

东北大学

硕士学位论文

人工智能技术在首钢三炼钢转炉控制中的应用

姓名：马红

申请学位级别：硕士

专业：控制工程

指导教师：王福利;杨昭平

2002. 1. 1

人工智能技术在首钢三炼钢转炉控制中的应用

摘 要

本文介绍了当前转炉炼钢及首钢三炼钢80吨转炉的控制现状，提出了用智能控制方法提高其转炉炼钢终点碳、温一次命中率的技术改造思路。

文章首先详细介绍了当前流行的几种智能控制方法：学习控制技术、模糊控制技术、专家系统、神经网络控制技术，并对四种技术及其具体系统应用、相关内容进行了详细解析，然后结合首钢三炼钢80吨转炉的具体情况，重点提出采用人工神经网络技术方法提高转炉炼钢一次碳温命中率的解决方案。

将人工神经网络技术应用到转炉炼钢过程控制，与增量模型结合，开发出转炉炼钢人工智能静态控制模型。通过在首钢80吨转炉的初步生产试验证明，采用人工智能静态控制模型后，比传统的静态控制模型提高了对炼钢过程各因素之间复杂非线性关系的处理能力，提高了对系统随机因素变化的反应能力和适应能力，因而提高了静态模型的控制精度和终点命中率。

关键词 转炉炼钢 人工智能 神经网络 静态模型

ARTIFICIAL INTELLIGENCE CONTROL
IN SHOUGANG 3TH CONVERTER SMELTING

ABSTRACT

In this paper, artificial intelligence control technique has been used in process of control BOF smelting. As a research, some intelligence control methods are analyzed and compared, such as auto-learning control, fuzzy control, expert control and neural network, then Artificial intelligence static control model of converter smelting has been developed combining with the increment model compared with conventional increment model. Artificial intelligence static control model has raised ability of treating the complicated unlined relationship of various factors in smelting process, adapting and responding to the change of system random factors.

The results of application of BOF artificial static control model on No.3 smelting plant of shougang shows that the application of artificial intelligence technology is favorable to further improve automatic control level in the process of BOF smelting.

The fact proved that the control precision and the end-point carbon temperature hitting ratio of the static control model has been improved.

KEY WORDS converter smelting, artificial intelligence,
neural networks, static model

声 明

本人声明所呈交的学位论文是在导师的指导下完成的。论文中取得的研究成果除加以标注和致谢的地方外，不包含其他人已经发表或撰写过的研究成果，也不包括本人为获得其他学位而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示感谢。

本人签名： 马红

日 期： 2002年1月20日

第一章 绪 论

1.1 当前转炉控制现状

目前在国内外炼钢厂中，采用氧气顶吹转炉炼钢工艺的较多，而且大多采用了先进的计算机过程控制，控制工艺水平比过去有明显的提高，那些容积在 100 吨以上的而且带副枪的转炉也存在一次拉碳率不高的普遍现象，终点碳温同时命中率在 55% 左右，对于国内采用大部分为 100t 以下的中小型转炉来说，由于厂房和生产成本等条件的限制，很难采用目前国际上在大型转炉上普遍使用的静态模型加副枪的动态控制系统，终点碳温同时命中率最高才到 50%。随着技术的进步，采用智能控制方法对转炉进行技术改造来提高炼钢一次拉碳率成为趋势。

根据国内武钢攀钢等相关炼钢厂进行的改造经验数据显示，采用静态模型的“一次拉碳”新方法冶炼连铸钢种，一次拉碳命中率即冶炼终点一次命中率由原来的 20% 以下提高到现在的 60% 以上，在国内炼钢厂同类装备水平的条件下，处于领先水平。同时，实践证明“一次拉碳”还对降低钢液脱氧合金化成本、改善钢质和提高炉龄起到了积极的作用。

以铁水提钒后的半钢为原料炼钢的攀钢转炉为例。过去因受条件限制，攀钢一直采用“高拉碳补吹”终点控制方法进行炼钢。这种传统的方法对高硫铁水炼钢曾经起到了重要的作用，但随着攀钢产能的提高和产品结构的调整以及发展全连铸技术的需要，其负面的影响已从方方面面表现出来，甚至成为了制约攀钢炼钢技术进步和实现全连铸的“瓶颈”环节。从 1999 年开始，攀钢对大量的转炉炼钢数据进行了统计分析和跟踪调查，在此基础上提出了改变炼钢操作传统观念、更新终点控制方法的措施：开展了一次拉碳命中的终点控制方法研究；建立了攀钢炼钢转炉的一次拉碳终点控制模型并进行了典型试验、跟踪试验和推广工作。一次拉碳控制模型的连铸钢种双命中率（终点目标温度和碳含量），在试验中达到 80% 以上，在生产应用中去年 9、10 月份连续两个月最好水平 Q 类钢达到 65.5%，铝镇静钢达到 51%。攀钢炼钢转炉一次拉碳终点控制技术的研究及其模型的建立，是攀钢投产以来转炉冶炼工艺上的重大突破。它不仅提高了

连铸钢种的一次命中率，为攀钢实现全连铸奠定了坚实的基础，而且，连铸钢种按一次拉碳模型进行冶炼终点控制，在终点钢水碳含量相同的条件下，氧含量降低了 1 2 0 - 1 4 0 p p m，钢渣 T F e 降低了 2 个百分点以上，转炉冶炼时间缩短了 4 m i n 以上。

另外通过武汉钢铁公司 80 吨转炉试验，采用了转炉人工智能静态控制模型后，与传统的静态控制模型控制相比，提高了静态模型的控制精度，一次终点碳温同时命中率可达到 6 2 . 2 %，超过了传统的静态模型。将人工智能静态控制模型应用到转炉生产中，可以作为吹炼过程控制的重要参考，在一定程度上可以替代熟练钢工进行吹炼控制和终点判断。

1.2 首钢 80 吨转炉控制现状及项目的提出

首钢第三炼钢厂，是首钢生产高附加值的并具有相当特点的大型炼钢厂，目前有三座 80 吨不带副枪的氧气顶吹转炉，四条方坯连铸生产线，目前已采用计算机操作。近几年，该厂逐年加大采用高新技术工艺及控制水平改造的投入，新上了两座 LF 炉，一座 VD 炉，并且在 2001 年底将一条小方坯连铸生产线改造为一条巨型坯生产线，所进行的改造大大提高了三炼钢的整体冶炼水平。

尽管三座转炉的炼钢方法基本上应用先进的计算机过程控制，但采用的转炉冶炼终点控制技术依然是“高拉碳补吹”操作方法，这对进一步扩大冶炼钢种，提高钢水品质，非常不利。如何采用先进的计算机智能控制进行“一次拉碳”操作方法是一个摆在三炼钢面前急需解决的课题。1999 年在首钢总公司的支持下，首钢自动化设计院、钢铁研究总院和首钢总计控共同开发首钢三炼钢转炉人工智能静态控制模型软件。以使转炉操作在加料、供氧等方面优化，满足生产的要求，从而大大提高转炉一次拉碳率。

第二章 转炉炼钢终点控制工艺

2.1 转炉炼钢终点控制工艺

转炉终点控制主要是指终点温度和成分的控制，转炉兑入铁水后，通过供氧，造渣，经过一系列物理化学反应，钢水达到所炼钢种的要求，这一时刻我们称之为“终点”。到达终点的具体标志即：钢中达到所炼钢种的控制范围；钢中磷硫含量低于规格下限要求一定范围；出钢温度保证顺利进行浇铸；对于沸腾钢，钢水应有一定氧化性；出钢时机主要是根据钢水的含碳量、温度等，所以重点也称作“拉碳”。终点控制不准确，不仅影响冶炼时间、转炉寿命，而且会增加金属消耗等。例如拉碳偏高时，需要补吹，产生了大量的一氧化铁，金属消耗增加，缩短炉衬寿命。若拉碳偏低时，不得不改钢号，或增碳，这样既延长了冶炼时间，也打乱了正常的生产秩序，影响质量。所以拉碳准确是终点控制的一项基本操作。

2.2 影响转炉炼钢终点控制的几个因素及其他

转炉炼钢过程是一个周期性的升温降碳过程，主要目的是在吹炼终点时尽可能达到目标钢水成份含量和温度。但由于炼钢过程是非常复杂的多元多相高温反应过程，影响钢水终点成份和温度的因素很多，主要因素有：炉龄、空炉时间、铁水装入量、废钢装入量、铁水硅含量、铁水锰含量、欠水磷含量、铁水硫含量、铁水温度、吹炼过程铁皮加入量、生白加入量、石灰加入量、轻烧加入量、萤石加入量、吹氧量等 16 种，其中各因素之间存在着线性关系，另外有些因素枪位、喷溅情况等对终点碳温的影响也不容忽视。

在实际冶炼过程中，采取何种控制方法把这些相关的因素考虑进去，并进行相应的操作来控制终点碳温的范围是一个需要深入研究的课题。

由于转炉炼钢过程中复杂的物理化学变化过程无法用数学方程时行准确的描述，影响了各种控制中模型的计算精度。将智能控制技术应用到炼钢过程控制中，

可在一定程度上克服常规模型的不足,可进一步提高数学模型的控制精度,改善控制效果。

结合当前各炼钢厂的实际情况,通过几个钢厂的试验,成功开发除了静态模型与人工神经网络技术相结合的人工智能控制系统,在中小型转炉上推广使用。同时进一步研究开发利用炉气分析实现转炉吹炼过程动态控制系统,对改变我国转炉炼钢自动控制水平落后的状况,缩小与发达国家的差距,提高我国转炉生产自动控制水平将具有十分重要的意义。

第三章 几种智能控制方法的介绍

3.1 综述

智能控制是自动控制理论、人工智能(AI)、运筹学和计算机科学相结合的产物。智能控制系统是在控制论、信息论、人工智能、仿生学、神经生理学及计算机科学发展的基础上逐渐形成的一类高级信息与控制系统。结合具体的工业生产过程,各种智能控制系统正在发挥巨大的经济和社会效益。

智能控制与智能自动化技术是众多学科和工程技术之集成。一方面,包括经典控制理论及现代控制理论在内的传统控制理论与技术无法满足工业及人类生活中日益复杂的控制与自动化要求;而另一方面,在计算机科学技术地推动下,人工智能科学与技术取得巨大进展。在此情况下,智能控制与智能自动化技术产生了,并逐渐发展起来。

尽管最初人们认为智能控制是自动控制理论(AC)与人工智能(AI),或 AC、AI 与运筹学(OR)的结合,但事实上,智能控制是一门仍在不断丰富和发展中的具有众多学科集成特点的科学与技术。它不仅包含了 AC、AI、OR、系统理论(ST)和计算机科学(CS)的内容,而且还从生物学、生理学、心理学、协同学及人类知识理论

等学科中吸取了丰富的营养。目前,在世界范围内,智能控制和智能化科学与技术正在成为自动化领域中最兴旺和发展最迅速的一个分支学科,并被许多发达国家确认为面向 21 世纪和提高国家竞争力的核心技术。

(1)智能(Intelligence):智能控制中的智能是指有自治能力的程度(Degree of Autonomy)。

(2)自治能力(Autonomy):自治能力是学习或获取各种知识、并利用此知识进行决策以改善自身行为的能力。

(3)智能控制器(Intelligent Controller):用智能控制方法或传统的系统及控制技术设计或实现的、用于模拟或完成正常的由人、动物或生物系统所完成的功能的控制器。

(4)智能控制系统(Intelligent Control System):智能控制系统是具有某种程度自治性的控制系统。

(5)智能控制方法:(Intelligent Control Methodology):利用旨在模拟人、动物或生物系统功能的技术或过程来为动态系统构造或实现控制、以达到预定要求的控制方法的集合。

3.1.1 智能控制系统的特征

- 处理各种不确定性、定性信息和数据结构的能力。
- 处理非结构化信息和数据的能力
- 对具有高度抽象性的离散符号指令作出响应的能力
- 辩识主控系统结构或构成变化的能力
- 处理和利用各种不同性质的知识的能力
- 根据主控系统或环境变化,对自身参数或结构进行修正或重构的能力
- 在运行过程中学习和获取关于对象和环境新知识并利用新知识改进控制行为的能力
- 基于对象行为预测的 controls 的多目标性。

任何具备上述一种或多种能力的控制系统均被认为是智能控制系统。从这个意义上讲,经典的反馈控制、变结构控制、自校正控制及自适应控制均被认为属于智能控制的范畴,它们与通常所说的智能控制的区别在于它们仅具有较低层次智能。而智能控制理论及应用研究的目的是利用包括传统控制及系统理论在内的已有各种理论及技术来构造在某种程度上具备上述特征的控制系系统,并最终实现具有完全自治力的系统。

目前关于智能控制的研究和应用沿着几个主要的分支发展,主要为:自适应控制(Adaptive Control)、模糊控制(Fuzzy Control)、神经网络控制(Neural Net-based Control)、基于知识的控制(Knowledge Based control)或专家控制(Expert Control)、复合智能控制(Hybrid Intelligent Control)、学习控制(learning Control)和基于进化机制的控制(Evolutionary Mechanism Based Control)。这些有的已在现代工业生产过程的智能控制与智能自动化投入实际应用。

3.2 几种智能控制方法的介绍

3.2.1 学习控制

智能控制是一种模拟人类智能的高级控制系统,实现高度智能化控制系统是智能控制的一个主要研究内容,而实现这一目的的重要技术就是采用学习控制技术。学习控制技术的发展是随着相关的模糊逻辑、神经网络、进化算法、专家系统等技术的发展而发展。在解决日益复杂多变的对象和环境的控制中,学习控制技术显示出重要的作用和巨大的生命力。

学习控制是一个能在其运行过程中逐步获得环境和被控对象未知信息,经过积累控制经验,并在一定的评价标准下进行估值、分类、决策和不断改进系统品质的自动控制系统。它具有搜索、识别、记忆、推理、修改和优化等功能。

关于学习问题早在六十年代后期就有研究。由于当时的学习技术缺乏相应的记忆和推理手段,较多的研究是搜索和识别方法。随着专家系统、模糊逻辑、神

神经网络、进化算法及其混合技术的发展，学习控制方法实现记忆、推理、优化等功能成为可能。

学习是一个复杂的过程，既包括多方面的学习内容又包括多方式的学习方法。从学习的多方式来看，学习控制的学习方式可以分为：有导师学习、无导师学习和加强学习。从学习的多内容来看，学习控制可以分为：1)面向控制器的参数学习--学习如何调节控制器参数；2)面向控制器的结构学习--学习如何调整控制器的结构；3)面向环境学习--考虑环境发生变化时学习如何修改控制行为；4)面向复杂不确定被控对象的学习--学习如何模拟和逼近对象的模型。

学习控制采用的主要理论有：模糊逻辑、人工神经网络、遗传算法、专家系统等。在这些理论中，模糊逻辑系统是基于知识的系统。它可以利用模糊逻辑表示和推理知识。尤其模糊逻辑的模糊语言描述的特点，使得模糊逻辑控制适合复杂的过程控制。但由于模糊逻辑对学习模型和学习算法缺少理论描述，因此为了弥补模糊逻辑在描述学习模型上的不足，模糊学习控制常采用如下技术：1)采用模糊逻辑的理论。如模糊基正交最小二乘技术、模糊最近聚类技术等。2)采用参考模型技术。3)采用人工神经网络理论。如 ART 技术，BP 技术等。4)采用进化算法。5)采用神经模糊网络技术等。通过混合其他技术发展模糊逻辑的学习算法是模糊逻辑在学习控制中的一个重要方法。

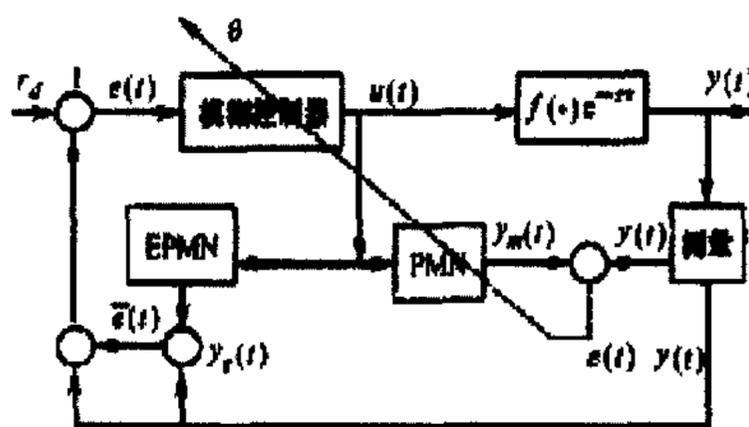


图 3.1 具有时间延迟的非确定过程学习系统

Fig.3.2 Learning systems of uncertain plant with time delays

人工神经网络是由大量神经元广泛联接而构成的非线性动力系统。它的基本神经元在输入输出结构上是简单非线性(称为作用函数),而大量的这种神经元按一定的拓扑结构和学习调整方法所构成的神经网络能表示出丰富的特征:并行计算、分布存储、可变结构、高度容错、非线性运算,自我组织、学习/自学习等。这些特性是人们长期追求和期望的系统特性,这使得神经网络被广泛研究和应用在学习控制中。但由于神经网络只能表示数值型数据,因此单纯使用神经网络作为学习模型,其应用受到限制。为了扩大神经网络学习控制的学习功能,常用的技术有:1)改进神经网络的学习模型;2)采用遗传算法;3)采用模糊神经网络技术;4)与模糊逻辑系统结合技术等。

遗传算法作为一种非确定的拟自然随机优化工具具有并行计算、快速寻找全局最优解等特点。它可以和其他技术混合使用,用于智能控制的参数、结构或环境的最优控制。

专家学习控制是通过有导师学习或无导师学习完善专家控制的特性,提高专家控制的智能和自动化过程。专家学习控制的过程可以理解为:通过给定的专家信息或通过机器感知获取必要信息,根据不同的学习类型,采用不同的学习算法或学习策略对新获取的知识进行学习。学习结果决定所需要采取的措施。由于专家控制存在自动地获取知识困难、无自学能力、知识面太窄等问题,因此为了改进专家控制的学习功能可以采用如下技术:1)模糊逻辑;2)神经网络;3)遗传算法;4)模糊神经网络;5)遗传神经网络;6)模糊、遗传和神经的混合技术等。但在实际应用中,由于专家控制具有较高的工程费用,因此有关专家学习控制的研究很少有报道。

3.2.2 模糊控制方法

由于模糊控制主要是模仿人的控制经验而不是依赖控制对象的模型,因此模糊控制器实现了人的某些智能。它也是智能控制的一个重要分支。

模糊集理论是介于逻辑计算和数值计算之间的一种数学工具，它形式上利用规则进行逻辑推理，但其逻辑取值可在 0 与 1 之间连续变化，采用数值的方法而非符号的方法进行处理。符号处理方法允许直接用规则来表示结构性的知识，但不能直接使用数值计算的工具，因而也不能用大规模集成电路来实现 AI 系统。而模糊系统可以兼有两者的优点，它可用数值方法来表示结构性知识，并用数值方法进行处理，因而可用大规模集成电路来实现模糊系统。

模糊控制主要研究那些在现实生活中广泛存在的、定性的、模糊的、非精确的信息系统的控制问题。这方面的工作首先是由 Zadeh 建立模糊集理论开始的。至今模糊控制已经得到了广泛的应用。模糊控制有三个基本组成部分：模糊化、模糊决策、精确化计算。模糊控制的工作过程简单地可描述为：首先将信息模糊化，然后经模糊推理规则得到模糊控制输出，再将模糊指令进行精确化计算最终输出控制值。

模糊系统可以看作是一种不依赖于模型的估计器，给定一个输入，便可以得到一个合适的输出。它主要依赖模糊规则和模糊变量的隶属度函数，而无需知道输入与输出之间的数学依存关系。模糊系统也是一种可以训练的非线性动力学系统，因而也存在诸如稳定性等需要研究的问题。

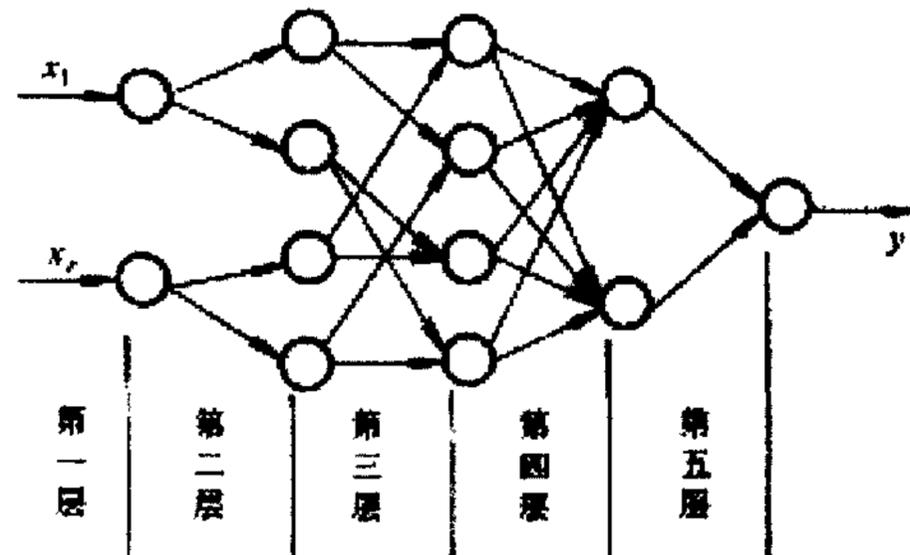


图 3.2 FC 结构

Figure3.2.FC structure

由于模糊控制不需要精确的数学模型，因此它是解决不确定性系统控制的一种有效途径。但它对信息进行简单的模糊处理会导致被控系统控制精度的降低和动态品质变差。为了提高系统的精度则必然要增加量化等级，从而导致规则的迅速增多，因此影响规则库的最佳生成，且增加系统的复杂性和推理时间。所以混合模糊控制的思想已引起大家的重视。例如模糊 P I D 调节器、模糊专家系统、自适应自学习模糊控制、模糊神经网络控制等。

可以看出，模糊控制既具有广泛的应用前景，又具有许多待开发和研究的理论问题。因此，可以说模糊控制是智能控制不可缺少的一部分。自从 1965 年美国加利福尼亚大学的 Zadeh 教授创建模糊集理论和 1974 年英国的 E.H.Mamdani 成功地将模糊控制应用于锅炉和蒸汽机控制以来，模糊控制得以广泛发展并在现实中得以成功应用，其根源在于模糊逻辑本身提供了由专家构造语言信息并将其转化为控制策略的一种系统的推理方法，因而能够解决许多复杂而无法建立精确的数学模型系统的控制问题，是处理推理系统和控制系统中不精确和不确定性的一种有效方法。从广义上讲，模糊控制是基于模糊推理，模仿人的思维方式，对难以建立精确数学模型的对象实施的一种控制。它是模糊数学同控制理论相结合的产物，同时也构成了智能控制的重要组成部分。模糊控制的突出特点在于：

(1) 控制系统的设计不要求知道被控对象的精确数学模型，只需要提供现场操作人员的经验知识及操作数据。

(2) 控制系统的鲁棒性强，适应于解决常规控制难以解决的非线性、时变及滞后系统。

(3) 以语言变量代替常规的数学变量，易于构造形成专家的“知识”。

(4) 控制推理采用“不精确推理”(approximate reasoning)。推理过程模仿人的思维过程，由于介入了人类的经验，因而能够处理复杂甚至“病态”系统。

模糊控制在理论上突飞猛进的同时,已越来越多地成功地应用于现实世界中。然而相比于传统的控制方法,应用于实时控制中的模糊控制到底有什么优势?许多学者在研究证明采用启发式规则的模糊控制器性能优于常规控制器性能时,是否进行了平等的比较,也即是否用性能较好的模糊控制器与性能较差的PI控制器进行着比较?

可以说每一种新的技术与方法在体现其优越性能的同时,也必定存在其局限性。应当承认,在对客观对象进行观察和认识时,模糊控制必竟不如人的认识全面深刻,因而若要达到真正仿人智能的效果,仍然需要其自身在工程应用中不断地朝着自适应、自组织、自学习方向发展。本文深入分析模糊控制研究体系内容,力求全面揭示模糊控制发展现状,从中展示模糊控制本身强大的生命力。

模糊控制发展到现阶段,其理论体系明显呈现以下几个分枝:模糊控制器的自适应功能研究;模糊控制器的解析结构研究;模糊控制的稳定性分析。下面以适应模糊控制器为例进行介绍

3.2.2.1 适应模糊控制器

在复杂系统的控制过程中,模糊控制器的自适应功能,一直是控制系统设计者们所追求的目标。这是因为基本模糊控制器源于操作人员的基本知识,不具有适应对象持续变化的能力。模糊自适应控制器的设计也同样遵循着以下两个目标功能

(1)根据被控过程的运行状态给出合适的控制规则,即控制功能。

(2)根据给出的控制规则的控制效果,对控制器的控制决策进一步改善,以获得更好的控制效果,即学习能力。

具有自适应功能模糊控制器的杰出代表为自组织模糊控制器(SOC),SOC在基本的模糊控制器基础上增加了调整控制机构,将控制器分为面向对象的控制级和面向控制器的规则调整级,规则调整级通过计算系统的性能指标来校正控制规则

的关系矩阵，建立、修改规则库，从而大大提高了系统性能。系统地分析并全面介绍了近年来自校正模糊控制器的发展状况，并给出了一种启发式自校正模糊控制算法，控制级和规则调整级采用同样的模糊推理策略，大大增加了自适应模糊控制器的鲁棒性，也使得控制器更加易于实现。

量化因子和比例因子的自调整是自适应模糊控制应用于实时控制中最有效的手段。控制器在线识别控制效果，依据上升时间、超调量、稳态误差和振荡发散程度等对量化参数进行自整定。量化因子的自调整不仅在方法上有了许多进展，同时也在实践中取得了成功的应用。

自学习模糊控制器是源于自适应模糊控制器又高于自适应模糊控制器的智能型控制器。自学习模糊控制器运用模糊推理的手段，在其运行过程中可逐步获得受控对象及环境的非预知信息，积累控制经验，并在一定的评价标准下进行估值、分类和决策，从而不断改善系统的品质。相比于依赖于对象的辨识的自适应模糊控制器，自学习模糊控制器并无本质的区别，它体现了模糊控制器由低级向高级、由常规向智能化发展的必然趋势，其优势体现在以下两点：

(1)对系统先验知识要求更少，对系统的非线性、不确定性及时滞等，具有更强的适应能力。

(2)具有实时搜索、特征辨识、特征记忆、直觉推理和多模态控制等仿人智能的特征。

该方法引入参考模型和重复学习控制机构。系统通过搜索、识别、记忆以及推理学习，寻求合理的控制行为，建立对于各控制环节的独立、解耦的规则库。该学习方法类似于人的学习过程，有效地克服了多变量间的强耦合和过程的时间滞后。它包括4个功能块：参考模型、学习算法、规则库的建立机构以及被控过程。

自学习模糊控制的另一类为模糊模型参考学习控制(FMRLC)，其结构类似于常规的模型参考自适应控制(MRAC)，由模糊语言信息及模糊推理过程表达的参考模型协助产生学习信号，参考模型的特性由理想的性能指标决定。学习机构在误

差信号的驱使下,不断修正模糊控制器的知识库,使得闭环系统特性与参考模型特性一致。相比于 MRAC,采用 FMRLC 方法不仅设计方法简单,无需建立系统数学模型,而且控制系统收敛速度快,抗干扰能力强。

3.2.2.2 基于神经网络的模糊控制器

基于神经网络的模糊控制器(FNN)近年来已逐渐成为研究的热点,原因在于二者之间的互补、关联性。模糊控制和神经网络二者各自的优势在于:模糊控制易于获得由语言表达的专家知识,能有效地控制难以建立精确模型而凭经验可控制的系统,而神经网络则由于其仿生特性更能有效利用系统本身的信息,并能映射任意函数关系,具有并行处理和自学习能力,容错能力也很强。在集成大系统中,神经网络可用于处理底层感知数据,模糊逻辑可用于描述高层的逻辑框架。神经网络和模糊系统均属无模型控制器和非线性动力学系统,但神经网络适合于处理非结构化信息,而模糊系统对处理结构化的知识更有效。二者的结合有效地推动了自学习模糊控制的发展。

模糊神经网络的控制大致可分为三类。第一类是直接利用神经网络的学习能力及映射能力,去等效模糊系统中的各个模糊功能块,第二类是在神经网络模型中引入模糊逻辑推理方法,使其具有直接处理模糊信息的能力,第三类是把模糊系统和神经网络集成在一个系统中,以发挥各自的优势。

用神经网络实现模糊控制的具体方法有很多。这里给出了一类基于神经网络建立模糊规则的自适应模糊控制系统。用 P_i 代表各个前提变量的真实度,代表各个规则的使用权值,通过神经网络的训练样本可学习、修改各个 p_i , w_i 的系数,从而达到在控制过程中调整隶属度函数和控制规则的目的,使原模糊控制系统的自学习功能得到了加强。采用模型联想记忆系统(FAMOVVS)实现自组织模糊控制的方法。该系统采用 LVQ 网络及其关联的学习算法产生模糊控制器前提条件部分隶属函数,在特定的限制条件及稳定性约束下,单独训练每个控制律以产生结论

部分的最优模糊控制规则。直升飞行控制器仿真研究表明,神经网络大大增强了自组织模糊控制器的学习能力。通过采用动态系统的增列式学习方法,提出 GARIC 控制器结构,模糊控制器的学习和整定是采用模糊推理和一个前向网络的结合实现的,并采用梯度下降法自动修正规则基。该系统包含三个不同的神经元:作用选择神经元(ASN),作用评价神经元(AEN)和随机作用神经元(SAM)。ASN 起普通模糊控制器的作用,AEN 对系统进行评价,SAM 随机综合 ASN 和 AEN 的作用,然后产生控制信号。利用两层前向网络结构构造了反馈控制器,而保留与自组织模糊控制相似的自组织机制,根据性能判决表,通过误差以及误差变化率得到神经网络的训练样本,从而实现自组织神经网络控制。这种结构改善了原有常规模糊控制器自调整时间长和计算量大的缺陷。

通常的模糊神经网络系统可看作分层前馈神经网络,然后用 B-P 网来实现。Junbong Nie 等在结构上做了一些改进:通过引入局部网络结构和前馈推理算法,用整个 RBF(Radial Basis Function)网来表达竞争组织机构和重复学习控制算法,使得基于 FRBF 网的模糊控制器能够实现“无师”学习。

模糊神经网络近年来的研究报告层出不穷,人们期待着它能够对整个控制学科作出突破性的贡献。但在实际中存在的问题是神经网络较复杂,学习计算时间长。如何简化模糊控制器的量化过程,将其转换成易于学习的算法;如何确定学习指标,构成有效的模糊控制学习系统;如何将模糊控制器的调整转化为等价的神经网络学习,利用等价的模糊逻辑来初始化神经元网络;模糊神经网络的稳定性、收敛性等,都是有待进一步研究的问题。

3.2.2.3 模糊控制今后发展的方向

非线性模糊自适应控制近年来有了很大的发展。巨大的进展一方面解决了一个又一个理论和实际问题,同时也提出越来越多的待解决的问题。可以说鉴于其本身的复杂性,建立类似线性控制理论一样完善的模糊控制理论几乎是不可能的,

一如非线性系统学科的完善程度达不到线性理论一样。但在建立的模糊控制理论中，可以尽可能地阐述系统的基本性质，提供可行的分析方法，尤其是发展起一些实用的综合方法。

模糊控制的发展基本上可分为两个阶段：初期的模糊控制器是按一定的语言控制规则进行工作的，而这些控制规则是建立在总结操作者对过程进行控制的经验基础上，或设计者对某个过程认识的模糊信息的归纳基础上，因而它适用于控制不易获得精确数学模型和数学模型不确定或多变一类对象。后期的模糊控制器则是基于控制规则难以描述，即过程控制还总结不出什么成熟的经验，或者过程有较大的非线性以及时滞等特征，试图吸取人脑对复杂对象进行随机识别和判决的特点，用模糊集理论设计自适应、自组织、自学习的模糊控制器。模糊控制从诞生到现在仅仅经历了二、三十年的时间，就已在经济、医学、军事尤其是工业应用方面取得了巨大的发展。然而，当今的模糊控制研究已经进入了新的阶段。总的来说，模糊控制理论落后于应用的发展，纵观最近的国内外文献表明，现在的模糊控制研究的注意力也主要集中在如何给它在理论上注入新鲜血液。模糊控制将在以下几个方面进行进一步研究：

(1)研究模糊控制器非线性本质的框架结构及其同常规控制策略的联系，揭示模糊控制器工作的实质和机理。它可提供系统的分析和设计方法，解决一些先前被认为是困难但却是非常重要的问题，如稳定性、鲁棒性等。

(2)在模糊控制已取得良好实践效果的同时，从理论分析和数学推导角度揭示和证明模糊控制系统的鲁棒性优于常规控制策略。

(3)研究模糊控制器的优化设计问题尤其是在线优化问题。模糊控制器源于采用启发式直觉推理，其本身的推理方式难于保证控制效果的最优。解决模糊控制器的优化问题也是进一步将其推向工业应用的有效手段。

(4)在理论研究中规则本身非线性问题及实际应用中模糊控制器的规则自学习和自动获取问题。前者之所以成为难点，是因为具有线性规则的模糊控制器本身

已属非线性控制,非线性规则则更使问题的系统化研究方法困难;后者则构成智能控制中专家系统的核心问题。

(5)将模糊控制同其它领域的理论研究方法相结合,利用模糊控制的优势解决该领域中过去用常规方法难以解决的问题。

模糊控制发展的前景是乐观的,随着相关学科的日新月异的发展,其自身也在不断完善,潜在的能力也不断发挥出来,尤其在工业中的应用将会日益广泛和成熟。

3.2.3 专家系统方法

毫无疑问,现在人工智能领域应用最多的是专家系统。从本质上来看,专家系统是由许多收集的规则组成,它清楚地表示了知识和结果。规则的最简单形式是 I F—T H E N 结构。一般的专家控制系统由三部分组成。其一是控制机制,它决定控制过程的策略,即控制哪一个规则被激活、什么时候被激活等。其二是推理机制,它实现知识之间的逻辑推理以及与知识库的匹配。其三是知识库,包括事实、判断、规则、经验以及数学模型。专家系统的迅速发展为人工智能学科的研究注入了强有力的生机,为人工智能走向实用奠定了基础。然而,专家系统的发展遇到了知识获取的“瓶颈”、“窄台阶”等困难,使其支持能力受到极大的限制而受到严重的挑战。因此,单一依靠专家系统的控制已无法满足实时性、灵活性、自适应性等的要求。专家系统的混合控制技术正引起各国专家的关注,如神经网络专家系统、专家模糊控制等。

作为智能控制系统的一个重要分支,专家控制系统离不开知识的表示、运用、获取和更新等知识工程。广义地说,设计控制系统的过程即是有效地组织和运用知识的过程。控制器是运用知识进行推理、决策而产生控制作用的装置,它一般由计算机完成,对于传统控制,控制对象模型及性能要求可以看成是用数值表示的知识。控制算法则是运用知识进行决策计算,以产生所需的控制作用。在智能

控制系统中，有一部分是数值类型的知识，但更主要的知识是一些经验和规则，它们用符号形式表示。在这种情况下，控制器设计的问题便是如何获取和运用知识进行推理和决策，以产生有效的控制。如果此系统带有学习功能，则还有一个如何更新知识以实现学习功能的问题。

80年代以来，专家系统在钢铁工业中得到了广泛的应用。日本钢铁工业A I技术使用最多，应用水平最高，居于领先地位。特别是在高炉、连铸、烧结、轧钢等生产过程中建立了大量的专家系统，如高炉异常炉况诊断专家系统、连铸漏钢预报专家系统等等，在实际生产应用中都取得了很好的效果。

专家系统在转炉炼钢应用中取得了较好的效果。如新日铁开发的转炉吹炼过程辅助专家系统(LD—ES)，包括静态推理、副论测量前后的推理和终点成份的推理三个部分。静态推理是根据当前条件和钢种，考虑到枪测量时间、测量后采取修正措施的时间、吹炼后期脱碳和升温系数，决定副枪测试时的目标成份和温度，辅助静态模型。主要是关于估计炉渣—金属反应规则的推理。终点成份的估计主要是根据吹炼过程情况，估计金属终点成份，特别是终点磷含量的估计。

日本NKK公司福山制铁所第三炼钢厂将静态模型、副枪控制、炉气分析和专家系统结合起来，形成了转炉吹炼过程人工智能控制系统。人工智能系统主要包括吹炼过程造渣情况判断和出钢预报以及反应转变点的预报。通过应用专家系统，把操作工片面的、感性的知识和经验模型化，引入“成渣”和“喷溅”的判断，通过判断结果，确定吹炼模式，调节吹炼参数。同时，专家系统包括根据终点副论数据和钢水磷含量的推测值等信息，进行出钢、补吹、冷却操作的判断等功能。

国内也在开发专家系统在钢铁工业中的应用研究，如转炉动态控制辅助专家系统的研究和吹炼后期补吹专家系统的开发等，其中开发工作最多的是专家系统在高炉中的应用，但大多数还处于实验室仿真阶段，有个别在工厂中试用，但可用性差，运转率极低，主要原因有：专家系统多是规则式，很少和工艺数模相结合；传感器太少，信息量不足；工作深度不够，如日本君津厂的规则约1500条，大分

厂约 5000 条（其中短期作业、长期作业各 2500 条），而我国高炉专家系统的规则还不足 100 条，甚至有的还不到 50 条。

专家系统对解决复杂过程控制问题提供了一种较好的解决办法，但它必须依赖于人类已有的知识和经验，对于人类还没有认识和掌握其规律的复杂过程则无能为力。

3.2.4 神经网络方法

模拟人类实际神经网络的数学方法问世以来，人们已慢慢习惯了把这种人工神经网络直接称为神经网络。神经网络在系统辨识、模式识别、智能控制等领域有着广泛而吸引人的前景。特别在智能控制中，人们对神经网络的自学习功能尤其感兴趣，并且把神经网络这一重要特点看作是解决自动控制中控制器适应能力这个难题的关键钥匙之一。

神经网络的基础在于神经元。神经元是以生物神经系统的神经细胞为基础的生物模型。在人们对生物神经系统进行研究，以探讨人工智能的机制时，把神经元数学化，从而产生了神经元数学模型。大量的形式相同的神经元连结在一起就组成了神经网络。神经网络是一个高度非线性动力学系统。虽然，每个神经元的结构和功能都不复杂，但是神经网络的动态行为则是十分复杂的；因此，用神经网络可以表达实际物理世界的各种现象。

神经网络模型是以神经元的数学模型为基础来描述的。神经网络模型由网络拓扑、节点特点和学习规则来表示。神经网络对人们的巨大吸引力主要在下列几点：

- 并行分布处理。
- 高度鲁棒性和容错能力。
- 分布存储及学习能力。
- 能充分逼近复杂的非线性关系。

在控制领域的研究课题中，不确定性系统的控制问题长期以来都是控制理论研究的中心主题之一，但是这个问题一直没有得到有效的解决。利用神经网络的学习能力，使它在对不确定性系统的控制过程中自动学习系统的特性，从而自动适应系统随时间的特性变异，以求达到对系统的最优控制；显然这是一种十分振奋人心的意向和方法。

3.2.4.1 人工神经网络技术

人工神经网络 (ANN) 是模拟人脑的功能，由大量简单的神经元广泛互联而成为一种复杂网络系统。是对人脑复杂功能的简化、抽象和模拟。

神经网络处理单元 (PE) 功能类似于生物神经元，其功能是对每个输入信号进行处理，以确定其强度 (加权) 确定所有输入信号的组合效果 (求和)，确定其输出。图 3.3 表示了 PE 的基本结构和功能。

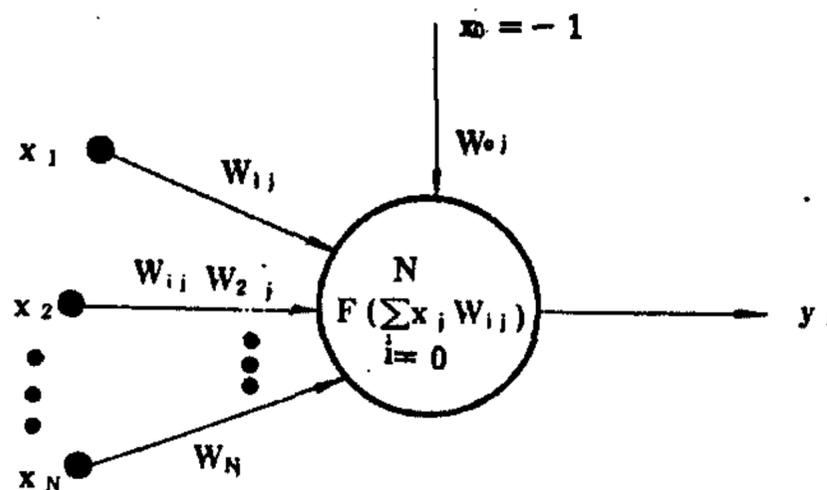


图 3.3 神经网络处理单元 (PE) 的基本结构示意图

Figure 3.3 The basic structure hint of NN PE

PE 的输入信号 x 来自外部或别的处理单元的输出: $X = (X_1, X_2, \dots, X_N)$
 其中 X_1 为 i 个输入的激励电平, N 表示数目, 联结到 j 结点的加权向量为 $W_j = (W_{1j}, W_{2j}, \dots, W_{Nj})$

其中 W_{ij} 表示从结点 i (或第 i 个输入结点) 到结点 j 与 j 结点之间的连接强度。则 j 结点的输入加权和为(***)

$P E$ 的激励电平 S_j 通过转移函数 $F(S)$ 而得到处理单元的最后输出值 Y ；一月 $(S_j) - F(Z X Y i) == F(X' W i)$

式中 F 为转移函数，其作用是将可能的无限域转换到一指定的有限范围内输出。

由多个处理单元 ($P E$) 相互联结而成的网络即构成人工神经网络，与单个处理单元相比，具有更强的识别和处理能力。结点之间的相互联系称为连接加权，反应了结点之间的连接强度。为了进一步提高网络的处理能力，可构成层网络，将上一层网络的输出作为下一层的输入。输入层和输出层之间的中间层称为隐蔽层，一般隐蔽层数为零到几层。网络隐蔽层的层数和隐蔽层和隐蔽网络结点数根据经验试验决定。

人工神经网络有很强的自学习能力、容错能力、自组织能力和推理能力，适于处理很难用准确数学方程描述的复杂的非线性关系和人类对其复杂规律还没有完全掌握、了解的复杂系统。

由于人工神经网络的特性，在冶金领域得到了越来越广泛的应用。日本和美国、欧洲的一些钢铁公司开发了大量的高炉、电炉、轧钢等生产过程中的神经网络模型，在实际使用过程中都取得了良好的控制效果，解决了一些常规控制方法很难解决的难题。

人工智能控制通常用完全不同的方法去讨论。但 AI 控制器例如：神经、模糊、模糊神经，以及遗传算法都可看成一类非线性函数近似器。这样的分类就能得到较好的总体理解，也有利于控制策略的统一开发。这些 AI 函数近似器比常规的函数估计器具有更多的优势，这些优势如下：

(1) 它们的设计不需要控制对象的模型 (在许多场合，很难得到实际控制对象的精确动态方程，实际控制对象的模型在控制器设计时往往有很多不确实性因

素, 例如: 参数变化, 非线性时, 往往不知道)

(2) 通过适当调整 (根据响应时间、下降时间、鲁棒性能等) 它们能提高性能。例如: 模糊逻辑控制器的上升时间比最优 PID 控制器快 1.5 倍, 下降时间快 3.5 倍, 过冲更小。

(3) 它们比古典控制器的调节容易。

(4) 在没有必须专家知识时, 通过响应数据也能设计它们。

(5) 运用语言和响应信息可能设计它们。

(6) 它们有相当好的一致性 (当使用一些新的未知输入数据就能得到好的估计), 与驱动器的特性无关。现在没有使用人工智能的控制算法对特定对象控制效果十分好, 但对其他控制对象效果就不会一致性地好, 因此对必须具体对象具体设计。

(7) 它们对新数据或新信息具有很好的适应性。

(8) 它们能解决常规方法不能解决的问题。

(9) 它们具有很好的抗噪声干扰能力。

(10) 它们的实现十分便宜, 特别是使用最小配置时。

(11) 它们很容易扩展和修改。

人工智能控制器可分为监督、非监督或增强学习型三种。常规的监督学习型神经网络控制器的拓朴结构和学习算法已经定型, 这就给这种结构的控制器增加了限制, 使得计算时间过长, 常规非人工智能学习算法的应用效果不好。采用自适应神经网络和试探法就能克服这些困难, 加快学习过程的收敛速度。常规模糊控制器的规则初值和模糊规则表是既定 “a-priori” 型, 这就使得调整困难, 当系统得不到 “a-priori” (既定) 信息时, 整个系统就不能正常工作。而应用自适应 AI 控制器, 例如使用自适应模糊神经控制器就能克服这些困难, 并且用 DSP 比较容易实现这些控制器。

常规模糊逻辑控制器的设计经常使用尝试法。需要 “a-priori” 信息, 如运用

自适应智能控制器就不需要“a-priori”（a-priori 规则库和隶属函数）信息。值得注意的是，与常规非自适应智能控制器相反，它根据输入信号更新它的“参数”，换句话说，它对变化的输入信号具有适应性。自适应控制器分两类：间接和直接控制器，间接自适应人工智能控制器有一个实时辨识模型，用于控制器的设计，间接控制器在每个采样周期需要采样控制对象的输入和输出信号，辨识器和控制器有很多形式，而直接 AI 控制器用特性表来实现对控制对象的控制，这个特性表由两个连续采样周期期间的误差的变化量构成，用来控制电流响应。

如用模糊逻辑控制器，最简单的应用可能是标量因子的运用。这种方法用现在的非自适应驱动器很容易实现，因而对工业界具有很大的吸引力。用改变隶属函数形状的方法可实现相似的效果。这种运用也可能通过改变规则来实现，如用直接 AI 控制器来实现，就是自适应控制器。它在每个采样瞬间先使用上一个采样周期采用的规则，如果得不到满意的特性，就用新的规则替代，从而得到满意的特性。

总而言之，当采用自适应模糊神经控制器，规则库和隶属函数在模糊化和反模糊化过程中能够自动地实时确定。有很多方法来实现这个过程，但主要的目标是使用系统技术实现稳定的解，并且找到最简单的拓扑结构配置，自学习迅速，收敛快速。人工智能的发展促使自动控制向智能控制发展。神经元控制是模拟人脑神经中枢系统智能活动的一种控制方式。由于它具有适应能力和学习能力，因此适合用作智能控制的研究工具。从本质上看，神经网络是一种不依赖模型的自适应函数估计器，而通常的函数估计器则依赖于数学模型。当给定的输入并不是原来认同的样本时，神经网络也能给出合适的输出，即它具有泛化功能。人工智能专家系统在一定意义上也可看作不依赖模型的估计器，这一点与神经网络有共同之处。但它采用的是符号处理方法而非数值方法，其硬件实现相对困难。在专家系统中，知识明显地表示为规则。而在神经网络中，知识是通过学习例子而分布地存贮在网络中，因此神经网络有很好的容错能力。当个别处理单元损坏时，

对神经网络整体行为只有很小的影响，而不会影响整个系统的正常工作。

神经网络同样也是一种可以训练的非线性动力学系统，因而呈现非线性动力学系统的许多特性，如李雅普诺夫稳定性、平衡点、极限环、平衡吸引子、浑沌现象等。这些都是在用神经网络组成的智能控制系统时必须研究的问题。

3.2.4.2 神经网络控制器的分类

神经网络的控制研究随着神经网络理论研究的不断深入而不断发展起来。从60年代开始，Widrow和Hoff就开始研究神经网络在控制中的应用了。1964年Widrow和Smith采用Adaline和Madaline网络结构以及Widrow-Hoff的最小均方误差(LMS)算法，进行“邦一邦”控制，复现一个已知的开关曲面，完成了小车一倒立摆系统的线性化动力学控制，这是神经网络在控制领域中最先得到应用的例子。根据神经网络在控制器中的作用不同，神经网络在控制系统设计中的应用一般分为两类，一类称神经控制，它是以神经网络为基础而形成的独立智能控制系统；另一类称为混合神经网络控制，它代表着那些利用神经网络学习和优化能力来改善传统控制的现代控制方法，如自适应神经控制等。目前神经控制器的分类还存在较大的争议，没有一个统一的分类法。综合目前各国专家的分类法，我们将一些典型的神经网络的控制结构和学习方式归结为以下七类。

(1) 导师指导下的控制器在许多情况下为了实现某一控制功能，简单地教会神经网络控制器模拟人作同样一件任务的操作行为是可能的。这种控制结构是假设人能够直接控制这类任务，只是从价格、速度、兼容性和安全性等方面考虑需采用自动控制方式。这种神经网络控制结构的学习样本直接取自于专家的控制经验。神经网络的输入信号来自传感器的信息和命令信号。神经网络的输出就是系统的控制信号。一旦神经网络的训练达到了能够充分描述人的控制行为，则网络识别

训练结束。神经网络控制器就可以直接投入实际系统的控制。这种控制结构简单，控制成功的把握大。在功能上它能模拟人类的控制技巧，同专家控制具有相当的功能，从获取知识的角度来看，神经网络更胜一筹。这种控制器的缺陷是其网络的训练只涉及静态过程，缺乏在线学习机制，且在网络训练时控制器不能投入实际运行。

(2) 逆控制器如果一个动力学系统可以用一个逆动力学函数来表示，则采用简单的控制结构和方式是可能的。神经网络的训练目的就是为了逼近此系统的逆动力学模型。神经网络接受系统的被控状态信息，神经网络的输出与该被控制系统的控制信号之差作为调整神经网络权系数的校正信号，并可利用常规的BP学习算法（当然改进的算法更佳）来进行控制网络的训练。一旦训练成功，从理论上来看只要直接把神经网络控制器接到动力学系统的控制端就可以实现无差跟踪控制，即要实现期望的控制输出只要将此信息加到神经网络的输入端就可以了。

(3) 适应网络控制器利用神经网络将线性系统的自适应控制设计理论和思想方法引入到非线性系统自适应控制系统中来是可能的而且被证明是可行的。这一思想首先在1990年由Narendra等提出并成功地应用于非线性系统的神经网络自适应控制。这一控制器在结构上完全等同于线性系统的自适应控制器，只是利用了非线性的神经网络代替了线性系统中的线性处理单元。自适应控制系统要求控制器能够随着系统环境或参数的变化而对控制器进行调节以便达到最优控制的特性。在这里，将控制误差 e （实际系统的输出与参考模型的输出之差）反馈到控制器中去并利用它对控制器特性进行修改最终使其误差趋于极小。在线性系统的自适应控制中，我们知道，这种对控制器特性进行修改的机制是相当复杂的。即使这样，我们还是可以将这些结果直接用于非线性系统，虽然这种情况相当少且非常专一。自适应网络控制器有两个控制结构：一是直接自适应网络控制结构；二是间接自适应网络控制结构。直接自适应网络控制结构是将系统误差信号 e 直接用于神经控制器的自适应调整。但目前还没有一种可行的方法来解决

未知动力学模型的控制问题。间接自适应网络控制结构利用神经网络辨识器和神经网络控制器代替经典控制结构中的辨识模型和控制器，使得系统的学习和控制能够实现。控制器的设计准则仍然是依赖于系统的输出预报误差最小原则。

(4) 神经内模控制结构内模控制以其较强的鲁棒性和易于进行稳定性分析的特点在过程控制中获得广泛的应用。在这种控制结构中，在反馈回路中直接使用系统的前向模型和逆模型。在内模控制结构中，与实际系统并行的网络模型一并建立，系统实际输出与模型M的输出信号差用于反馈的目的。这个反馈信号通过前向通道上的控制子系统G预处理，通常G是一个滤波器，用于提高系统的鲁棒性。系统模型M和控制器G由神经网络来实现。

(5) 前馈控制结构这种结构是基于鲁棒性问题而提出来的。通常单纯的求逆控制结构不能很好地起到抗干扰能力，因此结合反馈控制的思想组成前馈补偿器的网络控制结构。反馈控制的目的在于提高抗随机扰动的能力，而控制器的主要成分，特别是非线性成分将由网络控制器来完成。这种控制器设计的主要困难是如何找到一种有效的学习方法实现对系统模型未知条件下网络控制的在线学习。

(6) 自适应评价网络经常有这样一类系统，在一系列控制作用进行时没有一个直接的对系统控制效果的暗示信号，如两人下棋，在下棋过程中每一步的走法都无法得出胜负的结论，除了最后一步外。因此，这种现象属于缺乏系统的中间信息，但是，对有经验的棋手来说，能够在每一步作出准确的判断，直至最后胜利。这个例子也说明了当最后结果到来之前对每一步作出准确的评价是一件相当困难的事。自适应评价网络是由B r t、S u t t e n和A n t l e r s n在1983年提出来的。整个学习系统由一个相关的搜索单元和一个自适应评价单元组成。在这个算法中，相关搜索单元是作用网络，自适应评价单元为评价网络。它不需要控制系统数学模型，只是通过对某一指标J的处理和分析得到奖励或惩罚信号。

(7) 混合控制系统是由神经网络技术与模糊控制、专家系统等相结合形成的一

种具有很强学习能力的智能控制系统。它集人工智能各分支的优点，使系统同时具有学习、推理和决策能力，成为智能控制的最新发展方向。

从以上分析可知，不管采用何种神经网络控制结构，要真正实现神经网络智能控制的目的，必须具备一种有效的学习机制来保证神经控制器的自学习、自适应功能，达到真实意义上的智能控制。

3.2.4.3 BP 神经网络控制器

神经网络技术的研究从 50 年代末开始，但在其后近 30 年的时间里，一直处于理论研究阶段，没有真正应用于实际生活中。从 80 年代开始，神经网络技术的研究得到了迅速的发展，国际上形成了一股神经网络研究的热潮，并在生物、医学、机械、计算机、冶金、航空等领域得到大量应用，取得了许多成果，同时出现了多种神经网络算法，具有代表性的有 Hopfield 等人提出的联想记忆网络模型、Rumelhart 等人提出的多层前馈网络误差反传算法模型（BP 算法）、Hinton G E 等人提出的波耳兹曼机（Boltzmann Machine）等，其中 BP 算法是一种比较成熟而且应用广泛的神经网络模型。理论证明，三层 B P 网络可以表示任意非线性函数，具有自学习、自组织、自适应能力及高度的容错性和鲁棒性，适于分析和处理复杂的非线性系统。

实用反向传播是依时间反向传播的一种扩展算法。由 Werbos 提出的依时间反向传播(Back—Propagation through time)是一种通常用于训练循环网络的算法。在其基础上发展的实用反向传搅在控制系统上可以形成间接逆控制系统。这种系统如图 3.4 所示。

在这种系统中，一般是在逆模型神经网络执行误差反向传播时，其最后一层误差是由正模型神经网络的误差反传过来的。很明显，在控制系统中，对象的正

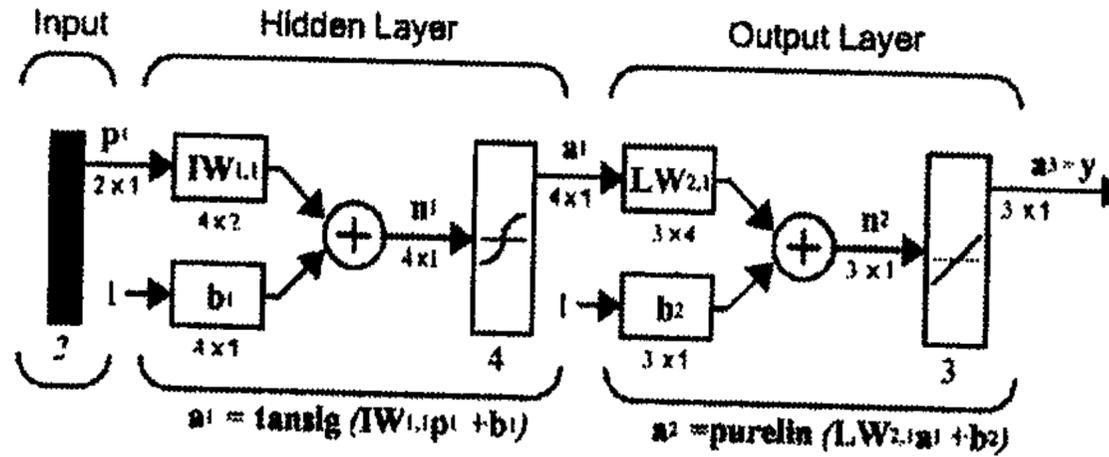


图 3.4 BP 神经网络结构图

Figure3.4 The three layer structure hint of BP

向模型 N_i 的作用是进行误差回传。在实际应用中。这种方法存在一些问题；既然，反向传播的信号是通过正向模型的；所以，实用反向传播算法需要一个良好的模型。但是要用神经网络建立一个好的模型并非一件容易的事。

反向传播算法也称 BP 算法。由于这种算法在本质上是一种神经网络学习的数学模型，所以，有时也称为 BP 模型。

BP 算法是为了解决多层前向神经网络的权系数优化而提出来的；所以，BP 算法也通常暗示着神经网络的拓扑结构是一种无反馈的多层前向网络。故而，有时也称无反馈多层前向网络为 BP 模型。

在这里，并不要求过于严格去争论和区分算法和模型两者的有关异同。感知机学习算法是一种单层网络的学习算法。在多层网络中，它只能改变最后权系数。

因此，感知机学习算法不能用于多层神经网络的学习。1986 年，Rumelhart 提出了反向传播学习算法，即 BP(backpropagation)算法。这种算法可以对网络中各层的权系数进行修正，故适用于多层网络的学习。BP 算法是目前最广泛用的神经网络学习算法之一，在自动控制中是最有用的学习算法。

3.2.4.3.1 BP 算法的原理

BP 算法是用于前馈多层网络的学习算法，前馈多层网络的结构一般如图 3-3 所示。

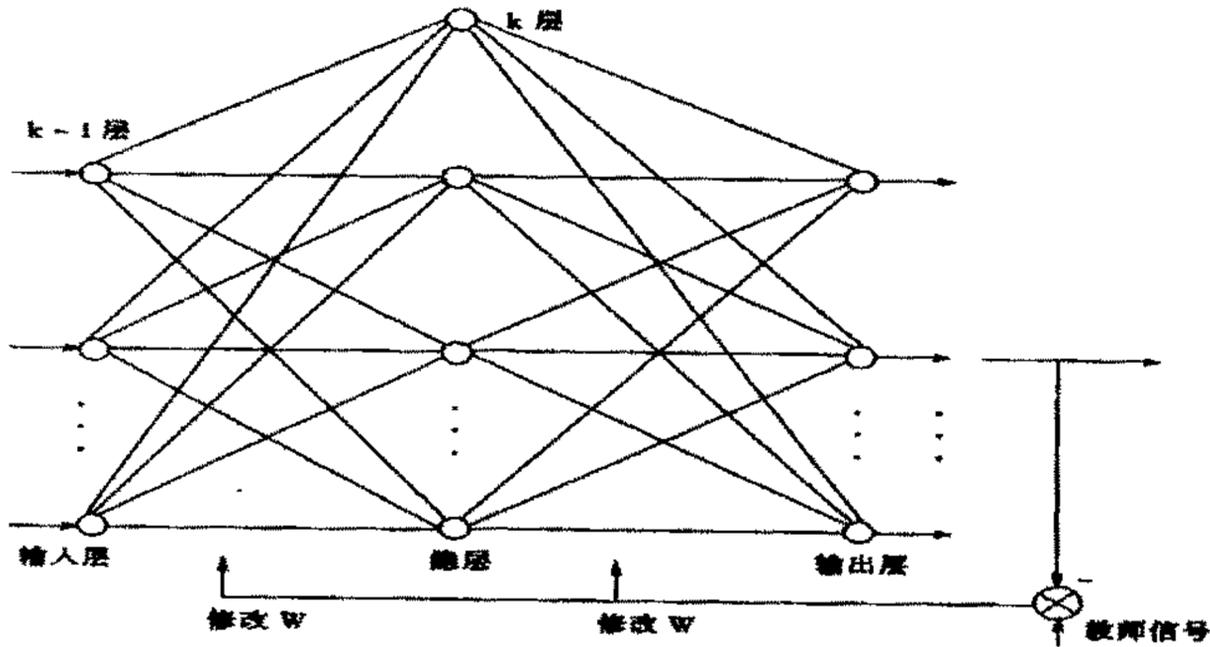


图 3.5 网络学习结构

Figure 3.5 The learning structure hint of NN

它含有输入层、输出层以及处于输入输出层之间的中间层。中间层有单层或多层，由于它们和外界没有直接的联系，故也称为隐层。在隐层中的神经元也称隐单元。隐层虽然和外界不连接，但是，它们的状态则影响输入输出之间的关系。这也是说，改变隐层的权系数，可以改变整个多层神经网络的性能。

设有一个 \$m\$ 层的神经网络，并在输入层加有样本 \$X\$；设第 \$k\$ 层的 \$i\$ 神经元的输入总和表示为 \$U_{ik}\$，输出 \$X_{ik}\$；从第 \$k-1\$ 层的第 \$j\$ 个神经元到第 \$k\$ 层的第 \$i\$ 神经元的权系数为 \$W_{ij}\$ 各个神经元的激发函数为 \$f\$，则各个变量的关系可用下面有关数学式表示：

$$X_{ik} = f(U_{ik}) \tag{3-1}$$

$$U_i^k = \sum_j W_{ij} X_j^{k-1} \tag{3-2}$$

反向传播算法分二步进行，即正向传播和反向传播。这两个过程的工作简述如下。

1. 正向传播

输入的样本从输入层经过隐单元一层一层进行处理，通过所有的隐层之后，则传向输出层；在逐层处理的过程中，每一层神经元的状态只对下一层神经元的状态产生影响。在输出层把现行输出和期望输出进行比较，如果现行输出不等于期望输出，则进入反向传播过程。

2. 反向传播

反向传播时，把误差信号按原来正向传播的通路反向传回，并对每个隐层的各个神经元的权系数进行修改，以望误差信号趋向最小。

3.2.4.3.2 BP 算法的数学表达

BP 算法实质是求取误差函数的最小值问题。这种算法采用非线性规划中的最速下降方法，按误差函数的负梯度方向修改权系数。

为了说明 BP 算法，首先定义误差函数 e 。取期望输出和实际输出之差的平方和为误差函数，则有：

$$e = \frac{1}{2} \sum_i (X_i^m - Y_i)^2 \quad (3-3)$$

其中： Y_i 是输出单元的期望值；它也在这里用作教师信号；

X_{im} 是实际输出；因为第 m 层是输出层。

由于 BP 算法按误差函数 e 的负梯度方向修改权系数，故权系数 W_{ij} 的修改量 ΔW_{ij} ，和 e

$$\Delta W_{ij} \propto - \frac{\partial e}{\partial W_{ij}} \quad (3-4)$$

也可写成

$$\Delta W_{ij} \propto -\eta \frac{\partial e}{\partial W_{ij}} \tag{3-5}$$

其中： η 为学习速率，即步长。

很明显，根据 BP 算法原则，求 $\partial e / \partial W_{ij}$ 最关键的。下面求 $\partial e / \partial W_{ij}$ ；有

$$\frac{\partial e}{\partial W_{ij}} = \frac{\partial e_k}{\partial U_i^k} \cdot \frac{\partial U_i^k}{\partial W_{ij}}$$

由于

$$\frac{\partial U_i^k}{\partial W_{ij}} = \frac{\partial (\sum_l W_{il} X_l^{k-1})}{\partial W_{ij}} = X_j^{k-1} \Big|_{l=j}$$

故而

$$\frac{\partial e}{\partial W_{ij}} = \frac{\partial e}{\partial U_i^k} \cdot X_j^{k-1}$$

从而有

$$\begin{aligned} \Delta W_{ij} &= -\eta \frac{\partial e}{\partial W_{ij}} \\ &= -\eta \frac{\partial e}{\partial U_i^k} \cdot X_j^{k-1} \end{aligned}$$

令

$$d_i^k = \frac{\partial e}{\partial U_i^k}$$

则有学习公式：

$$\Delta W_{ij} = -\eta \cdot d_i^k \cdot X_j^{k-1}$$

其中： η 为学习速率，即步长，一般取 0-1 间的数。

从上面可知， d_{ik} 实际仍未给出明显的算法公式，下面求 d_{ik} 的计算公式。

$$\begin{aligned} d_i^k &= \frac{\partial e}{\partial U_i^k} \\ &= \frac{\partial e}{\partial X_i^k} \cdot \frac{\partial X_i^k}{\partial U_i^k} \end{aligned} \tag{3-6}$$

从式(3-1)可知在式(3-5)中，有

$$\frac{\partial X_i^k}{\partial U_i^k} = f'(U_i^k) \tag{3-7}$$

为了方便进行求导，取 f 为连续函数。一般取非线性连续函数，例如 Sigmoid 函数。

当取 f 为非对称 Sigmoid 函数时，有：

$$f(U_i^k) = \frac{1}{1 + \exp(-U_i^k)}$$

$$\begin{aligned} \text{则有：} f(U_{ik}) &= f(U_{ik})(1-f(U_{ik})) \\ &= X_{ik}(1-X_{ik}) \end{aligned} \tag{3-8}$$

再考虑式(3-8)中的偏微分项 $\frac{\partial e}{\partial X_{ik}}$ ，有两种情况需考虑的：

1、如果 $k=m$ ，则是输出层，这时有 Y_i 是输出期望值，它是常数。从式(3-2)有

$$\begin{aligned} \frac{\partial e}{\partial X_i^k} &= \frac{\partial e}{\partial X_i^m} \\ &= (X_i^m - Y_i) \end{aligned}$$

从而有 $d_{im} = X_{im}(1-X_{im})(X_{im}-Y_i)$

2、如果 $k < m$ ，则该层是隐层。这时应考

虑上一层对它的作用，故有：

$$\frac{\partial e}{\partial X_i^k} = \sum_l \frac{\partial e}{\partial U_l^{k+1}} \cdot \frac{\partial U_l^{k+1}}{\partial X_i^k}$$

从式(3-4)中，可知有：

$$\frac{\partial e}{\partial U_l^{k+1}} = d_l^{k+1}$$

从式(3-2)中，可知有：

$$\frac{\partial U_l^{k+1}}{\partial X_i^k} = \frac{\partial (\sum_j W_{lj} X_j^k)}{\partial X_i^k} = W_{li} \Big|_{j=i}$$

故而有

$$\frac{\partial e}{\partial X_i^k} = \sum_l W_{li} \cdot d_l^{k+1}$$

最后有：

$$d_i^k = X_i^k(1 - X_i^k) \cdot \sum_l W_{li} \cdot d_l^{k+1}$$

从上述过程可知：多层网络的训练方法是把一个样本加到输入层，并根据向前传播的规则：

$$X_{ik} = f(U_{ik})$$

不断一层一层向输出层传递，最终在输出层可以得到输出 X_{im} 。

把 X_{im} 和期望输出 Y_i 进行比较。如果两者不等，则产生误差信号 e ，接着则按下面公式反向传播修改权系数：

$$\Delta W_{ij} = -\eta \cdot d_i^k \cdot X_j^{k-1}$$

$$U_i^k = \sum_j W_{ij} X_j^{k-1}$$

其中

$$d_i^k = X_i^k(1 - X_i^k)(X_i^k - Y_i)$$

$$d_i^k = X_i^k(1 - X_i^k) \sum_l W_{il} d_l^{k+1}$$

上面公式中，求取本层 d_i^k 时，要用到高一层的 d_i^{k+1} ；可见，误差函数的求取是从输出层开始，到输入层的反向传播过程。在这个过程中不断进行递归求误差。

通过多个样本的反复训练，同时向误差渐渐减小的方向对权系数进行修正，以达最终消除误差。从上面公式也可以知道，如果网络的层数较多时，所用的计算量就相当可观，故而收敛速度不快。

为了加快收敛速度，一般考虑上一次的权系数，并以它作为本次修正的依据之一，故而有修正公式：

$$\Delta W_{ij}(t+1) = -\eta d_i^k \cdot X_j^{k-1} + \alpha \Delta W_{ij}(t) \tag{3-9}$$

其中： η 为学习速率，即步长， $\eta = 0.1 - 0.4$ 左右

α 为权系数修正常数，取 $0.7 - 0.9$ 左右。

在上面，式(3-9)也称为一般化的 Delta 法则。对于没有隐层的神经网络，可取

$$\Delta W_{ij} = \eta(Y_j - X_j) \cdot X_i$$

其中： Y_i 为期望输出；

X_j 为输出层的实际输出；

X_i 为输入层的输入。

这显然是一种十分简单的情况，式(3-9)也称为简单 Delta 法则。

3.2.4.3.3 BP 算法的执行步骤

在反向传播算法应用于前馈多层网络时，采用 Sigmoid 为激发函数时，可用下列步骤对网络的权系数 W_{ij} 进行递归求取。注意对于每层有 n 个神经元的时候，即有 $i=1, 2, \dots, n; j=1, 2, \dots, n$ 。对于第 k 层的第 i 个神经元，则有 n 个权系数 $W_{i1}, W_{i2}, \dots, W_{in}$ ，另外取多一个 $W_{i,n+1}$ 用于表示阈值 θ_i ；并且在输入样本 X 时，取 $x=(X_1, X_2, \dots, X_n, 1)$ 。

算法的执行步骤如下：

1. 对权系数 W_{ij} 置初值。

对各层的权系数 W_{ij} 置一个较小的非零随机数，但其中 $W_{i,n+1} = -\theta_i$ 。

2. 输入一个样本 $X=(x_1, x_2, \dots, x_n, 1)$ ，以及对应期望输出 $Y=(Y_1, Y_2, \dots, Y_n)$ 。

3. 计算各层的输出

对于第 k 层第 i 个神经元的输出 X_{ik} ，有：

$$U_i^k = \sum_{j=1}^{n+1} W_{ij} X_j^{k-1}, \quad X_{n+1}^{k-1} = 1, W_{i,n+1} = -\theta_i$$

$$X_{ik} = f(U_{ik})$$

4. 求各层的学习误差 d_{ik}

对于输出层有 $k=m$ ，有

$$d_{im} = X_{im}(1-X_{im})(X_{im}-Y_i)$$

对于其他各层，有

$$d_i^k = X_i^k(1-X_i^k) \sum_l W_{li} d_l^{k+1}$$

5. 修正权系数 W_{ij} 和阈值 θ

用式(3-8)时有:

$$W_{ij}(t+1) = W_{ij}(t) - \eta \cdot d_i^k \cdot X_j^{k-1}$$

用式(3-9)时有:

$$W_{ij}(t+1) = W_{ij}(t) - \eta \cdot d_i^k \cdot X_j^{k-1} + \alpha \Delta W_{ij}(t)$$

其中:

$$\begin{aligned} \Delta W_{ij}(t) &= -\eta \cdot d_i^k \cdot X_j^{k-1} + \alpha \Delta W_{ij}(t-1) \\ &= W_{ij}(t) - W_{ij}(t-1) \end{aligned}$$

6. 当求出了各层各个权系数之后, 可按给定品质指标判别是否满足要求。如果满足要求, 则算法结束; 如果未满足要求, 则返回(3)执行。

这个学习过程, 对于任一给定的样本 $X_p = (X_{p1}, X_{p2}, \dots, X_{pn}, 1)$ 和期望输出 $Y_p = (Y_{p1}, Y_{p2}, \dots, Y_{pn})$ 都要执行, 直到满足所有输入输出要求为止。

第四章 转炉人工智能静态控制模型的开发

4.1 人工智能技术在转炉炼钢自动控制中的应用

在国内现有的炼钢转炉模型中，模型计算技术是影响转炉自动控制系统控制精度的一个重要因素。模型计算技术已从最初理论模型的简单自学习计算发展到目前的人工智能神经网络计算技术，大大提高了模型对冶炼过程中随机因素和系统变化因素的适应能力和处理能力，提高了模型的计算精度。

由于冶金过程的特点，传统的控制技术和精确数学模型遇到了难以逾越的困难，必须求助于人工智能（AI）技术。AI 技术广义包括专家系统、模糊逻辑控制和机器学习，而其中应用最多，使用最成熟的是专家系统（ES）。由于各国在长期的转炉炼钢过程中积累了大量的知识和经验，因此专家系统在转炉炼钢过程控制中得到了较多的应用，而人工神经网络技术由于发展较晚，在炼钢控制中的应用才刚刚开始，但已显示了良好的应用前景。

在武钢和攀钢等国内钢厂，将人工神经网络技术应用于转炉炼钢过程控制中，与增量模型相结合，开发出了转炉人工智能静态控制模型，实践证明进一步提高了转炉静态模型控制精度，提高模型对炼钢过程各因素复杂的非线性关系的处理能力和对系统随机因素变化的反应能力和适应能力，提高模型终点命中率。

4.2 人工智能模型设计

4.2.1 静态控制设计

首钢三炼钢厂的 80 吨转炉目前已采用计算机操作。为了进一步提高转炉控制一次碳温命中率。我们和钢铁研究总院共同为首钢三炼进行开发转炉人工智能静态控制模型软件。以便使转炉操作在加料、供氧等方面优化，满足生产的要求，从而大大提高转炉终点控制命中率。

静态控制是转炉动态控制的基础，其控制精度直接影响到动态控制的效果。目前普遍采用的静态模型有三种，即理论模型、统计模型和增量模型，三种模型各有特点，理论模型从炼钢反应的原理出发，根据冶金反应过程的物料平衡和能量平衡建立吹炼过程的冷却剂方程和氧耗方程，计算出为达到终点目标碳含量和温度所需的冷却剂加入量和耗氧量及各种造渣剂的加入量。理论模型是炼钢过程自动控制的基础，但由于吹炼过程中各种随机因素对吹炼终点结果会产生很大的影响，这些随机因素很难用数学方程进行准确的描述，因此理论模型与实际情况往往存在很大的偏差，目前已很少单独使用，而是与其它模型结合使用。统计模型是根据对大量生产实验数据进行统计分析，建立经验和半经验型的统计方程。统计模型具有很强的针对性，能够描述某一具体钢厂或者转炉在某一段时期内的反应变化规律，但对临时性变化因素很难及时作出反应，而且模型通用性很差。增量模型是目前应用最广泛的转炉静态控制模型，但增量模型中的系数主要是根据理论计算或统计分析方法或经验确定的，而且一旦系数确定，模型在使用过程中很难再进行修改，使得增量模型也存在一定的误差。

经过对三种静态模型的分析对比，我们采用以增量模型为基础，建立转炉吹炼过程静态控制模型。由于常规增量模型克服了由于原材料波动、计量误差、炉容变化等对模型计算结果造成的影响，较好的解决了转炉生产过程中连续变化因素对冶炼结果可能造成的影响，但对实际炼钢生产过程中可能出现的各种随机变化和突发性变化因素的处理能力却不够，如生产过程中补炉情况的变化、生产班次的变换、造渣剂的批量改变时可能会造成本炉和上炉之间冶炼过程和终点情况差别很大，此时如果采用常规增量模型将会造成较大的计算误差，使得本炉终点控制与目标值偏离较远。

为了克服常规增量模型的不足，研究提出了通过改进参考炉选取方法，提高增量模型对冶炼过程中可能出现的随机变化因素的适应能力和处理能力，增强增量模型的容错能力，提高增量模型的控制精度。

同时，由于生产过程中存在一些难以用准确的数学方程进行描述的复杂影响因素如炉龄的变化、枪龄的变化、空炉时间的变化等，这些因素的变化将会影响到吹炼过程和吹炼结果，但静态模型很难对这些因素进行处理，造成了静态模型的计算误差。静态模型在使用过程中存在的另外一个问题是：一旦静态模型投入使用，很难在线对模型参数进行修改和调整，即模型只能进行短期的在线学习，但对使用过程中可能发生的系统因素的变化如废钢种类的改变、造渣剂的改变等，常规模型却不能进行及时的调整和修改，以适应新的条件。上述缺陷由于是常规静态模型自身所固有的，所以在常规静态模型中很难解决。为了解决上述问题，在实践中将神经网络技术应用到转炉炼钢控制中，与常规静态模型相结合，开发人工智能静态控制模型，以克服常规静态模型的不足，进一步提高静态模型的控制精度和终点碳温命中率。

常规增量模型的参考炉选取办法是选取本炉的上一炉或上两炉。这种方法在正常吹炼情况下是比较合理的，但是当生产过程中发生随机因素变化时，可能会使该方法产生较大的计算误差。为了克服常规增量模型的不足，研究对常规增量模型进行了改进，提出了一种新的参考炉选取方法。

研究提出的改进参考炉选取方法是选取两类参考炉。一类参考炉是与本炉冶炼时间最接近的炉次，即常规增量模型的参考炉选取方法。另一类参考炉为标准参考炉，选取与本炉冶炼条件相接近的炉次，包括冶炼钢种、原料条件、铁水温度等与本炉相接近的炉次作为本炉的参考炉。通过采用选取两类参考炉进行加权平均，提高增量模型对随机变化因素的适应能力和处理能力。

对参考炉的选取采取下面三条原则：

(1)、两类参考炉都应选取吹炼情况正常的炉次，即选用的参考炉在吹炼过程中不应发生较大喷溅；

(2)、普通参考炉选取与本炉吹炼时间最接近的炉次；

(3)、标准参考炉选取铁水和造渣剂等初始原料条件以及冶炼终点要求等与本

炉接近的炉次；

根据上述原则，本研究对参考炉的选取采用了如下方法：每炉采用三个参考炉，一个为标准参考炉，另外两个为普通参考炉。

普通参考炉的选取方法是：选取吹炼情况正常，吹炼过程没有大喷等异常现象发生的本炉前面两炉作为参考炉。如果本炉冶炼情况正常，模型将自动作为下一炉的参考炉，否则不做替换。

标准参考炉的选取方法是：对相同的冶炼钢种，将铁水温度和废钢装入量分为3~8个级别，每个级别存储一个标准参考炉。铁水温度和废钢装入量的级别划分根据实际情况确定，如铁水温度可按20~30℃划分为一个级别，废钢装入量可按废钢总装入量的20%划分为一个级别。标准参考炉必须是吹炼终点碳温同时合格，而且吹炼过程没有发生大喷等异常现象的炉次。不同的冶炼钢种分别存储各自的标准参考炉。标准参考炉在每炉吹炼结束时由程序自动进行判断和更新，保证为最新炉次。

常规静态模型在使用中存在两个难以克服的缺陷：

(1)、对转炉炼钢生产过程中一些影响吹炼过程和终点结果，但却难以数学方程进行定量描述的变化因素的影响无能为力，如炉龄的影响、枪龄的影响等；

(2)、常规静态模型一旦投入使用，即使生产过程中某些影响因素发生了较大的变化，也难以在线修改模型参数和调整数学模型；

由于上述缺陷的存在，使得静态模型的控制精度很难进一步提高。所以必须与新的智能控制手段相结合的方法。

4.2.2 人工智能模型设计

人工神经网络技术(ANN)是模拟人脑的功能，在现代神经科学研究成果的基础上提出的反映人脑功能的若干基本特性的一种数学算法，是对人脑复杂功能的某

种简化、抽象和模拟。人工神经网络具有很强的自学习能力、容错能力、自组织能力和推理能力，对于处理难以用准确数学方程进行描述的复杂的非线性关系以及人类还没有完全掌握和了解规律的复杂系统。

由于人工神经网络的特点，适合于处理转炉炼钢过程。应用人工神经网络的自学习能力和自适应能力提高静态模型对炼钢过程中难以定量描述的变化因素的处理能力，同时利用人工神经网络的定期训练和自学习能力可以增强静态模型的在线调整和学习能力，进一步提高静态模型的控制精度。

对于转炉炼钢系统，影响终点碳含量和温度的因素有几十个，且各因素之间存在着复杂的非线性关系，有些因素如炉龄、枪位、喷溅情况等对终点碳温的影响很难用准确的数学方程进行描述。

经过分析，决定选用 **BP 网络建立转炉吹炼过程人工智能碳温预报模型。**

将 BP 网络应用到转炉炼钢过程控制中，开发吹炼终点碳温预报神经网络模型，利用已经训练好的网络，根据吹炼初始条件和过程参数，预报终点碳温值，为吹炼终点控制提供参考。

将 BP 网络应用到转炉炼钢静态控制模型中，可建立两个网络，即终点碳含量网络和终点温度网络。一个网络的输出值 Y_1 ，为吹炼终点碳含量，另一个网络的输出值 Y_2 ，为吹炼终点温度。两个网络均含有一个隐含层，隐含层的节点数根据训练结果进行确定。两个网络的输入单元相同，均为 16 个，分别是：炉龄 (X_{Z1})、空炉时间 (X_{g1})、铁水装入量 (X_{S1})、废钢装入量 (X_{g2})、铁水硅含量 (X_{g3})、铁水锰含量 (X_{S2})、铁水磷含量 (X_z)、铁水硫含量 (X_{Z2})、铁水温度 (X_{Z3})、吹炼过程铁皮加入量 (X_{Z4})、生白加入量 (X_I)、石灰加入量 (X)、轻烧加入量 (X_{Z5})、萤石加入量 (X_{Z6})、吹氧量 (X_{Z7}) 等等。通过收集生产过程的大量实际数据，对两个网络分别进行训练，结果为训练好的网络文件，包含了各因子之间的联结强度；即各因子对吹炼终点碳含量和温度的影响关系。计算转炉终点碳含量和温度的神经网络结构示意图

见图 4-1。

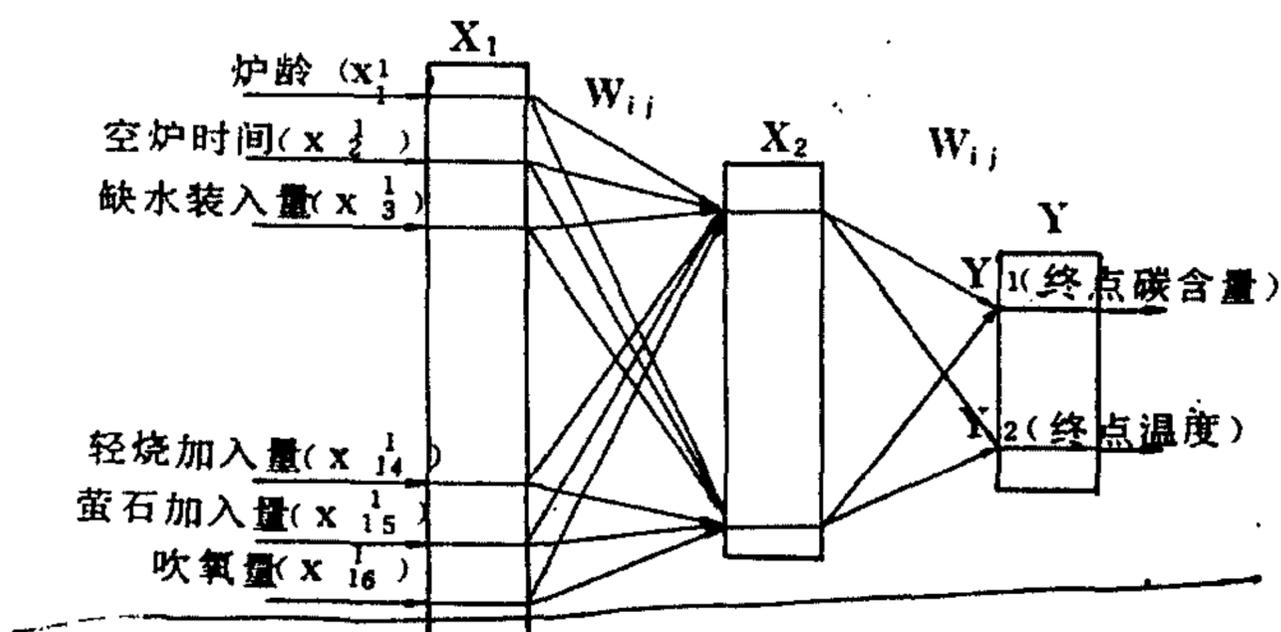


图 4.1 计算转炉终点碳含量和温度的神经网络结构示意图

99999Figure4.1 The structure hint of the end-point carbon temperature caculating

利用 B P 网络建立的终点碳含量网络和终点温度网络与改进的增一模型相结合，构成转炉人工智能静态控制模型，利用 B P 网络对不确定因素和复杂的非线性关系的处理能力来弥补传统增量模型的不足，可进一步提高静态模型对随机因素的敏感性和适应性，提高模型的命中率。

为了进一步提高静态模型对炼钢过程复杂变化因素的适应能力和处理能力，提高模型的命中率，充分发挥神经网络模型与增量模型各自的优点，弥补神经网络模型与传统增量模型的不足，研究进行了将终点碳温预报神经网络模型与改进的增量模型相结合，开发转炉人工智能静态控制模型的探索研究。

转炉人工智能静态控制模型的基本原理是：利用增量模型计算出为满足本炉终点目标碳含量和温度所需的吹氧量和冷却剂加入量，根据终渣碱度要求和终渣 MgO 含量要求计算出各种造渣剂的加入量。将计算结果以及本炉铁水成分和温度

等信息共 16 个参数 ($X_1^i - X_{16}^i$) 作为神经网络的输入节点, 输出节点为终点碳含量和温度, 调用训练好的神经网络进行计算, 可以算出如果按输入初始参数进行吹炼可能得到的终点碳含量和温度。将计算结果与本炉终点目标碳含量和温度比较, 根据比较结果对计算吹氧量和冷却剂加入量进行调整。如果网络输出的终点碳含量和温度值在本炉目标值控制精度范围内, 则认为增量模型计算的本炉吹氧量和冷却剂加入量是可行的, 可以按模型计算计算结果进行吹炼; 如果网络输出结果不在本炉目标控制精度范围内, 则需要对增量模型计算的吹氧量和冷却剂加入量进行调整。根据网络输出值和本炉目标值的偏差情况按一定的步长进行修改。将修改后的吹氧量和冷却剂加入量重新代入增量模型进行热量平衡和氧平衡计算。将模型计算结果重新输入神经网络进行计算, 根据网络输出结果判断校正后的吹氧量和冷却剂加入量是否合适。如果合适, 则输出计算结果。如果还不合适, 则重复上述过程, 直到网络输出值达到本炉目标控制精度范围内。

在神经网络模型的训练中发现, 神经网络的输出值有时与实际情况相差很大, 甚至出现超出常理的值。造成这种现象的原因是由于神经网络的计算过程不考虑任何物理意义, 只是根据所给定的输入和输出值进行训练, 训练好的网络为各影响因素之间的联接强度。当利用训练好的网络对给定的某一组输入值计算时, 网络输出值就有可能超出常理。为了避免在实际使用过程中出现这种情况, 必须人为规定模型计算的上下限值。当神经网络模型的输出值超过上下限时, 应去掉模型计算值而采用规定的上下限值。利用增量模型计算出神经网络输出的最大和最小容许值作为神经网络模型输出的上下限值, 较好地解决了神经网络输出值的超限问题。

4.2.2.1 静态增量模型

转炉炼钢过程控制中常用的增量模型的一般表达式为

$$Y_1 = Y_0 + a_1 \Delta X_1 + a_2 \Delta X_2 + \dots + a_n \Delta X_n + b$$

利用增量模型可以建立吹炼过程冷却剂方程和氧耗方程，计算出为满足本炉吹炼终点碳含量和温度要求所需的冷却剂加入量和吹氧量。

(1) 冷却剂方程

为了达到本炉目标终点温度所需的冷却能和冷却剂加入量，可根据参考炉冷却能及本炉与参考炉所需冷却能之差计算。

参考炉实际冷却能为

$$L_c = \frac{1000}{(W_{oc} + W_{Fc})} (a_1 W_{Fc} + \sum_{i=2}^n a_i W_{ic})$$

本炉与参考炉的冷却能之差为

$$\Delta L = b_1 \{ (T_{sB} - T_{oB}) - (T_{sc} - T_{oc}) \} + \sum_{i=2}^n b_i (M_{iB} - M_{ic})$$

本炉与参考炉的冷却能：

$$\{ F_1(C_B) - F_1(C_c) \} + \{ F_2(t_B) - F_2(t_c) \} + B_1$$

本炉所需冷却能为：

$$L_B = L_c + \Delta L$$

(2) 氧耗方程

为了达到本炉终点目标碳含量所需的吹氧量，可根据参考炉的耗氧量及本炉与参考炉氧耗之差计算。

参考炉目标氧耗为：

$$O_c = \frac{1}{W_{O_c} + W_{Fe}} (V_{O_c} + c_1 W_{Fe}(x))$$

本炉与参考炉氧耗之差:

$$\Delta O = \sum_{i=1}^n c_i (W_{iB} - W_{ic}) + \sum_{i=1}^n d_i (M_{iB} - M_{ic}) + B_2$$

本炉目标氧耗:

$$O_B = O_c + \Delta O$$

$$O_c = \frac{1}{W_{O_c} + W_{Fe}} (V_{O_c} + c_1 W_{Fe}(x))$$

为了达到本炉终点目标碳含量所需的吹氧量,可根据参考炉的耗氧,参考炉的选取对增量模型的计算精度有很大的影响,选择合适的参考炉是提高增量模型计算精度的一个重要因素。本文对参考炉的选取采用了如下方法:每炉采用三个参考炉,其中一个为标准参考炉,另外两个为本炉的上两炉。

标准参考炉的选取原则是:将铁水温度和废钢装入量分为不同的级别,每个级别存储一个标准参考炉。该炉必须是吹炼终点一次倒炉时钢水碳含量和温度同时达到终点目标要求,而且吹炼过程没有发生中喷或大喷的炉次。标准参考炉在每炉吹炼结束时由程序自动进行判别替换,以保证为最新炉次。

模型对三个参考炉进行加权平均处理,根据每个参考炉的初始条件与本炉的差值大小决定其加权系数。

转炉人工智能静态控制模型利用BP网络建立的终点碳含量网络和终点温度网络与改进的增量模型相结合,构成转炉人工智能静态控制模型,利用BP网络对不确定因素和复杂的非线性关系的处理能力来弥补传统增量模型的不足,可进

进一步提高静态模型对随机因素的敏感性和适应性，提高模型的命中率。

设计好的模型软件采用了 Windows 下友好的人机对话界面，通过下拉菜单和对话框方式输入初始参数和实际吹炼结果，并有输入自动查错功能及正确范围提示，防止输入操作失误。为了进一步提高模型的控制精度，程序定期对神经网络进行训练，保证模型能够对近期系统发生的变化情况及时作出反应并调整参数。神经网络训练所需数据由程序自动进行搜集，即在每炉吹炼结束后，模型自动对本炉实际吹炼结果进行分析，替换参考炉，同时将本炉数据存储在神经网络训练数据库中。当数据库中炉数达到一定数量时，模型将调用神经网络自动进行训练。并将训练好的网络文件自动替换旧的网络文件。

为了使转炉人工智能静态控制系统在生产中发挥最大作用，取得最佳使用效果，在静态控制计算机系统开发时应满足四条要求：准确可靠的数学模型、平易近人的操作画面、安全可靠的结构设计和维护方便的系统结构。

根据生产实际的需要，转炉人工智能静态控制系统具有如下功能：

- (1)、操作界面的设计友好美观，操作简单，结构坚固结实；
- (2)、具有静态模型计算的功能，可以根据吹炼初始条件和终点碳温目标值计算出为满足终点要求的吹炼过程控制参数；
- (3)、具有设计完备的数据库系统，可保存较长一段时间的生产数据，为各种查询、统计、打印报表操作提供数据；
- (4)、具有打印报表功能，可替代炉前人工报表；
- (5)、具有对某一段时期的吹炼情况如铁水成分、各种造渣剂的消耗、吹炼终点情况和成品成分进行统计，为管理人员和技术人员提供参考；
- (6)、具有输入自动查错和提示功能；
- (7)、软件具有安全保密和抗误操作的功能；
- (8)、软件具有在线联机帮助功能；

在静态控制系统的开发过程中，应按照上述要求进行，并将各功能有机地组

合，形成一个完整的计算机静态控制系统。

4.3 转炉人工智能静态控制模型工业试验结果

将模型应用到首钢三炼钢 80t 转炉生产中进行生产试验。试验铁水条件为：温度 1225~1327℃，S t 含量 0.207%~0.675%，Mn 0.115%~0.455%，P 含量 0.068%~0.094%，S 0.019%~0.043%。废钢装入量为 0~12 t。试验要求终点控制精度为：终点碳含量 (0.06±0.02)%，终点温度 1660±12℃。

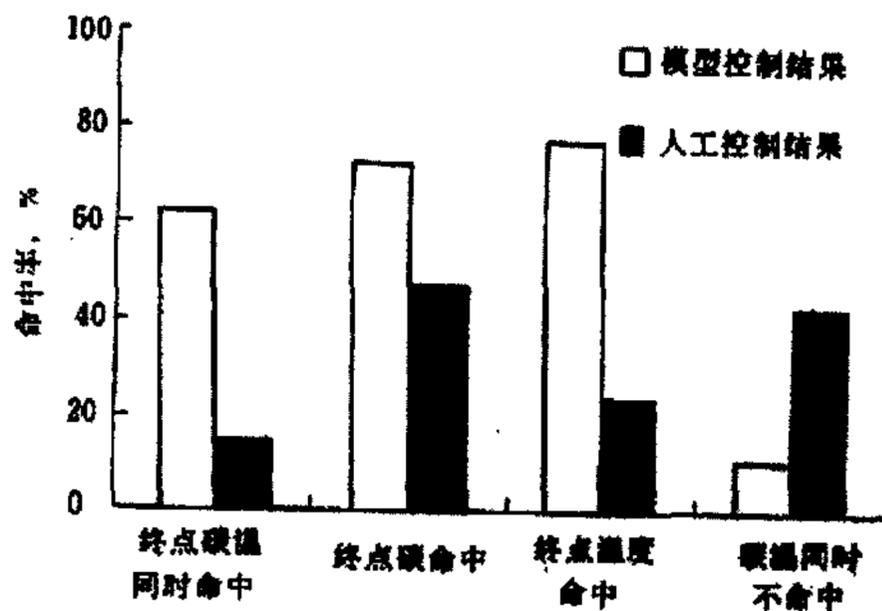


图 4.2 静态模型控制结果与人工控制结果比较

Figure 4.2 The compare result hint of static-control model and man-control model

根据模型计算结果进行吹炼要求吹炼过程中造渣剂加入量、冷却剂加入量和吹炼时间、供氧量均严格按照模型计算结果进行控制。冷却剂加入量不能超过模型计算结果±2.5kg/t，吹炼时间控制不能超过模型计算结果±1%，否则按未按模型计算结果吹炼对待。图 4-2 为静态模型控制结果与人工控制结果比较。

在搜集三炼钢 500 炉生产数据后，对终点碳含量网络和终点温度网络分别进行

训练。训练次数对训练结果的影响见图 4-3。

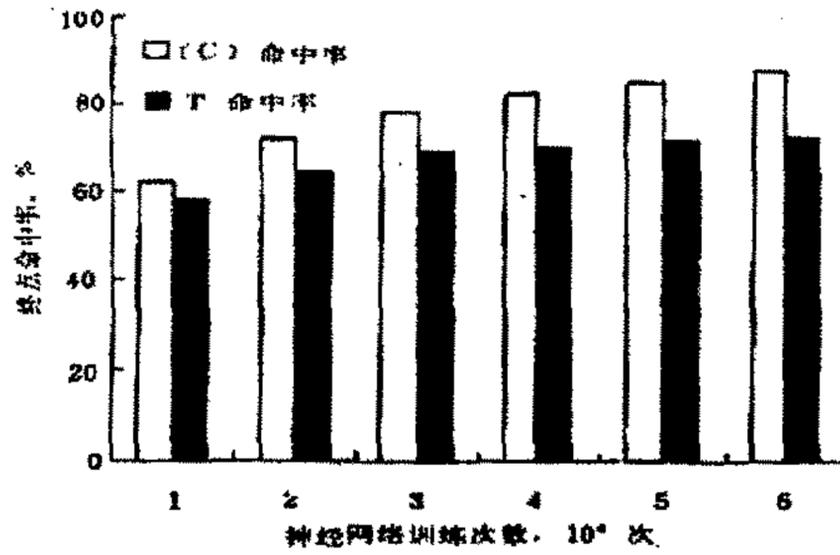


图 4.3 神经网络训练次数对终点命中率的影响

Figure4.3 The hint of the NN training affecting hit the target of end-point

在不同的控制精度时，经过 5 万次训练，终点碳、温命中率分别见表 4-1、表 4-2。

表 1 终点碳含量网络的训练结果					
偏差	±0.010	±0.015	±0.020	±0.025	±0.030
命中率, %	51.2	68.1	87.8	88.3	94.1

表 2 终点温度网络的训练结果					
偏差	±5℃	±10℃	±12℃	±15℃	±20℃
命中率, %	38.5	65.4	72.1	81.7	91.5

表 4.1 终点碳含络的训练结果

Table4.1 The result of end-point carbon NN training

表 4.2 终点温度网络的训练结果

Table4.2 The result of end-point temperature NN training

从训练结果看出，如果将终点碳含量的控制精度限定在目标值± 0.020%，终点温度的控制精度限定在目标值± 1.2℃，则训练好的神经网络对终点碳含量的命中率可达 85% 以上，对终点温度的命中率可达 70% 以上，超过了目前增量模型能够达到的控制精度。

表 3 工业试验结果

	C、T 双 命中率	C 命中率	T 命中率	C、T 均未 命中率
模型 命中率(%)	62.2	73.0	78.4	10.8

表 4.3 工业试验结果

Table4.3 The result of industry testing

从表 4-3 可以看出，采用静态模型后，一次拉碳回，时终点碳、温同时命中率可达到 62.2%，同时石灰、轻烧等造渣剂消耗量明显减少，石灰用量减少 1.25 ~ 2.5 kg / t。采用静态控制模型后，与人工控制结果相比，终点碳温命中率明显提高，倒炉次数明显减少，减轻了炉前工人的劳动强度，并提高了转炉作业生产率。

模型在试验前仅搜集了 500 炉生产数据对神经网络进行训练，而且数据来自 3 座转炉，相当于仅仅学习 15 天熟练工人的操作经验。目前人工智能静态控制模型在首钢三炼钢转炉生产还未正式投入使用，目前还处于试验阶段。以后将再实际应用过程中不断搜集大量数据并进行在线训练，将进一步提高终点命中率，并使模型达到 3 年以上熟练钢工的水平。

今后为了提高模型的精度和终点命中率，必须保证炉前计量系统的准确性，稳定原材料条件，规范化生产作业。为了提高模型的使用率，减少炉前人工输入量，保证输入数据的准确性，应将人工智能静态控制模型与基础自动化系统的化验分析系统等进行联网通讯，形成在线静态控制系统。

结束语

通过改造三炼钢转炉冶炼终点控制技术,从传统落后的“高拉碳补吹”操作方法发展到先进的“一次拉碳”操作方法。采用这种新方法冶炼连铸钢种,一次拉碳命中率即冶炼终点一次命中率由原来的20%以下提高到现在的60%以上,在国内炼钢厂同类装备水平的条件下,处于领先水平。同时,“一次拉碳”还对降低钢液脱氧合金化成本、改善钢质和提高炉龄起到了积极的作用。

首钢从1999年伊始,就对大量的转炉炼钢数据进行了统计分析和跟踪调查。在此基础上提出了改变炼钢操作传统观念、更新终点控制方法的措施:开展了一次拉碳命中的终点控制方法研究;建立了首钢三炼钢转炉的一次拉碳终点控制模型并进行了典型试验、跟踪试验和推广应用工作。一次拉碳控制模型的连铸钢种双命中率(终点目标温度和碳含量),在试验中达到80%以上。

首钢三炼钢转炉一次拉碳终点控制技术的研究及其模型的建立,是三炼钢投产以来转炉冶炼工艺上的重大突破。它不仅提高了连铸钢种的一次命中率,为三炼钢提高钢种品质奠定了坚实的基础,而且,连铸钢种按一次拉碳模型进行冶炼终点控制,在终点钢水碳含量相同的条件下,氧含量降低了115—145 ppm,钢渣TFe降低了1.5个百分点以上,转炉冶炼时间缩短了3min以上。

(1) 通过三炼钢工业试验,证明转炉人工智能静态控制模型与传统的静态控制模型相比,提高了静态模型的控制精度,终点碳温同时的中率可以达到62.3%,超过了传统的静态模型。

(2) 将人工智能静态模型应用到转炉生产中,可以作为吹炼过程控制的重要参考,在一定程度上可以替代熟练炼钢工进行吹炼控制和终点判断。

(3) 人工神经网络技术应用到转炉炼钢过程控制中,部分解决了常规静态模型很难处理的吹炼过程的随机性和大量影响因子之间复杂的非线性关系等难题,但目前还处于探索性阶段。随着人工神经网络技术的迅速发展,新的算法的出现,

必将在炼钢过程控制中发挥越来越大的作用，将炼钢过程自动控制技术提高到一个新水平。

参考文献

- 1 王雅贞等 氧气顶吹转炉炼钢工艺与设备 冶金工业出版社 1990年
2. 王顺晁 舒迪前 智能控制系统及其应用 机械工业出版社 1998年
3. 张乃尧 阎平凡 神经网络与模糊控制 清华大学出版社 1998年
4. 张国范、顾树生编,《微型计算机控制技术》,东北大学出版社,1997年。
5. Shao S. Fuzzy Self-organizing Controller and its Application for Dynamic Processes. Fuzzy Sets and Systems, 1988, 26:151~164
6. Rhee F V D, Vander Rhee F, Van Na Alemke H R et al. Knowledge Based Fuzzy Control of Systems. IEEE Trans Automatic Control, 1990, 35(2): 148~155
7. Chen, T C Tsao. A Description of the Dynamical Behavior of Fuzzy Systems, IEEE, Trans. on Systems, Man, and Cybernetics, 1989, 19(4):745~755
8. 鲍新福, 都志杰, 王芳君. 自调整比例因子控制器. 自动化学报, 1987, 13(2):129~133
9. 毛宗源, 狄净. 自调整比例因子控制器控制锅炉燃烧过程. 自动化学报, 1991, 17(5): 611~614
10. H R Bernji, P Khedkar. Learning and Tuning Fuzzy Logic Controllers Through Reinforcements. IEEE Trans on Neural Network, 1992, 3(5):724~740
11. 应行仁, 曾南. 采用 B-P 神经网络记忆模糊规则的控制. 自动化学报, 1991, 17(1):63~67
12. J R Jang. Self-learning Controller Based on Temp Back Propagation. IEEE Trans Neural Network, 1992, 3(5):714~723
13. Xiangjie Liu, Tianyou Chai. A Class of Neural-Fuzzy Controller and Its Application in AC Speed Adjustment with Varying Frequency. The 36th IEEE Conference on Decision and Control. San Diego, California

- USA. December ,1997:2742 ~2747
14. Jnubong Nie,D A Linkens. Learning Control using Fuzzified Self-organizing R adial Basis Function Network. IEEE Trans Fuzzy Syst, 1993, 1(4):281~287
 15. Arabashahi Payrran. Fuzzy Control of Back Propagation. IEEE'92 Fuzzy, 1992, 967~972
 16. Choi Jai et al. Fuzzy Parameter Adaptation in Neural systems. IJC-NN'92, Baltimoro,1992. 232~238
 17. Keller J M, Yager R R et al. Neural Network Implementation of Fuzzy Logic ,Fuzzy Sets and Systems, 1992, 45:1~12
 18. Xiang-Jie Liu, Xiaoxin Zhou. Structure Analysis of Fuzzy Controller with G aussian Membership Function. The 14th IFAC World Congress. Beijing China. 1999
 19. H Ying. A Nonlinear Fuzzy Controller with Nonlinear Control Rules is the Su m of a Global Nonlinear Controller and a Local Nonlinear PI-like Controller, Pr oceeding of 1992 NASA International Joint Technology Workship on Fuzzy Logic and Neural Network, Houston, Texas, USA, 1992, 40~47
 20. HYing. General Analytical Structure of Typical Fuzzy Controller and Their Limiting Structure Theorems. Automatica, 1993, 29:1139~1143
 21. Chen Chun Lee. A Self-learning rule-based controller employing approximate reasoning and neural net concepts. Int. J. Intelligent System. 1991, 16(1):71-93
 22. Psaltis D, Sideris A and Yamamura A A. A multilayered neural network controller. IEEE Control System Mag. , 1987, 8(4):17-21
 23. Chen V C and Pao Y H. Learning control with neural networks. Proc. 1989 IEEE Co nf. on Robotics and Automation, Scottsdale, Arizona, U. S. A. , 1989, 1448-1453

24. Astrom K J. Directions in Intelligent Control. In: Plenary Session IFAC International Symposium. ITAC'91, Tokyo, 1991, 15-17
25. 邓志东, 孙增圻, 刘建伟. BP 网络的 PID 型二阶快速学习算法. 自动化学报, 1995, 21(1): 67-71
26. K J Astrom, Thomas J. McAvoy Intelligent Control. J. Proc. Cont. 1992, (3): 115 ~127
27. Scharf E M, Mandic N J. The Application of a Fuzzy Controller to the Control of a Multi-degree Freedom Robot Arm. Industrial Application for Fuzzy Control M Sugeno(ed), North-Holland, 1985
28. Procyk T J, Mamdani E H. A Linguistic Self-organizing Process Controller, Automatica, 1979, 15(1): 15~30

致 谢

首先要感谢我的指导老师王福利教授、杨昭平高级工程师、潘辛教授级高级工程师（2002年2月初不幸因病去世）对我论文工作的耐心指导和帮助，特别是他们对学术研究认真负责的态度，将对我以后的工作和学习产生深远的影响；还要感谢钢铁研究总院冶金工艺研究所的何平教授级高级工程师和杨立红博士，在他们的帮助下，使得我有机会和他们共同完成了部分试验工作；其次要感谢高新技术公司各级领导对我的支持，当我遇到问题的时候总和他们讨论和交流；还要感谢我的班主任温记兰，他对我的关心使我终身难忘，最后要感谢我的家人，尤其是我的爱人对我工作的理解，他们是我最强有力的后盾。

作者从事科学研究和学习经历的简历

1988年至1992年在北京航空航天大学电子工程系学习

1992年7月至2000年12月在北京首钢高新技术公司从事工业自动化的编程调试工作.

1999年9月攻读东北大学控制工程硕士学位.

从1999年开始负责首钢三炼钢转炉智能控制系统以及工艺物流模型的开发.