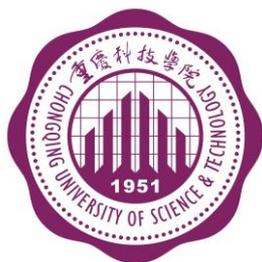


重庆科技学院



# 毕业论文

题目 神经网络模型在高炉布料中的应用

学院 冶金与材料工程学院

专业班级 冶金工程 2010-03

学生姓名 熊路 学号 2010440469

指导教师 高绪东 职称 讲师

评阅教师 \_\_\_\_\_ 职称 \_\_\_\_\_

2014年05月28日

# 注 意 事 项

## 1. 设计（论文）的内容包括：

- 1) 封面（按教务处制定的标准封面格式制作）
- 2) 原创性声明
- 3) 中文摘要（300 字左右）、关键词
- 4) 外文摘要、关键词
- 5) 目次页（附件不统一编入）
- 6) 论文主体部分：引言（或绪论）、正文、结论
- 7) 参考文献
- 8) 致谢
- 9) 附录（对论文支持必要时）

2. 论文字数要求：理工类设计（论文）正文字数不少于 1 万字（不包括图纸、程序清单等），文科类论文正文字数不少于 1.2 万字。

3. 附件包括：任务书、开题报告、外文译文、译文原文（复印件）。

## 4. 文字、图表要求：

- 1) 文字通顺，语言流畅，书写字迹工整，打印字体及大小符合要求，无错别字，不准请他人代写
- 2) 工程设计类题目的图纸，要求部分用尺规绘制，部分用计算机绘制，所有图纸应符合国家技术标准规范。图表整洁，布局合理，文字注释必须使用工程字书写，不准用徒手画
- 3) 毕业论文须用 A4 单面打印，论文 50 页以上的双面打印
- 4) 图表应绘制于无格子的页面上
- 5) 软件工程类课题应有程序清单，并提供电子文档

## 5. 装订顺序

- 1) 设计（论文）
- 2) 附件：按照任务书、开题报告、外文译文、译文原文（复印件）次序装订
- 3) 其它

## 学生毕业设计（论文）原创性声明

本人以信誉声明：所呈交的毕业设计（论文）是在导师的指导下进行的设计（研究）工作及取得的成果，设计（论文）中引用他（她）人的文献、数据、图件、资料均已明确标注出，论文中的结论和结果为本人独立完成，不包含他人成果及为获得重庆科技学院或其它教育机构的学位或证书而使用其材料。与我一同工作的同志对本设计（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了谢意。

毕业设计（论文）作者（签字）：

年 月 日

## 摘 要

布料制度是高炉生产四大制度之一，它影响高炉生产是否稳定顺行、能否降耗节能、增产提质，以及影响高炉的寿命，所以在整个高炉生产中是非常重要的。炉料的落点受到溜槽的旋转速度、料流排出量、料线高度、炉料种类和粒度、每环布料量、装入程序、炉料初速度、摩擦系数、潜体阻力等诸多因素的影响，其特征就是复杂且非线性，所以想通过某一方是预测他的结果是很困难的。而近年来人工神经网络发展迅速，它可以模拟人脑的活动、具有很好的非线性还具有大规模并行处理、自组织学习、外部环境的适应及容错能力，所以在许多领域都已研究利用人工神经网络进行预测。但人工神经网络自身也有诸多缺陷：如网络结构选择具有随机性、收敛速度慢或不收敛、局部极小值问题等。

本文根据经采用了变步长、附加动量、自适应学习率、引入陡度因子等方法进行优化和改进后的 BP 神经网络，并结合影响高炉布料的因素建立了预测模型，且取得了良好的结果。该模型是用 Visual C++ 语言编写的程序，并运行测试，结合数据进行了仿真实验，能够预测炉料落点，为布料预测模型奠定了基础。

**关键词：**高炉炼铁 布料 BP 神经网络 预测模型

## ABSTRACT

Fabric system is one of the four blast furnace production system, whether it affects the stability of blast furnace production along the line, whether saving energy saving, Yield and Quality, as well as the impact of the blast furnace life, so the entire blast furnace is very important. Charge of the placement by the rotational speed of the chute, the impact of stream discharge amount, feed line height, charge type and size, fabric per ring, loader, Burden initial velocity, friction coefficient, submerged body resistance, and many other factors, has complicated nonlinear characteristics, which makes it very difficult to predict. And in recent years, the rapid development of artificial neural networks, has good linearity, can simulate the human brain activity and self-organization learning, ability to adapt to massively parallel processing, fault tolerance, and the external environment, so in many areas of study, have been artificial neural networks to predict. But there are many artificial neural network itself is also flawed: as slow convergence or non-convergence, local minima problem, choose a random network structure and so on.

According to this paper by using a variable step, additional momentum, adaptive learning rate, the introduction of the steepness factor method optimization and improved BP neural network, combined with factors affecting BF established a forecasting model, and achieved good results. The model is written in Visual C ++ program, and run the test, combined with simulation data were able to predict the placement of charge, laid the foundation for the fabric predictive models.

**Keywords:** blast furnace ironmaking; BF; BP Neural Networks; Prediction Model

## 目录

摘 要.....	I
ABSTRACT.....	II
1 绪论.....	1
1.1 高炉布料概述.....	1
1.1.1 高炉布料的概念.....	1
1.1.2 影响布料的因素.....	1
1.2 国内外对布料的研究现状.....	1
1.3 无钟炉顶布料模型的发展现状.....	5
1.4 应用于预测中的人工神经网络.....	6
1.4.1 人工神经网络概述.....	6
1.4.2 BP 神经网络在布料预测中的应用.....	6
1.5 BP 算法的缺陷及改进.....	7
1.5.1 BP 算法的缺陷.....	7
1.5.2 BP 算法的改进.....	9
1.6 选题主要研究内容.....	10
1.6.1 选题的目的和意义.....	10
1.6.2 选题的研究内容.....	11
2 数据的收集及处理.....	12
2.1 实验数据的收集.....	12
2.1.1 炉喉内炉料分布规律总结.....	12
2.1.2 影响炉料落点因素分析.....	12
2.2 数据样本采集.....	12
2.2.1 参数的选择.....	12
2.2.2 数据的处理、分析.....	12
3 网络预测模型的实现.....	15
3.1 网络结构的确定.....	15
3.2 炉料落点预测模型的实现.....	17
3.2.1 网络初始化.....	17
3.2.2 网络结构自调整.....	19
3.2.3 系统运行.....	19
4 结论与展望.....	26
4.1 结论.....	26
4.2 未来的展望.....	26
参考文献.....	28
致 谢.....	31

# 1 绪论

## 1.1 高炉布料概述

### 1.1.1 高炉布料的概念

高炉生产的目的是要用最小的投入换取最大的输出。因此，我们要保证高炉生产的安全、均衡、稳定、顺行。高炉的操作制度就是一种工作准则，是在一定的生产条件下，根据高炉冶炼的基本理论，以优质、低耗、高产、长寿为目的而制定的。它的内容有热制度、造渣制度、送风制度和装料制度。

在高炉生产中，煤气自下向上流动，在此过程中加热并还原处于下降状态的铁氧化物。而将炉料装入炉内的方式直接影响到炉料在炉内的分布，炉料的分布又决定高炉上部煤气流的分布和流动，影响气-固接触，继而控制炉内质量与热量的传递以及炉料下降的顺行程度，从而整个高炉生产进程以及产品的质量 and 经济技术指标都将受到影响。将含铁物料中的铁还原出来生成生铁是高炉生产的主要任务，因其过程具有连续性，故向高炉内供料也需要不断地进行，并且使之能够合理的分布到炉内。因此，通过好的布料制度获得合理的煤气流分布是高炉生产稳定顺行、降耗节能、增产提质以及延长高炉寿命的重要有效途径。

### 1.1.2 影响布料的因素

装料制度的内容有料线高低、批重大小以及装料的顺序。无钟炉布料已经成为现代高炉布料的代表形式。影响炉料分布因素有：（1）溜槽旋转使其上炉料受到其旋转离心力的作用做变加速的滑落运动；（2）炉喉空区中煤气阻碍炉料让其做近似抛体运动；（3）炉料的分布受到炉料堆角规律的作用；（4）具体的装料制度也会影响炉料分布；（5）炉料分布还与高炉本体参数、溜槽布料方式、布料参数的选择等密切相关。

## 1.2 国内外对布料的研究现状

鉴于布料在炼铁生产中的重要性，国内外在这方面研究很广泛。综合国内外相关文献，可以将对其研究大致划分为三类。第一类是国内各钢铁厂在布料规律方面的研究，第二类是建立高炉布料的数学模型并加以研究，第三类则是在现代科学 DEM 软件的帮助下对高炉布料进行一系列研究。

对于第一类（布料规律）研究即各钢铁厂通过其工业实验研究分析以提高高炉高效稳定及长寿的比较优良的操作参数。例如武钢 6 号高炉，就是先对实际情况进行了认真分析，然后进行了大胆的探索，从布料矩阵方面不断进行优化，通过研究和分析最终决定采用开放型的布料矩阵<sup>[1]</sup>。使高炉中心开放从而使炉况达到了稳定和顺行，在生产实践中探索实践后，对于 6 号高炉原燃料找到了比较适合的布料模式，从而对炉顶原布料模式进行了优化，减少了高炉中心的焦炭量，使得煤气的利用率有所提高，在综合经济

效益方面取得了更好的成绩，几个不同布料矩阵的料面函数如图 1.1。

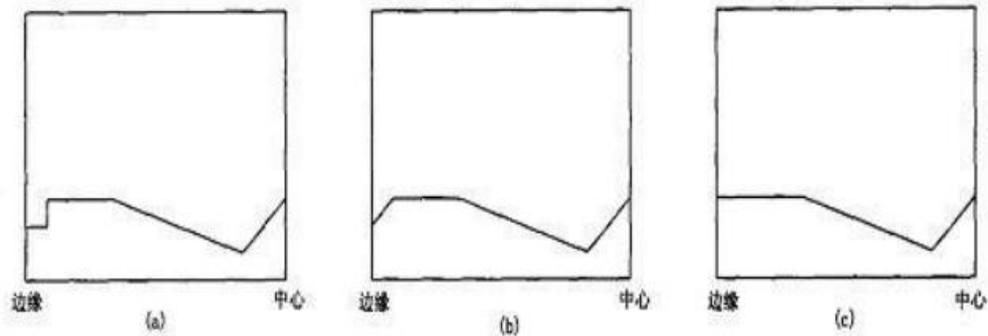


图 1.1 不同布料矩阵的料面函数

在现在更加进步的技术下，采用雷达监控结合布料调剂也是可行的方法。如武汉钢铁公司的 7 号高炉，在 2012 年装上雷达监控后，更好更方便的获取了料面形状，从而为布料调剂做出了更好的建议及指导，使得 7 号炉中煤气利用率从原先的 47% 增加到 50%，指标得到了大幅的改善<sup>[2]</sup>。

第二类研究（通过力学分析建立数学模型）可以定性和定量地了解、分析及控制高炉内炉料的初始分布。国内外学者通过力学分析、计算从而建立数学模型，对此类问题进行了诸多研究。并在建立的数学模型时对一些特殊的问题进行了优化改进。如吴敏等人将布料模型分成矿焦比计算模型、炉料分布模型、料流轨迹模型及 Q/r 料流模型四个部分，利用他们之间具有很强的依赖性并分别建立了四个部分的数学模型<sup>[3]</sup>。Q/r 料流模型是采用多项式数据拟合的方法处理开炉实验数据，建立料流量和下料开度值之间的关系，文中以焦炭为例建立数学模型：

$$F = \sum_{j=0}^n C_j^* \cdot \alpha^j \quad (1.1)$$

$C_j^*$  根据最小二乘法进行数据拟合得到。对炉料的受力和运动进行分析，从而对料流轨迹模型建模，进而得到主料流即炉料质心落点的位置坐标： $X_c = X_{c0} + v_{cx} * t$ ， $Y_c = Y_{c0} + v_{cy} * t$ ，其中  $X_{c0}$ 、 $Y_{c0}$  是炉料质点在溜槽末端的初始位置坐标， $v_{cx}$ 、 $v_{cy}$  分别是炉料离开溜槽时沿 X 轴、Y 轴的分速度。料流宽度就是通过上述方法求料流边缘的落点而求得。建立炉料分布模型的过程是先假定一个料面函数，然后通过体积相等及物质平衡关系求解函数方程中的系数，与此同时还要考虑炉煤气流分布、料料面下降及料层坍塌对料面形状的影响，并修正。根据焦炭层和矿石层的厚度及形状，获取高炉内焦炭层和矿石层径向分布情况用以建立矿焦比计算模型。实际生产的数据验证表明：以上模型具有一定得准确性，因此对生产有指导意义。图 1.2 为模型计算的料面结果。

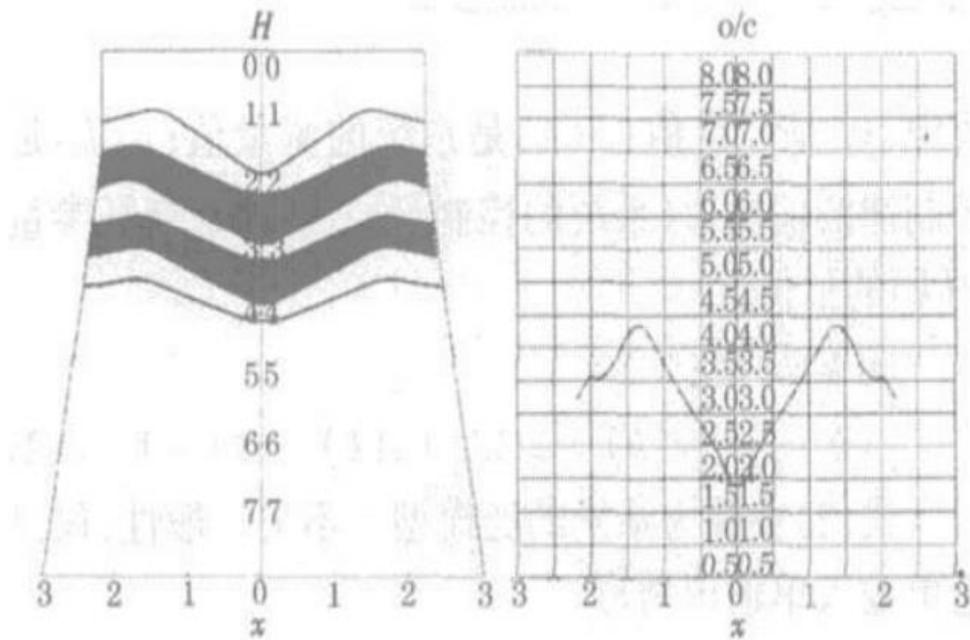


图 1.2 高炉布料模型运行画面

杜鹤桂、余艾冰的布料实验是通过模型做的，在综合考虑各影响因素时采用了正交试验法，通过回归分析的方法建立了回归方程，研究每个因素对炉喉径向矿焦比分布的影响时又采用了单因素分析法，从而得到了无料钟布料的一些规律。

张建良、张雪松等人在建立实验室无钟炉顶布料模型时运用了相似理论，通过实验模拟修正了布料轨迹方程，并求得了料层厚度、焦炭和矿的堆角及堆密度，将以往的炉料内堆角公式也进行了修正，修正后更符合实际高炉布料，下次布料的初始料面取上次布料的料面形状，减小了模拟结果受初始料面的影响<sup>[4][5]</sup>。每一个布料角度(环位)的布料情况都可以通过模型模拟，布料矩阵改变时的料面形状也可以被清楚地模拟出，模型还实时显示最近 3 批料的矿焦比曲线，可以验证程序的收敛性，并为高炉操作提供了重要的依据。模拟的料面形状与开炉前实测料面形状基本吻合。图 1.3 为模型计算的料面形状。

Takanobu INADA, Yoshimasa KAJIWARA and Tsutomu TANAKA 改进了大钟布料的数学模型，使之能够计算在一定操作参数下的径向平均粒度分布和混合粒径炉料下各粒径炉料径向分布规律。研究表明颗粒的径向分布取决于炉料斜面的筛分和沉积过程。所谓筛分过程即是在料堆中由于大颗粒间存在一定的空隙，当小颗粒炉料的粒径小于此空隙时就会穿过空隙向下渗透，此种现象即是对炉料进行了筛分，大颗粒会留在上层，小颗粒炉料会在料层底部堆积，即发生所谓沉积现象。研究表明在炉料运行过程中影响渗透过程的主要因素是大颗粒炉料与小颗粒炉料间的粒径之比，以及料堆坡面流动层颗粒的速度梯度。通过多次的工业试验的验证，模型被证实具有一定的准确性，此模型已被用于生产实践中。

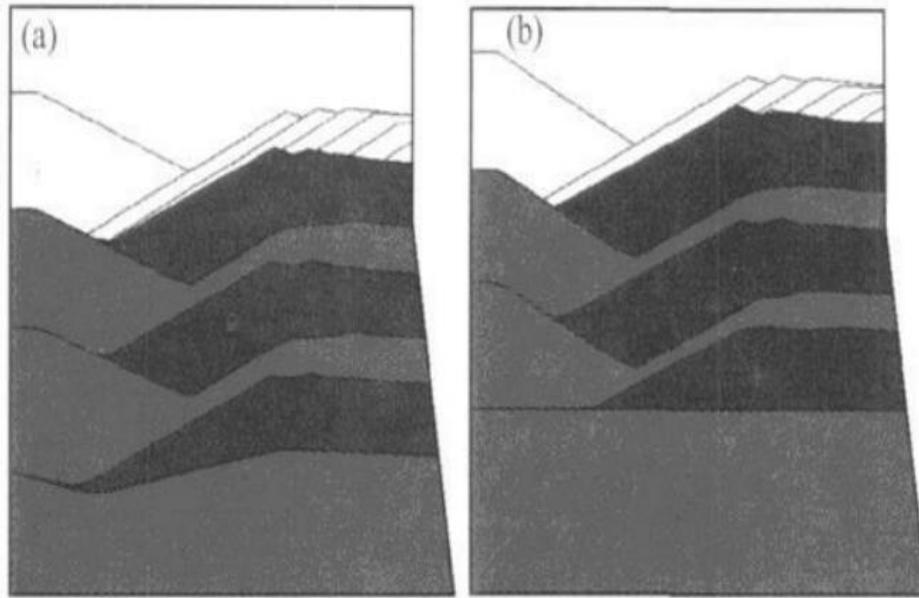


图 1.3 模型计算的料面形状

近年，吴敏等人提出利用料面温度场识别高炉气流分布的方法，并通过实验证明该方法能有效反映高炉煤气流分布状态，有利于指导高炉的料面操作<sup>[6]</sup>。

Masatoshi AKASHI 等人<sup>[7]</sup>运用 DEM 软件模拟计算了在考虑颗粒形状的条件下，研究了焦炭颗粒在焦炉里的偏析问题，并且对焦炭颗粒的形状对料流的影响，及其对炉料密度分布的影响进行了研究。通过软件计算球形与多球形不同情况下的料流情况，其与实验结果基本是一致的。但对于炉料密度分布，在球形条件下趋势不同，但在多球形及一种新方法条件下结果是一致的。偏析现象在很多工业领域都是常见现象，在布料过程中偏析现象也有非常重要的作用。对于高炉布料中炉料偏析的研究从很早就已经开始了，但是从查阅到的文献来看，研究的还不是很，主要研究见表 1.4 中所列。在 80 年代，N.Standish<sup>[8]</sup>和 William R. Ketterhagen 等人<sup>[9]</sup>就已经开始对布料过程中的偏析现象进行研究。他用料斗模型模拟炉料加入料斗的过程，研究了炉料颗粒在料斗内的偏析情况，研究得到在装料过程中小颗粒炉料会集中于中间地带，大颗粒炉料会集中于靠近容器壁的边缘地带，同时发现小颗粒的偏析在布料刚开始的时候比较强烈，而在后期会较轻微，而大颗粒物料此一特征则刚好相反，所得的实验结果与工业数据是相一致的结果。TakanObu INADA<sup>[10]</sup>等通过实验改进了数学模型，使得新的数学模型可以计算径向粒度分布，并研究了布料过程中颗粒的渗透和沉积行为，研究得到了新的数学模型，并弄清楚了颗粒的渗透行为和沉积行为。Hideki KAWAI 等人<sup>[11]</sup>运用二维冷态模型模拟炉料在高炉内运动情况，他将大颗粒和小颗粒的物料从模型顶部布入炉内，研究表明小颗粒炉料会从大颗粒炉料间的空隙向下渗透，向上的气流又会使小颗粒从大颗粒炉料间的空隙向上运动，当采用边缘布料时小颗粒炉料会集中在高炉边缘，会利于中心气流的发展；当采用水平均匀布料或中心布料时，小颗粒炉料会聚集于高炉中间和死料柱表

面；低密度的焦炭粉末会发生淘析现象；在均匀布料情况下，粉末的聚集会在炉墙间形成连接桥。Samik NAG 等人<sup>[12]</sup>曾研究了无料钟过程中炉料出溜槽后的料流的粒度偏析，通过物理模型对布料过程的模拟，得到了铁矿石、焦炭、烧结矿各料流的特点，以及在不同溜槽倾角下的粒度偏析，实验表明三者料流特点不同但是比较相似的；并且把实验得到的数据与前人得到的数学模型算得的数据进行比较，两者是非常吻合的。Hiroshi MIO 等人用 DEM 软件模拟了炉料在溜槽上运动的过程，结果表明在通过溜槽的过程中颗粒是发生偏析的，小颗粒会在底部，大颗粒在小颗粒上面，并用实验室模型进行实验，对软件模拟结果进行验证，实验结果证明软件模拟结果是正确的；后来他们又对溜槽角度对布料行为的影响进行研究，随着布料的量的增加荷质比会增加，料堆会向高炉中心移动，这是由于颗粒会不断向高炉中心滑落，随着烧结矿量的增加，焦炭颗粒被压向高炉中心。

### 1.3 无钟炉顶布料模型的发展现状

20 世纪 60 年代以后，高炉生产在理论研究方面被数字计算能力以及各种监测手段的提高为注入了新的活力。电脑技术的应用更是推动了高炉工艺在模型方面的发展。掌握炉内布料的规律，建立数学模型是建立其他模型的基础。

Yongfu Zhao、Stephen E.Yaniga 等人开发的无钟炉布料仿真模型<sup>[13]</sup>在美钢联的 Fairfield 厂 8 号高炉应用，其考虑了料线高度、炉身倾角、炉料下降速度及焦炭滑移等浮渣的因素，能够在线动态模拟无料钟高炉的布料过程；Mats J.Nikus 和 Henrik Saxen 的矿焦分布模型<sup>[14]</sup>是在温度测量基础上建立的。它在离线模拟上是比较成功的，但是还存在着很多不足；经文波、陈小雷开发的南钢 1 号高炉布料模型<sup>[15]</sup>，它主要针对由矿焦质量下降引起的高炉透气性差，炉况顺行差、炉温波动大等问题研究的，它可以确定炉料在炉喉半径方向上矿焦堆尖位置、风口中心线以上料柱的平均高度等控制参数。并在南钢 1 号高炉的指导生产中取得了显著地实际效果；日本新日铁公司的 RABIT 炉顶布料模型<sup>[16]</sup>是以实测数据和理论分析为依据建立的，考虑了焦炭层坍塌现象和上升煤气流对料面形成的重要作用；宝钢 2 号高炉布料模型<sup>[17]</sup>的主要思想是：（1）把无钟炉布料器溜槽的倾角和放置的次数组成很多倾角方式的代码组，并标记显示在三角图形上以备，（2）根据各种探测器得到的信息，结合炉料的装入现状，保证合理的煤气流分布作为前提而做出恰当的判断，作为在线调整的指导；东北大学的林成城等以马钢 2500m<sup>3</sup>高炉为原型的串罐无料钟实验模型<sup>[18]</sup>按 1/9 的比例缩小设计参数，然后在其上实验得到指导参数；李志全、郭兰芬等人提出以高炉布料的静态模型为基础，以动态模型的设计原理作为出发点，经过完善并通过实验室条件分析设计了动态模型<sup>[19]</sup>，还处于试应用阶段，但也是在布料模拟上的一个推进；杜续恩近年在以鞍钢高炉为基础的条件下也作了串罐无料钟布料模型的研究<sup>[20]</sup>，该模型能够计算确定不同炉料在不同料线、不同环位的落点位置，还能计算不同布料制度下的料面形状以及炉喉径向的料层厚度和矿焦比，能

够指导调整布料制度；滕召杰等人在已有模型的基础上还对科氏力、煤气曳力进行了综合分析设计了仿真模型<sup>[21]</sup>，对高炉内部的研究更细化了，在建模模拟预测方面更近了一步。

## 1.4 应用于预测中的人工神经网络

### 1.4.1 人工神经网络概述

人工神经网络（简称 ANN）是一门较新的学科，在 80 年代后期发展得较快。它对非线性过程建模是可以不了解数据产生原因的。其适应性很大，可以应用于许多领域，如近年来在投资预测等领域就得到了广泛应用，并取得了一定的成果。其中，应用最广的一种就是 BP(Back propagation)神经网络<sup>[22]</sup>，它由信息的正向传播和误差的反向传播两个过程组成<sup>[23]</sup>。理论上讲，一个三层的 BP 神经网络可以逼近任何的连续函数<sup>[24-28]</sup>，如图 1.1 所示，一般采用三层的神经网络在应用中进行预测。有非线性、非局限性、非常定性、非凸性等特点<sup>[29]</sup>。

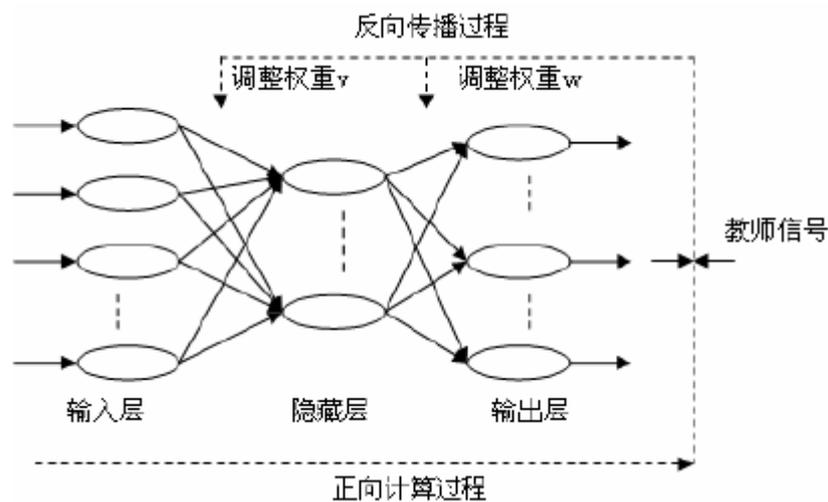


图 1.4 BP 神经网络的预测原理

### 1.4.2 BP 神经网络在布料预测中的应用

BP 算法于 1986 年被提出<sup>[30]</sup>，次年即首次应用于预测<sup>[31]</sup>。因它具有良好的非线性品质，且有自组织性，作为一种通用的非线性函数逼近工具，后来在预测领域中显示了很大的优势。

之后，《单变量经济时间序列的人工神经网络预测》一文被 Versino 和 Varfis 发表，接着《基于 BP 神经网络的循环燃气市场模式研究》又被 Werbos 发表，他们分别对实际的经济时间序列数据进行了研究并得出了预测结果<sup>[32][33]</sup>；Chakraborty 和 Weigend<sup>[34][35]</sup>在多变量时间序列等方面作了研究，结果是在预测方面统计法不如神经网络；Thomassey<sup>[36]</sup>等人将模糊逻辑技术与人工神经网络结合起来的方法模拟销售，使得在前

景预测的研究中应用到了人工神经网络,其研究结果证明用神经网络建立的预测模型是比较有效的。

到目前为止,也有许多学者如姜慧研、毕学工、滕召杰等将人工神经网络引入到高炉布料的应用中,但由于高炉内部生产及布料的复杂性,网络模拟预测这块在高炉布料中的应用一直处于研究阶段,远不如在硅含量预测等方面成熟。所以,在这方面还有很大的探索和努力的空间。

## 1.5 BP 算法的缺陷及改进

### 1.5.1 BP 算法的缺陷

#### (1) 收敛速度过慢或不收敛

在建模中可能导致 BP 神经网络收敛速度慢或不收敛的原因很多,诸如学习步长(学习速率)的设置和目标函数、初始权值等的选取等。Fahlman<sup>[37]</sup>通过研究证实,这些因素中最主要的原因大致有两个:一个是变动目标问题,另一个是学习步长的问题。由 Fahlman 提出的著名的级联相关(Cascade-Correlation, CC)算法,就是用来解决这个问题

的。

#### 1) 学习步长问题

标准 BP 算法是计算误差函数对权值的一阶偏导数,在计算渐渐缩减的误差时需依据权值空间的梯度。在应用中,过小的步长通常不会被采用,用来增加收敛速度的一般是较大的步长,但是也要注意,权值无法收敛到较好的局部最小值就是步长过大所导致。所以,目前采用二阶导数信息来加快 BP 算法收敛速度是很多正在使用的 BP 改进算法的通用方法。

#### 2) 变动目标问题

对网络权值进行修正一般是在网络的结构确定以后,此时没有相互直接通信作用于同一隐含层各节点之间的。各个隐节点需要完成的任务一般表示为误差信号,一直处于变动状态的输入信号和误差信号,导致了隐含层节点在很长时间内其实是混沌的,即各隐节点要完成的任务也是变动的,且需要较长时间才能稳定下来。曾有人用“羊群效应”<sup>[38]</sup>生动的描述了上述现象:即相当于多个不能互相通信的部门在解决两个问题是,都会涌向较大的一个而忽略另一个问题;而当他们回过头来解决另一个问题是,之前的问题有重新出现了。要解决这个问题,就只能允许同一时间部分隐节点去解决一个问题。

#### (2) 容易陷入局部极小<sup>[39]</sup>

BP 算法是沿着误差函数的斜面从某一起点开始逐渐达到误差的最小值进行训练,也就是采用梯度下降的方式。用一片连绵起伏的山脉来比喻二维权空间的误差曲面是很恰当地,如图 1.5。误差函数的极小点就是其低凹部分,训练陷入局部极小就是误差曲面的多极小点所导致。在低凹部分,网络的期输出与输出之间是几乎没有误差梯度的,

如图所示，这时网络的训练便陷入了局部极小值。

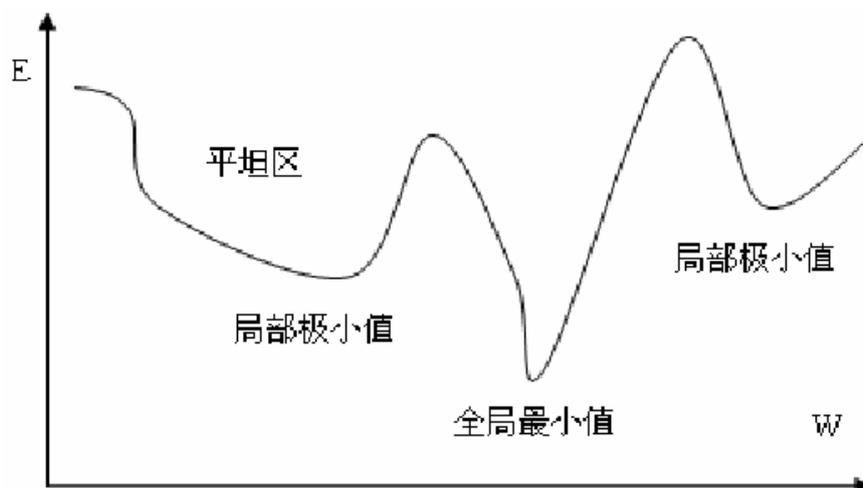


图 1.5BP 算法二维误差示意图

从下图还可以看出，误差的梯度基本无变化的一些区域中，即使是权值的调整量很大，误差也只是慢慢下降，产生这种情况的根本原因就在于每一步求解都取局部最优。这样一来，计算均方误差函数的最小值问题就是 BP 算法的关键，一个简单的任务，要想能够充分记忆，也需要经过多次学习和迭代过程。此时只有让学习速率就不太大，才能保证算法一定收敛。

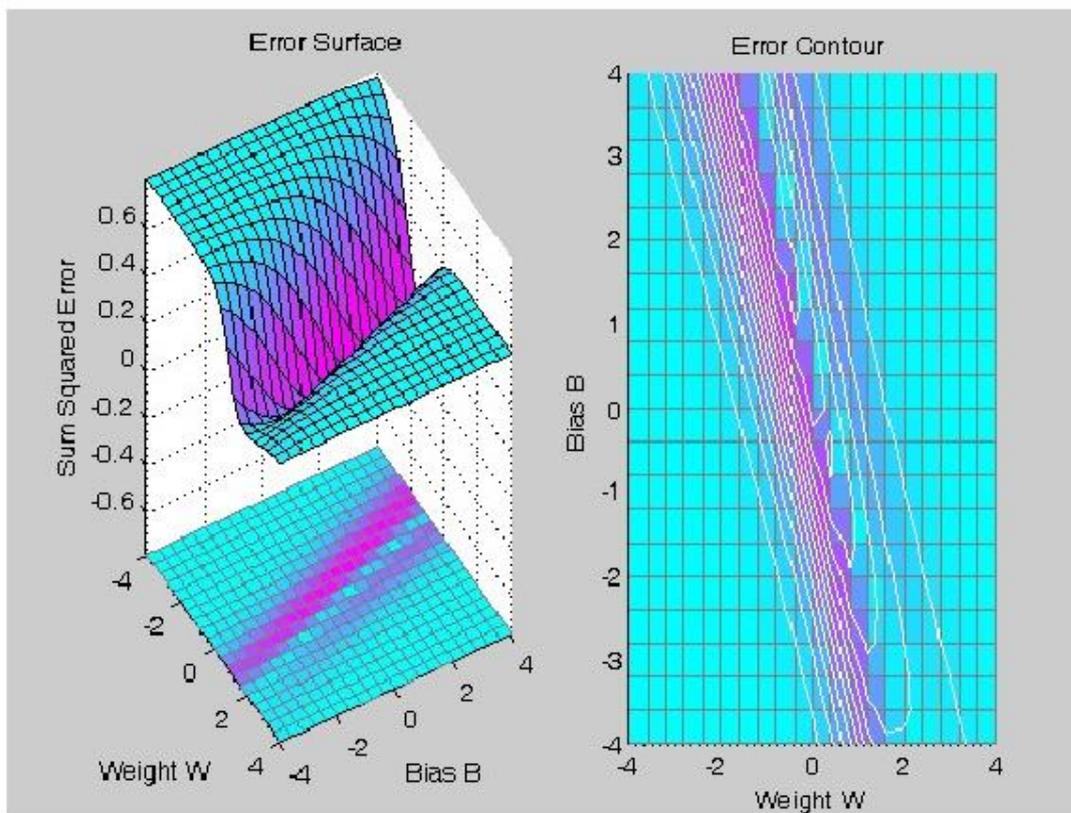


图 1.6BP 算法误差曲面图

### (3) 网络的泛化及自适应性差<sup>[40]</sup>

在 BP 算法中, 权值学习的指数函数一般绝对误差平方和, 绝对误差降低的仅仅是各个样本, 使得收敛的不平衡性的出现在各个神经元的学习中。在误差的贡献方面比较小时, 神经网络也就丧失了良好的性能。

## 1.5.2 BP 算法的改进

以梯度下降法为基础的 BP 神经网络已经在各个领域的到很好的应用, 包括高炉生产中预测硅含量等。所以对其缺陷的改进也有了方法:

### (1) 变步长<sup>[39]</sup>

在用 BP 网络建模时, 建模者需要选取一个作为学习步长  $\eta$ (也称为学习参数或学习率) 的值, 这时一般是根据自己的经验选。但实际运用中, 模型的建立直接决定于  $\eta$  的选取。一个多元函数的优化问题就是 BP 神经网络模型的实质, 也就是说变量连结系数, 目标的优化问题就是误差函数最小。求出了连接权的梯度就可以对其加以修正了, 从图 1.5 可以看出, 在平坦区内学习步长  $\eta$  太小会使训练次数增加, 因而要适当增大  $\eta$  值; 而  $\eta$  太大会因调整量过大而跨过较窄的“凹坑”, 使训练出现震荡, 这是对于在误差变化剧烈的区域而言, 继而迭代次数增加。另外, 可选步长在不同的点也是不一样的。

总之, 一个从始至终都合适的最佳学习参数在实际应用中是很难确定的。我们可以用变步长的思想来确定学习参数  $\eta$  的选取。当学习参数的值较大时, 输出节点远离目标节点; 当逼近稳定点时, 学习参数就取小值; 即根据具体情况用动值替代恒值, 以此提高 BP 算法的性能。

### (2) 神经网络自调整

由于输入和输出节点是由待解决的问题所决定的, 因此, 构建 BP 神经网络拓扑结构的关键就是隐含层的层数与节点的数目。研究过隐含层数目的有很多, 例如, 上世纪八十年代后期, Lippmann 和 Cyberko 就证明, 用含有两个隐层的网络可以解决各种形式的问题; Robert Hecht Nielson 等人认为只要节点数足够多, 即使只有一个隐含层, 对一个非线性的函数, 也可以任意精度逼近。在应用中, 一个较困难的问题就是隐含层节点数的选取。先设定初始层数, 然后让网络进行自组织学习、逐步调整网络的结构, 最后得到一个隐含层节点相对合适的网络模型是较好的解决办法。

### (3) 调整学习率及附加动量法<sup>[42]</sup>

该方法以反向传播作为基础, 在每一个权值变化的基础上加上一项正比于前次权值变化量的值, 并根据反向传播算法来产生新的权值变化, 公式为:

$$\Delta w_{ji}(t+1) = \alpha \Delta w_{ji}(t) + \eta \delta o$$

其中  $\alpha$  为动量系数,  $0 \leq \alpha < 1$ , 其调整公式如下:

$$\alpha(t+1) = \begin{cases} 0 & SSE(t+1) > SSE(t) \\ 0.95 & SSE(t+1) < SSE(t) \\ \alpha(n) & SSE(t+1) = SSE(t) \end{cases}$$

附一个加动量可以有效的解决了收敛速度缓慢、学习效率不高和易陷入局部极小的问题。

调整学习速率要从神经网络误差角度来考虑。学习速率的调节准则：当新误差大于旧误差的  $n$  倍数时，学习速率会下降；否则学习速率不会发生改变；当旧误差大于新的误差时，学习速率上升。自适应调整学习速率的式子如下：

$$\eta(t+1) = \begin{cases} 1.05\eta(t) & SSE(t+1) < SSE(t) \\ 0.7\eta(t) & SSE(t+1) > SSE(t) \\ \eta(t) & SSE(t+1) = SSE(t) \end{cases}$$

其中 SSE 为网络输出误差和。

## 1.6 选题主要研究内容

### 1.6.1 选题的目的和意义

可持续发展、环境保护是 21 世纪人类经济和社会发展的共同目标，早在 20 世纪 60 年代，人类就开始面临人口、粮食、资源、能源及环境污染等一系列危机。人类认识到环境问题是制约经济发展的一个根本性问题，环境保护及污染治理已经成为经济发展中一个不可忽视的问题。节能减排成了各国各工业生产中所要完成的首要任务。而钢铁行业又是能源、资源消耗的大户，炼铁系统是整个钢铁生产体系中耗能最大的系统，这也就使其成为最大环境负荷的排放者。2004 年钢铁行业  $CO_2$  排放量占整个中国工业的 10%，仅次于火电和水泥。而且一直到近年， $CO_2$  的排放量呈爆炸性增长<sup>[43]</sup>。仅高炉生产的能量消耗及二氧化碳排放量就分别占整个钢铁产业的 49% 和 53%<sup>[44]</sup>。降低这一产业的生产成本和对环境的污染，是让提高该产业综合竞争力的有效方法。

高炉生产有四大操作制度，其中一个非常重要的制度是布料。在高炉生产中，煤气从下向上加热并还原下降的铁氧化物。将炉料装入炉内的方式直接影响到炉料在炉内的分布，最终将改变高炉上部煤气流的分布和流动，影响气-固接触，继而控制炉内质量与热量的传递以及炉料下降的顺行程度，从而影响高炉生产整个进程以及产品的质量 and 经济技术指标。高炉生产主要任务是将含铁物料中的铁还原出来生成生铁，因其过程的连续性，故而需要不断地向高炉内供料，且由炉顶装料设备将炉料入炉并合理的分布到炉内。因此，通过好的布料制度获得合理的煤气流分布是高炉生产稳定顺行、降耗节能、增产提质以及延长高炉寿命的重要有效途径。

要想获得良好的布料制度，除了对以往实践经验的总结，也需要大量的实验研究及新的探索。而随着科学技术的发展以及电脑的广泛应用，现如今可以编译很多软件来模

拟实际生产过程。在电脑上来模拟实际生产过程，可以进行很多实验研究。就像天气预报一样，建立一个神经网络模型，输入各种单一变量就可以导出结果。有这样一个模拟程序，不仅可以让学习冶金的人更容易学习了解其模拟的生产过程；通过进一步的研究与完善，我相信它也能比试验更准确的导出结果，这样就可以省去实验中大量的设备、原料消耗，当然在环境可持续发展方面也能做到最好。

### 1.6.2 选题的研究内容

如上所述，国内外冶金人都为获得更优良的布料制度不断探索着，本文查阅了相关书籍和文献，理解并分析 BP 神经网络，选择经国内外大量研究者改进过得 BP 神经网络建立模型，用 VC6.0 编写程序。用实际生产数据进行训练，并加以修正，将程序的实用性提高了，也增加了其预报精准度。从而可以指导布料参数的确定，优化布料操作，使得达到更好的生产效率。具体研究内容如下：

① 建立神经网络模型，选取合适的实验参数，选择合理的影响因素，制定实验方案。

② 采集合适的生产数据，并对其分析处理，使之能对神经网络模型加以训练、调试，提高其实用性。

③ 进行仿真实验，对仿真实验结果与标准 BP 算法及其改进算法预测结果进行分析，然后对预测模型作出评价。

## 2 数据的收集及处理

### 2.1 实验数据的收集

#### 2.1.1 炉喉内炉料分布规律总结

根据以往高炉布料的经验, 炉料在炉喉内的分布具有以下特点: (1) 矿石与焦炭堆角相比, 矿石堆角一般略大于焦炭堆角。(2) 采用多环布料方式时, 主堆尖只有一个, 且位于主料流落点的位置上。(3) 炉料在炉内以高炉中心线为对称轴呈层状分布。(4) 无钟高炉布料时, 由于布料时间较长, 料流较小, 因而当矿焦层之间所形成的混和层相对较薄。

#### 2.1.2 影响炉料落点因素分析

装料制度的内容有料线高低、批重大小以及装料的顺序。而影响炉料分布因素主要有: (1) 炉喉空区中煤气阻力; (2) 溜槽旋转速度及其倾角; (3) 具体的装料制度也会影响炉料分布; (4) 炉料的分布受到炉料堆角规律的作用; (5) 炉料分布还与高炉本体参数、炉料种类粒度、溜槽布料方式、布料参数的选择等密切相关。

### 2.2 数据样本采集

#### 2.2.1 参数的选择

高炉生产过程是一个封闭的高度耦合的非线性复杂系统。将炉料装入炉内的方式将影响高炉生产及使用寿命。而影响布料制度的因素有很多, 如料线高度、溜槽倾角、转速、不同批重、不同节流阀开度、不同炉料密度、颗粒度、煤气流速、不同位置炉料下降、炉料堆角规律、高炉本体参数等。本文用 BP 神经网络算法来预测布料结果, 输入参数的选择很大程度上决定了预测结果。因此, 输入参数选择时不但要结合操作人员以往的经验和高炉生产特点及实际生产情况, 还要考虑各参数对炉料落点的相关性分析以及实际数据的采集条件, 最好选取影响炉料落点的因素相关性较大的参数。

本文选取料线高度、溜槽倾角、转速、节流阀开度、炉料真密度和炉料颗粒度、纵向煤气流速、径向煤气流速、形状因子(体积相同的球形颗粒与非球形颗粒表面积之比)作为回归模型的输入参数, 以炉料落点作输出参数, 建立神经网络模型。

#### 2.2.2 数据的处理、分析

各参数的频度也是会影响模型预报结果精度的。预报的精度会随着参数频度增大而增高, 从另一方面看, 频度与输入的数据成正比, 参数频度增大时, 系统学习所需时间和空间也随之增多。在实际运行系统时可以利用的时间是有限的, 这就需要在预报精度与参数频度之间做综合考虑, 然后将采集的实时数据做归一化处理, 以生成需要的输入

参数值。数据的分析处理流程大致如下：

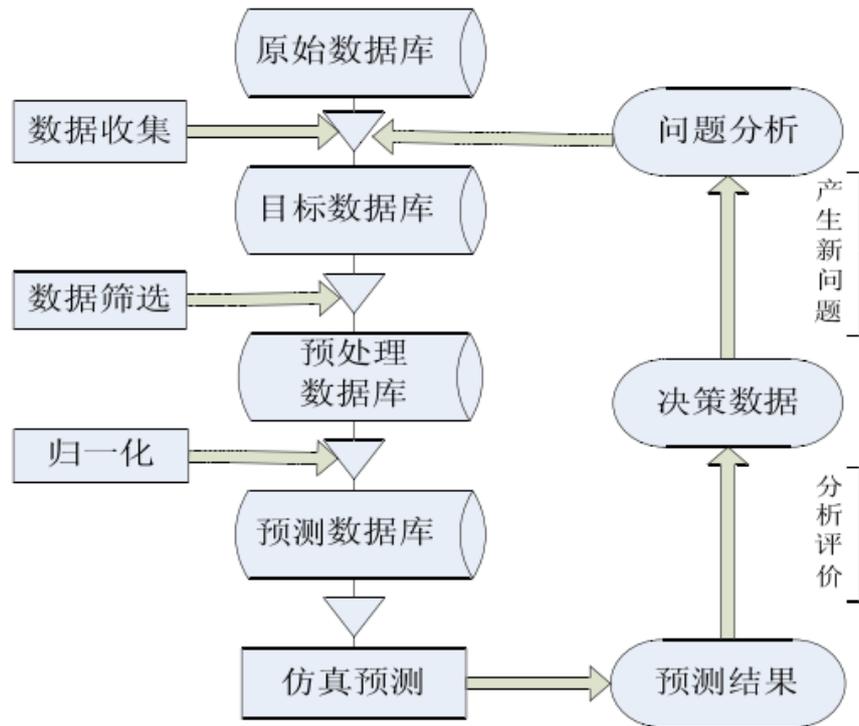


图 2.1 数据分析流程

对数据进行收集、分析、选择和预处理以获取训练样本集合，是非常关键和重要的一步。对不定问题求解前必须对数据加以分析，以找出其中主要的影响因素，然后对其进行滤波处理。为保证数据有效以及能够去除噪声的干扰，就必须对采集的数据进行处理。

原始样本集拥有不同的变量量纲，较大的输入量会使神经网络的收敛速度大大降低，为提高收敛速度，必须对参数进行归一化处理，本文采用联合归一化<sup>[45]</sup>，算法如下。

设置N个网络输入节点，在相同条件下选取的N个不同的特征参量（ $X^0, X^1, \dots, X^{N-1}$ ）作为网络的输入参数，从每个特征参量中选取L个特征值（ $X_0^i, X_1^i, \dots, X_{L-1}^i$ ，其中  $i=0, 1, \dots, N-1$ ），将参量和特征值组合起来构成了样本空间  $\Omega_{L \times N}$ 。联合归一化分两步：

①归一化列向量。采用最值法对列向量进行归一化。归一化后为：

$$\hat{X}_j^i = \frac{X_j^i - X_{\min}^i}{X_{\max}^i - X_{\min}^i}$$

其中： $i=0, 1, \dots, N-1$ ； $j=0, 1, \dots, L-1$ 。

②归一化行向量。用最值法对列向量进行归一化。归一化后为：

$$\bar{X}_j^i = \frac{\hat{X}_j^i - \hat{X}_{j,\min}^i}{\hat{X}_{j,\max}^i - \hat{X}_{j,\min}^i}$$

其中： $i=0, 1, \dots, N-1$ ； $j=0, 1, \dots, L-1$ 。

将经过联合归一化处理后的数据作为网络的输入参数。网络的实际输出需通过逆变换将其转换成绩有原先量纲的实际数据。

## 3 网络预测模型的实现

### 3.1 网络结构的确定

早在80年代末, Carroll和Rumllhart等, 用不同的方式证明了仅含有一个隐层的三层前向神经网络模型可以拟含任意一个非线性映射能力。所以, 采用一个三层前向反馈的神经网络来建立布料神经网络预报模型。因为网络的输入和输出层节点数根据训练样本来确定, 所以隐含层节点数的确定就是关键问题。

#### (1) 设置输入、输出层神经元

BP网络是一个从输入样本空间到输出期望空间的映射 ( $a_i \rightarrow b_j$ )。输出期望值j维, 输入样本i维, 而对应着神经元个数的就是维数。

本课题中用来预测炉料落点的输入量选取料线高度、溜槽倾角、转速、节流阀开度、炉料真密度和炉料颗粒度、纵向煤气流速、径向煤气流速、形状因子, 所以输入层数为9, 输出层为1。

#### (2) 设置隐含层神经元

隐层节点数过少, 会明显降低神经网络的归纳记忆的能力, 也就降低其从样本中获得信息的能力, 提取不到训练集中的样本规律, 这就削弱了其预测性能, 还有可能导致网络不收敛; 隐层节点数太多, 虽然能够更加精确的描述对象且使求解精度增高, 但是这样又会使系统运行的空间和时间变大, 会减弱对样本携带噪声的性能。隐层节点数通常由网络用途决定, 但也不是无例外。例如试凑法就是一个常用的方法。在网络训练时常用的误差代价函数为:

$$E_f = E_{\text{总}} + \varepsilon \sum_{h,j,i} |w_{ij}^h|, \quad h=1, 2; \quad j=1, 2 \dots m; \quad i=1, 2 \dots n。$$

其中,  $E_{\text{总}}$  表示网络输出误差的平方和;  $n$ 表示单个隐含层网络的输入层节点数;  $m$ 表示隐含层节点数; 这相当于引入一个遗忘项的作用, 可以使训练后的连接权值尽量小。

另决定隐层节点常用的一些经验公式如下:

$$m = \sqrt{n+l} + \alpha \quad (1)$$

$$m = \log n \quad (2)$$

$$m = \sqrt{nl} \quad (3)$$

本文中选用:  $m = \sqrt{n+l} + \alpha$

其中  $n$  为输入层神经元数目,  $l$  为输出层神经元数目,  $\alpha$  为1~10的常数。

#### (3) 选择激励函数

在人工神经网络中, 激励函数占有极其重要的地位, 单个神经元的输出与输入之间的函数关系就体现在激励函数上。Sigmoid 函数、径向基函数、阶跃函数等就是常见的激励函数。在使用梯度下降的 BP 算法学习的过程中, 神经网络会很容易的在学习过程

中出现了“平台现象”，这是因为较高的学习的误差是出现在一定的时间范围内的，这样的情况不会因学习次数的改变而改变，当这段时间结束后，误差有明显的开始下降的现象<sup>[42]</sup>。如果神经网络在学习过程中出现了“平台现象”，那么它需要相当长的一段时间才能结束这种状态，这就是 BP 算法收敛速度慢的主要原因。

任意神经元的输入进入饱和区就是网络出现平台现象的根本的原因，从而使得这些神经元的相关函数的导数无限接近于零，权值、阈值的改变起不到修正的作用，作用于神经元的函数对此有很大的影响。当作用于神经元的函数的曲线很陡时，就会进入斜率较大的区域，神经元也会随之进入饱和区，神经网络出现“平台现象”，可见选择正确的激励函数对于神经网络的运行非常重要。

Sigmoid 函数经过修正后<sup>[46]</sup>与幂函数、指函数等磨光函数都做了深入比较，讨论了他们作为磨光函数和其反函数作为过滤函数的具体值，验证了其优越性。所以采用 Sigmoid 函数。而较常见的 Sigmoid 函数有以下三种：

$$f_1(x) = \frac{1}{1 + e^{-x}}$$

$$f_2(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

$$f_3(x) = \arctg(x)$$

合适的激励函数，可以加快 BP 神经网络的收敛速度。本文在建立模型时，也将对激励函数进行选择。

#### (4) 模型的测试、训练及预测

收集到的样本一般将其分为训练集和测试集两个部分，分别用于训练和测试。将训练样本输入网络后，单次训练过程包括在进行正向传输训练的同时进行反向权值调整。为了提高模型的判定效率，本文采用定期测试的方法来解决 BP 模型的过适应问题，即用测试误差来决定是否结束训练，当测试误差有上升趋势时就结束训练<sup>[39]</sup>。对采集的历史数据进行归一化处理，将其作为预测部分。程序流程图如下：

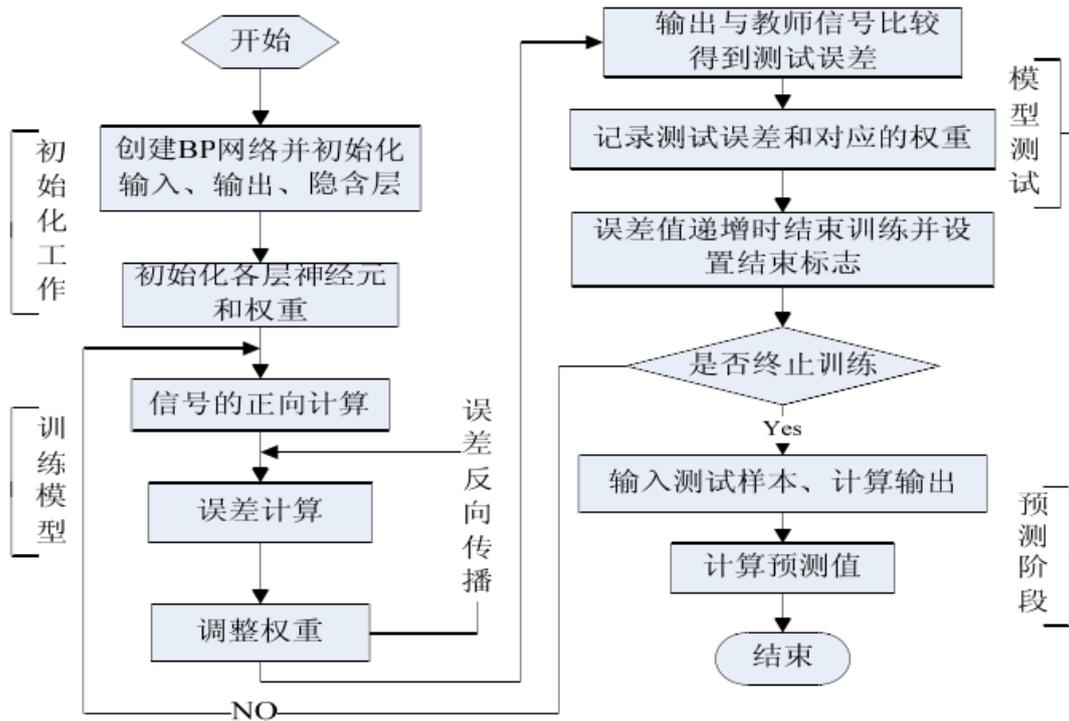


图 2.2 程序流程图

### 3.2 炉料落点预测模型的实现

#### 3.2.1 网络初始化

本节利用改进后的 BP 算法建立三层 BP 网络模型。

一、BP 神经网络的正向传播过程<sup>[47]</sup>

输入层：单元  $i$  的输出值  $O_i$  等于其输入值  $X_i$

隐层：对于第  $j$  个隐单元，其输入值  $net_j$  为其前一层个单元的输出值  $O_i$  的加权和：

$$net_j = \sum w_{ji} o_i - \theta_j$$

$\theta_j$ ：阈值。

输出值为：

$$o_j = f(net_j)$$

$f$ ：激励函数，当  $f$  为 Sigmoid 函数时，

$$f(net_j) = \frac{1}{1 + \exp(-net_j)}$$

输出层：输出值为输入值的加权和对于第  $k$  个输出单元，输出值  $o_k$  为：

$$o_k = f(net_k)$$

二、BP 神经网络的反向传播过程<sup>[47]</sup>

将  $E_p$  定义为误差函数:

$$E_p = \frac{1}{2} \sum_k (t_k - o_k)^2$$

$t_k$ : 对应的实际值。

①调整输出层的权系数

修整公式:

$$\Delta v_{kj} = -\eta \frac{\partial E_p}{\partial v_{kj}} = -\eta \frac{\partial E_p}{\partial net_k} \frac{\partial net_k}{\partial v_{kj}} = -\eta \frac{\partial E_p}{\partial net_k} \frac{\partial}{\partial v_{kj}} (\sum v_{kj} o_j - \theta_k) = -\eta \frac{\partial E_p}{\partial net_k} o_j$$

$\eta$ : 学习率,  $0 < \eta < 1$ 。

$$\text{定义 } \delta_k = -\frac{\partial E_p}{\partial net_k} = -\frac{\partial E_p}{\partial o_k} \frac{\partial o_k}{\partial net_k} = (t_k - o_k) f'(net_k) = (t_k - o_k) o_k (1 - o_k)$$

得到输出层任意神经元 k 的加权系数修正公式为:

$$\Delta v_{kj} = \eta \delta_k o_j = \eta o_k (1 - o_k) (t_k - o_k) o_j$$

式中:  $o_k$ 、 $o_j$  分别为输出节点 k、j 在样本作用是的输出;

$t_k$  为在样本输入输出对作用时输出节点 k 的目标值。

②调整隐含层的权系数

根据梯度法可得出隐含层每个神经元权系数的修整公式为:

$$\Delta w_{ji} = -\eta \frac{\partial E_p}{\partial w_{ji}} = -\eta \frac{\partial E_p}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} = -\eta \frac{\partial E_p}{\partial net_j} \frac{\partial}{\partial w_{ji}} (\sum w_{ji} o_i - \theta_j) = -\eta \frac{\partial E_p}{\partial net_j} o_i = \eta \delta_j o_i$$

$$\delta_j = -\frac{\partial E_p}{\partial net_j} = -\frac{\partial E_p}{\partial o_j} \frac{\partial o_j}{\partial net_j} = -\frac{\partial E_p}{\partial o_j} f'(net_j) = -\frac{\partial E_p}{\partial o_j} o_j (1 - o_j)$$

由于隐含层一个单元输出的改变会影响与该单元相连接的所有输出单元的输入, 即:

$$-\frac{\partial E_p}{\partial o_j} = -\sum_k \frac{\partial E_p}{\partial net_k} \frac{\partial net_k}{\partial o_j} = -\sum_k \frac{\partial E_p}{\partial net_k} \frac{\partial}{\partial o_j} \left( \sum_j w_{kj} o_j - \theta_k \right)$$

因此, 隐含层的任意神经元 j 的加权系数的修正公式为:

$$\Delta w_{kj} = \eta \delta_j o_i = \eta o_j (1 - o_j) \left( \sum_k \delta_k w_{kj} \right) o_i$$

式中:  $o_j$  为隐含节点 j 在样本作用下的输出;

$o_i$  为隐含节点 i 在样本作用下的输出, 即输入节点 j 的输入。

综上所述: 在样本作用时输出层的任意神经元 k 的加权系数改进公式为:

$$\Delta v_{kj}(k+1) = \Delta v_{kj}(k) + \eta \delta_k o_j$$

在样本作用时隐含层的任意神经元 k 的加权系数改进公式为：

$$\Delta w_{ji}(k+1) = \Delta w_{ji}(k) + \eta \delta_j o_i$$

输入层神经元为 9，即对炉料落点影响较大的 9 种因素；输出层神经元数为 1，即炉料的实际落点；初始的隐含层节点根据 (1) 计算取 8，网络的初始学习率取 0.9。隐含层转移函数用正切曲线函数 tansig，输出层转移函数用线性函数 purelin。

### 3.2.2 网络结构自调整

分别选取合适的数据为训练集和测试集进行训练和测试，以验证网络的可行性和准确性，网络的初始参数设置如下：学习率为 0.9，动量因子为 0.5，隐层数目为 8。网络经过多次训练后，最终会得到优化的 BP 神经网络结构。这个过程中合并与删除了隐节点，且在自身的组织和不断的学习下，神经网络的结构的到了优化与调整，获得一个大小合适、方便可行的模型结构。经过自调整后，焦炭模拟网络的学习率确定为 0.1，动量因子确定为 0.1，隐层数目为 5；矿石模拟网络的学习率确定为 0.15，动量因子确定为 0.1，隐层数目为 6。

### 3.2.3 系统运行

(1) 将焦炭的生产数据输入系统并保存，系统自动生成预测数如图。

样本序号	料线高度	溜槽倾角	溜槽转速	节流阀开度	炉料真密度	炉料颗粒度	纵向煤气...	径向煤气...
1	1.800	33.000	0.128	50.000	550.000	20.000	4.000	0.400
2	1.800	35.000	0.131	50.000	550.000	22.000	4.000	0.350
3	1.800	35.000	0.133	50.000	545.000	22.000	3.000	0.300
4	2.400	25.000	0.137	45.000	550.000	20.000	3.000	0.320
5	1.500	32.000	0.139	40.000	560.000	20.000	3.000	0.320
6	2.700	27.000	0.131	45.000	550.000	25.000	3.800	0.370
7	1.800	33.000	0.126	45.000	550.000	26.000	3.200	0.280
8	1.300	35.000	0.133	50.000	545.000	28.000	3.700	0.340
9	1.300	33.000	0.133	40.000	540.000	20.000	3.000	0.290
10	1.500	33.000	0.126	40.000	555.000	22.000	3.500	0.370
11	2.700	25.000	0.137	45.000	560.000	23.000	4.100	0.390
12	1.500	33.000	0.136	50.000	550.000	20.000	2.800	0.240
13	2.900	25.000	0.137	50.000	555.000	20.000	2.900	0.240
14	2.400	25.000	0.126	45.000	545.000	22.000	2.800	0.230
15	2.700	27.000	0.131	40.000	545.000	25.000	2.700	0.220
16	1.500	32.000	0.126	40.000	550.000	28.000	2.700	0.210
17	2.000	35.000	0.133	40.000	550.000	26.000	2.700	0.230
18	2.700	27.000	0.131	40.000	550.000	22.000	3.400	0.350
19	1.800	32.000	0.137	45.000	550.000	25.000	3.500	0.370
20	1.300	35.000	0.137	40.000	545.000	23.000	3.300	0.320
21	2.400	27.000	0.133	45.000	540.000	26.000	3.800	0.410
22	1.300	32.000	0.126	45.000	545.000	28.000	4.000	0.420
23	1.300	30.000	0.131	50.000	545.000	20.000	2.900	0.250
24	1.800	33.000	0.131	45.000	555.000	22.000	2.700	0.220
25	1.300	32.000	0.133	50.000	560.000	20.000	2.600	0.230
26	2.400	27.000	0.126	50.000	550.000	22.000	2.700	0.230
27	2.400	25.000	0.131	45.000	550.000	22.000	2.600	0.220
28	1.500	30.000	0.136	50.000	560.000	23.000	2.800	0.270
29	1.300	32.000	0.126	40.000	545.000	25.000	3.000	0.350
30	2.900	27.000	0.128	40.000	545.000	26.000	3.100	0.320
31	2.400	25.000	0.128	45.000	550.000	23.000	3.200	0.310
32	1.500	33.000	0.128	40.000	555.000	28.000	3.300	0.290
33	1.500	30.000	0.133	40.000	555.000	28.000	3.000	0.280

图3.1 建模数据文件

接下来选择加载已经训练好了的 BP 网络，对其进行其他状态地设定，在相应的输入框输入有效的参数进行参数的设定，并运行程序。



图 3.2 其他参数设定

运行后结果如下：

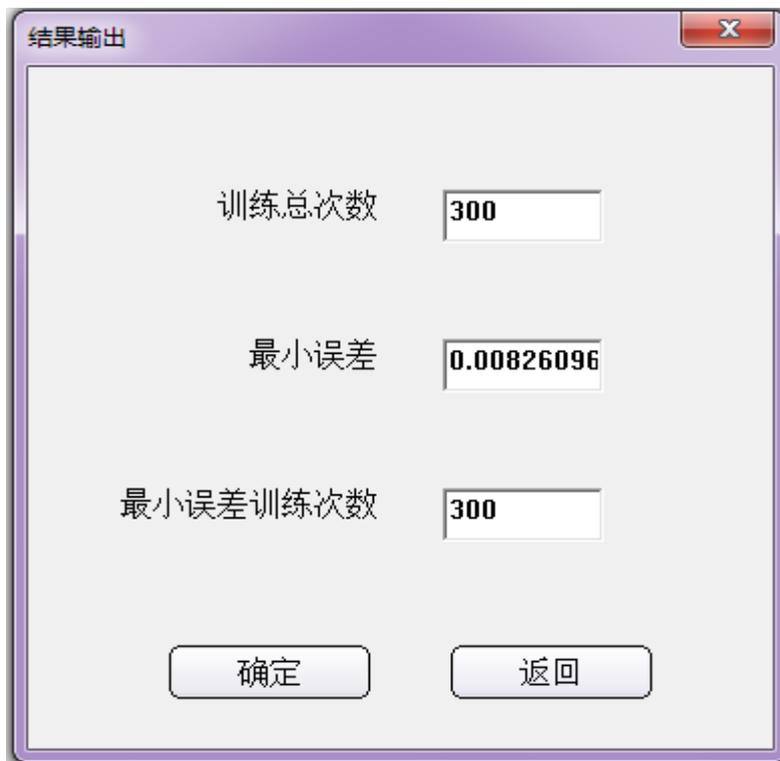


图 3.3 结果输出

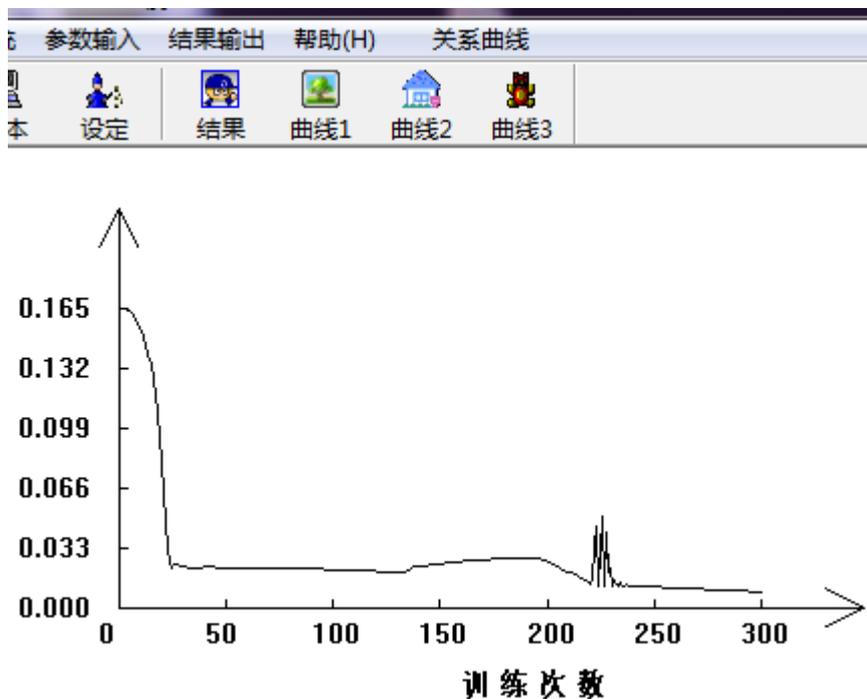


图 3.4 误差随训练次数关系图

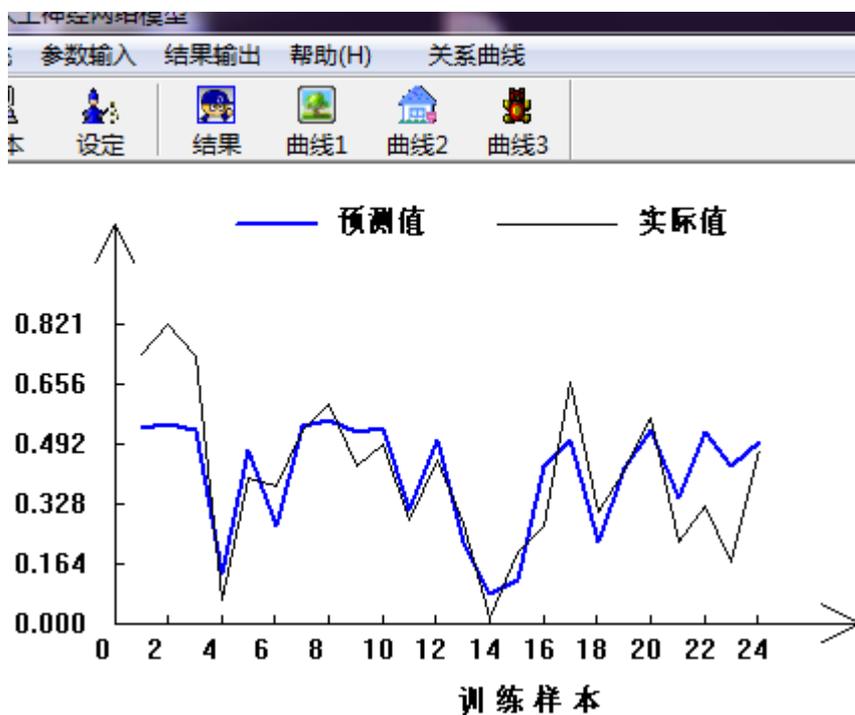


图 3.5 训练集焦炭落点归一化处理值与 BP 预测值拟合曲线

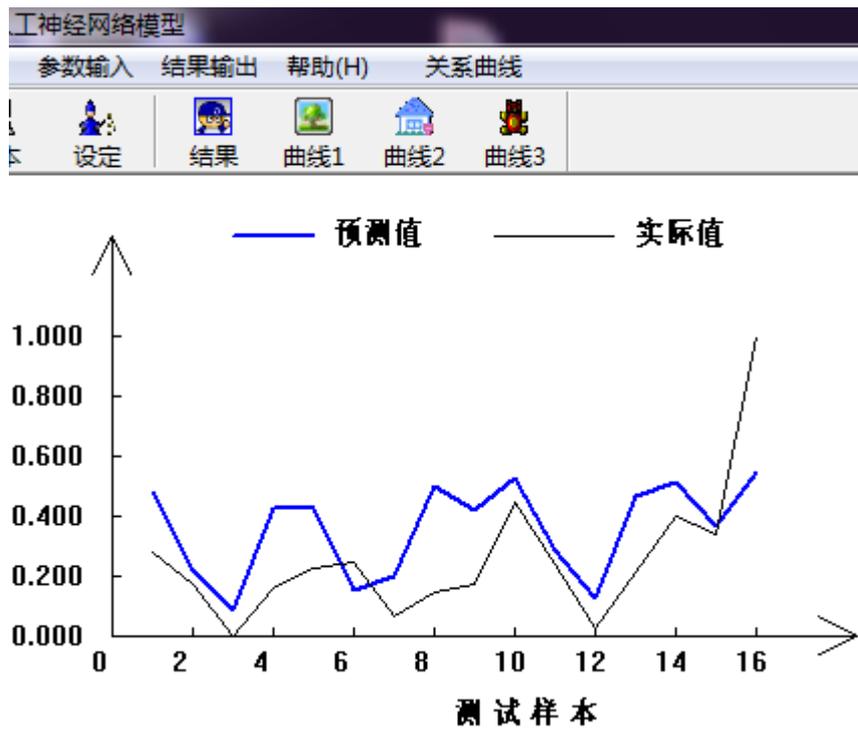


图 3.6 测试集焦炭落点归一化处理值与 BP 预测值拟合曲线

(2) 将矿石的生产数据输入系统并保存，系统自动生成预测数如图。

样本序号	料线高度	溜槽倾角	溜槽转速	节流阀开度	炉料真密度	炉料颗粒度	纵向煤气...	径向煤气...
1	1.800	33.000	0.128	50.000	1792.000	15.000	4.000	0.400
2	1.800	35.000	0.131	50.000	1792.000	15.000	4.000	0.350
3	1.800	35.000	0.133	50.000	1792.000	15.000	3.000	0.300
4	2.400	25.000	0.137	45.000	1792.000	15.000	3.000	0.320
5	1.500	32.000	0.139	40.000	1795.000	17.000	3.000	0.320
6	2.700	27.000	0.131	45.000	1795.000	17.000	3.800	0.370
7	1.800	33.000	0.126	45.000	1795.000	17.000	3.200	0.280
8	1.300	35.000	0.133	50.000	1788.000	17.000	3.700	0.340
9	1.300	33.000	0.133	40.000	1788.000	17.000	3.000	0.290
10	1.500	33.000	0.126	40.000	1788.000	15.000	3.500	0.370
11	2.700	25.000	0.137	45.000	1788.000	15.000	4.100	0.390
12	1.500	33.000	0.136	50.000	1792.000	15.000	2.800	0.240
13	2.900	25.000	0.137	50.000	1792.000	13.000	2.900	0.240
14	2.400	25.000	0.126	45.000	1795.000	13.000	2.800	0.230
15	2.700	27.000	0.131	40.000	1795.000	13.000	2.700	0.220
16	1.500	32.000	0.126	40.000	1795.000	13.000	2.700	0.210
17	2.000	35.000	0.133	40.000	1788.000	17.000	2.700	0.230
18	2.700	27.000	0.131	40.000	1797.000	17.000	3.400	0.350
19	1.800	32.000	0.137	45.000	1797.000	17.000	3.500	0.370
20	1.300	35.000	0.137	40.000	1797.000	14.000	3.300	0.320
21	2.400	27.000	0.133	45.000	1792.000	14.000	3.800	0.410
22	1.300	32.000	0.126	45.000	1792.000	14.000	4.000	0.420
23	1.300	30.000	0.131	50.000	1792.000	14.000	2.900	0.250
24	1.800	33.000	0.131	45.000	1795.000	15.000	2.700	0.220
25	1.300	32.000	0.133	50.000	1795.000	15.000	2.600	0.230
26	2.400	27.000	0.126	50.000	1795.000	15.000	2.700	0.230
27	2.400	25.000	0.131	45.000	1792.000	15.000	2.600	0.220
28	1.500	30.000	0.136	50.000	1792.000	15.000	2.800	0.270
29	1.300	32.000	0.126	40.000	1792.000	14.000	3.000	0.350
30	2.900	27.000	0.128	40.000	1795.000	14.000	3.100	0.320
31	2.400	25.000	0.128	45.000	1797.000	14.000	3.200	0.310
32	1.500	33.000	0.128	40.000	1798.000	17.000	3.300	0.290
33	1.500	30.000	0.133	40.000	1798.000	17.000	3.000	0.280

图 3.7 建模数据文件

接下来选择加载已经训练好了的 BP 网络，对其进行其他状态地设定，在相应的输入框输入有效的参数进行参数的设定，并运行程序。



学习效率	0.15	隐层数目	6
动量因子	0.1	训练样本比例%	60
训练次数	400	陡坡因子	1
最小系统误差	0.001	运行	取消

图 3.8 其他参数设定

运行后结果如下：



训练总次数	400
最小误差	0.00727761
最小误差训练次数	391
确定	返回

图 3.9 结果输出

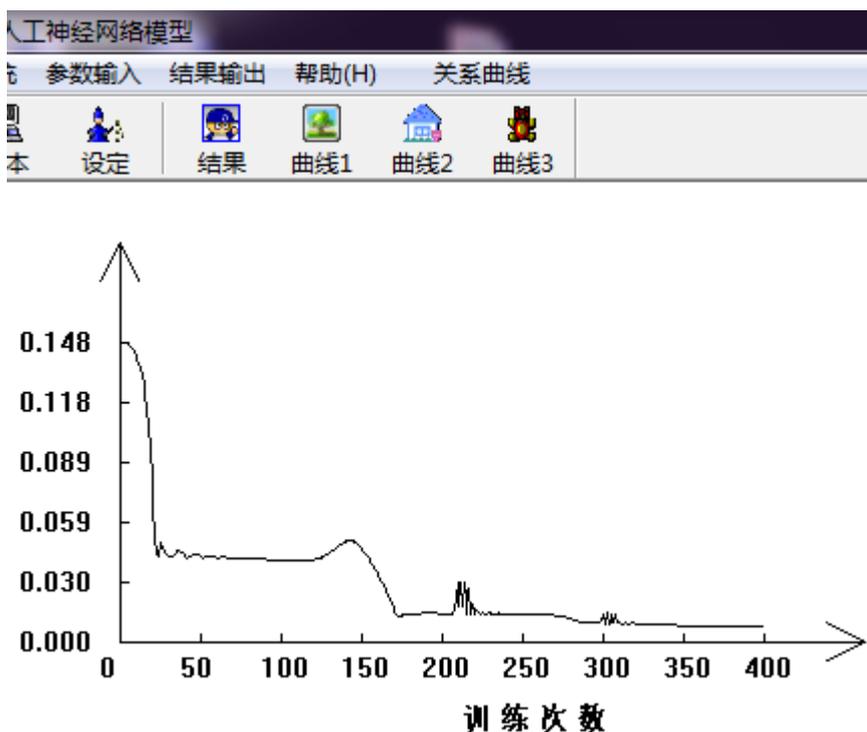


图 3.10 误差随训练次数关系图

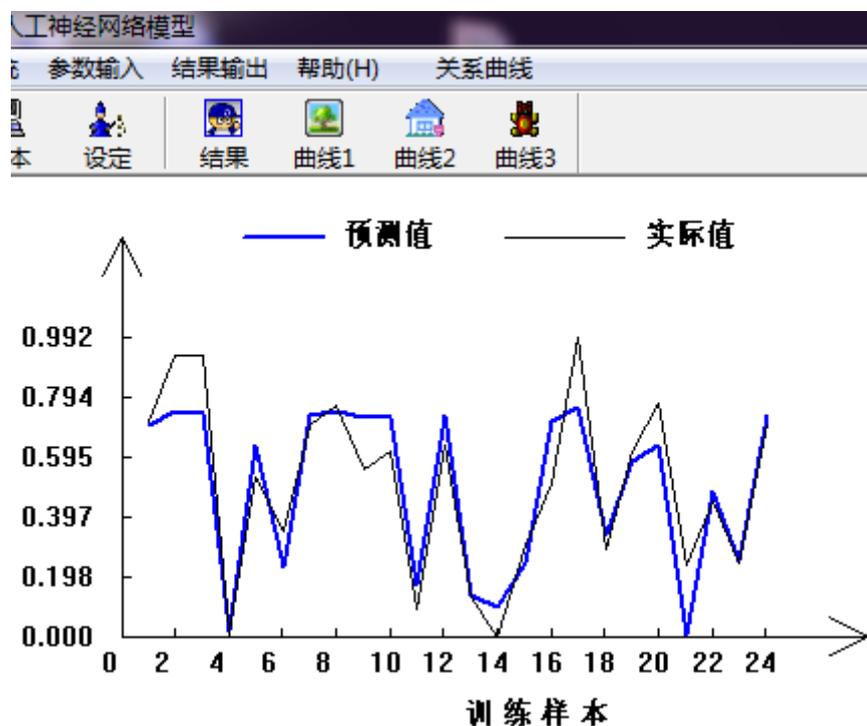


图 3.11 训练集矿石落点归一化处理值与 BP 预测值拟合曲线

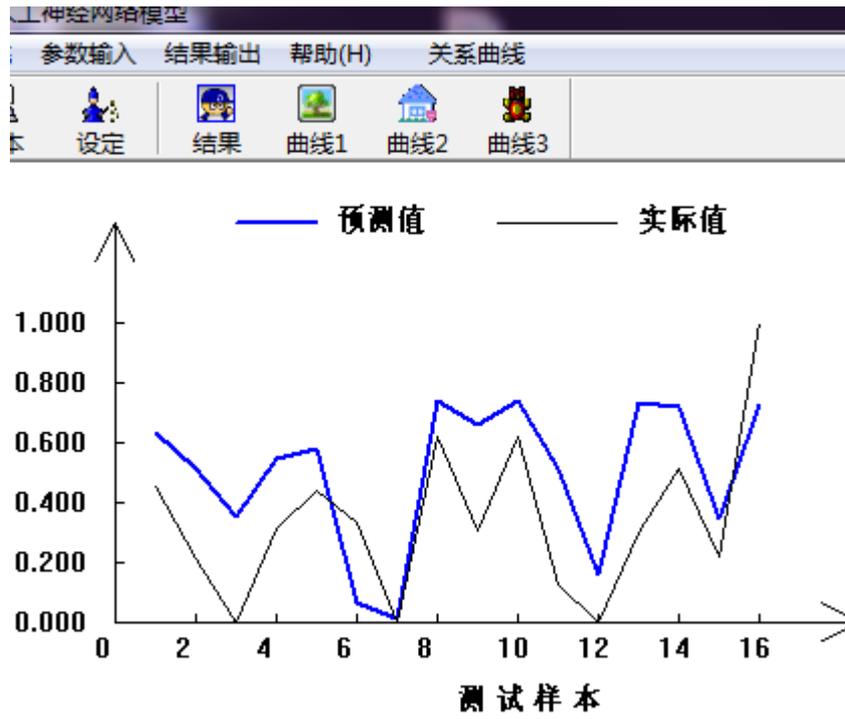


图 3.12 测试集矿石落点归一化处理值与 BP 预测值拟合曲线

## 4 结论与展望

### 4.1 结论

本课题主要研究了高炉布料时炉料的落点，建立了 BP 神经网络的炉料落点预报模型，利用 Visual C++ 编写了程序，并对软件进行了训练、测试，通过软件的运行取得了比较满意的结果。结合某钢铁公司炼铁厂高炉的实际生产数据进行了炉料落点的预报模拟的仿真实验，得出了如下结论：

#### ①分析了影响因素

选取的输入参数的好坏在很大程度上决定了预测模型预报的准确度，因此，在选择输入参数时，不但要结合操作人员的经验、高炉生产特点和实际生产情况，还要考虑各参数对炉料落点的相关性分析以及实际数据的采集条件，选取对炉料落点影响较的因素作输入参数是较好的。

本文选取料线高度、溜槽倾角、溜槽转速、节流阀开度、炉料真密度、炉料颗粒度、以及煤气流速和形状因子作为模型的输入参数，以炉料落点作为输出参数。

#### ②建立了预报模型

针对 BP 神经网络是的优点，选择了经过优化的 BP 网络作为建立预报模型的基本模型，这使得实验取得了较好的应用效果

#### ③应用结果分析

在网络初始化时，根据经验计算选取的参数并不一定适用，不一定是最终参数，在经过网络自调整后，部分设置经过优化，确定了网络结构的最终设定，之后对其运行，得出结果、拟合曲线；从图 3.4 和 3.10 可以看出，误差随着训练次数的增加，逐渐地趋近于 0；并且，通过图 3.5、3.6、3.11 和图 3.12 可以看出，图中曲线拟合得很好，所以模型的预测结果与实测结果是很接近的。

### 4.2 未来的展望

在不断的测试、应用和完善以后，相信优化的 BP 预报模型在未来的炼铁生产过程中，其测试的结果会更加的准确，这样就可以让其在各个钢铁公司的炼铁车间发挥作用，为炼出更好的铁水出一份力。“炉料落点预报模型”是高炉生产中比较难的问题，但在理论和实践方面有着重要的意义，是值得进行探讨和研究的。由于 BP 网络在炉料落点方面的研究还不是很成熟，所以就本文而言，还有很多方面需要进一步深入研究和改进，如：

①神经网络建模所建立的相当于一个灰箱模型，因为它并未探讨炼铁过程的机理，所以得出的结果还不能使人信服，这让其在应用中存在很大的局限性，因此，建立合理的炼铁物理模型是很有必要的。

②还可以进一步研究 BP 算法的理论。因为 BP 算法学习效率低、收敛速度慢等的

缺点依然存在，所以可以从这方面再做研究。

③该模型的运行，需要预先建立数据库，然后数据文件才能生成，最后加载于网络模型，数据处理及预报显然是缺乏即时性的，在新的数据的导入模式方面做研究是有着重要意义的。

## 参考文献

- [1] 李怀远, 裴汉钢, 周国钱, 杨佳龙. 武钢 6 号高炉布料实践[J]. 炼铁, 2006,(2):10-13.
- [2] 陈令坤, 陈先中. 基于料面形状特征和气流分布模式的高炉上部调剂技术研究[M]. 《冶金自动化》 2013.
- [3] 吴敏, 田超, 曹卫华. 无料钟高炉布料模型的研究与应用[J]. 控制工程, 2006,(5):490-493.
- [4] 张建良, 张雪松, 张汝旺, 郭豪, 刘一力, 苏东学, 于源浩. 无料钟炉顶多环布料料面形状的模拟[J]. 过程工程学报, 2008,(8):135-139.
- [5] 张建良, 张雪松, 国宏伟, 张汝旺. 无钟炉顶多环布料数学模型的开发[J]. 钢铁, 2008, (12):20-23.
- [6] 吴敏, 王昌军, 安剑奇, 何勇. 及预料面温度场的高炉煤气流分布识别方法[J]. 信息与控制, 2011,40 (1) .
- [7] Masatoshi AKASHI, Hiroshi MIO, Atsuko SHIMOSAKA, Yoshiyuki SHIRAKAWA, Jusuke HIDAKA, Seiji NOMURA. Estimation of bulk density distribution in particle charging process using discrete element method considering particle shape[J]. ISIJ International, 2008, (11): 1500-1506.
- [8] N.Standish. Studies of Size Segregation in Filling and Emptying a Hopper [J]. Powder Technology, 1985, (45):43-56.
- [9] William R. Ketterhagen, Jennifer S. Curtis, Carl R. Wassgren, Bruno C. Hancock. Modeling granular segregation in flow from quasi-three-dimensional, wedge-shaped hoppers. Powder technology, 2008, (179):126-143.
- [10] Takanobu INADA, Yoshimasa KAJIWARA, Tsutomu TANAKA. A mathematical model for particle size distribution In bell-type charging at blast furnace top [J]. ISIJ International, 1989, (9):761-770
- [11] Hideki KAWAI, Hiroshi YAKAHASHI, Morimasa ICHIDA. Segregation behavior for fine particles of sintered ores and coke supplied at the top of a two dimensional cold model of blast furnace [J]. ISIJ International, 2005, (8):1112-1121
- [12] Samik NAG, Mriganshu GUHA, Subhashis KUNDU, Subhash Kumar SINHA and Uttam SINGH. Mass Distribution in the Falling Stream of Burden Materials [J]. ISIJ International, 2008, (9):1316-1318
- [13] Yongfu Zhao, Stephen E. Yanga, Burden Distributing Computer Simulation for Fairfield Works No.8 Blast Furnace, 60th IRONMAKING CONFERENCE PROCEEDINGS, 2001.
- [14] Mats J. Nikus and Henrik Saxen, Model of the Ore-to coke Distribution in the Blast Furnace Shaft, 61st IRONMAKING CONFERENCE PROCEEDINGS, 2002

- [15] 经文波, 陈小雷. 无料钟高炉布料数学模型研究. 冶金自动化. 2003. 第一期.
- [16] 毕学工. 高炉过程数学模型及计算机控制. 北京: 冶金工业出版社, 1996.
- [17] 吕同冈. 宝钢高炉计算机技术的应用及开发. 宝钢技术. 1996. 第 6 期.
- [18] 林成城, 杜鹤桂, 杜钢. 高炉无料钟多环布料参数的确定. 东北大学学报(自然科学版), 总第 98 期. SUM No.98.
- [19] 李志全, 郭兰芬, 贾文君, 张红闯, 魏琼花, 尤想琴. 高炉布料动态模型系统的设计与应用[R]. 邯郸 056015.
- [20] 杜续恩. 串罐无料钟高炉布料数学模型开发与应用[A]. 鞍钢股份有限公司技术中心, 辽宁 鞍山 114009.2012.
- [21] 滕召杰, 程树森, 杜鹏宇. 高炉无料钟炉顶布料模拟程序的研究[R]. 北京科技大学 冶金与生态工程学院, 北京, 100083.
- [22] 左云波, 张怀存. 一种改进的 BP 网络快速算法[J]. 北京机械工业学院学报, 2005(3).
- [23] 韩力群. 人工神经网络理论、设计及应用[M]. 北京化学工业出版社. 2004.
- [24] 王钰, 郭其一. 基于改进 BP 神经网络的预测模型及其应用[J]. 计算机测量与控制. 2005.13(1): 39-42.
- [25] 徐月美, 张虹, 姜薇. 改进 BP 算法的研究及应用[J].2009(8).25(3):170-172.
- [26] 李翱翔, 陈健. BP 神经网络参数改进方法综述[J]. 技术分析. 2009(1):62-64.
- [27] 王晓敏, 刘希玉. BP 神经网络预测算法的改进及应用[J]. 计算机技术与发 2009(11),19(11):64-67.
- [28] 张山, 何建农. BP 神经网络的优化算法研究[J]. 计算机与现代化, 2009(1):73-75.
- [29] 胡守仁, 余少波. 神经网络导论. 长沙, 国防科技大学出版社, 1992: 15~20.
- [30] Rumelhart D E,Hinton G E,Williams R J. Learning Representations by Backpropagating Errors [J].Nature, 1986, 323: 533-536.
- [31] Lapedes A, Farber. Nonlinear signal processing using neural networks: prediction and system modeling [J].Technical Report,Los Alamos Laboratory, 1987.
- [32] Werbos P J.Generalization of back propagation with application to a recurrent gas market mode [J].Neural Networks, 1988, 1:339-356.
- [33] Varfis A, Versino C.Univariate economic time series forecasting by connectionist methods [J].IEEE ICNN.1990:342-345.
- [34] Weigend A. Predicting the future: a connectionist approach [J].Neural Networks, 1990(1):193-209.
- [35] Chakraborty K. Forecasting the behavior of multivariate time series using neural network [J].Neural Networks, 1992(5):449-461.

- [36] Thomassey S,Happirtte M.Short and mean-term automatic forecasting system application to textile logistics[J].European Journal of Operation Research,2005(1).
- [37] Fahlman S C,Lebiere C.The Cascade Correlation Learning Architecture [J].Advance in neural information processing sys-Tems,1990,2:524-532.
- [38] 袁曾任. 人工神经网络及应用. 北京, 清华大学出版社, 1999: 4~10.
- [39] 赵玉虹. 基于改进 BP 算法的安全库存量预测模型的研究. [D]浙江理工大学, 2011.
- [40] 康旭. 高炉铁水硅含量预报模型研究. [D]中南大学, 2005.
- [41] 张良均, 曹晶, 蒋世忠. 神经网络实用教程. 机械工业出版社, 2008.
- [42] 龙维, 高炉铁水硅含量预报模型的研究[D]. 重庆科技学院冶金与材料工程学院 2013.
- [43] 赵宴强, 李晓春, 李桂菊. 中国钢铁行业 CO<sub>2</sub> 排放现状及点源分布特征[J]. 钢铁研究学报, 2012,24(5): 2-4.
- [44] 毛磊, 高炉无钟炉布料实验研究[D]. 重庆大学材料科学与工程学院 2011.
- [45] 柳小桐. BP 神经网络输入层数据归一化研究. 机械工程与自动化, 2010.
- [46] 刘建信. SIGMOID 函数在连续体结构拓扑优化中的应用及 MSCNASTRAN 软件 2008.
- [47] 周亚罗. 基于模糊神经网络的高炉铁水硅含量的预测. 河北理工大学, 2007.

## 致 谢

在四年大学生活即将结束、毕业论文即将完成之际，我将我的感激和谢意诉诸笔端，以此表达我对曾经给予过我无私帮助和关怀的人们最诚挚的感谢和祝福。在此，我首先衷心感谢我的导师—高绪东老师对我的指导与帮助。在研究期间高老师从选题、论文的撰写、审稿以及生活等各方面都给予了极大的关心和支持。在学习与科研上经常和我们进行交流、指导。高老师客观严谨的治学态度和踏实、务实的工作作风、渊博的知识、高深的学术造诣、勤勉的敬业精神给了我极大的影响和帮助，将使我在今后的生活中终身受益。在此，谨向高老师致以衷心的感谢和崇高的敬意。

在论文撰写完成之际，感谢冶金与材料工程学院以及办公室各位老师在学习、生活中给予的帮助。感谢同组同学在研究及撰写论文时给予的帮助。

感谢百忙之中抽出大量时间和精力对本文进行评阅、审查，并提出宝贵意见的各位老师。

最后，特别感谢我的父母与家人。他们的支持和理解，是我最大的动力。感谢他们多年来为我的付出，自始至终都给予我的信任和鼓励，正是来自亲人们的爱与关怀，才能让我克服一切困难，实现自己的目标，并将不辜负大家的期望而继续努力。

熊路

2014 年 5 月