的扩大，预测的精度可能会提高，但同时发生了信息的损失。

(1) 根据平衡准则消除预测的多值性。在给出变量平衡准则较小值的季节性和年度性预测的组合中,一定存在接近过程实际变化的一种组合,同时在它们中间也存在一些不符合实际过程的组合(平衡准则的多值性)。应该在满足平衡准则的多种组合中找到真正的平衡,平衡准则多值性的排除依靠整修来达到,即引入补充的信息(外部补充)。指定的更高级的限制——物理可实现性准则可以成为这样的外部补充。对随机过程和的预测,一般情况下总是比对各个相加过程单独的预测更准确,这一性能可以用来提高长期预测的精度。首先外推出相加的总和过程,然后是分量过程,它们在任一时刻都应以一定的状态(平衡)与总过程一起存在。例如,为了预测科学工作者的数目,应首先预测国家居民人数的增长,然后再寻找科学工作者绝对数目的预测。

(2) 苏联科学院院士吉洪诺夫(ТИХОНОВ А.Н.)提出的解整修理论可作为在两准则平面上最优复杂度模型选择的依据。МГУА的独特性表现在它使用了早先在数学统计中未知的准则,即偏移最小准则 $n_{CM}^2$ 和变量平衡准则 $B_i$ 。这些准则可能导致模型的多值选择(由于存在局部最小值),并且相比其他准则具有更低的抗干扰性。两种准则的平方和形式的组合准则为

$$\rho^2 = n_{CM}^2 + \lambda I^2(N); \quad \rho^2 = n_{CM}^2 + \lambda \Delta^2(A+B)$$

式中,  $\lambda$  为解整修准则的权系数,它保证了最优模型选择的单值性和自组织算法对干扰的不敏感性;相加项 $\lambda I^2(N)$  和 $\lambda \Delta^2(A+B)$  就是苏联科学院院士吉洪诺夫提出的解整修理论的整修算子。求和可以由两准则对最优模型的顺序挑选来替代(首先根据第一个准则挑选 $F_1$ 个模型,然后根据第二个准则挑选 $F_2=1$ 个模型)。第一个准则是整修性的,它应该具有单模态特性,对干扰稳定。将准则 $I^2(3)$  或者 $\Delta^2(A+B)$  作为整修算子使用,它给出了模型的单值选择,并对干扰是低敏感的。

根据解整修理论,为消除多值性和对干扰的敏感性,建议补充某一个整修算子。可以使用不同的准则作为这样的补充算子,其中包括正规性准则 $\Delta^2(B)$  或者多步预测精度准则 $I^2(3)$ 。组合的准则具有形式: $\rho_1^2 = n_{CM}^2 + \Delta^2(B)$ ;  $\rho_2^2 = n_{CM}^2 + I^2(3)$ ;  $\rho_3^2 = B_i^2 + \Delta^2(B)$ ;  $\rho_4^2 = B_i^2 + I^2(3)$ 。可以用顺序地使用准则来代替两个准则的和(根据冈博的非最终解原则)。

正规性准则与将数据表划分为 $N_A$  和 $N_B$  两部分的问题的解相联系( $N = N_A \cup N_B$ )。显然,多步预测精度准则不要求数据表的划分,具有优势。短期预测的精度准则 $\Delta^2(C) = RR \leq 1$  用于所有情况下对模型逐一挑选的预先限制。

#### 3.4.4.8 几种其他准则

与前面所提到的准则一起的还有一系列的准则,它们也找到了应用之处。

(1) 步进积分精度准则。它估计在向前 $M$ 步的步进积分结果下产生的均方误差,借助表达式

$$I^2(N) = \frac{\sum_{t \in N} (\hat{y}_t^M - y_t)^2}{\sum_{t \in N} y_t^2} \rightarrow \min$$

来计算。建议将该准则用于差分方程,它不要求将观测划分为训练样本和检查样本,检

查同样可以用确定模型的那些数据来完成，因为积分和它的被积分表达是不相关的，积分（导数）可以看做新信息。因此，虽然它是用训练样本计算的值，准则仍然可以当做外部补充。

与对于  $t \in N$  只计算向前一步预测的均方偏差准则不同，如  $y_{t+1} = f(y_t)$ （单步预测），在使用步进积分准则时完成了步进预测的所有步，如  $\bar{y}_{t+1}^M = f(\bar{y}_t^M)$ 。如果预测模型以齐次差分方程组的形式给出，即  $x_{k+1} = Ax_k$ ，那么准则将有以下形式：

$$I^2(N) = \sum_{k=1}^{n-1} (x_{k+1} - A^k x_1)(x_{k+1} - A^k x_1) \rightarrow \min$$

步进积分精度准则不仅可以用在模型结构的选择上，还可以用于排除系数估计的偏移，为此在估计值的空间中应该使用搜索的方法。

(2) 元素多样性准则。该准则特别适用于自组织的第一阶段，以保证有尽可能多样化的元素。对复杂系统，适宜于与通常的准则一起使用，并满足元素的数目不要过分大的要求。

(3) 模型简单度准则。从根据某个筛选准则选出的几乎等价的数学模型中，相于简单度准则，选择在更简单的基函数下且含元素数目较少的模型作为最优复杂度模型。

(4) 作为整修的外部补充的变量值的限制。作为模型单值选择所必需的外部补充，有时可以使用关于限制条件的先验信息。对预测而言，在通常的情况下要求稳定的模型，由于这一原因，有时根据稳定性来考虑模型的挑选。我们常常还拥有预测值变化范围的信息，例如它不应大于 100%，这一先验信息也不应该向计算机隐瞒。根据吉洪诺夫所表述的外部补充的类型，产生了使用数学期望、自协方差、不相关实现的样本、平滑性要求及其他准则的可能性。显然，在进行最优复杂度模型选择时，如果它的需求者真正需要相应的性能，应考虑到这样一些外部补充。

#### 3.4.4.9 信息准则

与所考虑的在自组织理论范围内研究的筛选准则一起，近年来出现了基于熵最大化的信息准则。根据这个准则，在依据最大似真原则所估计的模型中，应该选择这样一种模型结构：它使得关于被检测量的真实模型的熵的期望值最大化。为了估计熵，使用了在似真函数达到最大值点处似真函数的对数的两倍的值（从这个量中需要扣去独立计算的模型参数数目的两倍的值）。

由于难于检查费歇尔的估计理论的适用性条件，信息准则的使用受到限制。在信息准则中加入了建模者指定的参数，这就失去了模型选择的客观性。其主要的缺点还在于，根据信息准则选出的模型可能是矛盾的，因此这个准则可以作为整修准则使用，对 МГУА 的基本准则起补充作用。

#### 3.4.4.10 组合准则

筛选准则的选择由任务的类型、建模者的目的及愿望来决定。常常对模型的多个要求是相互矛盾的，且并不总能够通过一个准则的最小化来达到。在自组织算法中应用了初看起来不太合理的准则，如偏移最小准则要求用观测数据表的第一半  $N_A$  得到的模型

能尽可能地与用另一半  $N_B$  得到的模型相同。这样的准则本身不是很有效的，因为两个几乎完全相同的模型有可能是同样坏和不准确的。由于模型选择多值性的原因，单使用这样的准则是不能筛选出最优模型的。这个论点对平衡准则也是有效的。这样的准则应该用于已经由相应的辅助性准则挑选出来的模型集合。

对准则的顺序使用是对选择进行整修的手段，即使它成为单值的。几个准则的使用也用于提高自组织算法的抗干扰性能。如果某个准则要求过于大量的计算，则需要借助于辅助性准则进行初步的挑选，以减小逐一挑选的数量。在这些情况下，需要转入准则的顺序使用（一个接一个）或者是组合准则，一般情况下对两个准则  $K_1$  和  $K_2$ ，它具有如下形式：

$$K_{1_{\text{KOM6}}} = \sqrt{\beta K_1^2 + (1 - \beta) K_2^2}$$

$$K_{2_{\text{KOM6}}} = \sqrt{\beta \left(\frac{K_1}{K_{1\max}}\right)^2 + (1 - \beta) \left(\frac{K_2}{K_{2\max}}\right)^2}$$

式中， $0 < \beta < 1$ ， $\lambda = 1 - \beta$ 。

在协调模型的矛盾要求（即解多准则优化的问题）时，组合准则的使用可以在当其中之一的准则导致多值选择时获得结构的单值选择。这时需要两个局部的准则，应根据建模所解决问题的物理意义来选择。

例如，如果用某个确定的准则来评价两个模型时得到了模型等价的结论，则应进一步使用第二个准则来评价，根据物理意义的不同做出单值选择。

根据几个筛选准则进行最优复杂度模型选择任务同模式识别任务是十分相似的，也就是在给定条件下选择类的任务。

#### 3.4.4.11 准则的顺序使用（体系）

为了绕开准则的规范化问题并简化计算程序，有时候用它们的顺序使用来代替准则的组合。这时应该区分基本准则和辅助性准则。基本准则根据任务的提出而选择，辅助性准则从属于基本准则，主要用于削减选择的数量。使用那些在模型复杂度增长的情况下能较好地表现出最小值的准则作为辅助性准则，这一点在基本准则不具有这个性能时要特别要求。例如，借助正规性准则可以进行初步的挑选，然后从挑选剩下的模型方案中按照偏移最小准则或平衡准则来进行选择。顺序使用不同的准则常常比使用组合准则更好，在这种情况下使用下列三个准则： $n_{CM}^2$  为偏移最小准则； $\Delta^2(C)$  为用考查序列计算的精度准则； $B_i^2$  为平衡准则。

在  $n_{CM}^2 - \Delta^2(C)$  平面上根据两个准则选择一定数量的最优模型，这之后按照平衡准则  $B_i^2$  的估计确定一个最优模型。在顺序使用不同的准则时，根据冈博的非最终解原则，建议逐步削减在每一步挑选出来的模型数量。如果输出的集合包含  $F$  个模型，那么根据第一个准则应该选取  $F_1$  个模型，根据第二个准则选取  $F_2$  个模型，根据第三个准则选取  $F_3$  个模型，这里  $F > F_1 > F_2 > F_3$ ，从  $F_3$  个模型中应该确定唯一的最优复杂度模型。

### 3.4.5 正规性准则形成方法

#### 3.4.5.1 变量的规范化

整修应保证获得单值、稳定的解，且解满足观测中的小改变引起较小的系数变化。整修是依靠将观测数据表划分为检查样本和训练样本来达到的，这是根据外部准则选择模型的最优结构所必需的。参与建模的变量，预先地应该被规范化。

广泛采用的一种按趋势项  $\varphi_t$  对变量  $v_t$  规范化的方法如下：

$$\bar{v}_t = \frac{v_t - \varphi_t}{\sigma_v}$$

一般情况下，选择幂多项式形式的趋势项

$$\varphi_t = \sum_{k=0}^q b_k t^k$$

或者是谐波函数的趋势项

$$\varphi_t = \sum_{k=0}^q (a_k \cos \omega_k t + b_k \sin \omega_k t)$$

对幂多项式在  $q=0$  时得到按均值的规范化：

$$m_v = \frac{1}{n} \sum_{t \in N} v_t$$

式中， $n$  为最常使用的观测实现的数目， $N$  为总样本。

按趋势项函数来规范化是不确定的（使用什么复杂程度的趋势项），且只使用在确实存在非平稳过程时。从原始数据中扣除趋势项大大增强了随机振荡的作用。由于在趋势项函数结构选择中有较大的不确定性，结果可能对应地得到失真的模型。由于自组织的结果取决于趋势项函数的选择，因而选择应以极大的谨慎来完成。为了保证信息矩阵具有最好的数值性能的最优规范化，必须将与趋势项之间的偏差除以标准偏差，这时得到下列规范化：

$$\bar{v}_t = \frac{v_t - \varphi_t}{\sigma_v}$$

$$\sigma_v = \sqrt{\frac{1}{n} \sum_{t \in N} (v_t - m_v)^2}$$

当  $q=0$  时， $\bar{v}_t = \frac{v_t - m_v}{\sigma_v}$ 。

#### 3.4.5.2 将数据表划分为几部分的方式

将原始数据表划分为几部分与正规性准则  $\Delta^2(B)$  的使用相联系。对于最优复杂度模型自组织，建议使用三个准则：偏移最小准则  $n_{CM}^2$ ，求平均的正规性准则（YKP），多步预测精度准则  $I^2(N)$  或者是短期预测精度准则  $RR = \Delta^2(C)$ 。这些准则中不会产生关于数据表划分方式的问题。但正规性准则有时还是需要使用的，因此有必要研究将

数据表合理地划分为几部分的问题。为计算正规性准则 $\Delta^2(B)$ ，观测数据应划分为两部分：训练样本和检查样本 ( $N = N_A \cup N_B$ )。可以这样来划分插值点，它使得：①信息矩阵具有最好的计算性能；②训练样本和检查样本的统计性能近似相似。

有很多准则或多或少地接近这个目标。划分基于按方差对点进行排列，对每个点计算对所有  $m$  个自变量  $v_k$  的方差，包括输出变量：

$$\sigma_t^2 = \frac{1}{m+1} \sum_{k=1}^{m+1} [(v_{kt} - m_k)^2]$$

式中， $v_{m+1} = y$ ， $m_k = \frac{1}{n} \sum_{t \in N} v_{kt}$ 。

两个点相互离得越远，它们之间的插值就越准确，因此，将具有大方差的点收入训练序列，可改善信息矩阵的计算性能。检查样本包含剩余的带有小方差的点，这些点位于接近变量平均值的地方。由于在训练序列中包含了那些与其平均值相距最远的点，信息矩阵在这种方式下获得了最好的计算性能。如果将实现按照数据表中点的方差值来排列，那么就可以得到筛选级数与训练序列和检查序列分别包含的点之间比例的依赖关系。

#### 3.4.5.3 将数据表最优划分为各部分

根据格德尔定理，为了进行数据表的划分，原则上必须还要一个二级外部补充。点不只划分为训练样本和检查样本，还要划分出考查样本  $N_C$  和  $N_D$ ，并用第二个考查样本计算的误差 $\Delta^2(C)$ 作为二级外部补充。这样来划分训练样本和检查样本，会使得 $\Delta^2(C) \rightarrow \min$ 。将原始数据划分为三个样本的优化必须要有三级外部补充 $\Delta^2(D)$ 。我们要提醒的是，所有使用的点的数目，也就是被考虑的历史区间的长度也应被优化。

在 MGYA 算法中，观测数据表的划分常常如下进行。

正规性准则：

$$\begin{aligned} N_A &= 0.7N; & N_B &= 0.3N; & N_C &= N_D = 0; \\ N_A &= 0.6N; & N_B &= 0.2N; & N_C &= N_D = 0.1N \end{aligned}$$

偏移最小准则：

$$\begin{aligned} N_A &= 0.5N; & N_B &= 0.5N; & N_C &= N_D = 0; \\ N_A &= 0.4N; & N_B &= 0.4N; & N_C &= N_D = 0.1N \end{aligned}$$

式中， $N_A, N_B, N_C, N_D$  是在训练样本、检查样本、第一和第二考查样本中对应的点数， $N$  是点的总数。

数据表更有效的划分要借助二级外部补充进行，可以使用筛选级数最小数目准则、极大极小化准则和其他一些准则。

(1) 筛选级数最小数目准则。根据这个准则，要选择观测数据表的这样一种划分：在它之下使用的 MGYA 的多级算法所需要的筛选级数为最小数目。这样得到的模型将是最简单的。在每种具体的情况下，可以借助改变  $N_A$  对  $N_B$  的比例关系来获得最优的级数。在图 3-4 中展示了这种相关性，它被称为托杜阿 (Тодуа) 抛物线，在建立抛物线时将实现按照基点的方差来排列，比例值离散地改变。

(2) 托杜阿抛物线。以下的定理形成了按照达到最优复杂度模型的最简单结构准则将数据表划分为两部分的方法。

**定理** 如果将点按照与平均值的均方差值排列，那么就有检查样本的点数对训练样本点数比例关系的唯一值，在它之下将得到筛选级数的最小值  $K$ ，以及相应的最优复杂度模型的完全多项式的最小阶数。

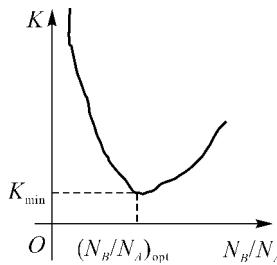


图 3-4 托杜阿抛物线

样本  $A$  在 МГУА 中用于确定系数的估计值，而样本  $B$  用于选择最优复杂度模型的结构，在这种情况下，使用模型简单度准则作为外部补充，即格德尔方法有效。

(3) 极大极小化准则。建议这样来选择观测表的划分，在它之下偏移最小准则的最大值达到最小，即

$$\max(n_{CM}^2) \rightarrow \min$$

以这个目的对每个模型得到对于所有可能划分的  $n_{CM}^2$ ，之后从这个性能参数的所有可能值中确定给出最优划分的最小值。相应地，也可以针对点的每一种划分，对所有的模型得到  $n_{CM}^2$ ，并从所有最小值中选择最大值： $\min(n_{CM}^2) \rightarrow \max$ 。这等价于外部准则的最小值对应于真实模型的概率应该是最大的。在使用外部准则的正则形式下，得以成功地构造和在计算机上计算所要求的分布函数。

(4) 将数据表划分为两个完全相同的序列  $N_A$  和  $N_B$  的方案的逐一挑选。为了计算偏移最小准则，必须要划分出点数相同的两个样本。为了获得最优划分，应该进行点属于训练样本和检查样本的所有可能方案的逐一挑选，这样的挑选只对于非常短的数据样本是实际可实现的。

(5) 点“云团”直径。最小二乘法给出了一个矢量，它是由模型的自变量矢量所形成的线性空间中局部模型的输出矢量的正交投影。根据将点划分为  $N_A$  和  $N_B$  的方法不同，输出矢量将发生改变。在矢量终点平面上所有点的几何位置形成了“云团”，它的直径可以作为二级准则的尺度。选择这样一种划分：在它之下直径比所有其他划分都小。获得这种性能参数的算法要求实现所有可能的观测划分，而这在实际中也仅对于小样本是可能的。

(6) 经验优化。如果仅限于数据表的伪最优划分，则计算的困难可能减小。让我们考虑下列整修方法的应用。假设给定  $n$  个点，第一批  $n - n_c - m$  个点用于建立模型，并根据所给定的整修方法将它们划分为训练样本和检查样本。下面的  $n_c = T_v$  个点组成考查样本并作为第二个补充，这里  $T_v$  为预测的超前时间。剩下的  $m$  个点必须要用来对

给定划分下的预测误差求平均，为此  $n - n_c$  个点顺序地从 1 移动到  $m$ ，这时得到预测  $y_{t,j}^M$ ，对它用考查样本确定误差（它可以是对所有  $m$  个预测的平均），例如，可以得到

$$\Delta(C)_m = \sqrt{\frac{1}{mT_v} \sum_{j=1}^m \sum_{t \in N_c} (y_t - y_{t,j}^M)^2}$$

### 3.4.6 МГУА 理论的基本状况

#### 3.4.6.1 自组织的原则

在筛选的级数逐渐增长时（相应的，借助展开局部描写的方程组所得到的完全多项式的级数增长），外部准则值通过了全局最小值，它对应于最优（对该准则）复杂度模型。完全多项式复杂化的数量级取决于局部描写的类型，并总是可以选择以使得最小值是唯一的。将局部描写方程组展开为完全多项式的最方便的方法是借助于格德尔数。

#### 3.4.6.2 关于点数的最小值定理

将阶数为  $q$  的完全多项式任意划分为局部项时，如果训练序列的点数不少于每个局部模型相加项的数目，均方偏差准则可以用训练样本的点来得到（局部模型和完全多项式的所有系数的最优估计）。例如，对于形如  $y_k = a_0 + a_1x_i + a_2x_j + a_3x_ix_j$  的双线性局部描写，为评价模型精度所必需的代数最小值，对正规性准则（通常的或 УКР）而言是 5 个点，对偏移最小准则而言是 8 个点。对数据表的点数没有要求的是 УКР，它是将所有点依次（逐个）划分到训练序列下得到的正规性准则的和。

在 МГУА 的多级多项式算法中，在筛选的第一级使用了，如包含 3 项的局部描写。在使用 УКР 准则下，点的代数最小值等于 4。在第二级和以后的各级中也使用 4 个数据点，总模型从局部描写方程组中排除过渡性变量而得到，其结果是最优复杂度的总模型可能包含比局部描写的相加项数目多得多的相加项。

在 МГУА 的谐波算法中，在筛选的第一级，为了从原始数据中划分出一个谐波分量，要求最少 3 个点。相应的，在筛选的第一级可划分出的频率的最大可能数目等于原始数据的点数除以 3。在划分出频率后，确定所有点上的残差。在筛选的第二级，新的频率已经从残差中被划分出来，以此类推。其结果是最优复杂度的总模型可能包含比原始数据点数除以 3 还多的谐波数目，正如卡捷尔尼科夫（Котельников）定理所要求的。

#### 3.4.6.3 关于信息矩阵的退化以及多级性的误差

在过大的筛选级数（大于 4~5）下，局部描写的系数矩阵由于存在共轴的（相互联系的）元素变得不确定。检查序列  $B$  在这种情况下失去了外部补充的性能（成为更小信息量）。在相对不大的筛选数目（小于 5~6）下，带有不确定矩阵的模型可以直接从挑选中排除。此外，可以在每一级的筛选中保留元素  $x_i$  的原始集合，这个方法使得不仅可以提高矩阵的确定性，还可以排除多级性的方法性误差，后者是由于多级算法的完全多项式不包含高莫戈罗夫—冈博幂多项式的所有可能项而产生的。考虑到原始的元

素可以补充一系列相加项，这样就使指定的多项式保持完全。

#### 3.4.6.4 关于模型自组织的抗干扰性能

在干扰/信号比所表示的干扰强度增大的情况下，与通信理论中著名的关于含噪声的信道的香侬（Шенон）第二定理相似的定理已确立，МГУА 的算法选择更简单的模型（与物理的真实模型相比）作为最优复杂度模型。偏离的程度取决于准则的形式：对正规性准则而言，它比对偏移最小准则大，这样，对称的偏移最小准则是更能抗干扰的。在非常大的干扰下（如由于信息基的不完全而引起），可根据 МГУА 选择观测的均值作为最优复杂度模型。

列举出的 МГУА 理论的状况及定理适合于所有多级算法。МГУА 的多级算法可以包含在每级筛选之后计算残差的操作或者不包含它。

#### 3.4.6.5 关于用训练序列测量得出的均方误差不增长定理

在 МГУА 的多级算法中，该定理确立了用训练序列测量得出的均方误差逐级不可能增长，并且与筛选进行的方式无关（即变量对的选择）。

#### 3.4.6.6 自组织算法的收敛性

收敛性的概念对解决辨识问题具有重要意义（预测模型自组织的收敛性还未被研究过）。与参数估计的算法相类似，自组织算法所属的结构辨识的迭代算法只有在这样的情况下对实际应用才是合适的，即当局部模型的序列收敛到真实模型，而该模型的信号隐藏在包含噪声的数据里。与参数估计的方法不同，其研究的是参数估计的序列对其真值的接近，并且通常要区分弱收敛性、概率收敛性等。还要求对结构辨识算法的收敛性进行补充研究。

目前已确立了收敛性的类型，并给出了在等于 1 的选择自由度下和等于原始变量数目的选择自由度下收敛性的严格证明。这里区分了下列三种类型的收敛性：

(1) 对点的收敛，如果矢量的序列达到被称为“凝结点”的那个点。

(2) 对解的收敛，如果矢量序列的极限存在并等于被观测的矢量。

(3) 结构上的收敛，如果在筛选的每一级中所获得的数学描写的序列存在极限值，并且它符合真实的描写。

在确定收敛性时，距离的测量却仍然是个问题，因为在选出的点上对两个函数间的距离进行通常的确定时，收敛性的概念与对解的收敛性相吻合。对模型的线性结构可以使用数学描写的对应参数的差的平方和。

在辨识问题中，МГУА 多级算法的收敛性对指出的三种收敛类型都已被证明，并且收敛到凝结点的过程如同在稳定系统中平衡状态的建立过程。收敛性对于预测问题还没有被研究过，这里的进程如同在伺服系统中的过程，代替收敛点应该考虑被称为趋势的稳定运动点的几何位置。带残差计算法的收敛性也没有研究过。

### 3.4.6.7 在不完全信息基下的模型自组织

如果被研究的对象包含  $M$  个输入量，相互间以  $f$  个方程相联系，那么为了对其进行完全的数学描写， $m \geq M - f$  个变量就足够了，剩余的变量可以作为过渡性变量被排除掉。如果以上关系事先已知，那么为了获得对象模型， $m$  个非共轴的变量就足够了。

在有干扰的情况下，借助于 МГУА 可以找到包含不完全因素组成的模型，这是因为本质性的因素是相互联系的。虽然联系是未知的，但这不妨碍模型的自组织。模型自组织的结果选择了数目不多的变量作为自变量（带不完全信息基的模型）。自组织结果所获得的模型的描写，减轻了当一定的实质性变量难以测量时进行预测的任务的难度。它们的影响可以借助于其他变量被考虑到。这再一次指出了适合于预测的模型不一定是物理的、适于控制的模型。

对于建模的系统边界的选择，实际上不能这样指出被建模系统的边界，即使得它的模型在精度上是自治的，也即由闭合的（一定的）方程组来描写。这与格德尔的定理相矛盾。与此同时，关于建立某个非常大的信息采样系统的理想被指明为获得长期预测的唯一途径。

如果在边界之下自组织算法给出的系统准则具有足够深度的最小值（数量级为  $D_{\min} \leq 10^{-5}$ ），边界（变量的集合）是足够的，那么某些子系统可能没有进入这个边界。能够客观地确定建模的最优区域和最优复杂度模型，这是自组织方法与模拟方法相比所具有的优点，后者使用完全物理的模型。

### 3.4.6.8 МГУА 准则和算法的抗干扰性能

显然，已有的先验信息、基函数、筛选准则及其数学表达的选择，以及 МГУА 算法的特殊性都对自组织的抗干扰性能有影响。为了确定给定模型（如多项式）的抗干扰性能，应用了计算试验。

如果  $q_{\Phi}$ ,  $q_{np}$  是实际数据和预测，那么预测的准则为

$$\Delta^2(C) = RR = \frac{\sum_{i=1}^{n_C} (q_{\Phi} - q_{np})^2}{\sum_{i=1}^{n_C} (q_{\Phi} - \bar{q}_{\Phi})^2} = \begin{cases} < 0.5 & \text{好} \\ < 0.8 & \text{合格} \\ > 1 & \text{预测带给使用者虚假信息} \end{cases}$$

噪声幅值的增大减小了借助 МГУА 算法获得的最优模型的复杂度，正是从这点可以发现通信和自组织的共同性。根据香侬关于带噪声信道的定理，当干扰幅值增长时，接收器的通带应该减小。相类似的，在数据显示有大的噪声分量下，建议采用线性回归，因为线性方程最适合在强受扰数据和大的预测超前区间下进行预测。

在对称形式的两个准则（即基本准则  $n_{CM}^2$  和整修准则  $\Delta^2(B)$ ）的平面中寻找最优模型时，干扰可以超过信号大约 5 倍。这里的干扰/信号的极限比的数字取决于竞争模型的离散集合和信号的形式，它仅仅指明了抗干扰性能基本指标的数量级。物理模型的结构辨识问题仅在小噪声下可以用 МГУА 算法解决，这时干扰的功率大约比信号功率小 2 倍。最优复杂度预测模型的自组织的任务可以在干扰功率超过信号功率几倍的情况下

用 МГУА 算法解决。

模型的多准则选择和对称准则的使用是当没有关于干扰的专门信息时提高模型自组织算法抗干扰性能的基本措施。所以在受干扰的数据下，不是按一个准则，而是按准则的体系或者准则群来选择。

(1) 用于提高 МГУА 抗干扰性能的对称准则。

最优复杂度模型的多准则选择显著地提高了 МГУА 算法的抗干扰性能。已确认对称和组合准则的抗干扰性总是优于非对称和单独的准则。下列形式的对称偏移最小准则：

$$n_{CM}^2 = \frac{\sum_{i=1}^{n_A+n_B} (y_A - y_B)^2}{\sum_{i=1}^n y_{\Phi_i}^2} \rightarrow \min$$

具有更高的抗干扰性。式中，下标指出了用于确定模型参数估计的观测表的部分； $y_{\Phi_i}$  是过程的实际值（数据表）。将正规性指标对称化也是适宜的，如果将其按下列公式计算：

$$\Delta^2(AB) = \sum_{i=1}^{n_B} (\hat{y}_A - y_{\Phi})_i^2 + \sum_{i=1}^{n_A} (\hat{y}_B - y_{\Phi})_i^2 = \Delta^2(B/C) + \Delta^2(A/B) \rightarrow \min$$

它等于以下情况时两个通常的正规性准则的和，即当 A 部分和 B 部分彼此相等，并轮流作为训练样本和检查样本时。此外，还提出了另一种对称形式的正规性准则：

$$\begin{aligned} S^2 &= \Delta^2(AB) = \sum_{i=1}^{n_A+n_B} (\hat{y}_A - y_{\Phi})_i^2 + \sum_{i=1}^{n_A+n_B} (\hat{y}_B - y_{\Phi})_i^2 \\ &= \Delta^2(B/C) + \Delta^2(A/B) \rightarrow \min \end{aligned}$$

式中， $y_{\Phi}$  是实际数据。这里根据用 A 和 B 得到的系数的估计来计算对所有数据的偏差，这个准则比通常的非对称的准则具有更好的抗干扰性。因为  $S^2$  同时也是组合准则，它也促进了 МГУА 的抗干扰性：

$$S^2 = \Delta^2(AB) = n_{CM}^2 + 2 \sum_{i=1}^{n_A+n_B} (\hat{y}_A - y_{\Phi})(\hat{y}_B - y_{\Phi}) \rightarrow \min$$

(2) 进一步提高预测自组织的抗干扰性的前景。

自组织的方法、算法及准则的抗干扰性的提高首先应该依靠通信（信息论）的通用理论在建模中的推广来达到。预测模型自组织的算法保证了抗干扰性，在它之下干扰可超过信号大约 5 倍。按照相关无线电接收器的框图对原始数据的处理又将抗干扰性提高了 20 倍，即可以建立算法，使得噪声可超过信号 100 倍。这不应使我们吃惊，因为通信专家有把握地保持了与火星附近的宇宙飞船的通信，更不用说在近地轨道上。

### 3.5 本章内容小结

本章对预测问题和模型自组织方法进行了介绍。自组织算法是一种智能性的数学建模方法，建模所需的先验信息是最小化的，并且可以在不考虑对象中一系列本质性因

素、在噪声超过有益信号几倍的情况下建立模型，这些特点使得它从根本上区别于传统的确定性和概率性建模方法，因而被成功地应用于系统辨识、短期及长期预测的任务。本章重点描述了自组织方法的基本原则和自组织算法用于建模的主要内容，包括模型复杂化规则、基函数系的选择、筛选的准则以及整修方法。本章的内容是理解后面关于行动感知器的实现中预测模型的建立和数学仿真中相应内容的数学基础，也是深入掌握自组织算法的入门性知识。

## 第4章 飞行器智能控制系统中行动感知器的建立

在无人飞行器智能控制系统中，除动态专家系统、目标综合模块、估计和决策支持模块外，要求使用预测算法。在对对象自身的状态、控制系统的参数和包含了其他动态对象的外界环境的参数实施预测的同时，还要进行预测结果和实际情景的经常核对。预测模型的建立以及预测结果与实际参数的比较在行动感知器中实现，行动感知器是智能控制系统中一个关键机制。因此，研制更完善的预测方法和算法是动态对象控制理论和实践中的重要和迫切的任务。为实现这些算法，必须建立研究过程的模型，在大多数现代智能系统中实现了数学模型的建立。

本章研究了在行动感知器中建立预测模型的几种方法，重点是作者提出的 Demark 趋势项与自组织算法相结合的改进型算法，它们是实现行动感知器的基础。在算法建立的过程中考虑了对无人飞行器智能控制系统算法保障的特殊要求，即紧凑性和快速性。

### 4.1 自组织方法建模的应用

自组织方法是进行复杂系统数学建模的基本方法之一，它允许在不预先指定研究对象物理规律性的条件下建立数学模型。与其他的方法不同，在智能系统运行的过程中，该方法可以根据智能系统外部或内部条件的变化和目标的改变修正或者改造模型。

模型自组织的方法建立在根据外部准则对各种方案的逐一选择基础上。它使用计算机对所掌握的短数据样本进行处理，在此基础上找到所需结果，并允许在先验信息最少的条件下建立预测模型。当动态对象在随机条件下工作时，关于它的先验信息量通常是最少的，因此适宜采用自组织的方法建立数学模型。数学模型的研制者应该给出模型选择的准则群（自组织准则），而具有最优复杂度的数学模型随之自动选择产生。

自组织算法的运行在于将选择模型逐步复杂化，并根据外部准则对其进行评价，准则的最小值即确定了最优复杂度模型。随着模型结构复杂度的逐步增加，外部准则值随之降低，逐渐达到最小值，该最小值即对应最优复杂度模型。如果某个准则导致选择的多值性或者对输入数据的微小改变过于敏感，则向它补充具有同一模态特性的第二个准则（整修算子），以保证可以唯一地确定最优复杂度模型。

根据自组织理论，在模型的复杂度上升的条件下，对数学模型进行逐次组合和选择，是寻找最优复杂度模型的通用方法。

为了获得单值的解，必须要有合理选择的外部补充条件——外部准则。我们将外部准则理解为用不参与参数估计的信息计算的准则。根据外部准则的不同选择，最优复杂

度模型可能是不同的。

在噪声存在时，内部准则不能解决选择最优复杂度模型的任务。例如，使用训练序列的均方偏差的内部准则，当存在噪声时，在没有补充的外部信息条件下，原则上是不能够找到具有最优复杂度的唯一模型的，必须要有对检查序列误差进行估计的外部指标。

在自组织算法中，实现通常包括训练部分、检查部分和考查部分。

训练样本用于获得模型参数的估计值；检查样本用于获得模型的结构，即用于选择最优复杂度模型；考查样本用于评价不同的模型，也可将其用于选择训练样本和检查样本的最优划分。

自组织算法所依据的基本原则有：

(1) 最优复杂度模型选择的单值性。

随模型结构复杂度逐步增加，外部准则值达到极小，它的第一个最小值决定了唯一的最优复杂度模型。

(2) 将数据表划分为几部分。

通常将过程原始数据表划分为两部分或三部分：训练样本 A，检查样本 B 和考查样本 C。它们用于获得模型参数的估计、选择模型结构和评价不同的模型。

(3) 使用外部准则进行模型选择。

在选择模型的外部准则中，包括下列基本准则：①偏移最小准则，同一性是最优模型的基本和必要的性能；②正规性准则，它要求数据表 B 部分的均方误差是最小的，该准则可以作为对偏移最小基本准则进行补充的辅助性和整修性准则使用。

(4) 选择的原则。

将自古以来在进化和新物种的人工培育中起作用的生物界中的选择原则用在复杂系统的信息加工算法中是非常方便的。借助模型种类的组合、交叉和选择，在多级筛选后选择出最优复杂度模型。

(5) 保存选择自由度原则。

保存选择自由度原则是自组织中基础性的原则之一，它与选择的原则有很多共同点。选择的自由度这样来保证：向每一个筛选的下级传递的不是一个解，而是从上级中选出的几个最优解。多级性和在筛选的每级之后存在选择的自由度是自组织算法的基本性能。

在自组织算法中，建立在不完全数学归纳上的元素分组考虑法（МГУА）是数学模型自组织方法中一种重要的方法。与主观系统分析法和建立在演绎方法基础上的模拟建模方法相比，按照元素分组考虑的自组织方法既不要求积累足够多的具有低噪声水平的先验信息，也不要求对建模对象做深入的研究以获得理论上的表示。

总体上，元素分组考虑法具有良好的抗干扰能力，它根据模型研制者所指定的外部准则群，对各种方案进行逐一挑选，从而客观选择最优复杂度模型。

运用了元素分组考虑法的自组织理论研究的主要结果是：①在使用多级选择算法时，可保证寻找最优复杂度模型的过程是收敛的；②当样本数据中存在噪声时，不完全（简化的）非物理模型同完全的物理模型相比更适宜于建立预测模型。

自组织方法是一种通用的方法，广泛地应用在解决插值任务、短期预测任务、长期预测任务和模式识别任务中。实现自组织算法的基本结构包括下列模块：①考虑到选定的基函数组对观测数据进行预先处理的模块（处理的结果是削减了变量集合）；②按照所选定的复杂化规则产生竞争模型集合的模块（竞争模型产生算法）；③根据整修方法挑选最优复杂度模型的选择准则模块，该准则是外部的补充条件。

这些基本的模块按照图 4-1 所示的结构连接起来，构成自组织算法运行的体系。

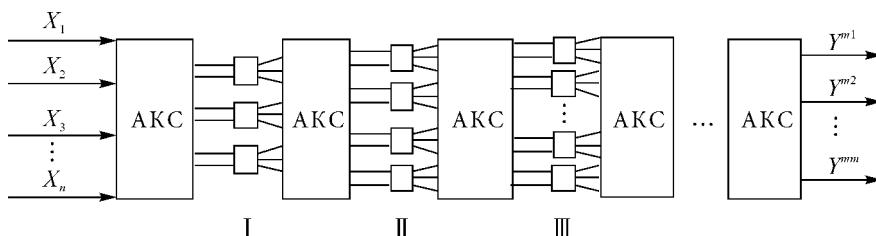


图 4-1 自组织算法建模过程结构框图

图中：

$X_1, X_2, X_3, \dots, X_n$  是竞争模型，建立在根据对原始数据的初步分析而选择的基函数基础上；

AKC 是选择准则群，其中常常使用正规性准则  $\Delta^2(B)$ 、偏移最小准则  $n_{CM}^2$ 、变量平衡准则  $B_i^2$ 、模型简单度准则以及其他准则；

$Y^{m1}, Y^{m2}, \dots, Y^{mm}$  是根据 AKC 选择后建立的模型；

I, II, III 是产生竞争模型的复杂化过程，通常采用组合、交叉和变异等手段来提高模型的复杂度。

在自组织时产生了大量的不同复杂度的各种各样的竞争模型。竞争模型发生器给出了包含冗余信息的不同复杂度结构的中间方案。排除不合适的模型之后，剩余的集合由品质准则来评价，并选择出最优复杂度模型。

产生不同复杂度模型的方法划分为单级和多级，它们分别对应于完全和不完全的数学归纳。在采用完全归纳时，逐一选择的工作量可能大到不可容许的程度，在这种情况下，依靠合理选择的基函数的组合（如借助元素分组考虑法）使得中间方案的数目仍然保持在可实现的范围之内，即多级算法。

虽然在逐一选择的过程中，按照准则一定可以找到非常接近最优的模型，但在多级算法中存在漏掉最优复杂度模型的概率。

可以用不同的基函数实现元素分组考虑的算法。通过对已有的先验信息做预处理，可以正确地选择出更准确地反映物理过程的基函数。

动态对象的数学描述要么用它的微分方程表示，要么用方程的解表示。解的低频部分称为趋势项函数，它们是用下列形式表示的动力学方程的解：

$$y(t) = h(\mathbf{u}, s, t) \quad (4-1)$$

或者在相应的假设下，有

$$y(t) = f(t, \mathbf{c}) + s(t) \quad (4-2)$$

式中,  $s(t)$  是附加的噪声。趋势项函数  $f(t, \mathbf{c})$  可以用某些基函数组来逼近, 即

$$f(t, \mathbf{c}) = \sum_{i=0}^n c_i \varphi_i(t) \quad (4-3)$$

式中,  $\varphi_i(t)$  是基函数。

自组织时在分离趋势项的算法中一般使用下列的基函数:

①幂多项式

$$\varphi_i(t) = t^i \quad (4-4)$$

用于建立模型

$$y(t) = \sum_{i=0}^n c_i t^i \quad (4-5)$$

②三角函数

$$\varphi_{2i}(t) = \cos \omega_i t \quad (4-6)$$

$$\varphi_{2i-1}(t) = \sin \omega_i t \quad (4-7)$$

用于组成模型

$$y(t) = \sum_{i=0}^m c_i \cos \omega_i t + \sum_{i=0}^m d_i \sin \omega_i t, \quad i = 0, 1, 2, \dots, m \quad (4-8)$$

③指数函数

$$\varphi_i(t) = e^{\beta_i t} \quad (4-9)$$

用于建立模型

$$y(t) = \sum_{i=0}^m c_i e^{\beta_i t} \quad (4-10)$$

样本实现  $N$  划分为用来估计模型参数的训练样本实现  $N_A$  和用来进行合适模型选择的检查样本实现  $N_B$ 。为选择模型使用了不同的准则, 其中包括偏移最小准则和正规性准则。偏移最小准则是一个主要的准则, 因为唯一性是最优模型必须具有的性能。

原始数据样本划分为两个相同的部分  $N_A, N_B$ , 在它们之上分别确定了输出为  $y_t^A, y_t^B$ , 参数为  $C_i^A, C_i^B$  的两个模型  $A, B$ 。偏移最小准则等于在全样本 ( $t \in N$ ) 之上的模型  $A, B$  输出偏差的均方值, 即

$$n_{CM}^2 = \frac{\sum_{t \in N} (y_t^A - y_t^B)^2}{\sum_{t \in N} y_t^2} \rightarrow \min \quad (4-11)$$

正规性准则确定了检查样本模型均方偏差, 即

$$\Delta^2(B) = \frac{\sum_{t \in N_B} (y_t^M - y_t)^2}{\sum_{t \in N} y_t^2} \rightarrow \min \quad (4-12)$$

建议将正规性准则用做辅助性准则(整修)使用。

在筛选模型的过程中, 还使用变量平衡准则(详见第3章):

$$B_i^2 = \sum_{t \in p} \sum_{j=1}^s b_{tj} = \sum_{t \in p} \sum_{j=1}^s (f_j - g_j^{-1})^2 \quad (4-13)$$

在预测模型的自组织时，除了将原始数据表划分为训练样本和检查样本外，建议将部分数据划分为考查样本  $N_C$ ，用于检查预测的品质。用考查样本来计算由模型计算出的值与真值间的均方偏差为

$$RR = \Delta^2(C) = \frac{\sum_{t \in N_C} (y_t^M - y_t)^2}{\sum_{t \in N_C} y_t^2} \rightarrow \min \quad (4-14)$$

这个准则与前面所讨论的准则之一结合使用。

## 4.2 短时间序列建模的应用

在预测动态对象控制系统中各种不同类型的过程时，关于过程“行为”过去的信息要么十分有限，要么足够完全，但过程变化的趋势在接近预测计算的时刻已发生了改变。这时，建立在只使用统计数据基础上的传统预测方法，要么完全无效，要么导致不充分可信的结果，在这种情况下需要使用补充的专家信息。

短时间序列的预测方法是将统计信息和专家信息结合到统一的模型中。该方法区别于其他的方法的两个有益点为：①它们使用对每个研究领域的专家都方便的专家命题的形式；②所有的方法都基于统一的模型，在模型中结合了实质上所有有关研究过程的各种信息。

### 4.2.1 时间序列的描述

我们假设，所研究的现象在每一离散的时刻  $t$  用某个量  $y_t \in \mathbf{R}$  表征。序列

$$y_t, t = \dots, -1, 0, 1, \dots \quad (4-15)$$

称为时间序列，而  $y_t$  称为序列的值。

时间序列的值在测量区间  $(1, 2, 3, \dots, m)$  被观察，观察的结果形成了如下的序列：

$$\bar{y}_t, t = 1, \dots, m \quad (4-16)$$

预测的任务就是寻找在超前的周期  $(m+1, \dots, m+n)$  中所确定的序列，即

$$\hat{y}_t, t = m+1, \dots, m+n \quad (4-17)$$

在通常的情况下，序列 (4-15) 可以表示为以下四个分量的和：

(1) 系统分量，从平均意义上表示了被预测的现象在时间上的改变特性，被称为趋势项。

(2) 以有可能改变的频率绕趋势项的振荡分量。

(3) 以比绕趋势项的振荡高得多的频率振荡的特征振荡分量。

(4) 随机分量。

在对足够广泛的领域内不同机理的现象进行预测分析的基础上得到了这样的结论，即参数间为下列线性关系：

$$F(t, \boldsymbol{\theta}) = (\boldsymbol{\theta}, \boldsymbol{\varphi}(t)) \quad (4-18)$$

式中， $t = 1, \dots, m, m+1, \dots, m+n$ ，确定为离散时间序列； $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_K)$  为参数

矢量； $\boldsymbol{\varphi} = (\varphi_1, \varphi_2, \dots, \varphi_K)$  为矢量函数，通常的情况下其分量为非线性函数； $(\theta, \varphi(t)) = \sum_{i=1}^k \theta_i \varphi_i(t)$  为标量积，可以作为趋势项模型，其中  $k$  为模型 (4-18) 中非线性函数的数量。

在正确选择  $k$  和  $\varphi_i$  的情况下，模型 (4-18) 可以描述足够复杂的时变现象，同时，当使用在预测算法中时它又足够简单。 $\varphi_i$  可以使用线性的、平方的、多项式的、级数的函数等。应该特别指出，两参数的模型

$$F(t, \theta_1, \theta_2) = \theta_1 \varphi_1(t) + \theta_2 \varphi_2(t) \quad (4-19)$$

是实践中最常遇到的模型。

仅当建立周期的持续时间  $m$  足够长的情况下，才能获得关于时变特性的可信结论，也才有可能借助时间序列做到有效地预测。在对实际中的序列预测经验进行分析的基础上，可以得出以下的结论：为了预测出所有的分量，持续时间  $m$  应具有上百个单位长度的数量级；当数量  $m$  为几十个单位长度的数量级时，只对于用趋势项、特征分量和随机分量的和表示的时间序列可以得到满足精度要求的预测结果；当序列的持续时间低于某个值  $m_{\min}$  时，完全不可能借助观测结果 (4-16) 得到或多或少满足要求的预测，这时要求引入关于预测现象的补充信息。数量  $m_{\min}$  由所要求的预测精度、预测的最大深度  $n$ 、趋势项和随机分量的特性决定。

在观测的持续时间  $m < m_{\min}$  的情况下，必须引入形如专家判断的补充信息以获得研究现象的可信预测，因为当时间序列具有小的持续时间  $m$  时，从分析观测结果中形式上得出的统计结论可信度低。

#### 4.2.2 专家判断

研究领域内的专家以更简单和更自然的方式判断在预测超前周期时刻的时间序列可能值的下限和上限，还可以判断趋势、最大和最小值的出现，或者建立时间序列将来值与过去值间的联系。

这种类型的判断可以表示成逻辑代数的复杂命题形式，这些复杂命题借助于逻辑连接符  $\&$ ,  $\vee$ ,  $\Rightarrow$ ，由形式为

$$\alpha + \beta y_\mu \geq \gamma + \delta y_\nu \quad (4-20)$$

的基本命题  $u$  组成。其中，超前的周期时刻  $\mu, \nu$  和量  $\alpha, \beta, \gamma, \delta$  由专家给定。从简化的目的出发，式 (4-20) 的表达可以写成队列  $\langle \alpha, \beta, \gamma, \delta, \mu, \nu \rangle$  的形式。

专家判断的集合  $L$

$$\{w^l : l = 1, \dots, L\} \quad (4-21)$$

可以看做逻辑代数复杂命题的总和，即

$$\bigwedge_{l \in L} w^l \quad (4-22)$$

鉴于每个命题  $w^l$  自身又是基本命题 (4-20) 的某个集合借助逻辑连接符  $\&$ ,  $\vee$ ,  $\Rightarrow$  组成的复杂命题，式 (4-22) 的命题可以化为具有用  $u_h$  表示的基本命题的正规和的形式，即

$$\sum_{h=1}^H u_h \quad (4-23)$$

式中,  $H$  是基本命题的数量,  $h$  是给出的集合中具体命题的对应下标。

因为在超前周期的时间序列的值应该对应于趋势项模型 (4-18), 任何基本命题 (4-20) 以线性不等式的形式

$$\alpha + \beta(\theta, \varphi(\mu)) \geq \gamma + \delta(\theta, \varphi(\nu)) \quad (4-24)$$

或

$$(\theta, \beta\varphi(\mu) - \delta\varphi(\nu)) \geq \gamma - \alpha \quad (4-25)$$

确定了对参数  $\theta_i$  和函数  $\varphi_i(t)$  的限制。这里, 超前周期的时刻  $\mu, \nu$  和量  $\alpha, \beta, \gamma, \delta$  由专家给定。

那么专家判断的总和就对应线性不等式组

$$(\theta, \beta_h\varphi(\mu_h) - \delta_h\varphi(\nu_h)) \geq \gamma_h - \alpha_h, \quad h = 1, \dots, H \quad (4-26)$$

在实际应用中, 重要的情景常常使用区间形式的专家判断, 不等式组 (4-25) 将具有如下形式:

$$(\theta, \varphi(t^l)) \geq a^l, \quad (\theta, \varphi(t^l)) \geq -b^l, \quad l = 1, \dots, L \quad (4-27)$$

如果存在这样的趋势项模型, 在其基础上得到序列  $\hat{y}_t, t = m+1, \dots, m+n$ , 哪怕对于一个下标  $h$ , 不等式组 (4-26) 都是相容的, 那么专家判断称为相容的; 在相反的情况下, 专家判断是矛盾的。

如果还能对专家的专长进行预先的估计, 那么这种类型的补充信息对于时间序列的预测可能是有益的。在这种状态下, 每个专家判断  $w^l$  用似真度  $p^l$  来表征, 在满足条件  $p^l \in [0, 1]$ ,  $l = 1, \dots, L$  时, 形式上与概率可能是相同的。那么判断的集合可由下式表示:

$$\{(w^l, p^l) : l = 1, \dots, L\} \quad (4-28)$$

如果专家判断是相容的, 那么对应于它们的不等式组 (4-26) 是相容的。一般情况下, 不等式组的解是不唯一的, 因此, 为了寻找趋势项模型, 应该加入补充的假设。例如, 按照模型计算出的时间序列值应与在建立预测的周期上的观测结果最大程度地吻合就是一种补充假设。在这样的假设下, 寻找最优模型的过程就是在专家判断约束限制下, 使得在统计数据基础上形成的准则最小的过程。

假设, 已知预测现象的观测序列形式为

$$\bar{y}_t, \quad t = 1, \dots, m \quad (4-29)$$

相容的判断集合

$$\{w^l : l = 1, \dots, L\} \quad (4-30)$$

以及精确到函数和参数矢量的模型

$$F(t, \boldsymbol{\theta}) = (\boldsymbol{\theta}, \varphi(t)) \quad (4-31)$$

任务在于寻找与观测的结果 (4-16) 和专家判断 (4-21) 最吻合的预测序列, 即转入在限制条件

$$(\theta, \beta_h\varphi(\mu_h) - \delta_h\varphi(\nu_h)) \geq \gamma_h - \alpha_h \quad (4-32)$$

下, 函数最小化的任务

$$\min_{\theta_i, \varphi_i(t)} J(\boldsymbol{\theta}, \boldsymbol{\varphi}(t)) \quad (4-33)$$

准则具有如下的形式：

$$J = \sum_{t=1}^m \Phi(\tilde{y}_t - (\boldsymbol{\theta}, \boldsymbol{\varphi}(t))) \quad (4-34)$$

式中， $\Phi$  为选定的准则函数，根据实际的设想来选择。

这样就表示了借助时间序列对宽范围的过程进行预测的操作，该操作可以在专家系统的范围内得以实现。其优点表现在专家系统可工作在复杂的条件下和非标准的情形中。这种方法预测的有效性依靠在建立动态对象预测模型中既使用统计信息，也使用专家信息来达到。

所给出的建立预测模型的方法可应用在动态对象的复杂控制系统中，如智能控制系统。在“功能—智能系统”中，可以将该方法与自组织算法同时使用。自组织算法使用在当测量包含了动态对象足够信息的条件下，即测量的老化效应还没有影响到预测模型建立的精度。当测量的老化效应已经对预测模型的精度产生影响时，使用基于短时间序列的算法。在这种情况下，预测模型的精度依靠建模中使用的专家信息来提高。在智能系统行动感知器中的失调量可以作为从自组织预测模型向短时间序列模型转换的指标，对象动力学特性的测量值也可以作为指示标志。在对象高度机动的条件下测量其参数，当相邻的短样本间的本质区别重复出现时，就切换至基于预测时间序列的模型。

### 4.3 改进型 Demark 趋势项建模

形如 Demark 趋势项的线性趋势项的特点为实现简单，并可以在最短的时间段内确定研究过程的变化趋势。这样的趋势项可用于非常短的测量样本的预测，这种情况在传感器缺失的条件下常常遇到，即当智能控制系统安装在高度机动的无人飞行器上时。

传统的 Demark 趋势项通过使用测量样本的极值点来建立，可以表达为

$$\hat{x}_{0k} = k_{0k} t_k + d_{0k} \quad (4-35)$$

式中， $k$  表示使用该模型获得预测值的时刻； $\hat{x}_{0k}$  为该时刻被预测出的量； $k_{0k}$ ， $d_{0k}$  是趋势项参数，分别为趋势项的斜率和常数。

$k_{0k}$ ， $d_{0k}$  按下列方式得到：根据测量样本长度的不同，将其划分为具有一定长度的两个不同的组，在每个组中分别选择出具有最大、最小值的点。为获得趋势项，按照下列顺序用直线连接最大、最小值点：当样本总体上具有下降趋势时，使用两个组中的最大值点；当样本总体上具有上升趋势时，使用两个组中的最小值点。趋势项所连接的那些点称为基点。这样， $k_{0k}$ ， $d_{0k}$  由选出的基点坐标所确定。

式 (4-35) 的模型在样本具有较大动态变化时具有一定的优越性。但该模型的建立只利用了样本中最大、最小值点，未充分利用测量样本的全部信息。为此，作者提出了对传统 Demark 趋势项的第一步改进措施，即在建立趋势项时利用全部测量样本，并根据对不同划分下的所有测量样本的平均结果决定基点纵坐标的值，同时增加了对基点横坐标的选择自由。

经过上述改进后，建立在样本平均值基础上并带有选定基点  $a_1$ ， $b_1$  的 Demark 趋

势项表达形式为

$$\hat{x}_{1k}(a_1, b_1) = k_{1k}t_k + d_{1k} \quad (4-36)$$

式中,  $k$  表示使用该模型获得预测值的时刻,  $\hat{x}_{1k}$  为该时刻被预测出的量,  $k_{1k}, d_{1k}$  分别为斜率和常数的趋势项参数,  $a_1, b_1$  为经配置得出的基点。

$k_{1k}, d_{1k}, a_1, b_1$  按下列方式得到: 将测量样本按不同要求划分为两个大小不同的组。对每组中的所有样本分别取平均, 得到两个平均值, 作为两个基点的纵坐标。根据任务需要和对测量样本的预先分析决定基点横坐标的位置, 与计算出的纵坐标相配置, 得到基点  $a_1, b_1$ 。用直线连接  $a_1, b_1$  得到趋势项。 $k_{1k}, d_{1k}$  随  $a_1, b_1$  而定。

从建模过程可以看出模型 (4-36) 与 (4-35) 相比有以下优点:

(1) 由于采用了分组中所有样本的平均值, 得到的趋势项对样本具有更精确的逼近(而不是只趋近极值点)。

(2) 由于可以对基点的横坐标进行任意配置, 实际上是对测量样本的不同时间段施加不同的权重, 从而可挑选出我们感兴趣的样本段, 使得建立的趋势项具有特定的针对性, 即可符合不同预测任务的需求。例如, 如果在划分样本时使第二个组的长度小于第一组的长度, 再将第二个基点的横坐标选择为靠近样本的终点, 这样获得的趋势项将对样本最近的变化具有更好的逼近, 将有效克服测量数据老化效应的影响。

样本组的划分、基点坐标的配置等问题, 取决于我们所要完成的预测任务的需求和对象的动态特性, 需要在建模过程中仔细权衡。

模型 (4-36) 虽经改进, 但趋势项模型仍属传统的线性预测模型, 精度不高, 特别是在无人飞行器高度机动的条件下, 不能对对象运动过程中表现出的非线性特性进行有效的预测。因此, 在实际应用中, 仅在无人飞行器接近直线的飞行段使用趋势项建模。为了在各种运行条件下提高预测模型的精度, 作者提出了借助 Yazvinski 滑动窗和自组织方法对式 (4-36) 中获得的初步改进型再次优化的建模方法, 将优化后的模型称为改进型 Demark 趋势项。借助 Yazvinski 滑动窗进一步补偿测量老化效应的影响, 而在被预测参数出现非线性特性而与线性趋势项不符合的区间, 采用自组织方法对趋势项进行修正, 使其更加准确(当然是在获得该参数的新的测量之后)。

改进型 Demark 趋势项这样来获得: ①利用式 (4-36) 的模型对测量样本进行粗逼近, 获得线性趋势项; ②从测量样本中分离趋势项获得残差; ③用自组织的方法建立残差的非线性模型; ④将线性趋势项与非线性模型进行组合, 得到最终的改进型 Demark 趋势项。

趋势项的准确化依靠在模型中增加非线性修正项, 从而提高模型的复杂度来进行。模型中的非线性修正项用自组织方法建立, 并使用元素分组考虑法实现模型自组织。根据对被预测参数动力学特性的实际考虑的构想来选择使用的基函数, 即通过理论分析削减其函数集合的大小。特别指出, 作者在实现这一经典的自组织算法时, 使用了极少的基函数组。使用极少的基函数可以实质性地削减计算消耗, 在精度没有明显损失的条件下提高算法的快速性。考虑到对机载数字计算机中算法实现的快速性以及对存储容量的硬性要求, 使用这样的改进型, 可以做到通过 6 级选择来建立惯性导航系统误差的预测模型。而采用带有完全基函数组的元素分组考虑法不可能在这样的时间内建立模型。

用自组织方法实现的改进型 Demark 趋势项建模过程的结构框图如图 4-2 所示。

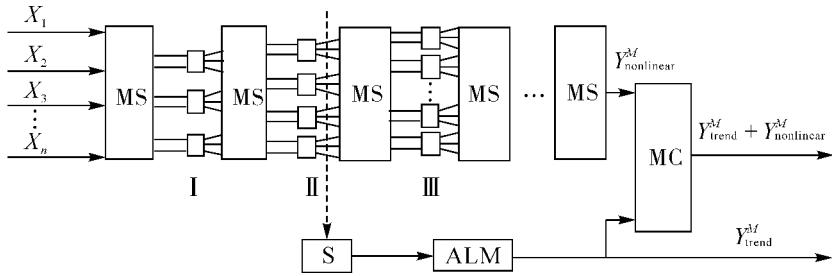


图 4-2 改进型 Demark 趋势项建模过程结构框图

与图 4-1 相比, 图 4-2 中增加的部分 ALM 表示用式 (4-36) 中初步改进的 Demark 线性趋势项建立预测模型。模块 S 代表两种模型的切换, 模块 MC 代表两种模型的组合环节。 $Y_{\text{trend}}^M$  为采用 Demark 趋势项建立的线性预测模型,  $Y_{\text{nonlinear}}^M$  为采用自组织算法建立的非线性修正项, 是对残差的逼近, 这两部分的组合  $Y_{\text{trend}}^M + Y_{\text{nonlinear}}^M$  成为改进型 Demark 趋势项, 它的使用可提高预测模型的精度。

最终根据预测精度准则决定选择下列模型中的一个模型:

- (1) 线性 Demark 趋势项, 其特点为简单和模型建立快速。
- (2) 改进型 Demark 趋势项, 其中包含了根据当前测量样本信息用自组织方法建立的非线性修正项。

研制出的改进型 Demark 趋势项具有如下的算法表达形式:

$$\hat{x}_{2k} = \hat{x}_{1k} + c_k \quad (4-37)$$

式中,  $\hat{x}_{2k}$  为动态对象在时刻  $k$  的状态变量预测;  $\hat{x}_{1k}$  为采用式 (4-36) 得到的线性趋势项;  $c_k$  为用自组织方法建立的残差的非线性修正项, 计算形式为

$$c_k = \sum_{i=1}^L a_i \mu_i(f_i, x) \quad (4-38)$$

式中,  $L$  为基函数的数目;  $\mu_i$  为参数集合  $F_p$  中的基函数;  $F_p = \{a_i \mu_i(f_i, x) \mid i = 1, \dots, L\}$ , 为基函数组, 每个基函数表示为参数  $(a_i, f_i)^\top$  的二维矢量, 其中,  $a_i$  为幅值,  $f_i$  为频率。

在算法中使用正规性准则和收敛度准则作为选择的准则, 分别表示如下:

$$\Delta^2 = \frac{\sum_{i=1}^{N_B} (z_i - \hat{x}_i)^2}{\sum_{i=1}^{N_B} z_i^2} \quad (4-39)$$

$$I = \frac{\sum_{i=1}^N (\hat{x}_i - z_i)^2}{\sum_{i=1}^N z_i^2} \quad (4-40)$$

式中,  $z_i$  为测量值;  $\hat{x}_i$  为根据模型预测的值;  $\Delta^2$  为在检查样本  $N_B$  上计算出的均方误差;

差;  $I$  为在插值区间上的单步积分误差值, 该区间包含训练样本  $N_A$  和检查样本  $N_B$ , 即  $N = N_A + N_B$ 。

这样, 通过两步的改进, 在传统的线性趋势项基础上获得了具有独创性的算法, 即改进型 Demark 趋势项, 它可以在无人飞行器机载数字计算机时间和机器存储容量有限的情况下建立被研究参数的预测模型, 可适用于无人飞行器高度机动的情况, 既保证了建模过程简单快速, 又使模型具有较高的精度。

#### 4.4 本章内容小结

算法的紧凑性和快速性是对无人飞行器智能控制系统算法保障的特定要求, 这是由无人飞行器运行的特点所决定的。根据这些要求, 对已知的自组织方法、结合专家判断信息的短时间序列方法和传统的 Demark 趋势项算法进行了分析, 这些算法是行动感知器的基础。考虑到无人飞行器算法实现的特殊要求, 选择了 Demark 趋势项作为基本算法, 它具有紧凑、实现简单的特点, 相应地要求最少的建立时间。为了提高 Demark 趋势项建模的精度, 首先对趋势项建立的过程进行了第一步改进, 又进一步提出了用 Yazvinzki 滑动窗和元素分组考虑的多级自组织方法对线性趋势项进行优化的措施, 获得了改进型 Demark 趋势项。Yazvinzki 滑动窗可克服测量老化效应的影响, 而通过用自组织方法建立的非线性修正项对残差的进一步逼近, 来对线性趋势项做出修正, 从而在被预测参数出现非线性特性的区间, 可以使预测的结果更加准确。

这样给出的独创性算法, 能够在传感器缺失的条件下建立被研究参数的预测模型。

# 第5章 飞行器智能控制系统控制算法的研制

## 5.1 控制算法的体系结构

作者建议使用分层的两级算法作为飞行器智能控制系统的控制算法。

该体系中的上层控制算法是在目标综合模块中实现的场景选择决策算法，即当存在有关周围环境和对象自身的信息时，在动机模块的基础上综合目标，做出从有限的场景中选择最好方案的决策。为了完成这一过程，在动机模块中放置一组准则，它们对应于对象运行的不同外部条件。根据具体的任务，对这组准则的综合考虑构成了评价函数，而决策依据评价函数来实现。根据技术系统决策方法的经典理论，每一具体时刻评价函数值的最小化结果对应于最佳场景。

由于在精度准则中包含了用测量系统误差模型计算出的参数，因此，场景的选择建立在行动感知器中用自组织算法建立的基准测量系统误差预测模型的基础上，这样当误差预测模型结构变化时，评价函数就会随之不断地改变。

在场景选择之后，控制算法体系的下层保证以最优方式实现上层所选出的轨迹，即按照某个目标泛函用最优控制的方法使得实际轨迹与最优轨迹间的偏差最小。为此，采用了最优控制，利用了极大值原理和变分法。

最优控制的各种非线性算法具有不同的精度性能和特殊性。现代控制理论中开发了依靠更精确地考虑到被研究对象的特殊性来提高控制精度的综合方法。但是只有在拥有控制对象的可靠先验信息时才能保证控制算法达到必要的精度，因此，必须要有被研究过程模型和输入及测量噪声的统计特性的可靠先验信息。在实际应用中先验信息通常不能准确得知，因此，为了确定研究过程的模型，使用了各种各样的辨识算法，而为了确定噪声的统计特性，使用了不同的自适应方法。

考虑到对飞行器控制系统算法保障统一化的要求，可以使用自组织算法来辨识被研究过程的模型。高精度的控制算法通常假定数学模型具有给定的结构，而在行动感知器中实现参数误差模型最优结构下模型参数的辨识。作者建议使用改进型 Demark 趋势项算法来建立预测模型。该算法第一步先建立线性预测模型，然后借助非线性自组织方法对线性模型改型，以得到更准确的非线性模型（但需要花更长的时间）。

应该看到，即使对于低阶次的线性系统，最优控制问题的解也是很复杂的，而算法本身在多数情况下是非线性的，这样整个系统在优化后便成为非线性的。因此，对非线性控制对象实现最优控制算法将具有很大的工作量，甚至常常不能在实际机载条件下得

以实现。为了减少计算消耗又不降低精度，作者研究了对象模型的全局线性化问题。通过运用微分几何理论，在无人飞行器运行的过程中，挑选出可以使用线性数学模型和相应的线性调节器的区间，这些线性模型与非线性模型完全吻合。在这些区间，最优控制的算法针对对象的线性化模型设计，其特点为可靠、简单，并在飞行器控制实践中已得到良好的开发。然后借助于非线性反变换得到实际状态下的控制作用，在其余的区间则使用非线性模型。这样就研制出了继电调节器，它在线性模型吻合区间使用线性调节器实现控制，而在其余的区间使用非线性调节器。

使用微分几何的方法对于精确线性化以及对于最优控制算法设计的有效性，取决于在非线性变换矩阵中和在行动感知器误差模型中被预测的对象参数的精度。

在对象运动模型中，相应地，在非线性变换矩阵、优化目标泛函和最终的最优控制调节器中都有状态向量参数，这些参数在测量系统中获得，对应地就具有由行动感知器根据误差模型预测的测量误差。因此，体系中的下层控制在由自组织方法计算的对象状态预测的基础上实现。预测的误差量越准确，非线性变换和对应的最优控制就越成功。

基于导航系统测量误差模型和对象运动模型的、带有体系中上下两层间相互作用关系的控制算法的结构框图在图 1-6 中已给出。该图还表示出了实现上下两层控制算法时采用的主要方法和手段。

## 5.2 体系上层中的决策

运行体系上层中的控制算法做出选择飞行器运行的某个场景的决策，这一过程在目标综合模块中按照选定的动机方式进行。对当前的任务，实现了最简单的动机概念，即优先权属于具有最大权值的飞行器运行场景，也就是在按照评价函数对准则群分析的基础上选择最佳场景。

决策常常与不确定性相联系。因此，必须尽力以最优方式使用已有的信息，并对所有可能的解决方案进行加权处理，努力从中找到最好的方案。

在决策的评价函数中考虑排除不确定性的影响。该评价函数灵活地适应各种情况，基于客观原则建立而排除主观因素的干扰，因此，对它进行编程和在计算机中实现决策的过程成为可能。

按照评价函数进行决策的数学表示为

$$E_0 = \{E_{i0} \mid E_{i0} \in E \wedge e_{i0} = \max_i e_i\} \quad (5-1)$$

$$e_i = J_E(e_{ij})_{j=1,n} \quad (5-2)$$

式中， $E$  是所考虑方案  $E_i$  的集合， $i=1, \dots, m$ ， $m$  为方案的有限数目； $E_0$  是最优方案的集合； $E_{i0}$  是最优方案，即带有最大权值的方案； $e_i$  是根据评价函数  $J_E$  计算出的方案  $E_i$  的权值； $e_{ij}$  是对应于方案  $E_i$  和外部条件  $F_j$  的解的有益度。

方案  $E_i$  的集合、外部条件  $F_j$  的集合和对应的解的有益度  $e_{ij}$  间的相互关系通常可表示为解矩阵，见表 5-1。

表 5-1 解矩阵

	$F_1$	$F_2$	$F_3$	...	$F_j$	...	$F_n$
$E_1$	$e_{11}$	$e_{12}$	$e_{13}$	...	$e_{1j}$	...	$e_{1n}$
$E_2$	$e_{21}$	$e_{22}$	$e_{23}$	...	$e_{2j}$	...	$e_{2n}$
$E_3$	$e_{31}$	$e_{32}$	$e_{33}$	...	$e_{3j}$	...	$e_{3n}$
...	...	...	...	...	...	...	...
$E_i$	$e_{i1}$	$e_{i2}$	$e_{i3}$	...	$e_{ij}$	...	$e_{in}$
...	...	...	...	...	...	...	...
$E_m$	$e_{m1}$	$e_{m2}$	$e_{m3}$	...	$e_{mj}$	...	$e_{mn}$

在矩阵的各行中放置各种方案，各列中放置对应于它们的不同外部条件。在该矩阵的各单元中填充解的结果——解的有益度，即在每个方案中对应于外部条件的准则值。在这个矩阵基础上计算每个方案评价函数的值，并以此选择具有最大权值的最佳方案。

使用什么准则来建立评价函数，取决于任务和它所形成的情形的特点，即我们基于什么，并朝什么目标努力。在智能系统中，在知识库中设立了由研究领域的专家判断所确定的、用于计算评价函数的合适的准则作为选择的原则。当出现相似的情景时，从知识库中选择在积累的经验意义上最有利的相应准则。同时将新情景下采用的准则的结果补充到知识库中。

根据技术系统中决策方法的经典理论，经常使用下列准则以建立评价函数：①极大极小准则；②贝叶斯—拉普拉斯准则；③色维德什准则；④库维兹准则；⑤霍德什—列蒙准则等。

极大极小准则（MM）使用在式（5-1）中描写的评价函数，它对应于极端小心的态度。

当  $Z_{MM} = \max_i e_{ir}$  和  $e_{ir} = \min_j e_{ij}$  时，有如下的关系成立：

$$E_0 = \{E_{i0} \mid E_{i0} \in E \wedge e_{i0} = \max_i \min_j e_{ij}\} \quad (5-3)$$

式中， $Z_{MM}$  是极大极小指标的评价函数。

在根据极大极小指标建立评价函数  $Z_{MM}$  时，每个方案  $E_i$  仅由自己结果中的一个  $e_{ir} = \min_j e_{ij}$  来表示。

贝叶斯—拉普拉斯准则（B-L）考虑了可能得到的每个结果。

假设  $q_j$  为外部状态  $F_j$  出现的概率，那么 B-L 准则为

$$Z_{BL} = \max_i e_{ir} \quad (5-4)$$

$$e_{ir} = \sum_{j=1}^n e_{ij} q_j \quad (5-5)$$

$$E_0 = \left\{ E_{i0} \mid E_{i0} \in E \wedge e_{i0} = \max_i \sum_{j=1}^n e_{ij} q_j \wedge \sum_{j=1}^n q_j = 1 \right\} \quad (5-6)$$

对应的选择规则可以解释如下：

将解矩阵  $\|e_{ij}\|$  扩充一列，该列中的元素为对应行中各元素的数学期望值。选择这

列中具有最大值  $e_{ir}$  的那些行的方案  $E_{i0}$ 。

这时假定, 进行决策的情景由下列的情况来表征: ①状态  $F_j$  出现的概率已知并与时间无关; ②解实现了 (理论上) 无穷多次; ③对于小数目的解实现允许存在某种风险。

当实现数目足够大时, 平均值逐步稳定。因此, 在完全 (无穷) 实现时, 风险实际上被排除了。

人们使用 B-L 准则时的出发点比使用极大极小准则时更乐观, 但该出发点建立在有更高的信息水平和足够长实现的假设基础上。

色维德什准则的评价函数为

$$a_{ij} = \max_i e_{ij} - e_{ij} \quad (5-7)$$

$$e_{ir} = \max_j a_{ij} = \max_j (\max_i e_{ij} - e_{ij}) \quad (5-8)$$

准则和最优方案的集合按下列方式建立:

$$Z_S = \min_i e_{ir} = \min_i [\max_j (\max_i e_{ij} - e_{ij})] \quad (5-9)$$

$$E_0 = \{E_{i0} \mid E_{i0} \in E \wedge e_{i0} = \min_i e_{ir}\} \quad (5-10)$$

色维德什准则 (S) 可理解为最大可能的损失依靠选择合适方案被最小化。

对应于 S 准则的选择规则可解释如下:

从对应列的最大结果  $\max_i e_{ij}$  中减去解矩阵  $\|e_{ij}\|$  的每个元素, 差  $a_{ij}$  形成了余量矩阵  $\|a_{ij}\|$ 。将这个矩阵扩充, 使其包含最大差值  $e_{ir}$  的一列。选择这样一些方案, 在它们的行中有这列的最小值。

从矩阵  $\|e_{ij}\|$  结果的观点看, S 准则有风险, 但从矩阵  $\|a_{ij}\|$  的观点看, 它又是无风险的。

库维兹准则 (HW) 的评价函数位于极端悲观主义和极端乐观主义的选择点之间:

$$Z_{HW} = \max_i e_{ir} \quad (5-11)$$

$$e_{ir} = c \min_j e_{ij} + (1 - c) \max_j e_{ij} \quad (5-12)$$

$$E_0 = \{E_{i0} \mid E_{i0} \in E \wedge e_{i0} = \max_i [c \min_j e_{ij} + (1 - c) \max_j e_{ij}] \wedge 0 \leq c \leq 1\} \quad (5-13)$$

式中,  $c$  为权因子。

依据 HW 准则的选择规则如下:

将解矩阵  $\|e_{ij}\|$  扩充一列, 使其包含每一行中最大最小结果的平均加权值。选择这样一些方案  $E_{i0}$ , 在它们的行中有这列的最大元素  $e_{ir}$ 。当  $c=1$  时, HW 准则转换为 MM 准则。

霍德什—列蒙准则 (H-L) 同时依据 MM 准则和 B-L 准则。借助参数  $v$  表达出对使用的概率分布的置信度。如果置信度高, 则强化 B-L 准则; 反之, 则着重 MM 准则。

该评价函数由下式决定:

$$Z_{H-L} = \max_i e_{ir} \quad (5-14)$$

$$e_{ir} = \nu \sum_{j=1}^n e_{ij} q_j + (1 - \nu) \min_j e_{ij}, \quad 0 \leq \nu \leq 1 \quad (5-15)$$

而 H-L 最优解的集合描写为

$$E_0 = \left\{ E_{i0} \mid E_{i0} \in E \wedge e_{i0} = \max_i \left[ \nu \sum_{j=1}^n e_{ij} q_j + (1 - \nu) \min_j e_{ij} \right] \wedge 0 \leq \nu \leq 1 \right\} \quad (5-16)$$

对应于 H-L 准则的选择规则如下：

将解矩阵  $\|e_{ij}\|$  扩充一列，该列由每行的数学期望与最小结果的平均加权（固定的权系数）组成。选择其行上有这一列的最大值的解的那些方案  $E_{i0}$ 。

对  $\nu=1$  的情况，H-L 准则转化为 B-L 准则；对  $\nu=0$  的情况，H-L 准则转化为 MM 准则。

根据所考虑的准则对被分析的情景所提出的要求，将以上所述的准则单独应用于理想化的实际方案。在要求非常强的理想化条件下，可以依次应用各个准则。在这之后，作为最优方案挑选出来的几个方案中，仍然必须以带有意向的方式划分出某个最终的解。这种方法使得：①可以最好地洞察决策问题的所有内部联系；②减弱主观因素的影响。

从飞行器运行的实际设想来考虑，上述准则或者它们的综合运用，对于建立给定任务的评价函数是可行的。

在控制算法体系的上层，目标根据控制误差和外部条件来综合。在本书介绍的研究工作中，考虑了下列的动态性能指标和外部条件：①  $F_1$ ，即飞行器位置确定的误差；②  $F_2$ ，即飞行器终点脱靶量确定的误差；③  $F_3$ ，即飞行器速度确定的误差；④  $F_4$ ，即飞行器定向确定的误差；⑤  $F_5$ ，即飞行区域主动干扰的强度；⑥  $F_6$ ，即完成任务的概率；⑦  $F_7$ ，即存活率；⑧  $F_8$ ，即燃料消耗。每一外部条件的权系数根据实际的设想来选择。我们要指出，上述清单并未穷尽工作中的所有情况。

为了演示智能系统的运行，在研究中考虑了飞行器的 4 种飞行场景：①  $E_1$ ，即轨迹 1；②  $E_2$ ，即轨迹 2；③  $E_3$ ，即轨迹 3；④  $E_4$ ，即轨迹 4。

这样，解矩阵对于所给定的任务具有表 5-2 所示的形式。

我们要指出，使用某种场景的决策不只一次地进行，而是当行动感知器中的误差模型更新时每次都要进行。

表 5-2 给定任务的解矩阵

	$F_1$	$F_2$	$F_3$	$F_4$	$F_5$	$F_6$	$F_7$	$F_8$
$E_1$	$e_{11}$	$e_{12}$	$e_{13}$	$e_{14}$	$e_{15}$	$e_{16}$	$e_{17}$	$e_{18}$
$E_2$	$e_{21}$	$e_{22}$	$e_{23}$	$e_{24}$	$e_{25}$	$e_{26}$	$e_{27}$	$e_{28}$
$E_3$	$e_{31}$	$e_{32}$	$e_{33}$	$e_{34}$	$e_{35}$	$e_{36}$	$e_{37}$	$e_{38}$
$E_4$	$e_{41}$	$e_{42}$	$e_{43}$	$e_{44}$	$e_{45}$	$e_{46}$	$e_{47}$	$e_{48}$

### 5.3 体系下层中的控制回路结构

体系下层的飞行器控制系统包含下列的子系统：①导航子系统；②稳定及控制子系统；③速度控制子系统。下层体系中的控制回路通常具有图 5-1 中所表示的结构。

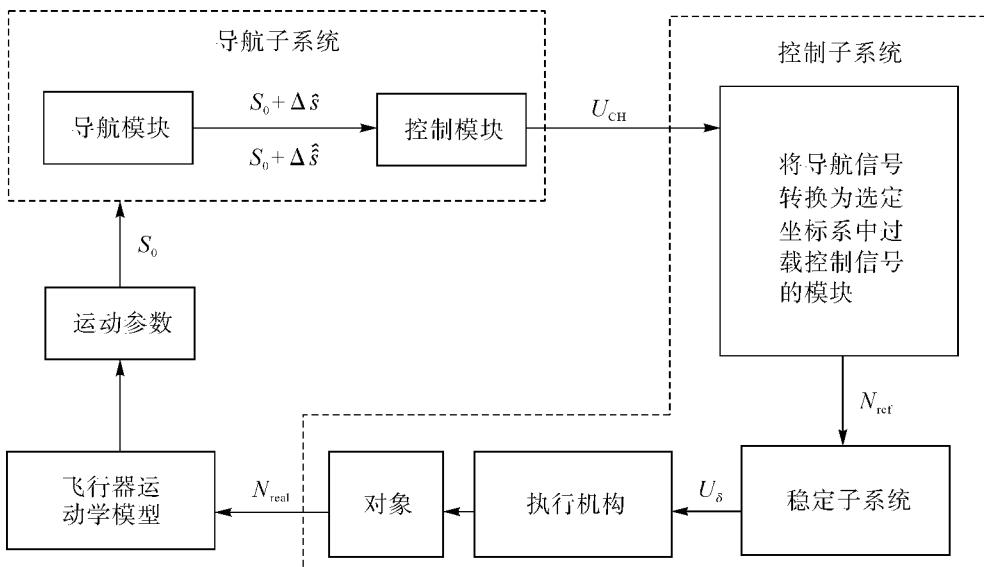


图 5-1 体系下层中控制回路的结构框图

图中符号的意义如下：

$S_0$ ——飞行器运动实际参数；

$S_0 + \Delta\hat{s}$ ——在导航模块中由最优估计法给出的导航参数，其中， $\Delta\hat{s}$  为估计误差；

$S_0 + \Delta\hat{\hat{s}}$ ——在导航模块中由预测法给出的导航参数，其中， $\Delta\hat{\hat{s}}$  为预测误差；

$U_{CH}$ ——导航指令（控制信号）；

$N_{ref}$ ——法向过载指令；

$N_{real}$ ——实际建立的过载；

$U_\delta$ ——到舵机的控制指令。

导航子系统给出飞行器质心运动的规律，并依靠改变相应的法向控制力保证飞行器按照该规律运动。稳定子系统使飞行器按要求绕质心进行角运动，并保证过渡过程具有满意的动态性能。

导航系统由导航模块和控制模块组成。导航模块测量飞行器运动的所有参数，对其进行处理以获得这些参数的最优估计或预测，用于在控制模块中形成导航指令，即轨迹变化的规律和按照选定的轨迹控制飞行器飞行的算法。控制模块中的综合控制算法使用了经典的算法，如极大值原理和变分法。

## 5.4 体系下层中的最优控制律

考虑下列带约束的问题：

必须将泛函

$$J = \int_{t_0}^{t_f} \Phi[\mathbf{x}(t), \mathbf{u}(t), t] dt \quad (5-17)$$

在  $n$  维向量微分方程

$$\dot{\mathbf{x}}(t) = \mathbf{f}[\mathbf{x}(t), \mathbf{u}(t), t] \quad (5-18)$$

的约束下最小化。其中， $m$  维向量  $\mathbf{u}$  是要选择的控制函数，而  $n$  维向量  $\mathbf{x}$  是结果轨迹。假设函数  $\mathbf{f}$  具有沿  $\mathbf{x}$  和  $\mathbf{u}$  的连续微分。通常，这里关于光滑性的假设可保证对于式 (5-17) 中的泛函，对任一分段—连续的函数  $\mathbf{u}$  存在唯一允许的轨迹  $\mathbf{x}$ 。这样，对属于分段—连续类函数的一簇允许控制函数和任一给定的允许初始条件  $\mathbf{x}(t_0)$ ，式 (5-17) 确定了在所考虑的时间区间内唯一的允许解。

在初始时刻和初始状态向量已确定的条件下，控制任务（波里兹任务）归结为对方程

$$\dot{\mathbf{x}}(t) = \mathbf{f}[\mathbf{x}(t), \mathbf{u}(t), t], \quad \mathbf{x}(t_0) = \mathbf{x}_0 \quad (5-19)$$

描写的系统，使泛函

$$J = \theta[\mathbf{x}(t_f), t_f] + \int_{t_0}^{t_f} \Phi[\mathbf{x}(t), \mathbf{u}(t), t] dt \quad (5-20)$$

最小。

向泛函中引入拉格朗日因子，得到下列表达式：

$$\bar{J} = \theta[\mathbf{x}(t_f), t_f] + \int_{t_0}^{t_f} \{\Phi[\mathbf{x}(t), \mathbf{u}(t), t] + \boldsymbol{\lambda}^T(t)[\mathbf{f}[\mathbf{x}(t), \mathbf{u}(t), t] - \dot{\mathbf{x}}(t)]\} dt \quad (5-21)$$

泛函式 (5-21) 的哈密尔顿函数由下列关系式确定：

$$H[\mathbf{x}(t), \mathbf{u}(t), \boldsymbol{\lambda}(t), t] = \Phi[\mathbf{x}(t), \mathbf{u}(t), t] + \boldsymbol{\lambda}^T(t)\mathbf{f}[\mathbf{x}(t), \mathbf{u}(t), t] \quad (5-22)$$

式中， $\boldsymbol{\lambda} = \frac{\partial \Phi}{\partial \dot{\mathbf{x}}}$ ，为常数，称为拉格朗日不确定因子。

式 (5-21) 积分项的变换得出

$$\begin{aligned} \bar{J} = & \theta[\mathbf{x}(t_f), t_f] - \boldsymbol{\lambda}^T(t_f)\mathbf{x}(t_f) + \boldsymbol{\lambda}^T(t_0)\mathbf{x}(t_0) + \\ & \int_{t_0}^{t_f} \{H[\mathbf{x}(t), \mathbf{u}(t), \boldsymbol{\lambda}(t), t] + \dot{\boldsymbol{\lambda}}^T(t)\mathbf{x}(t)\} dt \end{aligned} \quad (5-23)$$

泛函的一阶差分具有如下形式：

$$\begin{aligned} \mathbf{x}(t) &= \hat{\mathbf{x}}(t) + \delta\mathbf{x}(t) \\ \mathbf{u}(t) &= \hat{\mathbf{u}}(t) + \delta\mathbf{u}(t) \\ t_f &= \hat{t}_f + \delta t_f \end{aligned} \quad (5-24)$$

式中， $\delta\mathbf{x}(t)$  为对应于到达时刻偏差  $\delta t_f$  下实际轨迹与最优轨迹的偏差， $\hat{\mathbf{x}}(t)$  和  $\hat{\mathbf{u}}(t)$

为最优轨迹和最优控制。

我们来确定差  $\delta \bar{J} = \bar{J}[\mathbf{x}, \mathbf{u}, t_f] - \bar{J}[\hat{\mathbf{x}}, \hat{\mathbf{u}}, t_f]$ , 若只考虑分解中的线性项, 我们得到:

$$\begin{aligned}\delta \bar{J} &= \delta t_f \left\{ H[\mathbf{x}(t_f), \mathbf{u}(t_f), \boldsymbol{\lambda}(t_f), t_f] + \frac{\partial \theta[\mathbf{x}(t_f), t_f]}{\partial t_f} \right\} + \delta \mathbf{x}^T(t_f) \left\{ \frac{\partial \theta(\mathbf{x}, t)}{\partial \mathbf{x}} - \boldsymbol{\lambda}(t_f) \right\} \\ &\quad + \int_{t_0}^{t_f} \left\{ \delta \mathbf{x}^T(t) \left[ \frac{\partial H(\mathbf{x}, \mathbf{u}, \boldsymbol{\lambda}, t)}{\partial \mathbf{x}} + \dot{\boldsymbol{\lambda}}(t) \right] + \delta \mathbf{u}^T(t) \left[ \frac{\partial H(\mathbf{x}, \mathbf{u}, \boldsymbol{\lambda}, t)}{\partial \mathbf{u}} \right] \right\} dt\end{aligned}\quad (5-25)$$

为了得到极小值的必要条件, 应该使一次差分为零。这样就得到确定了最优控制和状态向量的  $2n$  维微分方程组:

$$H = \Phi[\mathbf{x}(t), \mathbf{u}(t), t] + \boldsymbol{\lambda}^T(t) \mathbf{f}[\mathbf{x}(t), \mathbf{u}(t), t] \quad (5-26)$$

$$\frac{\partial H}{\partial \boldsymbol{\lambda}} = \dot{\mathbf{x}} = \mathbf{f}[\mathbf{x}(t), \mathbf{u}(t), t] \quad (5-27)$$

$$\frac{\partial H}{\partial \mathbf{x}} = -\dot{\boldsymbol{\lambda}} = \frac{\partial \mathbf{f}^T[\mathbf{x}(t), \mathbf{u}(t), t]}{\partial \mathbf{x}} \boldsymbol{\lambda}(t) + \frac{\partial \Phi[\mathbf{x}(t), \mathbf{u}(t), t]}{\partial \mathbf{x}} \quad (5-28)$$

$$\frac{\partial H}{\partial \mathbf{u}} = 0 = \frac{\partial \Phi[\mathbf{x}(t), \mathbf{u}(t), t]}{\partial \mathbf{u}} + \frac{\partial \mathbf{f}^T[\mathbf{x}(t), \mathbf{u}(t), t]}{\partial \mathbf{u}} \boldsymbol{\lambda}(t) \quad (5-29)$$

在初始时刻和终点时刻的条件为

$$\begin{aligned}\mathbf{x}(t_0) &= \mathbf{x}_0 \\ \boldsymbol{\lambda}(t_f) &= \frac{\partial \theta[\mathbf{x}(t_f), t_f]}{\partial \mathbf{x}(t_f)} \\ H[\mathbf{x}(t_f), \mathbf{u}(t_f), \boldsymbol{\lambda}(t_f), t_f] + \frac{\partial \theta[\mathbf{x}(t_f), t_f]}{\partial t_f} &= 0\end{aligned}\quad (5-30)$$

根据庞特里亚金极大值原理, 通过变分法得到的式 (5-27)~(5-29) 方程组达到哈密尔顿函数极大值的解确定了最优控制  $\mathbf{u}(t)$ 。根据泛函  $J$  的类型和不同的约束条件, 存在解决最优控制问题的各种近似方法, 如梯度法、惩罚函数法、伪线性化法。解最优控制问题的具体方法的选择取决于泛函的类型和不同的约束条件, 也取决于对所要解决问题精度的要求。

我们来看解最优控制问题的一个例子。该任务是要使品质准则

$$J = \frac{1}{2} (\mathbf{x}^T \mathbf{F}_f \mathbf{x})_{t=t_f} + \frac{1}{2} \int_{t_0}^{t_f} (\mathbf{x}^T \mathbf{S} \mathbf{x} + \mathbf{u}^T \mathbf{G} \mathbf{u}) dt \quad (5-31)$$

最小。式中,  $\mathbf{F}_f$  和  $\mathbf{S}$  是半正定矩阵,  $\mathbf{G}$  是正定矩阵。

系统由变系数的向量线性微分方程描述:

$$\dot{\mathbf{x}} = \mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{u} \quad (5-32)$$

其中,  $\mathbf{x}$  为  $n$  维向量,  $\mathbf{u}$  为  $m$  维向量,  $\mathbf{A}$  和  $\mathbf{B}$  是维数分别为  $n \times n$  和  $n \times m$  的矩阵。

必须将系统由某个初始状态  $\mathbf{x}(t_0)$  导入给定的终点状态:

$$\mathbf{x}(t_f) = 0$$

哈密尔顿函数由公式 (5-22) 确定, 即

$$H = \frac{1}{2} \mathbf{x}^T \mathbf{S} \mathbf{x} + \frac{1}{2} \mathbf{u}^T \mathbf{G} \mathbf{u} + \boldsymbol{\lambda}^T (\mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{u}) \quad (5-33)$$

从方程(5-28)和(5-29)我们得到

$$\dot{\lambda} = -\frac{\partial H}{\partial x} = -Sx - A^T \lambda$$

$$\frac{\partial H}{\partial u} = 0 = Gu + B^T \lambda$$

即

$$u = -G^{-1}B^T \lambda \quad (5-34)$$

将  $u$  的定义代入系统状态方程, 得到线性两点边界问题:

$$\begin{bmatrix} \dot{x} \\ \dot{\lambda} \end{bmatrix} = \begin{bmatrix} A & -BG^{-1}B^T \\ -S & -A^T \end{bmatrix} \cdot \begin{bmatrix} x \\ \lambda \end{bmatrix}$$

带有条件如  $x(t_0)$  给定, 则

$$\lambda(t_f) = F_f x(t_f)$$

借助过渡矩阵来解边界问题, 得到控制律:

$$u(t) = [G(t)]^{-1} B^T(t) P(t) x(t) \quad (5-35)$$

这里,  $P$  是黎卡提矩阵微分方程的解, 它应该被反时间积分:

$$-\dot{P} = A^T P + P A + P B G^{-1} B^T P + S \quad (5-36)$$

初始条件为  $P(t_f) = F$ 。

黎卡提方程的解析解和最优控制算法的定义使用在下层体系中用于建立飞行器控制算法。类似式(5-31)的品质准则反映了在将对象从选定的点转移到终点的过程中, 使实际轨迹与基准轨迹间偏差最小化的要求、终点的脱靶量最小的要求和控制作用的消耗最小的要求。

## 5.5 基于微分几何理论的对象模型精确线性化

将非线性系统线性化的一系列方法基本上可分为两类, 即近似线性化方法和精确线性化方法。近似线性化方法很早就已知并被广泛地应用在实践中, 用于分析系统性能指标和综合控制律, 其中包括在飞行器控制领域的应用。近似线性化方法的不足表现在: ①线性化只在挑选出的状态点的足够小的邻域内完成, 才能保证忽略模型中非线性函数的高阶项的前提条件成立; ②在线性化方程中考虑的不是全状态向量, 而是实际状态向量与挑选出的状态向量间的差, 该差称为扰动状态。因此, 近似线性化又称为小扰动线性化。当扰动在大范围内变化时, 往往不能运用这种方法。精确线性化不局限于选择固定状态和小邻域, 而是要找到变换, 在实施变换的条件下建立原系统和变换后系统间的同胚映射, 并且变换后系统是线性的。与近似线性化方法相比, 这种方法的优点是线性化是在流形中相对于全状态变量进行的, 不损失原系统的精度, 因而是精确线性化, 可适用于状态变量在任意范围内变化的情况。

寻找这种变换的一种有效途径是运用微分几何理论, 它确定了控制问题中的几何方法。近年来, 利用微分几何方法, 对非线性系统的精确线性化问题和解耦等问题, 取得了实质性的突破, 并在一些实际系统的控制中得到了应用。有观点认为, 微分几何方法

对于非线性控制系统的重要性类似于过去的 Laplace 变换、复变函数、线性代数等理论对于线性系统的重要性。

非线性系统的完全线性化依靠使用微分几何理论的非线性变换和非线性状态反馈实现。对本质非线性控制系统，考虑使用微分几何方法在找到的线性空间中形成线性控制律的可能性，然后依靠非线性反变换得到在原非线性空间中的实际控制作用。这样，就可以采用传统线性系统控制算法综合的方法，找到与非线性模型相吻合的解，成功地解决复杂非线性系统控制律的综合问题。

以下给出对于仿射非线性系统模型全局线性化的微分几何理论的基本结论。

微分几何理论是用于分析微分方程的连续变换组理论 (Lie 组)。微分方程的形式允许对作用在流形 (比线性空间  $R^n$  更一般的定义，在其中发生系统的运动) 上的连续组建立 Lie 代数和根据该代数的结构确定组本身性能。

在微分几何理论中使用了比线性空间更广泛的空间类型，称为微分流形，研究它的基本工具是曲线坐标。因此，不失一般性，我们可以把系统置于流形上进行分析，认为非线性系统的动态特性是由定义在流形上的向量场决定的。应用定义在微分流形上的向量场分析非线性系统的方法，就是非线性系统的微分几何方法。在局部的意义上， $m$  维流形中的每一个点的一个邻域可以和  $m$  维空间  $R^m$  的一个开子集  $U$  同胚。因此， $m$  维光滑流形存在  $m$  维切空间，且切空间中的向量具有局部坐标表示。

在实现被控对象模型精确线性化的过程中，使用到了以下的有关微分流形的基本概念和运算。

(1) 向量场的 Lie 导数。

设  $\mathbf{x} \in U \subset R^n$ ，在  $U$  上给出一个光滑标量函数  $\lambda(\mathbf{x})$  和一个  $n$  维的向量场  $\mathbf{f}(\mathbf{x})$ ，将通过下列运算：

$$L_f \lambda(\mathbf{x}) = L_f \lambda(x_1, x_2, \dots, x_n) = \sum_{i=1}^n \frac{\partial \lambda}{\partial x_i} f_i(x_1, x_2, \dots, x_n) = \frac{\partial \lambda}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}) \quad (5-37)$$

得到新的标量函数  $L_f \lambda(\mathbf{x})$ ，定义为  $\lambda(\mathbf{x})$  对向量场  $\mathbf{f}(\mathbf{x})$  的 Lie 导数。其中， $\frac{\partial \lambda}{\partial \mathbf{x}} =$

$\left( \frac{\partial \lambda}{\partial x_1}, \frac{\partial \lambda}{\partial x_2}, \dots, \frac{\partial \lambda}{\partial x_n} \right)$  是  $\lambda(\mathbf{x})$  的 Jacobi 矩阵。可以多次重复上述的运算，如先取  $\lambda(\mathbf{x})$  沿向量场  $\mathbf{f}(\mathbf{x})$  的导数，然后再取沿向量场  $\mathbf{g}(\mathbf{x})$  的导数，就可以定义新的函数，即

$$L_g L_f \lambda(\mathbf{x}) = \sum_{i=1}^n \frac{\partial L_f \lambda}{\partial x_i} g_i(\mathbf{x}) = \frac{\partial L_f \lambda}{\partial \mathbf{x}} \cdot \mathbf{g}(\mathbf{x}) \quad (5-38)$$

(2) 向量场的 Lie 括号。

对于定义在  $U$  上的两个  $n$  维的向量场  $\mathbf{f}(\mathbf{x})$ ,  $\mathbf{g}(\mathbf{x})$ ，可以定义向量场  $\mathbf{g}(\mathbf{x})$  对  $\mathbf{f}(\mathbf{x})$  的 Lie 导数，记为  $ad_f \mathbf{g}(\mathbf{x})$  或  $[\mathbf{f}, \mathbf{g}](\mathbf{x})$ ，称为  $\mathbf{f}(\mathbf{x})$  和  $\mathbf{g}(\mathbf{x})$  的 Lie 括号，借助于 Lie 括号获得新的向量场：

$$ad_f \mathbf{g}(\mathbf{x}) = [\mathbf{f}, \mathbf{g}](\mathbf{x}) = \frac{\partial \mathbf{g}}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}) - \frac{\partial \mathbf{f}}{\partial \mathbf{x}} \mathbf{g}(\mathbf{x}) \quad (5-39)$$

式中,  $\frac{\partial \mathbf{g}}{\partial \mathbf{x}}$ ,  $\frac{\partial \mathbf{f}}{\partial \mathbf{x}}$  分别表示  $\mathbf{f}(\mathbf{x})$  和  $\mathbf{g}(\mathbf{x})$  的 Jacobi 矩阵:

$$\frac{\partial \mathbf{g}}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial g_1}{\partial x_1} & \frac{\partial g_1}{\partial x_2} & \cdots & \frac{\partial g_1}{\partial x_n} \\ \frac{\partial g_2}{\partial x_1} & \frac{\partial g_2}{\partial x_2} & \cdots & \frac{\partial g_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial g_n}{\partial x_1} & \frac{\partial g_n}{\partial x_2} & \cdots & \frac{\partial g_n}{\partial x_n} \end{bmatrix}, \quad \frac{\partial \mathbf{f}}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \cdots & \frac{\partial f_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \cdots & \frac{\partial f_n}{\partial x_n} \end{bmatrix} \quad (5-40)$$

当  $\mathbf{g}(\mathbf{x})$  对  $\mathbf{f}(\mathbf{x})$  多次重复使用 Lie 括号后, 得到下列表达式:

$$ad_f^k \mathbf{g}(\mathbf{x}) = [\mathbf{f}, ad_f^{k-1} \mathbf{g}](\mathbf{x}) = \frac{\partial(ad_f^{k-1} \mathbf{g})}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}) - \frac{\partial \mathbf{f}}{\partial \mathbf{x}} ad_f^{k-1} \mathbf{g}(\mathbf{x}) \quad (5-41)$$

(3) 对合分布。

设向量场  $\mathbf{f}$  是定义在  $R^n$  的一个开子集  $U$  上的光滑映射, 它将  $U$  中任意一点  $\mathbf{x}$  映射为  $R^n$  空间中的一个  $n$  维向量。设有  $d$  个光滑向量场  $f_1, f_2, \dots, f_d$  都定义在开子集  $U$  上, 则对于任意  $\mathbf{x} \in U$ , 向量  $f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_d(\mathbf{x})$  可张成  $R^n$  的一个子空间。用  $\Delta(\mathbf{x})$  表示这个向量空间, 即

$$\Delta(\mathbf{x}) = \text{span}\{f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_d(\mathbf{x})\} \quad (5-42)$$

称  $\Delta$  是一个分布。

若对每个  $\mathbf{x}$ ,  $f(\mathbf{x}) \in \Delta(\mathbf{x})$ , 则称向量场  $f$  属于分布  $\Delta$ , 记为  $f \in \Delta$ 。

如果属于分布  $\Delta$  的向量场  $\tau_1, \tau_2$  的任意偶对的 Lie 括号  $[\tau_1, \tau_2]$  是属于  $\Delta$  的一个向量场, 即

$$\tau_1 \in \Delta, \quad \tau_2 \in \Delta \Rightarrow [\tau_1, \tau_2] \in \Delta \quad (5-43)$$

则分布  $\Delta$  称为对合的。

(4) Frobenius 定理。

定义在  $\mathbf{x} \in U \subseteq R^n$  中的分布  $\Delta = \text{span}\{f_1, f_2, \dots, f_d\}$  称为是完全可积的, 当且仅当存在  $n-d$  个标量函数  $h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_{n-d}(\mathbf{x})$  满足偏微分方程组:

$$\frac{\partial h_i}{\partial x_j} f_j = 0, \quad 1 \leq i \leq n-d, \quad 1 \leq j \leq d \quad (5-44)$$

Frobenius 定理: 一个非奇异分布  $\Delta$  是完全可积的, 当且仅当该分布是对合的。

Frobenius 定理提供了一类偏微分方程可解性的充要条件。

(5) 相对阶  $r$ 。

考察单输入-单输出仿射非线性系统:

$$\begin{cases} \frac{d\mathbf{x}}{dt} = \mathbf{f}(\mathbf{x}) + \mathbf{g}(\mathbf{x})u \\ y = h(\mathbf{x}) \end{cases} \quad (5-45)$$

式中,  $\mathbf{x} \in U \subseteq R^n$ ,  $\mathbf{f}, \mathbf{g}$  是光滑的向量场。设  $\mathbf{x}_0$  的邻域为  $U_0$ , 如果对  $\mathbf{x} \in U_0$ , 有

$$\begin{cases} L_g L_f^k h(\mathbf{x}) = 0, & k = 0, 1, \dots, r-2 \\ L_g L_f^{r-1} \neq 0 \end{cases}$$

则称系统 (5-45) 在  $x_0$  处具有相对阶  $r$ 。

(6) 非线性系统 (5-45) 的标准型。

**定理 5-1** 设系统 (5-45) 在  $x_0$  处相对阶为  $r (r \leq n)$ , 令

$$\begin{aligned}\varphi_1(\mathbf{x}) &= h(\mathbf{x}) \\ \varphi_2(\mathbf{x}) &= L_f h(\mathbf{x}) \\ &\vdots \\ \varphi_r(\mathbf{x}) &= L_f^{r-1} h(\mathbf{x})\end{aligned}$$

若  $r$  严格小于  $n$ , 则总能找到  $n-r$  个函数  $\varphi_{r+1}(\mathbf{x}), \varphi_{r+2}(\mathbf{x}), \dots, \varphi_n(\mathbf{x})$ , 使得映射

$$\boldsymbol{\varphi}(\mathbf{x}) = \begin{bmatrix} \varphi_1(\mathbf{x}) \\ \varphi_2(\mathbf{x}) \\ \vdots \\ \varphi_n(\mathbf{x}) \end{bmatrix}$$

在  $x_0$  处有非奇异的 Jacobi 矩阵。并且总是可以选择  $\varphi_{r+1}(\mathbf{x}), \varphi_{r+2}(\mathbf{x}), \dots, \varphi_n(\mathbf{x})$ , 使得

$$L_g \varphi_i(\mathbf{x}) = 0, \quad \forall r+1 \leq i \leq n, \quad \forall \mathbf{x} \in U_0$$

根据定理 5-1, 在  $x_0$  的邻域  $U_0$  内,  $\boldsymbol{\varphi}(\mathbf{x})$  的 Jacobi 矩阵可以作为一个局部坐标变换。

设变换

$$\mathbf{z} = \boldsymbol{\varphi}(\mathbf{x}) = \begin{bmatrix} \varphi_1(\mathbf{x}) \\ \varphi_2(\mathbf{x}) \\ \vdots \\ \varphi_n(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} h(\mathbf{x}) \\ L_f h(\mathbf{x}) \\ \vdots \\ L_f^{r-1} h(\mathbf{x}) \\ \lambda_1(\mathbf{x}) \\ \vdots \\ \lambda_{n-r}(\mathbf{x}) \end{bmatrix} \quad (5-46)$$

由于  $\mathbf{z} = \boldsymbol{\varphi}(\mathbf{x})$  在  $x_0$  处的 Jacobi 矩阵非奇异, 故  $\mathbf{x} = \boldsymbol{\varphi}^{-1}(\mathbf{z})$  存在。令

$$a(\mathbf{z}) = L_f^r h(\boldsymbol{\varphi}^{-1}(\mathbf{z}))$$

$$b(\mathbf{z}) = L_g L_f^{r-1} h(\boldsymbol{\varphi}^{-1}(\mathbf{z}))$$

则有

$$\frac{d\mathbf{z}_r}{dt} = a(\mathbf{z}) + b(\mathbf{z})u$$

而

$$\begin{aligned}\frac{d\mathbf{z}_{r+k}}{dt} &= \frac{\partial \varphi_{r+k}}{\partial \mathbf{x}} \frac{d\mathbf{x}}{dt} = \frac{\partial \lambda_k}{\partial \mathbf{x}} \frac{d\mathbf{x}}{dt} = L_f \lambda_k(\mathbf{x}) + L_g \lambda_k(\mathbf{x})u \\ &= L_f \lambda_k(\boldsymbol{\varphi}^{-1}(\mathbf{z})) \xrightarrow{\text{def}} q_{r+k}(\mathbf{z}), \quad 1 \leq k \leq n-r\end{aligned}$$

则在变换 (5-46) 下, 系统 (5-45) 的状态空间描述如下:

$$\left\{ \begin{array}{l} \frac{dz_1}{dt} = z_2 \\ \vdots \\ \frac{dz_{r-1}}{dt} = z_r \\ \frac{dz_r}{dt} = a(\mathbf{z}) + b(\mathbf{z})u \\ \frac{dz_{r+1}}{dt} = q_{r+1}(\mathbf{z}) \\ \vdots \\ \frac{dz_n}{dt} = q_n(\mathbf{z}) \\ y = z_1 \end{array} \right. \quad (5-47)$$

方程组 (5-47) 称为非线性系统 (5-45) 的标准型。

(7) 非线性系统精确线性化的充要条件。

**定理 5-2** 非线性系统  $\frac{dx}{dt} = f(x) + g(x)u$ , 在  $x_0 \in U_0$  可以精确线性化的充分必要条件是: 存在定义于  $U_0$  上的实值函数  $\lambda(x)$ , 使得

$$\left\{ \begin{array}{l} \frac{dx}{dt} = f(x) + g(x)u \\ y = \lambda(x) \end{array} \right. \quad (5-48)$$

在  $x_0$  处的相对阶为  $n$ 。

在满足定理 5-2 的条件下, 选取标准型坐标变换

$$\mathbf{z} = \varphi(\mathbf{x}) = \begin{bmatrix} \varphi_1(\mathbf{x}) \\ \varphi_2(\mathbf{x}) \\ \vdots \\ \varphi_n(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} h(\mathbf{x}) \\ L_f h(\mathbf{x}) \\ \vdots \\ L_f^{n-1} h(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_n \end{bmatrix} \quad (5-49)$$

和控制律

$$u = \frac{1}{b(\mathbf{z})}(-a(\mathbf{z}) + v) = \frac{1}{L_g L_f^{n-1} h(\mathbf{x})}(-L_f^n h(\mathbf{x}) + v) \quad (5-50)$$

式中,  $v$  为外部参考输入。由此可得到闭环系统的描述如下:

$$\left\{ \begin{array}{l} \frac{dz_1}{dt} = z_2 \\ \frac{dz_2}{dt} = z_3 \\ \vdots \\ \frac{dz_{n-1}}{dt} = z_n \\ \frac{dz_n}{dt} = v \end{array} \right. \quad (5-51)$$

(8) 多输入-多输出非线性系统的反馈线性化。

考察多输入—多输出仿射非线性系统：

$$\begin{cases} \frac{dx}{dt} = f(x) + \sum_{i=1}^m g_i(x)u_i \\ y_i = h_i(x), \quad i = 1, 2, \dots, m \end{cases} \quad (5-52)$$

对于系统 (5-52)，如果对  $x_0$  的一个邻域  $U$  及整数向量  $(r_1, r_2, \dots, r_m)$ ，下列条件满足：

$$\textcircled{1} L_{g_j} L_f^{k_j} h_i(x) = 0, \quad \forall x \in U, \quad 0 \leq j \leq m, \quad 0 \leq i \leq m, \quad 0 \leq k \leq r_i - 2;$$

\textcircled{2}  $m \times m$  矩阵

$$T(x) = \begin{bmatrix} L_{g_1} L_f^{r_1-1} h_1(x) & L_{g_2} L_f^{r_1-1} h_1(x) & \cdots & L_{g_m} L_f^{r_1-1} h_1(x) \\ L_{g_1} L_f^{r_2-1} h_2(x) & L_{g_2} L_f^{r_2-1} h_2(x) & \cdots & L_{g_m} L_f^{r_2-1} h_2(x) \\ \vdots & \vdots & & \vdots \\ L_{g_1} L_f^{r_m-1} h_m(x) & L_{g_2} L_f^{r_m-1} h_m(x) & \cdots & L_{g_m} L_f^{r_m-1} h_m(x) \end{bmatrix} \quad (5-53)$$

在  $x_0$  处非奇异，则称系统 (5-52) 在  $x_0$  处有一个向量相对阶  $(r_1, r_2, \dots, r_m)$ 。

当  $r_1 + r_2 + \dots + r_m = n$  时，令  $Z = (z_1, z_2, \dots, z_m)^T$ ，其中  $z_i = (z_{i1}, z_{i2}, \dots, z_{ir_i})^T$ ，可取局部坐标变换  $Z = \varphi(x)$  为

$$z_{11} = \varphi_1^1, \dots, z_{1r_1} = \varphi_1^{r_1}, \quad z_{21} = \varphi_2^1, \dots, z_{2r_2} = \varphi_2^{r_2}, \dots, z_{mr_m} = \varphi_m^{r_m}$$

式中，

$$\begin{cases} \varphi_1^1 = h_1(x), \varphi_1^2 = L_f h_1(x), \dots, \varphi_1^{r_1} = L_f^{r_1-1} h_1(x) \\ \varphi_2^1 = h_2(x), \varphi_2^2 = L_f h_2(x), \dots, \varphi_2^{r_2} = L_f^{r_2-1} h_2(x) \\ \vdots & \vdots \\ \varphi_m^1 = h_m(x), \varphi_m^2 = L_f h_m(x), \dots, \varphi_m^{r_m} = L_f^{r_m-1} h_m(x) \end{cases} \quad (5-54)$$

在此坐标下有

$$\begin{bmatrix} \frac{dz_{1r_1}}{dt} \\ \frac{dz_{2r_2}}{dt} \\ \vdots \\ \frac{dz_{mr_m}}{dt} \end{bmatrix} = \begin{bmatrix} L_f^{r_1} h_1(x) \\ L_f^{r_2} h_2(x) \\ \vdots \\ L_f^{r_m} h_m(x) \end{bmatrix} + \begin{bmatrix} \sum_{j=1}^m L_{g_j} L_f^{r_1-1} h_1(x) u_j \\ \sum_{j=1}^m L_{g_j} L_f^{r_2-1} h_2(x) u_j \\ \vdots \\ \sum_{j=1}^m L_{g_j} L_f^{r_m-1} h_m(x) u_j \end{bmatrix} = b(x) + T(x)u$$

由相对阶的定义， $T(x)$  非奇异，令  $u = T^{-1}(x)[-b(x) + v]$ ， $v$  为新的参考输入，则有

$$\begin{bmatrix} \frac{dz_{1r_1}}{dt} \\ \frac{dz_{2r_2}}{dt} \\ \vdots \\ \frac{dz_{mr_m}}{dt} \end{bmatrix} = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_m \end{bmatrix} \quad (5-55)$$

综上所述, 当相对阶  $r = \sum_{i=1}^m r_i = n$ , 在局部坐标变换  $Z = \varphi(x)$  和反馈变换  $u = T^{-1}(x)[-b(x) + v]$  之下, 系统 (5-52) 可变换为线性系统, 即

$$\begin{cases} \frac{dz}{dt} = Az + bv \\ y = Cz \end{cases} \quad (5-56)$$

式中,

$$A = \begin{bmatrix} A_1 & & & \\ & A_2 & & \\ & & \ddots & \\ & & & A_m \end{bmatrix}_{n \times n}, \quad A_i = \begin{bmatrix} 0 & I_{r_i-1} \\ 0 & 0 \end{bmatrix}_{r_i \times r_i}, \quad B = \begin{bmatrix} b_1 & & & \\ & b_2 & & \\ & & \ddots & \\ & & & b_m \end{bmatrix}_{n \times m},$$

$$b_i = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix}_{r_i \times 1}, \quad C = \begin{bmatrix} c_1 & & & \\ & c_2 & & \\ & & \ddots & \\ & & & c_m \end{bmatrix}_{m \times n}, \quad c_i = [1, 0, \dots, 0]_{1 \times r_i}$$

式 (5-56) 是一个可控可观测的线性系统, 而每个控制输入  $v_i$  仅控制  $z_i$ , 也仅对输出  $y_i = z_{ii}$  有影响, 即控制输入与输出之间实现了单对单的解耦, 系统 (5-52) 得到了精确线性化。式 (5-56) 称为多输入-多输出非线性系统的积分器串联正则标准型。

为综合坐标  $z$  下系统的控制律, 可以使用线性系统的任一方法找到控制作用  $v = (v_1, v_2, v_3, \dots, v_m)$ , 然后借助非线性反馈  $u = T^{-1}(x)[-b(x) + v]$  得到原系统在坐标  $x$  下的物理上的原控制  $u$ 。

## 5.6 飞行器控制继电调节器的研制

飞行器在空间的运动方程具有下列形式:

$$\begin{cases} \frac{dX_g}{dt} = V \cos\theta \cos\psi \\ \frac{dY_g}{dt} = V \sin\theta \cos\psi \\ \frac{dZ_g}{dt} = -V \cos\theta \sin\psi \end{cases} \quad (5-57a)$$

$$\begin{cases} \frac{d\gamma}{dt} = \omega_{xd} - \tan\theta \cos\gamma \omega_{yd} + \tan\theta \sin\gamma \omega_{zd} \\ \frac{d\varphi}{dt} = \frac{\cos\gamma}{\cos\theta} \omega_{yd} - \frac{\sin\gamma}{\cos\theta} \omega_{zd} \\ \frac{d\theta}{dt} = \sin\gamma \omega_{yd} + \cos\gamma \omega_{zd} \end{cases} \quad (5-57b)$$

$$\begin{cases} m \frac{dV}{dt} = -G \sin\theta - W + P \cos\alpha \cos\beta \\ mV \frac{d\theta}{dt} = -G \cos\theta + L_y \cos\gamma_c + L_z \sin\gamma_c + P (\cos\gamma_c \sin\alpha - \sin\gamma_c \cos\alpha \sin\beta) \\ -mV \cos\theta \frac{d\psi}{dt} = -L_y \sin\gamma_c + L_z \cos\gamma_c + P (-\sin\gamma_c \sin\alpha - \cos\gamma_c \cos\alpha \sin\beta) \end{cases} \quad (5-57c)$$

$$\begin{cases} J_x \frac{d\omega_{xd}}{dt} = M_{xd} + (J_y - J_z)\omega_{yd}\omega_{zd} \\ J_y \frac{d\omega_{yd}}{dt} = M_{yd} + (J_z - J_x)\omega_{zd}\omega_{xd} \\ J_z \frac{d\omega_{zd}}{dt} = M_{zd} + (J_x - J_y)\omega_{xd}\omega_{yd} \end{cases} \quad (5-57d)$$

式中,  $X_g$ ,  $Y_g$ ,  $Z_g$  是飞行器在水平坐标系中的位置坐标;  $V$ ,  $\theta$ ,  $\psi$  是速度、速度倾角及速度偏角;  $\varphi$ ,  $\vartheta$ ,  $\gamma$  是飞行器方位角、俯仰角和横滚角;  $\omega_{xd}$ ,  $\omega_{yd}$ ,  $\omega_{zd}$  是飞行器绕质心运动的速度在固联坐标系中的投影;  $\gamma_c$  是速度倾角;  $G$  是重力;  $P$  是发动机推力;  $L_y$ ,  $L_z$  是法向和横向的气动升力;  $W$  是迎头阻力;  $M_{xd}$ ,  $M_{yd}$ ,  $M_{zd}$  是气动力矩在固联坐标系中的投影;  $\alpha$ ,  $\beta$  是攻角和侧滑角;  $m$  是飞行器质量;  $J_x$ ,  $J_y$ ,  $J_z$  是飞行器的转动惯量。

当只考虑飞行器在垂直平面内的运动时, 方程 (5-57) 简化为

$$\begin{cases} \frac{dX_g}{dt} = V \cos\theta \\ \frac{dY_g}{dt} = V \sin\theta \\ \frac{d\vartheta}{dt} = \omega_{zd} \\ m \frac{dV}{dt} = -G \sin\theta - W + P \cos\alpha \\ mV \frac{d\theta}{dt} = -G \cos\theta + L_Y + P \sin\alpha \\ J_z \frac{d\omega_{zd}}{dt} = M_{zd} \end{cases} \quad (5-58)$$

为计算气动力和气动力矩, 通常使用简化模型, 将它们用相应的气动力和气动力矩系数来表示。

忽略关于速度大小的方程, 得到关于  $\theta$ ,  $\vartheta$ ,  $\omega_{zd}$  的方程:

$$\begin{cases} \frac{d\theta}{dt} = k_1 \cos\theta + k_{21}(\vartheta - \theta) + k_3 \sin(\vartheta - \theta)P + k_{22}\delta \\ \frac{d\vartheta}{dt} = \omega_{zd} \\ \frac{d\omega_{zd}}{dt} = k_{42}(\vartheta - \theta) + k_5 \omega_{zd} + k_{41}\delta \end{cases} \quad (5-59)$$

式中,  $\delta$  是气动舵偏角;  $k_1, k_{21}, k_{22}, k_3, k_{41}, k_{42}, k_5$  是导入系数, 取决于气动力、气动力矩系数、对象质量、转动惯量、重力加速度、攻角、马赫数、空气密度, 并在飞行器一定的飞行模式下被看做冻结参数, 具体定义如下:

$$\begin{aligned} k_1 &= -\frac{G}{mV}, \quad k_{21} = \frac{c_y^\alpha QS_{\text{ref}}}{mV}, \quad k_{22} = \frac{c_y^\delta QS_{\text{ref}}}{mV}, \quad k_3 = \frac{1}{mV}, \\ k_{41} &= \frac{m_z^\delta QS_{\text{ref}} b}{J_z}, \quad k_{42} = \frac{m_z^\alpha QS_{\text{ref}} b}{J_z}, \quad k_5 = \frac{m_z^{\omega_{zd}} QS_{\text{ref}} b}{J_z} \cdot \frac{b}{V} \end{aligned}$$

式中,  $Q = \frac{1}{2}\rho V^2$ , 为动压;  $\rho$  为空气密度;  $S_{\text{ref}}$  为气动参考面积;  $b$  为平均气动弦长;  $c_y^\alpha, c_y^\delta$  分别为法向气动升力系数的功角分量和舵偏角分量;  $m_z^\alpha, m_z^\delta$  分别为法向稳定气动力矩系数和控制力矩系数;  $m_z^{\omega_{zd}}$  为法向气动阻尼力矩系数。

将方程 (5-59) 写为仿射非线性系统的标准形式, 得到

$$\dot{\mathbf{x}} = f(\mathbf{x}) + \sum_{i=1}^2 \mathbf{g}_i(\mathbf{x}) \mathbf{u}_i \quad (5-60)$$

式中,

$$\begin{aligned} \mathbf{x} &= \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} \theta \\ \vartheta \\ \omega_{zd} \end{bmatrix}, \quad \mathbf{f}(\mathbf{x}) = \begin{bmatrix} k_1 \cos \theta + k_{21}(\vartheta - \theta) \\ \omega_{zd} \\ k_{42}(\vartheta - \theta) + k_5 \omega_{zd} \end{bmatrix} \\ \mathbf{g}_1(\mathbf{x}) &= \begin{bmatrix} k_3 \sin(\vartheta - \theta) \\ 0 \\ 0 \end{bmatrix}, \quad \mathbf{g}_2(\mathbf{x}) = \begin{bmatrix} k_{22} \\ 0 \\ k_{41} \end{bmatrix} \\ \mathbf{u} &= \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = \begin{bmatrix} P \\ \delta \end{bmatrix} \end{aligned}$$

按下列形式选择输出函数  $h_1(\mathbf{x}), h_2(\mathbf{x})$ :

$$\begin{cases} h_1(\mathbf{x}) = \theta \\ h_2(\mathbf{x}) = \vartheta \end{cases} \quad (5-61)$$

按由  $\mathbf{g}(\mathbf{x})$  确定的向量场进行输出函数的微分运算, 得到

$$\left\{ \begin{array}{l} L_{\mathbf{g}_1} h_1(\mathbf{x}) = k_3 \sin(\vartheta - \theta) \\ L_{\mathbf{g}_2} h_1(\mathbf{x}) = k_{22} \\ L_{\mathbf{g}_1} h_2(\mathbf{x}) = 0 \\ L_{\mathbf{g}_2} h_2(\mathbf{x}) = 0 \\ L_{\mathbf{g}_1} L_f h_2(\mathbf{x}) = 0 \\ L_{\mathbf{g}_2} L_f h_2(\mathbf{x}) = k_{41} \end{array} \right. \quad (5-62)$$

那么有如下等式成立:

$$\mathbf{B}(\mathbf{x}) = \begin{bmatrix} L_{\mathbf{g}_1} h_1(\mathbf{x}) & L_{\mathbf{g}_2} h_1(\mathbf{x}) \\ L_{\mathbf{g}_1} L_f h_2(\mathbf{x}) & L_{\mathbf{g}_2} L_f h_2(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} k_3 \sin(\vartheta - \theta) & k_{22} \\ 0 & k_{41} \end{bmatrix} \quad (5-63)$$

如果满足条件  $\vartheta \neq \theta$ , 则矩阵  $\mathbf{B}(\mathbf{x})$  的行列式值不为零。在这种情况下, 系统

(5-63) 具有向量相对阶  $r_1=1, r_2=2$ , 而  $r=r_1+r_2=3$ , 即等于系统自身的维数。

根据微分几何理论关于多输入—多输出非线性系统可反馈线性化的充要条件, 模型(5-59) 借助非线性变换 (5-61) 和非线性状态反馈

$$\mathbf{u} = \mathbf{B}^{-1}(\mathbf{x}) \times [-\mathbf{A}(\mathbf{x}) + \mathbf{v}] \quad (5-64)$$

可以完全线性化。式中,

$$\mathbf{A}(\mathbf{x}) = \begin{bmatrix} k_1 \cos \theta + k_{21}(\vartheta - \theta) \\ k_{42}(\vartheta - \theta) + k_5 \omega_{zd} \end{bmatrix} \quad (5-65)$$

而

$$\mathbf{v} = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix}$$

为变换后的等效控制。

线性化后我们得到新模型形式为

$$\begin{cases} \frac{dy_1}{dt} = v_1 \\ \frac{dy_2}{dt} = \omega_{zd} \\ \frac{d\omega_{zd}}{dt} = v_2 \end{cases} \quad (5-66)$$

式中,  $y_1=\theta$ ,  $y_2=\vartheta$ 。

与关于位置的方程相结合得到下列完全的方程:

$$\begin{cases} \frac{dX_g}{dt} = V \cos \theta \\ \frac{d\theta}{dt} = v_1 \\ \frac{d\vartheta}{dt} = \omega_{zd} \\ \frac{d\omega_{zd}}{dt} = v_2 \end{cases} \quad (5-67)$$

由模型 (5-67) 所描述的系统可以看做在状态向量间和控制作用间不存在交联的两个独立的线性子系统。同模型 (5-58) 相比, 使用模型 (5-67) 可以从本质上简化设计过程。模型 (5-67) 具有线性系统的最简单形式, 对每个子系统可以单独实施控制, 有一整套在实践中深入研究过的方法可用来对其综合控制算法, 找到控制作用  $\mathbf{v}=(v_1, v_2)^T$ 。然后, 借助于非线性反馈式 (5-64), 得到实际状态下的控制作用  $\mathbf{u}$ , 即发动机推力和气动舵偏角的改变规律, 并将其施加于物理对象。

实际的控制作用  $\mathbf{u}$  将具有下列形式:

$$\begin{bmatrix} P \\ \delta \end{bmatrix} = \frac{1}{k_{41}k_3 \sin(\vartheta - \theta)} \left\{ \begin{bmatrix} -k_{41}k_1 \cos \theta - k_{41}k_{21}(\vartheta - \theta) + \\ k_{22}k_{42}(\vartheta - \theta) + k_{22}k_5 \omega_{zd} \\ -k_3k_{42}(\vartheta - \theta) \sin(\vartheta - \theta) - \\ k_3k_5 \omega_{zd} \sin(\vartheta - \theta) \end{bmatrix} + \begin{bmatrix} k_{41} & -k_{22} \\ 0 & k_3 \sin(\vartheta - \theta) \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} \right\} \quad (5-68)$$

当矩阵  $B(x)$  的行列式值等于零, 即不能够将原系统导入线性空间时, 就在原非线性模型(5-58)的基础上综合控制算法。这样就得到飞行器控制的继电调节器形式:

$$v = \begin{cases} -kx \\ -F(x) \end{cases} \quad (5-69)$$

这里, 第一个方案对应可以实施线性化变换的情况, 第二个方案对应在不满足变换的条件下使用非线性算法, 其特点为复杂和工作不稳定。

## 5.7 本章内容小结

本章介绍了研制无人飞行器智能控制系统控制算法的工作。对现代无人飞行器控制系统提出的精确要求, 需要在其设计时使用非线性控制算法。但是非线性算法实现复杂, 因此, 提出了在不损失精度的条件下减少计算的任务。作者提出了运用微分几何理论来解决这个问题的一种有效途径。运用微分几何理论, 在无人飞行器运行的过程中挑选出这样一些区间, 在其间借助非线性状态变换和非线性反馈, 实现了系统模型的精确线性化, 使得可以应用相应的线性调节器来完成控制任务, 大大简化了控制器设计的工作量。在此基础上研制出了继电调节器, 其在符合线性模型的区间, 可以借助于线性调节器实现控制, 而在余下的区间, 借助于非线性控制算法来实现。

除了将微分几何理论用于飞行器控制模型的线性化外, 还可将它用于在长时间自主运行模式下飞行器惯性导航系统误差预测模型的线性化。在具有智能组件的导航系统中, 在确定导航系统状态向量各分量的观测度指标时, 将用到惯导系统误差的线性化模型参数。

如同飞行器动力学模型一样, 在惯导系统误差模型的结构预先给定的条件下, 可以进行相似的变换, 而带有给定结构的惯导系统误差的具体模型参数可以通过自组织方法找到。

本章还给出了作者将“功能—智能系统”用于无人飞行器控制所研制出的实现控制算法的2级体系框图。在上层体系中考虑到精度要求和其他的外部条件, 进行飞行器最佳运行场景的综合, 而下层控制则保证最佳场景的实现。

# 第6章 返回大气层式无人飞行器 智能控制系统的“系统生成”

## 6.1 问题的提出

返回大气层式无人飞行器为了有效地完成给定的任务，通常具有沿不同轨迹移动的可能性。在实际应用中，常常使用三种类型的运动轨迹：无控轨迹，有控轨迹，具有最终滑行段运动的有控轨迹。每个无人飞行器预先被规划好按照某种具体的轨迹飞行，这降低了无人飞行器完成给定任务的有效性。

作者给出了一种很有前景的无人飞行器完成控制任务的新方法，即综合智能控制系统。智能系统安装在无人飞行器上，可以根据运动轨迹、外部环境及其他情况，在对事件可能的发展情况进行预测的基础上实现运动场景的选择。

智能系统包含各种各样的算法保障，它们的组成和配置在智能系统运行过程中将发生改变。鉴于此，考虑到智能系统“系统生成”的各个阶段算法保障的特殊性，有必要为其活动的每一个阶段研制相应的算法保障。

本章以具有功能结构的返回大气层式无人飞行器智能控制系统的运行为例，展示实现行动感知器时算法保障的选择。使用智能系统来控制无人飞行器，由于不要求已知关于飞行器运动场景的大量先验信息，因而可以提高飞行器的有效性。甚至在算法、准则和准则的阈值均已知的情况下，也保留了飞行器运动场景选择的不唯一性，该不唯一性是由飞行器测量设备的个体特点所决定的。

## 6.2 返回大气层式无人飞行器智能控制系统的运行过程

智能系统综合的有前景的发展方向之一是专家系统、自组织方法、决策方法、自适应控制方法和目标形成算法的共生，将它们连接起来置于阿诺辛提出的功能结构框架之下，即“功能—智能系统”。这样的智能系统是复杂的功能系统，这些功能系统又由一组更简单的功能系统组成。智能系统的结构如图1-3所示。

目标综合在考虑到外部（周围）环境、智能系统自身的状态及动机的信息，在存在记忆的条件下实现。然后动态专家系统进行评价，该评价作为决策的基础，同时在行动感知器中实现估计。当决策产生之后，就实现控制。

下一步，对对象的控制作用的结果进入行动感知器。关于作用结果与预测符合度的

信息将传递到专家系统和目标综合系统。这样，当作用结果与预测不一致时，便产生新的专家评价，做出另外的决策，并实现新的控制作用。在一致性不可能达到的情况下，智能系统的目标发生改变。如果作用结果与预测符合，则说明控制选择成功，达到了智能系统的目标。

按照所给出的框图，将智能系统综合的全局问题划分为几个任务。

智能系统目标综合的任务是建立或改进已有的获得周围环境信息的方法和手段，还必须有确定智能系统整体、其组成元素和独立的功能系统状态的方法。在形成目标时，要求有关于智能系统状态的准确信息，还要求有足以实现给出目标的广泛的知识库。

智能系统运行的目标在不断增长的数据库和动机机制下形成。通常在实际应用中，实现动机机制的功能系统是进行目标选择的规则和准则群。实现动机功能的功能系统是智能系统中最复杂的系统。

无人飞行器智能系统的动机机制适宜于通过包含相对较少的准则群的紧凑算法来实现（泰勒动机理论）。选择这种实现方式的原因是由于安装在动态对象上的测量系统和相对于动态对象的外部信息系统是有限的。

在智能系统运行的过程中预先考虑了将某些简单的功能系统复杂化的可能。例如，当新信息来到时，专家系统的数据库扩大，而当智能系统运行条件变化时，用自组织算法建立的预测数学模型将随之改变。

在“功能—智能系统”中，适宜于考虑系统复杂化算法，它可以提高系统运行的品质、存活率以及提高完成给定的和在工作过程中独立形成的任务的精度。

在发展的当前阶段，智能系统不能完全独立地存在。一定程度上的独立性留给它用于获得经验和达到完善，这使得智能系统能更好地完成系统研制者确定的任务和使命。研制者所致力达到的智能系统发展的顶点是高度组织性的生物的各种相似形。生物进化的主导机制之一是有益的适应结果和作为这种结果的基础的自我保存的反射作用。无人飞行器智能控制系统的使命是使动态对象沿最优轨迹（在使用的准则群的意义上）朝选定的目标移动，并具有最小的终点偏差。通常在动态对象运动时，轨迹的选择是在考虑到最大限度的自我保存的条件下依靠给出的智能系统的功能结构来实现的。如果在动态对象运行的最后阶段发生了它的自我毁灭，那么这种情况与使用动态对象智能控制系统的功能结构的可能性和依据性并不矛盾。所假定的智能系统独立性的限制基本上通过动机机制来达到。在实现动态对象智能控制系统动机模块时，适宜于使用社会性生物动机机制的相似形。社会性生物的动机有别于具有独居生命方式的生物，区别在于运行目标选择时优先权的偏移。在社会性生物中可观察到牺牲个体的自我保存而得到的相互救助，即由于保存组织而抑止自我保存的反射作用。这是因为社会性生物并不以自我保存作为第一目标，而有更高的目标，即保全社会性组织。

这样，功能结构可以使用在无人飞行器智能控制系统的综合中。在动机模块中，必须要考虑根据无人飞行器运行的阶段来改变目标选择准则的权系数，或者在动态对象运行的最后阶段使用某种规划好的控制算法。

## 6.3 智能系统“系统生成”的基本阶段

为了制定出实现智能系统复杂化的方案，可以借鉴生物中的现象。这样做的适宜性可由生物与所研究的智能系统具有相似的体系构成来解释。“系统生成”是指在智能系统工作的整个区间功能系统的形成过程。根据与生物“系统生成”的类比，它描述了在生物发展的各个年龄时期功能系统的形成，可以将智能系统的“系统生成”划分为表征系统状态的类型或者阶段，如“生成前阶段”和“出生后阶段”。智能系统组成中的功能系统应达到一定的发展水平，该水平由智能系统组织的复杂度、它的用途和运行的环境条件所确定。在实际应用中，智能系统的功能系统发展的充分度水平由研制者在系统设计阶段决定。例如，无人飞行器智能控制系统在“生成前阶段”考虑了在动态数据库中存在所允许的空中飞行通道的周围环境的有关参数信息，考虑了用于全局反馈回路中建立模型的基函数组，考虑了对应于不同运行场景的飞行器参数值。这些信息使得智能系统在“系统生成”的“出生后阶段”能够完成以下功能：使全局反馈回路中和周围环境中的参数模型复杂化（准确化），同时实现飞行器运行场景的最优选择。最优化理解为包含飞行器运行自身参数、外部环境状态和终点偏差的目标函数的动态品质泛函的最小化。

与经典的“系统生成”不同，有关“系统生成”的现代概念被扩展了，它包含了在最大限度发展状态下智能系统运行过程的描述，还包含了由外部环境破坏性影响所制约的逐渐解体、损耗、老化、存活水平降低等状态下的运行过程的描述。

出生后的“系统生成”可划分为三个阶段：①运行过程中智能系统的发展；②带有所有功能系统最大限度发展的智能系统运行周期的描述；③智能系统有效性降低阶段，即完成系统运行周期的最终阶段。

在“系统生成”的所有阶段，均将有益的适应结果作为发展的主导因素。

在“生成前阶段”，智能系统的研制者基于先验数据、合理的想法，根据所采用的智能系统综合的概念决定所有功能系统的发展水平。功能系统的这一发展水平应该保证智能系统在自主模式下能顺利地运行。

从智能系统自主运行的最初阶段起，在与外界环境接触中进行了各种不同信息的搜集。在出生后“系统生成”的第一阶段进行动态数据库的积极扩充，进行目标形成这一功能系统中记忆模块的填充和全局反馈回路中预测模型的建立。这之后，实现伴随着天信息的不断增长的智能系统最大程度地有效运行。

出生后“系统生成”的第二阶段的特点是智能系统所有功能系统充满了各种信息。在这一阶段功能系统使用另外的算法用于处理信息，因为只需要更新信息，而对于保存和处理新信息，没有必要形成新结构，常常也没有技术实现的可能性。学习过程和智能系统结构的复杂化过程在出生后“系统生成”的第一阶段完成。在它的第二阶段实现智能系统在最大可能发展水平上的最有效地运行，这与成熟生物的状态相类似。

智能系统在出生后“系统生成”的第二阶段的运行伴随着自适应程度的降低。因此，在智能系统中适宜于考虑当智能系统运行的外部环境有实质性改变和目标有剧烈变

化的条件下，提高自适应程度的可能性。例如，在全局反馈回路中适宜于采用带有储备趋势项的自组织算法。

智能系统“系统生成”第三阶段的特点是大多数功能系统有效性的降低。这一阶段的这种特殊性是由于能源的枯竭而造成的。在这一阶段，智能系统仅够保证最重要的功能系统的工作。例如，在返回大气层式无人飞行器智能系统中，第三阶段对应于运行的结束阶段，在其终点通常只有某一个功能系统工作，而剩余的系统被切断，因为采用它们被认为是不适宜的。剩余的能源集中起来为某一个功能系统的工作提供保证。

在智能系统工作的所有阶段都要进行功能系统的能源保证的最优化，并且使得在部件生命周期结束时，能源储备趋近于零。在智能系统运行的整个区间不只进行能源消耗的最优化，也进行用于解决智能系统的当前任务及其他所动用的功能结构的信息资源的消耗的最优化。

动态对象通常运行在外部刺激因素很少改变的条件下，即动态对象智能系统被弱激励。在这样的条件下必须要考虑足够积极地形成功能系统，使它们能够满足要求地响应剧烈变化的动态对象运行条件。在出生后“系统生成”的第一阶段，当缺乏传入性信息时，如何积极形成功能系统，对智能系统的理论和实践而言都是复杂和极其迫切的任务。在进行智能系统的综合时，必须考虑到功能的最小保证原则。功能的最小保证原则是智能系统适应外部环境的基本条件。在出生前的“系统生成”阶段，智能系统在功能的最小保证原则基础上得到发展，而在出生后“系统生成”的第一阶段产生对外部环境改变的更准确的适应。

## 6.4 返回大气层式无人飞行器运动的各阶段行动感知器的运行过程

以全局反馈回路的综合为例，来演示动态对象智能控制系统“系统生成”每一阶段的特殊性。在全局反馈回路中的基本算法是行动感知器中基于自组织方法的预测模型建立算法。

预测模型有如下形式：

$$\varphi(x) = \sum_{i=1}^L a_i \mu_i(f_i, x) \quad (6-1)$$

式中， $L$  是模型中基函数的数目； $\mu_i$  是来自参数集合中的基函数； $F_p = \{a_i \mu_i(f_i, x) \mid i=1, \dots, L\}$ ，是基函数组。每个基函数根据二维的参数向量  $(a_i, f_i)^T$  来确定，其中， $a_i$  是幅值， $f_i$  是频率。

在“系统生成”的第一阶段，在形成行动感知器时使用了自组织算法中最丰富的基函数的储备。选择准则群基本上包含了如正规性指标和收敛度指标这样的一些指标。

正规性指标是在检查样本  $N_B$  上计算的均方误差 $\Delta^2$ ，即

$$\Delta^2 = \frac{\sum_{i=1}^{N_B} (z_i - \hat{x}_i)^2}{\sum_{i=1}^{N_B} z_i^2} \quad (6-2)$$

式中,  $z_i$  是测量的值,  $\hat{x}_i$  是根据模型预测的值。

有限差分模型单步积分收敛度准则形式如下:

$$I = \frac{\sum_{i=1}^N (\hat{x}_i - z_i)^2}{\sum_{i=1}^N z_i^2} \quad (6-3)$$

式中,  $I$  是在整个插值区间上的单步积分误差值, 该区间包括训练样本  $N_A$  和检查样本  $N_B$ , 即  $N = N_A + N_B$ 。

第二阶段的特点是无人飞行器在弱干扰环境中运动, 因此, 适宜于用带有储备趋势项的自组织算法和极少的基函数来建立模型。

第三阶段假定无人飞行器智能控制系统所有资源枯竭和无人飞行器生命周期结束。在本阶段建议使用本书第 4 章中作者提出的改进型 Demark 趋势项算法来建立模型。通常在这一阶段有强干扰作用于动态对象, 测量样本少, 且模型建立和准确化的时间有限。因此, 动态对象运动场景的选择适宜于在对简单的线性预测模型分析的基础上完成。可以使用 Demark 趋势项的相似形作为简单的线性预测模型。Demark 建议“自右向左”建立过程的趋势项, 以此最大程度地考虑“测量老化”效应。与传统的 Demark 趋势项不同, 所建议的改进型使用的不是两点测量, 而是整个测量样本。

在本阶段, 测量样本如在自组织算法中一样划分为训练样本和检查样本。趋势项被筛选, 改进型的 Demark 趋势项的结构为以下形式:

$$\hat{x}_{2k} = \hat{x}_{1k} + c_k \quad (6-4)$$

式中,  $\hat{x}_{2k}$  是动态对象智能系统状态变量的预测量;  $\hat{x}_{1k}$  为采用式 (4-36) 得到的线性趋势项;  $c_k$  为用自组织方法建立的残差的非线性修正项, 具有如下形式:

$$c_k = \sum_{i=1}^L a_i \mu_i(f_i, x) \quad (6-5)$$

使用函数代替系数可以对所发生的变化特性有更准确的描述。描述函数可以从基函数的标准集合中选择。

借助一个通用的准则式 (6-2) 进行改进型趋势项的筛选。根据被预测的状态变量的物理意义, 可以使用某个特殊的选择准则。例如, 在预测轨迹参数时, 使用与给定的动态对象运动轨迹的偏差值作为选择指标。

数学仿真的结果显示了返回大气层式无人飞行器智能控制系统全局反馈回路中行动感知器工作的有效性。使用智能系统自组织算法对传统 Demark 趋势项进行改进可以提高预测的精度, 相应地, 可提高行动感知器的精度。

## 6.5 本章内容小结

本章介绍了返回大气层式无人飞行器智能控制系统的算法组成。通过对无人飞行器智能控制系统“系统生成”的分析, 给出了在无人飞行器生命周期的不同阶段使用具体类型算法保障的建议。

本章研究了返回大气层式无人飞行器运行的三个基本阶段，分析了每个阶段无人飞行器运行的特殊性，在该分析的基础上选择了实现行动感知器的特殊算法保障。

第一阶段假定不存在关于对象和外部环境参数的信息。在这一阶段建议在行动感知器中使用带有足够丰富基函数的自组织算法。

第二阶段的特点是无人飞行器在弱扰动环境中运动。因此，适宜于采用带有储备趋势项的自组织算法和极少的基函数用于建立模型。

第三阶段假定无人飞行器智能控制系统所有资源枯竭和无人飞行器生命周期结束。这一阶段建议使用在第 4 章中提出的改进型 Demark 趋势项算法。

这样就给出了无人飞行器智能控制系统“系统生成”的全过程，并在对其运行特殊性分析的基础上给出了智能控制系统行动感知器的算法保障。

## 第7章 算法的仿真研究

在将“功能—智能系统”用于飞行器的控制中，作者提出了用自组织算法对传统的 Demark 趋势项进行改进的方法，获得了具有独创性的改进型 Demark 趋势项，可用于飞行器智能控制系统中行动感知器的综合、建立飞行器运动参数预测模型，既满足无人飞行器机载算法快速性、紧凑性的特殊要求，又保证了必需的精度。

为了验证改进型 Demark 趋势项算法的有效性，将该算法用于建立惯性导航系统中飞行器速度参数误差预测模型，进一步预测速度参数的误差，将预测出的误差值用于修正导航系统输出的速度参数，从而达到提高惯性导航系统精度的目的。作者进行了改进型算法与传统自组织算法和 Demark 趋势项的仿真对比，结果表明，作者提出的算法精度最高，其优势在长期预测中尤为突出。

研究工作还进行了对以惯性导航为基系统的导航综合系统最优结构的仿真。在导航综合系统工作过程中，根据外部条件的变化，进行了组合布局的切换，保证了在任一时刻导航系统具有最优的结构。切换根据输出参数误差的预测值进行，而预测模型同样采用改进型 Demark 趋势项建立。仿真结果表明，用基于改进型 Demark 趋势项的误差预测来进行导航综合系统布局的切换，可保证导航综合系统在每一工作时刻都具有最优的结构，输出可靠的导航参数。

为了演示智能系统“系统生成”各个阶段算法保障的基本特点，作者仿真了返回大气层式无人飞行器智能系统“系统生成”的三个基本阶段中行动感知器的实现过程，采用适宜于各个阶段的相应算法建立了飞行器运动参数误差预测模型。

基于微分几何理论，作者实现了飞行器运动模型的反馈线性化，大大简化了控制律的综合过程。为了进一步验证算法，将该方法用于控制发动机推力矢量/气动力复合控制的导弹，对垂直平面内进行蛇形机动、匀速、匀加速运动的目标实施制导，仿真了该制导过程，结果达到了较高的制导精度。

### 7.1 用改进型 Demark 趋势项建立惯性导航系统误差预测模型的数学仿真

以惯性导航系统输出参数中关于飞行器速度误差的预测为例进行了仿真。在仿真中比较了在短期、中期及长期预测中，用改进型 Demark 趋势项、传统 Demark 趋势项和传统的自组织方法所建立的预测模型的精度。仿真中使用了从批量生产的惯性导航系统的半实物试验中得到的数据作为测量样本。

在对仿真结果分析的基础上，给出了在无人飞行器智能控制系统的智能组件中建立误差预测模型的建议。

### 7.1.1 惯性导航系统输出速度参数及误差修正

惯性导航系统输出参数误差的修正是通过使用外部测量信号来达到的。由于飞行器工作状态和运行环境条件的特殊性，使得我们不是总能获得测量的当前值，也不是总能利用测量值的最优估计，因此，考虑用预测的方法来进行输出参数误差的修正。在测量值可达的时间段内，利用不同的方法建立误差参数的预测模型；当测量值消失后，用预测模型来进行外推，获得误差参数的预测值，将该值用于输出参数误差的修正。

惯性导航系统输出参数及用预测方法实现误差修正的结构如图 7-1 所示。

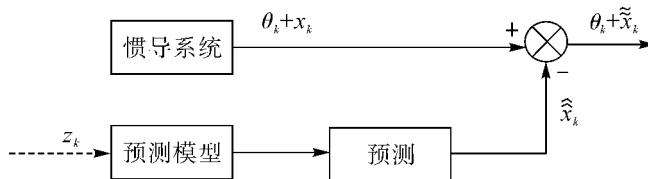


图 7-1 惯性导航系统输出参数及误差修正结构图

图中各参数的含义如下：

$\theta_k$  为飞行器速度参数的真值；

$x_k$  为飞行器速度参数误差；

$z_k$  为飞行器速度误差测量值；

$\hat{x}_k$  为飞行器速度误差预测值；

$\tilde{x}_k$  为  $x_k$  与  $\hat{x}_k$  的差值，即修正后的速度参数误差；

$\theta_k + \tilde{x}_k$  为惯性导航系统修正后的输出速度参数， $k$  为获得测量样本的离散时刻。

图中测量信号  $z_k$  的输入用虚线表示，是为了说明测量信号不是来自一个固定的外部信号源，而是随导航综合系统的结构优选而不断切换的最优外部测量信号。在 7.2 节中仿真了导航综合系统结构的优选过程。

### 7.1.2 惯性导航系统输出速度参数误差的预测模型

在仿真时考虑了用以下三种方法建立惯性导航系统输出速度参数的误差预测模型。

(1) 线性趋势项。

建立在平均样本值基础上，并带有选定的基点，它是对传统 Demark 趋势项的第一次改进的结果，同式 (4-36)。以下称之为模型 1，表达形式为

$$\hat{x}_{1k}(a_1, b_1) = k_{1k}t_k + d_{1k} \quad (7-1)$$

式中， $\hat{x}_{1k}$  为预测量， $k_{1k}$ ， $d_{1k}$  分别为趋势项的斜率和常数参数， $a_1, b_1$  为选定的基点。所有量和参数都根据测量样本的时刻  $t_k$  来确定。

$k_{1k}, d_{1k}, a_1, b_1$  按下列方式获得：将测量样本划分为不同的两部分，将每部分中的

所有样本点取平均得到两个平均值。分别选择两部分样本的中点作为基点的横坐标，与两个平均值相结合得到基点  $a_1$ ,  $b_1$ 。用直线连接两个基点得到趋势项。

模型 1 对样本的最近变化趋势有更准确的逼近，且具有建模过程快的优点。

(2) 由传统自组织方法确定的非线性模型。

在本问题中从实际考虑出发，选择下列形式的非线性函数用于建立模型：

$$\hat{x}_{2k} = A_{1mk} \sin(\omega t_k + P_{1k}) + A_{2mk} \cos(\omega t_k + P_{2k}) \quad (7-2)$$

式中， $\hat{x}_{2k}$  为预测量； $A_{1mk}, A_{2mk}$  和  $P_{1k}, P_{2k}$  分别为调和分量的幅值和相位，用自组织方法来挑选。所有量和参数相对于时刻  $t_k$  来确定。式 (7-2) 以下称之为模型 2。

模型 2 的精度较高，但需要更长的建立时间。

(3) 改进型 Demark 趋势项。

以下称之为模型 3，表达形式为

$$\hat{x}_{3k} = \sum_{i=1}^2 w_i \hat{x}_{ik} \quad (7-3)$$

式中， $\hat{x}_{3k}$  是动态对象在时刻  $k$  的状态变量预测； $\hat{x}_{ik}$  ( $i=1, 2$ ) 分别为利用模型 1 和模型 2 获得的部分预测量， $\hat{x}_{1k}$  为对样本初次逼近的线性趋势项， $\hat{x}_{2k}$  为分离趋势项后对残差逼近的非线性修正项； $w_i$  为权系数，位于 0 到 1 之间，根据预测的长度来选择。

为了评价不同模型的精度，使用了均方偏差准则和总和偏差准则，它们按照下列方式确定：

$$\Delta_1 = \frac{\sum_{t \in N_p} (y_t^M - y_t)^2}{\sum_{t \in N} y_t^2} \quad (7-4)$$

$$\Delta_2 = \begin{cases} \text{dev}_{(L+1)/2} \\ \frac{\text{dev}_{L/2} + \text{dev}_{L/2+1}}{2} \end{cases} \quad (7-5)$$

式中， $N$  为样本项数； $N_p$  为预测项数； $L$  为预测周期数； $y_t$ ,  $y_t^M$  分别为实际值和预测量； $\Delta_1$  为在每个预测周期中预测量与实际量间的偏差； $\Delta_2$  为在一定的长度区间中预测量与实际量间的总和偏差。式 (7-5) 的准则用于评价预测模型的统计特性，综合考虑了各种因素，其中包括样本长度、预测长度及测量到达时刻和测量噪声的水平。根据仿真的结果，在  $L \geq 20$  的条件下，将式 (7-5) 的准则用于评价预测模型的精度是符合要求的。

准则  $\Delta_2$  用下列方式确定：在由  $L$  个预测周期构成的一定长度的区间内，按照式 (7-4) 的准则对每个周期计算预测值与实际值的偏差，得到  $L$  个偏差值。将  $L$  个偏差值按照升序排列，对  $L$  为奇数的情况， $\text{dev}_{(L+1)/2}$  表示下标为  $(L+1)/2$  的那个周期的偏差值；而对偶数的情况， $\Delta_2$  等于下标分别为  $L/2$  和  $L/2+1$  的两个周期的偏差值的平均值。

### 7.1.3 仿真结果

用 7.1.2 中的三种模型进行了预测惯性导航系统输出速度误差参数的仿真，并对仿真结果进行了比较。

仿真时考虑了飞行器运行的基本条件（即测量样本长度、预测的长度、测量到达时刻和测量噪声水平）。仿真了预测长度分别为5步、10步和20步的短期、中期和长期预测的情况，每步的长度等于一个采样间隔。给出了测量样本由20个测量点构成条件下的仿真结果，这是根据实际的考虑来选择的。仿真时从实际导航系统的要求出发，选择速度测量的噪声水平为50 m/min。

用改进型 Demark 趋势项建立的预测模型在短期、中期及长期预测中给出的结果如图7-2~图7-4所示。图中同时给出了用线性趋势项和传统自组织算法预测获得的结果。

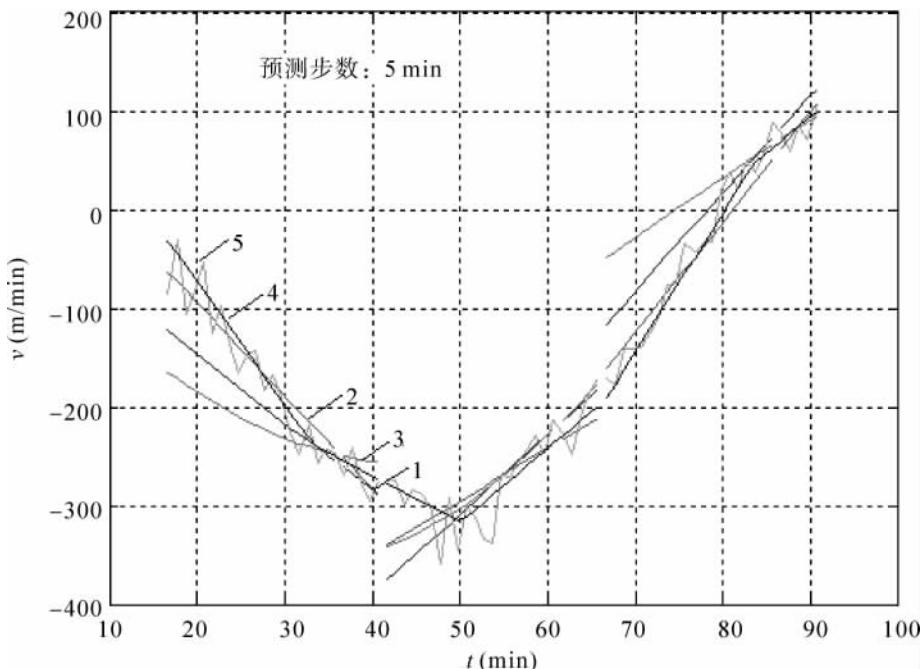


图7-2 改进型算法与其他算法预测的导航系统速度误差比较(短期预测)

图7-2~图7-4中：1为使用改进型 Demark 趋势项获得的导航系统误差曲线；2为使用线性趋势项得到的导航系统误差曲线；3为使用传统自组织算法得到的导航系统误差曲线；4为导航系统误差的真值；5为包含噪声的测量数据。

从图中可以看出，在短期预测中，三种模型获得的预测结果较接近。线性趋势项可以在最短的区间以满意的精度决定研究过程的变化趋势，即用线性趋势项和改进型趋势项得到的预测结果具有一致的精度指标。随着预测长度的增加，用改进型 Demark 趋势项与用线性趋势项得到的预测结果的差别逐渐明显。线性趋势线不断被用自组织方法选择出的非线性修正项修正，得到改进型趋势线，后者与基准值更接近，具有更高的预测精度。从图中可以看到，随着预测长度的增加，不能只使用线性趋势项来预测，特别是在研究对象运行过程中出现本质非线性的那些区间上。依靠用自组织方法建立的非线性修正项对趋势项分离后的残差进行逼近，提高了预测精度，并且因为在选择非线性修正项时使用了极少的

基函数组，因此，数字计算机中计算时间的消耗和机器存储量增加并不明显。

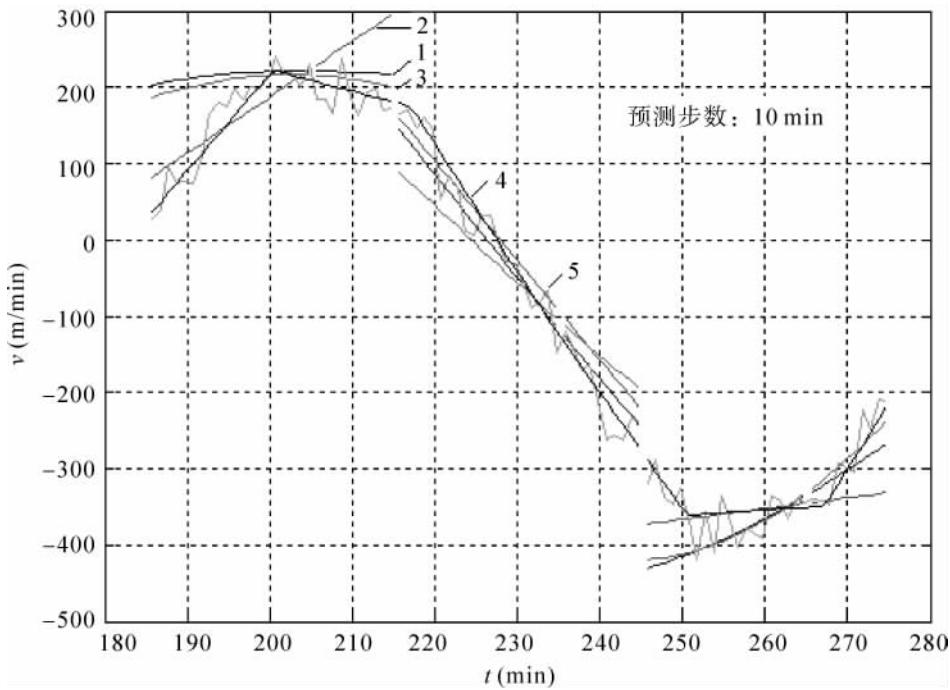


图 7-3 改进型算法与其他算法预测的导航系统速度误差比较(中期预测)

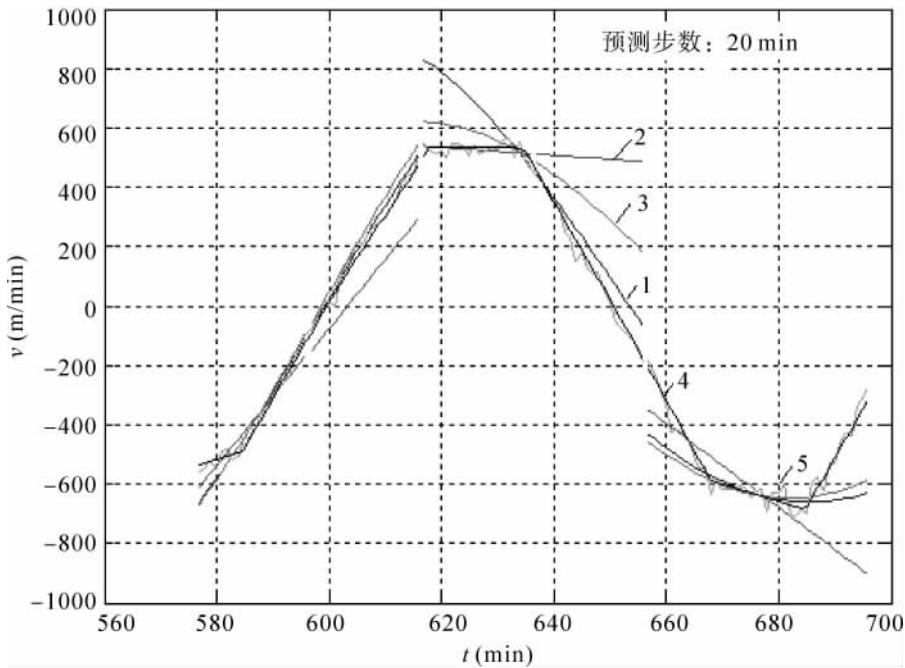


图 7-4 改进型算法与其他算法预测的导航系统速度误差比较(长期预测)

从曲线的直观对比可看出，采用改进型算法预测出的误差参数与真实的参数最接近，改进型算法的优势在长期预测中更明显。

除了显示用三种方法获得的导航系统速度误差的预测曲线外，使用改进型 Demark 趋势项建立飞行器惯性导航系统速度误差预测模型的有效性还表示在表 7-1~表 7-3 的统计结果中。

表 7-1 改进型算法与其他算法对导航系统速度误差预测的精度比较（短期预测）

模型	$E_{11}$ (%)	$E_{12}$ (%)	$E_{13}$ (%)	$E_{14}$ (%)	$E_{15}$ (%)	$E_2$ (%)
改进型模型	8.4	15	12.6	8.9	12.6	12
线性趋势项	12.3	20.5	18.7	19.2	21.2	18
自组织模型	10.7	12.7	10.6	12.2	12.3	12

表 7-2 改进型算法与其他算法对导航系统速度误差预测的精度比较（中期预测）

模型	$E_{11}$ (%)	$E_{12}$ (%)	$E_{13}$ (%)	$E_{14}$ (%)	$E_{15}$ (%)	$E_2$ (%)
改进型模型	11.2	10	11.3	12.5	11	11
线性趋势项	20	22	22	24.4	24.4	23
自组织模型	16	13	14.1	16	16	15

表 7-3 改进型算法与其他算法对导航系统速度误差预测的精度比较（长期预测）

模型	$E_{11}$ (%)	$E_{12}$ (%)	$E_{13}$ (%)	$E_{14}$ (%)	$E_{15}$ (%)	$E_2$ (%)
改进型模型	20	21	35	38.5	22.5	27
线性趋势项	80	58.5	70	64.4	58.5	66
自组织模型	31	31	38	40.2	40.6	36

表中的统计数据也证实了图中所表现的趋势，采用改进型算法的预测精度高于其他两种算法。 $E_{11} \sim E_{15}$  表示使用不同起始时刻的测量数据计算得到的预测误差值， $E_2$  为它们的平均值。

从表中的统计数据可以看出，对于短期预测，使用三种模型的预测误差没有太大的区别，但用于选择非线性修正项的时间比用于建立线性模型的时间多 7 倍。在长期预测中，改进型 Demark 趋势项的精度比纯线性趋势项高 2 倍，且优于自组织模型的精度。随着预测长度的增加，三种模型的预测精度均下降，但改进型 Demark 趋势项精度下降最小，在长期预测中预测误差保持在 30% 以下，而自组织模型预测的误差为 36%，线性趋势项预测的误差高达 66%。从以上数据可以看出，在长期预测中，用线性趋势项预测的误差超过了真值的 50%，预测结果对导航系统输出的误差参数起不到修正作用，而改进型 Demark 趋势项却可以使导航系统输出的误差参数的精度提高 70% 以上。这就为导航系统误差参数的长期预测这一难题提供了有效的解决措施。

仿真结果表明，将改进型 Demark 趋势项用于建立惯性导航系统速度误差预测模

型，可以适应飞行器机动飞行状态，并在长期预测中有效预测导航系统误差。当飞行器实施机动时，测量样本有限，这时仅用线性趋势项快速预测导航误差；当累积了足够的测量数据时，就采用借助自组织算法实现的非线性修正项对残差建模。这样，得到的改进型 Demark 趋势项提高了预测精度。线性模型和非线性修正模型随飞行器机动程度的不同实时切换。该算法简单，并具有在飞行器高度机动的条件下，快速、可靠地预测导航系统误差的能力。既保证了需要的精度，又不需占用大的计算资源，并且在长期预测中优势明显。仿真的结果充分验证了使用线性趋势项和自组织算法相结合的改进型 Demark 算法建立预测模型的有效性。

## 7.2 基于改进型 Demark 趋势项进行导航综合系统结构选择的数学仿真

现代飞行器测量系统具有标准组合，其中包括惯性导航系统、GPS、各种无线电定位系统等。在飞行器运行期间不断地发生测量系统配置的切换，保证以最优的组合结构来获得最可靠的测量信息，即在各个工作区间同惯性导航系统组合工作的是不同的外部测量系统。结构的切换根据观测度数值准则进行，而观测度数值准则可以在预测的基础上确定。

用改进型 Demark 趋势项建立预测模型是一种独创性的算法，它可以在先验信息最少和不考虑研究对象一些本质因素的条件下确定对象变化的趋势。因此，在观测度数值准则的计算中考虑用 Demark 趋势项建立预测模型。然后在这个模型的基础上进行预测，借助于预测计算观测度。观测度的最大值决定了在飞行器下一运行区间与惯性导航系统组合的外部测量系统的组成。这样就实现了在预测基础上导航综合系统最优配置的选择。

借助于预测选择测量系统最优结构的仿真，以惯性导航系统陀螺稳定平台漂移速度的确定为例进行。

带有智能组件的测量系统的结构如图 7-5 所示。这里采用了以下表示：1 为基导航系统，通常为惯性导航系统； $2, \dots, N$  为外部信息传感器和测量系统； $\lambda$  为形成测量  $z_k$  和确定观测度的模块；BO 为惯性导航系统误差估计模块；БД 为动态数据库；

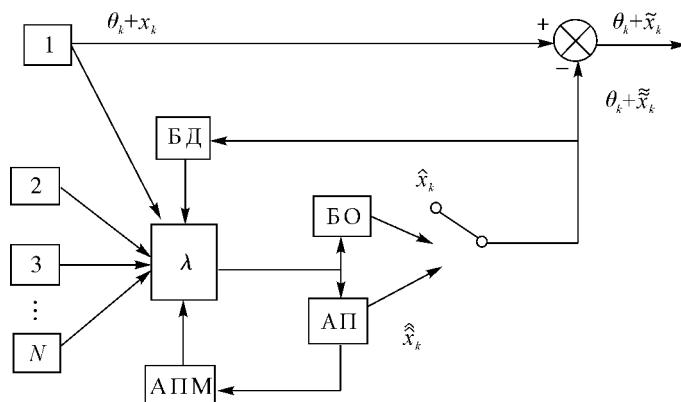


图 7-5 导航综合系统结构框图

$\text{AIM}$  为模型建立算法模块;  $\text{AP}$  为惯性导航系统误差预测算法模块;  $\theta_k$  为真实的导航信息;  $x_k$  为基导航系统(惯导系统)误差;  $\hat{x}_k$  为基导航系统误差估计;  $\tilde{x}_k$  为估计误差;  $\hat{\tilde{x}}_k$  为基导航系统误差预测;  $\tilde{\tilde{x}}_k$  为预测误差。

外部信息传感器通常使用机载无线电定位系统、地面近距离无线电定位站、地面远距离无线电定位站、天体修正器、GPS/ГЛОНАСС 卫星系统。在所研究的测量系统中, 使用了机载无线电定位系统和 GPS 卫星系统。

确定陀螺稳定平台漂移速度及其估计值的仿真结果如图 7-6 所示。图中:  $\epsilon$  为惯导系统陀螺平台漂移速度; 1 为陀螺平台漂移速度测量模型; 2 为使用 GPS 得到的陀螺平台漂移速度估计; 3 为使用无线电定位系统得到的陀螺平台漂移速度估计。

为了估计在  $T_1 \sim T_2$  区间陀螺稳定平台的漂移速度, 在预测的基础上进行了观测度数值计算并得到了结果:  $\lambda_2 > \lambda_1$ ,  $\lambda_1$  为无线电定位系统信号的观测度值,  $\lambda_2$  为 GPS 信号的观测度值。根据这一结果, 在  $T_1 \sim T_2$  区间应使用 GPS 作为外部测量系统来确定估计  $\epsilon$ 。

如果不是基于预测而是根据在前一区间  $0 \sim T_1$  的直接测量, 计算出的观测度数值结果为  $\lambda_1 > \lambda_2$ , 那么据此判断, 在区间  $T_1 \sim T_2$  最优估计将是使用无线电定位系统而得到的。从图 7-6 中看到, 这一结论不符合实际情况。可见, 对预测结果的分析给出了正确选择导航系统配置的可能性: 在当前区间  $T_1 \sim T_2$ , 有  $\lambda_1 < \lambda_2$ , 即导航系统的最优组合是惯性导航系统和 GPS。预测分析给出的结果大约比根据直接测量得到的结果准确 20%。相类似地, 在区间  $T_2 \sim T_3$ , 在预测基础上得到的估计比在直接测量基础上得到的估计准确 10%~20%, 即测量系统的最优组合是惯性导航系统和无线电定位系统, 因为这时根据预测模型计算出的观测度数值结果为  $\lambda_1 > \lambda_2$ 。

图 7-6 的结果显示了根据预测进行导航综合系统配置决策的适宜性, 而预测采用了改进型 Demark 趋势项来建立模型。根据最近测量样本的直接分析来选择导航系统的配置给出了更差的结果。

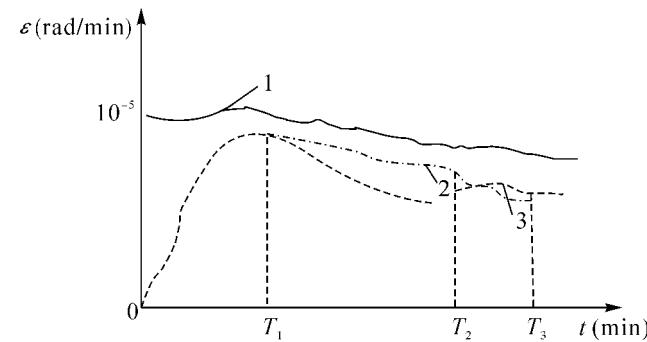


图 7-6 在导航综合系统不同结构下陀螺平台漂移速度的估计比较

### 7.3 返回大气层式无人飞行器“系统生成”三个阶段中行动感知器实现的数学仿真

为了使返回大气层式无人飞行器能有效地完成任务, 应考虑到在智能控制系统的

“系统生成”的每一阶段中算法保障的特殊性，并根据特殊的要求来研制智能控制系统活动的每一阶段的算法保障。

对返回大气层式无人飞行器智能控制系统“系统生成”的各个阶段中行动感知器的实现过程进行了仿真，实现行动感知器的算法保障的选择以惯性导航系统误差的预测为例进行了演示。

图 7-7~图 7-9 表示了在智能系统“系统生成”的三个基本阶段中，在行动感知器中进行的对惯性导航系统误差的预测。

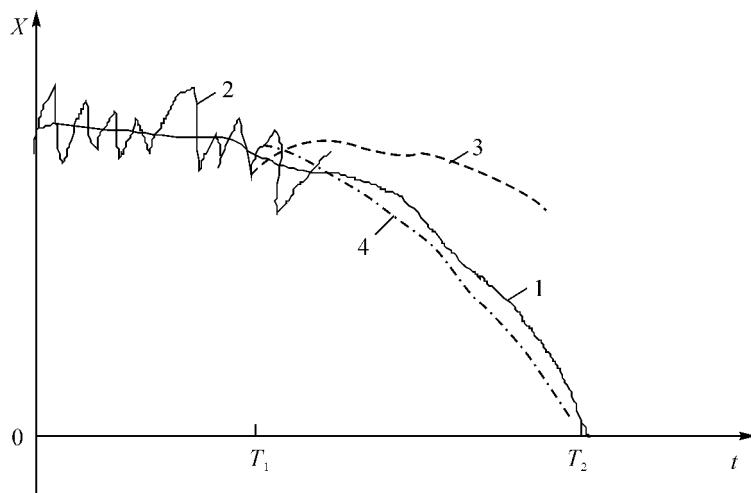


图 7-7 第一阶段惯性导航系统误差的预测

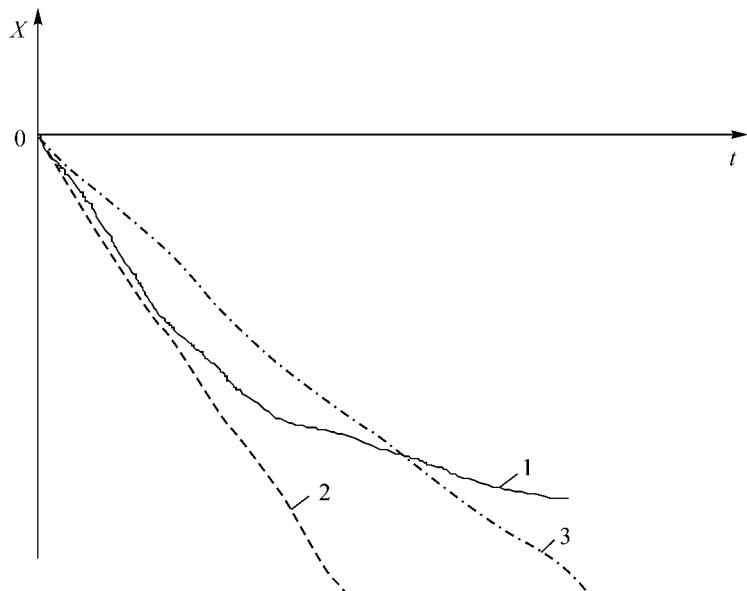


图 7-8 第二阶段惯性导航系统误差预测

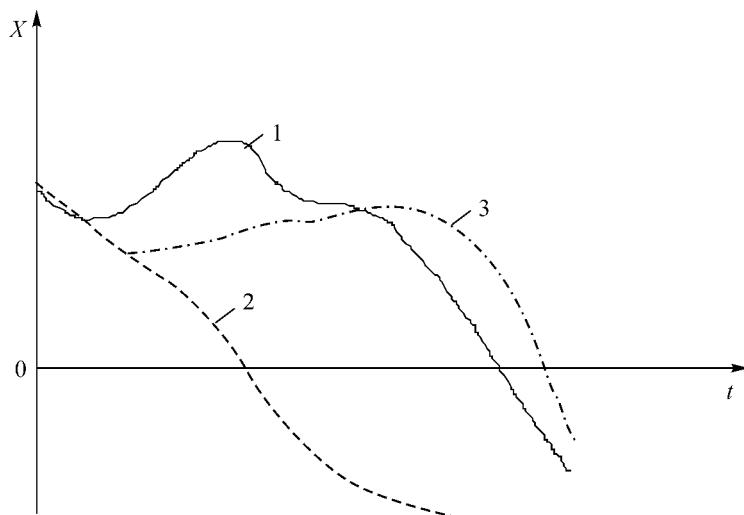


图 7-9 第三阶段惯性导航系统误差预测

图 7-7 中使用了下列表示：1 为基准模型；2 为测量值；3 为用线性趋势项得到的预测；4 为用自组织方法得到的预测。

图 7-8 中使用了下列表示：1 为基准模型；2 为用线性趋势项获得的预测；3 为用储备趋势项获得的预测。

图 7-9 中使用了下列表示：1 为基准模型；2 为用自组织方法获得的预测；3 为用改进型 Demark 趋势项获得的预测。

第一阶段假定缺少关于对象和外部环境参数的信息。在这一阶段建议在行动感知器中使用带有足够丰富的基函数的自组织算法。正如图 7-7 所表示的，依靠从丰富的基函数组合中挑选的局部模型的组合和选择，在自组织基础上得到的预测与基准模型以最好的方式吻合。线性趋势项由于先验信息不足，从起始段就不能逼近研究过程的实际趋势。

第二阶段的特点是无人飞行器在弱扰动环境中运动。因此，适宜于采用带有储备趋势项的自组织算法，并且在建立模型时使用极少的基函数。依靠对相似的情景使用储备模型，包括时间和机器存储量在内的用于建立模型的计算消耗大大减少，这对于智能控制系统的实现也是重要的要求。

第三阶段假定无人飞行器智能控制系统所有资源枯竭和无人飞行器生命周期结束。在这一阶段建议使用本书第 4 章中介绍的改进型 Demark 趋势项。同自组织算法相比，改进型 Demark 趋势项的算法允许在最短的时间区间以可接受的精度确定研究过程的趋势，特别是在动态对象进行高度机动、测量样本大大受限的条件下。如图 7-9 所示，在自组织方法基础上得到的预测由于测量信息不够具有较大的误差。

## 7.4 发动机推力矢量/气动力复合控制导弹对机动目标实施制导的数学仿真

现代作战环境要求战术导弹具有高机动作战性能。高速、大机动是未来导弹发展的趋势，这对导弹的控制方式和控制系统提出了更高的要求，传统的气动力控制方法已不再适用。为此，现代具有反导能力的防空导弹在拦截末段普遍采用直接侧向力和气动力复合控制方法，以提高控制系统的快速响应特性和控制精度。但导弹的高度机动以及复合控制的方式使得导弹在空间的运动方程是多变量耦合的复杂非线性模型，难于基于小扰动线性化的假设来设计控制律。从第5章中介绍的研究结果可以看出，微分几何理论是实现非线性对象大范围精确线性化的一条有效途径，并且在此基础上实现了继电调节器。在非线性对象运行范围内可以找到适当的区间，在该区间内可以采用线性调节器完成非线性对象的控制，而不损失原模型的精度。

因此，运用第5章中获得的结论，尝试采用基于微分几何理论的反馈线性化方法来进行推力矢量/气动力复合控制导弹的控制，在此基础上设计制导律，仿真这种类型导弹对高度机动目标实施制导的过程。仿真中只研究了对垂直平面内进行蛇形机动、匀速、匀加速运动的目标实施制导的过程。

### 7.4.1 导弹动力学模型

推力矢量/气动力复合控制的导弹在垂直平面内的动力学方程如下：

$$\begin{cases} m \frac{dV}{dt} = -G \sin\theta + L_x + F \cos(\psi + \vartheta - \theta) \\ mV \frac{d\theta}{dt} = -G \cos\theta + L_y + F \sin(\psi + \vartheta - \theta) \\ \frac{d\vartheta}{dt} = \omega_{zd} \\ J_z \frac{d\omega_{zd}}{dt} = M_z + M_F \end{cases} \quad (7-6)$$

式中， $m$ ， $J_z$  分别为导弹的质量和转动惯量； $V$ ， $\theta$ ， $\vartheta$ ， $\omega_{zd}$  分别为导弹的速度、弹道倾角、弹体俯仰角和俯仰角速度； $G$ ， $L_x$ ， $L_y$  分别为重力、气动阻力和升力； $M_z$ ， $M_F$  分别为气动力矩和推力产生的力矩； $F$ ， $\psi$  分别为推力和推力矢量夹角。

气动力、推力、气动力矩和推力力矩又可表示为

$$\begin{aligned} L_x &= C_x Q S_{ref}, \quad L_y = C_y Q S_{ref} = (C_y^\alpha \alpha + C_y^\delta \delta) Q S_{ref}, \\ M_z &= m_z^\alpha \alpha Q S_{ref} b + m_z^\delta \delta Q S_{ref} b + m_z^{\omega_{zd}} \omega_{zd} \frac{b}{V} Q S_{ref} b, \\ M_F &= -F l \sin\psi, \quad G = mg, \quad \alpha = \vartheta - \theta, \\ F &= I_s g \dot{m}_0, \quad Q = \frac{1}{2} \rho V^2 \end{aligned} \quad (7-7)$$

式中， $C_x, C_y^\alpha, C_y^\delta, m_z^\alpha, m_z^\delta, m_z^{\omega_{zd}}$  分别为气动阻力系数、气动升力系数的攻角分量、气

动升力系数的舵偏角分量、气动稳定力矩系数、气动控制力矩系数、气动阻尼力矩系数;  $\rho$ ,  $S_{\text{ref}}$ ,  $b$  分别为空气密度、气动面参考面积和平均气动弦长;  $I_s$ ,  $\dot{m}_0$ ,  $g$  分别为发动机比冲、喷气流量和重力加速度;  $l$  分别为推力作用力臂;  $\alpha$  为攻角;  $\delta$  为气动舵偏角。

定义以下的动力学系数:

$$\begin{aligned} k_{11} &= -\frac{g}{V}, \quad k_{12} = \frac{C_y^a \rho V S_{\text{ref}}}{2m} + \frac{F}{mV}, \quad k_{13} = \frac{C_y^a \rho V S_{\text{ref}}}{2m} + \frac{F}{mV}, \\ k_{14} &= \frac{C_y^{\delta} \rho V S_{\text{ref}}}{2m}, \quad k_{15} = \frac{F}{mV}, \\ k_{21} &= \frac{m_z^a \rho V^2 S_{\text{ref}} b}{2J_z}, \quad k_{22} = \frac{m_z^{\omega_{zd}} \rho V S_{\text{ref}} b^2}{2J_z}, \\ k_{23} &= \frac{m_z^{\delta} \rho V^2 S_{\text{ref}} b}{2J_z}, \quad k_{24} = -\frac{Fl}{J_z} \end{aligned} \quad (7-8)$$

假设  $|\psi_{\max}| \leq 20^\circ$ ,  $|\alpha_{\max}| \leq 20^\circ$ , 则有  $\sin\psi \approx \psi$ ,  $\sin(\psi + \alpha) \approx \psi + \alpha$ 。

若忽略速度大小的方程, 考虑到上述假设, 式 (7-6) 中后三个方程用定义的动力学系数可表示为

$$\begin{cases} \frac{d\theta}{dt} = k_{11} \cos\theta + k_{12}\vartheta - k_{13}\theta + k_{14}\delta + k_{15}\psi \\ \frac{d\vartheta}{dt} = \omega_{zd} \\ \frac{d\omega_{zd}}{dt} = k_{21}(\vartheta - \theta) + k_{22}\omega_{zd} + k_{23}\delta + k_{24}\psi \end{cases} \quad (7-9)$$

这样, 就将导弹在垂直平面内的动力学模型表示为以气动舵偏角和推力矢量夹角( $\delta$ ,  $\psi$ )为控制输入的仿射非线性模型:

$$\dot{x} = f(x) + \sum_{i=1}^2 g_i(x)u_i \quad (7-10)$$

$$x = (\theta, \vartheta, \omega_{zd})^T, \quad u = (u_1, u_2)^T = (\delta, \psi)^T \quad (7-11)$$

$$f(x) = \begin{bmatrix} k_{11} \cos\theta + k_{12}(\vartheta - \theta) \\ \omega_{zd} \\ k_{21}(\vartheta - \theta) + k_{22}\omega_{zd} \end{bmatrix}, \quad g_1(x) = \begin{bmatrix} k_{14} \\ 0 \\ k_{23} \end{bmatrix}, \quad g_2(x) = \begin{bmatrix} k_{15} \\ 0 \\ k_{24} \end{bmatrix} \quad (7-12)$$

#### 7.4.2 导弹数学模型的反馈线性化及控制律设计

对系统 (7-10), 取输出函数  $y_1 = h_1(x) = \theta(t)$ ,  $y_2 = h_2(x) = \vartheta(t)$ , 对其求关于系统函数  $f(x)$  和输入函数  $g_1(x)$ ,  $g_2(x)$  的 Lie 导数。

$$L_{g_1} h_1(x) = k_{14} \neq 0, \quad L_{g_2} h_1(x) = k_{15} \neq 0,$$

$$L_{g_1} h_2(x) = 0, \quad L_{g_2} h_2(x) = 0,$$

$$L_{g_1} L_f h_2(x) = k_{23} \neq 0, \quad L_{g_2} L_f h_2(x) = k_{24} \neq 0$$

矩阵

$$\begin{bmatrix} L_{g_1} h_1(\mathbf{x}) & L_{g_2} h_1(\mathbf{x}) \\ L_{g_1} L_f h_2(\mathbf{x}) & L_{g_2} L_f h_2(\mathbf{x}) \end{bmatrix}$$

非奇异，则系统 (7-10) 具有相对阶  $r = r_1 + r_2 = 3 = n$ 。根据非线性系统可反馈线性化的充要条件，相对阶等于系统的维数，则系统 (7-10) 可反馈线性化。选取控制输入如下：

$$\mathbf{u} = (\delta, \varphi)^T = \mathbf{B}^{-1}(\mathbf{x})(-\mathbf{A}(\mathbf{x}) + \mathbf{v}) \quad (7-13)$$

式中，

$$\begin{aligned} \mathbf{B}(\mathbf{x}) &= \begin{bmatrix} L_{g_1} h_1(\mathbf{x}) & L_{g_2} h_1(\mathbf{x}) \\ L_{g_1} L_f h_2(\mathbf{x}) & L_{g_2} L_f h_2(\mathbf{x}) \end{bmatrix} \\ \mathbf{A}(\mathbf{x}) &= \begin{bmatrix} k_{11} \cos \theta + k_{12} (\vartheta - \theta) \\ k_{21} (\vartheta - \theta) + k_{22} \omega_{zd} \end{bmatrix}, \quad \mathbf{v} = (v_1, v_2)^T \end{aligned}$$

则可将系统 (7-10) 化为以下的积分器串联的正则标准型：

$$\begin{cases} \frac{d\theta}{dt} = v_1 \\ \frac{d\vartheta}{dt} = \omega_{zd} \\ \frac{d\omega_{zd}}{dt} = v_2 \end{cases} \quad (7-14)$$

式中， $\mathbf{v}$  为等效输入。这样，利用反馈线性化，将系统 (7-10) 化为彼此解耦的，以  $v_1, v_2$  为控制输入，以  $\theta, \vartheta$  为输出的两个等效子系统 (7-14)。对式 (7-14)，采用成熟的设计方法容易找到控制律  $\mathbf{v} = (v_1, v_2)^T$ ，使得输出  $(\theta, \vartheta)$  满足一定的要求。

定义参考输出  $y_{jR}(t)$  和实际输出与参考输出之间的误差为  $e_j(t) = y_j(t) - y_{jR}(t)$ ，则不失一般性，可以取等效输入如下：

$$v_j = y_{jR}^{(r_j)}(t) - \sum_{i=1}^{r_j} c_{i-1} e_j^{(i-1)}, \quad j = 1, 2 \quad (7-15)$$

得到误差的微分方程为

$$e_j^{(r_j)} + c_{r_j-1} e_j^{(r_j-1)} + \dots + c_1 e_j' + c_0 e_j = 0, \quad j = 1, 2 \quad (7-16)$$

由于  $c_0, c_1, \dots, c_{r_j-1}$  是我们选择的反馈系数，可以任意设置，因此，方程 (7-16) 的特征根可以任意配置。假定设置  $c_0, c_1, \dots, c_{r_j-1}$  使得所有特征根均位于复平面的左半开平面，即  $\text{Re}(s_i) < 0$ ，甚至可以位于  $\text{Re}(s_i) < \sigma_0$ ，这样可以使得误差以快于  $e^{-\sigma_0 t}$  的速率衰减，系统的输出就可以渐进跟踪参考输出。获得等效输入  $\mathbf{v}$  后，再根据反馈关系式 (7-13)，得到实际的控制输入量  $\mathbf{u}$ 。

这样，利用微分几何的方法，就实现了发动机推力矢量/气动力复合控制的导弹数学模型的精确线性化，并实现了控制解耦，将相互耦合的发动机推力矢量和气动舵偏角复杂控制律的设计转换为对等效控制输入  $\mathbf{v}$  的寻找，大大简化了设计过程。

#### 7.4.3 仿真中对系统实际条件的考虑

按照上述的设计方法，基于反馈线性化模型，对导弹攻击垂直平面内机动目标的制

导过程进行仿真。

假设目标作蛇形机动，在垂直平面内的运动方程为

$$\begin{cases} \frac{dx_t}{dt} = V_t \cos\theta_t \\ \frac{dy_t}{dt} = V_t \sin\theta_t \end{cases} \quad (7-17)$$

式中， $(x_t, y_t)$  为目标位置坐标， $V_t$  为机动的速度，速度矢量倾角  $\theta_t$  按以下规律变化：

$$\theta_t = 10^\circ \sin(2\pi ft), \quad f = 0.1 \text{ Hz} \quad (7-18)$$

当  $V_t = 200 \text{ m/s}$  时，目标机动的最大过载为  $2.2 \text{ g}$ 。

采用常规的比例导引律，等效输入  $(v_1, v_2)$  按下列方式形成：

$$\begin{aligned} v_1 &= k_p v_{\text{los}} \\ v_2 &= -k_2 \omega_{\text{zd}} + k_1 (k_0 \text{sign}(\theta_{\text{los}} - \theta) - \alpha) \end{aligned} \quad (7-19)$$

式中， $\theta_{\text{los}}, v_{\text{los}}$  分别为导弹—目标视线角和目标视线角速率； $k_p, k_0, k_1, k_2$  为控制系数，由理论计算和仿真结果选取。

式 (7-19) 中， $v_{\text{los}}$  由比例导引头给出，并不需要测量  $\theta_{\text{los}}$  的具体数值，只需要得到导弹—目标视线角与弹道倾角的相对位置关系，从而判断符号。攻角  $\alpha$  与纵向过载间有固定的关系，可以由过载传感器得到的值计算，俯仰角速度  $\omega_{\text{zd}}$  由角速度传感器测量。这样，式 (7-19) 右边的各变量在实际中均可获得，它们经控制系数  $k_p, k_0, k_1, k_2$  加权后，就可计算出控制量  $v_1, v_2$  的数值。

舵偏角和推力矢量夹角  $\delta, \psi$  根据式 (7-13) 由  $v_1, v_2$  变换得到：

$$\begin{bmatrix} \delta \\ \psi \end{bmatrix} = \begin{bmatrix} k_{14} & k_{15} \\ k_{23} & k_{24} \end{bmatrix}^{-1} \left( \begin{bmatrix} -k_{11} \cos\theta - k_{12} (\vartheta - \theta) \\ -k_{21} (\vartheta - \theta) - k_{22} \omega_{\text{zd}} \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} \right) \quad (7-20)$$

式 (7-20) 中的各动力学系数与气动力和力矩系数有关，可根据气动力系数插值表计算得到。

仿真中舵偏角和推力矢量夹角限位值分别取为

$$|\delta_{\max}| \leq 30^\circ, \quad |\psi_{\max}| \leq 20^\circ \quad (7-21)$$

因为仿真主要考察控制算法的有效性，因此，导引系统、舵系统和发动机喷管控制系统均作为理想的环节考虑。

#### 7.4.4 仿真结果

为验证制导与控制算法的有效性，对以下 5 种典型情况进行了仿真：

- ①从空中发射导弹，攻击在导弹前下方进行蛇形机动的目标；
- ②从空中发射导弹，攻击在导弹前上方进行蛇形机动的目标；
- ③从空中发射导弹，攻击在地面作匀加速运动的目标；
- ④从空中发射导弹，攻击在地面作匀速运动的目标；
- ⑤从地面发射导弹，攻击在空中进行蛇形机动的目标。

导弹发射的初始速度为  $266 \text{ m/s}$ ，发射角和发射时弹体俯仰角分别为  $5^\circ$  和  $10^\circ$ ，发射时刻导弹以尾追方式攻击机动目标。仿真结果如下：

(1) 目标机动的初始位置  $(x_{t0}, y_{t0}) = (2000, 4000)$ , 导弹发射初始位置  $(x_{m0}, y_{m0}) = (0, 6000)$ 。最终的制导精度为 0.48 m, 制导时间 32.2 s。制导过程中导弹和目标运动轨迹如图 7-10 所示; 弹道倾角、弹体俯仰角、导弹—目标视线角的变化曲线如图 7-11 所示; 图 7-12 为舵偏角变化曲线; 图 7-13 为推力矢量夹角变化曲线。

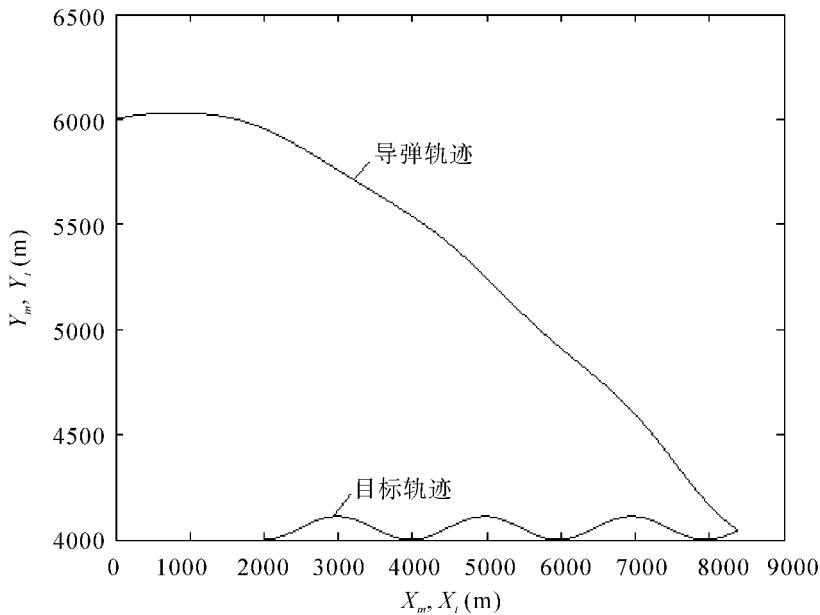


图 7-10 导弹和目标运动轨迹

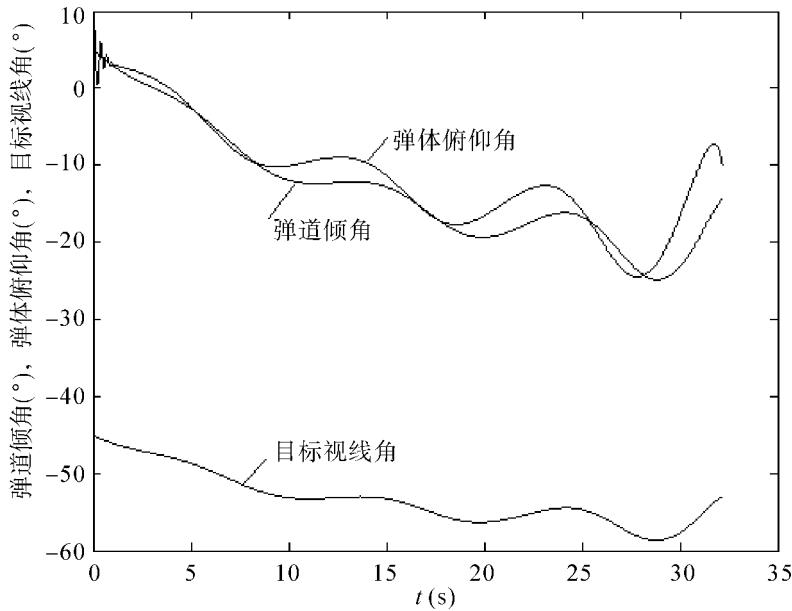


图 7-11 弹道倾角、弹体俯仰角及导弹—目标视线角变化曲线

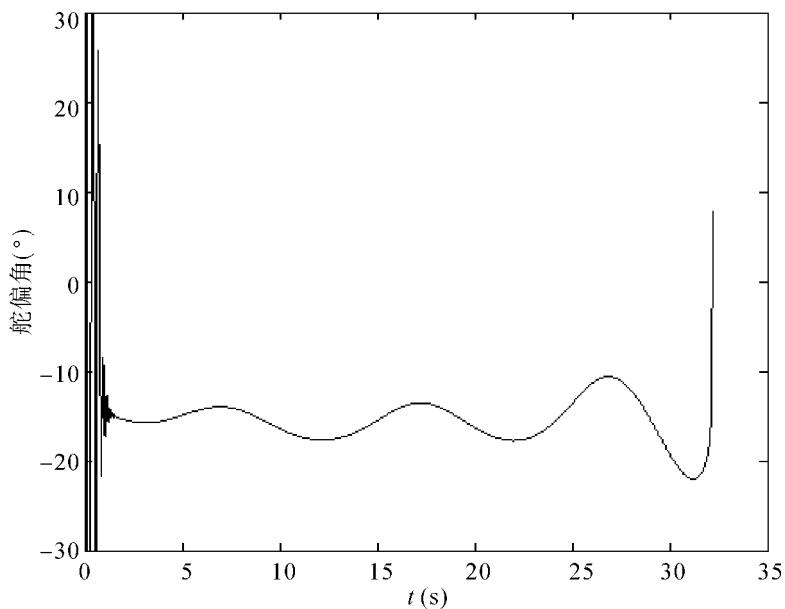


图 7-12 舵偏角变化曲线

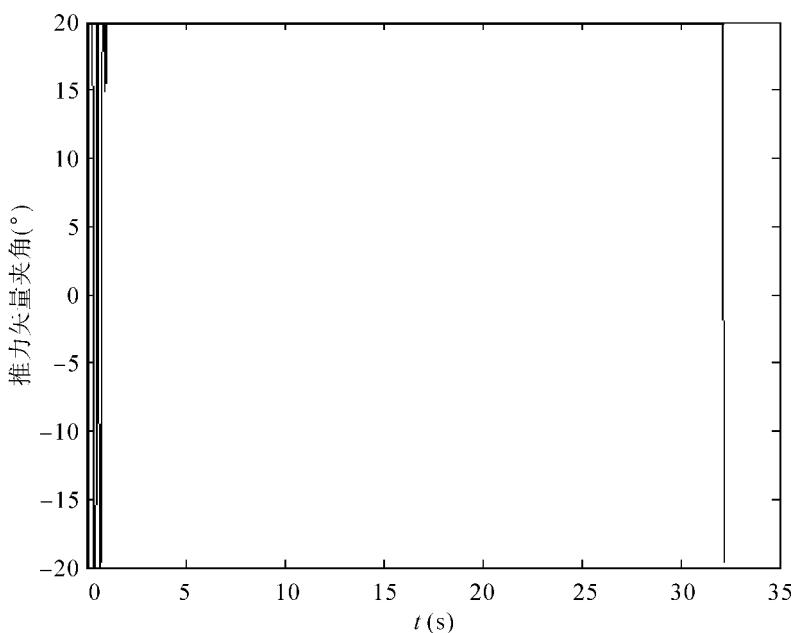


图 7-13 推力矢量夹角变化曲线

(2) 目标机动的初始位置  $(x_{t0}, y_{t0}) = (1000, 6000)$ , 导弹发射初始位置  $(x_{m0}, y_{m0}) = (0, 4000)$ 。最终制导精度 0.05 m, 制导时间 45.9 s。制导过程中导弹和目标运动轨迹如图 7-14 所示; 弹道倾角、弹体俯仰角、导弹—目标视线角的变化曲线如图 7-15 所示; 图 7-16 为舵偏角变化曲线; 图 7-17 为推力矢量夹角变化曲线。

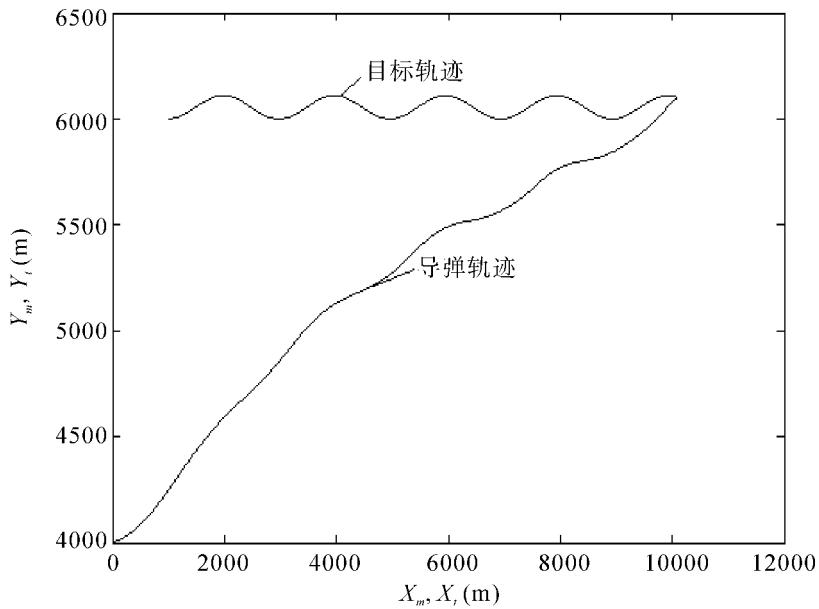


图 7-14 导弹和目标运动轨迹

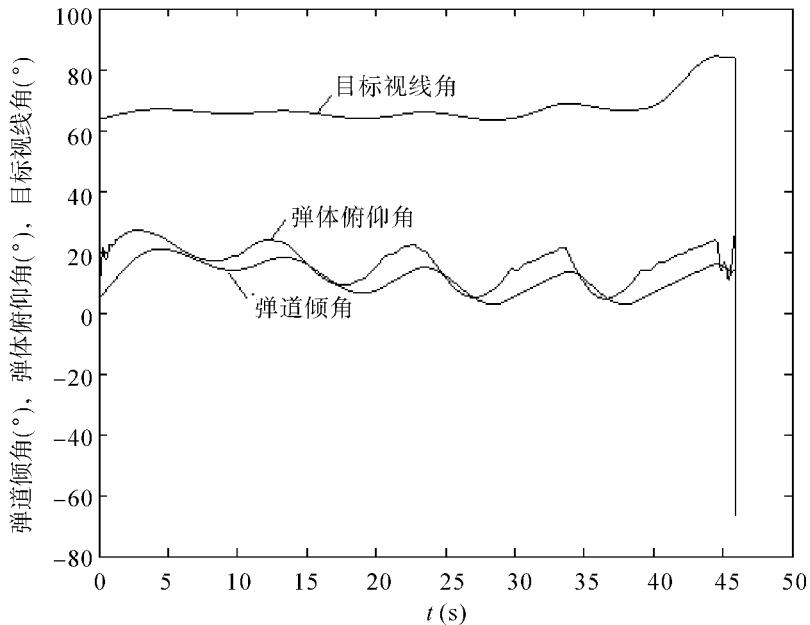


图 7-15 弹道倾角、弹体俯仰角及导弹—目标视线角变化曲线

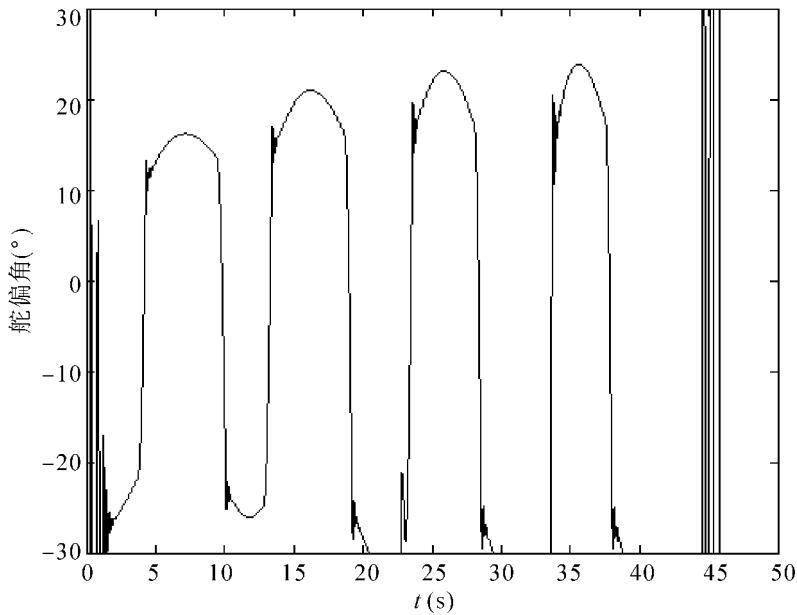


图 7-16 舵偏角变化曲线

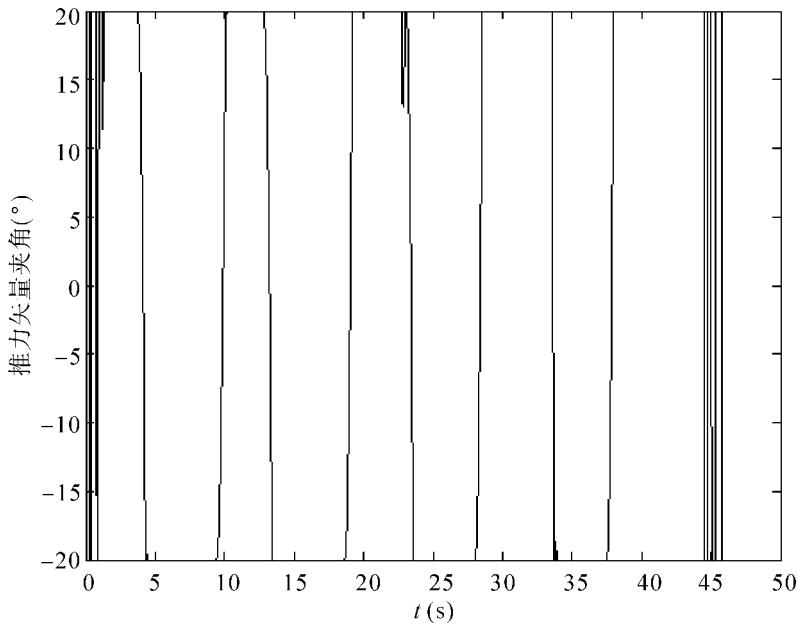


图 7-17 推力矢量夹角变化曲线

(3) 地面目标以  $5 \text{ m/s}^2$  的加速度作匀加速运动，目标初始位置  $(x_{t0}, y_{t0}) = (2000, 0)$ ，导弹发射初始位置  $(x_{m0}, y_{m0}) = (0, 4000)$ 。最终制导精度  $0.35 \text{ m}$ ，制导时间  $20.0 \text{ s}$ 。制导过程中导弹和目标运动轨迹如图 7-18 所示；弹道倾角、弹体俯仰角、导弹—目标视

线角的变化曲线如图 7-19 所示；图 7-20 为舵偏角变化曲线；图 7-21 为推力矢量夹角变化曲线。从图 7-18 可见，在制导过程中导弹除了采用尾追方式跟踪目标外，在必要的情况下，还可对目标进行迎头攻击，这是由所采用的制导与控制算法保证的。

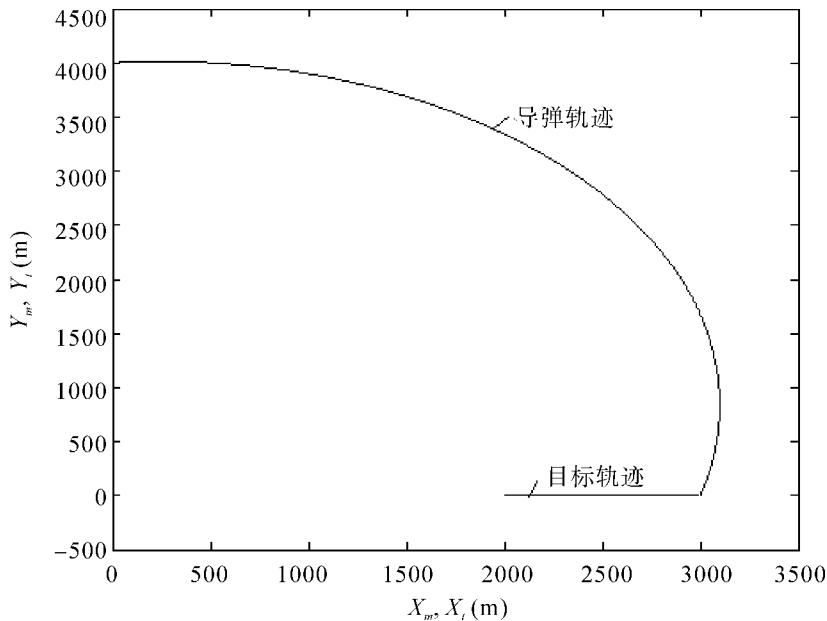


图 7-18 导弹和目标运动轨迹

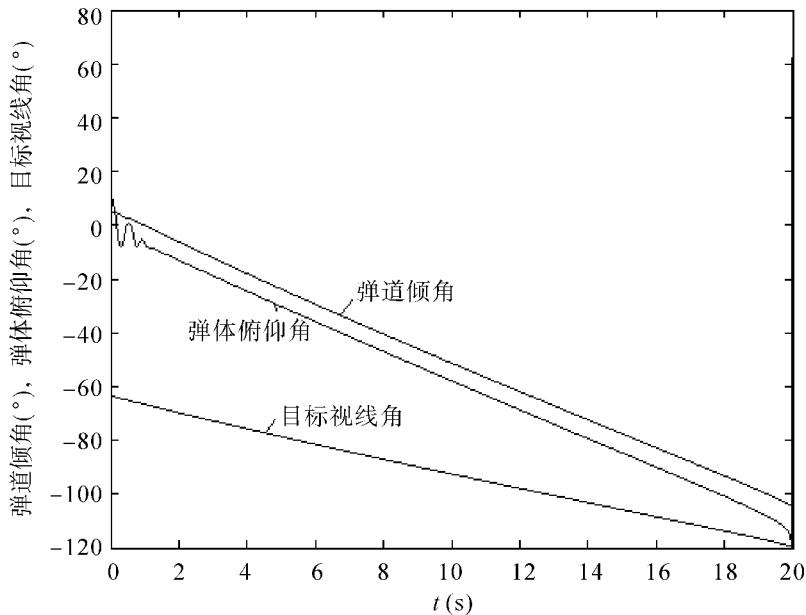


图 7-19 弹道倾角、弹体俯仰角及导弹—目标视线角变化曲线

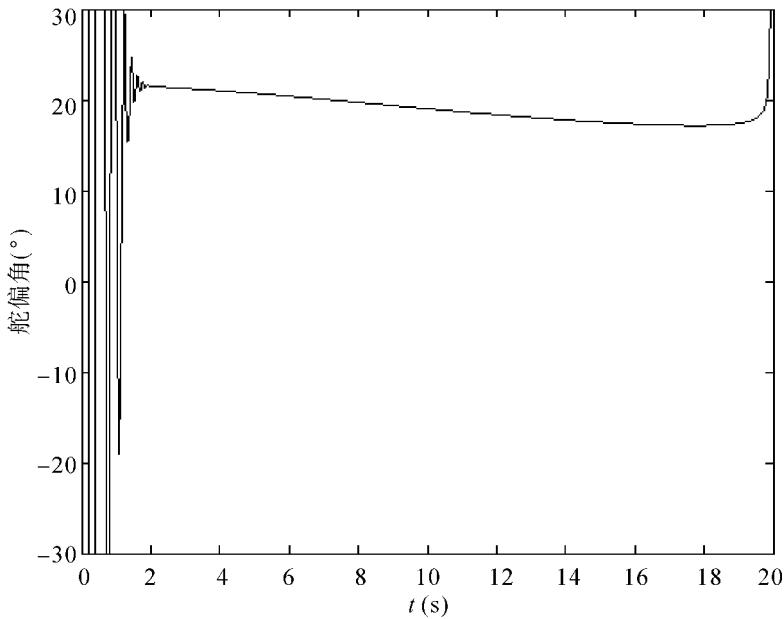


图 7-20 舵偏角变化曲线

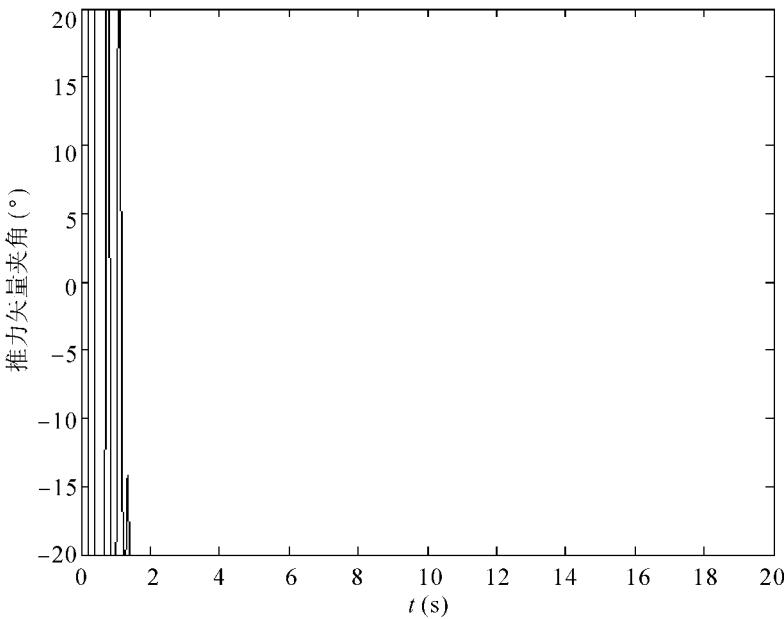


图 7-21 推力矢量夹角变化曲线

(4) 地面目标以 200 m/s 的速度作匀速直线运动，目标初始位置  $(x_{t0}, y_{t0}) = (2000, 0)$ ，导弹发射初始位置  $(x_{m0}, y_{m0}) = (0, 4000)$ 。最终制导精度 0.35 m，制导时间 39.3 s。制导过程中导弹和目标运动轨迹如图 7-22 所示；弹道倾角、弹体俯仰角、

导弹—目标视线角的变化曲线如图 7—23 所示；图 7—24 为舵偏角变化曲线；图 7—25 为推力矢量夹角变化曲线。

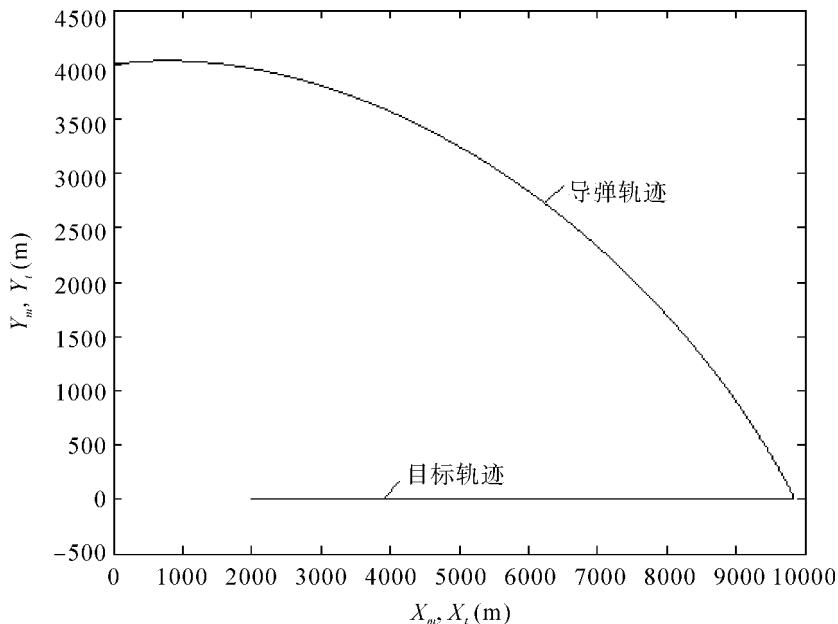


图 7—22 导弹和目标运动轨迹

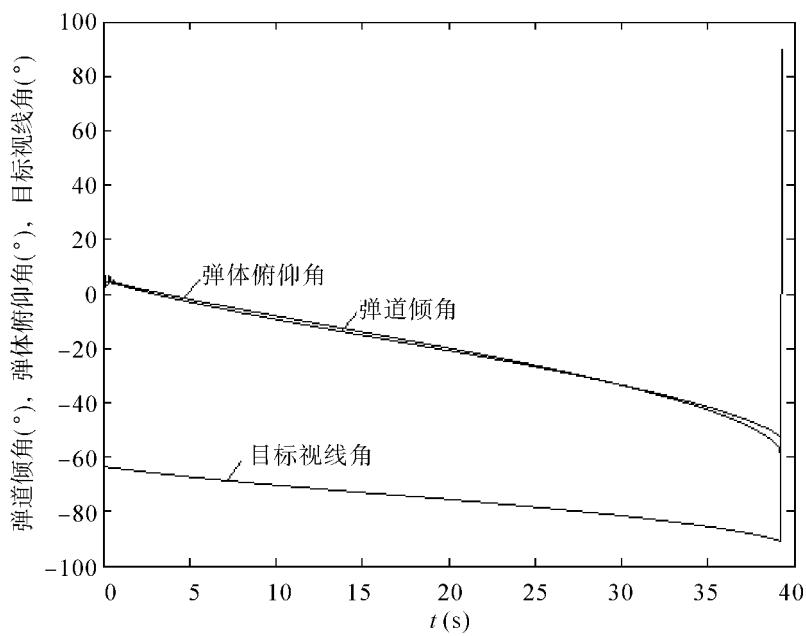


图 7—23 弹道倾角、弹体俯仰角及导弹—目标视线角变化曲线

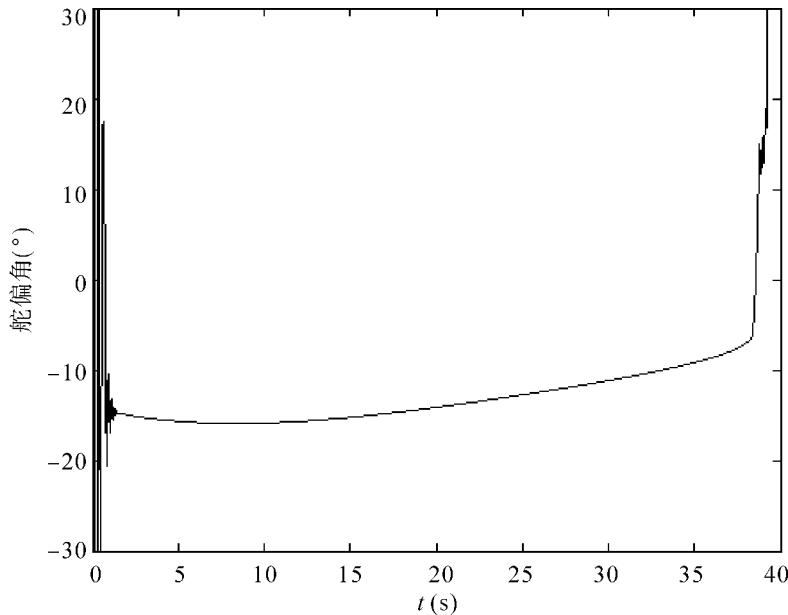


图 7-24 舵偏角变化曲线

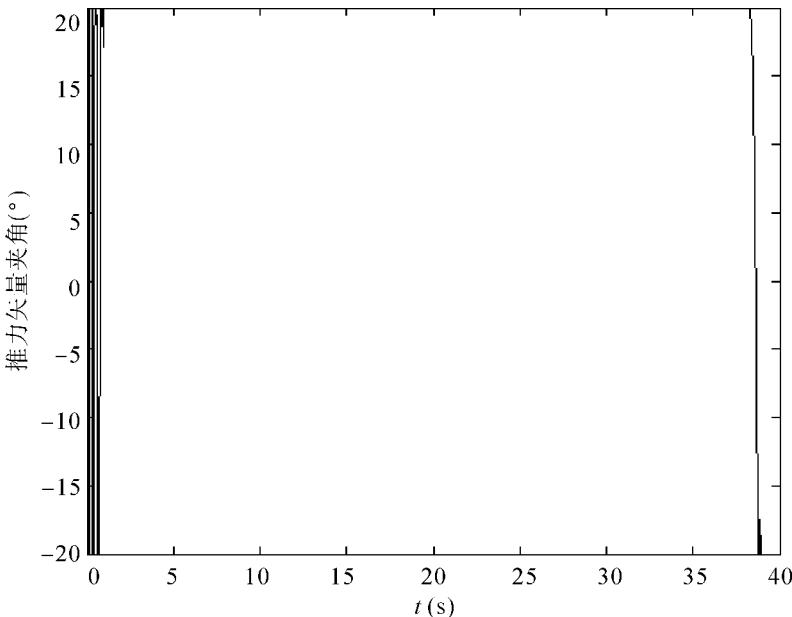


图 7-25 推力矢量夹角变化曲线

(5) 从地面发射导弹，攻击在空中作机动的目标，目标机动的初始位置  $(x_{t0}, y_{t0}) = (4000, 6000)$ 。最终的制导精度为 0.17 m，制导时间 216.6 s。制导过程中导弹和目标运动轨迹如图 7-26 所示；弹道倾角、弹体俯仰角、导弹—目标视线角的变化曲线如

图 7-27 所示；图 7-28 为舵偏角变化曲线；图 7-29 为推力矢量夹角变化曲线。

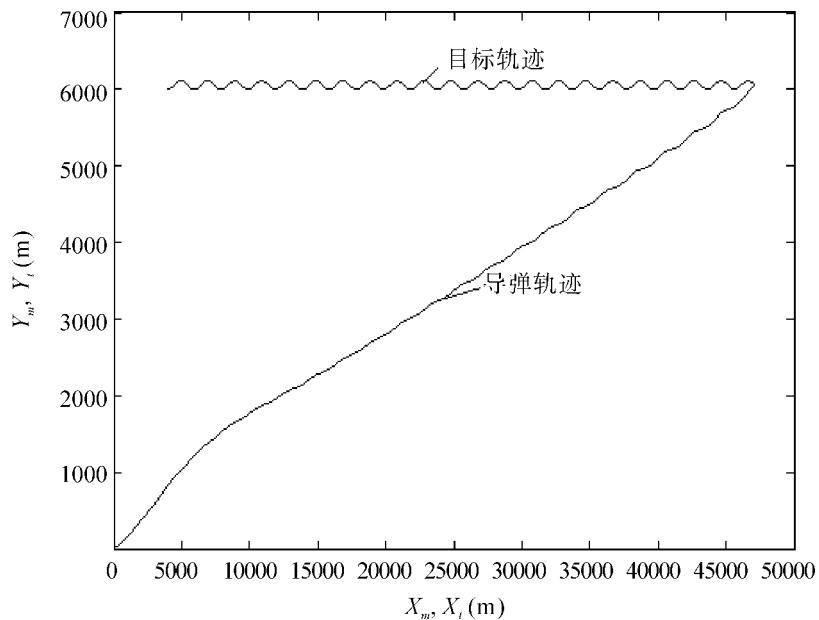
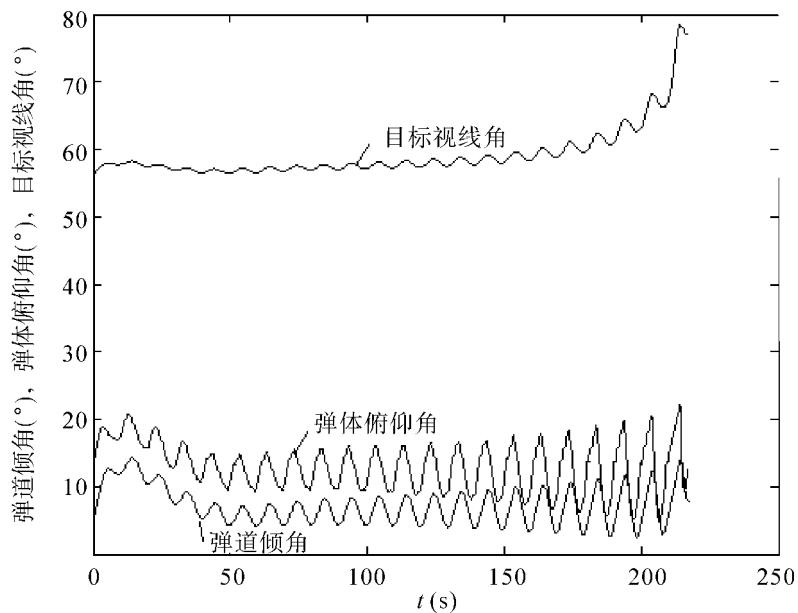


图 7-26 导弹和目标运动轨迹



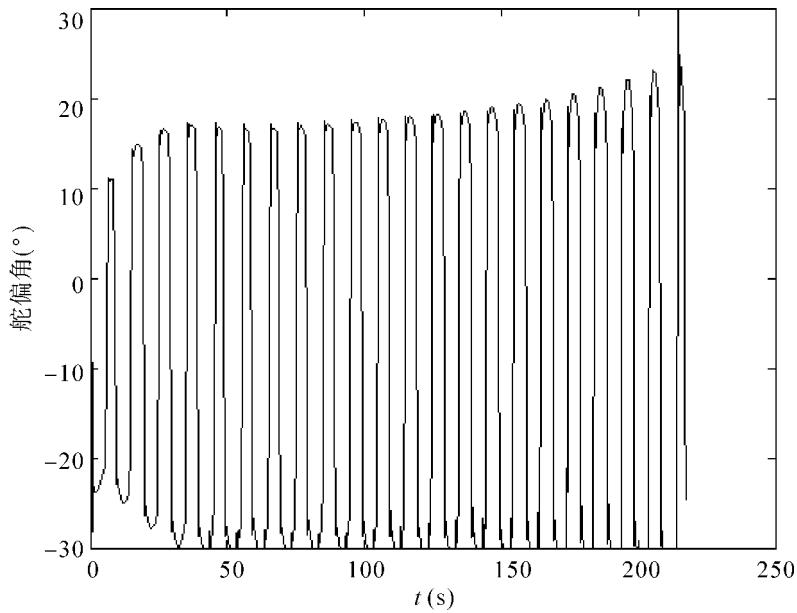


图 7-28 舵偏角变化曲线

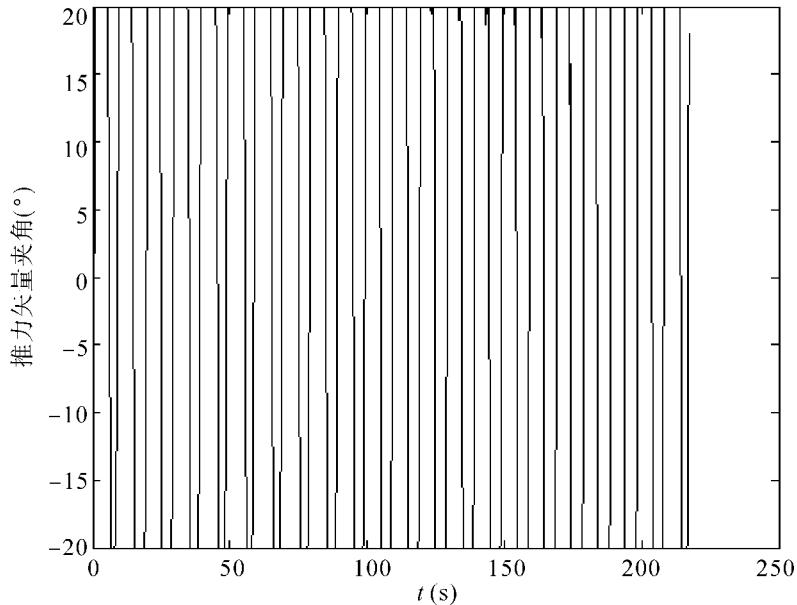


图 7-29 推力矢量夹角变化曲线

#### 7.4.5 结论

以上的理论分析及仿真计算，证明了对发动机推力矢量/气动力复合控制的导弹，采用基于微分几何理论的反馈线性化方法来设计控制算法，在运用传统的比例导引律

下，可以实现对垂直平面内蛇行机动、匀速及匀加速运动目标的有效制导，达到了较高的制导精度，在工程上具有一定的应用前景。

在上述方法中，反馈线性化得以成功实现的前提是被控对象的非线性模型参数要精确已知，即变换式(7-20)中的各动力学系数要精确已知。这些系数和气动力系数相关，对于后者，我们能够掌握的是其标称值，而实际值随飞行条件而变化，变化的规律事先不能准确预知。因此，还应该运用一些智能化的辨识方法，建立自适应鲁棒控制器，适应模型参数的变化，保证反馈线性化方法的有效实现。在建立自适应鲁棒控制器的过程中，可以采用第3章中介绍的自组织方法用于建立对象参数的模型。

## 7.5 本章内容小结

第7章中给出了对作者所提出的预测及控制算法的仿真验证结果。改进型 Demark 趋势项算法的有效性以惯导系统误差预测任务和无人飞行器智能控制系统行动感知器中飞行器测量系统结构的选择为例，进行了演示，并进行了与传统自组织算法、线性趋势项算法精度的比较分析。除数学仿真外，还进行了使用从实际批量生产的导航系统的半实物试验中得到的数据的仿真。

对无人飞行器智能控制系统在“系统生成”的三个基本阶段，行动感知器的预测算法的仿真结果与使用自组织方法和线性趋势项的预测结果进行了比较。

研究了基于微分几何理论的反馈线性化控制算法。为演示所研制的算法工作的品质，仿真了发动机推力矢量/气动力复合控制的导弹对垂直平面内进行蛇形机动、匀速及匀加速运动的目标实施制导的过程，达到了较高的制导精度。

上述各项仿真的结果证实了所研制的预测及控制算法具有足够高的精度，可适应飞行器和目标高度机动的条件，并具有实现简单、快速、紧凑的特点，在工程上具有一定的应用前景。

## 结 论

将书中所介绍的主要研究内容总结为以下几点：

(1) 对现有的在实际中应用的飞行器智能控制系统所作的分析基础上，推荐了最具发展前景的智能控制系统，即“功能—智能控制系统”。该系统可集成传统智能组件，并将目标综合、动态专家系统、行动感知器、决策与控制连接起来，置于功能系统这个统一的框架中，全系统在自调整的原则下运行，保证达到有益结果。

(2) 给出了“功能—智能系统”用于飞行器控制的实现框图，它具有上下两个层次的结构。在上层控制中进行目标综合，完成最佳飞行场景的选择；下层则通过控制作用，以最优方式实现所选择的场景。场景的选择和控制的实现均建立在行动感知器中用自组织算法实现的基准测量系统误差预测模型的基础上。

(3) 飞行器智能控制系统行动感知器的实现是建立预测模型。在用于实现行动感知器算法保障的计算时间及存储量有限的条件下，建议使用改进型 Demark 趋势项算法来建立预测模型。改进体现在两方面：一是建立趋势项时使用了分组测量样本的平均值和选定的滑动基点；二是用自组织方法选择了最优的非线性修正项。测量老化的效应依靠使用“Yazvinski 窗”来克服。该算法的特点是紧凑和实现简单，并保证了较高的精度。

(4) 研制了基于微分几何理论的无人飞行器智能控制系统的继电算法。在所建议的控制算法中挑选出了飞行器的运行区间，在其间可以使用线性调节器代替非线性调节器而不损失精度。使用这个算法大大地简化了实现，这是综合无人飞行器智能控制系统的重要要求。

(5) 进行了返回大气层式无人飞行器“系统生成”基本阶段的分析。在分析的基础上进行了无人飞行器智能控制系统行动感知器算法保障的选择。对无人飞行器运行的每个阶段提出了紧凑和实现简单的预测算法。

(6) 将研制的改进型 Demark 趋势项算法用于建立惯性导航系统输出参数误差预测模型和选择飞行器测量系统最优结构，并将研制的控制算法用于发动机推力矢量/气动力复合控制导弹的控制，实现了对垂直平面内进行蛇形机动、匀速和匀加速运动目标的制导。进行了预测算法和控制算法的仿真，仿真结果证实了所研制算法的有效性和高精度。根据实验室试验的数据进行的仿真结果也展现了所建议的预测算法的有效性。

(7) 书中介绍的研究工作的实用价值在于，所完成的研制算法的综合运用可以提高

无人飞行器完成给定任务的精度，在保证给定精度的条件下，依靠使用更便宜的系统以降低无人飞行器的成本，依靠选择最优飞行路线以节约无人飞行器的能源。

书中所介绍的理论研究工作是将“功能—智能系统”用于飞行器控制的最新尝试，有待在新一代飞行器研制的工程应用中实现。同时，书中所提出的独创性的预测和控制算法，作为独立的组件也可用于当今在研的飞行器控制系统中。

## 参考文献

- [1] Васильев С Н, Жерлов А К, Федосов Е А, et al. Интеллектуальное управление динамическими системами [M]. Москва: Физматлит, 2000.
- [2] Drescher G L. Made-Up minds: A constructivists approach to artificial intelligence [M]. London: Cambridge, the MIT press, 1991.
- [3] Narendra K S. Neural network for control: Theory and practice [J]. Proc of the IEEE, 1996, 84 (10): 1385–1406.
- [4] Rauch H E, Schaecter D B. Neural networks for control, identification, and diagnosis [C] // Proc. of World space congress. Washington: [s. n.], 1992: F4. 4—M1. 06.
- [5] Michalewicz Z. Genetic algorithm+Data structure = Evolution programs [M]. Berlin-Heideberge: Springer-Verlag, 1994.
- [6] Ивахненко А Г. Техническая кибернетика [M]. Киев: Гос. Изд-во техн. лит. УССР, 1962.
- [7] Kambhampati S K, Davis L S. Multi-resolution Path planning for mobile robots [J]. IEEE J. of Robotics and automation, 1986, RA-2: 135–145.
- [8] Khatib O. Real-time obstacle avoidance for manipulators and mobile robots [J]. Intern. J. of Robotics research, 1986 (5) 90–98.
- [9] Емельянов В В. Теория и практика эволюционного моделирования [M]. Москва: Физматлит, 2003.
- [10] Vassilyev S N, Doganovski S A, Maskimkin N N, et al. Integrated control systems with reconfiguration of active plants. Design and applications [C] // Proc. of the second IFAC workshop on new trends in design of control systems, Smolenice: [s. n.], 1997: 517–522.
- [11] Dumont A G, Huzmezan M. Concepts, methods and techniques in adaptive control [C] // Proc. of the American control conference. New York: [s. n.], 2002: 1137–1155.
- [12] Убейко В М, Убейко В В. Экспертные системы в технике и экономике [M]. Москва: Изд-во МАИ, 1992.
- [13] Handelman D A, Stengel R F. An architecture for real-time rule-based [C] // Proc. of the American control conference. Washington: [s. n.], 1987: 1636

—1642.

- [14] Wos L. Solving open questions with an automated theorem proving program [J]. Lecture notes in computer science, 1982, 138: 1–31.
- [15] Kambhampati S K, Davis L S. Multi-resolution Path planning for mobile robots [J]. IEEE J. of robotics and automation, 1986 (2): 135–145.
- [16] Vassilyev S N. Machine synthesis of mathematical theorems [J]. J. of logical programming, 1990, 9 (2–3): 235–266.
- [17] Васильев С Н. Методы синтеза условий выводимости хорновских и некоторых других формул [J]. Сибирский математический журнал, 1997, 38 (5): 1034–1046.
- [18] Мушник Э, Мюллер П. Методы принятия технических решений [M]. Москва: Мир, 1990.
- [19] 程武山. 智能控制理论、方法与应用 [M]. 北京: 清华大学出版社, 2009.
- [20] Нгуен Х З, Шахназаров Г А. Структурирование алгоритмического обеспечения интеллектуальных систем управления сложными динамическими объектами [C] // Интеллектуальные системы: Труды шестого международного симпозиума. Москва: [s. n. ], 2004: 113–116.
- [21] Евстифеев В В, Хаммуд А. Нейронные сети в адаптивных системах [C] // Аэрокосмические технологии: Научные материалы первой международной научно-технической конференции. Реутов: [s. n. ], 2004: 216–223.
- [22] Федосов Е А. Бортовые экспертные системы тактических самолётов 5-го поколения [M]. Москва: Научно-информационный центр ГосНИИАС, 2002.
- [23] Федосов Е А. Критические технологии России [C] // Труды всероссийской конференции государственных научных центров РФ. Москва: [s. n. ], 1995: 80–95.
- [24] Федунов Б Е. Проблемы разработки бортовых оперативно-советующих систем для антропоцентрических объектов [J]. Изв. РАН. Теория и системы управления, 1996 (5): 147–160.
- [25] Федунов Б Е, Романова В Д, Юневич Н Д. Бортовые оперативно-советующие экспертные системы на борту антропоцентрических человеко-машинных объектов [J]. Интеллектуальные системы, 1996, 1 (1–4): 145–157.
- [26] Канащенков А И. Формирование облика авионики перспективных летательных аппаратов [J]. Изв. РАН. Теория и системы управления, 2002 (6): 128–138.
- [27] Позняков П В., Федунов Б Е. Основы информационной интеграции бортовой аппаратуры [M]. Москва: Изд-во МАИ, 1993.
- [28] Виноградов А Н. Динамические интеллектуальные системы: 2. Моделирование целенаправленного поведения [J]. Изв. РАН. Теория и системы управления, 2003 (1): 87–94.

- [29] Виноградов А Н. Динамические интеллектуальные системы: 1. Представление знаний и основные алгоритмы [J]. Изв. РАН. Теория и системы управления, 2002 (6): 72–85.
- [30] Захаров В Н. Интеллектуальные системы управления: основные понятия и определения [J]. Изв. РАН. Теория и системы управления, 1997 (3): 138 –145.
- [31] Анохин П К. Проблемы центра и периферии в физиологии нервной деятельности [M]. Н. Новгород: Изд. Новгород, 1935.
- [32] Неусыпин К А. Синтез интеллектуального измерительного комплекса [M]. Москва: МПУ, 1998.
- [33] Pupkov K A, Neusipin K A, Ke Fang. The genetic program of intelligent systems of dynamic objects [C] // Proc. of the 23<sup>rd</sup> Chinese control conference. Shanghai (China): [s. n.], 2004: 1143–1144.
- [34] Пролетарский А В. Разработка компонентов интеллектуальной системы управления движением [C] // Интеллектуальные системы: Труды шестого международного симпозиума. Москва: [s. n.], 2004: 190–191.
- [35] Пупков К А, Неусыпин К А, Кэ Фан. Алгоритм управления интеллектуальной системы возвращающегося в атмосферу БЛА [C] // X X IX академические чтения по космонавтике. Москва: [s. n.], 2005: 389–390.
- [36] Кэ Фан. Анализ и разработка интеллектуальной системы управления летательными аппаратами одного класса [D]. Москва: МГТУ им. Н. Э. Баумана, 2005.
- [37] Неусыпин К А, Логинова И В. Вопросы теории и реализации интеллектуальных систем [M]. Москва: МПУ, 1999.
- [38] Кэ Фан. Разработка блока синтеза цели интеллектуальной системы управления [C] // X X IX академические чтения по космонавтике. Москва: [s. n.], 2005: 387 –388.
- [39] Ивахненко А Г, Мюллер Й А. Самоорганизация прогнозирующих моделей [M]. Киев: Техника, 1985.
- [40] Неусыпин К А. Направления развития интеллектуальных систем [J]. Автоматизация и современные технологии, 2002 (12): 12–15.
- [41] Кэ Фан, Неусыпин К А. Концептуальный синтез интеллектуальных систем [C] // Тезисы докладов второй международной конференции по проблемам управления. Москва: [s. n.], 2003: 168.
- [42] Пупков К А, Неусыпин К А, Кэ Фан. Модификация трендов Демарка с помощью подхода самоорганизации [J]. Автоматизация и современные технологии, 2004 (1): 10–13.
- [43] Демарк Т. Технический анализ–новая наука [M]. Москва: Диаграмма, 1997.
- [44] 柯芳, Neusipin K A. 智能系统中的自组织算法建模研究 [C] // 2009 国防科技工

业生产制造技术与工艺创新研讨会会刊. 北京: 国防科工局信息中心, 2009: 11—14.

- [45] Головченко В. Б. Прогнозирование временных рядов по разнородной информации [M]. Новосибирск: Наука, 1999.
- [46] Бокс Дж, Дженкинс Г. Анализ временных рядов. Прогноз и управление [M]. Москва: Мир, 1974.
- [47] Винер Н. Кибернетика и общество. Творец и робот: Пер. с англ. [M]. Москва: Тайдекс Ко, 2003.
- [48] 刘小河. 非线性系统分析与控制引论 [M]. 北京: 清华大学出版社, 2008.
- [49] Yesildirek A, Lewis F L. Feedback linearization Using Neural Networks [J]. Automatica, 1995, 31 (11): 1659—1664.
- [50] Ge S S. Robust adaptive NN feedback linearization control of nonlinear systems [J]. Int. J. of system science, 1996, 27 (12): 1327—1338.
- [51] 张友安, 胡云安. 导弹控制和制导的非线性设计方法 [M]. 北京: 国防工业出版社, 2003.
- [52] Kim J H, Jang J S. Nonlinear model inversion control for bank-to-turn missile [J]. AIAA, 95—3318—CP.
- [53] Botrots S M, Caglayan A K, Zacharias G L. Learning the nonlinear inverse flight dynamics using radial basis functions [C] // Proc. of the ACC. Washinton: [s. n. ], 1995: 3510—3514.
- [54] Пупков К А, Неусыпин К А. Вопросы теории и реализации систем управления и навигации [M]. Москва: Биоинформ, 1997.
- [55] 高为炳. 变结构控制理论 [M]. 北京: 中国科学技术出版社, 1990.
- [56] Пупков КА, Коньков ВГ. Интеллектуальные системы [M]. Москва: Изд—во МГТУ им. Баумана, 2003.
- [57] Neusipin K A, Ke Fang. The new orientation of development in the field of intelligent systems [C] // Proc. of 2003 Intelligent automation conference. Hong Kong (China): [s. n. ], 2003: 30—34.
- [58] Неусыпин К. А. Современные системы и методы наведения, навигации и управления летательными аппаратами [M]. Москва: Изд. МГОУ, 2009.
- [59] Мушик Э, Мюллер П. Методы принятия технических решений [M]. Москва: Мир, 1990.
- [60] Бесекерский В А, Попов Е П. Теория систем автоматического управления [M]. СПб.: Изд-во «Профессия», 2004.
- [61] Пупков К А, Коньков В Г. Особенности комплексирования технологий робастного, нейро-нечёткого и адаптивного управления в интеллектуальных систем [C] // Интеллектуальные системы: Труды шестого международного симпозиума. Москва: [s. n. ], 2004: 47—55.

- [62] Пупков К А, Неусыпин К А, Кэ Фан. Интеллектуализация измерительного комплекса летательного аппарата [J]. Изв. Вузов, приборостроение, 2004 (8): 18–23.
- [63] Пупков К А, Неусыпин К А, Кэ Фан. Интеллектуальная система управления динамическим объектом [J]. Авиакосмическая техника и технология, 2004 (1): 20–28.
- [64] Неусыпин К А, Пролетарский А В, Цибизова Т Ю. Системы управления летательными аппаратами и алгоритмы обработки информации [M]. Москва: Изд. МГОУ, 2006.
- [65] Неусыпин К А, Фам С Ф. Алгоритмические методы повышения точности навигационных систем ЛА [M]. Ханой: Изд. Мир, 2009.
- [66] 许树柏. 层次分析法原理 [M]. 天津: 天津大学出版社, 1988.
- [67] 韩力群. 人工神经网络理论、设计及应用 [M]. 北京: 化学工业出版社, 2007.
- [68] 钟珞. 人工神经网络及其融合应用技术 [M]. 北京: 科学出版社, 2007.
- [69] 阎平凡. 人工神经网络与模拟进化计算 [M]. 北京: 清华大学出版社, 2006.
- [70] Брусиловский П М, Розенберг Г С. Проверка неадекватности имитационной модели динамической системы с помощью алгоритмов МГУА [J]. Автоматика, 1981 (6): 43–48.
- [71] Высоцкий В Н. О наилучшем разделении экспериментальных данных в алгоритмах МГУА [J]. Автоматика, 1976 (6): 71–74.
- [72] Грошков А Н, Мельник В С. Задача оптимального управления линейными объектами с распределёнными параметрами (на примере управление качеством воздуха промышленного города) [J]. Автоматика, 1980 (1): 57–66.
- [73] Ивахненко А Г. Долгосрочное прогнозирование и управление сложными системами [M]. Киев: Техника, 1975.
- [74] Ивахненко А Г. Индуктивный метод самоорганизации моделей сложных систем [M]. Киев: Наук. думка, 1982.
- [75] Ивахненко А Г. Системы эвристической самоорганизации в технической кибернетике [M]. Киев: Техника, 1971.
- [76] Ивахненко А Г, Степашко В С. Помехоустойчивость моделирования [M]. Киев: Наук. думка, 1984.
- [77] Ивахненко А Г, Пека П Ю, Востров Н Н. Комбинированный метод моделирования водных и нефтяных полей [M]. Киев: Наук. думка, 1984.
- [78] Козубовский С Ф, Юрачковский Ю П. Информационные критерии селекции моделей [J]. Автоматика, 1981 (4): 80–89.
- [79] Ивахненко А Г. Перцептрон-система распознавания образов [M]. Киев: Наук. думка, 1975.
- [80] Растигин Л А, Маджаров Н Е. Введение в идентификацию объектов управления

[M]. Москва: Энергия, 1977.

- [81] Розенблatt Ф. Принципы нейродинамики. Перцептроны и теория механизмов мозга [M]. Москва: Мир, 1965.
- [82] Хомовненко М Г, Коломнец Н Г. Самоорганизация систем простых частных моделей, прогнозирующих урожай пшеницы [J]. Автоматика, 1980 (1): 28–37.
- [83] Цыпкин Я З. Адаптация и обучение в автоматических системах [M]. Москва: Наука, 1968.
- [84] Юрачковский Ю П. Восстановление полиномиальных зависимостей на основе самоорганизации [J]. Автоматика, 1981 (4): 15–20.
- [85] Юрачковский Ю П. Сходимость многорядных алгоритмов МГУА [J]. Автоматика, 1981 (3): 32–36.
- [86] Юрачковский Ю П, Грошков А Н. Оптимальное разбиение исходных данных на обучающую и проверочную последовательности на основе анализа функций распределения критерия [J]. Автоматика, 1980 (2): 5–12.
- [87] Тихонов А Н, Арсенин В Я. Методы решения некорректных задач [M]. Москва: Наука, 1979.
- [88] Ивахненко А Г, Зайченко Ю П, Димитров В Д. Принятие решений на основе самоорганизации [M]. Москва: Сов. Радио, 1976.
- [89] Бокс Дж, Дженкис Т. Анализ временных рядов. Прогноз и управление [M]. Москва: Мир, 1974.
- [90] Ивахненко А Г. Развитие, современное состояние и будущее МГУА: (Обзор) [J]. Автоматика, 1982 (5): 3–17.
- [91] Ивахненко А Г. Индуктивный метод самоорганизации моделей сложных систем [M]. Киев: Наука, 1982.
- [92] Ivaknenko A G, Ivaknenko G A. Problems of further development of the group method of data handling algorithms. Part1 [J]. Pattern recognition and image analysis, 2002, 10 (2): 187–194.
- [93] Головченко В Б. Прогнозирование временных рядов по разнородной информации [M]. Новосибирск: Наука, 1999.
- [94] Головченко В Б. Прогнозирование временного ряда по экспертным высказываниям [J]. Изв. АН СССР. Техн. Кибернетика, 1991 (3): 47–51.
- [95] Головченко В Б, Носков С И. Комбинирование прогнозов с учётом экспертной информации [J]. Автоматика и телемеханика, 1992 (11): 109–117.
- [96] Кендэлл М Дж, Стыарт А. Многомерный статистический анализ и временные ряды [M]. Москва: Наука, 1976.
- [97] Makridakis, Spyros G. Forecasting: Methods and applications [M]. Santa Barbara: John Wiley, 1978.

- [98] Кэ Фан. Модификация трендов Демарка методом самоорганизации [C] // X VII Академические чтения по космонавтике: Сборник материалов. Москва: [с. н.], 2004: 379.
- [99] Jazwinski A H. Stochastic processes and filtering theory [M]. New York: [с. н.], 1970.
- [100] Пупков К А, Неусыпин К А, Кэ Фан. Модификация интеллектуальной системы в условиях сенсорной депривации [C] // Интеллектуальные системы: Труды шестого международного симпозиума, Москва: 2004: 147.
- [101] 柯芳, 涅乌希宾. 飞行器智能控制系统研究进展 [J]. 兵工学报, 2010, 31 (7): 939–949.
- [102] Брайсон А, Хо Ю-ши. Прикладная теория оптимального управления: Пер. с англ [M]. Москва: Мир, 1972.
- [103] Пупков К А, Егупов Н Д, Коньков В Г, и др. Методы анализа, синтеза и оптимизации нестационарных систем автоматического управления [M]. Москва: Изд-во МГТУ им. Н. Э. Баумана, 1999.
- [104] Лебедев А А, Бобронников В Т, Красильников М Н, и др. Статистическая динамика и оптимизация управления летательных аппаратов [M]. Москва: Машиностроение, 1985.
- [105] Лебедев А А, Карабанов В А. Динамика системы управления беспилотных летательных аппаратов [M]. Москва: Машиностроение, 1965.
- [106] Сейдж Э П, Уайт Ч С. Оптимальное управление системами [M]. Москва: Радио и связь, 1982.
- [107] Моисеев Н Н. Методы оптимизации [M]. Москва: Наука, 1978.
- [108] Федосов Е А, Инсаров В В, Селивухин О С. Системы управления конечными положением в условиях противодействия среды [M]. Москва: Наука, 1989.
- [109] Isidory A. Nonlinear control systems: An introduction [M]. New York: Springer-Verlag, 1985.
- [110] Краснощёченко В И, Крищенко А И. Нелинейные системы: Геометрические методы анализа и синтеза [M]. Москва: Изд-во МГТУ им. Н. Э. Баумана, 2005.
- [111] Федосов Е А. Динамическое проектирование систем управления автоматических маневренных летательных аппаратов [M]. Москва: Машиностроение, 1997.
- [112] Лебедев А А, Чернобровкин Л С. Динамика полета [M]. Москва: Машиностроение, 1973.
- [113] Неусыпин К А, Забелинский А И. Некоторые аспекты теории организации и прогнозирования [M]. Москва: Сигналъ МПУ, 2000.
- [114] Неусыпин К А. Алгоритмические методы повышения точности навигационной системы [D]. Москва: МГТУ им. Н. Э. Баумана, 1996.

- [115] Бобров А. В. Направления совершенствования навигационной аппаратуры летательных аппаратов [J]. Автоматизация и современные технологии, 2000 (7): 29—34.
- [116] Неусыпин К. А., Кэ Фан. Измерительный комплекс летательного аппарата с интеллектуальной компонентой [C] // Электронные средства и системы управления: Сборник материалов международной научно — практической конференции. Томск: [s. n. ], 2004: 255.
- [117] 程云龙. 防空导弹自动驾驶仪设计 [M]. 北京: 中国宇航出版社, 1993.