

分类号_____ 密级 _____

UDC _____

学 位 论 文

首钢精品棒材产品性能预报系统的研发

作 者 姓 名： 吴朝晖

指 导 教 师： 关守平 教授 东北大学自动化研究所

杨雄 高工 首钢技术研究院

申请学位级别： 硕士 学 科 类 别： 专业学位

学科专业名称： 控制工程

论文提交日期： 2011 年 6 月 论文答辩日期： 2011 年 6 月

学位授予日期： 2011 年 月 答辩委员会主席： 井元伟

评 阅 人： 徐林 王凤琴

东 北 大 学

2011 年 6 月

R&D of Mechanical Properties Prediction System for products of ShouGang competitive bar

By Wu Zhaohui

Supervisor: Professor Guan Shouping

Senior Engineer Yang Xiong

Northeastern University

June 2011

独创性声明

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谢意。

学位论文作者签名：吴朝晖

日期：2011.6

学位论文版权使用授权书

本学位论文作者和指导教师完全了解东北大学有关保留、使用学位论文的规定：即学校有权保留并向国家有关部门或机构送交论文的复印件和磁盘，允许论文被查阅和借阅。本人同意东北大学可以将学位论文的全部或部分内容编入有关数据库进行检索、交流。

作者和导师同意网上交流的时间为作者获得学位后：

半年 ☐ 一年 ☐ 一年半 ☐ 两年 ☒

学位论文作者签名：吴朝晖

签字日期：2011.6

导师签名：

签字日期：2011.6.24

首钢精品棒材产品性能预报系统的研发

摘 要

首钢精品棒材车间合金钢产品力学性能生产检验周期长,对合金钢棒材产品生产带来很多不便,为此展开了首钢精品棒材产品力学性能预报系统的开发,并最终实现由力学性能预报代替实物生产检验的目的,一旦研发成功,将大大提高生产检验效率,降低生产成本,对调整工艺、生产组织、销售具有重要的意义。

论文设计了首钢精品棒材产品性能预报系统。通过分析包括输入输出点变量的确定、样本数据采集处理和隐层节点选取等主要内容,构建了 BP 神经网络模型。通过各种算法的优劣性比较,选择了收敛性和准确性更好的 LM 算法,大大改善了网络泛化能力。同时,由于非样本数据的网络预测准确性差,论文又利用 spss 统计分析软件开发了非线性形似度逼近模型和算法,两种算法相辅相成,相互配合,使得改善后的算法大大提高预测模型的计算稳定性和精度。

基于上述模型,采用 Matlab 语言编写和开发了首钢合金结构钢的力学性能预报系统。通过对系统的偏差分析,各项力学性能预测结果均以达到预期目标。目前该系统已投入到生产检验中去,为其它产品性能预测打下了良好的基础。

关键词: 棒材; 性能预报; BP 神经网络; 偏差分析; SPSS 统计分析软件

R&D of Mechanical Properties Prediction System for products of ShouGang competitive bar

Abstract

It is very long for Mechanical properties testing cycle of ShouGang competitive bar products plant which affect whole manufacture of alloy constructional steel product. So we should research Mechanical Properties Prediction System for Alloy Constructional Steel of ShouGang Corporation which replace original testing pattern with prediction system. If succeeded, it will be remarkable for process adjustment, organism of production and sales, where could increase testing cycle and reduce producing cost.

This paper makes a comprehensive design of development and application of mechanical properties prediction system for alloy constructional steel product of ShouGang Corporation. We construct BP neural network model by analysis of primary aspect, which including confirmation of I/O variable, treatment of sample data and selection of the number of the Hidden Layer Nodes. We choose the LM calculation method by comparison, of which improve ability of network generalization. We developed non-linear approximation similarity calculation method by SPSS statistical analysis software for which accuracy of properties prediction of non-sample data Accuracy is unsatisfactory. If the above-mentioned methods are used together, it will improve accuracy of properties prediction evidently.

In the base of the theory of modal, we develop the mechanical properties prediction system for alloy constructional steel product of ShouGang Corporation using Maltlab. All of prediction result is satisfactory by variance analysis. Now the prediction system has put into service for production testing. It will be engaged in other product in the future.

Key words: bar; the mechanical properties prediction; BP neural network; SPSS statistical analyzing software

目 录

独创性声明	I
摘 要	II
Abstract	III
第 1 章 绪论	1
1.1 性能预报模型的分类	1
1.1.1 统计回归模型	2
1.1.2 人工神经网络模型	2
1.2 性能预报在冶金领域的应用	3
1.2.1 性能预报在板带材上的应用	4
1.2.2 性能预报在线棒材上的应用	5
1.3 性能预报技术存在的问题和展望	6
1.4 论文研究内容与结构安排	7
第 2 章 合金结构钢预测模型算法建立	9
2.1 人工神经网络简介	9
2.1.1 人工神经网络的特点	10
2.1.2 人工神经网络的发展及主要类型	11
2.1.3 神经网络学习算法	12
2.2 合金结构钢性能预报神经网络模型	14
2.2.1 输入层与输出层变量的确定	14
2.2.2 样本数据的采集及处理	15
2.2.3 隐层数目和隐层节点数的选取	16
2.3 非线性相似度逼近模型	20
2.3.1 变量之间的相关性分析	20
2.3.2 非线性相似度逼近算法建立	22
2.4 本章小结	25
第 3 章 合金结构钢力学性能预报系统设计	27
3.1 编程语言选择	27
3.2 预报系统的结构和主要功能	27
3.2.1 预报系统的使用前提	28
3.2.2 钢种信息的编辑区域	28

3.2.3 工艺数据编辑区域	29
3.2.4 计算方法选择区域	30
3.2.5 单批次性能预测显示区域	31
3.2.6 批处理预测区域	31
3.2.7 单批次预测历史记录区域	32
3.3 成分预警功能	32
3.4 数据“不落地”的自动化功能	33
3.4.1 数据自动修约功能	33
3.4.2 电子报表生成功能	34
3.4.3 预报系统与 ERP 的信息下载和上传	35
3.5 系统的程序设计	36
3.5.1 VC 编程语言与 MATLAB 软件的数据接口	36
3.5.2 核心算法的编程	37
3.6 本章小结	41
第 4 章 预报系统的应用和偏差分析	43
4.1 试验室条件的完善	43
4.2 力学性能预报检验工作原则	43
4.3 力学性能预报流程	45
4.3.1 常规力学性能生产检验流程	45
4.3.2 力学性能预报系统流程	45
4.3.3 应用期间预报偏差	46
4.4 样本数据对预报系统的偏差影响	47
4.5 隐层节点数对泛化能力的影响	47
4.6 网络模型泛化能力测试	48
4.7 预报系统偏差统计	50
4.7.1 检验数据的预报偏差分析	50
4.7.2 偏差产生原因分析	53
4.8 本章小结	54
第 5 章 结论与展望	57
参考文献	59
致 谢	63

第1章 绪论

组织性能预报技术是近年来国际冶金领域研发的热点，是冶金领域前沿的重点研究技术，具有广泛的应用前景。钢材组织性能预报系统是一门跨学科的实用技术，它涉及的主要技术领域有传热学、压力加工、金属组织工程学、数值分析、人工智能技术和计算机语言等。钢材组织性能预报系统是在现代冶金装备自动化水平不断提高的基础上，充分结合现代信息技术最新成果的产物。钢材组织性能预报的基本研究思路就是深入考察钢材的各个生产工序之可控工艺参数与钢材组织演变之间的关系，从而确立各可控工艺参数与钢材组织性能之间的定量关系。近年来国内外冶金专家开展了大量的有关钢材的化学成分、显微组织与力学性能关系的研究工作，以求通过这些工作来达到描述、预测和控制产品性能的目的^[1]。

钢材组织性能预报系统主要应用于以下几个方面：

- (1) 产品质量检验：性能预报系统的应用将大大减少产品的质量检验，缩短生产周期，有效地降低生产成本；
- (2) 优化现有生产工艺：通过优化现有生产工艺，在不提高品种档次的同时，提升产品性能及质量的稳定性；
- (3) 新工艺的开发；
- (4) 新品种的开发；
- (5) 指导生产设备的改造和设计等。

1.1 性能预报模型的分类

目前常用的性能预报模型的建立主要有两种：统计回归模型和人工神经网络模型。传统的回归模型的最大优势在于它能表达一定的物理意义，但在形式上作了一些简化和假设，具有不完整性的缺点；人工神经网络模型可从大量的输入数据和所设计的关系中进行学习，并从系统中观察重复发生的事件而获得经验，它解决问题的方式不同于传统逻辑思维的算法，其操作具有形象思维的属性，特别适合解决数学建模难以描述的非结构化的问题和非线性化的问题，但其算法从本质上是一种局部寻优算法，不可避免的存在局部极小值。

1.1.1 统计回归模型

这是工业生产中应用较多的一种形式，主要针对于工艺成熟的生产厂的常规产品，因具有大量的生产检验和产品性能数据，这些数据之间有一种内在的规律，当选用恰当的数理统计方法后，可以建立预报产品性能的回归模型。使回归模型经多次逼近修正，以提高预报控制的精度，设计对应的计算机软件可实现在线修正。此模型在回归时不同程度地省略了影响钢板性能的工艺和材质组织因素，有一定的局限性，不太适应现代轧机的技术发展，但对于传统的、工艺稳定的、常规产品的性能预测仍有其独特的简约效果。

1.1.2 人工神经网络模型

20 世纪 50 年代初开始，世界各国冶金学者通过对实验数据进行统计回归，建立了大量的预报热轧钢板组织性能的数学模型。然而常规数学模型预报存在的问题是数学模型只能根据钢材的化学成分和轧制工艺参数包括开轧温度、终轧温度、压下量等来预报钢材的组织性能，可是化学成分和生产工艺参数与成品最终力学性能之间的关系非常复杂，受生产过程中各种随机因素的干扰，化学成分和生产工艺参数对力学性能的影响很难用准确的数学表达式表示出来，实际是一种非线性的关系。利用常规的统计回归数学模型预报存在着很大的局限性。人工神经网络事先无需给定公式（模型）的形式，而是以实验数据为基础，经过有限次迭代计算而获得的一个反映实验数据内在规律的数学模型，非常适合研究复杂非线性系统的特性。人工神经网络是模拟人脑对外界外部环境进行学习过程而建立起来的人工智能模式识别方法，人工神经网络模型具有很强的容错性、自适应性和非线性的映射能力，特别适于解决因果关系复杂的非确定性推理、判断、识别和分类等问题。因此，可以利用人工神经网络实现钢材化学成分、轧制工艺参数与力学性能的直接映射，进而达到较好的对钢材力学性能的预报^[2]。

利用人工神经网络来进行钢铁产品的性能预报技术正在蓬勃发展，并具有广阔的前景。20 世纪 80 年代中期以来，在美国、日本等发达国家，人工神经网络得到了迅速发展，成为一门新兴的交叉学科。据介绍，德国西门子公司将神经网络应用于轧制过程的自动控制，进行轧制力预报，带钢温度预报和自然宽展预报，使轧制力预报精度提高 15~40%。温度精度提高 25%，宽展精度提高 25%。日本日立公司的 Masahiro Kayama 等人将神经网络和模糊控制用于开发“日立自组织诊断和分析系统”，用于支持操作人员以提高钢铁生产企业的管理效率，

并将其应用于连续生产中的镀层重量预报模型,镀层重量预报精度得到明显改善。目前国内外先进的轧制线,如 CSP、ISP 等,则是用此模型实现在线控制的。

在国内,利用人工神经网络来进行钢材的性能预报技术也正在兴起:国内的一些研究者在实验室进行了等效模拟试验,运用了大量工业数据,开展了利用人工神经网络预测中厚板的力学性能研究,其预测的相对误差可控制在 10%~15% 之间,并在宝钢等企业进行工业性应用的合作。本钢集团的李泾和孙洪刚^[3]等人针对长型材生产过程,采用计算机对特钢型材生产过程进行模拟,提出了利用初始化学成分和生产工艺参数组成预测特钢型材产品力学性能的 BP 神经网络模型,实现了对型材力学性能的离线预测,预测精度较高:抗拉强度的预报偏差在 $\pm 2\%$ 以内,淬透性能的预报偏差在 $\pm 3\%$ 以内,冲击功的预报偏差在 $\pm 8\%$ 以内。北京科技大学的周颖,郑德玲等^[4]提出了一种基于免疫识别原理的径向基函数神经网络学习算法。通过预报热轧带肋钢筋力学性能的仿真实验结果表明,该算法计算量较小,精度高。武汉科技大学的王生朝,程晓茹^[5]等人基于神经网络原理,采用 BP 算法训练神经网络,建立热轧控制参数(轧制温度、化学成分、变形量等)对描述产品力学性能的参数的映射关系。离线仿真表明,屈服强度预测的相对误差最大值为 9.0%,85%的预报相对误差落在 6.0% 以内;抗拉强度和延伸率 90% 相对误差在 6% 以内。沈阳航空工业学院的郑晖^[6],开发了利用人工神经网络预测力学性能的软件。软件共分三大部分:数据处理部分、人工神经网络训练部分、运用成熟网络预报部分。用此软件对 SS400 钢的性能进行预报,产品力学性能的预报值与实际值拟合良好,预报结果的相对误差较小:测试的结果中,屈服强度 88% 相对误差在 $\pm 4\%$ 以内,抗拉强度 86% 相对误差在 $\pm 2\%$ 以内,延伸率 78% 相对误差在 $\pm 6\%$ 以内。

1.2 性能预报在冶金领域的应用

计算机技术在轧制过程中的不断应用,使现代化的轧钢生产达到一个全新的水平。经典力学与数值模拟相结合,有效的用于力能参数优化和产品质量(如板形)预报、工艺参数优化和设备设计等方面。但随着人类对钢铁材料的性能质量要求越来越高,计算机数值模拟技术正由轧件尺寸形状的预测和力学模拟转到金属组织性能预测和控制上来。利用数学模型预测钢材组织演变及力学性能的想法诞生于 20 世纪 50 年代^[7]。热轧钢的力学性能预报一直是世界各国冶金工作者最关注的研究方向之一,与之相关的大量基础研究工作也相继展开。近年来,国外有不少冶金学者分别开发了各种不同类型的热轧模型^[8,9],用于离线计算轧制负

荷, 微观组织演变等。

美国钢铁学会投资开发了计算机综合产品性能预报及控制系统^[10], 并已在一些钢厂应用, 取得了如下效果:

- (1) 用同一种坯料可生产多种钢材, 从而减少了冶炼品种, 提高了效益;
- (2) 利用计算机协助钢材设计, 缩短了试验周期, 降低了开发成本;
- (3) 根据数据实测信息, 可迅速决定终轧温度、控冷参数与性能之间的关系, 在工艺上及时做出调整, 进行质量检测及控制, 对稳定和提高性能有明显作用;
- (4) 能充分利用信息指导生产。如生产不正常, 通过计算机虚拟现实, 能及时发现问题, 使生产和质量状况迅速改变。

1.2.1 性能预报在板带材上的应用

热轧带钢的力学性能预报一直是世界各国冶金工作者最关注的研究方向之一, 与之相关的大量基础研究工作也相继展开。热轧生产中带钢力学性能与微观组织变化是密切相关的, 只有将二者结合起来才能精确描述这一过程并用于在线预测。这将涉及到温度场模型、微观组织演变模型等, 是一个比较复杂, 综合性较强的工程。英国率先给出了可以定量描述热轧生产以及随后的冷却过程中线材显微组织演变的数学模型。在 20 世纪 80 年代, 许多研究者都开始致力于这方面的研究, 到 90 年代, 大量的数学模型已经能够用来描述析出、相变等复杂的冶金学现象。许多钢铁工作者都尝试将这些冶金学模型、温度场模型及变形模型结合起来, 应用到实际生产中, 以生产出理想的产品。这一方法首先在热轧板带钢生产中实现, 其基本思路是利用物理冶金学模型, 综合温度场及变形计算, 对热轧生产中各种金属学现象, 如奥氏体的再结晶, 奥氏体向铁素体、珠光体和贝氏体的相变等进行计算机模拟, 预测出轧后产品的性能。

1997 年, 奥钢联工程技术公司与林茨钢厂合作开发了热连轧带钢质量控制系统 (VAI-Q Strip), 并实现了该技术的首次在线应用^[11]; 其核心是轧制过程及相关显微结构的物理—冶金模型。该模型考虑了化学成分、实际轧制温度、形变再结晶、微合金析出等晶粒细化的影响, 并根据晶粒尺寸进一步导出力学性能模型, 目前已用于低碳钢、结构钢和低合金高强度 (Ti-Nb) 微合金钢, 在力学检验中可减少实际取样 40%~50%, 取得了很好的经济效益。之后不久, 西门子的在线显微结构监控系统 (BM-MM) 也推向了市场。

这些研究和开发大大激励了国内在该领域的相关研究人员。许多知名科研院所, 如钢铁研究总院、东北大学、中国科学院金属研究所等, 也相继开展了热轧

带钢力学性能预报技术的研究工作,并研制出自己的性能预报系统,其中有代表性的技术有钢铁研究总院与东北大学合作完成的连铸连轧过程组织性能预报系统(Q-HSM),中国科学院金属研究所研制的热轧带钢组织性能预报系统(ROLLAN)。南京钢铁集团的朱鹏举^[12]针对南钢中厚板生产过程,四辊中板轧机的控轧控冷轧制工艺,建立了C-Mn钢在控轧和控冷生产中微观组织演变和力学性能预测的物理冶金模型。根据现场数据,计算了轧制过程奥氏体晶粒尺寸和再结晶分数的演变,预测了在不同工艺条件下连续冷却转变各相的体积分数和铁素体的晶粒尺寸等显微组织参数和相关的力学性能,预测结果和实测值吻合较好。

1.2.2 性能预报在线棒材上的应用

相对于板带钢生产过程而言,线材生产在以下几个方面有着明显的不同:(1)孔型中的变形不均匀;(2)平均压下率由孔型的次序所决定;(3)变形速率很高;(4)较短的变形时间和孔型中的大量热交换。与生产过程相对应,线材生产中显微组织演变过程中的物理冶金模型一般主要包括4个子模型:奥氏体再结晶模型、奥氏体相变模型、组织模型和力学性能模型。这4个子模型是开展线材组织性能预测的核心^[13]。因而,预测难度较大。尽管如此,组织性能预测在线材生产中的应用还是迅速开展起来,引起钢铁工作者的广泛兴趣。

在国外,报道比较完整的研究主要有:意大利的E.Anelli成功地预报了从焊丝软钢(ES17)到钢丝绳(FF82K)线材的组织演变,以及Maccagno.T.M等研制的线棒材轧制时奥氏体晶粒组织演变的数学模型,并用电子表格计算了各种工艺条件下奥氏体晶粒度的变化^[14]。可见,这已成为一个热点研究对象,并逐渐将组织性能预报扩展到线棒材生产上。

在国内,武钢大型厂和武汉科技大学合作进行的“显微组织和力学性能预报研究”项目,针对武钢大型厂高线车间的实际生产情况,提出了适用于高碳钢高速线材控轧控冷生产中组织转变和力学性能的预报模型,其预报结果与现场实测结果十分吻合^[15-17]。该预测模型为制定合理的高碳钢高速线材控轧控冷工艺制度提供理论依据,使产品的金相组织及机械性能得到明显的改善,其中82B盘条因组织、性能不合改判80C由6.91%降低到0.82%,改判为82MnA由3.75%降低为0.12%,取得了显著的经济效益。武汉科技大学的蔡丹、赵嘉蓉^[18],针对武钢高速线材车间生产的82B钢种在斯太尔摩冷却线上的相变过程进行模拟,预测了最终的显微组织和力学性能。并在研究中,开发得到一个预报硬线钢显微组织演变和线材最终力学性能的计算机软件,成为计算机离线研究轧制工艺的辅助工具。

华中科技大学的张云祥、张海鸥^[19]等人开发了用于模拟高碳钢高速线材生产过程中断面温度分布,奥氏体组织演变和产品性能的系统的数学模型组。由实验确定的临界应变、奥氏体再结晶、斯太尔摩冷却线上奥氏体相变、组织和力学性能关系子模型耦合轧件温度场,构建了一个组织性能预报系统。该系统所计算出的轧制线上关键点钢材温度,奥氏体晶粒度和力学性能与实测值吻合较好。

目前,查到的有关棒材组织性能预报的文献较少:东北大学的陈连升和河北理工大学的宋进英等人^[20],针对石钢棒材厂的调制钢棒材生产,进行了棒材组织性能预报软件的开发。模拟了从轧制到调质整个工艺过程中的温度场、轧制负荷、组织性能、热处理效果等。并对 20CrMo 和 40Cr 两个钢种进行了现场实际计算,计算出的轧制和轧后冷却过程的温度变化以及热轧态与热处理态组织性能的预报结果均与现场实测数据吻合得比较好,偏差在 5% 范围之内。

1.3 性能预报技术存在的问题和展望

目前,描述钢材热轧组织演变的物理冶金模型大多是由实验模拟结果得到的半经验公式。由于实验室条件的限制,还应进一步提高这些公式的精度,并深入探讨钢材的动、静态再结晶行为。线材生产的产品种类繁多,包括低碳钢、中高碳钢、冷镦钢和合金钢。这些钢种的化学成分范围波动较大,要得到准确的、适于每一钢种的数学模型,需要大量的实验研究。此外,不同化学元素及其含量对组织演变过程的影响仍处于定性研究阶段,其定量化还有待探讨。不同产品的具体生产工艺不同,其温度场和变形过程均较复杂,给编制计算机软件实时跟踪钢材内部组织演变带来困难。在轧后冷却过程中发生的相变,由于出现了贝氏体和马氏体也变得更加复杂。有关钢材冷却过程中相变开始温度的精确计算也是难点,这都需要进一步简化动力学和热力学计算。

钢材产品的性能预报因目的不同,采用的方法也不同。其中材料组织与力学性能之间关系的研究是冶金学者企图达到数字化钢材材质设计和制造而作的努力。虽取得一些定性的认识,但达到完全数值化的定量描述难度较大,一时还难以在工业生产中实质性应用。随着钢材力学性能预报技术应用范围的不断拓展,技术应用的进程似乎再次遇到了瓶颈。武汉钢铁(集团)公司和宝山钢铁股份有限公司先后试用过西门子的 BM-MM,但都没有取得预想中的实际效益。除了林茨钢厂,几乎所有报道都是只谈模型精度,而没有提到应用效果以及是否产生了效益,这说明性能预报技术要想实用化还有很大难度^[21]。

人工神经网络模型适合研究复杂的非线性系统特性,对于先进的钢材轧制生

产线,可实现在线的控制轧制。但是,运用人工智能技术进行预报和控制需要建立精确的数据采集系统和庞大的数据库,这对于我国大多数钢铁企业来说难以实现,这也正是制约人工智能技术在轧钢生产中广泛应用的症结所在。统计回归模型是一种较传统的方法,当模型实现在线完善修正,不断提高预报值的精度后,是可以用于传统轧机的生产管理和物理性能检验控制的,并能收到一定的效果的,此种低成本数据处理系统,对于传统轧机的产品性能发掘和信息发觉是一种有益的工作^[22]。在不久的将来,可望将人工智能技术与数学模型预报技术有机地结合起来,从而实现对组织性能的准确预报和控制。

钢材组织性能预报系统为钢铁生产企业提供了一个数字化的平台,或者说提供了一个电子实验室,借助于该平台,可以帮助用户实现生产的最优化,在最大限度地降低生产成本的同时提高产品的质量。鉴于以上事实,钢材组织性能预报系统的市场前景很好,直接的和间接的经济效益巨大^[23]。尤其值得指出的是随着钢材组织性能预报技术的不断开发和完善,钢材组织性能预报系统的离线预报和在线预测结果有可能成为一种普遍接受和认可的工业标准。从而在钢铁企业交货时,部分或全部地实现力学性能的免检。这一点已不再是难以企及的梦幻,它的实现并不遥远。钢材组织性能预报系统对冶金工程师来讲是一个威力巨大的定量工具,在它的帮助下,可以探索在冶金过程中各种可能的工艺参数的组合所可能产生的结果。而这一点无论在实验室还是在工业现场都是无法做到的^[24]。

1.4 论文研究内容与结构安排

本论文重点开展如下内容的研发工作,具体结构安排如下:

(1) 合金结构钢力学性能预报模型和算法的设计、研究和选择

通过分析研究各种 BP 神经网络模型算法,选择出最适合合金结构钢的力学性能预测算法,并针对非样本数据奇异性较大的问题,开发对非样本数据预测更为有效的算法;

(2) 首钢合金结构钢力学性能预报系统的开发

设计首钢合金结构钢力学性能预报系统的各种功能模块,采用 Matlab 语言和 VC++ 语言联合编写和开发性能预报系统,开发单批次/批处理预测、预报系统与 ERP 之间信息的下载和上传、数据的自动修约、电子报表的自动生成和成分自动预警等功能;

(3) 力学性能预报系统的实际应用和偏差分析

在满足上线基本条件的基础上,在线应用本系统进行力学性能预报,并通过

网络模型泛化能力测试和偏差分析来检验预报系统的偏差及其产生原因。

第2章 合金结构钢预测模型算法建立

利用数学模型预测钢材组织演变及最终力学性能的想法诞生于20世纪50年代。而由于化学成分、工艺参数与成品最终力学性能之间的关系非常复杂,利用常规的统计回归数学模型预报存在着很大的局限性,即常规数学模型很难用准确的数学表达式来反映——化学成分和生产工艺参数对力学性能影响的这种非线性的关系。但当常规方法无法解决或效果不佳时神经网络就显示出其优越性。尤其是当对问题的机理等规律不甚了解或不能用数学模型表示的系统,神经网络往往是最有力的工具。另外,神经网络对处理大量原始数据而不能用规则或公式描述的问题,表现出极大的灵活性和自适应性。因此神经网络作为人工智能的一个重要发展方向,在组织性能预报技术领域发挥着重要作用。

2.1 人工神经网络简介

自20世纪80年代中期以来,在美国、日本等发达国家,人工神经网络逐渐发展成为一个十分热门的交叉学科。它涉及生物、电子、计算机、数学和物理等学科,有着非常广泛的应用背景,这门学科的发展对目前和未来的科学技术的发展将有重要影响。人工神经网络(Artificial Neural Networks,简称为ANNs,也简称为神经网络(NNs)或称作连接模型(Connectionist Model))是模拟人脑对外界外部环境进行学习的过程而建立起来的人工智能模式识别方法:从人脑的结构看,它是由大量神经细胞组合而成的,这些细胞相互联接,每个细胞完成其某一种基本功能,如兴奋与抑制。从整体看,它们相互整合完成一种复杂的计算机思维活动,这些工作是并行的、有机的关联在一起。在人的日常生活中,每天都有成千上万的信息需要脑来处理,一个简单的动作如端一杯水、打一个电话,就牵涉到记忆、学习和相位变换等功能,而人却可以不假思索地完成,这就说明需要有一种新型的、类似于人脑结构的系统来完成那些计算机做起来很慢或很困难的工作。

人工神经网络就是采用物理可实现的系统来模仿人脑神经细胞的结构和功能的系统。它是由很多处理单元有机地联接起来,进行并行的工作,它的处理单元

十分简单，其工作则是“集体”进行的，它的信息传播、存贮方式与神经网络相似，它没有运算器、存贮器、控制器这些现代计算机的基本单元，而是相同的简单处理器的组合。它的信息是存贮在处理单元之间的连接上，因而，它是与现代计算机完全不同的系统。

人工神经网络是一种模范动物神经网络行为特征，进行分布式并行信息处理的算法数学模型。这种网络依靠系统的复杂程度，通过调整内部大量节点之间相互连接的关系，从而达到处理信息的目的。人工神经网络具有自学习和自适应的能力，可以通过预先提供的一批相互对应的输入—输出数据，分析掌握两者之间潜在的规律，最终根据这些规律，用新的输入数据来推算输出结果，这种学习分析的过程被称为“训练”。

2.1.1 人工神经网络的特点

在生物体内的神经细胞中，来自其他几个神经细胞的轴突输出是发放脉冲串，用脉冲串在单位时间内的发放率来表示其兴奋活动情况。在人工神经网络的硬件实现时，也有人用数字脉冲频率的大小表示单元的状态和输出，但与真正的神经网络还有较大的差距。而且由于信息的传递是采用电压的方式，因而大多数人工神经网络只有空间累加而没有时间累加。在人工神经网络中，也没有考虑突触原则中的疲劳和不应期。神经网络是由大量的神经细胞组成，而且神经细胞会不断死亡和增殖，在人工神经网络中，由于物理器件的限制，它的神经单元的数目大大小于真正神经网络中的细胞数，因而其功能也比真正神经网络差得多，这是两者最大的区别。当然，随着新器件（如分子器件）的发展会逐步缩小这个差距。

人工神经网络中，神经元处理单元可表示不同的对象，例如特征、字母、概念，或者一些有意义的抽象模式。网络中处理单元的类型分为三类：输入单元、输出单元和隐层单元。输入单元接受外部世界的信号与数据；输出单元实现系统处理结果的输出；隐层单元是处在输入和输出单元之间，不能由系统外部观察的单元。神经元间的连接权值反映了单元间的连接强度，信息的表示和处理体现在网络处理单元的连接关系中。人工神经网络是一种非程序化、适应性、大脑风格的信息处理，其本质是通过网络的变换和动力学行为得到一种并行分布式的信息处理功能，并在不同程度和层次上模仿人脑神经系统的信息处理功能。它是涉及神经科学、思维科学、人工智能、计算机科学等多个领域的交叉学科。

人工神经网络是并行分布式系统,采用了与传统人工智能和信息处理技术完全不同的机理,克服了传统的基于逻辑符号的人工智能在处理直觉、非结构化信息方面的缺陷,具有自适应、自组织和实时学习的特点。

虽然人工神经网络与真正的神经网络存在很大差别,但是由于它吸取了生物神经网络的部分优点,因而有其固有的特点:

(1) 人工神经网络在结构上与目前的计算机根本不同,它是由很多小的处理单元互相联接而成,每个单元的功能简单,但大量简单的处理单元集体的、并行的活动得到预期的识别、计算的结果,具有较快的速度;

(2) 人工神经网络具有很强的容错性,即局部的或部分的神经元损坏后,不影响全局的活动;

(3) 人工神经网络所记忆的信息是存贮在神经元之间的权中,从单个权中看不出其贮存信息的内容,因而是分布式的存贮方式;

(4) 人工神经网络具有十分强的学习功能,人工神经网络中的连接权和连接的结构都可以通过学习而得到。

2.1.2 人工神经网络的发展及主要类型

自1943年第一个神经网络模型—MD模型被提出至今,神经网络的发展十分迅速,特别是1982年提出的Hopfield神经网络模型和Rumellart于1985年提出的反向传播算法(Back Propagation),使得Hopfield模型和多层前馈型神经网络成为用途非常广泛的神经网络模型。它的基本结构是由大量的神经元联接而成,适当选取神经元兴奋模式的初始状态,当网络的状态逐渐达到一极小点(稳定点),从而联想到稳定处的样本。

人工神经网络按照网络拓扑结构可分为前向网络(Feedforward Network)和反馈网络(Recurrent Network)两大类。前向网络特点是:信号的流向是从输入通向输出。而反馈网络的主要不同点表现在它的输出信号通过与输入连接而返回到输入端,从而形成一个回路。反向传播网络(Back-Propagation Network,简称BP网络)是前向网络的核心部分,在人工神经网络的实际应用中,80%~90%的人工神经网络模型是采用BP网络或它的变化形式,体现了人工神经网络最精华的部分。它是将W-H学习规则一般化,对非线性可微分函数进行权值训练的多层网络。

BP 网络主要用于:

- (1) 函数逼近: 用输入矢量和相应的输出矢量训练一个网络、逼近一个函数;
- (2) 模式识别: 用一个特定的输出矢量将它与输入矢量联系起来;
- (3) 分类: 把输入矢量以所定义的合适方式进行分类;
- (4) 数据压缩: 减少输出矢量维数以便于传输或存储。

反馈网络又称自联想记忆网络, 其目的是为了设计一个网络, 储存一组平衡点, 使得当给网络一组初始值时, 网络通过自行运行而最终收敛到这个设计的平衡点上。反馈网络能够表现出非线性动力学系统的动态特性。它所具有的主要特性为以下两点:

- (1) 网络系统具有若干个稳定状态。当网络从某一初始状态开始运动, 网络系统总可以收敛到某一个稳定的平衡状态;
- (2) 系统稳定的平衡状态可以通过设计网络的权值而被存储到网络中。

2.1.3 神经网络学习算法

目前神经网络理论与应用都取得了长足进步, 在神经网络预测方面, 前馈型 BP 网络成为用途最广泛的网络之一。BP 网络的产生归功于 BP 算法的获得。BP 算法属于 δ 算法, 是一种监督式的学习算法。其主要思想为: 对于 q 个输入学习样本: $p^1, p^2, \dots, p^q$, 已知与其对应的输出样本为: $T^1, T^2, \dots, T^q$ 。学习的目的是用网络的实际输出 $A^1, A^2, \dots, A^q$ 与目标矢量 $T^1, T^2, \dots, T^q$ 之间的误差来修改其权值, 使 A^j ($j=1, 2, \dots, q$) 与期望的 T^j 尽可能地接近, 即: 使网络输出层的误差平方和达到最小。它是通过连续不断地在相对于误差函数斜率下降的方向上计算网络权值和偏差的变化而逐渐逼近目标的。每一次权值和偏差的变化都与网络误差的影响成正比, 并以反向传播的方式传递到每一层的。BP 算法由两部分组成: 信息的正向传递与误差的反向传播。在正向传播过程中, 输入信息从输入层经隐含层逐层计算传向输出层, 经过转换函数 (取 sigmoid 函数) 作用后, 再把中间层节点的输出信号传播到输出节点, 最后输出识别或判别结果, 每一层神经元的状态只影响下一层神经元的状态。如果输出层未能得到期望的输出, 则计算输出层的误差变化值, 将偏差信号沿着原来的连接通路反向传播回来, 通过一定的学习规律来不断调整各层神经元的权值, 以使网络模型的输出与期望输出之间的偏差达到足够小的期望目标, 而且这种调整过程是自动进行

的, 是一种自学习过程。

当输入和输出是非线性关系时, 以及训练样本充足的情况下, 该算法非常有效。但在实践中, BP 算法暴露了自身存在的弱点, 如收敛速度慢、全局搜索能力差等问题。因为问题的求解空间多是及其复杂的多维曲面, 存在多个局部极小点, 使得陷入局部极小的可能性大大增加。由此, 近年来出现了基于遗传算法 (GA) 的进化神经网络 (Evolutionary Neural Network)。以遗传算法为代表的进化算法也是仿效生物处理模式来获得智能信息处理功能的理论^[25], 它模拟生物的进化现象 (自然淘汰、交叉、变异等), 来表现复杂现象的一种概率搜索方法, 以达到快速而有效地解决各种困难问题。首先是将问题求解表示成基因型 (如二进制编码串), 从而构成染色体群, 根据适者生存的原则, 从中选取适应环境的个体, 淘汰不好的个体, 把保留下来的个体复制再生。通过交叉、变异等遗传算子产生新一代染色体群。依据某种收敛条件, 一代一代不断进化, 最后收敛到最适应环境个体上, 求得问题最优解。神经网络和遗传算法目标相近而方法各异, 将两种方法结合起来, 必能达到取长补短的作用。近年来, 在这方面已取得不少研究成果, 形成了遗传算法和神经网络相结合的进化神经网络^[26-28]。

比起早期的 BP 神经网络, BP 的改进算法如增加动量项、学习率自适应调整等无论在理论上还是网络性能上都更加成熟, 能够有效地抑制网络陷入局部极小, 缩短学习时间。但对于较复杂的非线性预测而言, 这种快速 BP 算法仍然收敛较慢, 精度不高; 以遗传算法为代表的进化算法虽然具有较好的全局搜索能力, 但在进化后期, 由于群体中个体的差异已变得很小, 适应度值也比较接近, 此时选择和交叉操作算子对进化效果都不大。虽然变异操作可以提高进化后期的收敛速度, 但也存在将已接近最优解的个体变成适应度较低个体的可能性。

LM 算法是 Levenberg-Marquardt 算法的简称, 是 Levenberg (1944) 和 Marquardt (1963) 提出的一种最优化算法, 解决非线性最小二乘问题。Gauss-Newton 法收敛迭代时, 容易出现搜索方向的系数矩阵出现奇异阵 (非满秩) 而使得算法常常收敛到一个非驻点, 以及由于初始点选择不当出现不收敛 2 种情形, LM 算法针对这一情况, 考虑采用信赖域策略。牛顿法只能保证算法的局部收敛性, 信赖域方法它不仅可以用来代替一维搜索, 而且也可以解决 Hessian 矩阵不正定和鞍点等困难。这种方法首先选择提出的 1 种阻尼最小二乘法。

在实际中, 为了减轻非最优点的奇异问题, 使目标函数在接近最优点时, 在

极值点附近的特性近似二次性，以加快寻优收敛过程，一般是通过在搜索方向的系数矩阵 $J^T J$ 的主对角阵中的每个元素都加一个小的正数 u （由于起阻尼作用，故称阻尼因子），这就是 LM 算法的基本思想，即：

$$(J^T J + uI)p = -J^T e \quad (2.1)$$

$$w^{(k+1)} = w^k + \alpha p$$

式中， e 是误差， p 为前进方向， w 为连接权， J 为计算目标误差函数对连接权的一阶导数，各参数具体表达式参见文献^[29,30]。

变量 u 决定了学习算法是根据牛顿法还是梯度法来完成，下式为更新参数的 Levenberg-Marquarat 规则^[31]

$$\Delta w = (J^T J + uI)^{-1} \cdot J^T e \quad (2.2)$$

随着 u 的增大，Levenberg-Marquarat 中的项 $J^T J$ 可以忽略。因此学习过程主要根据梯度下降，即 $u^{-1} J^T e$ 项。 u 为零时，就是 Gauss-Newton 算法的基本原理。只要迭代使误差增加， u 也就会增加，直到误差不再增加为止，但如果 u 太大，则会使学习停止（因 $u^{-1} J^T e$ 接近于 0），当已经找到最小误差时，就会出现这种情况，这就是为什么当 u 达到最小值时要停止学习的原因。因此，LM 优化算法是梯度下降法与高斯牛顿法的结合，既有高斯牛顿法的局部收敛性，又有梯度下降法的全局特性，可以有效地改善网络收敛性能。就训练次数及准确程度而言，LM 算法明显优于 BP 算法及其衍生算法。

2.2 合金结构钢性能预报神经网络模型

2.2.1 输入层与输出层变量的确定

由于首钢精品棒材车间生产的合金结构钢批量大，数量多，生产检验数据较多，冶炼工艺、轧制工艺和调质热处理等工艺基本稳定，可很好的反映化学成分、热处理工艺等参数与钢材力学性能之间的关系，因此钢材的上述参数具有一定的规律性和代表性，因此本性能预报系统以合金结构钢精棒材作为力学性能预报研究对象。以 40CrA 为例，其热处理工艺为一次淬火+回火，淬火温度均为 850℃，回火温度均为 520℃。对于同一钢种，由于其热处理工艺是固定不变的，所以其输入层几何参数不考虑热处理工艺，而只是包括其规格和主要化学成分。若输入层几何参数变量太多，则可能会带来网络收敛精度和速度的问题，因此在选择输

入参数时，既要全面而合理的反应几何特征，又要尽量避免网络冗余而造成的资源浪费。40CrA 的化学成分包括：碳、硅、锰、磷、硫、铬、镍、铜、钼等，但磷、硫、钼的含量少且波动范围较小，其变化对 40CrA 力学性能影响的程度很小，所以可以作为次要因素将其忽略；镍、铜的含量是固定不变的，所以也可以不考虑。只将碳、硅、锰、铬、规格等五个因素作为输入层单元；40CrA 的力学性能主要衡量指标为屈服强度（ R_{eL} ）、抗拉强度（ R_m ）、断后伸长率（ A ）、断面收缩率（ Z ）和冲击功（ A_k ），将它们作为输出单元。由此确定的 40CrA 钢力学性能预报模型的神经网络模型结构如图 2.1 所示。




图 2.1 40CrA 钢性能预报模型神经网络结构

Fig.2.1 Neural network model for mechanical properties prediction of 40CrA

2.2.2 样本数据的采集及处理

以 40CrA 钢为例，样本数据包括网络输入值（规格、碳、硅、锰、铬）和输出值（屈服强度、抗拉强度、断后伸长率、断面收缩率和冲击功）。本力学性能预报模型所需的样本数据均取自首钢精品棒材生产线的生产检验数据。40CrA 原始数据库共收集了从 2007 年 1 月~2009 年 10 月 40CrA 所有的检验数据,包括规格、主要化学成分和各力学性能。

首先要对原始数据库进行一些预处理工作：1）规格和成分以及各力学性能完全相同的冗余数据要进行筛选，将完全重复的数据删除，并按照规格有小到大、各成分由小到大的顺序进行排序(目前,这一步操作已由仿真组自行开发的 Matlab 程序进行处理)；2）对规格、成分均相同，但力学性能不同的数据要进行合并处理，合并原则是：以屈服强度为主要参照目标，去掉包含力学性能最小值和最大

值的批次, 保留力学性能大小位居中间的数据; 合并后数据库中每个批次数据均包括两个力学检验样品的数据, 按照屈服强度小在前、大在后进行排列; 3) 将合并后的所有数据进行归一化处理。经过预处理后, 40CrA 的数据库中共包括 1735 组样本数据。将所有样本数据按规格分为 14mm、16~22mm、24~36mm、38~55mm、60~80mm, 共 5 组。分别将这五组样本数据带入用 Matlab 开发的神经网络程序进行训练, 优化隐层节点数和传递函数, 隐层单元节点数采用试凑法来确定, 具体过程见下文介绍。

神经网络在学习、训练之前, 通常要对样本数据进行处理。因为有些变量不在同一个数量级上, 这种奇异的输入输出将大大增加神经网络的训练时间甚至有可能导致网络不收敛, 因为相匹配的权值阈值很难搜索到。例如在图 2.1 的网络模型中, 规格在 14~80mm 之间波动, 而 C、Si、Mn、Cr 却在 0.17~1.1% 之间波动; 断后伸长率在 9~17.5% 之间波动, 而屈服和抗拉强度却在 785~1490MPa 之间波动, 这些输入或输出层各变量之间的巨大差异很有可能会导致网络训练的失败。因此在神经网络样本训练之前, 最好先对样本数据进行处理, 将网络输入或输出项调整到相近或相同的数量级上。样本数据进行+1~-1 之间的归一化处理是神经网络常用的数据处理方式, 但为了减小小数点位数, 使数据比较整齐, 仿真组决定将所有输入和输出数据都控制在 0~10 之间。具体操作过程为: 将输入和输出变量先进行归一化处理, 然后再进行样本学习训练, 识别后再用与归一化处理后的相反过程对数据进行处理, 最终返回原始结果。归一化公式和反归一化过程公式分别为 2.3 和 2.4。

$$X_{\text{归一}} = 10 \times \frac{X_{\text{原}} - \text{Min}(X_{\text{原}})}{\text{Max}(X_{\text{原}}) - \text{Min}(X_{\text{原}})} \quad (2.3)$$

$$X_{\text{原}} = 0.1 \times X_{\text{归一}} \times (\text{Max}(X_{\text{原}}) - \text{Min}(X_{\text{原}})) + \text{Min}(X_{\text{原}}) \quad (2.4)$$

式中: $X_{\text{原}}$ —原始样本数据;

$X_{\text{归一}}$ —归一化后的样本数据;

$\text{Min}(X_{\text{原}})$ —原始样本数据最小值;

$\text{Max}(X_{\text{原}})$ —原始样本数据最大值;

2.2.3 隐层数目和隐层节点数的选取

网络结构的选取包括网络的总体结构(单网络或多网络)、隐层数目和隐层节

点数目等网络结构参数的确定,它对网络计算性能有很大影响。美国学者 David C. 还在文献中介绍了一种用于在线识别和自适应最优控制的神经网络结构。

增加隐层数虽然可以降低误差,提高精度,但同时也使网络复杂化,从而增加了网络权值的训练时间,而误差精度的提高实际上也可以通过增加隐含层中的神经元数目来实现,其训练效果也比增加层数更容易观察和调整。所以一般情况下,应优先考虑增加隐含层中的神经元数。网络精度的提高,可以通过采用一个隐含层,而增加其神经元个数的方法来获得,这在结构实现上,要比增加更多的隐含层要简单的多,那么究竟选取多少个隐含节点才合适?这在理论上并没有明确的规定,但与样本数量紧密相关,因为样本的训练过程就是减少未知网络参数个数的过程,由于神经网络具有输入输出映射能力,可以近似等效于一组方程组,若网络中待定参数大大多于等效方程组个数,计算结果将不稳定,对未训练的数据会出现较大误差,若待定参数过少,会造成网络过度适合,学习过程不易收敛,文献^[32,33]给出了样本数目与待定网络参数的经验关系式,

$$KN = \alpha NT \quad (2.5)$$

式中, K 为输出节点个数; N 为样本数; NT 为待定网络参数个数; α 为网络调节系数(一般取 1~2)。

对于单隐层网络,待定网络参数的个数可以用下式确定:

$$NT = J(I + K) + J + K \quad (2.6)$$

式中 I 为输入节点数, J 为隐层节点数。

但是按照公式 2.5 和 2.6 确定的隐层节点数目通过实际测试发现,网络的收敛性很好(见图 2.2),样本数据预报精度达到了 99.9%以上(图 2.3~图 2.7),但是对于非样本数据,网络预测稳定性很差,负值、几十万的远超乎合理范围的奇异数据经常出现(图 2.8),非样本数据的奇异性比例达到了 60%以上,无法实现稳定应用。




图 2.2 迭代计算的收敛曲线 (平方和误差)

Fig.2.2 Convergence curve of iterative computation (error sum squares)




图 2.3 屈服强度网络识别与真实值比值

Fig.2.3 Ratio between value of networks prediction and true value for yield strength




图 2.4 抗拉强度网络识别与真实值比值

Fig.2.4 Ratio between value of networks prediction and true value for tensile strength




图 2.5 伸长率网络识别与真实值比值

Fig.2.5 Ratio between value of networks prediction and true value for elongation




图 2.6 断面收缩率网络识别与真实值比值

Fig.2.6 Ratio between value of networks prediction and true value for reduction of cross-section area




图 2.7 冲击功网络识别与真实值比值

Fig.2.7 Ratio between value of networks prediction and true value for impacting energy




图 2.8 神经网络的奇异数据
Fig.2.8 Special data of neutral networks

影响 BP 神经网络技术稳定应用的是网络泛化能力，网络泛化能力低，则对于非样本数据出现奇异数据的概率就大。而影响网络泛化能力的主要因素就是隐层单元数目的确定。本课题通过对隐层单元节点数、样本数据量、输入层变量数、输出层变量数、收敛精度等参数进行大量的计算和网络泛化数据测试分析，研究了较为稳定的隐层节点数量的确定方法，即

$$J * N = \alpha [M * (I + J) + M] \tag{2.7}$$

式中， I 为输入节点数， J 为输出节点个数； N 为样本个数； M 为需要确定的隐层节点数， α 为网络调节系数（在 0.8~1.2 之间）。

采用该方法，显著改善了网络泛化能力，奇异数据产生比例降低到 10% 以下。

2.3 非线性相似度逼近模型

为提高预报模型精度和稳定性，在常规的神经网络算法基础上，开发了非线性相似度逼近算法，该方法与神经网络方法结合，实现了力学性能预报系统的稳定应用，彻底消除了奇异数据的发生。

2.3.1 变量之间的相关性分析

SPSS 是美国公司开发的专业统计分析工具，具有统计报表（reports）、均数比较（compare means）、一般线性模型（general linear model）、相关性（correlate）、回归（regression）、分类（classify）、多重响应（multiple response）等分析功能。本课题利用统计分析中的双变量相关分析方法研究了规格、成分等各变量对各输

出变量的权重影响因子。

相关分析是研究变量间密切程度的一种统计方法。当分析多个事物之间关系，而这种关系又往往是变量之间的数量关系时，可采用双变量相关分析方法，并作出统计学推断。双变量相关分析可以输出变量两两间的 Pearson 相关系数。

为减小误差，较为准确分析变量之间相关性，将样本数据进行规格范围的分区离散，然后进行逐段分析，因此各段相关性结果会有所变化。以 2007~2009 年 24~36mm 规格范围的 40CrA 钢样本数据为例，图 2.9 为相应的相关性分析的归一化样本数据，以屈服强度 Rt0.5 为例，进行规格、C、Si、Mn、Cr 与 Rt0.5 相关性分析，分析结果见表 2.1。

从统计分析的显著性检验结果来看，24~36mm 规格、Si、Mn、Cr 与屈服强度 Rt0.5 的相关性较强，Mn 的相关系数最大，为 0.33，Si 为 0.196，Cr 为 0.168，规格的相关系数为 0.128，C 相比其他因变量相关性不强，可定义为 0.01。其他规格范围的相关性分析步骤同理，但不同规格范围的相关度有所不同，但是 Si、Mn、Cr 三个元素始终是相关度比较大的三个变量。

	guide	C	Si	Mn	Cr	Rt0.5	Rm	A	ds	CVn
1	.00	1.43	2.31	2.00	3.33	4.42	4.23	2.50	3.56	5.57
2	.00	1.43	3.08	3.33	5.56	3.79	3.86	7.00	4.75	3.42
3	.00	1.43	3.08	4.67	2.96	.87	.12	6.00	3.22	5.06
4	.00	1.43	3.85	5.33	1.11	1.13	.72	6.00	6.44	5.04
5	.00	1.43	3.85	6.00	4.44	2.67	1.74	6.00	6.27	3.73
6	.00	2.86	.77	.67	2.96	3.83	4.85	6.50	1.19	4.37
7	.00	2.86	2.31	2.00	3.70	.97	.75	6.00	5.93	4.43
8	.00	2.86	2.31	2.67	4.44	3.50	3.86	6.50	.85	4.68
9	.00	2.86	3.08	1.33	1.85	4.42	3.73	7.00	5.93	4.43
10	.00	2.86	3.08	2.67	3.70	4.08	3.73	3.50	2.88	5.51
11	.00	2.86	3.08	2.00	3.33	5.24	4.23	2.00	4.41	3.73
12	.00	2.86	3.08	2.00	2.59	2.91	1.99	6.50	7.12	5.06
13	.00	2.86	3.08	2.00	2.22	1.26	.37	6.00	7.80	3.80
14	.00	2.86	3.85	2.67	2.59	6.50	6.22	4.00	2.37	5.19
15	.00	2.86	3.85	3.33	3.33	4.85	3.73	3.00	5.08	3.67
16	.00	2.86	3.85	6.67	3.33	5.34	4.36	6.67	3.50	5.51
17	.00	2.86	4.62	4.00	4.44	3.11	3.11	5.00	2.88	4.68
18	.00	2.86	4.62	2.00	2.96	2.82	3.36	7.50	4.58	4.75
19	.00	2.86	4.62	6.67	5.19	6.08	4.98	6.00	8.81	3.86
20	.00	2.86	4.62	5.33	3.33	1.26	1.59	6.00	3.39	4.94
21	.00	2.86	4.62	6.67	6.30	2.82	1.99	4.50	4.58	4.87
22	.00	2.86	4.62	8.00	5.93	1.97	1.16	5.83	5.65	4.79
23	.00	2.86	5.38	6.00	3.33	2.33	1.43	5.00	5.42	4.87
24	.00	2.86	6.15	6.67	4.07	2.28	1.37	5.50	4.41	6.84
25	.00	4.29	1.54	1.33	4.07	4.37	3.24	6.00	5.59	4.18

图 2.9 相关性分析的归一化样本数据

Fig.2.9 Normalized sample data of correlation analysis

表2.1 各因变量与Rt0.5相关性分析结果
Table2.1 lation analysis result between dependent variables and Rt0.5

		规格	C	Si	Mn	Cr	Rt0.5
规格	Pearson						
	Correlation	1	.029	.024	.034	.000	.128 (**)
	Sig. (2-tailed)	.	.483	.565	.400	.996	.002
	N	597	597	597	597	597	597
C	Pearson						
	Correlation	.029	1	-.040	-.097 (*)	.081 (*)	-.053
	Sig. (2-tailed)	.483	.	.332	.018	.048	.200
	N	597	597	597	597	597	597
Si	Pearson						
	Correlation	.024	-.040	1	.665 (**)	.225 (**)	.196 (**)
	Sig. (2-tailed)	.565	.332	.	.000	.000	.000
	N	597	597	597	597	597	597
Mn	Pearson						
	Correlation	.034	-.097 (*)	.665 (**)	1	.406 (**)	.330 (**)
	Sig. (2-tailed)	.400	.018	.000	.	.000	.000
	N	597	597	597	597	597	597
Cr	Pearson						
	Correlation	.000	.081 (*)	.225 (**)	.406 (**)	1	.168 (**)
	Sig. (2-tailed)	.996	.048	.000	.000	.	.000
	N	597	597	597	597	597	597
Rt0.5	Pearson						
	Correlation	.128 (**)	-.053	.196 (**)	.330 (**)	.168 (**)	1
	Sig. (2-tailed)	.002	.200	.000	.000	.000	.
	N	597	597	597	597	597	597

** Correlation is significant at the 0.01 level (2-tailed) .

* Correlation is significant at the 0.05 level (2-tailed) .

2.3.2 非线性相似度逼近算法建立

根据相关性的双尾显著性检验结果,可以确定某规格范围内某一性能与规格、C、Si、Mn、Cr 的相关系数: r1, r2, r3, r4 和 r5。并根据式 (2.8) 确定该规格范围内的因变量权重系数分别为

$$\begin{aligned}
 A1 &= r1 / (r1 + r2 + r3 + r4 + r5) \\
 A2 &= r2 / (r1 + r2 + r3 + r4 + r5) \\
 A3 &= r3 / (r1 + r2 + r3 + r4 + r5) \\
 A4 &= r4 / (r1 + r2 + r3 + r4 + r5) \\
 A5 &= r5 / (r1 + r2 + r3 + r4 + r5)
 \end{aligned} \tag{2.8}$$

由此，建立样本数据的相似度逼近函数， σ 的最小值表示与该待测数据因变量最接近的样本数据。

$$\begin{aligned}
 \sigma_{\min} &= \sqrt{A_1(X_{1\text{样本}} - X_1)^2 + A_2(X_{2\text{样本}} - X_2)^2 + \dots + A_n(X_{n\text{样本}} - X_n)^2} \\
 &= \sqrt{\sum_{i=1}^n A_i(X_{i\text{样本}} - X_i)^2}
 \end{aligned} \tag{2.9}$$

式中， A_i 为各输入变量的权重系数； $X_{i\text{样本}}$ 为样本数据的第 i 个输入变量； X_i 为待预测的第 i 个输入变量， n 为输入变量（影响因子）个数。注：此式中各输入变量须经过归一化处理。

采用该方法可以确定待测数据与样本数据库中因变量最接近的样本数据，从而获得较为可靠的经验值。由此确定了性能的预测值。

表 2.1 为 Rt0.5 的相关性的双尾显著性检验结果，由图可知 24~36mm 规格区间的 Rt0.5 与规格、C、Si、Mn、Cr 的相关系数依次为： $r1=0.128$ ， $r2=0.01$ （不显著，假设为显著因子的 10%）， $r3=0.196$ ， $r4=0.330$ ， $r5=0.168$ 。根据公式 2.6 可确定该规格范围内的因变量 Rt0.5 权重系数 $A1=0.184$ ， $A2=0.014$ ， $A3=0.282$ ， $A4=0.475$ 和 $A5=0.242$ 。

由此，根据式 (2.9) 建立样本数据中 Rt0.5 的相似度逼近函数，式 (2.10) 中 $Rt0.5_{\min}$ 表示与待测数据 Rt0.5 最接近的样本数据，从而确定 Rt0.5 的预测值

$$Rt0.5_{\min} = \sqrt{0.184(X_{1\text{样本}} - X_1)^2 + 0.014(X_{2\text{样本}} - X_2)^2 + 0.282(X_{3\text{样本}} - X_3)^2 + 0.475(X_{4\text{样本}} - X_4)^2 + 0.242(X_{5\text{样本}} - X_5)^2} \tag{2.10}$$

根据式 (2.10) 可以确定待测数据与样本数据库中 Rt0.5 最接近的样本数据，从而获得较为可靠的经验值。由此确定了 Rt0.5 的预测值。

表2.2 各因变量与CVn相关性分析结果
Table2.2 Correlation analysis result between dependent variables and CVn

		guige	C	Si	Mn	Cr	CVn
guige	Pearson						
	Correlation	1	.029	.024	.034	.000	.211 (**)
	Sig. (2-tailed)	.	.483	.565	.400	.996	.000
	N	597	597	597	597	597	597
C	Pearson						
	Correlation	.029	1	-.040	-.097 (*)	.081 (*)	-.016
	Sig. (2-tailed)	.483	.	.332	.018	.048	.704
	N	597	597	597	597	597	597
Si	Pearson						
	Correlation	.024	-.040	1	.665 (**)	.225 (**)	.116 (**)
	Sig. (2-tailed)	.565	.332	.	.000	.000	.004
	N	597	597	597	597	597	597
Mn	Pearson						
	Correlation	.034	-.097 (*)	.665 (**)	1	.406 (**)	.105 (**)
	Sig. (2-tailed)	.400	.018	.000	.	.000	.010
	N	597	597	597	597	597	597
Cr	Pearson						
	Correlation	.000	.081 (*)	.225 (**)	.406 (**)	1	.014
	Sig. (2-tailed)	.996	.048	.000	.000	.	.725
	N	597	597	597	597	597	597
CVn	Pearson						
	Correlation	.211	-.016	.116 (**)	.105 (**)	.014	1
	Sig. (2-tailed)	(**)	.000	.704	.004	.010	.725
	N	597	597	597	597	597	597

表 2.2 为夏比 V 型冲击功 CVn 的相关性的双尾显著性检验结果，由图可知 24~36mm 规格区间的 CVn 与规格、C、Si、Mn、Cr 的相关系数依次为：r1=0.211，r2=0.01（不显著，假设为显著因子的 10%）左右，r3=0.116，r4=0.105，r5=0.01

(不显著, 假设为显著因子的 10%)。根据公式 2.6 可确定该规格范围内的因变量 Rt0.5 权重系数 $A1=0.467$, $A2=0.02$, $A3=0.256$, $A4=0.232$ 和 $A5=0.02$ 。

由此, 根据公式 2.7 建立样本数据中 Rt0.5 的相似度逼近函数, 式 (2.11) 中 $CVn_{\min}$ 表示与待测数据 CVn 最接近的样本数据。

$$CVn_{\min} = \sqrt{0.467(X_{1\text{样本}} - X_1)^2 + 0.02(X_{2\text{样本}} - X_2)^2 + 0.256(X_{3\text{样本}} - X_3)^2 + 0.232(X_{4\text{样本}} - X_4)^2 + 0.02(X_{5\text{样本}} - X_5)^2} \quad (2.11)$$

根据式 (2.11) 可以确定待测数据与样本数据库中 CVn 最接近的样本数据, 从而获得较为可靠的经验值。由此确定了 CVn 的预测值。

同理, 抗拉强度、断后伸长率和断面收缩率的预测值也可采用同样的分析方法来确定。

后来, 又对该公式进行了如下修正完善:

采用公式 2.9 确定好相似度最接近的样本数据后, 在此基础上再进行非线性预测, 预测公式为

$$\sigma = \sigma_{\min} + A1 \times (X1_{\text{样本}} - X1) \times \alpha1 + A2 \times (X2_{\text{样本}} - X2) \times \alpha2 + \dots + An \times (Xn_{\text{样本}} - Xn) \times \alpha n \quad (2.12)$$

式中 $\alpha1, \dots, \alpha n$ 分别为单因变量的梯度 (函数导数, 函数可简化为线性函数)

改善后的算法大大提高了预测模型的计算稳定性和精度。为确保此合金结构钢性能预报系统预测的准确性和稳定性, 本性能预报系统采用人工神经网络和非线性相似度逼近算法相结合的方法来进行预测, 对于出现奇异数据的神经网络算法, 预报系统自动转入非线性相似度逼近算法。两种算法分别有各自的特点: 神经网络算法的优点是预测数据速度较快, 非线性映射好, 但缺点是泛化能力不稳定; 非线性相似度逼近算法避免了奇异数据出现, 但是计算量大, 预测速度较慢, 计算效率低。两种算法相辅相成, 相互配合。

2.4 本章小结

本章从人工神经网络模型出发, 对 BP 网络模型的 BP 算法、BP 改进算法和 LM 算法之间的优劣进行了比较, 最终选择采用 LM 算法作为神经网络模型的算法; 通过确定输入层与输出层变量、样本数据的采集和处理、隐层数目及隐层节点数的确定等三个方面建立神经网络模型; 同时针对非样本数据的奇异问题, 利用 SPSS 自主开发了非线性相似度逼近算法, 并根据两种算法的特点, 将这两种

算法结合使用，即只在非样本数据出现奇异数据时采用非线性相似度逼近算法，实现了预测效率和准确性的完美组合。

第3章 合金结构钢力学性能预报系统设计

3.1 编程语言选择

力学性能预报系统的可视化操作界面由功能强大的 VC++语言进行编写，但是后台计算的神经网络预测模型采用的是 Matlab 语言。

Matlab 是一种基于矩阵/数组的高级语言，它具有流程控制语句、函数、数据结构、输入输出，并且具有面向对象的程序设计特性。据文献统计，目前 Matlab 在学术界与工业界都是使用率极高的工具软件。而在 Matlab 环境下所开发出来的神经网络工具箱，以人工神经网络理论为基础，根据各种典型的修正网络权值的规则，加上网络训练过程，用 Matlab 编写出各种网络设计与训练的子程序，网络设计者则可根据自己需要去调用工具箱中有关神经网络的设计训练程序，使自己能够从繁琐的编程中解脱出来，从而提高效率和解题质量。

3.2 预报系统的结构和主要功能

预报系统的整体软件结构如下（见图 3.1 预报控制系统的主界面）：

- （1）预报系统的使用前提：使用该系统的前提条件的提示；
- （2）钢种信息的编辑区域：通过手工或 ERP 系统导入钢种的基本信息，本模块和工艺数据编辑区域是整个系统的基本数据来源；
- （3）工艺数据编辑区域：本模块系该钢种需做热处理性能时的热处理工艺条件；
- （4）计算方法选择区域：本模块是整个系统的核心，在这里可以选择最满意算法，并可进行自动修约；
- （5）单批次性能预测结果显示区域；
- （6）批处理预测区域：可根据三级系统导出的数据库文件进行性能预报的批量处理；
- （7）单批次预测历史记录区域：显示单批次预测过程的历史记录。




图 3.1 预报系统的操作界面示意图
Fig.3.1 Operation pane figure of prediction system

下面就图 3.1 上各区域的主要作用和操作办法一一具体介绍如下。

3.2.1 预报系统的使用前提

在系统操作界面的右下方用红色字体“清晰”显示本系统稳定使用的前提条件，指出在“铸坯低倍检验或轧制工艺异常时”，不建议使用该预报系统。

3.2.2 钢种信息的编辑区域




图 3.2 钢种信息编辑区域示意图
Fig.3.2 Figure of editing area of steel information

如图 3.2 所示，在该部分区域内主要是对被预测批次钢种的主要信息进行编辑，如钢种的选择，目前主要包含 40CrA、40CrMo、35CrMo 以及 20CrMo 等十个钢种。除此以外，例如钢种的规格、该批次钢的炉次号、轧制批次号以及钢种的主要成分都需要用户在预测前进行编辑。

同时模型为了方便用户使用，在成份编辑区域还增加了通过输入轧制批次号然后直接从三级数据库中进行查找并读入其他的相关信息的功能。如图 3.3 所示，在选择完钢种后，只需要输入轧制批号，然后点击“选择”按钮选择该批号所在的数据库文件（一般可直接从三级上下载下来）例如图中选择 123.xls 文件，再点击旁边的“确定”按钮模型则会自动在 123.xls 数据库种查找到该输入轧制批号的记录信息，并自动把该条记录的其他信息，例如成份规格炉批号等信息自动读入程序并显示出来。这样就避免了人工的查找以及手工的输入可能会带来的输入错误的发生，在保证了准确度的前提下提高了工作效率。




图 3.3 根据轧制批号直接数据读入示意图
Fig.3.3 Figure of direct loading data according to rolling lot number

在成份的编辑区域主要是采用了下拉菜单的形式，这样用户可以通过下来菜单进行成份数值的选择，同时它也具备了手动输入数值的功能，也就是说用户也可以直接通过手动的数值输入来进行数据的编辑。

3.2.3 工艺数据编辑区域

在钢种信息的编辑区域下方就是工艺数据的编辑区域（图 3.4），该部分主要是针对该批次钢进行的淬火和回火工艺的信息的显示，如淬火温度以及淬火时间等，该部分的操作与前面钢种信息编辑区域的“钢种选择”功能密切相关，这是因为在钢种选择到某一对应钢种时，其附带的相关信息例如该钢种的性能标准值以及相应的工艺参数都会自动的添加到程序中并读入界面中显示，其数据的修改可以由用户来完成，其数据文件是“setting.txt”，该文件位于该执行程序的当前文件夹下，其内容格式如图 3.5 所示。




图 3.4 工艺数据区域显示示意图
Fig.3.4 Figure of process data area

setting.txt - 记事本

文件(F) 编辑(E) 格式(O) 查看(V) 帮助(H)

5	屈服	抗拉	延伸	断面收缩	冲击	淬火温度	淬火时间	回火温度	回火时间
空白	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
40CrA	785.0	980.0	9.0	45.0	47.0	850.0	30.0	525.0	30.0
40CrMo	785.0	980.0	9.0	45.0	47.0	850.0	30.0	525.0	30.0
35CrMo	785.0	980.0	9.0	45.0	47.0	850.0	30.0	525.0	30.0
20CrMo	785.0	980.0	9.0	45.0	47.0	850.0	30.0	525.0	30.0

图 3.5 setting 文件内容格式示意图
Fig. 3.5 Figure of format for file “setting”

从图中可以看到，对应每一个钢种其相应的性能标准值以及工艺参数都可以直接从该文本中进行编辑，在对钢种进行选择的时候程序会自动读入其相应的性能标准值以及工艺参数并显示到“工艺数据”编辑区域以及“性能预测结果”显示区域。

3.2.4 计算方法选择区域

该区域主要的功能就是对预测计算方法的选择（见图 3.6），目前模型提供的计算方法有非线性相似度逼近和神经网络两种算法。选择“非线性相似度”代表的是优先选择神经网络，对于奇异数据进行非线性相似度算法切换，也就是说该选择为组合算法。选择“神经网络算法”，则代表只使用神经网络算法。目前在线使用的是“非线性相似度”的组合算法，也是系统默认算法。两种计算方法的转换可直接在界面上通过其前面的选择框直接点选即可。

到此为止，单次预测的全部输入参数都已经确定完毕，这样就可以直接点击该区域内的“确定”按钮，模型就会自动开始计算。计算完毕后，系统会自动将

计算结果显示到单批次钢的全部信息的记录和显示区域，同时会将该批次的全部信息以及预测结果都写入到系统自动生成的名字为“outputresult.xls”文件中，该文件固定用来对单次性能预测的结果记录和保存。




图 3.6 计算方法选择区域示意图

Fig.3.6 Figure of selecting area of computing methods

3.2.5 单批次性能预测显示区域

单批次的预测计算结束后接下来就是性能预测结果的显示区域（图 3.7），在该区域内主要有三部分，第一行以及第二行是对两套五种性能的预测结果显示，第三行就是判断性能合不合格的标准值，如果预测结果小于该标准值就判定该性能不合格，只要有一种性能不合格，该批次钢种就属于不合格批次。此外，为了方便用户对标准的维护，在该系统执行文件的当前文件夹下有一个名为“setting.txt”文档文件，用户可以通过编辑该文本文档得到对应钢种所需的标准值，然后在选择到对应的钢种时，系统会自动读取该标准值并显示到其标准值编辑框内。

性能预测结果					
结果一： 屈服 (MPa):	942.69	抗拉 (MPa):	1055.38	延伸 (%):	15.77
结果二： 屈服 (MPa):	952.31	抗拉 (MPa):	1060.77	延伸 (%):	15.50
标准值： 屈服 (MPa):	785.0	抗拉 (MPa):	980.0	延伸 (%):	9.0
				断面收缩 (%):	51.77
				断面收缩 (%):	51.35
				冲击 (AIO):	50.62
				冲击 (AIO):	56.45
				冲击 (AIO):	47.0

图 3.7 性能预测结果显示区域示意图

Fig.3.7 Figure of displaying area of mechanical prediction result

3.2.6 批处理预测区域

系统不仅支持单批次预报，还具有批量预报功能。从 ERP 系统下载的原始物料信息可直接导入进预报系统，可自动进行批量连续预报计算，不仅提高程序效率，还避免手动输入有可能带来的输入误差，提高了现场自动化程度，实现数据落地。

在该模块中，用户只需提供原始的数据输入数据库，其内容需要包含预测计

算所需的钢种、成份、规格等数据，同时该数据库的文件格式为 EXCEL 表格形式（见图 3.8），该表格可直接从三级上下载下来。选择完原始数据库后，直接点击其旁边的“开始预测”按钮，这时模型会自动弹出一个对话框，需要输入用户要保存的文件名字，然后模型就会自动进行数据读入和处理，并把结果文件写入自己定义的保存文件中。



图 3.8 批处理预测界面示意图
Fig.3.8 Figure of batch prediction

3.2.7 单批次预测历史记录区域

对于每进行一次单批次性能预报，该系统都会留下其历史记录，包括钢种、规格、成份及热处理工艺等内容（见图 3.9）。

序号	钢种	规格 [mm]	炉次号	轧制批次号	C [%]	Si [%]	Mn [%]	P [%]	S [%]	Cr [%]	Cu [%]	Mo [%]	Ni [%]	淬火温度 [度]	淬火时间 [Min]	正火温度 [度]
01	40CrA	Φ55			0.40	0.25	0.63	0.009	0.006	0.85	0.01	0.001	0.01	850.0	30.0	520.0
02	40CrA	Φ56			0.40	0.25	0.63	0.009	0.006	0.85	0.01	0.001	0.01	850.0	30.0	520.0
03	40CrA	Φ22			0.40	0.25	0.63	0.009	0.006	0.85	0.01	0.001	0.01	850.0	30.0	520.0
04	40CrA	Φ22			0.40	0.25	0.63	0.009	0.006	0.85	0.01	0.001	0.01	850.0	30.0	520.0

图 3.9 单批次预测历史记录区域示意图
Fig.3.9 Figure of historical record of single prediction

3.3 成分预警功能

预报系统还具有成分和热处理工艺预警功能（见图 3.10），当从 ERP 下载下来的物料信息出现混炉或原始信息录入错误等情况导致的成分超出该钢种成分范围时，系统会有相应“成分超标警报”信息弹出，提醒检验人员进行数据审查，且不进行预报计算。对于生产符合操作要点要求，热处理工艺要求不变，且规格、成分相同的合金结构钢，预报系统的使用不仅提高了力学性能指标的稳定性，避免了由于热处理水温变化、操作人员变化等引起的性能波动，而且通过对比抽检性能，也可以警示工艺上的可能变化，益于管理和督导。




图 3.10 成分预警信息示意图

Fig.3.10 Figure of composition pre-warning information

3.4 数据“不落地”的自动化功能

前期开发完成的预报模型投入现场使用后，得到了现场认同，同时他们在使用过程中也提出了更高、更合理的功能要需求，使得预报系统功能越来越完善，实用性和人性化更强，满足更多现场的实际需求。尤其是实现了对性能预测数据与 ERP 系统的自动采集和传输，实现了数据的自动修约和电子报表的自动生成，实现了数据“不落地”，可由预报电子报表替代机械性能试验台账，大大降低了人工手写劳动强度，减少人为误差，显著提升了质检总站的自动化程度和管理水平（见图 3.11）




图 3.11 电子台账示意图

Fig.3.11 Figure of electronic document

3.4.1 数据自动修约功能

现场在实际的操作过程中, 需要根据国标对生产检验出来的结果进行数值修约, 其修约的标准是 GB/T 8170-2008。预报模型使用前, 其修约必须通过人工去判断进行相应的数值修约, 不仅人力劳动强度大, 而且也容易出现错误。所以现场希望性能预报模型能具备自动修约功能, 为此根据国标中的修约规则开发了自动修约功能。表 3.1 为自动修约的修约规则和举例, 自动修约功能的复选框见图 3.6 所示。

表 3.1 自动修约规则及示例
Table3.1 Rules and examples of automatic of value rounding

类别	强度值范围	修约间隔	强度值尾数范围	修约	举例
Rel、Rm	≤200MPa	1	小数点后四舍六入，五视单双，奇进偶不进		
	>200~1000MPa	5	0~2.5（含）	舍，修约成 0	932.5→930； 931.1→930
			2.5~7.5（不含）	修约成 5	936.5→935； 937.4→935
			7.5~9.9	进一，修约成 0	927.5→930； 938.1→940
	>1000MPa	10	四舍六入，五视单双，奇进偶不进		1004.1→1000； 1005.0→1000； 1015.0→1020； 1015.2→1020
A、Z	—	0.50%	0~2.5（含）	舍，修约成 0	25.25→25.0； 25.12→25.0
			2.5~7.5（不含）	修约成 5	25.30→25.5； 25.74→25.5
			7.5~9.9	进一，修约成 0	24.75→25.0； 25.83→26.0
KU（V）	≥10J	1	四舍五入		

3.4.2 电子报表生成功能

在没有使用预报模型前，现场对出来的最终检测数据是采用手动填入报表和出结果报告单的，为此也造成了巨大的人力和物力浪费，也经常出现人工输入错误。应现场工作人员的要求，单独开发了用于自动生成报表的应用程序，专门用来处理预报模型生成的预报结果。图 3.12 为自动生成的电子报表功能的界面示意图。




图 3.12 自动生成报表功能界面示意图
Fig.3.12 Figure of automatic report creating

使用过程中只需要将预报计算的结果文件选择上，再点击按钮“确定”即可，应用起来非常方便，原试验报告见图 3.13，生成的试验报告格式图例见图 3.14。




图 3.13 原试验报告

Fig.3.13 Original testing report




图 3.14 自动生成的力学性能报表示意图

Fig.3.14 Figure of mechanical properties report after automatic creating

3.4.3 预报系统与 ERP 的信息下载和上传

为了便于用户使用，并实现“数据不落地”要求，性能预报系统的信息导入格式与 ERP 系统下载格式一致，保证了 ERP 下载文件信息可直接导入到预报系统中进行计算处理。同时，预报系统的计算结果文件格式也按照 ERP 系统文件上传格式形式进行设计，实现了预报结果的自动导入。（见图 3.15）




图 3.15 预报数据与 ERP 系统数据共享

Fig3.15 Data sharing between predicting data and ERP system

3.5 系统的程序设计

在模型的程序设计上,主要的关键点在于 VC 平台与 MATALAB 软件的接口程序以及核心算法的程序编写上。

3.5.1 VC 编程语言与 MATLAB 软件的数据接口

由于界面设计上是利用 VC++6.0 的开发平台,但性能预报的核心算法是利用 MATALAB 软件中的神经网络工具函数进行编写和计算的,这就涉及到一个很关键的问题,即在 VC 界面上如何去调用 MATALAB 的计算函数。MATLAB 作为一个强大的计算软件,在相继推出 6.x 版本后,它与其他软件的兼容性得到了很大的提升,它不仅可以在其他的程序设计语言中调用 MATLAB 同时也还可以在 MATLAB 中调用其他的程序设计语言编写的函数或子程序。而现在需要的就是在别的软件中去调用其 MATLAB 的计算函数。为达到这一目的,就需要在 VC 中进行一些系统环境的设置以及在 MATLAB 中进行特殊的编译使之能被 VC 所调用。

(1) 在 VC++中调用 MATLAB 引擎时的环境设置

需要在 VC++中调用 MATLAB 的引擎时,需要进行的环境设置有:

(a) 在 VC 工程的头文件处添加 MATLAB 编译出来的.h 文件,其包含了启动 MATLAB 调用和关闭的函数声明。

(b) 单击【tool】菜单下的【option】选项,在弹出的【option】对话框中选择【directories】选项。在【directories】选项中的【conditionals】选项里的【include path】中加入目录路径<MATLAB>\extern\include,该路径包含了 MATLAB.h 等有用的头文件。

在【library Path】中,加入<MATLAB>\bin 和<MATLAB>\extern\lib.这两个目录路径包含了可外部调用的 DLL 和 LIB 文件。

(c) 单击【project】菜单下的【setting】,在【link】菜单下 category 为【general】下的 object/library modules 项下添加由 Matlab 编译出来的.lib 文件,如果有多个,则都需要添加进去。

(d) 在 VC 工程的.CPP 下添加由 MATLAB 编译出来的.h 文件,用 #include 的格式。

(2) MATLAB 中的特殊编译

该部分中主要进行的工作是将.M 文件利用 MATLAB 汇编成 C 语言或 C++ 语言，以供 VC 使用，由于 C 语言为最基本的语言，所以一般将其汇编成 C 语言，这样编出来的程序兼容性较强。其编译工具为 MATLAB 的 mcc 工具，其具体命令如下：

Mcc -W lib:liba -T link:lib yourname

例如，在 MATLAB 中,.M 文件的名字为 yuce.m,要生成的 lib 库的名字为 liba,则命令则为：

Mcc-W lib:liba -T link:lib yuce

在 MATLAB 环境下编译该命令后，后台会自动生成一系列文件，其中有用的为.lib,h,.dll,ctf 这四个文件，将该四个文件拷贝出来，将其放置在 VC 工程的文件夹下即可。

3.5.2 核心算法的编程

在这部分中除了纯粹的编程语言的编写外，其所涉及到的核心算法有两个，一个就是利用神经网络工具箱的函数直接在 MATLAB 中编译生成函数，另外一个就是基于其样本数据库范围内非线性相似度逼近算法，后面的优化算法弥补了神经网络算法中由于偏离样本数据库产生的数据波动过大产生奇异数据的缺陷，进一步提高了预测的计算精度和稳定性。在程序设计中主要涉及到的函数有：

(1) 神经网络计算函数：YUCEJISUAN2 () (见图 3.16)



图 3.16 神经网络计算函数
Fig.3.16 Calculating function of neutral networks

(2) 非线性相似度逼近算法函数：CHAZHIDEAL () (见图 3.17)




图 3.17 非线性相似度逼近算法函数

Fig.3.17 Calculating function of non-linear approximation similarity calculation method

(3) 单次预测结果输出函数：writresulttxt () (见图 3.18)




图 3.18 单次预测结果输出函数

Fig.3.18 Output function of single prediction

(4) 批量预测函数：readexcel () 与 writbatchtxt ()

其中 readexcel () 函数是用来读取批次预测的原始数据 (见图 3.19), writbatchtxt () 函数则是用于将结果文件写入用户指定文件名的文件中 (见图 3.20)。




图 3.19 批量预测的输入函数
Fig.3.19 Input function of batch prediction




图 3.20 批量预测计算函数
Fig.3.20 Calculating function of batch prediction

(5) 自动修约功能函数

通过自动修约函数可以直接在程序中将预测出来的结果进行修约，并通过操作界面上是否进行自动修约的选择功能确定输出的结果是经过修约还是不经过修约。（见图 3.21）




图 3.21 自动修约功能函数
Fig.3.21 Function of automatic value rounding

(6) 电子报表自动生成功能函数（见图 3.22）




图 3.22 自动报表生成功能函数
Fig.3.22 Function of automatic report creating

3.6 本章小结

本章通过采用 MATLAB 语言和 VC++ 语言开发了合金结构钢力学性能预报系统，开发了首钢合金钢性能预报系统，并将系统主界面分成七大区域，实现了单批次/批处理预测、成分预警、数据自动修约和电子报表输出等主要功能，实现了性能预报系统与 ERP 之间“数据不落地”的信息传递。

第4章 预报系统的应用和偏差分析

本预报系统于2009年12月开始在精品棒材车间的试验室进行了实际应用,在不影响正常生产检验的情况下,采用了一种过渡的工作原则,经过一段时间的预报分析,效果显著。

由于预报系统的预测算法以神经网络为主,因此,神经网络预测模型的泛化能力就直接影响预报系统精度。网络泛化能力也称网络推广能力,指的是网络模型对未参加样本训练的数据的计算稳定性。如果一个模型仅对样本数据有较好的输入输出映射关系,而泛化能力不强,这样的网络模型没有应用价值。因此,网络泛化能力是衡量网络模型性能的重要指标,主要受样本数据和隐层节点数的影响。

4.1 试验室条件的完善

为了确保性能预报系统能够在精品棒材试验室得以采用,拓展实验室网络数据采集功能,对精棒实验室的数据网络开发完善,对精棒实验室的3台拉力试验机、2台冲击试验机进行了改造,同时还对拉力试验机的系统数据采集软件PowerTest进行了升级,对冲击试验机进行硬件改造并增加微机及试验软件对试验机进行控制,增加一台SQL数据服务器,配合《数据采集管理软件》用来存放拉力、冲击试验机实验数据。由此,实现对试验室终端试验软件升级,实现性能预测系统和ERP系统之间自动采集和传输数据,实现理化检验数据网络化管理和资源共享。

4.2 力学性能预报检验工作原则

(1) 性能预报系统本次研究适用的钢种范围:40CrA、35CrMoA、20CrA、20CrMoA、30CrMoA、42CrMoA。

(2) 在炼钢和轧钢工艺精细化控制的基础上,检验工作采用模型预报检验及实物抽查检验操作相结合模式,逐步过度,并最终采用模型预报方式进行产品力学性能检验以替代生产实物取样检验数据,为用户提供产品的热处理力学性能指

标。

(3) 性能预报技术指标：经热处理后的力学性能（屈服强度、抗拉强度、伸长率、面缩率、冲击功）指标。

(4) 预报产品做到定期抽验，其实物抽验按轧制组距周期对预报牌号进行抽验，抽验频次（批次）要求（见表 4.1）。

表 4.1 实物抽验频次 Table4.1 Frequency of inspection of real sample		
序号	组距 Φ ，mm	抽测频次（批次），不少于
1	14 ~ 30	1
2	> 30 ~ 40	1
3	> 40~ 60	2
4	> 60~ 80	2

(5) 取样要求：

40CrA 取样要求：

实物检验批次：每个轧制批次各取 2 根，每根试样长度 600mm 做常规性能检验；预报检验批次：每个轧制批次各取 2 根，每根试样长度 200mm（见图 4.1）。力学性能做预报检验（其余项目做实物检验）。




图 4.1. 截取对比试样
Fig.4.1 Test species for comparison

35CrMoA、20CrA、20CrMoA、30CrMoA、42CrMoA 钢种取样要求：

实物检验批次：每个轧制批次各取 2 根，每根试样长度 600mm 做常规性能检验，预报检验批次：每个轧制批次取 2 根，每根试样长度 250 mm，力学性能做预报检验。如有特殊情况执行临时通知。

(6) 在该项目实施过程中发现有不符合标准数值时，精棒检查站及时通知高线厂补充该炉次取样，进行实物检验。

(7) 在实行性能预报工作期间，生产厂发生重大工艺异常情况及进行产品成分调整试验时，通知质量监督总站，恢复正常取样进行实物检验。

(8) 逐步提高同牌号产品批次性能预报率指标：

同牌号产品批次性能预报率，一般实施三个月以后逐步达到 $\geq 90\%$ 。对产品的取样抽测频次，要从按大组距或按周进行取样抽测，尽快实现批次性能预报率目标要求。

4.3 力学性能预报流程

4.3.1 常规力学性能生产检验流程

常规的精棒试验室力学性能生产检验流程是：

钢材现场取样（600mm X2 根）→加工毛坯试样（1-1.5 小时，拉力、冲击、低倍、顶段）→热处理（淬火+高温回火）、顶段（2.5-3 小时）→精加工分别制成拉伸试样和冲击试样（1-1.5 小时）→进行拉伸、冲击试验→报出试验数据（1-2 小时），钢材生产检验周期约 8 小时。（见图 4.2）




图 4.2 拉伸、冲击试样图
Fig.4.2 Test species for tensile testing and impact testing

4.3.2 力学性能预报系统流程

应用力学性能预报检验方法：

钢材现场取样（200-250mm X2 根）→机加工制样（0.5-1 小时，低倍、顶段）；ERP 数据采集→三级导出所预报炉批化学成分数据（见图 4.3）、钢材规格、热处理工艺等项参数（见图 3.4）→进入预报模型计算（→分别报出相关力学性能预报数据（0.5-1 小时）（见图 3.13），性能预报系统的钢材生产检验周期约 1.5 小时。

熔炼号	凭证号	轧制批号	长材物料编码	长材物料描述	钢种	规格	根数	钢坯重量	尺寸精度	定尺长度	岗位生产时间	钢坯垛位号	C	Si	Mn	P
0C02815	24	X005D40190	30001597	棒材 40CrA-Φ55-DC-BZ	40CrA	Φ55 28-28	70.028	G3	6	B9	.38	.23	.62	.011		
0C02815	24	X005D40191	30001597	棒材 40CrA-Φ55-DC-BZ	40CrA	Φ55 28-28	70.028	G3	6	B9	.38	.23	.62	.011		
0C02815	24	X005D40192	30001597	棒材 40CrA-Φ55-DC-BZ	40CrA	Φ55 18-18	45.018	G3	6	B9	.38	.23	.62	.011		
0A02369	24	X005D40193	30001597	棒材 40CrA-Φ55-DC-BZ	40CrA	Φ55 18-18	45.018	G3	6	B9	.41	.25	.65	.008		
0C02816	24	X005D40194	30001597	棒材 40CrA-Φ55-DC-BZ	40CrA	Φ55 28-28	70.028	G3	6	A4	.41	.23	.66	.012		

图 4.3 三级系统导出的化学成分

Fig.4.3 Composition outputting from three-level system of ERP system

4.3.3 应用期间预报偏差

本预报系统于 2009 年 12 月开始在精品棒材试验室进行试运行，针对以 40CrA 为代表的 5 个牌号的产品进行性能预报，其中 40CrA 的预报相对偏差见表 4.2。

表 4.2 钢种预报相对实例							
Table4.2 Example of relative deviation for steel prediction							
40CrA（批）	12 月 (41)	1 月 (34)	2 月 (30)	3 月 (13)	4 月 (2)	合计 (120)	相对偏差
屈服强度%	2.05	5.87	2.77	7.67	1.03	19.39	2.85
抗拉强度%	1.14	4.15	3.19	5.03	0	13.51	2.04
延伸率%	1.58	5.25	4.13	4.33	1	16.29	2.71
收缩率%	1.5	2.98	3.72	2.69	4.32	15.21	2.20
冲击功%	1.37	3.64	3.98	7.99	9.68	26.66	2.52

本预报系统目标值是：在冶炼、轧制过程稳定前提下，预报精度达到命中率≥90%；检测性能预报偏差：屈服强度≤±3%，抗拉强度≤±3%，延伸率≤±3%；收缩率≤±3%，冲击功≤±5%。因此表明在 2009 年 12 月-2010 年 4 月期间，该钢种力学性能预报达到了预期效果。

从下一节起，本论文将详细分析预报偏差产生的原因。

4.4 样本数据对预报系统的偏差影响

网络模型接受的知识训练越全面,它的泛化能力也就越强,预报精度越高。如果一个网络模型在训练中只进行了一种材料样本数据的非线性拟合,却要求它对超越拟合范围的数据进行计算,显然是不合理的。因此,网络模型的泛化能力在一定程度上也取决于样本数据是否充足,就要求样本数据涵盖的范围要广。但同时庞大的数据库会增加网络模型结构的复杂性(如隐层节点的增加),降低网络计算效率和收敛精度,从而变相地降低了网络泛化能力。因此,合理的样本数据库要兼顾“全”而“少”的原则,在保证数据类型全面的同时尽量减少数据量。合理的样本数据库不仅可以节约资源,还能提高网络学习效率。所以在本性能预报模型中,将各钢种的样本数据分别进行训练,在每个钢种的样本数据库中,尽量搜集足够多的样本数据,保证样本数据充足,但同时为了避免网络模型结构过于复杂,将每个钢种都按规格进行分组,每组单独进行训练。

为了提高样本数据的涵盖范围,需要每月定期对样本数据库进行更新和学习训练,不断提高样本知识量。

4.5 隐层节点数对泛化能力的影响

网络的拓扑结构直接影响网络对未训练数据计算结果的稳定性。隐层节点太少,网络不易收敛,太多的隐层节点数又会导致网络中待定参数过多,使网络稳定性变差,降低泛化能力。但对同一网络模型来说(如隐层节点数确定),网络收敛精度越高,泛化能力也就越强,因为一个网络模型对参加训练的样本数据的误差都很大,更谈不上对非样本数据的计算。但如果仅为加速网络收敛速度和精度而大量增加隐层节点数,将付出降低网络泛化能力的代价。因此,隐层节点数的确定问题关系着网络模型的性能优劣,但如何确定能兼顾精度和泛化能力的最佳的隐层节点数,至今没有明确定论,但如公式(2.5)、(2.6)的一些经验公式可以参考借鉴。

在本模型隐层节点数的选取过程中,首先利用公式(2.5)、(2.6)给出的经验进行计算,由五组样本数据分别求得其各自隐层单元节点数,求得的隐层节点数分别为:14mm: 20个、16~22mm: 159个、24~36mm: 200个、38~55mm: 252个、60~80mm: 210个。

用没有经过训练的非样本数据进行网络泛化能力测试后，发现其预测结果非常不稳定，力学性能值会偏差很大，有的甚至出现负数或上万的数。60%以上的奇异数据出现使得预报系统无法实现生产应用。

经过深入分析，在现有隐层节点数的基础上，进一步减小隐层节点数，同时降低训练网络的迭代误差，即不收敛，但模型的网络泛化能力却有显著提高。仍以规格为 16~22mm 为例，将隐层节点数由最初的 159 减小至 118 个，则预测结果会逐渐接近合理值，进入合理范围之内，但样本数据本身的预测精度并没有明显降低，样本数据训练的平方和误差达到 10，训练收敛曲线见图 4.4。通过反复试算，不断修改网络调节系数 α ，最终在牺牲样本数据训练精度和减小隐层单元节点数之间逐渐取得平衡，同时建立了确定隐层单元节点数的经验公式 (2.7)。修正隐层节点数后，各规格隐层节点数分别为：14、118、150、180、145。




图 4.4 修正隐层节点数后的收敛曲线

Fig.4.4 Convergence curve after amendment of hidden layer node numbers

4.6 网络模型泛化能力测试

以 40CrA 钢为例，用 09 年 11 月的 40CrA 现场检验数据（非样本数据）对本性能预报模型进行泛化能力测试。由于每个批次都出两份检验结果，所以预报模型也相应给出两份性能预测值。11 月份检测的有效数据共 79 个批次（冲击 74 批），将每批同一力学性能的两个实测值和两个预测值分别取平均值。采用性能预报模型的多批次处理功能，将此 79 个批次进行泛化测试，得到人工神经网络模型的泛化测试结果，见图 4.5。




图 4.5 网络模型的泛化测试结果


Fig4.5 Networks generalization testing result of networks model

从图 4.5 可以看出，79 批测试数据的性能预测值与实际检验值的偏差较小，且稳定性较好。各力学性能的平均预报偏差为：屈服强度（ReL），1.73%；抗拉强度（Rm），0.93%；延伸率（A），0.55%；断面收缩率（Z），0.71%；冲击吸收功为（Ak），1.30%。由此证明本模型的网络泛化能力很强，可以用来进行相应钢种的力学性能预测。

4.7 预报系统偏差统计

4.7.1 检验数据的预报偏差分析

自以 40CrA 钢为代表的合金结构钢性能预报模型在线试运行以来，每月都对该预报模型的试运行钢种进行预报精度分析，对该月的预报值与检测值进行预报精度统计。以 40CrA 钢为例，将 09 年 11 月~10 年 3 月的所有 40CrA 抽测批次进行预测，并将预测值与检测值进行比较。采用网络预测精度评估方法，求得 40CrA 上线试运行以来的网络预测精度。图 4.6 为五项力学性能预报偏差散点；图 4.7 为五项力学性能预测值与检验值的比较。五项力学性能平均相对偏差分别为：屈服强度 2.85%、抗拉强度 2.04%、断后伸长率 2.71%、断面收缩率 2.20%、冲击功 2.52%。通过对 2009 年 11 月~2010 年 3 月份 40CrA 生产检验数据对模型预测精度的验证，表明以 40CrA 为代表的合金结构钢性能预报模型能够可靠、准确的进行性能预测，预测精度较高，各项力学性能预测精度均已达到项目预期的目标要求（相对偏差平均值在 3% 以内），在冶炼、轧制工艺过程稳定前提下，至今预报命中率 100%。






图4.6 五项力学性能预报偏差散点
Fig4.6 Splattering distribution curve of five mechanical properties prediction




图 4.7 五项力学性能预测值与检验值的比较

Fig4.7 Comparison between predicting value and testing value of five mechanical properties

4.7.2 偏差产生原因分析

纵观 09 年 11 月~10 年 3 月的所有检测数据，发现偏差产生的原因主要存在于以下两方面：

（1）因为数据库里没有相关成分信息（新成分），新成分预测会产生一定波动：而数据库中已有的成分、工艺具有学习记忆性，对于新成分数据来说，根据模型记忆按内在的算法规律进行推论，总会与实际检验值存在一定的偏差。但总体来讲，数据库成分工艺涵盖的越广、越全面，预测稳定性也越好。但是做为数据库完善和日后稳定性应用，新成分的出现会使模型更加完善。经过数据库的不断补充、更新，由此原因产生的偏差问题可以逐步得到解决。

（2）人为、工艺、设备等隐性变化带来的实际检测数据波动。

如表 4.3 所示，炉号为 9C06457、轧制批号为 X910D40647 的检测数据：两次测试的屈服强度差为 40MPa，抗拉强度差为 10MPa；而两次计算获得的屈服强度差为 70Mpa，抗拉强度差为 30MPa。通过比较可知，其计算值比实测值的波动大。但是查看数据库中的原始检测数据，发现相同成分（同一炉号：9C06457）、不同轧制批次的检测数据，存在较大差别，见表 4.4。

表4.3 力学性能的检验值和预测值比较
Table4.2 Comparison between testing value and predicting value

日期	批号	规	C	Si	Mn	Cr	屈服	抗拉	屈服	抗拉	屈服	抗拉差
		格					1	1	2	2	差	
检验值	2009.11.16						1080	1150	1040	1140	40	10
		D40647	20	0.39	0.24	0.64	0.88					
预测值							1010	1120	1080	1150	70	30

表4.4 相同成分和规格、不同批次的力学性能检测值比较
Table4.3 Comparison of testing value for product of different lots, same composition and same size

日期	批号	规格	C	Si	Mn	Cr	屈服	抗拉	屈服	抗拉	屈服	抗拉	
							1	1	2	2	差	差	
检测值	2009.10.24	D40647	20	0.39	0.24	0.64	0.88	1080	1150	1040	1140	105	60
检测值	2009.10.27	D40648						975	1090	1010	1120		

X910D40647 和 X910D40648 这两个批次来自于同一炉号 9C06457, 故成分相同, 热处理工艺也相同, 但从表 4.4 可知: 强度性能却差异较大, 屈服强度最大偏差为 105MPa, 抗拉强度最大偏差为 60Mpa。同样的问题也出现在表 4.5 所示的批次中, 如轧制批号为 X912D30040、X912D30041 和 X912D30042 三个轧制批次, 其屈服强度检验值最大差为 175 MPa, 其抗拉强度检验值最大差为 90 MPa; 轧制批号为 X912D20037、X912D20038 和 X912D20039 三个轧制批次, 其屈服强度检验值最大差为 160MPa, 其抗拉强度检验值最大差为 170MPa。而预报系统的预测函数是基于样本数据基础上的学习经验, 对于这类多批次出现的实际检验数据波动范围大的问题, 样本数据库根据概率准则进行相应处理。

表 4.5 相同成分、不同批次的力学性能检测值比较
Table4.4 Comparison of testing value for product of different lots and same composition

序号	炉号	批号	规格	C	Si	Mn	Cr	屈服1	抗拉1	屈服2	抗拉2	屈服差	抗拉差
1	9C07472	D30040	70	0.41	0.26	0.65	0.89	935	1130	1070	1180	175	90
		D30041						1070	1170	1100	1210		
		D30042						1110	1220	1060	1160		
2	9C07474	D20037	70	0.43	0.23	0.62	0.87	880	1090	995	1170	160	170
		D20038						910	1110	995	1180		
		D20039						835	1010	890	1090		

以上情况表明, 此类计算偏差波动完全是由于多批次实际检测数据波动范围大引起的, 经调研可能是由于工艺、人员调整、现场设备维修或更换配件等“隐性”波动原因引起的。但是在成分不变的情况下, 由于没有相应的过程数据采集系统, 这些隐性变化很难获知, 实际检验带来的性能波动也在所难免。采用力学性能预报系统之后, 根据以往多年历史数据经验, 预测最大概率的性能值作为其性能稳定值可以减弱这些人员、工艺、设备等隐性变化带来的性能偏差。

4.8 本章小结

本章汇报了预报系统的在线使用情况及其结果偏差的分析。从流程看, 本预报系统已明显优于常规生产检验流程; 通过网络模型泛化能力测试验证了本模型的网络泛化能力很强, 可以用于相应钢种的性能预测, 通过预测系统的偏差分析验证了本系统在冶炼、轧制工艺过程稳定前提下对性能的预报精度已经达到了预

期的目标要求，并对偏差产生的两个原因进行了分析，提出了减小偏差的措施。

第5章 结论与展望

武汉钢铁（集团）公司和宝山钢铁股份有限公司先后试用过西门子的 BM-MM，但都没有取得预想中的实际效益，迁钢 2160 西门子的性能预报系统也一直未投入使用。几乎所有报道都是只谈模型精度，而没有提到应用效果以及是否产生了效益，这说明性能预报技术要想实用化还有很大难度。人工神经网络模型适合研究复杂的非线性系统特性，对于先进的钢材轧制生产线，可实现在线的控制轧制。但是，运用人工智能技术进行预报和控制需要建立精确的数据采集系统和庞大的数据库，这对于我国大多数钢铁企业来说难以实现，这也正是制约人工智能技术在轧钢生产中广泛应用的症结所在。

2009 年 5 月，技术研究院与质监站合作，开始开发以 40CrA 钢为代表的合金结构钢力学性能预报模型，是对性能预报技术探索的一次有益尝试。根据合金结构钢热处理后的性能特点，分别确定了影响 40CrA、35CrMo 等钢的主要影响因子，将相关化学成分、规格和热处理工艺作为输入条件，强度、延伸、段缩、冲击等五个力学性能作为预测目标，采用 BP 前馈神经网络结构，成功开发了合金结构钢的性能预报系统，并实现了在线应用。课题取得的效果如下：

（1）检验周期缩短，工作效率提高：实现 40CrA、35CrMoA 等十个钢种的合金结构钢的在线快速分析检测和数据报出，提高力学性能的分析、检测速度，钢材生产检验周期由目前检验平均 8 小时缩减为平均 1.5 小时完成，有效提高检验人员工作效率 81%。

（2）降低成本，提高生产率和成材率：自合金结构钢力学性能预报系统上线以来，显著减少了试验室的检验量、加工量，也明显减少了现场的取样量，减轻工人劳动强度，节约水、电及机加工耗材，降低检验成本和生产费用。各使用钢种预报批次比例少则在 70%左右，多则在 80%以上，性能预报系统成为主要的力学性能分析手段。

（3）数据不落地的信息化技术开发，提升管理水平和效率：预报系统与 ERP 系统的数据下载和上传，避免人为误差，提高工作效率。电子报表自动生成功能和数据自动修约技术开发，进一步缩短了中间流程，减少人工数据误操作，提高了自动化程度和工作效率。

课题取得的创新点如下：

(1) 开发了可提高神经网络泛化能力的单隐层神经元节点数目的确定方法：影响 BP 神经网络技术稳定应用的是网络泛化能力，网络泛化能力低，则对于非样本数据出现奇异数据的概率就大。而影响网络泛化能力的主要因素就是隐层单元数目的确定。通过对隐层单元节点数、样本数据量、输入层变量数、输出层变量数、收敛精度等参数进行大量的计算和网络泛化数据测试分析，研究了较为稳定的隐层节点数量的确定方法，即：

$J * N = \alpha [M * (I + J) + M]$ ，式中， I 为输入节点数， J 为输出节点个数； N 为样本个数； M 为需要确定的隐层节点数， α 为网络调节系数（在 0.8~1.2 之间）。采用该方法，显著减少了奇异数据产生。

(2) 开发了数据的非线性相似度逼近方法：为稳定性能预报系统的在线应用，彻底避免因神经网络预测非样本数据而产生的奇异数据，开发了非线性相似度逼近方法，与神经网络方法结合，实现了性能预报系统的稳定应用。

$$\sigma_{\min} = \sqrt{\sum_{i=1}^n A_i (X_{i\text{样本}} - X_i)^2}$$
 式中， A_i 为各输入变量的权重系数； $X_{i\text{样本}}$ 为各输入变量的样本数据； X_i 为待预测的各输入变量数据。注：此式中各输入变量须经过归一化处理。

自 2009 年 12 月起至今，力学性能预报系统一直在线稳定应用，预报命中率 100%。预报钢种各项性能偏差均在 5% 以内。以 40CrA 钢为例，性能预报批次预报偏差均小于 3%，依次为：屈服强度 2.85%，抗拉强度 2.04%，延伸率 2.71%；收缩率 2.20%，冲击功 2.52%。

合金结构钢性能预报技术具有一定的可移植性和技术推广性，它的成功开发不仅将来可以推广服务于山西长治和贵州水钢的精棒生产线，也为板、带材的性能预报技术开发奠定一定的技术基础，同时利用性能预报系统采用的仿真技术，也可促进合金钢棒材品种钢的研发。

参考文献

1. 杨兆林, 潘国平, 闻玉胜等. 传统中板轧机产品力学性能预报及应用探讨[J], 安徽冶金, 2003, (3): 1~6.
2. 胡于华, 程晓茹, 戴宇杰. 基于人工神经网络的 CSP 热轧板带力学性能预报[J], 南方金属, 2007, (1): 17~19.
3. 李径, 孙洪刚, 赵宪明. 特殊钢轧制过程力学性能预报[J], 金属世界, 2006, (5): 17~19.
4. 周颖, 郑德玲, 王英. 基于人工免疫的 RBF 神经网络在钢筋性能预报中的应用[J], 北京科技大学学报, 2005, 27 (1): 123~125.
5. 王生朝, 程晓茹. BP 神经网络在热轧中厚板力学性能预测中的应用[J], 武汉科技大学学报 (自然科学版), 2004, 27 (1): 15~17.
6. 郑晖. 利用人工神经网络预测板带力学性能的软件开发[J], 塑性工程学报, 2003, 10 (5): 71~75.
7. 沙孝春, 兰勇军, 李殿中等. 带钢热轧组织性能预测与控制技术应用与发展[J], 轧钢, 2003, 20 (3): 23~26.
8. Hodgson P D, Gibbs R K. A mathematical model to Predict the mechanical Properties of Hot Rolled C-Mn and micro-alloyed steels. ISIJ International[J], 1992, 32 (12): 1329~1338.
9. Laasraoui A Jonas J J. Prediction of temperature distribution flow stress and micro-structure during the multi-pass hot rolling of steel plate and strip[J], ISIJ International, 1991, 31(1): 95~105.
10. 贺毓辛. 信息发掘及钢材性能发掘[J], 轧钢, 2001, (2): 6~8.
11. Luger A, Hubmer G. In-line control of the mechanical properties of hot rolled strip based on complete process model[C]//Proc. Conf. on Modeling of Metal Rolling Process-Through Process Model[M], London: ISIJ Int., 2001: 83~86.
12. 朱鹏举. 中厚板生产过程中组织性能的预报[J], 江苏冶金, 2006, 34 (5): 13~16.
13. 许云波, 刘相华, 王国栋. 热轧带钢组织一性能预测和控制模型及其应用前景[J], 钢铁研究学报, 2002 (1): 65~68.

14. T M Maccagno, J J Jones, P D Hodgson. Spreadsheet Modeling of Grain Size Evolution during Rod Rolling[J], ISIJ International, 1996, 36(6): 301~304.
15. 蔡丹, 赵嘉蓉. 高碳钢线材的控冷工艺初探[J], 钢铁研究, 2003 (3): 24~28.
16. 程先舟. 高线车间硬线产品组织性能研究进展[J], 武钢技术, 2005, 43 (1): 5~7.
17. 程先舟. 高碳钢线材组织性能的研究[J], 轧钢, 2005, 22 (4): 20~23.
18. 蔡丹, 赵嘉蓉. 82B 线材控冷工艺及性能模拟[J], 武汉科技大学学报 (自然科学版), 2003, 26 (1): 5~7.
19. 张云祥, 张海鸥, 王桂兰等. 高碳钢线材轧制组织和性能模型的应用[J], 特殊钢, 2006, 27 (4): 8~10.
20. 陈连生, 宋进英, 任吉堂等. 调制钢棒材组织性能预报软件的开发和应用[J], 钢铁研究学报, 2007, 19 (4): 95~106.
21. 郭朝晖, 张群亮, 苏异才等. 关于热轧带钢力学性能预报技术的思考[J], 冶金自动化, 2009, 33 (2): 1~6.
22. 闻玉胜, 潘国平, 杨兆林等. 传统中板轧机产品力学性能预报及应用探讨[J], 冶金标准化与质量, 2003, 41 (6): 16~19.
23. 干勇. 薄板坯连铸连轧 (TSCR) 热轧过程组织性能预报技术的开发[J], 钢铁, 2003, 38 (8): 10~15.
24. 刘正东, 董瀚, 干勇. 热连轧过程中组织性能预报系统的应用[J], 钢铁, 2001, 38 (2): 68~71.
25. 陈国良. 遗传算法及其应用[M], 北京: 人民邮电出版社, 1999, 1~8.
26. 戈玲, 吴新余. 优化反向传播神经网络的自适应遗传算法[J], 南京邮电学院学报, 1998, 18 (3): 1~8.
27. 周伟良, 何鲲, 曹先彬等. 基于一种免疫遗传算法的 BP 网络设计[J], 安徽大学学报, 1999, 23 (1): 63~66.
28. A. K. Srivastava, S. K. Srivastava, K. K. Shukla. Genetic Evolution of Neural Network Based on a New Three-Parents Crossover Operator[J], Proceedings of the IEEE International Conference on Industrial Technology, 2000, 2: 153~158.
29. 袁亚湘, 孙文瑜. 最优化理论与方法[M], 北京: 科学出版社, 1997, 373~403.
30. 张莹莹, 王劭伯. 基于 LM 的神经网络偏差补偿预测控制及其应用[J], 福州

大学学报（自然科学版），2001，29（1）：43～46.

31. 闻新. MATLAB 神经网络应用设计[M], 北京: 科学出版社, 2000, 35~47.
32. W.C.Carpenter, M.E. Hoffman. Selecting the Architecture of a Class of Back-propagation Neural networks used as Approximation[J], Artificial Intelligence for Engineering Design, Analysis and Manufacturing: AIEDAM, 1997, 11(1):33~44.
33. 姚华, 罗仁平, 陈军. 盒形件毛坯外形预测中 BP 网络结构的确定[J], 模具技术, 1999, 6: 26~29.

致 谢

在本论文完成之际，谨向我的导师关守平教授表示最衷心的感谢和最诚挚的敬意。

在攻读硕士的这段时间里，关老师给予了我悉心的指导、帮助和关怀，为我的学习和研究工作提供了良好的条件。从论文的选题开始、研究工作的开展到论文的最后完成，都倾注了关老师大量的心血。关老师严谨求实的治学态度，持之以恒的科研精神，耐心细致的工作作风以及给予我的培养指导都使我受益匪浅、永志难忘。

感谢信息科学与工程学院的各位老师，感谢他们给我学习生活上的教导和关心。

本次课题是以神经网络研究理论为基础，参考了前人的研究理论和部分结果，并经过独立分析和试验，设计和开发了首钢精品棒材产品性能预报系统，经过多次试验，确定了神经网络模型和算法选择，并已投入到实际的生产检验中去，带来了很好的经济效益，大大提高了检验效率。本文中的试验工作和最终上线得到了首钢高线厂精品棒材车间和首钢质监站的大力支持，在此特表示感谢。