

DOI:10.19344/j.cnki.issn1671-5276.2025.04.034

基于 AdaBoost-BP 的热镀锌钢板镀层厚度预测

洪静, 王平

(南京航空航天大学 高速载运设施的无损检测监控技术重点实验室, 江苏 南京 210016)

摘要:冷轧热镀锌钢板镀层厚度与防腐性能密切相关。利用一种新的镀层厚度预测方法, 融合自适应增强算法与 BP 神经网络, 通过多次自适应调整样本权重, 构建多个 BP 神经网络模型, 以群体估计代替单一网络估计。研究结果表明: 镀层厚度预测相对误差在 10% 以内, 优于 BP 预测结果, 并且满足工程要求。

关键词:热镀锌钢板; 镀层厚度预测; 自适应增强算法; BP 神经网络模型

中图分类号:TP183 **文献标志码:**A **文章编号:**1671-5276(2025)04-0184-05

Prediction of Galvanized Steel Plate Coating Thickness Based on AdaBoost-BP

HONG Jing, WANG Ping

(Key Laboratory of Non-destructive Testing and Monitoring Technology of High-speed Transportation Facilities,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: Cold rolled galvanized steel sheet coating thickness is closely related to its anti-corrosion performance. This article introduces a new method for predicting coating thickness, which combines adaptive enhancement algorithm and BP neural network. By multiple adaptive adjustments of sample weights, multiple BP neural network models are constructed to replace single network estimation with group estimation. The research results indicate that the relative error of coating thickness prediction is within 10%, which is better than the BP prediction results and meets the engineering requirements.

Keywords: galvanized steel plates; coating thickness prediction; adaptive enhancement algorithm; BP neural network model

0 引言

镀锌层对钢板的防腐性能具有重要意义。镀层超厚, 增加了生产成本, 还会降低镀层黏附性, 提高镀层脱落风险; 镀层超薄, 降低了防腐能力, 从而缩短钢板使用寿命。目前, 国内外钢铁企业普遍将 X 射线测厚仪安装在气刀下游 100~200 m 处, 此时环境温度较低, 且钢板表面锌液完全凝固, 无法满足厚度控制系统快速响应的要求, 当出现异常检测结果时, 说明至少产生了 100 m 不合格产品。因此, 建立镀层厚度的估计模型十分必要。

长久以来, 研究人员对镀层厚度的影响因素进行研究, 以获得精确的预测模型。PRINZ 等^[1]提出了一种在线参数估计的热轧带钢厚度自适应扰动前馈控制策略。PAN 等^[2]将压力、气刀间隙和钢板速度作为输入参数建立了镀层厚度的神经网络模型, 并在此基础上提出了基于神经网络的镀层厚度控制系统。LIU 等^[3]对热轧带钢质量控制过程的多变量、非线性、强耦合和时变特性进行

了研究, 建立了一种新的热连轧带钢厚度、板形和板形预测模型。王超^[4]建立了基于深度极限学习机结构的镀层厚度模型。

鉴于神经网络模型能够处理大量数据, 因此它已经成为研究镀层厚度建模的主要方向。然而, 目前的镀层厚度估计方法仍然受限于单一模型^[5-8], 如单一统计回归模型或单一神经网络模型。考虑到镀锌机制的复杂性和多样性^[9], 单一模型通常表现不佳。因此, 本文采用多模型协同合作的方式, 以群体估计代替单一模型估计, 以提高镀层厚度估计的准确性^[10-11]。

1 镀层厚度的检测设备

X 射线检测技术广泛应用于厚度和缺陷检测领域, 其具备非接触、高灵敏度、高精度、快速性等优点。

合作机组的生产线安装有两台 X 射线测厚仪, 对钢板上下表面的镀层厚度进行扫描检测。测厚仪以 3 点扫描的工作方式进行检测, 以上表面为例, 测厚仪探头在钢板表面的扫描轨迹和探

基金项目:国家自然科学基金项目(62073162)

第一作者简介:洪静(1999—), 女, 江西九江人, 硕士研究生, 研究方向为电磁无损检测, 2516431516@qq.com。

头检测点如图 1 所示。钢板以速度 v 运行,测厚仪固定在钢板长度方向的某一位置,沿着钢板宽度方向进行往复周期性扫描。在扫描过程中,测厚仪分别对钢板操作侧、中心线及驱动侧进行检测,依次获得第 i 、 $i+1$ 和 $i+2$ 个厚度值。本文选取三者的平均值作为镀层厚度的实际值,其中,镀层厚度以单位面积内的镀锌质量 (Zn galvanized thick, ZAT) 衡量 (单位 g/m^2),操作侧镀层厚度用 ZAT_0 表示,中央侧镀层厚度用 ZAT_1 表示,驱动侧镀层厚度用 ZAT_2 表示。




图 1 测厚仪的扫描方式

2 AdaBoost-BP 神经网络的镀层厚度预测建模方法

由于实际应用场景复杂多变,且数据量大,若将干扰特征和干扰数据引入估计模型,不仅会提高模型的训练耗时,还会降低模型的估计精度。此外,数据集中含有离散特征,且样本数量分布不均匀。因此,对镀层厚度估计建模需要进行全面的考量。本文利用某钢铁企业合作机组的实际生产数据,对镀层厚度的估计方法进行探究,本文的研究流程如图 2 所示。




图 2 镀层厚度估计的研究路线

2.1 AdaBoost-BP 基本原理

AdaBoost (adaptive boosting) 的核心原理是将多个弱学习器加权组合,生成一个强大的分类器或回归器,适用于各种机器学习任务。AdaBoost 在训练模型的过程中,会自动调整样本的权重,更加关注在训练中难以拟合的样本;同时 AdaBoost 可以组合不同基础回归模型一起使用,能更好地捕捉数据的不同特征和关系,从而提高模型预测性能;相对于一些其他复杂的回归算法,AdaBoost 的超参数相对较少,通常不需要做复杂的调整,这使得其相对容易实现和使用。BP 神经网络能处

理大规模数据,能并行训练神经网络,并加快训练过程。因此本研究选择将 BP 与 AdaBoost 相结合,以 BP 神经网络作为 AdaBoost 弱学习器,提高运行速度的同时进一步提高模型预测精度。具体流程如下。

步骤 1:假设训练集为 $X = \{(x^{(i)}, y^{(i)})\}_{i=1}^N$,第 i 个样本的权重为 $D_t(i)$, $t=1, \dots, T$, T 为 BP 模型的数量。

步骤 2:初始化训练样本的权重:

$$D_t(i) = \frac{1}{N} \quad (1)$$

步骤 3:训练得到第 t 个 BP 网络,记为 $h_t(x)$,样本 $\{x^{(i)}, y^{(i)}\}$ 在该网络的输出为 $h_t(x^{(i)})$ 。计算训练集在 $h_t(x)$ 上的最大误差 E_t 、每个样本的相对误差 $e_t(i)$ 和 $h_t(x)$ 的误差率 e_t :

$$E_t = \max |y^{(i)} - h_t(x^{(i)})| \quad (2)$$

$$e_t(i) = \frac{|y^{(i)} - h_t(x^{(i)})|}{E_t} \quad (3)$$

$$e_t = \sum_{i=1}^N D_t(i) e_t(i) \quad (4)$$

步骤 4:计算第 t 个 BP 网络 $h_t(x)$ 的权重 a_t

$$a_t = \frac{e_t}{1 - e_t} \quad (5)$$

步骤 5:更新训练集内每一个样本 $\{x^{(i)}, y^{(i)}\}$ 的新一轮权重 $D_{t+1}(i)$:

$$D_{t+1}(i) = \frac{D_t(i)}{\sum_{i=1}^N D_t(i) \alpha^{1-e_t(i)}} \quad (6)$$

步骤 6:重复上述步骤 3—步骤 5 直到训练完 T 个 BP 网络。

步骤 7:将训练完的 T 个 BP 网络进行集成,取权重为中位数的 BP 模型的输出结果作为最终结果:

$$H(x) = \inf \left\{ y \in A : \sum_{\substack{h_t(x) \leq y \\ 0 < j < n}} \ln \left(\frac{1}{a_t} \right) \geq \frac{1}{2} \sum_{t=1}^{T_n} \ln \left(\frac{1}{a_t} \right) \right\} \quad (7)$$

2.2 数据预处理

本文从某钢铁企业的生产机组获取了连续半年的数据,共 5 163 卷钢板数据,每卷钢板数据存储为一个文件,即共获得了 5 163 个文件。每个文件含有 30~200 组样本,每组样本都包含钢板、锌液、气刀、镀层厚度参数。

理论研究认为^[12-16],镀层厚度受到锌液温度、锌液成分、钢板温度、钢板速度、气刀参数等众

多因素影响。但在某一特定应用场景下,锌液温度等参数相对稳定,具有慢时变特性,其对厚度的影响十分微弱,若将这类参数引入模型估计,不仅无法提高估计精度,还会带来额外噪声,使估计精度不佳。

为了选择对镀层厚度影响最为显著的参数,也为了剔除冗余参数,本文采用偏相关分析方法从钢板速度、钢板温度、锌液温度、气刀实际参数值(压力、距离、高度、喷嘴倾角)选取对镀层厚度影响较大的主成分进行试验,结果如图3所示。计算结果表明:镀层厚度与钢板速度、气刀压力、气刀距离、气刀高度存在较强的相关性,而与锌液温度、钢板温度、喷嘴角度的相关性较弱。基于此,本文将剔除相关性较弱的3个冗余特征。




图3 偏相关系数计算结果

实际应用场景中,以测厚仪的检测结果为真实厚度值,因此干扰数据主要来源于气刀设备和钢板。经大量实践表明,当某组的气刀实际参数值与设定值偏离大于5%以及钢板镀层厚度数据波动大于目标厚度的5%时,表明此时设备处于异常状态,要剔除该组数据,图4展示了数据滤除的规则。其中该气刀设备的气压、距离、高度的标定最大输出值,分别标记为 K_{nep} 、 K_{ned} 、 K_{neh} , P_i 为第 i 组气刀实际压力值, $P_{s,i}$ 为气刀设定压力值, D_i 为第 i 组气刀实际距离值, $D_{s,i}$ 为气刀设定距离值, H_i 为第 i 组气刀实际高度值, $H_{s,i}$ 为气刀设定高度值, $Z_{AT,0i}$ 为第 i 组操作侧镀层厚度值, $Z_{AT,1i}$ 为第 i 组中央侧镀层厚度值, $Z_{AT,2i}$ 为第 i 组驱动侧镀层厚度值, Z_C 为目标镀层厚度, 钢板镀层厚度数据波动用镀层厚度最大值减去镀层厚度最小值表示。将气刀的实际参数值与设定值偏离大于5%,以及钢板镀层厚度数据波动大于目标厚度5%的第 i 组数据删除。

经过滤除干扰数据,实现了原始数据集的优化,数据集由原本的5163个钢板文件减少为5152个钢板文件。数据集有合金化(galvannealed, GA)和纯

锌(galvanized, GI)两种镀层类型。对于镀层种类这一参数,本文将建立GA数据集厚度模型和GI数据集厚度模型。




图4 数据滤除的规则

由于单个文件内为某卷钢板的生产数据,文件内的数据相似性极高。为避免测试数据泄露,本文以文件为最小划分单位。针对目标厚度钢卷数量不均匀的问题,本文将目标镀层厚度相同的钢卷以文件为最小划分单位,按照8:1:1划分为训练文件、验证文件和测试文件^[17]。将所有训练文件内数据合并为训练集,所有测试文件内数据合并为测试集,所有验证文件内数据合并为验证集,此时GA的各数据集具有一致的分布,GI镀层用相同的方法进行处理。训练集用于学习模型的参数矩阵;验证集一方面用于调整模型的超参数(网络层数、各层节点数量等),一方面用于观测模型是否收敛、是否出现过拟合;测试集用于评估模型的最终性能。

2.3 AdaBoost-BP 模型框架与超参数设计

结合前文特征集优化和数据集优化的结果,BP模型的输入层为钢板速度、气刀压力实际值、气刀距离实际值、气刀高度实际值4个参数,输出层为镀层厚度均值 $Z_{AT,ave}$ 。本文提出了1种镀层厚度的估计方法,该方法将AdaBoost R2算法与BP模型相结合,通过串行的方式训练一系列BP模型,建模框架如图5所示。由于数据量较大,为保证模型快速收敛以及最终估计效果,需要对模型的超参数进行考量。




图5 AdaBoost-BP 的镀层厚度估计建模框架

本文将隐含层每层节点数设置为 10,分别建立隐含层层数为 1~4 的网络模型。综合评价 4 个模型的训练耗时以及模型精度,最终将隐含层层数设置为 3,此时网络隐含层的节点数为(10,10,10)。对于节点数设置,本文在 10~100 范围内随机均匀取值,通过观测模型的收敛情况以及收敛效果,最终确定 3 层隐含层的节点数分别为(16,64,10)。

本文选择 ReLU 函数作为激活函数。ReLU 零点右侧为线性,具有固定梯度,与指数激活函数相比,ReLU 的梯度求导过程简单,极大地减少了计算量,使训练速度更快。

本文通过实验对比了两种优化算法,结果表明尽管 SGD 算法计算速度很快,但收敛很不稳定,损失曲线震荡比较剧烈;Adam 算法的损失曲线下降比较稳定,可以逐渐收敛。因此本文采用 Adam 优化算法进行训练。综上所述,本文的超参数设计如表 1 所示。

表 1 超参数表

参数	设定值
BP 模型数量	30
BP 模型隐含层层数	3
隐含层神经元数量	16,64,10
各层的激活函数	ReLU
损失函数	均方误差损失函数
优化器算法	Adam
优化器学习率	0.000 01
最大迭代次数	300

3 仿真实验结果与分析

3.1 评价指标

为了验证模型的准确性,使用平均绝对百分比误差(mean absolute percentage error, MAPE)、平均绝对误差(mean absolute error, MAE)和相对误差(relative error, RE)分布作为不同网络模型的性能评价指标。

3.2 实验结果与分析

为了比较提出的模型性能,选择与 BP 做对比。两种算法的运行总时长、训练时长和测试时长如表 2 所示。训练过程中 BP 与 AdaBoost-BP 中神经网络的结构和参数相同。

表 2 AdaBoost-BP 与 BP 的训练时长对比 单位:s


算法类型	总时长	模型训练时长	测试时长
BP	556.582	556.590	0.008
AdaBoost-BP	621.890	622.400	0.510

如表 2 所示,AdaBoost-BP 的运行总时长高于 BP。原因在于增加了多次分配权重的次数,从而增加了计算的复杂度。但在工程实践中,AdaBoost-BP 的测试时长可以满足工程应用。


4 个模型在测试集上的预测效果如图 6 所示,相应的预测精度如表 3 所示。

表 3 Adaboost-BP 与 BP 预测精度对比

方法	镀层种类	MAE	MAPE/%
BP	GA	1.629	3.513
AdaBoost-BP		1.249	2.721
BP	GI	2.370	3.162
AdaBoost-BP		1.650	2.313



(a) GA 镀层厚度预测相对误差分布图



(b) GI 镀层厚度预测相对误差分布图

图 6 镀层厚度相对误差分布图

通过图 6 可以清楚地看出:本文所建立的算法模型对镀层厚度的预测误差主要集中在 5% 以内,占比较 BP 有大幅度提升,且预测误差在 10% 以内的占比高达 99%,相较于文献[4]的误差主要分布在 20% 以内,本研究结果的误差主要分布

在 10% 以内,相对误差分布提高了 10%。

综上所述,与 BP 模型相比,本文提出的 AdaBoost-BP 镀层厚度估计模型在测试集估计效果更好,该方法可以使估计误差集中在较低水平,并更符合工业生产镀层厚度相对误差低于 $\pm 10\%$ 的要求。

4 结语

针对冷轧热镀锌钢板镀层厚度的预测,本文引入了一种基于 AdaBoost-BP 神经网络的镀层厚度估计建模方法。基于两个不同数据集的实验结果表明,采用构建多个 BP 模型以群体估计代替单一 BP 模型估计的策略是有效的。在构建多个 BP 模型的过程中,通过自适应调整训练样本的权重,有助于后续生成的 BP 模型更加专注地学习高误差样本,从而提高了模型的准确性。这种新提出的模型可以在提升镀锌质量方面发挥重要作用,并为现场生产工艺优化提供有益的指导。

参考文献:

- [1] PRINZ K, STEINBOECK A, MÜLLER M, et al. Online parameter estimation for adaptive feedforward control of the strip thickness in a hot strip rolling mill[J]. Journal of Manufacturing Science and Engineering, 2019, 141(7):071005.
- [2] PAN Z S, ZHOU X H, CHEN P. Development and application of a neural network based coating weight control system for a hot - dip galvanizing line [J]. Frontiers of Information Technology & Electronic Engineering, 2018, 19(7):834-846.
- [3] LIU Y, WANG X J, SUN J, et al. Strip thickness and profile - flatness prediction in tandem hot rolling process using mechanism model - guided machine learning [J]. Steel Research International, 2023, 94(1):2200447.
- [4] 王超. 极限学习机算法及其在热镀锌生产过程建模中的应用研究[D]. 沈阳:东北大学,2016.
- [5] 鲍成人,康永林,王龙. 气刀工艺对锌层厚度影响的数值模拟[J]. 钢铁研究学报,2016,28(8):39-43.
- [6] 赵兴时,张扬. 热镀锌机组锌层精度控制分析及优化[C]. 2015 年全国冷轧板带生产技术交流会议论文集. 温州:中国金属学会,2015:143-145.
- [7] 吴婷. 基于神经网络预测的涂层厚度控制系统研究[D]. 沈阳:东北大学,2008.
- [8] 吴剑胜,王天林,周玄昊,等. 基于神经网络的热镀锌镀层厚度建模与预测方法[J]. 中国仪器仪表, 2017(4):65-68.
- [9] 张岩,翟景峰,王军生,等. 基于深度映射多核的热镀锌镀层厚度预测[J]. 中国冶金, 2023, 33(8): 112-117.
- [10] 杨卫涛. 基于 BP_Adbost 设计的河南省地区经济运行分析[J]. 南阳理工学院学报,2016,8(1):46-48.
- [11] 杨定礼,赵正敏,白秋产. 基于 Adbost 与空间支持向量域分类的人脸检测[J]. 电路与系统学报, 2013,18(2):321-325.
- [12] 黄友坡,王中辉. 热基板镀锌镀层厚度波动影响分析[J]. 山东冶金,2023,45(3):32-34,37.
- [13] 张宏岭,向前,张彦文,等. 不同涂镀层对冷轧板拉伸性能的影响[J]. 物理测试,2025,43(1):14-19.
- [14] 仰照. 热镀锌锌层厚度在线闭环控制系统研究[D]. 合肥:安徽工业大学,2023.
- [15] 尚立立,孙晓敏,路金鹏,等. 降低 180 g 以上冷轧镀锌产品锌层超差率技术研究[J]. 河南冶金,2025, 33(1):51-53.
- [16] 闫鹏. 镀锌层厚度对金属耐腐蚀性能的影响研究[J]. 冶金与材料,2025,17(2):4-6.
- [17] 杨东红. 基于改进 BP 神经网络的新能源汽车销量预测[J]. 自动化与仪器仪表,2021(11):60-63.

收稿日期:2023-10-11