

GA-BP 神经网络结合 EDXRF 技术实现对中低合金钢中 Cr、Mn 和 Ni 元素含量的预测

宋海声¹, 陈召^{1*}, 徐大诚², 徐荣网³

¹西北师范大学物理与电子工程学院, 甘肃 兰州 730070;

²苏州大学电子信息学院, 江苏 苏州 215031;

³昆山书豪仪器科技有限公司, 江苏 苏州 215300

摘要 利用能量色散 X 射线荧光光谱分析(EDXRF)技术与遗传算法优化的反向传播(GA-BP)神经网络对中低合金钢中 Cr、Mn 和 Ni 元素进行含量分析。通过能量色散 X 射线荧光光谱仪对六类中低合金钢标准样品做激发处理, 获得 X 射线荧光光谱, 使用两点法扣除背景, 求得各元素对应 K_α 特征峰强度。利用所得 108 组谱线数据及其对应含量建立 GA-BP 神经网络, 使用训练完成的 GA-BP 神经网络对另外 36 组中低合金钢样本含量进行预测, 并将所预测结果与基本参数法分析结果和标准样品化学分析结果进行对比, Cr、Mn 和 Ni 元素含量平均误差分别为 0.0287%、0.0314% 和 0.0423%。实验结果表明, 遗传算法优化的 BP 神经网络适用于 EDXRF 对中低合金钢中 Cr、Mn 和 Ni 元素含量的分析。

关键词 X 射线光学; X 射线荧光光谱; 中低合金钢; 遗传算法; 逆向误差传播神经网络; 元素含量

中图分类号 TL82

文献标志码 A

DOI: 10.3788/LOP202259.1234001

Prediction of Cr, Mn, and Ni in Medium and Low Alloy Steels by GA-BP Neural Network Combined with EDXRF Technology

Song Haisheng¹, Chen Zhao^{1*}, Xu Dacheng², Xu Rongwang³

¹School of Physics and Electronic Engineering, Northwest Normal University, Lanzhou 730070, Gansu, China;

²School of Electronic Information, Soochow University, Suzhou 215031, Jiangsu, China;

³Kunshan Soohow Instrument Technology Co., Ltd., Suzhou 215300, Jiangsu, China

Abstract The Cr, Mn, and Ni content of medium and low alloy steel were analyzed using energy dispersive X-ray fluorescence spectroscopy (EDXRF) and black propagation neural network optimized by genetic algorithm (GA-BP). EDXRF was used to excite the six standard samples of medium and low alloy steel and the X-ray fluorescence spectra were obtained. The characteristic peak intensity of each element was obtained by subtracting the background using the two-point method. A total of 108 groups of spectral data and their corresponding content-based GA-BP neural network were obtained. To forecast the contents of 36 low alloy steel samples, the training completion of the GA-BP neural network was used. The predicted results and the fundamental parameter method analysis results were compared. The average errors of the chemical analysis results of the standard samples were 0.0287%, 0.0314%, and 0.0423% for Cr, Mn, and Ni, respectively. The experimental results showed that the BP neural network optimized by the genetic algorithm is suitable for the EDXRF analysis of Cr, Mn, and Ni in medium and low alloy steel.

Key words X-ray optics; X-ray fluorescence spectroscopy; medium and low alloy steel; genetic algorithm; error back propagation neural network; element content

收稿日期: 2021-04-30; 修回日期: 2021-06-15; 录用日期: 2021-06-27

通信作者: *chenzhao970316@163.com

1 引言

随着现代工业的飞速发展,社会生产生活对于具有耐蚀、耐磨、低温等良好性能的合金钢的需求越来越旺盛^[1],因此,对合金钢性能的研究具有重要意义。合金钢是在基础碳素钢中加了一定量合金元素而构成的铁碳合金。加入合金元素可改善抗氧化性能、提高钢的强度、提升塑性和工艺性能。合金元素包括:C、N、Cu、Mn、Ni、Co、W、Cr、Mo、V和Ti等。准确地测定合金钢中的合金元素含量,对于了解和控制合金钢的质量和性能具有重要意义。还能够促进研究合金元素对钢材性能的影响、开发新品种和提高钢材相关产品的质量^[2]。合金钢中的Cr、Mn和Ni元素是较为常见的成分元素^[3-4]。测定合金元素的方法很多,例如化学分析法、分光光度法、原子吸收光谱法和X射线荧光光谱法等。其中化学分析法最为精准,但是过程繁琐、分析速度慢,将化学分析法应用到生产过程不够现实,对于生产过程,无法进行实时控制。本文将化学分析法测定结果作为标准含量进行对比。X射线荧光光谱分析(XRF)法具有快速、准确、经济有效和可原位实时检测等诸多优点,X射线荧光光谱法分为两种,即能量色散X射线荧光光谱法(EDXRF)和波长色散X射线荧光光谱法(WDXRF)。本文所使用的就是能量色散X射线荧光光谱法。

X射线照射到样品上,样品受激发会产生二次射线,称为X射线荧光。X射线荧光包含样品的化学组成信息,不同元素产生的X射线荧光具有不同的波长和能量,从波长的角度去进行分析的方法称为波长色散X射线荧光光谱法;从能量的角度去进行分析的方法称为能量色散X射线荧光光谱法。通过测量一系列由样本辐射出的特征X射线的波长或者能量,即可确定元素的种类;分析测得的谱线强度,即可确定该元素的含量。

自20世纪60年代以来,由于固体探测器、核电子学和小型计算机的发展,EDXRF技术的使用越发广泛,已大范围应用于合金、塑料等物质的重金属测定。EDXRF是基于对元素特征X射线的识别以及对其荧光强度的计算来实现定性或定量分析的^[5]。X射线荧光光谱法中,定量分析的方法有:经验系数法、理论影响系数法、基本参数(FP)法以及一些包括神经网络在内的智能算法^[6],基本参数法是X射线荧光光谱分析领域中的一种进行元素定

量分析的具体方法,利用数学理论方法去校正基体效应,即利用一些参数,例如质量吸收系数、荧光产额、吸收边跳跃比、与探测器有关的几何因子和效率,再结合实验测得的荧光强度,即可计算求得含量定值。基本参数法是目前普遍使用且精度较高的一种元素定量分析方法,但是涉及物理常量及参数较多,数据的查找和计算比较复杂^[7]。本文提出基于遗传算法优化的误差反向传播(GA-BP)神经网络,实验结果表明,将GA-BP神经网络应用到EDXRF对中小合金钢中Cr、Mn和Ni元素的测定中具有良好的前景。

2 原理

2.1 EDXRF原理

能量色散X射线荧光光谱分析(EDXRF)是定性和定量测定样品中元素的技术,元素含量的测量结果与它们的化学形式无关。当一束X射线撞击样品时,它与样品中的原子相互作用包括三个过程,即光电效应、相干(瑞利)和非相干(康普顿)散射。光电效应过程中,当入射光子能量大于样本原子中的电子束缚能时,电子就会被击出,电子被击出伴随产生空穴,由于层级之间存在能量差,外层电子就会向内层跃迁以填补空穴,这样多余的能量就会以X射线的形式释放,此X射线称为二次X射线。即高能X射线照射到样品之上,样品中元素可产生二次X射线,又称X射线荧光,X射线荧光包括连续谱线和特征X射线。特征X射线能量和强度分别反映元素的性质和含量信息。依据Moseley定律^[8],各个元素的能量 E 是固定的,特征X射线的能量 E 只取决于元素种类,表示为

$$E = K(Z - s), \quad (1)$$

式中: K 和 s 是随光谱级数变化的常数; Z 是元素的原子序数。

利用EDXRF进行元素定量分析,包括三个步骤。首先要根据待测样品和元素及分析准确度要求,准备具有均匀和合适粒度的样品;其次选择合适的激发条件进行实验,对样品中的元素进行有效激发和实验测量;最后通过探测器采集和多道脉冲分析器处理,获得谱线强度数据,并在此基础上,借助一定的数学方法,定量计算分析物浓度^[9]。准确测量出待分析元素的谱峰净强度是分析测定出元素含量的第一要务。特征X射线的谱峰强度反映了相应元素的含量,而谱峰的净强度是在谱峰强度

减去背景后得到的。得到谱峰的净强度后,即可建立谱线强度与元素含量之间的函数关系。然而,对于复杂体系中主、次、微量元素的分析,需要进行复杂基体效应校正,谱峰净强度和元素含量的函数关系较为复杂,并非一定是线性关系。而BP神经网络具有很强的非线性拟合能力,适合于谱线数据向含量的过渡过程。

2.2 GA-BP

BP神经网络是误差反向传播算法的学习过程。BP神经网络具有出色的非线性拟合能力,在识别、分类和数量预测方面具有一定的优势。但由于BP神经网络是基于梯度下降法的,收敛速度较慢,误差函数极易陷入局部极小值,直接应用于实际工程中识别效果不理想。遗传算法是一种概率自适应迭代优化过程,全局搜索性能良好,不易陷入局部极小。即使定义的是不连续、不规则的适应度函数,也能快速准确地找到全局最优解,适合并行处理,具有不依赖梯度信息搜索的特点。本文利用该特征对BP神经网络的权值和阈值进行了优化,提高了网络的识别精度。这样,遗传算法和神经网络的优势互补,既充分利用了遗传算法的全局搜索能力,又充分利用了神经网络广泛的非线性映射能力,加快了网络学习速度,提升了整个学习过程中的逼近能力和泛化能力^[10-12]。




图1 BP神经网络结构图

Fig. 1 Structure diagram of BP neural network

构建遗传算法优化的BP神经网络具体步骤如下^[13-15]。

1) 构建网络

建立一个具有三层结构的BP神经网络,包括输入层的三个节点、隐含层的五个节点和输出层的三个节点。

2) 节点编码

如果输入层中的节点数为 n ,隐藏层中的节点数为 l ,输出层中的节点数为 m ,则编码长度为

$$H = n \times l + l \times m + l + m. \quad (2)$$

3) 种群初始化

对由染色体组成的种群进行初始化,设每个染色体的长度 $L = G + H$,其中 G 为隐含层节点二进制码的长度。

4) 适应度函数

适应度函数计算公式为

$$F = r \left[\sum_{i=1}^m (y_i - y'_i)^2 \right], \quad (3)$$

式中: m 是网络输出节点数; y_i 是第 i 个节点的预期输出; y'_i 是第 i 个节点的预测输出; r 是系数。

5) 选择操作

遗传算法的选择操作包括轮盘赌法、随机遍历法、锦标赛法等。本文选择轮盘赌,在轮盘赌中,个体被选择并以一定的概率传递给下一代种群,个体的概率与适应度的大小成正比。每个个体 k 的选择概率 P_k 表示为

$$f_k = \frac{r}{F_k}, \quad (4)$$

$$P_k = \frac{f_k}{\sum_{k=1}^M f_k}. \quad (5)$$

6) 交叉操作

第 s 个染色体 g_s 和第 t 个染色体 g_t 在位置 i 处的交点表示为

$$\begin{cases} g_{si} = g_{si}(1 - c) + g_{ti}c \\ g_{ti} = g_{ti}(1 - c) + g_{si}c \end{cases} \quad (6)$$

7) 变异操作

选择第 p 个个体的第 j 个基因进行突变,表示为

$$g_{pj} = \begin{cases} g_{pj} + (g_{pj} - g_{\max}) \cdot f(d), u > 0.5 \\ g_{pj} + (g_{\min} - g_{pj}) \cdot f(d), u \leq 0.5 \end{cases} \quad (7)$$

$$f(d) = u \left(1 - \frac{d}{T_{\max}} \right)^2, \quad (8)$$

式中: g_{\max} 是基因 g_{pj} 的上界; g_{\min} 是基因 g_{pj} 的下界; d 是当前迭代数; T_{\max} 是最大迭代次数; u 是 $[0, 1]$ 中的随机数。

8) BP神经网络预测

利用遗传算法获得最优个体,解码适应度最大的个体得到相应的连接权值和阈值,建立新的BP神经网络即GA-BP神经网络,并输出预测结果。

3 实验部分

3.1 实验条件

实验装置为 HITACHI X-MET8000 手持式 X 射线荧光光谱分析仪。实验装置的主要技术指标：管电压为 40 kV，管电流为 8 μA，激发时间为 6 s，探测器为硅漂移探测器(SDD)。环境温度为 24 ℃。实验仪器的含量分析方法为基本参数法。

3.2 实验样品

实验样品采用六类中低合金钢标准样品，六类中低合金钢标准样品包含 Cr、Mn 和 Ni 元素含量各不相同的各个标样。六类标准样品分别为：18CrNiW、30CrMnSiNiA、38CrMoAl、CrWMn、GSBH40067-93 和 YSBS15301-94。六类中低合金钢包含 Fe、Ti、V、Cr、Mn、Ni、Cu、Mo 和 C 等元素。Cr、Mn 和 Ni 三种元素含量范围如表 1 所示。

表 1 各类合金钢实验样本元素含量范围

Table 1 Element content range of experimental samples of various alloy steels unit: %

Sample name	Cr	Mn	Ni
18CrNiW	0.340-1.830	0.120-0.710	2.680-4.580
30CrMnSiNiA	0.587-1.592	0.744-1.607	0.971-2.064
38CrMoAl	0.995-2.028	0.161-0.691	0.069-0.443
CrWMn	0.319-1.354	0.172-1.280	0.037-0.245
GSBH40067-93	0.581-1.950	0.216-1.350	0.229-2.290
YSBS15301-94	0.313-1.520	0.292-1.310	0.521-3.180

3.3 实验过程

训练集包括：16 组 18CrNiW、20 组 30CrMnSiNiA、20 组 CrMoAl、16 组 CrWMn、24 组 GSBH40067-93 和 24 组 YSBS15301-94 数据，每组数据包含三维的输入和三维的输出，输入为 Cr、Mn 和 Ni 的特征峰净强度，输出为化学分析法测定对应样品的 Cr、Mn 和 Ni 元素含量。测试集包括 4 组 18CrNiW、5 组 30CrMnSiNiA、5 组 38CrMoAl、4 组 CrWMn、7 组 GSBH40067-93 和 7 组 YSBS15301-94，每组数据包括 Cr、Mn 和 Ni 的特征峰净强度。实验开始，使用 X 射线荧光光谱分析仪对样品分别进行激发，获得各个样品的谱线图。对谱线图的处理包括：对特征峰的定位，对特征峰的寻峰定位包括数值比较法、导数算法、连续小波变换算法、对称零面积变换算法、指数修正高斯拟合算法、多尺度谱峰定位等算法，本文选用数值比较法^[16]。特征峰选定 Cr、Mn 和 Ni 的 K_α 谱线的特征峰，Cr、Mn 和 Ni 的 K_α 峰能量分别

为 5.414、5.898、7.477 keV，对于 Cr、Mn 和 Ni 的荧光产额分别为 0.258、0.291、0.392，相较于 C、H 和 O 等轻元素，荧光产额较高一些，分析难度适中；特征峰净强度为特征峰总强度与背景之差。扣除背景使用两点法，如图 2 所示。




图 2 两点法扣除背景示意图

Fig. 2 Schematic of background subtraction by two-point method

两点法扣除背景获得特征峰净强度公式为

$$I_{net} = I_p - (I_H + I_L) / 2, \quad (9)$$

式中： I_{net} 为特征峰净强度； I_L 为特征峰左边点的强度； I_H 为特征峰右边点的强度，过左边点与右边点作切线； I_p 为特征峰顶点与 θ_p 处切线强度的差。

将 Cr、Mn 和 Ni 元素的特征峰净强度作为 GA-BP 神经网络的输入、3 种元素的标准含量(化学分析法)作为神经网络模型对应的输出，对 GA-BP 神经网络进行训练。输入层 3 个神经元，隐含层 5 个神经元，输出层 3 个神经元。神经网络隐含层神经元个数的确定一般利用经验公式法和逐步逼近法。根据 Kolmogorov 定理，经验公式包括以下两个公式，

$$n_2 = \sqrt{n_1 + m + 1} + a, \quad (10)$$

$$n_1 = \log_2 n_2. \quad (11)$$

神经网络构建中隐含层神经元数目为 n_2 ，输入层数目为 n_1 ，输出层数目为 m ； a 的取值范围为 1~10。本文选用式(10)，输入层数目为 3，输出层为 3， a 的值采用逐步逼近的方式进行确定，在 $a=3$ 时，GA-BP 神经网络具有较好的训练效果，由此确定隐含层神经元个数为 5。选择 tansig 函数作为输入层到隐含层的激发函数，选择 purelin 函数作为隐含层到输出层的激发函数，训练函数选择 trainlm，trainlm 训练函数使用 Levenberg-Marquardt 优化算法，是神

表 2 GA-BP 神经网络重要参数
Table 2 Important parameters of GA-BP neural network

Parameter	Numeric value	Parameter	Numeric value
Training sample	108×3	Output layer Activation function	purelin
Test sample	36×3	Population size	45
Input neuron	3	Iteration ordinal Number	20
Hidden layer neuron	5	Learning rate	0.1
Output layer neuron	3	Training steps	1000
Training function	trainlm	Crossover rate	0.2
Hidden layer Activation function	tansig	Mutation rate	0.0025

神经网络中较为常用且高效的训练函数。GA-BP 神经网络的关键相关参数列于表 2。在训练完成遗传算法优化之后,得到 GA-BP 神经网络模型,对 36 组测试样本进行含量的预测。

4 实验结果与分析

训练样本的输入节点数设置为 108×3 的矩阵,输出节点数设置为 108×3 的矩阵。图 4 为训练过程得到的均方差(MSE)曲线,训练到 18 次后 MSE 趋于稳定,达到 0.00078347,误差水平可达 10⁻³。从图 3 可以看出,误差要求 10⁻⁴ 以内,神经网络的预测误差与设定的阈值误差十分接近,这表明该网络具有较强的全局搜索能力,在很大程度上能避免网络陷入局部最小值,有效提高网络的识别精度。其中,train、validation、test、best 和 goal 分别表示训练结果、实验结果、测试曲线、最佳目标和最佳训练阈值。如图 4 所示,相关系数为 0.99814,表明网络输出值和期望值的拟合度比较高,网络输出值与期望值基本保持一致,遗传算法优化的 BP 神经网络可以应用到 EDXRF 分析低合金钢中 Cr、Mn 和 Ni 元素含量中。

使用 GA-BP 神经网络和基本参数法分别在同

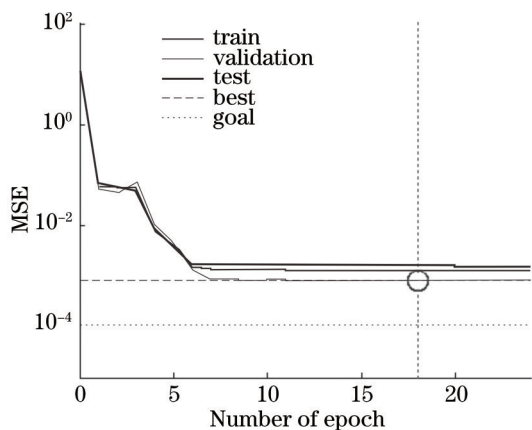


图 3 训练过程的均方差曲线
Fig. 3 Mean square error curve of training process

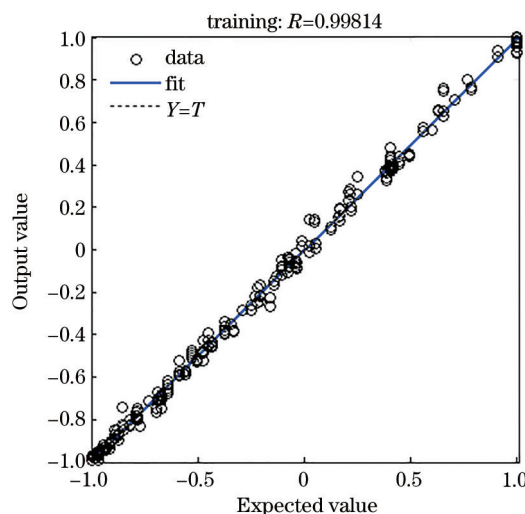


图 4 训练过程的线性回归结果
Fig. 4 Linear regression results of training process

一实验条件下,对相同的 36 组中低合金钢样本中 Cr、Mn 和 Ni 三种元素含量进行分析。将化学分析法测定的样本中 Cr、Mn 和 Ni 三种元素含量作为标准含量,图 5(a)~(c)分别展示了 Cr、Mn 和 Ni 三种元素分析结果,由图 5 可知,对于 Cr 和 Ni 元素,GA-BP 神经网络预测的误差折线相较于基本参数法分析的误差折线更为稳定。对于 Mn 元素,GA-BP 神经网络预测的误差折线,在稳定性上没有明显优势。经过计算,Cr 元素 GA-BP 神经网络预测结果的平均误差为 0.0287%;Mn 元素 GA-BP 神经网络预测结果的平均误差为 0.0314%;Ni 元素 GA-BP 神经网络预测结果的平均误差为 0.0423%。GA-BP 神经网络对三种元素含量都有很好的预测效果。

表 3 是用训练好的网络对部分实验样本(CrWMn)进行预测所得的结果。表中列出了使用 GA-BP 神经网络对 CrWMn 系列的五个样本中 Cr、Mn 和 Ni 三种元素含量的预测结果,同时给出了使用化学分析法和基本参数法对样本的分析结果,将

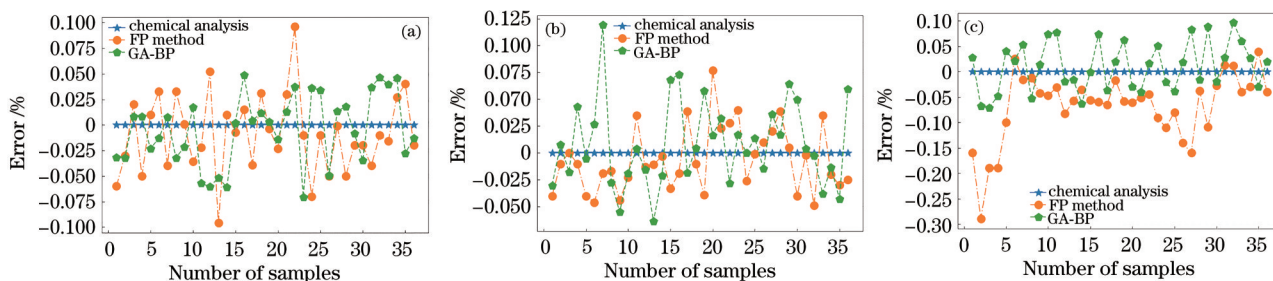


图 5 GA-BP 和 FP 法对三种元素的分析结果误差分布。(a) Cr 元素; (b) Mn 元素; (c) Ni 元素

Fig. 5 Error distributions of analysis results of three elements by GA-BP and FP methods. (a) Cr element; (b) Mn element; (c) Ni element

表 3 CrW Mn 系列样本预测结果

Table 3 Prediction results of CrW Mn series samples

unit: %

Sample	Analysis method	Cr		Mn		Ni	
		Predicted value	Relative standard deviation	Predicted value	Relative standard deviation	Predicted value	Relative standard deviation
CrW Mn1	Standard	0.319		1.280		0.037	
	FP	0.350	9.718	1.270	0.781	0.020	45.946
	GA-BP	0.330	3.448	1.285	0.391	0.057	54.054
CrW Mn2	Standard	0.444		0.959		0.088	
	FP	0.440	0.901	0.920	4.067	0.030	65.909
	GA-BP	0.447	0.676	1.017	6.048	0.151	71.591
CrW Mn3	Standard	0.763		0.883		0.131	
	FP	0.740	3.014	0.960	8.720	0.070	46.565
	GA-BP	0.749	1.835	0.899	1.812	0.101	22.901
CrW Mn4	Standard	1.060		0.347		0.191	
	FP	1.090	2.830	0.370	6.628	0.140	26.702
	GA-BP	1.073	1.226	0.379	9.222	0.151	20.942
CrW Mn5	Standard	1.354		0.172		0.245	
	FP	1.450	7.090	0.200	16.279	0.200	18.367
	GA-BP	1.391	2.733	0.144	16.279	0.261	6.531

化学分析法的分析结果作为标准含量。可以看出, GA-BP 神经网络对三种元素含量都有很好的预测结果。对于 Cr 元素, GA-BP 神经网络预测结果平均相对标准偏差为 1.984%, 小于基本参数法 4.711% 的结果, 并且五个样本相对标准偏差皆小于基本参数法的相对标准偏差; 对于 Mn 元素, GA-BP 神经网络预测结果平均相对标准偏差为 6.75% 小于基本参数法 7.295% 的结果; 对于 Ni 元素, GA-BP 神经网络预测结果平均相对标准偏差为 35.204%, 小于基本参数法 40.698% 的结果。数据表示, GA-BP 神经网络可以准确地应用于 Cr、Mn 和 Ni 元素含量的预测。

5 结 论

基本参数法作为目前 EDXRF 的定量分析技术领

域中应用较为普遍且准确度较高的一种方法, 具有较高的参考价值。本文采用遗传算法优化的 BP 神经网络, 对 36 组元素含量不尽相同的中低合金钢样本进行含量分析。实验结果表明, GA-BP 神经网络预测结果的误差总体较小, 具有较高的精准度, 相较于基本参数法, 仍然在 Cr、Mn 和 Ni 元素含量的分析精准度上拥有明显优势。这表明, GA-BP 神经网络在 EDXRF 对中低合金钢的元素分析领域具有良好的前景。

参 考 文 献

[1] 张金生, 李丽华, 金钦汉. 微波消解-微波等离子体炬原子发射光谱法测定合金钢中的铜、锰、钼[J]. 分析实验室, 2004, 23(7): 31-33.
Zhang J S, Li L H, Jin Q H. Determination of copper, manganese and molybdenum in the alloy steels by microwave digestion-microwave plasma

- torch atomic emission spectrometry[J]. Analytical Laboratory, 2004, 23(7): 31-33.
- [2] 张洪志, 莫庆军. 中低合金钢中 16 种微量元素的光谱分析[J]. 山东冶金, 1998, 20(1): 46-48.
Zhang H Z, Mo Q J. Spectral analysis of 16 trace elements in medium-low alloy steels[J]. Shandong Yejin, 1998, 20(1): 46-48.
- [3] 刘平. 利用 X 荧光能谱仪快速测定合金钢中钛元素[J]. 分析仪器, 2017, (4): 75-78.
Liu P. Rapid analysis of titanium in ferroalloy by X-ray fluorescence energy spectrometer[J]. Analytical Instrumentation, 2017, (4): 75-78.
- [4] 刘平, 孙金龙, 田禾. 利用 X 射线荧光能谱仪快速测定合金钢中锰元素[J]. 中国锰业, 2017, 35(6): 106-109, 122.
Liu P, Sun J L, Tian H. A rapid analysis of manganese in ferroalloy by X-ray fluorescence energy spectrometer[J]. China's Manganese Industry, 2017, 35(6): 106-109, 122.
- [5] 冉景, 王德建, 王灿, 等. 便携式 X 射线荧光光谱法与原子吸收/原子荧光法测定土壤重金属的对比研究[J]. 光谱学与光谱分析, 2014, 34(11): 3113-3118.
Ran J, Wang D J, Wang C, et al. Comparison of soil heavy metals determined by AAS/AFS and portable X-ray fluorescence analysis[J]. Spectroscopy and Spectral Analysis, 2014, 34(11): 3113-3118.
- [6] 吉昂. X 射线荧光光谱三十年[J]. 岩矿测试, 2012, 31(3): 383-398.
Ji A. Development of X-ray fluorescence spectrometry in the 30 years[J]. Rock and Mineral Analysis, 2012, 31(3): 383-398.
- [7] 李纪民, 张桂芹, 舒培桂. X 射线荧光分析中基本参数法的应用[J]. 原子能科学技术, 1989, 23(1): 15-19.
Li J M, Zhang G Q, Shu P G. Application of the fundamental-parameters method in X-ray fluorescence analysis[J]. Atomic Energy Science and Technology, 1989, 23(1): 15-19.
- [8] Albertini V R, Paci B, Generosi A. Energy-dispersive, X-ray fluorescence analysis[M]//Encyclopedia of analytical chemistry: applications, theory and instrumentation. Weinheim: John Wiley & Sons, 2006: 1-17.
- [9] 罗立强, 詹秀春, 李国会. X 射线荧光光谱分析[M]. 2 版. 北京: 化学工业出版社, 2015.
Luo L Q, Zhan X C, Li G H. X-ray fluorescence spectrometry[M]. 2nd ed. Beijing: Chemical Industry Press, 2015.
- [10] 肖佳琳, 岳殿武, 赵政铎, 等. 基于遗传算法优化 BP 神经网络的可见光定位[J]. 光电子·激光, 2019, 30(8): 810-816.
Xiao J L, Yue D W, Zhao Z D, et al. A visible light localization algorithm based on BP neural network optimized by genetic algorithm[J]. Journal of Optoelectronics·Laser, 2019, 30(8): 810-816.
- [11] 彭基伟, 吕文华, 行鸿彦, 等. 基于改进 GA-BP 神经网络的湿度传感器的温度补偿[J]. 仪器仪表学报, 2013, 34(1): 153-160.
Peng J W, Lü W H, Xing H Y, et al. Temperature compensation for humidity sensor based on improved GA-BP neural network[J]. Chinese Journal of Scientific Instrument, 2013, 34(1): 153-160.
- [12] 郭亮, 林远添, 张震华, 等. 不锈钢激光着色机理及基于神经网络的颜色预测[J]. 中国激光, 2016, 43(11): 1102008.
Guo L, Lin Y T, Zhang Z H, et al. Mechanism of laser coloration of stainless steel and color prediction based on neural network[J]. Chinese Journal of Lasers, 2016, 43(11): 1102008.
- [13] Xue H X, Bai Y P, Hu H P, et al. Influenza activity surveillance based on multiple regression model and artificial neural network[J]. IEEE Access, 2018, 6: 563-575.
- [14] 王俊, 刘明哲, 庾先国, 等. 遗传算法优化的 BP 神经网络在 EDXRF 中对钛铁元素含量的预测[J]. 原子能科学技术, 2015, 49(6): 1143-1148.
Wang J, Liu M Z, Tuo X G, et al. BP neural network optimized by genetic algorithm approach for titanium and iron content prediction in EDXRF[J]. Atomic Energy Science and Technology, 2015, 49(6): 1143-1148.
- [15] 王书涛, 王兴龙, 陈东营, 等. GA-BP 神经网络在检测微量磷酸盐中的应用[J]. 中国激光, 2015, 42(5): 0515001.
Wang S T, Wang X L, Chen D Y, et al. Application of GA-BP neural network in detection of trace phosphate[J]. Chinese Journal of Lasers, 2015, 42(5): 0515001.
- [16] 于坤, 焦青亮, 刘子龙, 等. 基于改进正弦余弦算法的光谱特征峰定位方法[J]. 光学学报, 2019, 39(9): 0930008.
Yu K, Jiao Q L, Liu Z L, et al. Positioning of characteristic spectral peaks based on improved sine cosine algorithm[J]. Acta Optica Sinica, 2019, 39(9): 0930008.