

分类号: TG335

学校代码: 10109

密级: 公开

太原科技大学硕士学位论文
(专业型)

硕士学位论文

THESIS OF MASTER DEGREE

(专业型)

学位论文题目: 基于深度学习的二辊斜轧穿孔机工艺
参数预测研究

英文题目: Research on process parameter
prediction of two-high cross - rolling
punch based on deep learning

研究生姓名: 孙继芸

导师姓名及职称: 王贞艳 副教授

培养单位: 电子信息工程学院

学科专业: 控制工程

论文提交日期: 2023年5月

论文答辩日期: 2023年6月4日

答辩委员会主席: 任一峰 教授

中文摘要

近些年，在科技创新发展的大环境中，钢铁行业也逐步表现出了智能化的特征。由于我国钢铁行业的飞快发展，对钢铁制品的质量在日益提升，客户对钢铁产品的需求逐渐呈现多样化和个性化，加速产品智能化生产、提升市场竞争能力和生产效益成为钢铁企业发展的迫切需求。为实现我国钢铁制造业的高质量快速发展，需要实现由制造向“智造”的转型。穿孔工艺作为无缝钢管成型过程中的首要工序，在传统的生产中，需先按照产品规格要求计算出穿孔机工艺参数将其作为设定参数，再通过试轧凭借生产经验去调整，关键工艺参数的调整决策依赖工作人员的知识储备和认知水平，调试周期长，且调试过程中需要试生产。

针对无缝钢管二辊斜轧穿孔生产工艺中轧机的工艺参数对钢管质量影响较大，传统机理公式计算的设定值精度不高的问题，本文以二辊斜轧穿孔设备的工艺参数为研究对象，通过对传统数学模型的分析，建立基于深度学习的斜轧穿孔机工艺参数预测模型，进行斜轧穿孔机各工艺参数的预测研究。论文主要内容如下：

(1)首先介绍了无缝钢管穿孔生产流程以及穿孔形变过程。依据斜轧理论确定穿孔机中影响毛管椭圆度、壁厚不均和外径大小的主要工艺参数为：轧辊间距、导板间距和顶头前伸量。将上述三个参数设为模型的输出变量，然后根据输出变量的传统计算公式并结合实际生产经验确定了六个输入变量，分别为：管坯直径、毛管直径、顶头直径、送进角、壁厚、轧辊出口锥角。

(2)提出一种基于鸽群改进 RBF 神经网络的斜轧穿孔机工艺参数预测模型。采用 RBF 神经网络对二辊斜轧穿孔机工艺参数（轧辊间距、导板间距、顶头前伸量）进行预测，并用鸽群算法对 RBF 神经网络的中心、方差（宽度）和权值进行优化。采用生产数据对该预测模型进行训练和验证，仿真结果表明，所提出的预测模型对轧辊间距、导板间距及顶头前伸量具有较高的预测精度且适用性强。

(3)提出一种基于深度神经网络的斜轧穿孔机工艺参数预测模型。利用深度神经网络建立二辊斜轧穿孔机工艺参数预测模型，在训练深度神经网络时运用小批量梯度下降法和 Adam 算法相结合进行梯度估计修正，优化训练速度。采用生产数据对所建模型进行训练和验证，仿真结果表明，采用深度神经网络建立的穿孔机工艺参数预测模型的性能优于传统数学模型和基于鸽群改进 RBF 神经网络预测模型，具有较高的预测精度。

(4)设计开发了斜轧穿孔工艺参数智能预测界面。以实际工业需求为设计目标，嵌

入多输入多输出深度神经网络的核心算法，采用 MATLAB 开发了可视化的工艺参数预测计算系统。

关键词：斜轧穿孔；穿孔机工艺参数；PIO-RBF 神经网络；深度神经网络；界面设计

ABSTRACT

In recent years, in the environment of scientific and technological innovation and development, the steel industry has gradually shown the characteristics of intelligence. Due to the rapid development of China's steel industry, the quality of steel products is improving day by day, and customers' demand for steel products is gradually diversified and personalized. Accelerating the intelligent production of products and improving market competitiveness and production efficiency have become urgent needs for the development of steel enterprises. In order to realize the high-quality and rapid development of China's steel manufacturing industry, it is necessary to realize the transformation from manufacturing to "intelligent manufacturing". As the primary process in the forming process of seamless steel pipe, in traditional production, it is necessary to calculate the process parameters of the piercer as the set parameters according to the requirements of product specifications, and then adjust them through trial rolling with the help of production experience. The adjustment decision of key process parameters depends on the knowledge reserve and cognitive level of workers, and the debugging period is long, and trial production is needed during the debugging process.

In order to solve the problem that the process parameters of the rolling mill have a great influence on the quality of the seamless steel tube in the two-roll cross-rolling piercing production process, and the accuracy of the set values calculated by the traditional mechanism formula is not high, this paper takes the process parameters of the two-roll cross-rolling piercing equipment as the research object, establishes the process parameter prediction model of the cross-rolling piercing machine based on deep learning, and makes a prediction study on the process parameters of the cross-rolling piercing machine. The main contents of this paper are as follows:

(1) Firstly, the production process of seamless steel pipe piercing and the piercing deformation process are introduced. According to the theory of skew rolling, the main technological parameters affecting the ellipticity, uneven wall thickness and outer diameter of capillary in rolling mill are: roller spacing, guide plate spacing and plug extension. The above three parameters are set as the output variables of the model, and then six input variables are determined according to the traditional calculation formula of the output variables and combined with the actual production experience, namely: tube blank diameter, capillary

diameter, plug diameter, feed angle, wall thickness and roll exit cone angle.

(2) A process parameter prediction model of cross rolling punch based on pigeon group improved RBF neural network was proposed. The process parameters (roll spacing, guide spacing and tip elongation) of the two-high diagonal rolling punch were predicted by using RBF neural network. The center, variance (width) and the connection weight between hidden layer and output layer were optimized by pigeon swarm algorithm. The model was trained and verified by using production data. The simulation results show that the proposed model has high prediction accuracy and strong applicability for roll spacing, guide spacing and head elongation.

(3) A prediction model of process parameters of cross rolling punch based on deep neural network is proposed. The deep neural network was used to establish the process parameter prediction model of two-high diagonal rolling piercer. The low batch gradient descent method and Adam algorithm were combined to make gradient estimation and correction when training the deep neural network, so as to optimize the training speed. The model was trained and verified with production data. The simulation results show that the prediction model based on deep neural network is superior to the traditional mathematical model and the improved RBF neural network based on pigeon group, and has higher prediction accuracy.

(4) Design and develop an intelligent prediction interface for process parameters of cross-rolling piercing. A visualised process parameter prediction calculation system was developed using MATLAB with practical industrial requirements as the design objective and embedding a core algorithm of multi-input and multi-output deep neural networks.

Keywords: Cross-rolling piercing; Adjusting parameters of piercer; PIO-RBF neural network; Deep neural network; Interface design

目 录

第一章 绪论.....	1
1.1 研究背景与意义.....	1
1.2 斜轧穿孔研究现状.....	2
1.3 智能算法研究现状.....	4
1.4 主要研究内容.....	5
第二章 无缝钢管二辊斜轧穿孔机.....	9
2.1 无缝钢管斜轧穿孔工艺.....	9
2.1.1 二辊斜轧穿孔生产流程.....	9
2.1.2 斜轧穿孔过程变形分析.....	9
2.1.3 斜轧穿孔变形区相关参数.....	10
2.2 无缝钢管斜轧穿孔机理论基础.....	10
2.2.1 穿孔机关键工艺参数的确立.....	10
2.2.2 斜轧穿孔机工艺参数计算模型.....	11
2.3 小结.....	12
第三章 基于 PIO-RBF 神经网络斜轧穿孔机工艺参数预测建模.....	13
3.1 数据的获取和预处理.....	13
3.1.1 实验数据采集.....	13
3.1.2 数据预处理.....	14
3.1.3 主成分分析法.....	15
3.1.4 模型预测精度指标.....	16
3.2 径向基函数神经网络.....	17
3.2.1 径向基函数神经网络及特点.....	17
3.2.2 径向基函数神经网络结构.....	17
3.2.3 径向基函数网络算法设计.....	18
3.3 基于 PIO-RBF 神经网络预测模型建立.....	19
3.3.1 鸽群优化算法.....	20
3.3.2 PIO-RBF 神经网络模型流程.....	21
3.3.3 仿真研究.....	23
3.5 小结.....	28
第四章 基于深度神经网络斜轧穿孔机工艺参数预测建模.....	29
4.1 深度神经网络的结构与算法.....	29
4.1.1 深度神经网络结构.....	29
4.1.2 小批量梯度下降法.....	30
4.1.3 深度神经网络的反向传播算法.....	31

4.2 二辊斜轧穿孔机工艺参数的深度神经网络预测模型	31
4.2.1 深度神经网络层数.....	32
4.2.2 隐含层神经元个数.....	33
4.2.3 Adam 优化算法	34
4.2.4 基于 Adam 优化算法的深度神经网络预测模型.....	36
4.3 仿真研究.....	38
4.4 小结.....	41
第五章 斜轧穿孔机工艺参数预测界面开发	43
5.1 界面开发环境.....	43
5.2 界面开发需求分析.....	44
5.2.1 界面开发的目的.....	44
5.2.2 界面的功能分析.....	44
5.3 主要功能模块设计.....	45
5.3.1 数据处理模块.....	46
5.3.2 深度神经网络训练模块.....	47
5.3.3 智能预测模块.....	48
5.3.4 预测效果可视化模块.....	49
5.4 性能分析.....	50
5.5 小结.....	51
第六章 总结与展望	53
参考文献.....	55

第一章 绪 论

1.1 研究背景与意义

制造业是国民经济的主要组成部分，它为社会提供了大量的就业机会，为国民经济的发展提供了坚实的基础。如果没有强大的制造业，一个国家的经济就会受到严重的影响，人民的生活水平将会大大降低，经济发展也会受到极大的影响。制造业不仅是国家经济的支柱，而且在贯彻落实新的发展思想、创新发展阶段、建立新的发展格局过程中，肩负着重大任务。钢铁行业在国民经济中的作用不可替代，它既是国家经济发展的重要支撑，又是国家经济发展的重要保障。习近平总书记在党的二十大报告中指出：“坚持把发展经济的着力点放在实体经济上”，“推进制造业向高端，智能，绿色转型”。在工业“4.0时代”，中国制造业向智能化的跨越式发展有着巨大的发展潜力以德国 Thyssen、日本 Nippon Steel、韩国 POSCO 为代表，国外先进钢铁企业在智能工厂的研究和实践上已经走在前列，为实现我国钢铁制造业的高质量发展，必须从传统生产方式向智能化生产方式转变，通过促进钢铁制造业数字化网络化智能化，走创新发展的道路，提质增效，使得自动化的生产装置和企业生产制造经营管理体系两部分之间的对接更加顺畅，从而达到智能化生产，以满足客户个性化定制的需要。

无缝钢管是钢铁行业中一种重要的经济型钢材，具有良好的力学性能、耐高温性和耐低温性，同时具备一定的抗冲击性。随着航天工业、机械制造等行业的创新发展以及国家经济体制的转变，无缝钢管在国防建设和国民经济中的作用日益凸显，力求将扩张生产量为主的模式转向标志于提高产品质量、尺寸精度、表面质量的稳定性以及生产效率,争取经济效益最大化，且不断满足用户产品升级和重大创新项目的需求。

斜轧穿孔法是一种最为常用的无缝钢管制造工艺。其生产方法分为带导板的二辊斜轧穿孔和三辊斜轧穿孔。而二辊斜轧穿孔又是目前热轧无缝钢管生产中常用的方法之一，在二辊斜轧穿孔生产中，金属横截面的变形是一个从圆形变成椭圆，然后再变成圆形的过程，变形过程是由工具设计和轧机调整（轧辊间距、导板间距、顶头位置等工艺参数）来确定的^[1]。因此，在轧机工具设计完成后，轧机的调整对钢管的质量影响很大，而在传统的生产中，大多是按照产品规格要求计算出工艺参数将其作为设定参数，凭借生产经验去调试，使工艺参数达到最优后再进行生产，这种方式已无法满足用户对产品高质量、多元化、个性化需求的趋势^[2]。近些年，各国研究学者在热轧带钢生产方面开展了大量的性能预测和控制研究，并建立了多种相关模型。因此，在研究穿孔过程中，针对不同规格的产品建立斜轧穿孔机工艺参数预测模型很有必要。

1.2 斜轧穿孔研究现状

钢管按照工艺方式可划分为两大类：无缝钢管和焊接钢管。无缝钢管的制造始于1886年德国曼内斯兄弟发明的两辊斜轧穿孔设备，利用穿孔设备将实心管坯穿轧成空心管坯，为无缝钢管生产创造了良好条件。无缝钢管是一种整体无接缝、可承受较强压力的长条中空圆形钢材，相对于焊管生产而言，无缝钢管有着大量的生产性投资和高昂的成本，而且生产过程复杂，但其材料具有良好的稳定性和品种适应性。无缝钢管的制造工艺是将钢坯加热到一定温度，然后再用轧辊进行挤压，最后轧制成具有一定壁厚的毛管。热轧无缝钢管的制造过程有如下几个方面：管坯准备及检查、管坯加热、穿孔、轧管、定(减)径、热处理、成品管矫直、精整、检验(无损、理化、台检)、入库。生产工艺流程如图 1.1 所示。




图 1.1 热轧无缝钢管生产流程图

Fig 1.1 Flow chart of hot rolled seamless steel pipe production

在无缝钢管生产工艺中，穿孔机是无缝钢管生产过程中一种重要的在线设备，该设备的操作质量是整个生产工艺中一个关键环节，它需要具备良好的工艺性能和可靠性，能有效满足不同行业的生产需求。因此，对穿孔机进行严格的质量控制至关重要。按照穿孔机的构造及穿孔时所产生的变形特征，穿孔方法将根据图 1.2 分类如下：

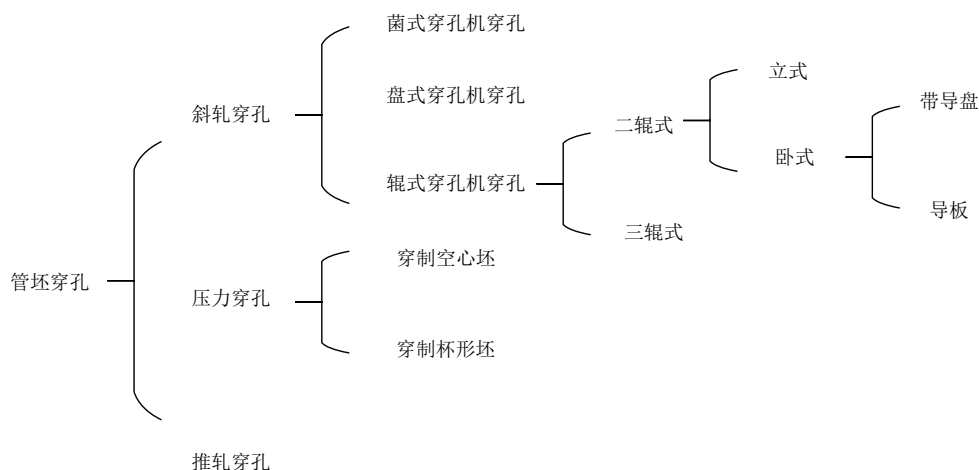



图 1.2 穿孔方法分类图

Fig. 1.2 Piercing method classification diagram

二辊斜轧穿孔机是德国曼乃斯曼兄弟发明并在 1886 年投入工业生产的，曼乃斯曼穿孔法是当前使用最多的一种穿孔方法^[3]。二辊式斜轧穿孔机类型分为：盘式、菌式、辊式。三种类型的变形区形状一致，变形过程特征也大同小异，但由于盘式和菌式两种穿孔机都受到构造条件的制约，从而限制了生产种类。所以这两种穿孔机已经很少使用了。

二辊式穿孔机主要由主传动、前台、机架、后台四大部分构成。该设备具有一个箱形的铸造机架，机架的左侧和右侧各装有两个轧辊。结合图 1.3 可见，轧辊沿着同一方向旋转，其旋转方向和倾斜角度决定了它们所加工出产品的形状和尺寸，也可以影响穿孔机的效率和性能。



1-轧辊；2-导板；3-顶头；4-顶杆；5-管坯；6-毛管

图 1.3 二辊斜轧穿孔的孔型组成

Fig 1.3 Pass composition of two-roll cross-rolling piercing

目前,国内很多机组普遍可进行半自动、全自动以及手动操作,随着生产管理水平的提高,许多企业生产线基本实现了计算机控制与管理。在一些发达国家的大部分炼钢企业都已实现了对某些工艺参数的在线智能调参。在中国的绝大多数钢厂,大部分的穿孔机是由 PLC 进行远程控制,但是这种控制方式只限于设备的启动与停止,而对工艺参数的自动调节还无法实现。由于研究手段的限制,近几年,随着人工智能的飞速发展,为实现穿孔机自动控制提供了广阔的前景,文献[4]从热传导和金属流动等基本理论出发,提出了一种基于金属塑性变形模型用于穿孔轧制过程中。文献[5]分别建立了多线性主成分分析模型和多态 MPCA 模型,检测穿孔过程并检测故障。文献[6][7]利用有限元和神经网络结合方法建立了斜轧穿孔的质量模型。文献[8]利用有限元模型来改进穿孔机的操作。文献[9]通过标准化准则确定了损伤函数的分布,模拟了穿孔过程。文献[10]研究了顶头对穿孔过程的影响,使用 DeForm 软件模拟了穿孔。文献[11]从毛管质量的角度出发,利用三维钢塑性有限元法对斜轧穿孔工艺进行仿真和分析,在此基础上对变形区的结构进行了优化设计。文献[12]开发了一种监测无缝钢管穿孔时出现的偏心率的方法。文献[13]结合工业实测数据将人工神经网络 BP 算法应用于斜轧穿孔模型中,与理论计算结果比较得到将人工神经网络算法和斜轧穿孔工艺相结合可以有效地处理钢管成品的质量问题。文献[14]也提出了基于灰色关联分析的 PSO-BP 神经网络模型解决斜轧穿孔的管形预测问题,并应用 MATLAB 软件开发了穿孔工艺模型参数预测系统。上述工作在斜轧穿孔方面取得一些较好的预测效果,为实际生产中工艺参数的设定和孔型的最佳制定提供一种可行的方法。上述工作在斜轧穿孔方面取得一些较好的预测效果,但针对斜轧穿孔设备的工艺参数的预测研究鲜有报道。目前仍采用依据轧制机理,结合生产经验加以整理,从理论到实践进行分析验证和导出主要工艺参数的理论公式以供小型无缝钢管生产使用^[15]。

1.3 智能算法研究现状

随着无缝钢管的普及,不仅可以满足不同行业的需求,人们对无缝钢管的质量要求也日益提高。在我国智能制造技术于钢铁行业中的应用已经相对广泛,为钢铁行业的发展带来较大的改善,也为钢铁行业智能化发展创造了有利条件^[16]。在计算智能化不断发展的今天,很多学者都在试验新的算法,其中神经网络算法、遗传算法等启发性的研究方法正朝着实用方向发展^[17]。例如潘孝礼^[18]等在实验中表明采用步进均值子时段 MPLS 建立连轧荒管质量预报模型的可行性和有效性;陈鑫等依据轧制传统工艺理论并结合传统经验分析轧制生产机理来建立标准 BP 神经网络模型,通过模拟试验,证明了所建模型的准确度很高,能够很好地适应工业现场的需求,将理论与智能的结

合更近了一步^[19]；M. Bagheripour 将三维有限元方法和人工神经网络结合来提高轧制力和轧制力矩的预测准确性^[20]；LEE D 等利用长短时记忆网络的在线学习功能，实现了对热轧轧制力的预报，提高了模型的预测精度^[22]；刘欣玉等针对轧制力预测，通过 MATLAB 构建了 BP 神经网络模型，利用 BP 神经网络提高预测精度^[23]。YANG J M 等对铝热连轧轧制力模型进行了深入研究，提出应用遗传算法对 BP 神经网络进行结构优化设计，构建了一种新型的轧制力智能模型并对其进行分析，实验证实将神经网络与智能算法结合可提高预测精度^[24]；然而这些算法的运用相对复杂，需要设定的参数较多，因此限制了它的广泛范围。近几年，群体智能算法越来越受到广泛关注，这类算法原理简单，仅需要设定少量的参数就能获得更好的优化效果。例如杨景明等提出了一种基于改进粒子群算法的 RBF 神经网络应用于轧制力的预测，比传统的粒子群优化 RBF 神经网络预测精度更高^[25]。WANG Z 等^[26]采用粒子群算法优化标准 BP 神经网络，经数据验证 PSO-BP 神经网络模型比传统 BP 神经网络模型的预测精度高，为轧制力的高精度预测提供了新的方法。文献[27]将轧制机理和深度学习模型相结合，实现精轧宽度的高精度预测；马威^[28]等结合工业大量的轧制数据成功建立了基于深度学习框架的深度前馈神经网络模型，为轧制力以及板带厚度研究领域提供了新的研究方向。这些方法都可以借鉴到热轧无缝钢管的模型预测领域。

在国内，尽管对钢管加工过程中的品质规范与控制的研究起步较迟，但是，伴随着钢管生产的不断发展，其相关的理论和技术也得到了快速的发展，从简单的加工到复杂的制造，从结构设计到质量控制，从机械设计到软件应用，以及相关技术研究和开发也都取得了重大进展，但我们并不满足。我国的学术界和科研工作者还在为提高钢管的生产质量水平而不断地寻求更好的方法。

1.4 主要研究内容

在分析了国内外无缝钢管的发展现状后，对无缝钢管制造的主要工序—穿孔进行了清晰的说明，并针对无缝钢管二辊斜轧穿孔生产工艺中轧机工艺参数对钢管质量影响较大，传统机理公式计算的设定值精度不高的问题去研究解决。具体研究内容如图 1.4 所示：

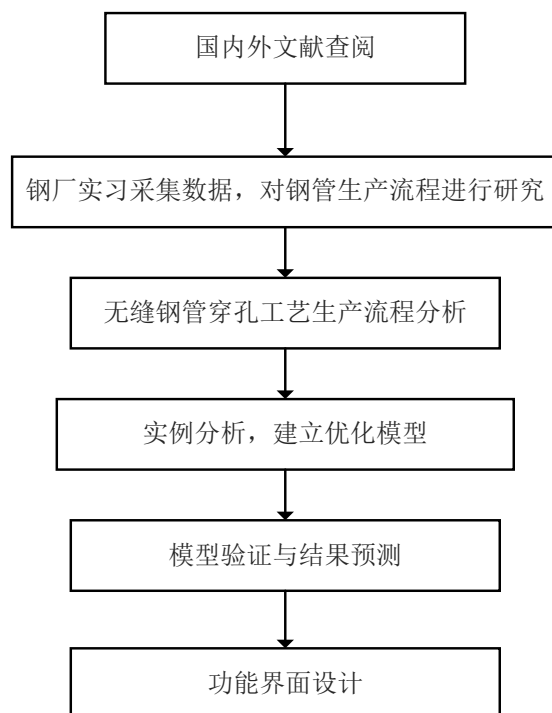


图 1.4 总体研究内容

Fig 1.4 Overall research content

第一章 阐述了课题的研究背景和意义，介绍了穿孔机的发展概况。整理了国内外关于无缝钢管生产工艺等方面的研究现状以及生产过程，确定本文研究的主要内容。

第二章 通过简单介绍对无缝钢管斜轧穿孔工艺流程的分析，在对穿孔变形区介绍的基础上，确立了传统的二辊斜轧穿孔机工艺参数数学模型及主要特征参数。以提取的3个主要因素（轧辊距、导板距、顶头前伸量）作为模型的输出，通过对这三个输出参数的计算公式推理确定将管坯直径、毛管直径、顶头直径、送进角、壁厚、轧辊出口锥角等6个参数作为斜轧穿孔机工艺参数预测模型的输入。

第三章 提出了一种基于 PIO-RBF 神经网络的斜轧穿孔机工艺参数预测模型。以二辊斜轧穿孔机工艺参数为研究对象，现场采集某无缝钢管厂生产数据，以此建立基于聚类分析的 RBF 神经网络的斜轧穿孔机工艺参数预测模型。利用鸽群优化算法优化 RBF 神经网络参数，进一步改善工艺参数的预报准确率，并基于 MATLAB 软件对该模型进行了仿真。与基于聚类分析的 RBF 神经网络模型的预测效果相比，仿真结果表明，基于鸽群优化算法的 PIO-RBF 神经网络模型的预测效果更好。

第四章 提出一种基于深度神经网络的斜轧穿孔机工艺参数预测模型。采用深度神经网络算法结合数据训练集建立斜轧穿孔机工艺参数预测模型，并融合小批量梯度下降法（MBGD）和 Adam 优化算法来提高模型的精度和训练速度。同时在 MATLAB 平

台仿真，仿真结果表明，该模型预测效果良好，优于传统数学模型和 PIO-RBF 神经网络模型，更适合用于指导实际生产。

第五章 设计开发了无缝钢管斜轧穿孔机工艺参数预测系统。基于 MATLAB 的 APP 平台以深度神经网络算法模型为核心，开发了一个可视化的斜轧穿孔机工艺参数预测界面，可为无缝钢管斜轧穿孔生产过程中穿孔机的工艺参数设置提供指导。

第六章 对论文中提出的预测方法以及开发的预测界面进行总结，并对下一步工作进行展望。

第二章 无缝钢管二辊斜轧穿孔机

在无缝钢管生产过程中，穿孔机是最为关键的一台设备，它的运行好坏直接关系到产品的品质以及整条生产线的生产率。圆管坯是一种常见的金属结构，在穿孔过程中主要通过对其进行塑性变形工艺加工使圆管坯内部产生孔洞。由于管坯的穿孔具有很大的复杂性，牵扯到了许多复杂且变化的工艺参数。因此，正确地设计穿孔机工具有着重要的意义。任何一个模型的建立，在搭建前少不了对生产工艺的了解。本章通过分析若干工艺参数对毛管椭圆度、壁厚不均和外径大小的影响并结合无缝钢管二辊斜轧穿孔生产过程和斜轧穿孔过程的形变分析，选取主要关键因素。

2.1 无缝钢管斜轧穿孔工艺


2.1.1 二辊斜轧穿孔生产流程

二辊斜轧穿孔的生产首先在环形加热炉中将原料加热至轧制温度以后，圆坯由轧辊的锥形入口段推力进入轧机，斜轧时穿孔运动特征如下：穿孔机轧辊在相同方向上转动，轧辊轴线与轧制线形成一定角度，热实心管坯在进入轧辊后，在与轧辊的摩擦作用下反方向转动，在轧辊轴线与管坯轴线轧制轴线形成一定角度(前进角)的情况下，管坯在轴向上发生偏移移动，从而使芯棒形成螺旋运动穿过空心毛管。

2.1.2 斜轧穿孔过程变形分析

斜轧穿孔过程中，主要有两种变形形式：基本变形和附加变形。基本变形是指金属在轧制过程中由于受外部压力，表面所发生的形状改变，这些改变大部分取决于变形区的工具设计和穿孔机的工艺参数调整。附加变形是金属在外力作用下，由于内部变形不均匀产生的变形，由于内部变形会引起内部应力的增加，容易导致毛管内外表面上和内部产生缺陷等。

穿孔变形区主要由轧辊、顶头和导板等工具组成。变形区按照穿孔时所起的作用，可划分为四个阶段：穿孔准备区、穿孔区、平整区和归圆区等^[3]。在变形过程中四个区域段之间存在一定的关联，它们相互影响，相互作用，共同构成一个完整的变形系统。在这一变形系统中，金属的横截面由最初的圆形变形为椭圆形，最后再到圆形，这一过程是由内到外反复连续变化的过程。图 2.1 表示斜轧穿孔过程中变形区的分布情况。



1-穿孔准备区；2-穿孔区；3-平整区；4-归圆区

图 2.1 斜轧穿孔变形区

Fig 2.1 Cross-rolling piercing deformation zone

在穿孔区内较早地将管坯与导板相接，能够使管坯的横向变形迅速得到控制，同时降低毛坯的椭圆程度。但如果管坯和导板提前接触，则管坯的轴向移动阻力和转动阻力会加大。在穿孔区中，轧辊和顶头接触的距离会慢慢减小，在这个区域内金属发生塑性变形的同时利用导盘来阻止金属发生横向变形并纵向拉伸金属材料。在平整区中对于金属的压下量相对较小，所以主要用来修整管壁表面质量及尺寸精度。归圆区的目的是通过轧辊把椭圆形的断面毛管靠轧辊以螺旋的方式把毛管转圆。

2.1.3 斜轧穿孔变形区相关参数

(1)轧制带处压下量：表示管坯直径在轧制带处发生的变化，其取值范围在 9~12%。

(2)直径扩径率：一般范围在 3~40%，如果扩径率超出一定范围，容易造成内外表面缺陷或导致壁厚不均更加严重。

(3)前进角：前进角的大小决定轧制力的大小，随着前进角的增大，在穿轧过程中管坯同轧辊之间接触摩擦力就会减小，这样可以有效地缩短轧制时间，提高生产效率。

(4)延伸系数：如果延伸系数越大，说明毛管的壁厚越薄。在实际生产中，可以根据不同的需求来选择合适的延伸系数，以达到最佳效果。

(5)轧辊间距：两个轧辊轧制带之间的距离。

(6)导板间距：两个导板过渡段之间的工作距离。

(7)顶头前伸量：顶头顶尖从轧辊中心线延伸出去的距离。

(8)孔型椭圆度系数：导板间距与轧辊间距的比值。

2.2 无缝钢管斜轧穿孔机理论基础

2.2.1 穿孔机关键工艺参数的确立

在无缝钢管标准中，几何尺寸是衡量无缝钢管质量极其重要的因素。其产品几何尺寸精度主要表现为：

(1) 钢管壁厚精度偏差

无缝钢管壁厚偏差的控制体现了生产装备及工艺调整的整体水平，也反映了产品的质量水平。因此，壁厚精度是无缝钢管制造工艺中评价钢管质量的重要指标之一。

(2) 钢管外径精度

热轧无缝钢管的外径精度与外径控制方法、现场生产条件和生产因素等有关。同时也涉及到了减径机的孔形精确性，以及各个机架的变形量的平衡调节。

(3) 钢管椭圆度

钢管椭圆度是指钢管表面的一种特征，其椭圆度值是通过测量钢管的圆形截面上最大直径和最小直径的差来定义。

由穿孔变形过程可以清楚看到，斜轧穿孔时，轧件的变形量很大，影响毛管尺寸精度的工艺因素很多。因此，轧机调整是非常重要的，而且较为复杂。其中，轧机的工艺参数：轧辊间距、导板间距和顶头前伸量是影响毛管椭圆度、壁厚不均和外径大小的主要因素。

(1) 轧辊间距：是指两个轧辊的轧辊带之间的距离，是重要的工艺参数之一。轧辊间距的大小对毛管的壁厚起决定性因素；例如轧辊的间隔变小，则整个变形区就会延长，并且与之对应的部分区域也会延长。

(2) 导板间距：毛管的外径主要受导板间距的影响。例如当导板间隔增大时，其横向变形增大，纵向变形降低。在斜轧变形区内，导板间距和轧辊间距之比决定着工件的椭圆程度，椭圆程度越大，毛管内表面出现裂缝的可能性越大。

(3) 顶头前伸量：是指当顶头进入两个轧辊所在区域时，顶头头部的位置距离轧辊轧制带的长度。若顶头位置前移，那么穿孔准备区缩短。顶头前伸量对毛管外径和壁厚存在很大的影响；

因而，将轧辊间距、导板间距、顶头前伸量设为斜轧穿孔工艺参数预测模型的输出变量。

2.2.2 斜轧穿孔机工艺参数计算模型

关于计算工艺参数轧辊间距、导板间距、顶头前伸量的公式文献^[28]已提出：

(1) 轧辊间距 b

$$b = (1 - \delta) d_z \quad (2.1)$$

式中：

δ —为压缩带处压缩量，根据经验数据 δ 为 15% ~ 16%，取 $\delta = 15\%$ ；

d_z —管坯直径，mm；

轧辊间距的大小与压缩带处的压缩量坯料直径有关。

(2)导板间距 l

$$l = b \times \left[1 + \frac{0.75 \times (d_z - b)}{d_z} \times \frac{d_0}{d_z} \right] \quad (2.2)$$

式中： d_0 —毛管直径， mm ；由式(2.2)可知，导板间距的计算取决于轧辊间距、管坯直径和毛管直径值。

(3)顶头前伸量 y

$$D_t = d_m - \Delta d_k = d_m - (0.075 - 0.00135s_0) d_0 \quad (2.3)$$

$$y = (0.8 \sim 1) d_1 + (1 \sim 2.5) D_t + \frac{(1.5 \sim 1.75) \pi}{2} \times \frac{\eta_0}{\eta_T} d_0 \tan \beta - \frac{D_t + 2s_0 - b}{2 \tan \alpha_2} \quad (2.4)$$

式中：

D_t —顶头直径， mm ；

d_m —毛管内径， mm ；

s_0 —壁厚， mm ；

d_1 —顶头鼻部直径， mm ；

β —送进角，度； α_2 为轧辊出口锥角，度；

η_0 —轴向滑移系数； η_T 为切向滑移系数。

由式(2.3)和式(2.4)可以看出，顶头前伸量的计算较复杂，影响因素较多。

上述三个工艺参数的计算公式中，在计算轧辊间距时压缩带上的压缩量应以经验资料为依据；而导板间距和顶头前伸量的计算又与轧辊间距有着密切的联系；但这些参数计算只是初步结果，可作为设定值。从计算模型中总结可以得出影响三个工艺参数的可测量因素有管坯直径、毛管直径、顶头直径、送进角、壁厚、轧辊出口锥角。而压缩量和滑移系数则需要根据经验和调试确定。

2.3 小结

本章主要介绍了无缝钢管斜轧穿孔工艺，其中包括二辊斜轧穿孔的生产过程、穿孔过程中的变形分析以及穿孔机的三个主要工艺参数。分析了穿孔变形区相关参数对毛管质量的影响，确立了影响成品质量的关键工艺参数（轧辊间距、导板间距、顶头前伸量），选取其作为模型的输出。结合传统数学模型分析与实际生产过程，将穿孔机调节的关键工艺参数：毛管直径、管坯直径、顶头直径、壁厚、送进角、轧辊出口锥角用作模型的输入。

第三章 基于 PIO-RBF 神经网络斜轧穿孔机工艺参数预测建模

在传统的生产中，大多是根据产品规格要求按照传统数学模型计算出工艺参数将其作为设定参数。由于斜轧穿孔生产过程复杂，各影响因素之间具有多变量、非线性、强耦合的关系，所以难以保证工艺参数的计算精度。采用传统穿孔机工艺参数建模方法的计算结果与实际情况略有偏差。与之相比，神经网络算法因对复杂系统进行建模时具有显著的优势，而应用于非线性系统的建模中。因此，本章提出一种基于 PIO-RBF 神经网络的斜轧穿孔机工艺参数预测模型来预测斜轧穿孔机工艺参数。

3.1 数据的获取和预处理

3.1.1 实验数据采集

图 3.1 是某钢厂连轧钢管生产线，实验设备是斜轧穿孔机，将坯料放入环形加热炉中，使其达到最高温度 1280°C，然后用穿孔机将其穿成中空毛管，穿孔机组将热管坯通过进口台传送至主机座进行穿孔轧制，主机座采用锥形辊以及水平排列的导板，然后通过主传动装置实现管坯的咬入和穿孔。



图 3.1 现场生产设备

Fig 3.1 Field Production Equipment

从某钢厂进行实际测量和采集材料为 304L 的 189 组数据作为实验数据，用于穿孔机工艺参数预测建模，每组数据中包含 6 个输入变量（管坯直径、毛管直径、顶头直径、送进角、壁厚、轧辊出口锥角）和 3 个输出变量（轧辊间距、导板间距、顶头前伸量）。所得实验数据集的部分组成如表 3.1 所示。

表 3.1 部分实验数据集组成

Tab. 3.1 Composition of some experimental data sets

工艺参数	第一组	第二组	第三组	第四组	第五组
管坯直径	100	110	110	90	110
顶头直径	82	94	95	62	75
毛管直径	107	114	115	100	115.5
出口锥角	3.5	3.5	3.5	3.5	3.2
送进角	10	10	8	8	8
壁厚	7	8	4.5	17	18
轧辊间距	89	97	94	87	99
导板间距	98	106	104	100	108
顶头前伸量	60	53	63	50	56

3.1.2 数据预处理

数据的预处理主要对 3.1.1 节所获得的样本数据进行归一化处理。由于各类数据样本的测量单位不一样且不是同一量级，若直接参与到模拟计算中，会对最后的预测结果产生不利的影响。一般情况下，对全部变量执行归一化处理，这样会使将要进行运算的变量无论之前数值多少都能统一映射在[-1,1]区间内，把有量纲的表达式经变换化为无量纲的表达式，该方法不仅提高了模型的收敛性，而且还缩短了模型的学习时间。下面给出数据归一化处理的公式：

$$x' = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \quad (3.1)$$

式中： x_{\min} 和 x_{\max} 分别表示样本最小值和最大值； x' 表示样本归一值； x 表示样本原始值。

对样本数据进行[-1,1]规范化处理，具体采用以下映射：

$$f : x \longrightarrow y = \frac{2(x - x_{\min})}{(x_{\max} - x_{\min})} - 1 \quad (3.2)$$

当我们使用归一化数据进行预测时得到的是归一值，而评价一个预测模型的性能应该是实际值。因此，在运算结束之后，将输出值进行反向归一化，恢复实际数值。方式如下：

$$x = (x_{\max} - x_{\min}) \cdot x' + x_{\min} \quad (3.3)$$

通过反归一化处理还原真实数值所采用的映射如下：

$$f : y \longrightarrow x = \frac{1}{2}(x_{\max} - x_{\min})y + \frac{1}{2}(x_{\max} + x_{\min}) \quad (3.4)$$

该批生产数据中毛管直径为 $\phi 75 \sim \phi 247mm$ ；壁厚为 $7 \sim 22.5mm$ 的无缝钢管；所用的坯

料直径为 $\phi 76 \sim \phi 250\text{mm}$ 。将实际采集到的数据通过归一化处理之后的部分数据列举如下表 3.2 所示。

表 3.2 归一化后的样本集

Tab. 3.2 Normalized Sample Set

样本 变量	1	2	3	4	5
管坯直径	-0.5930	-0.8837	-0.7093	-0.8837	-0.7093
顶头直径	-0.5038	-0.8797	-0.6992	-0.8797	-0.6241
毛管直径	-0.5747	-0.8621	-0.6552	-0.8621	-0.6552
出口锥角	-1.0000	-1.0000	1.0000	-1.0000	1.0000
送进角	1.0000	1.0000	0	1.0000	1.0000
壁厚	-0.8235	-0.8235	-0.8235	-0.8088	-0.8824
轧辊间距	-0.5443	-0.8608	-0.7089	-0.8481	-0.6456
导板间距	-0.5385	-0.8580	-0.6331	-0.8462	-0.6450
顶头前伸量	-0.5775	-0.6901	-0.6901	-0.5775	-0.6761

3.1.3 主成分分析法

主成分分析法是一种多变量统计方法，通过数学处理降维，将实际情况中的多个高度相关的指标进行数据融合，形成一组相互无关且新的综合指标从而取代原来的指标。用于减少输入数据特征间的冗余性，对输入数据进行 PCA 处理后，可除掉各个成分之间的相关性，各特征之间相关程度降低。

主成分分析^[29]的主要原理是寻找一组能最大程度表征数据方差的正交向量，把高维数据转换为一组低维数据，对其进行降维得到一个新的数据矩阵。

设 $X = (x_1, x_2, \dots, x_p)$ ，其中 x_i 是 N 维矢量，则 PCA 变换为：

$$Y = A^T (X - \bar{X}) \quad (3.5)$$

其中 $\bar{X} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_p)$ ， $\bar{x}_i = \frac{1}{N} \sum_{j=1}^N x_{ij}$ 为各矢量均值；而 $A = (u_1, u_2, \dots, u_d)$ 是由 X 的斜方

差矩阵 $\sum_x = E \left\{ \left(X - \bar{X} \right) \left(X - \bar{X} \right)^T \right\}$ 按由大到小的特征值 λ_i 对应的特征值向量 u_i 组成。

其 PCA 重构为：

$$X^* = AY \quad (3.6)$$

通过 PCA 转换之后，基本消除了 Y 的各矢量间的关联度。

以 MATLAB 为实验平台，使用 “pca” 函数进行数据降维处理，其所采用的方式如下：

$$[\text{coeff}, \text{score}, \text{latent}] = \text{pca}(\text{train_x}') \quad (3.7)$$

式中：

train_x': 经过归一化处理后的输入训练集数据;

coeff: 主成分系数矩阵, 也叫做转换矩阵, 是理论中的原数据 X 矩阵所对应的协方差矩阵的全部特征向量构成的矩阵, **coeff** 的每一列代表一个特征值所对应的特征向量, 列的排列方式对应由大到小的特征值;

score: 使用 PCA 转换后的新数据矩阵, 大小和 X 一致;

latent: 由高到低排列原数据 X 所对应的协方差矩阵的特征值。可根据每个值占总数($\text{sum}(\text{latent})$)的比例知道该维度的信息量多少。

将“pca”函数对归一化处理后的输入样本数据进行数据降维后, 部分数据列举如下表 3.3 所示。

表 3.3 PCA 处理后的输入样本集

Tab. 3.3 Input sample set after PCA processing

样本 变量	1	2	3	4	5
管坯直径	-1.1955	3.5035	3.6927	-11.9067	0.7901
顶头直径	-9.5200	3.0062	2.9371	2.4830	-2.2070
毛管直径	-0.9780	0.4947	0.3111	-0.5799	0.5995
出口锥角	-0.4198	1.2171	1.0979	-2.1328	0.8951
送进角	-1.0841	0.2755	0.3146	-0.4311	-1.6824
壁厚	-0.1116	-0.0357	-0.0405	-0.0204	-0.0361

3.1.4 模型预测精度指标

本文研究的斜轧穿孔机工艺参数预测问题属于回归问题, 可以通过预测值与真实值的偏差情况来反映模型的预测精度。本文选取的评价指标包括均方误差(MSE)、均方根误差(RMSE)、决定系数(R^2), 这 3 项评价指标值越小, 代表预测精度越高。

均方误差能够反映预测值与真实值差的平方关系, MSE 的计算公式如下:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - y_i)^2 \quad (3.8)$$

式中: N 为样本数; Y_i 为 i 第各样本的真实值; y_i 为第 i 个样本的预测值。

均方根误差能够表示预测值与真实值之间的关系, RMSE 的计算方式如下:

$$RMSE = \sqrt{MSE} \quad (3.9)$$

决定系数可用来衡量模型预测能力的好坏, 其取值范围为 $[0,1]$ 。

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - y_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (3.10)$$

3.2 径向基函数神经网络

3.2.1 径向基函数神经网络及特点

径向基函数神经网络(Radial Basis Function Neural Network, RBF 神经网络), 可以将输入空间中的非线性映射到一个更简单的空间, 从而实现对非线性映射的局部逼近。在径向基函数网络中使用一种局部激励函数, 避免了大的外推误差对网络输出的可靠性。径向基函数网络学习速度快, 能够以任何精确度逼近任一连续的函数, 且具有唯一最优逼近特征, 不存在局部极小值, 适用于实时在线控制。

在对非线性动态系统识别时, 常用的前馈神经网络为 BP 网络与 RBF 网络, 从表 3.4 中可以看出, RBF 神经网络在一些方面要优于 BP 神经网络。

表 3.4 BP 网络和 RBF 网络对比

Table 3.4 Comparison between BP Network and RBF Network	
BP 神经网络	RBF 神经网络
全局逼近	局部逼近
隐层自变量: 输入与权向量的内积;	隐层自变量: 输入与中心向量的距离;
激励函数: S 型函数	激励函数: 径向基函数
可以有多个隐层	只有一个隐层
训练速度慢	训练速度快

RBF神经网络具有很强的非线性拟合力, 从而实现对系统进行建模和预测, 因其为单隐层网络, 所以学习收敛速度快。此外, RBF神经网络还具有强大的非线性处理能力, 可以解决复杂问题, 帮助人们更好地理解 and 处理复杂的数据, 拥有良好的推广能力。

3.2.2 径向基函数神经网络结构

以毛管直径、顶头直径、送进角、轧辊出口锥角、管坯直径、壁厚作为神经网络的输入, 轧辊间距、导板间距、顶头前伸量作为网络的输出, 其原理拓扑结构如图3.2所示。




图3.2 RBF神经网络结构示意图

Fig. 3.2 schematic diagram of RBF neural network structure

第1层是输入层。所述层的每一个节点以直接相连的方式实现输入向量的数据传送，节点数为 m 。

第2层是隐含层。在隐含层中，神经元的转换函数是径向基函数，该函数可以用来拟合任意高维函数，可以帮助我们理解复杂的高维数据并有效地进行分析处理。本文选取的径向基函数为高斯函数，函数表达式为：

$$R_i(X - C_i) = \exp\left[-\frac{\|X - C_i\|^2}{2\sigma^2}\right] \quad (3.11)$$

式中： $X = [x_1, x_2, \dots, x_m]$ ； C_i 表示相应于隐含层所在第 i 个神经元的中心矢量，该中心矢量包括隐含层第 i 个神经元至全部输入层神经元的中心分量，即 $C_i = [C_{i1}, C_{i2}, \dots, C_{im}]$ ； $\|X - C_i\|$ 为 X 到 C_i 的欧氏距离； σ^2 为高斯函数的方差。则输出函数 y_j 为：

$$y_j = \sum_{i=1}^m w_{ij} R_i(X - C_i) \quad (3.12)$$

式中： y_j 为第 j 个神经元在输出层的输出数值即为穿孔工艺参数的预测值， w_{ij} 为隐含层所在的第 i 个神经元和输出层第 j 个神经元之间的连接权重。

3.2.3 径向基函数网络算法设计

RBF 神经网络结构设计对其性能有重大的影响，隐含层节点的设定是 RBF 神经网络结构设计中重要的一部分，隐含层所涉及的参数的选取分别有：隐层节点数目、中心值、方差（宽度）及隐含层到输出层之间的连接权值。

(1)网络的隐层节点的个数不仅影响网络的计算复杂度，还影响网络的泛化性能。若隐含层节点数目太小时，将导致欠拟合现象；若隐含层节点数目太多，则会产生过度拟合，从而影响网络的推广性能。

(2)隐含层中心点位置的选择也很重要。若隐含层的中心位置选择不当，不仅会影

响映射效果，而且不利于输入空间进行拟合。

(3)隐含层中心的宽度是影响分类预测能力的一个重要因素。若宽度过小时，会降低类别识别的准确性；而宽度过大时，则使得网络的泛化能力下降。

(4)隐含层和输出层之间的权重是关系到整个映射效果的好坏。

综合分析，利用 **k-means** 聚类方法，得到隐含层每个节点的径向基函数的中心矢量 c_j 和隐含层基函数的宽度参数 δ_j 。通常采用的聚类方法是用 **k** 均值算法来实现对中心向量的实时调整，对训练样本进行聚类处理，用聚类最短间隔作为指标寻找径向基函数的中心向量，使每个输入样本矢量与中心矢量之间的距离达到最小值。**k-means** 聚类算法详细步骤为^[30]：

(1)随机地设定各隐含层节点的初始中心矢量 $c_j(0)$ ， $(j=1,2,\dots,a)$ 、初始学习率 $\beta(0)$ 和误差目标函数限定值 ε 。

(2)计算当前的欧式距离，并求出节点的最短距离 $r(1 \leq r \leq a)$ ；

$$d_j(t) = \|x(t) - c_j(t-1)\| \quad (3.13)$$

$$d_{\min}(t) = \min d_j(t) = d_r(t) \quad (3.14)$$

其中， r 为输入样本 $x(t)$ 与中心向量 $c_j(t-1)$ 之间距离最短的隐含层节点序号。

(3)调整中心

$$c_j(t) = c_j(t-1), \quad (j=1,2,\dots,a, \text{且} j \neq r) \quad (3.15)$$

$$c_j(t) = c_j(t-1) + \beta(t)[x(t) - c_r(t-1)] \quad (3.16)$$

(4)修正学习速率

$$\beta(t+1) = \frac{\beta(t)}{\sqrt{1 + \text{int}(t/a)}} \quad (3.17)$$

$\beta(t)$ 为学习速率，一般 $0 \leq \beta(t) \leq 1$ ， $\text{int}(\cdot)$ 表示取整函数。通过对隐含层节点进行计算来调整其中心矢量和学习率。

(5)在步骤(2)中对下一个样本 $p(p=1,2,\dots,P)$ 重复计算，直至满足误差目标函数 $J = \sum_{p=1}^P J^p \leq \varepsilon$ 为止，聚类结束。

3.3 基于 PIO-RBF 神经网络预测模型建立

尽管 RBF 神经网络具有快速的学习能力，能够精确地逼近任何连续函数在有限时间内达到一定精度。构建 RBF 神经网络模型的核心问题是确定 RBF 神经网络结构及关键参数，包括确定隐含层节点的数量、中心值、高斯函数的宽度，以及如何对网络权重进行学习。当参数设置不合理时，不仅导致 RBF 神经网络的逼近精度降低，而且会使 RBF 神经网络收敛困难。在最近几年，受自然生物群体智能现象的启发，通过模拟

社会性动物行为提出的一种随机优化算法，例如蚁群优化、粒子群优化、鸽群优化等。鸽群算法具有原理简单的特点、需要调整的参数极少、易于实现，与其他群体算法比较有着计算相对简单，鲁棒性相对较强等明显优点。本节采用鸽群算法优化 RBF 神经网络的中心、方差（宽度）和隐层与输出层之间的连接权重。

3.3.1 鸽群优化算法

在RBF神经网络的学习算法中，对算法性能影响较大的3个参数分别是：基函数的中心，方差（宽度）、隐含层与输出层之间的连接权值。采用鸽群优化(Pigeon-Inspired Optimization,PIO)算法对这3个参数进行优化更新。

鸽群优化是一种新的智能群体优化算法，它模拟了鸽子的归巢行为。在性能方面，相比较于模拟鸟群捕食的粒子群智能优化算法，鸽群优化算法不仅有更快的收敛速度且在某种程度下可减缓局部最优问题^[31]，在该算法中，根据模仿鸽子归巢过程中的每个阶段所使用的导航工具来寻找目标的原理提出两种算子模型：地图和指南针算子、地标算子，这两种算子模型是对鸽子利用太阳、地球磁场和地标来寻巢的高度总结。

首先对鸽群优化模型中的每一只虚拟的鸽子进行速度和位置的初始化，而且在多维解空间中随着每一次迭代，每只鸽子的速度和位置都会得到更新，数学表达式如下：

$$V_m^l = V_m^{l-1} e^{-R \times l} + \text{rand} (X_{gbest} - X_i^{l-1}) \quad (3.18)$$

$$X_m^l = X_m^{F_a-1} + V_m^{F_a} \quad (3.19)$$

式中： V_m 和 X_m 分别为第 m 只鸽子的速度和位置；

l 为迭代次数；

位置向量 $X_m = [X_{m1}, X_{m2}, \dots, X_{m3}]$ ；

速度向量 $V_m = [V_{m1}, V_{m2}, \dots, V_{m3}]$ ；

$\text{rand}(\cdot)$ 函数为 $0 \sim 1$ 任意一个随机数；

R 为地磁因数，其取值范围为 $0 \sim 1$ ；

X_i^{l-1} 为第 i 只鸽子在 $l-1$ 次迭代中的位置；

X_{gbest} 为全部鸽子经过 $F_a - 1$ 次循环迭代后进行比较，所得到的全局最优位置。直到循环的迭代次数达到所设置的最大值时，更新就会停止，转入地标算子中继续运行。

在地标算子中，根据位置的比较来判断哪些属于对地标位置不熟悉而远离目的地的鸽子，从而舍弃。因此鸽群的数目会随着每一次的迭代减少 $1/2$ ，具体的位置更新表达式为：

$$N_d^l = \frac{N_{d-l}^l}{2} \quad (3.20)$$

$$X_c^{l-1} = \frac{\sum_{q=1}^{N_d^{l-1}} X_q^{l-1} f(X_q^{l-1})}{N_d^{l-1}} \quad (3.21)$$

$$X_m = X_q^{l-1} + rand(X_c^{l-1} - X_q^{l-1}) \quad (3.22)$$

式中： N_d^l 为第 l 次迭代后鸽子的位置；

$f(\cdot)$ 为适应度函数；

X_c 为经淘汰后所剩鸽群的中心位置，并作为地标。

当地标算子循环至最大迭代次数或适应度函数小于设定的阈值则跳出位置更新。令鸽群算法中适应度函数为如下形式：

$$f = \frac{\lambda_f}{m} \sum_{j=1}^m (Y_j - y_j)^2 \quad (3.23)$$

式中， Y_j 为第 j 个理想输出值， y_j 为第 j 个实际输出值， λ_f 为常数增益。

3.3.2 PIO-RBF 神经网络模型流程

通过采用鸽群算法来优化RBF神经网络的中心位置、标准差和权值，并建立斜轧穿孔轧机工艺参数的预测模型。具体鸽群算法流程如下：

步骤1：初始化RBF神经网络结构以及参数。

如选取 n 个数据样本作为输入数据，初始化隐层的神经元个数 h ，RBF的中心参数、标准差以及权值。

步骤2：不同的输入参数具有不同的量纲，可影响神经网络的训练过程以及精度。因此，在训练之前通过数据归一化的方法对参数进行预处理至[0,1]。

步骤3：初始化鸽群数量 N 、个体向量维度 D 、指南针算子迭代次数 T_1 和地标算子迭代次数 T_2 等参数以及个体位置 X 和速度 V ，计算种群的适应度值。

步骤4：在指南针算子迭代的阶段，利用公式(3.18)~公式(3.19)对鸽子的位置和速度进行修正，对个体的适应度值进行计算，同时对总体最优结果和单个历史最优结果进行更新，并判断是否达到指南针算子迭代次数，如果符合，则执行步骤5，如果不符合，则执行步骤4。

步骤5：在地标算子阶段，对鸽群进行数量的更新，以适应度值为依据来对这些鸽子进行排序，在每个循环过程中，将适应度值差的1/2鸽子剔除，然后对剩下的鸽子进行中心位置的计算，再依据公式(3.20)~公式(3.22)对剩余鸽子的位置更新，同时对它们

的历史最优以及整体最优进行更新，判断是否达到地标算子迭代次数，如果满足则执行步骤6，否则，回转步骤5。

步骤6：将群体最优值赋给RBF神经网络参数，计算工艺参数预测值。

步骤7：按照公式(3.24)~公式(3.29)调整更新RBF网络的中心 c_i 、方差 σ_i 、隐含层到输出层之间得连接权值 w_{ij} 。具体更新方式为：

$$\Delta w_{ij}(t) = \eta_i (Y_{ij} - y_{ij}) R_i \tag{3.24}$$

$$\Delta \sigma_i(t) = \eta_1 \frac{w_{ij}(t)}{\sigma_i^3} \sum_{j=1}^m (Y_{ij} - y_{ij}) \|X - c_i\|^2 R_i \tag{3.25}$$

$$\Delta c_i(t) = \eta_1 \frac{w_{ij}(t)}{\sigma_i^2} \sum_{j=1}^m (Y_{ij} - y_{ij}) \|X - c_i\|^2 R_i \tag{3.26}$$

$$w_{ij}(t+1) = w_{ij}(t) + \eta_2 \Delta w_{ij}(t) \tag{3.27}$$

$$\Delta \sigma_i(t) = \sigma_i(t) + \eta_2 \Delta \sigma_i(t) \tag{3.28}$$

$$c_i(t+1) = c_i(t) + \eta_2 \Delta c_i(t) \tag{3.29}$$

步骤 8：学习中止。当式(3.19)的误差适应度值符合限定阈值则停止 RBF 神经网络训练。

其训练流程图如图 3.3 所示。

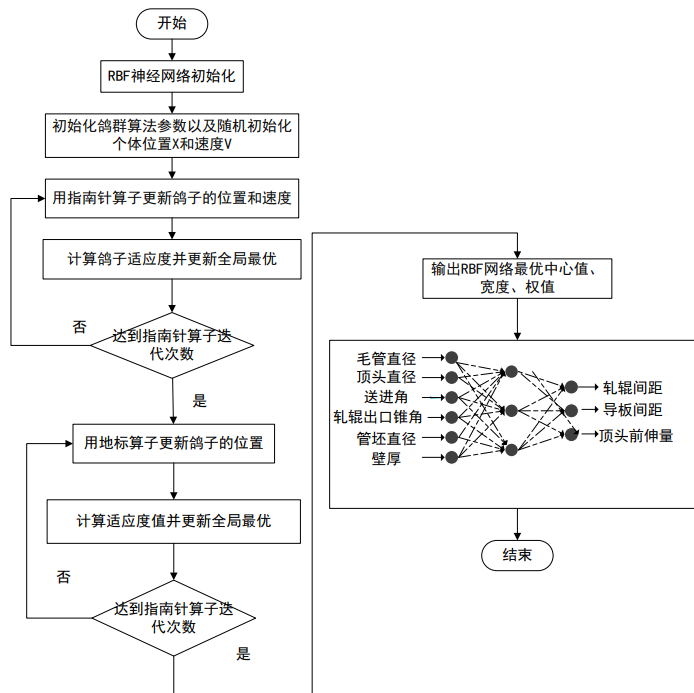


图 3.3 PIO-RBF 网络训练流程图

Fig.3.3 PIO-RBF network training flow chart

3.3.3 仿真研究

结合国内某钢管生产厂的生产数据整理了材料为304L的189组数据，该批生产数据中毛管直径为 $\phi 105 \sim \phi 235\text{mm}$ ，壁厚为 $7 \sim 16\text{mm}$ 的无缝钢管，所用的坯料直径为 $\phi 100 \sim \phi 219\text{mm}$ 。从总样本数据中随机选取148组数据作为训练数据集，用于RBF神经网络模型建模，将随机选取的39组数据作为检验数据，验证所建模型的正确性和有效性。通过均方误差对训练样本的输出损失进行评估，图3.4表示PIO-RBF神经网络优化中损失函数（均方误差）变化曲线，由图可知迭代次数近200次时才能趋于稳定，且损失函数较低。

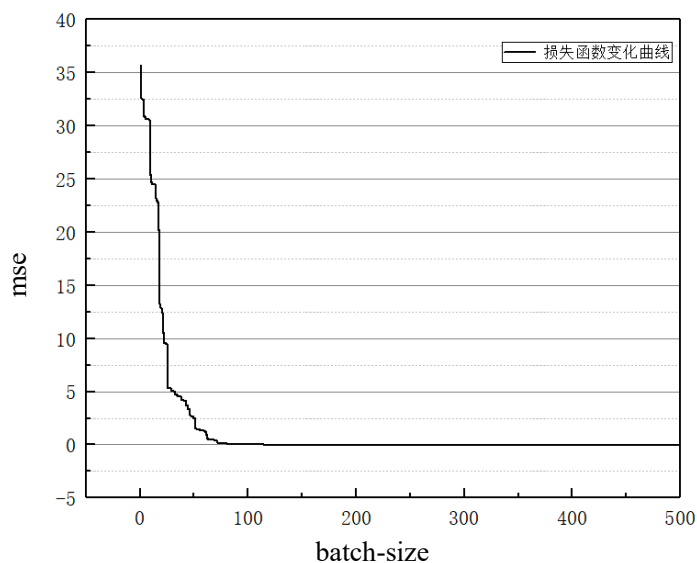


图 3.4 PIO-RBF 网络损失函数曲线

Fig.3.4 PIO-RBF network training flow chart

在仿真过程中，PIO-RBF神经网络模型中的参数设置如表3.4所示。鸽群算法中鸽群数目 $N=30$ ，地图和指南针算子迭代次数 $T_1=90$ ，地标算子迭代次数 $T_2=15$ ，地磁因数 $R=0.3$ ，模型最大训练迭代次数为500次，训练目标为0.0001，PIO-RBF神经网络的目标函数是输出的预测值与实际值的MSE。

表 3.4 PIO 算法参数设置

Tab 3.4 Parameter Settings of PIO Algorithm

鸽群数 N	地图和指南针算子迭代次数	地标算子迭代次数	地磁因数	最大训练次数	训练误差目标
30	90	15	0.3	500	0.0001

对于该预测模型，选择相对误差作为评估标准：

$$E_R = \frac{y_{ii} - y_i}{y_i} \times 100\% \quad (3.30)$$

式中， y_i 是样本的实际值， y_{ii} 是样本的预测值。


为进一步证实上述提出的 PIO-RBF 网络预测模型的有效性，将其与基于 K-means 聚类基函数的 RBF 模型进行比较。由于传统结果易受初始聚类中心的影响，在实际仿真过程中发现：若通过随机方式确定初始聚类中心可能会产生不同的聚类结果，可能导致最终分类效果与全局最终分类严重偏离，并且在聚类数目偏大时，此类缺点更加突出。并在多次仿真实例中，当聚类数为 3 时，效果最佳，具体结构参数设置如表 3.5 所示。

表 3.5 RBF 模型结构参数设置

Tab 3.5 Structural parameter setting of RBF model


输入维数	输出维数	聚类数	最大训练次数	训练目标误差
6	3	3	500	0.0001

利用基于聚类分析的 RBF 神经网络、PIO-RBF 神经网络分别对轧辊间距、导板间距、顶头前伸量进行预测，通过对其预测结果和实际测量值的对比分析，获得两种模型下轧辊间距、导板间距、顶头前伸量的预测结果如图 3.5 所示，相对误差图如图 3.6 所示。




(a) 轧辊间距预测曲线

(a) Prediction curve of roller spacing



(b)导板间距预测曲线

(b) Guide plate spacing prediction curve




(c)顶头前伸量预测曲线

(c) Prediction curve of plug protrusion


图 3.5 不同模型轧辊间距、导板间距和顶头前伸量的预测结果

Fig. 3.5 Prediction results of roller spacing, guide plate spacing and plug protrusion of different models.




(a) 轧辊间距

(a) roller spacing



(b) 导板间距

(b) Guide plate spacing.



(c) 顶头前伸量

(c) Protrusion of plug

图 3.6 不同模型下轧辊间距、导板间距和顶头前伸量的相对误差曲线

Fig. 3.6 Relative error curves of roller spacing, guide plate spacing and plug extension under different models

表 3.6 预测结果对比

Tab.3.6 Comparison of prediction results

参数	模型	均方根误差	平均绝对误差	决定系数
轧辊间距	RBF	22.2362	22.2007	0.7163
	PIO-RBF	3.2633	2.6433	0.9939
导板间距	RBF	16.3931	16.3360	0.8653
	PIO-RBF	3.3207	2.7673	0.9945
顶头前伸量	RBF	155.5544	155.5281	<0
	PIO-RBF	5.3197	4.9154	0.9872

图 3.5 和图 3.6 仿真结果表明，所提出的 PIO-RBF 模型对于轧辊间距、导板间距及顶头前伸量的预测均具有较高的预测精度，其轧辊间距预测结果平均相对误差为 2.20%，导板间距预测结果平均相对误差为 2.32%，顶头前伸量预测结果平均相对误差为 8.61%。

表 3.6 为 PIO-RBF 模型与基于聚类分析的 RBF 神经网络模型在限定的迭代次数下，均方根误差、平均绝对误差与决定系数之间的比较，实验结果表明，与基于聚类分析的 RBF 神经网络相比，PIO-RBF 神经网络模型具有较好的预报性能和较高的预测精度，

能够更好地满足工程需要。

3.5 小结

在对 RBF 神经网络原理和学习算法展开了深入的研究之后，利用鸽群算法优化 RBF 神经网络中高斯函数的中心矢量、基宽向量和网络权值，并建立基于 PIO-RBF 神经网络斜轧穿孔机工艺参数的预测模型。实例仿真表明，相较于基于聚类分析的 RBF 神经网络模型，所提出 PIO-RBF 神经网络模型具有更精准的预测结果，工艺参数的预测相对误差均在 9%以内。可在生产前预测穿孔机设备的工艺参数，实现高效、高质量生产。

第四章 基于深度神经网络斜轧穿孔机工艺参数预测建模

由于 RBF 神经网络属于浅层神经网络，对一些复杂功能的表达及泛化能力存在一定的局限。而深度学习方法是近年来经过大量实践并取得很好成果的一种通用方法，也是近年来人工智能领域中最活跃的分支之一。深度神经网络不仅对噪声有很好的抑制作用，对复杂函数的表达也有很好的处理效果且特征学习能力更强。因此本章采用深度神经网络算法结合数据训练集建立斜轧穿孔机工艺参数预测模型，并融合小批量梯度下降法（Mini-batch Gradient Descent，简称 MBGD）和 Adam 优化算法来提高模型的精度和训练速度。

4.1 深度神经网络的结构与算法

4.1.1 深度神经网络结构

深度神经网络(Deep Neural Networks, DNN)是一类以感知机为基础的带有更多隐含层的神经网络模型。DNN 以各层之间的全连接为主，利用误差反向传递进行反复学习，使得神经元之间的权重和阈值不断更新^[32]。根据节点在网络中的位置，将其划分为三部分：输入层、隐含层、输出层，如图 4.1 所示。




图 4.1 深度神经网络模型基本结构

Fig 4.1 Basic Structure of Deep Neural Network Model

对于第 l 层的第 i 个神经元来说，其输入和输出表达分别如式(4.1)和式(4.2)所示。

$$z_i^l = \sum_{j=1}^n w_{ji}^l a_j^l + b_i^l \quad (4.1)$$

$$g_i^l = \sigma(z_i^l) \quad (4.2)$$

式中, n 为 DNN 第 $l-1$ 层的神经元个数, w_{ji}^l 为连接第 $l-1$ 层的第 i 个神经元与第 l 层的第 j 个神经元之间的连接权重值, a_i^l 为第 l 层的第 i 个神经元的输入, b_i^l 为第 l 层的第 i 个神经元的输入偏置, g_i^l 为第 l 层的输出, $\sigma(\cdot)$ 表示激活函数。本文的输入层和隐含层采用 Relu 函数, 输出层采用 sigmoid 函数。

4.1.2 小批量梯度下降法

在进行深度神经网络训练时, 训练数据的规模一般都比较大会。在传统梯度下降算法中, 每一次迭代都要计算整个训练数据上的梯度, 这就会耗费大量的计算资源。除此之外, 在大规模训练集中的数据往往有很多冗余, 从而导致收敛速度过低^[32]。而且, 当目标函数存在多个局部最小值时, 传统梯度下降算法极易陷入局部最小值。Mini-batch 梯度下降综合了传统梯度下降与随机梯度下降的优点, 该算法既保留了随机梯度算法速度上的优势, 又使模型训练具有整体性。

在深度神经网络算法中, 为了使预测输出值和真实值越接近, 文中采用均方误差损失函数, 表示为:

$$\text{MSE}(\theta) = \frac{1}{m} \sum_{i=1}^m (y_i - x_i)^2 \quad (4.3)$$

式中 θ 表示神经网络中待训练的权重系数, y 表示预测输出值, i 为样本标签, x 表示目标值。为了寻找使得损失函数 MSE 最小的 θ 值, 采用梯度下降迭代式为:

$$\theta^{(n+1)} = \theta^{(n)} - \eta \nabla_{\theta} \text{MSE}(\theta^{(n)}) \quad (4.4)$$

其中 η 为学习率, 表示每次迭代的步长; $\nabla_{\theta} \text{MSE}(\theta)$ 表示梯度向量的损失函数。

在每次迭代过程中随机批量抽取一小批样本, 并根据(4.4)式更新梯度和权重, 直到将所有样本训练完。小批量随机梯度下降流程如图 4.2 所示。

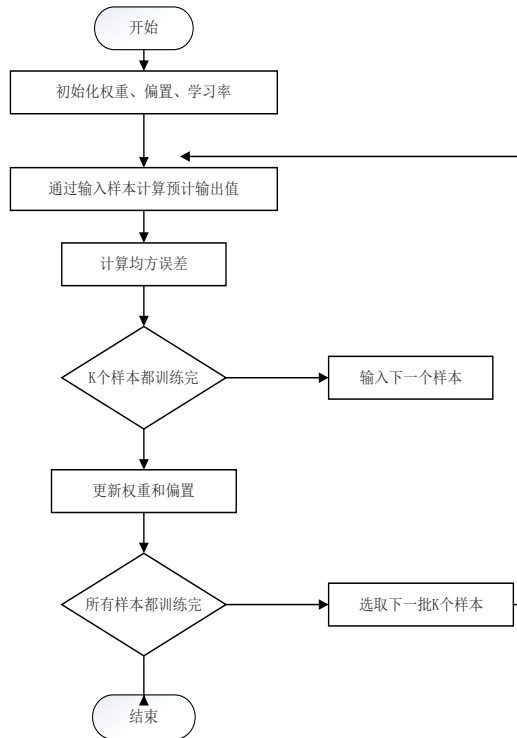


图 4.2 小批量随机梯度下降计算流程图

Fig 4.2 Flow chart of small batch random gradient descent

4.1.3 深度神经网络的反向传播算法

在深度神经网络算法中，反向传播是将输出层的数据与目标数值进行对比，若误差不能满足设计需求，就对其进行相应权重校正，然后反向传播到输入层，并对各层的权重和偏置依次调整，从而达到逐层向前进行反向处理的目的，通过反复对误差进行计算来判断误差是否达到设定的要求。通过引入均方误差损失函数对训练样本的输出损失进行评估，使得预测输出值更接近真实值，其损失函数定义如下：

$$J(w, b) = \frac{1}{m} \sum_{i=1}^m \frac{1}{2} \|\hat{y} - y\|^2 \quad (4.5)$$

式中 $J(w, b)$ 代表的是损失函数， \hat{y} 代表模型的预测值， y 代表样本实际值， m 为样本数。反向传播的目的是寻找一组使损失函数 $J(w, b)$ 最小化的 w 、 b 。

4.2 二辊斜轧穿孔机工艺参数的深度神经网络预测模型

根据二辊斜轧穿孔的机理和传统数学模型分析，设置斜轧穿孔机工艺参数轧辊间距、导板间距和顶头前伸量作为预测模型的输出，将毛管直径、坯料直径、顶头直径、送进角、壁厚、轧辊出口锥角设为模型的输入，确定模型为 6 个输入 3 个输出的深度神经网络预测模型。采用某钢厂无缝钢管的生产数据对斜轧穿孔机的工艺参数进行模型

预测。由于深度神经网络的复杂性和强大的拟合性，从而需要更多的数据来避免过拟合的发生。将采集的 1093 组样本中随机选取 993 组样本作为模型的训练集，100 组样本作为测试集。对原始数据进行归一化处理，再采用 PCA 白化来降低输入数据特征之间的相关性。所得实验数据集的部分组成如表 4.1 所示。

表 4.1 部分实验数据集组成

Tab. 4.1 Composition of some experimental data sets

工艺参数	第一组	第二组	第三组	第四组	第五组
管坯直径	85	110	110	185	247
顶头直径	65	87	75	165	103
毛管直径	89	114	115	194	249
出口锥角	3.2	3.2	3.2	3.2	3.2
送进角	10	10	10	10	10
壁厚	10	12	18	13	71
轧辊间距	74	97	97	167	220
导板间距	82	106	107	184	238
顶头前伸量	53	53	50	75	127

该批生产数据中毛管直径为 $\phi 76 \sim \phi 247\text{mm}$ ；壁厚为 $4 \sim 72\text{mm}$ 的无缝钢管；所用的坯料直径为 $\phi 75 \sim \phi 247\text{mm}$ 。

深度神经网络在建模过程中，存在许多需要人工设定的超参数，其中隐含层层数、隐含层节点数、目标优化算法、学习率、梯度函数等都与模型的性能密切相关，具体的选择需要在具体实验中进行验证。

4.2.1 深度神经网络层数

通过固定其它所有参数，设置如下表 4.2 所示对比了不同隐含层所对应的模型性能指标。通过选取均方误差 (MSE)、平均绝对百分误差 (MAPE) 两个度量方法对所建模型的精度进行检验。对隐含层层数设定一个初始值，在此基础上逐渐增加。通过比较该网络模型的性能指标，选择性能指标最佳所对应的隐含层层数。

表 4.2 不同隐含层所对应的模型性能指标

Tab.4.2 Model performance indicators corresponding to different hidden layers

隐含层层数	MAPE	MSE
2	5.57	0.0903
3	3.30	0.0524
4	4.25	0.0754
5	6.63	0.0972
6	6.61	0.1056
7	7.92	0.0777
8	7.69	0.0724
9	10.07	0.0937

根据表 4.2 可知，模型性能在隐含层层数为 3 时最佳，而后随着隐含层层数的增加，模型的性能逐渐变差。且结合仿真模拟经验来看，如果层数越多，则越容易产生过拟合的问题还会加大学习的难度，导致模型的收敛性越差。

4.2.2 隐含层神经元个数

隐含层中的节点数量过少则可能会出现欠拟合情况，反之，如果隐含层中的节点数量过多可能会引发过拟合。在上文中已经确定模型的最优隐含层层数为 3 层，还需确定每个隐含层的节点数。为了得到最佳隐含层节点数，在调试第一层节点数时，固定其它两个隐含层节点数；在选择好第一层最佳的节点数后，继续固定第三层节点数，来调试第二层的节点数，以此类推^[33]。将均方误差（MSE）、平均绝对百分误差（MAPE）两个度量方法作为检验所建模型精度的标准，具体性能指标对比结果如下表 4.3 所示。

表 4.3 不同隐节点所对应的模型性能指标

Tab 4.3 Model performance indicators corresponding to different hidden nodes

隐含层层数 (第几层)	隐含层神 经元数目	MAPE	MSE
1	5	7.22	0.1044
1	10	3.47	0.0610
1	20	4.67	0.0791
1	30	5.68	0.0811
1	40	6.04	0.0987
1	50	8.05	0.1256
2	5	7.44	0.1249
2	10	9.14	0.0944
2	20	7.01	0.0707
2	30	5.67	0.0864
2	40	4.01	0.0664
2	50	9.17	0.0894
3	5	9.60	0.1891
3	10	6.11	0.0988
3	20	5.31	0.0841
3	30	4.33	0.0683
3	40	6.32	0.0845
3	50	7.87	0.1095

根据表 4.3 的实验对比结果可知，并不是隐含层节点数目越多，模型性能就越好。当第一层节点数为 10，第二层节点数为 40，第三层节点数为 30 时，模型的预测效果最佳。

4.2.3 Adam 优化算法

在深度神经网络中，由于网络层数的增多，会使得网络的训练容易陷入局部极小点甚至鞍点。为了取得较好的梯度更新效果，采用结合动量方法 Momentum 与自适应学习率的 Adam 优化算法用于神经网络的梯度更新。Adam 是一种随机目标函数一阶梯度优化算法，以低阶自适应矩估计为基础，使用动量作为参数的更新方向，因此收敛速度快，学习效果更佳。

Adam 算法采用指数移动平均方法对网络梯度的均值（一阶矩）和方差（二阶矩）

进行估算，从而给不同参数提供独立的自适应学习率^[33]。其主要参数有：梯度学习率 α ，一阶矩估计的指数衰减率 β_1 ，二阶矩估计的指数衰减率 β_2 ，通常取 $\beta_1 = 0.9$ ， $\beta_2 = 0.999$ 。具体算法如下：

步骤 1：初始化参数 θ ，一阶矩变量 m_0 ，二阶矩变量 v_0 ，以及时间步长 $t = 0$ 。

步骤 2： $t = t + 1$ ，计算 t 时刻 m 个样本的平均梯度

$$g_t \leftarrow \frac{1}{m} \nabla_{\theta_{t-1}} \sum_i L(f(x_i; \theta_{t-1}), y_i) \quad (4.6)$$

式中

$(f(x_i; \theta_{t-1}), y_i)$ 表示神经网络的输出函数；

$L(f(x_i; \theta_{t-1}), y_i)$ 表示神经网络的代价函数。

步骤 3：计算有偏一阶矩估计

$$m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (4.7)$$

步骤 4：计算有偏二阶矩估计

$$v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (4.8)$$

步骤 5：计算修正一阶矩偏差

$$\hat{m}_t \leftarrow \frac{m_t}{1 - \beta_1^t} \quad (4.9)$$

步骤 6：计算修正二阶矩偏差

$$\hat{v}_t \leftarrow \frac{v_t}{1 - \beta_2^t} \quad (4.10)$$

步骤 7：计算参数更新

$$\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \varepsilon) \quad (4.11)$$

式中： α 为全局学习率， ε 为极小数。

Adam 算法训练神经网络流程如图 4.3 所示。

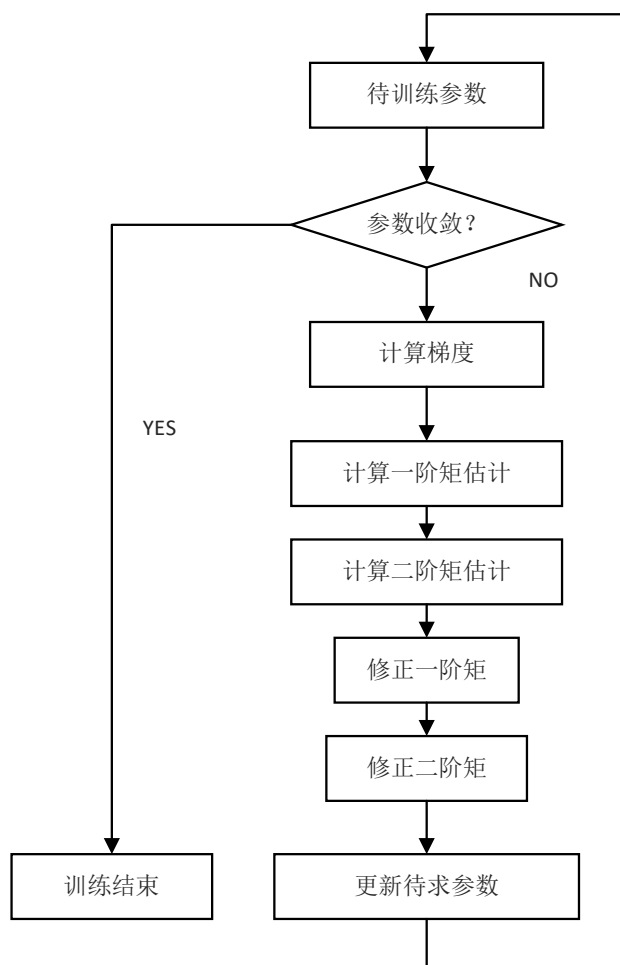


图 4.3 Adam 算法训练流程图

Fig 4.3 Adam algorithm training flow chart

4.2.4 基于 Adam 优化算法的神经网络预测模型

在训练神经网络时，训练数据的规模通常都比较大。对于传统梯度下降算法每次迭代都要计算整个训练数据上的梯度，需要消耗较多的计算资源，另外大规模训练集中的数据通常会非常冗余，造成收敛速度过慢^[33]。此外，当目标函数存在多个局部最小值时，传统梯度下降算法极易陷入局部最小值。

为避免上述问题，采用小批量梯度下降法，而梯度估计是影响该方法性能的主要因素之一。为了更有效的训练神经网络，采用 MBGD 和 Adam 算法结合修正梯度估计。MBGD 是在每次迭代中，都从大小为 m 的训练集中随机取出一个小批量，然后用这个小批量来计算梯度，Adam 算法通过指数移动平均方法估计网络梯度的均值(一阶矩)和方差(二阶矩)，以此为不同参数提供独立的自适应学习率^[33]。其主要参数包括：学习率 η ，一阶矩估计的指数衰减率 β_1 ，二阶矩估计的指数衰减率 β_2 ，通常取 $\beta_1 = 0.9$ ， $\beta_2 = 0.999$ 。MBGD 和 Adam 相结合的优化算法的流程如表 4.4 所示。

表 4.4 MBGD 和 Adam 算法相结合的流程

Tab. 4.4 Process of Combination of MBGD and Adam Algorithm

MBGD 和 Adam 算法结合的优化算法在第 k 个训练迭代的更新	
输入：训练集 $D = \{(x_k, y_k)\}_{k=1}^m$ ；学习率 η ；矩估计的指数衰减速率 β_1 、 β_2 ； ε 为用于数值稳定的小常数；	
输出：学习参数 w 、 b	
1: 初始化参数 w 、 b ；初始化参数一阶矩变量 $m = 0$ ，二阶矩变量 $v = 0$ ，及时间步长 $t = 0$ 。	
2: 随机采集一个小批量： $D' = \{(x_i, y_i)\}_{i=1}^{m'} \subset D$	
3: $t = t + 1$ 时，计算 t 时刻梯度： $\delta_w \leftarrow \frac{1}{m'} \nabla_w \sum J(w, b)$, $\delta_b \leftarrow \frac{1}{m'} \nabla_b \sum J(w, b)$;	
4: 更新有偏一阶矩估计： $m_w \leftarrow \beta_1 \cdot m_w + (1 - \beta_1) \cdot \delta_w$, $m_b \leftarrow \beta_1 \cdot m_b + (1 - \beta_1) \cdot \delta_b$;	
5: 更新有偏二阶矩估计： $v_w \leftarrow \beta_2 \cdot v_w + (1 - \beta_2) \cdot \delta_w^2$, $v_b \leftarrow \beta_2 \cdot v_b + (1 - \beta_2) \cdot \delta_b^2$;	
6: 修正一阶矩偏差： $\hat{m}_w \leftarrow \frac{m_w}{1 - \beta_1^t}$, $\hat{m}_b \leftarrow \frac{m_b}{1 - \beta_1^t}$;	
7: 修正二阶矩偏差： $\hat{v}_w \leftarrow \frac{v_w}{1 - \beta_2^t}$, $\hat{v}_b \leftarrow \frac{v_b}{1 - \beta_2^t}$;	
8: 计算更新： $w \leftarrow w - \eta \frac{\hat{m}_w}{\sqrt{\hat{v}_w} + \varepsilon}$, $b \leftarrow b - \eta \frac{\hat{m}_b}{\sqrt{\hat{v}_b} + \varepsilon}$;	
Until 达到停止条件	

对神经网络模型分别采用 SGD、Momentum、RMSprop 和 Adam 四个优化算法进行训练，结果表明 RMSprop 和 Adam 具有良好的效果。对确定具体优化方法，这里对 RMSprop 和 Adam 优化算法做了相关对比实验，具体对比实验结果如下表 4.5 所示。

表 4.5 各优化模型预测下正确率对比


Tab. 4.5 Comparison of Correct Rates under Prediction of Various Optimization Models

优化算法	测试集正确率		
	轧辊间距	导板间距	顶头前伸量
无 MBGD+Adam(迭代1000)	97.80%	95.90%	65%
MBGD+Adam(迭代10000)	99.35%	97.50%	74.70%
MBGD+RMSprop(迭代1000)	95.35%	93.80%	68.15%
MBGD+RMSprop(迭代2000)	99.35%	96.94%	71.41%

由表 4.5 可见，在迭代训练 1000 次的情况下，选择 MBGD 和 Adam 结合优化算法，其正确率较高。而且，当迭代训练为 2000 次的情况下，RMSprop 算法的学习效果依然不及 Adam 优化算法。因此，在 MBGD 和 Adam 优化算法模型下，其收敛速度更快，学习效果更为有效。


4.3 仿真研究

该模型目标函数选取均方误差，设学习速率为 0.001，训练次数为 500，批量大小 batch-size 为 100。通过建立的深度神经网络模型对轧辊间距、导板间距、顶头前伸量进行预测，将预测结果与实测值进行对比分析，其预测结果如图 4.4 所示，相对误差如图 4.5 所示。




(a) 轧辊间距预测值与实际值对比图

(a) Comparison between predicted value and measured value of roll spacing;



(b) 导板间距预测值与实际值对比图

(b) Comparison between predicted value and measured value of guide plate spacing




(c) 顶头前伸量预测值与实际值对比图

(c) Comparison between predicted value and measured value of plug forward extension


图 4.4 轧辊间距、导板间距、顶头前伸量的预测结果图

Fig. 4.4 Prediction results of roller spacing, guide plate spacing and plug protrusion.




(a) 轧辊间距的相对误差折线图

(a) Line chart of relative error of roll spacing



(b) 导板间距的相对误差折线图

(b) Line chart of relative error of guide plate spacing



(c) 顶头前伸量的相对误差折线图

(c) Line chart of relative error of plug forward extension

图 4.5 轧辊间距、导板间距、顶头前伸量的相对误差折线图

Fig. 4.5 Line chart of relative error of roller spacing, guide plate spacing and plug extension.

从图 4.4 和图 4.5 中可以看出，所提出的深度神经网络模型对于轧辊间距、导板间距及顶头前伸量的预测均具有较高的预测精度，其轧辊间距预测结果平均相对误差为

0.9925%，导板间距预测结果平均相对误差为 1.0999%，顶头前伸量预测结果平均相对误差为 4.8015%。

表 4.6 传统模型与预测模型结果对比

Tab. 4.6 Comparison of results between traditional model and prediction model

Model	工艺参数	RMSE%	MAE%	R-Square	运行时间(s)
数学模型	轧辊间距	2.8505	2.2690	0.8995	—
	导板间距	3.1700	1.8938	0.9696	
	顶头前伸量	49.0102	34.4652	<0	
RBF	轧辊间距	22.2362	22.2007	0.7163	28.3641
	导板间距	16.3931	16.3360	0.8653	
	顶头前伸量	155.5544	155.5281	<0	
PIO-RBF	轧辊间距	3.2633	2.6433	0.9939	97.7221
	导板间距	3.3207	2.7673	0.9945	
	顶头前伸量	5.3197	4.9154	0.9872	
深度神经网络	轧辊间距	1.2816	2.6433	0.9847	8.5741
	导板间距	1.9330	2.7673	0.9907	
	顶头前伸量	9.5521	4.9154	0.8989	

表 4.6 比较了使用传统数学模型、RBF 神经网络模型、PIO-RBF 神经网络模型和深度神经网络模型得到的预测结果及算法运行时间。从对比结果可以看出，虽然使用传统公式计算的轧辊间距和导板间距的误差较小，但由于计算中有些系数取了经验值，并且顶头前伸量的计算公式中使用了轧辊间距和导板间距的计算值，使得三个工艺参数的耦合关系紧密，前伸量计算的累积误差变大，预测结果明显要比 PIO-RBF 模型和深度神经网络差。而 PIO-RBF 神经网络模型和深度神经网络模型虽然在预测误差方面相差不明显，但从算法复杂度和运行时间上看，深度神经网络的结构和运行时间优于 RBF 神经网络和 PIO-RBF 神经网络，更利于用于在线预测。研究结果表明，基于深度神经网络的工艺参数预测模型的性能优于传统数学模型和 PIO-RBF 神经网络模型。

4.4 小结

本章提出一种基于深度神经网络的斜轧穿孔机工艺参数预测模型。使用深度神经网络构建工艺参数预测模型，以小批量梯度为基础结合 Adam 优化算法进行梯度估计修正，优化训练速度，克服多隐层网络所具有的内在缺陷，根据实例验证仿真结果表明，穿孔机工艺参数经深度神经网络模型预测与实测数据比较，工艺参数的预测相对误差均在 5%以内。从而证明该预测模型能够实现轧机工艺参数的高精度预测，并可用于指导生产。

第五章 斜轧穿孔机工艺参数预测界面开发

随着信息技术的发展，智能制造的人机交互和信息可视化技术发展迅速。例如，通过机器学习和深度学习进行智能分析，从而实现智能化人机交互，这种智能化人机交互可以大大提高生产效率和质量，让制造过程更加高效便捷。此外，信息可视化技术也可以使机器更加准确地识别和理解数据，从而更好地服务于客户。本章通过对无缝钢管斜轧穿孔变形工序的智能预报模型和关键影响因素的研究，开发了一套基于深度神经网络的斜轧穿孔机工艺参数预报系统。

5.1 界面开发环境

MATLAB 是一款由美国 MathWorks 公司研制的用于处理科学和工程问题的计算机辅助设计程序软件，具有很高的实用价值。MATLAB 具有很多优点其中最突出的是工具箱非常丰富，不仅包含了常用的数学函数，还提供很多高级功能，例如数值计算、绘图、数据分析等，此外还提供大量的函数库，可以帮助用户轻松实现复杂的计算任务，运算功能强大、人机界面友好，编程效率高深受广大工程师欢迎的计算工具。文献^[35]应用 MATLAB 的 GUI 界面平台开发了多晶模型生成系统，简化多晶体几何建模的操作流程。文献^[36]通过 MATLAB GUI 平台开发热轧带钢表面缺陷分类和检索系统多晶模型生成系统，方便企业对表面缺陷信息的分析，减少企业损失，提升企业形象。文献^[37]将灰色预测模型作为理论基础，利用 GUI 控件的布局设计和回调函数程序的编写，开发一套基于 MATLAB GUI 的灰色预测系统，完成对模型的参数估计、检验、数据拟合及预测，有效地解决了模型的构建和求解过程中的复杂问题。文献^[38]借助 MATLAB 和 AutoCAD 软件开发了轧机棒材连轧计算机辅助孔型设计软件，实现连轧工艺参数和孔型的输出，缩短了孔型设计周期。

本系统界面利用 MATLAB App Designer 工具完成设计。MATLAB App Designer 是一种交互式开发环境，可以利用设计界面直接将每一个组件构造出来，将每个组件视为一个对象，用户通过代码区来对组件的行为进行自定义，以使设计的程序达到预期。具备高效的数据传送功能、工具种类多样化但操作简单易于掌握。

MATLAB App Designer 设计工具可以为系统进行排版与设计，为应用程序的开发带来便利，用户仅需将可视化构图中的各部分拖曳至该构图中，就可以按照对应的模块编写相应的算法，并利用该算法实现相关功能。其操作如下：

(1) 打开 MATLAB，在面板的命令行输入指令“app designer”，回车进入 App Designer 程序的编辑页面。

(2) 按照系统模块的要求，对所需的组件构建接口进行分析。在完成界面布局之后，

MATLAB 会以控件类型为依据，在代码视图中自动生成 m 编码文件，系统会将. fig 文件和. m 文件保存到同一个文件夹中，在此基础上，在代码视图中，通过对设计视图中相应的子模块编写回调函数，实现相应的功能。

5.2 界面开发需求分析

5.2.1 界面开发的目的

轧机的工艺参数对钢管的质量影响很大。在传统的生产中，大多是按照产品规格要求计算出工艺参数将其作为设定参数，凭借生产经验去调整。关键工艺质量的预测与操作决策依赖工作人员的知识储备和认知水平。不可避免的会出现不符合规格的产品，会造成资源浪费问题。为减少人为的错误和低效率，并以实际需求为背景，以深度神经网络模型为核心，设计并开发了基于深度神经网络的斜轧穿孔机工艺参数预测系统。用户通过人机交互界面与系统交流，辅助该系统进行生产操作，有助于在复杂的穿孔变形预测中将轧机工艺参数预测的误差最小化，大大提高了生产效率和生产质量，最大的释放生产力和降低生产成本，同时增强企业的竞争力。

5.2.2 界面的功能分析

在软件系统的开发中效率高、准确率高、稳定性好、速度快是其最基本的特性，而无缝钢管斜轧穿孔机工艺参数预测系统其核心功能之一是实现无缝钢管斜轧穿孔机的工艺参数的精确预测。在设计开发的主要目的是为用户提供一个使用友好的界面，以便工作人员可以轻松地进行操作，此外，界面上还应显示数据信息的可视化显示图以及分析结果。结合用户和实际生产需求，本界面功能如下图 5.1 所示

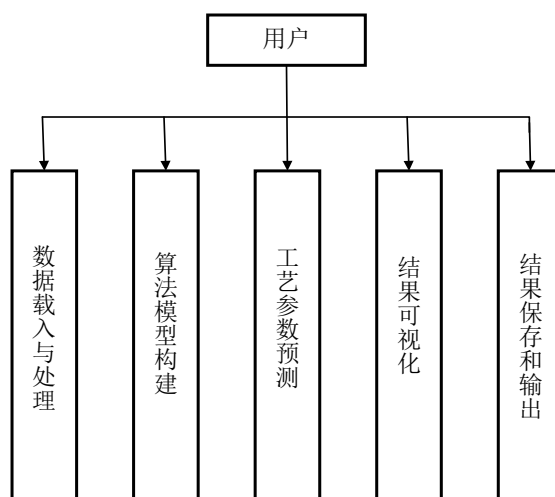


图 5.1 界面功能示例图

Figure 5.1 Example diagram of interface function

5.3 主要功能模块设计

模块化建模仿真软件的首要问题之一是对模型进行分析并划分。合理的模块划分方法能够极大地减少建模的复杂性并增强其实用性。为了满足界面功能的需求，将斜轧穿孔机的工艺参数预测界面分为四个功能模块系统包括如下模块：数据处理模块、深度学习训练模块、智能预测效果、预测效果可视化模块。界面的总体结构如图 5.2 所示：

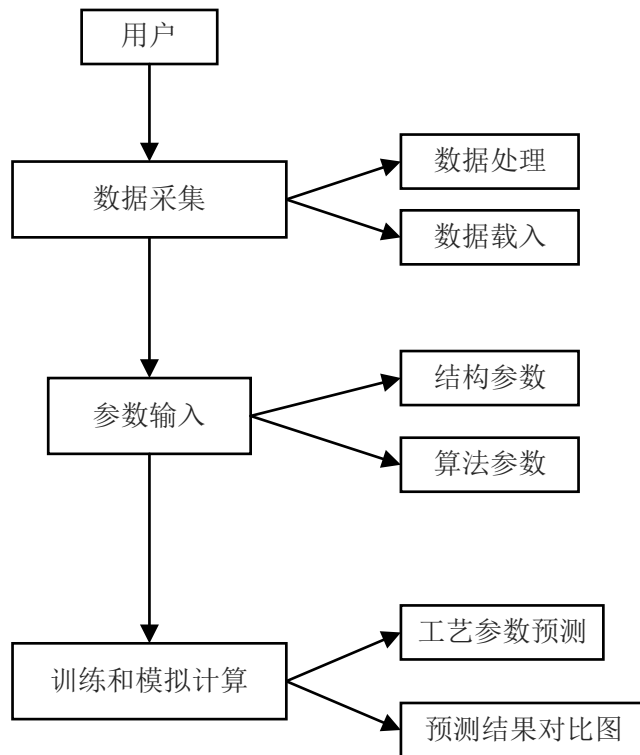


图 5.2 界面总体结构图

Fig 5.2 Overall structure diagram of interface

该系统的界面及各级子界面由按钮(Buttons)、文本编辑框(Editable Texts)、数值编辑框(NumericEditField)、复选框 (CheckBox)、表(UI Table)、坐标轴(UI Axes)等控件组成。该平台的设计中，每个模块都包含图形化界面和回调函数。界面整体布局如图 5.3 所示。

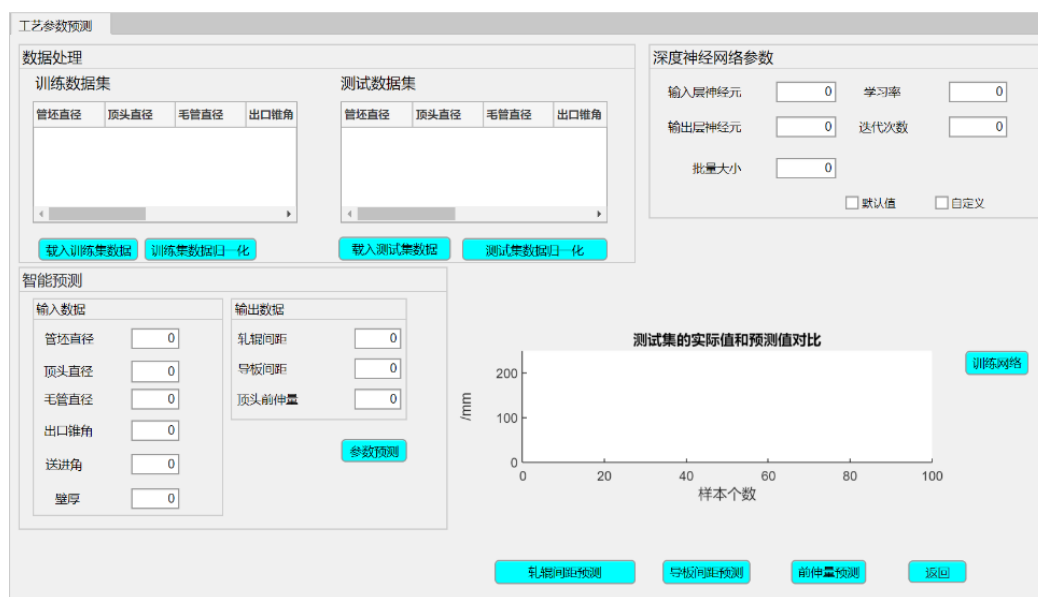


图 5.3 界面整体布局

Fig 5.3 Overall Layout of Interface

5.3.1 数据处理模块

数据处理模块主要包含两大功能：数据集的载入和数据集归一化处理。避免由于输入和输出数据之间的巨大差异而增加预测误差，对数据进行综合分析评价,将采集的管形数据分为训练集和测试集，训练集用于预测模型的预测值，测试集用于预测检验模型的预测功能；首先如图 5.4 分别点击“载入训练集数据”和“载入测试集数据”按钮；其次如图 5.5 点击分别点击“训练集数据归一化”“测试集数据归一化”按钮，对数据进行规范化处理，目的是为了消除不同维度数据数量之间的差异。

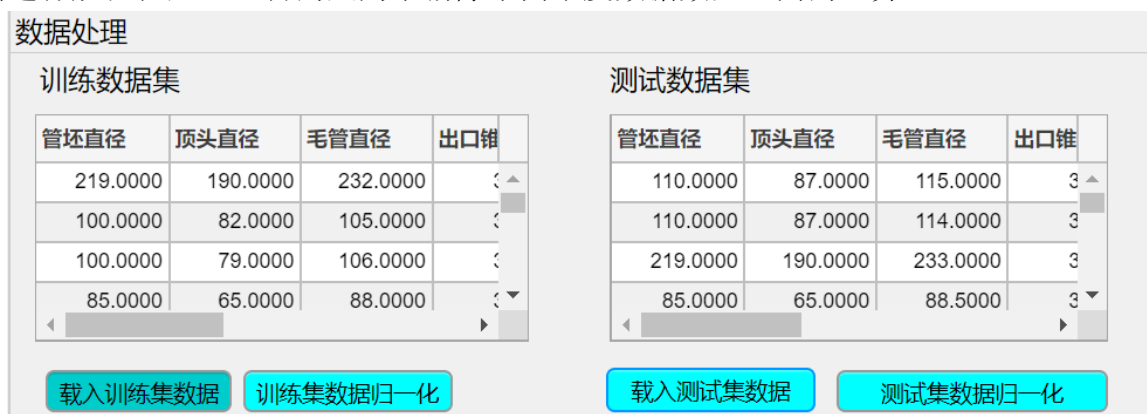


图 5.4 载入数据效果图

Fig 5.4 Loading data effect diagram



图 5.5 数据归一化效果图

Fig 5.5 Data Normalization Effect Diagram

5.3.2 深度神经网络训练模块

如图 5.6 所示在深度神经网络训练模块中根据需求对输入层神经元个数、输出层神经元个数、学习率、迭代次数、批量大小进行设置。其中默认值是该模型经过多次训练后得到的最佳参数值。然后如图 5.7 所示点击“训练网络”按钮，在训练完成后会弹出一个界面，显示“训练完成”即表示完成对深度神经网络模型函数的调用。

深度神经网络参数

输入层神经元 学习率

输出层神经元 迭代次数

批量大小

默认值 自定义

图 5.6 预测模型训练参数设置示例图

Fig 5.6 Example diagram of parameter setting of prediction model

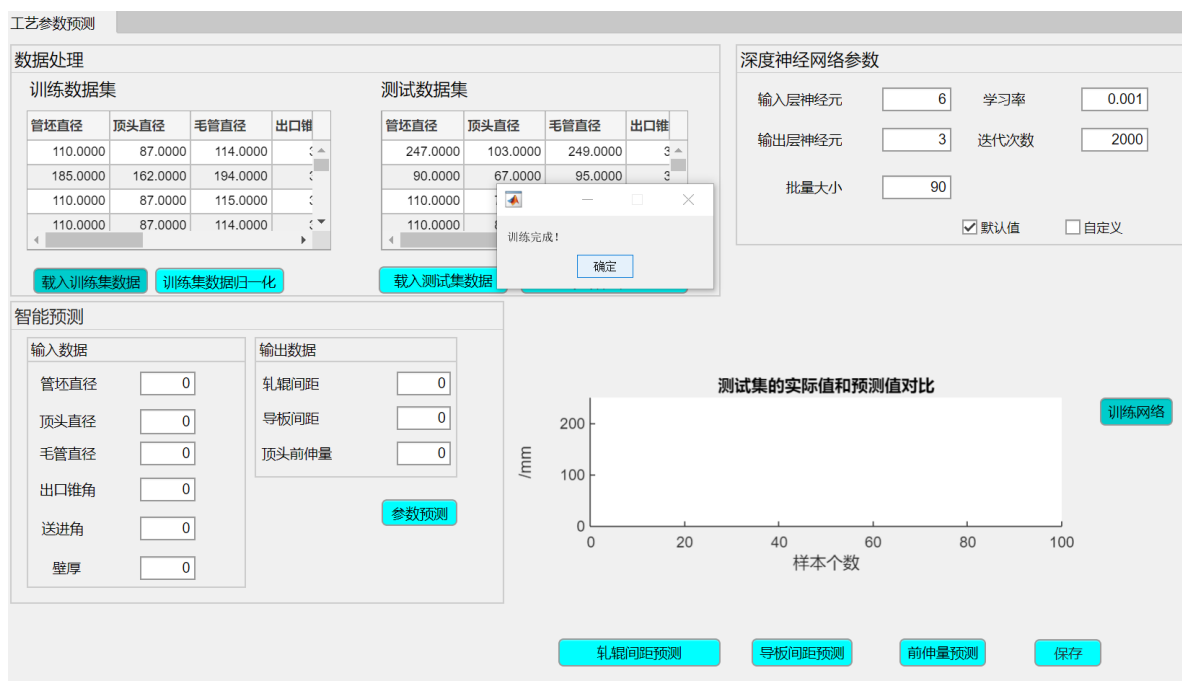


图 5.7 网络训练进展示例

Fig 5.7 example of network training progress

5.3.3 智能预测模块

如图 5.8 所示，在智能预测模块里可以按照毛管的生产规格在输入数据面板中分别输入管坯直径、顶头直径、毛管直径、出口锥角、送进角、壁厚对应的参数值，点击“参数预测”按钮。便可以在输出面板中显示轧辊间距、导板间距、顶头前伸量的数值。



图 5.8 参数预测效果图

Fig 5.8 Parameter Prediction Effect Diagram

5.3.4 预测效果可视化模块

在该模块中将测试集的部分实际值和预测值的对比数据结果直观地显示出来。其中分别设置了“轧辊间距预测”、“导板间距预测”、“前伸量预测”三个按钮。“保存”按钮可将预测结果保存为 excel 文件后缀为.xlsx。如图 5.9-5.11 所示，分别呈现三个参数的预测对比图。




图 5.9 轧辊间距预测对比图

Fig 5.9 Comparison Diagram of Roll Spacing Prediction




图 5.10 导板间距预测对比图

Fig. 5.10 Comparison Diagram of guide plate spacing




图 5.11 顶头前伸量预测对比图

Fig. 5.11 Comparison Diagram of plug protrusion prediction

5.4 性能分析

1、基于 MATLAB APP 开发的系统定义了需要读取的输入参数，采用 excel 导入数据、图像输出两种形式，通过调整输入参数可以得到不同的结果，供工作人员进行产前分析，为生产过程的参数设置提供依据。

2、本文利用深度神经网络模型预测穿孔机的工艺参数，用以在生产前预测参数设置是否合理，系统具有预测结果可视化、参数调整方便等特点，可广泛应用于指导穿孔生产，具有实际意义。

3、图形化界面界对每个模块的输入方式和输出方式实现了可视化，不仅提高了数据输入的可靠性，而且方便了仿真结果的分析过程。

本界面涉及基于 MATLAB 的二辊斜轧穿孔工艺参数预测系统。本界面包括的主要内容有数据导入并对其进行数据归一化处理，深度神经网络模型算法系统实现对斜轧穿孔机调整参数的训练、预测以及训练效果展示，该界面结合 MATLAB 编程实现网络模型的建立训练和预测，提供一种设计简单、检测速度快、灵活性高且稳定可靠的基于 MATLAB 的斜轧穿孔机调整参数的预测方法。本系统实现数据导入、数据处理、模型预测以及预测结果显示等功能于一体，减少了工作量，已知毛管的成品规格可利用深度神经网络预测轧机的关键影响参数（轧辊间距、导板间距、顶头前伸量），用以指导穿孔生产，保证钢管生产质量。

5.5 小结

本章主要从 MATLAB App Designer 的介绍、界面的需求分析、界面的功能模块设计以及界面的效果展示来介绍具体内容。预测界面的核心是采用基于深度神经网络算法对穿孔机的工艺参数进行实时在线预测。

第六章 总结与展望

二十一世纪以来，全球工业发展搭上了信息化与智能化这条快速路，工业生产技术进入了快速发展的全盛阶段。其中，无缝钢管的生产作为钢铁制品的重要分支，更是在工艺技术等方面取得了进步。

本文以系列化无缝钢管热连轧智能生产线及装备项目为背景，针对复杂多变的无缝管斜轧穿孔生产工艺，借助于质量预报模型，将深度学习方法应用于质量控制系统中，通过现场采集的大量数据，建立斜轧穿孔机工艺参数预测模型，从而指导生产，提高钢管生产的质量。本文通过以下三个方面深入探讨了二辊斜轧穿孔机工艺参数预测模型以及提高工艺参数预测精度的方法。

(1)综合分析了传统的二辊斜轧穿孔调整参数数学模型并确立主要特征参数，其次确立了两辊斜轧穿孔机工艺参数预测模型的输入和输出变量。

(2)在 PIO-RBF 神经网络的多输入多输出模型中，通过与基于聚类分析的 RBF 神经网络模型对比，穿孔机工艺参数（轧辊间距、导板间距、顶头前伸量）经 PIO-RBF 网络模型预测得到数据与实际数据比较，其相对误差均在 9%以内。

(3)基于深度神经网络的工艺参数预测模型中，为解决多隐层网络存在的固有缺陷，以小批量梯度为基础结合 Adam 优化算法进行梯度估计修正，避免在训练过程中陷入局部最优点。轧机工艺参数经深度神经网络模型预测与实测数据比较，轧机工艺参数的相对误差均在 5%以内，具有较高的精准的预测结果。

(4)设计穿孔工艺参数智能预测系统，开发了工艺参数预测界面。共包含四个模块，可实现对数据进行导入、处理、保存，在系统中采用深度神经网络算法预测模型对穿孔机的工艺参数进行预测，其预测结果可在系统界面中直观显示，用以指导穿孔生产，保证钢管生产质量。

本文基于深度学习对二辊斜轧穿孔机工艺参数进行预测，并取得了一定的研究成果。本文研究的课题还可以在一下几个方面仍需研究与完善：

(1)后期还需采集更多现场数据提高模型的精度，同时完善预测系统的功能，美化软件界面；

(2)本文采用的预测模型通过采集数据进行一次性训练。但是在钢铁生产过程中，对斜轧穿孔机工艺参数预测实时性的要求越来越高。目前只能进行离线预测，下一步可研究在线实时预测，提高穿孔机工艺参数预测的应用价值。

参 考 文 献

- [1] 李连诗, 韩观昌等. 小型无缝钢管生产(上册) [M], 冶金工业出版社, 1989, 117.
- [2] 肖冬. 无缝钢管生产过程质量预报及关键参数优化控制[D]. 沈阳: 东北大学, 2009.
- [3] 陆璐. 33Mn2V 钢斜轧穿孔过程与显微组织模拟研究[D]. 天津工业大学, 2010.
- [4] Glowacki M. Modelling of heat transfer, plastic flow and microstructural evolution during shape rolling[J], J. Master. Process. Technol, 1995, 53(22): 159—166.
- [5] D. Xiao, J. Jiang, Y. Mao, et al. Process monitoring and fault diagnosis for piercing production of seamless tube[J]. Mathematical Problems in Engineering, 2016, 1-13.
- [6] 双远华. 斜轧(穿孔)过程质量控制理论与实验研究[D]. 燕山大学.
- [7] 双远华, 李国祯. 钢管斜轧理论及生产过程的数值模拟[M]. 冶金工业出版社, 2001.
- [8] V. A. Toporov, A. I. Stepanov, O. A. Panasenkov, et al. Use of finite-element modeling to improve the piercing operation on a piercing mill[J]. Metallurgist, 2014, 58(7):563-567.
- [9] Z. Pater, A. Tofil. FEM Simulation of the tube rolling process in diescher's mill[J], Advances in Science & Technology Research Journal, 2014, 8(22):51-55.
- [10] M. M. Skripalenko, B. A. Romantsev, V. E. Bazhenov, et al. Fem simulation of Mannesmann piercing of aluminum alloy ingots[J]. Izvestiya Vysshikh Uchebnykh Zavedenij. Tsvetnaya Metallurgiya, 2018, (6):42-50.
- [11] Krzyzanowski M, Beynon J H. Measurement of oxide properties for numerical evaluation of their failure under hot rolling conditions[J]. Journal of Materials Processing Technology, 2002, 125(1):398-404.
- [12] W. H. Guo, R. Chen, J. J. Jin. Online eccentricity monitoring of seamless tubes in cross-roll piercing mill[J]. Journal of Manufacturing Science and Engineering, 2015, 137:007-021.
- [13] 双远华, 赖明道. 人工神经网络在预测斜轧穿孔毛管偏差中的应用[J]. 中国有色金属学报, 2001(5):862-866.
- [14] 王清华, 加世滢, 胡建华, 周新亮, 赵铁琳. 基于 Matlab 的无缝钢管穿孔工艺模型参数预测系统. ZL202110765429X, 发明专利
- [15] 韩观昌. 小型无缝钢管生产[M]. 北京: 冶金工业出版社, 1990.
- [16] 胡韬. 智能制造技术在我国钢铁行业中的应用分析[J]. 冶金与材料, 2019, 39(05):102-103.

- [17]楚东来,赵伟辰,林春城.群智能算法的研究现状和发展趋势[J].信息通信,2015(11):38-39.
- [18]潘孝礼,肖冬,毛志忠,等.基于均值子时段 MPLS 方法的毛管质量预报[J].系统仿真学报,2008(7):1677-1680.
- [19]陈鑫,朱明杰,吴敏,等.结合机理计算与神经网络预测的无缝钢管轧制力建模[J].冶金自动化,2015,39(4):32-37.
- [20]M. Bagheripoor, H. Bisadi. Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process[J]. Applied Mathematical Modelling, 2013, 37(7):4593-4607.
- [21]X. D. Li. Rolling force prediction of hot strip based on combined friction[J]. Materials Science and Engineering Conference Series, 2017, 269(1):012-053.
- [22]LEE D, LEE Y. Application of neural-network for improving accuracy of roll force model in hot-rolling mill[J]. IFAC Proceedings Volumes, 2000, 33(22):227-231.
- [23]刘欣玉,潘露,帅美荣.基于 Matlab 的 BP 神经网络轧制力预报模型及应用[J].重庆科技学院学报(自然科学版),2016,18(6):96-98,103.
- [24]YANG Jingming, GU Jiaqi, YAN Xiaoying, et al. Prediction of rolling force based on improved genetic algorithm for optimizing BP neural network[J]. Mining and Metallurgical Engineering, 2015, 35(1):111-115.
- [25]杨景明,闫晓莹,顾佳琪,车海军.基于改进粒子群优化 RBF 神经网络的轧制力预报[J].矿冶工程,2014,34(06):110-113+118.
- [26]WANG Z, ZHANG G, WANG J, et al. Prediction of rolling force for two-stand steckel mill based on PSO-BP neural network[J]. Research on Iron and Steel,2017, 45(3):23-26.
- [27]何垚东,李旭,丁敬国,等.融合轧制机理和深度学习的带钢精轧宽度预测[J].轧钢,2022(002):039.
- [28]马威,李维刚,赵云涛,等.基于深度学习的热连轧轧制力预测[J].钢铁研究学报,2019,31(9):805-815.
- [29]常威威,郭雷,刘坤,等.基于 Contourlet 变换和主成分分析的高光谱数据噪声消除方法[J].电子与信息学报,2009(12):5.
- [30]崔小彦.基于 RBF 神经网络与蚁群算法的瓦斯预测模型研究[D].辽宁工程技术大学.

- [31]段海滨,叶飞. 鸽群优化算法研究进展[J]. 北京工业大学学报, 2017, 43(1):1-7.
- [32]魏立新,魏新宇,孙浩,等. 基于深度网络训练的铝热轧轧制力预报[J]. 中国有色金属学报, 2018, 28(10):128-134.
- [33]胡石雄. 基于深度学习的热轧带钢力学性能预报[D]. 武汉科技大学, 2019. 姬壮伟.
- [34]基于 pytorch 的神经网络优化算法研究 [J]. 山西大同大学学报 (自然科学版),2020,36(06):51-53+58
- [35]范婉婉. 304 不锈钢极薄带轧制变形区细观力学行为研究[D]. 太原理工大学.
- [36]邢健夫. 基于卷积神经网络的热轧带钢表面缺陷识别及系统开发[D]. 东北大学, 2019.
- [37]黄冉,杨本硕,杨德平. 基于 MATLAB/GUI 灰色预测系统开发及应用[J]. 青岛大学学报: 工程技术版, 2014, 29(3):6.
- [38]曾庆芦,李铂涛,刘昊,等. 基于 CARD 和 Pro/E 二次开发的轧机零件参数化设计[J]. 机械工程与自动化, 2015(5):3.
- [39]田川,王闯,刘灿,等. 基于鸽群改进 RBF 网络的软件质量预测方法[J]. 航空计算技术, 2021, 51(5):24-28.
- [40]王鹏飞. 基于 GM-RBF 组合模型的高路堑边坡稳定性预测研究[J]. 建筑结构, 2021, 51(20): 140-145.
- [41]段雪厚,王石刚,徐威,等. 基于径向基神经网络的薄板平整轧制力预报模型[J]. 上海交通大学学报, 2011, 45(6): 924-928.
- [42]郝晓丽,张靖. 基于改进自适应聚类算法的 RBF 神经网络分类器设计与实现[J]. 计算机科学, 2014, 41(6): 260-263.
- [43]LEE L Y. Application of neural-network for improving accuracy of roll-force model in hot-rolling mill[J]. Control Engineering Practice, 2002. 473-478.
- [44]SON J S, LEE D M, KIM I S, et al. A study on genetic algorithm to select architecture of a optimal neural network in the hot rolling process[J]. Journal of Materials Processing Technology, 2004,153-154: 643-648.
- [45]马湧,王晓鹏,马莎莎. 基于 Keras 深度学习框架下 BP 神经网络的热轧带钢力学性能预测[J]. 冶金自动化, 2019(2):5.
- [46]江锦红. 无缝钢管穿孔生产过程的监测与质量预报[D]. 东北大学, 2019.
- [47]李婵. 无缝钢管穿孔生产质量标准化研究[D]. 河北工程大学, 2015.
- [48]李新创,栾治伟,施灿涛. 人工智能技术在钢铁行业中的应用研究[J]. 冶金自动化,

2020(1):7.

- [49]Buyrukolu S , Ylmaz Y , Topalcengiz Z . Correlation value determined to increase Salmonella prediction success of deep neural network for agricultural waters[J]. Environmental Monitoring and Assessment, 2022.
- [50]Zhang S H , Che L Z , Liu X Y . Modelling of Deformation Resistance with Big Data and Its Application in the Prediction of Rolling Force of Thick Plate[J]. Mathematical Problems in Engineering, 2021, 2021.
- [51]刘菊, 常然然. 基于卷积神经网络的轧制力预测[C]// 全国冶金自动化信息网 2018 年会论文集. 全国冶金自动化信息网;冶金自动化杂志社, 2018.