

基于 IIGA-BP 神经网络的钢材销售预测模型^①



陈永当^{1,2}, 曹坤煜^{1,2}

¹(西安工程大学 机电工程学院, 西安 710600)

²(西安市现代智能纺织装备重点实验室, 西安 710600)

通讯作者: 曹坤煜, E-mail: cao_kunyu@163.com

摘要: 为克服传统 BP 神经网络 (BP Neural Network, BPNN) 在销售预测中, 预测精度低、收敛速度慢的缺点. 提出了一种基于改进免疫遗传算法 (Improved Immune Genetic Algorithm, IIGA) 优化 BP 神经网络的销售预测模型. 改进的免疫遗传算法提出了新的种群初始化方式、抗体浓度的调节机制及自适应交叉算子、变异算子的设计方法, 有效的提高了 IIGA 的收敛能力和寻优能力. 并用 IIGA 优化 BPNN 的初始权值和阈值, 改善网络参数的随机性导致 BPNN 输出不稳定和易陷入局部极值的缺点. 以某钢铁企业的历史销售数据为例进行实证研究, 利用 Matlab 分别构建 BP、IGA-BP 和 IIGA-BP 神经网络预测模型进行仿真对比分析. 实验证明, IIGA-BP 神经网络预测模型较 BP 神经网络预测模型预测精度提高了 23.82%, 较 IGA-BP 神经网络预测模型预测精度提高了 22.02%. IIGA-BP 神经网络模型对钢材销售预测的泛化性能更好, 预测效果更稳定误差基本保持在 [-0.25, 0.25] 之间, 预测精度大幅度提高, 为企业销售预测提供了一种较为有效的方法.

关键词: BP 神经网络; 免疫遗传算法; 灰色关联分析; 主成分分析; 销售预测

引用格式: 陈永当, 曹坤煜. 基于 IIGA-BP 神经网络的钢材销售预测模型. 计算机系统应用, 2021, 30(10): 138-147. <http://www.c-s-a.org.cn/1003-3254/8067.html>

Sales Forecasting Model for Steel Product Based on IIGA-BP Neural Network

CHEN Yong-Dang^{1,2}, CAO Kun-Yu^{1,2}

¹(School of Mechanical and Electrical Engineering, Xi'an Polytechnic University, Xi'an 710600, China)

²(Xi'an Key Laboratory of Modern Intelligent Textile Equipment, Xi'an 710600, China)

Abstract: To eliminate the shortcomings of low precision and slow convergence in the sales forecasting based on the traditional BP Neural Network (BPNN), this study proposes a new model based on an Improved Immune Genetic Algorithm (IIGA) optimized BP neural network. IIGA presents a new way of population initialization, a regulatory mechanism of antibody concentration, and a design method of adaptive crossover operators and mutation operators. Therefore, the convergence ability and global search ability of IIGA are greatly improved. In addition, IIGA can optimize the initial weights and thresholds of the BP neural network and overcome the drawbacks of output instability of the BP neural network and proneness to local minimum induced by the randomness of network parameters. With the past records of sales figures in a steel enterprise as an example, the BP, IGA-BP and IIGA-BP neural network forecasting models are built with Matlab for simulation comparison. The experiments demonstrate that the precision of the IIGA-BP model is 23.82% higher than that of the BP model and 22.02% higher than that of the IGA-BP model. The IIGA-BP model

① 基金项目: 中国纺织工业联合会科技项目 (2016091, 2019064); 西安市科技计划 (201805030YD8CG14-16); 西安市科技创新平台/重点实验室建设项目 (2019220614SYS021CG043); 西安工程大学青年学术骨干支持计划

Foundation item: China National Textile and Apparel Council Project (2019064, 2016091); S & T Program of Xi'an Municipality (201805030YD8CG14-16); Xi'an Science and Technology Innovation Platform/Key Laboratory Project (2019220614SYS021CG043); Youth Academic Backbone Support Plan of Xi'an Polytechnic University

收稿时间: 2020-11-22; 修改时间: 2020-12-22; 采用时间: 2021-01-18

possesses better generalization about steel sales forecasting and more stable forecasting, with errors basically in the range of -0.25 to 0.25 , and its forecasting precision is dramatically improved. The proposed model provides a more effective method for sales forecasting in enterprises.

Key words: BP Neural Network (BPNN); Immune Genetic Algorithm (IGA); grey relation analysis; principal component analysis; sales forecasting

随着企业市场化进程的不断推进,企业间的竞争压力及销售市场的不稳定程度与日俱增.如何合理、准确预测产品的市场需求,已成为现代企业控制产能,有效规避经营风险,实现精准营销的重要举措^[1].因此销售预测是现代企业经营管理中不可或缺的一环,预测的准确性也直接关系到企业生产经营的成败.为准确预测企业在未来时间内的销售量,国内外学者再度掀起了对预测模型的研究.

近年来,国内外学者针对预测模型进行了大量研究,并相继提出了神经网络、极限学习、机器学习、时间序列模型等销售预测方法^[2-4].神经网络因其具有强大的自适应学习能力和较好的非线性拟合能力,而被广泛应用于销售预测模型的构建^[5].其中,最具代表性的BP神经网络(BP Neural Network, BPNN)因其完备的理论体系已逐渐成为学者们关注的重点.如:吴正佳等^[6]针对备货型企业的销售情况,利用BPNN强大的学习和存贮信息的能力,建立了基于BPNN的销售预测模型.Qin等^[7]通过选取网络类型在制定网络参数优化机制的基础上,提出了BPNN销售预测模型.高文等^[8]采用logsig激励函数,在对影响因素数据收集与降维处理的基础上,建立了基于BPNN的预测模型.Bibaudalves等^[9]以数据的季节性与价值性为导向,提出了一种采用月平均值具有最佳结构的神经网络销售预测模型.但由于易陷入局部极值和对初始网络权重敏感性等问题是BPNN难以避免的不足,对此,学者们提出了许多优化BPNN的有效方法.如:查刘根等^[10]利用免疫算法优化BPNN的初始权值和阈值,提出了基于免疫遗传算法的BPNN预测方法.郑建刚等^[11]提出了一种改进的免疫遗传算法,扩大了BPNN模型中权值的搜索空间,提高了BPNN的学习效率和精度.Cheng等^[12]提出了一种基于自适应免疫遗传算法优化BPNN的网络流量预测新方法.朱玉等^[13]提出一种基于IGA的BP网络应用于煤与瓦斯的突出强度预测.Yang等^[14]采用免疫遗传算法优化BPNN的权值,建

立了用电量增长率的神经网络预测模型.张浩等^[15]提出了一种自适应免疫遗传算法优化的BP神经网络用于粮食产量预测研究.Wang^[16]运用免疫遗传算法优化神经网络,进行电力负荷预测.Yun等^[17]提出了一种基于父辈免疫遗传算法的碳纤维性能预测神经网络模型.王华强等^[18]将用免疫遗传算法全局寻优和BP网络局部寻优相结合提出了IGA-BP网络模型并应用于高炉铁水硅含量的预测.Huang^[19]将免疫遗传算法与小波神经网络相结合,实现了对离心式压缩机性能的预测.付传秀等^[20]将免疫遗传算法与BP神经网络相融合,对中国区域经济协调发展水平进行预测.这些采用免疫遗传算法优化BPNN的研究,在一定程度上解决了BPNN的不足,但由于免疫遗传算法自身存在着早熟收敛和种群质量低下等问题.因此只有在进一步改进优化的基础上才能更好的解决BPNN的预测问题.

综上所述,BPNN虽然在销售预测方面取得较好的效果.但由于传统BPNN利用梯度下降原理对网络参数进行调节,存在收敛速度慢、易陷入局部最优的缺点,且该算法初始权值和阈值的随机选取致使神经元缺乏调节能力,基于此本文提出了改进免疫遗传算法与传统BP神经网络模型于一体的有效的神经网络销售预测模型.利用改进的免疫遗传算法(Improved Immune Genetic Algorithm, IIGA)中特有的种群初始化方式、抗体浓度调节机制及交叉算子、变异算子自适应调节策略解决免疫遗传算法(Immune Genetic Algorithm, IGA)的早熟收敛问题,进而初始化BPNN各连接层的权值和阈值,改善网络参数随机性导致BP神经网络输出不稳定和易陷入局部极值的缺点,从而提高算法的收敛速度和模型的预测精度.

1 改进免疫遗传算法优化BP神经网络设计

1.1 BP神经网络

BP神经网络是含有一个或多个隐含层的多层前馈神经网络,其较强的非线性拟合能力是解决不确定

性问题的数学模型. 它采用逆向传播算法基于梯度下降原理以监督学习的方式实现模式识别和函数逼近功能, 是目前应用最为广泛的神经网络^[21]. 最为典型的3层神经网络结构, 可以实现任何函数输入到输出分布式并行信息处理的高度非线性映射, 通过数据信息的正向传递和误差的反向传播按一定的规则不断调整权值阈值, 修正网络误差, 直至输出误差或训练次数满足预定条件, 如图1. 该网络结构具有一个隐含层, 输入节点数为 x_m , 输出节点数为 y_n ; w_{ij} 、 w_{jk} 分别为各连接层间的权值向量; θ_j 、 ζ_k 分别为隐含层与输出层的阈值向量.

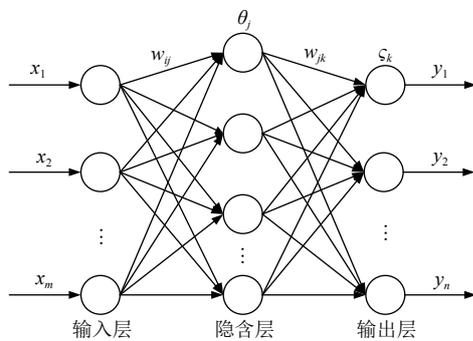


图1 BP神经网络结构图

1.2 改进免疫遗传算法优化BP神经网络原理

免疫遗传算法是一种模拟生物免疫原理和遗传进化过程的新型进化优化算法, 是具有免疫功能的遗传算法. 通过在免疫算子中加入遗传算子, 兼顾搜索速度与搜索能力的同时, 又避免了遗传算法的退化现象及早熟收敛问题. 它将需要优化的参数编码形成串联群体, 通过免疫遗传进化操作, 将种群进化到更好的搜索空间, 使种群中的个体达到最优^[22]. 免疫遗传算法较为突出的寻优能力和种群多样性保持机制, 正好弥补BP神经网络的不足, 但标准免疫遗传算法在处理复杂优化问题上仍存在收敛速度慢和局部极值问题. 因此, 考虑改进免疫遗传算法对BP神经网络进行优化.

本文采用改进免疫遗传算法从以下3个方面优化BP神经网络:

- (1) 确定网络拓扑结构
- (2) 优化BP神经网络初始权值和阈值

以种群中最优抗体的适应度为导向利用免疫遗传算法寻优, 得到全局适应度最高的一组网络参数即为初始权值和阈值.

(3) 仿真预测

将得到的初始权值和阈值, 回代BP网络在训练期间再次局部寻优, 获得最优权值阈值, 进而实现最佳预测输出.

1.3 改进免疫遗传算法优化BP神经网络过程

先对免疫遗传算法的种群初始化方式、抗体浓度的调节机制及交叉算子、变异算子的自适应调节策略进行改进. 用改进的免疫遗传算法以种群中最优抗体的适应度值为导向进行全局寻优, 定位最优解的参数空间, 再用BP算法的局部寻优能力通过Bayesian函数对网络权值和阈值进行精调, 使网络输出值逐步逼近期望值, 最后经过反归一化得到预测值. 采用改进免疫遗传算法优化BP神经网络算法流程, 如图2.

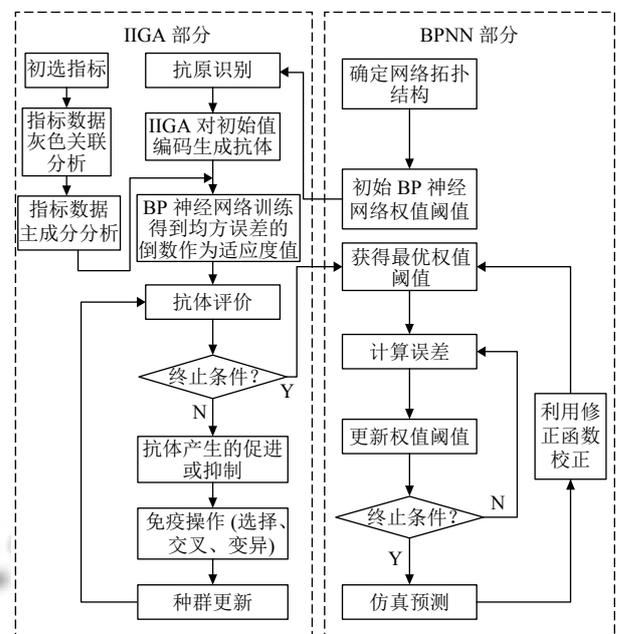


图2 改进免疫遗传算法优化BP神经网络算法流程图

具体步骤如下:

- (1) 确定网络拓扑结构
- (2) 抗原识别

抗原对应问题的目标函数即网络预测的均方误差最小.

$$E(x) = \min E = \min \frac{1}{2m} \sum_{i=1}^m \sum_{j=1}^n (Q_{ij} - Y_{ij})^2 \quad (1)$$

式中, m 为样本总数, n 为输出节点总数; Q_{ij} 、 Y_{ij} 分别为第 i 个抗体对应神经网络的期望输出值与预测输出值.

(3) 产生初始抗体

为避免初始权值阈值随机化, 计算效率较低的弊端, 在保证种群多样性的同时加快算法收敛速度. 本文先采用 Nguyen-Widrow 方法^[23]产生 70% 初始种群; 剩余 30%, 采用多次进化随机生成的方法, 在每次生成的抗体群中只保留部分适应度较高的抗体, 并将抗体群中适应度较弱的抗体, 在下次进化过程中进行替代, 以此为循环, 直至达到随机生成的种群规模.

Nguyen-Widrow 方法:

$$w = 0.7 \times s^{1/r} \text{normr}(2\text{rand}(s, r) - I(s, r)) \quad (2)$$

$$\theta = 0.7 \times s^{1/r} \text{normr}(2\text{rand}(s, l) - I(s, l)) \quad (3)$$

式中, w 为权值矩阵, θ 为阈值矩阵; s 、 r 分别为网络隐含层节点数与输入指标的维数; $\text{rand}(s, r)$ 为 s 行 r 列的均匀分布的随机数矩阵; $I(s, l)$ 为 s 行 r 列的全 1 矩阵; $\text{normr}(J)$ 为 J 矩阵的标准化归一矩阵.

(4) 抗体编码

本文采用实数编码方式对神经网络初始连接权值及阈值编码, 得到随机分布的基因码串, 每一个基因码串, 对应一组权值阈值.

抗体编码长度为:

$$S = n \times m + m \times l + m + l \quad (4)$$

式中, n 、 m 、 l 分别为输入层、隐含层及输出层节点数.

(5) 亲和度计算

① 抗体与抗原之间的亲和度

抗体与抗原间的亲和度大小是决定抗体优劣的评判标准, 以训练数据均方误差的倒数作为免疫遗传算法的原始亲和度函数即适应度函数.

适应度函数为:

$$f(x) = \frac{1}{\alpha + E(x)} \quad (5)$$

式中, α 为避免分母为零的小正量; $E(x)$ 为网络的目标函数.

为了防止进化初期, 初始抗体群中的特殊抗体误导种群的发展方向. 本文采用线性调整策略, 对适应度函数进行调整^[24].

$$f' = \beta \frac{f + f_{\min}}{f_{\max} + f_{\min}} \quad (6)$$

式中, f_{\max} 、 f_{\min} 分别为当代种群中最大与最小的适应度值; f 为当前抗体的适应度值; f' 为修正后抗体适应度值; β 为调节系数.

② 抗体与抗体之间的亲和度

本文采用欧几里得距离作为衡量抗体间相似度的重要指标. 抗体 $v = \{v_1, v_2, \dots, v_n\}$ 与抗体 $r = \{r_1, r_2, \dots, r_n\}$ 之间的欧氏距离^[25] 为:

$$d_v = \sum_{1 \leq i \leq n} \sqrt{(v_i - r_i)^2} \quad (7)$$

亲和度为:

$$S_{v,r} = \frac{1}{1 + d_v} \quad (8)$$

式中, $S_{v,r} \in (0, 1)$ 反映了抗体 v 与抗体 r 之间的相似程度.

抗体浓度为:

$$C_v = \frac{1}{N} \sum_{r=1}^N S_{v,r} \quad (9)$$

式中, C_v 反应种群中相似抗体所占的比例; N 为抗体总数; $S_{v,r} = \begin{cases} 1, & \rho \cdot S_r \leq S_v \leq \lambda \cdot S_r \\ 0, & \text{其他} \end{cases}$, ρ 与 λ 为调节系数, ρ 稍小于 1 通常取 0.9-1, λ 稍大于 1 通常取 1-1.1. 这样抗体浓度的计算既考虑相同抗体又考虑了相似抗体.

(6) 基于浓度的种群调节

为避免简单的选择操作, 使适应度高的抗体逐渐积累导致抗体浓度过高的情况. 根据免疫机制中抗体间因浓度的不同而相互抑制的原理, 引入浓度调节因子调节抗体被选择的概率 P_s . 对任意抗体 v_i, v_j 如果 $|f(v_i) - f(v_j)| \leq \xi$, $\xi > 0$, 则抗体 v_i 被选择的概率为:

$$P_s(v_i) = \alpha C_i \left(1 - \frac{f(v_i)}{\max f(v)} \right) + \beta \frac{f(v_i)}{\max f(v)} \quad (10)$$

式中, α, β 为 0-1 间的可变参数; C_i 为抗体 v_i 的浓度; $f(v_i)$ 为抗体 v_i 的适应度值; $\max f(v)$ 为种群中最大适应度值. 这样既保留了适应度较高的抗体, 又抑制了浓度高的抗体, 保持了种群的多样性, 提高了算法的收敛能力.

(7) 免疫操作

① 克隆选择

按照精英保留与轮盘赌相结合的策略进行克隆选择操作. 在每次更新记忆库时, 先将适应度较高的抗体进行保存, 再按照式 (10) 计算出选择概率大小将种群中优秀的抗体存入记忆库.

② 自适应交叉与变异

为了使算法的交叉与变异概率能够根据种群中抗

体适应度高低和算法进化代数进行自适应调整, 则需对交叉和变异概率进行参数设计。

交叉概率 P'_c , 变异概率 P'_m 为:

$$P'_c = \begin{cases} \frac{P_c(T-t) \sin\left(\frac{\pi}{2} + \frac{f' - f_{avg}}{f_{max} - f_{avg}}\right)}{T}, & f' > f_{avg} \\ \frac{P_c(T-t) \sin\left(\frac{\pi}{2} \frac{f_{avg} - f'}{f_{avg} - f_{min}}\right)}{T}, & f' \leq f_{avg} \end{cases} \quad (11)$$

$$P'_m = \begin{cases} \frac{P_m(T-t) \sin\left(\frac{\pi}{2} + \frac{f - f_{avg}}{f_{max} - f_{avg}}\right)}{T}, & f > f_{avg} \\ \frac{P_m(T-t) \sin\left(\frac{\pi}{2} \frac{f_{avg} - f}{f_{avg} - f_{min}}\right)}{T}, & f \leq f_{avg} \end{cases} \quad (12)$$

式中, f' 为待交叉抗体的最大适应度值; f_{max} 为当前种群的最大适应度值; f_{avg} 为当前种群的平均适应度值; f_{min} 为当前种群的最小适应度值; f 为待变异抗体的适应度值; t 为算法当前的进化代数; T 为算法的总进化代数; P_c 、 P_m 分别为交叉与变异概率的初始值。

(8) 网络初始权值和阈值的确定

以种群中最优抗体的适应度为导向循环进行评价、选择、交叉、变异等操作, 直到达到设定的进化代数, 选择适应度最高的一组网络参数即为初始权值和阈值。

(9) 仿真预测

取得初始权值、阈值后, 利用 BP 算法进行学习, 不断调整, 直至满足既定的网络误差或达到最大进化代数, 得到最优权值和阈值, 并实现预测输出。

2 钢材销售预测模型的建立

2.1 钢材销售主要影响因素识别

钢材的销售状况受各种复杂因素的影响, 以某钢铁企业的历史销售数据为例, 从影响钢材销售量的众多因素中选取国内生产总值(X_1)、钢材出口量(X_2)、钢材进口量(X_3)、房地产开发投资(X_4)、金属切削机床产量(X_5)、拖拉机产量(X_6)、全社会固定资产投资(X_7)、车辆产量(X_8)、全国建筑业总产值(X_9)作为初选指标。9 个影响因素数据选自 1994—2018 年《中国统计年鉴》^[26], 如表 1。

表 1 某钢铁企业钢材销售量及影响因素数据

年份	国内生产总值(亿元)	钢材出口量(万吨)	钢材进口量(万吨)	房地产开发投资(亿元)	金属切削机床产量(万台)	拖拉机产量(万台)	全社会固定资产投资(亿元)	车辆产量(万辆)	全国建筑业总产值(亿元)	钢材销售量(万吨)
1994	48637.50	151.00	2245.00	2554.00	20.65	4.67	17042.10	163.56	4653.32	3101.56
1995	61339.90	567.00	1397.00	3149.00	20.34	6.33	20019.30	178.97	5793.75	3311.23
1996	71813.60	422.00	1599.00	3216.40	17.74	8.37	22974.00	185.81	8282.25	3448.45
1997	79715.00	462.00	1323.00	3178.40	18.65	8.24	24941.10	206.85	9126.48	3681.89
1998	85195.50	357.00	1242.00	3614.20	11.91	6.78	28406.20	213.71	10061.99	4070.25
1999	90564.40	368.00	1486.00	4103.20	14.22	6.54	29854.70	240.30	11152.86	4503.76
2000	100280.10	621.00	1596.00	4984.10	17.66	4.10	32917.70	267.70	12497.60	4885.48
2001	110863.10	474.00	1722.00	6344.10	25.58	3.82	37213.50	304.53	15361.56	6104.69
2002	121717.40	545.00	2449.00	7790.90	30.86	4.54	43499.90	434.30	18527.18	7205.60
2003	137422.00	696.00	3717.00	10153.80	30.58	4.88	55566.60	651.47	23083.87	9161.04
2004	161840.20	1423.00	2930.00	13158.30	48.72	11.38	70477.40	736.74	29021.45	11140.66
2005	187318.90	2052.00	2582.00	15909.25	51.14	16.33	88773.60	847.50	34552.10	13352.03
2006	219438.50	4298.00	1850.00	19422.92	57.30	19.93	109998.20	1114.83	41557.16	16719.84
2007	270092.30	6265.00	1687.00	25288.84	64.69	20.31	137323.90	1368.67	51043.71	21496.63
2008	319244.60	5923.00	1543.00	31203.19	71.73	28.44	172828.40	1434.40	62036.81	22899.96
2009	348517.70	2460.00	1763.00	36241.81	58.55	37.13	224598.80	2128.01	76807.74	25989.76
2010	412119.30	4256.00	1643.00	48259.40	69.73	33.68	251683.80	2784.12	96031.13	30798.90
2011	487940.20	4888.00	1558.00	61796.89	88.68	40.19	311485.10	2854.31	117059.65	33675.41
2012	538580.00	5573.00	1366.00	71803.79	88.23	52.73	374694.70	3004.62	137217.86	35916.98
2013	592963.20	6233.00	1408.00	86013.38	87.55	66.56	446294.10	3422.52	159312.95	41126.31
2014	641280.60	9378.00	1443.00	95035.61	85.80	64.37	512020.70	3620.83	176713.42	42579.88
2015	685992.90	11240.00	1278.00	95978.85	75.50	68.82	561999.80	3613.32	180757.47	39308.26
2016	740060.80	1083.00	1322.00	102580.61	67.28	61.84	606465.70	4023.03	193566.78	39829.11
2017	820754.30	7541.00	1330.00	109798.53	60.85	34.44	641238.40	4096.35	213943.56	39874.46
2018	900309.50	6933.00	1317.00	120263.51	48.86	24.35	645675.00	3941.97	235085.53	42036.63

2.2 灰色关联分析

灰色关联分析是一种通过权衡同一坐标系中各因素序列曲线的相似程度,来判断系统中因素间的关联性.它对样本容量以及样本间规律性无特别要求,具有计算量小,精度高的特点,是研究少样本、贫信息分析和预测领域的新方法^[27].本文主要采用灰色因素关联分析法对钢材销售量的主要影响因素进行识别,找出各输入因素与输出量之间的关联程度,从而提取出影响输出指标的主控因素.

具体步骤如下:

(1) 确定参考序列和比较序列

根据研究需要,以表1中1994–2018年的钢材销量作为因变量 Y ,并记参考序列为 $Y = \{y(k) | k = 1, 2, \dots, n\}$;钢材销售的9个影响因素分别作为自变量组,9组比较序列为 $X_i = \{x_i(k) | k = 1, 2, \dots, n\}, i = 1, 2, \dots, m$.

(2) 数据的无量纲化

为避免数量级差别过大而导致预测误差较大的情况,在对数据计算前需要进行无量纲化处理.本文采用均值转换法,以消除不同数据间的量纲差异.计算公式为:

$$x'_i(k) = \frac{x_i(k)}{\frac{1}{m} \sum_{k=1}^n x_i(k)} \quad (13)$$

(3) 计算各因素与钢材销售量的关系系数

$$\eta_i(k) = \frac{\min_i \min(k\Delta_i(k)) + \rho \max_i \max(k\Delta_i(k))}{\Delta_i(k) + \rho \max_i \max(k\Delta_i(k))} \quad (14)$$

式中, $\Delta_i(k) = |y(k) - x_i(k)|$; ρ 为分辨系数,一般取0–1.

(4) 计算各因素与钢材销售量的关联度

$$r_i = \frac{1}{n} \sum_{k=1}^n \eta_i(k) \quad (15)$$

将上述过程基于Matlab 2018a平台编写计算程序,分辨系数 ρ 设定为0.5,则灰色关联分析结果,如表2.

表2 各影响因素与钢材销售量灰色关联度表

影响因素	灰色关联度
国内生产总值(X_1)	0.9399
钢材出口量(X_2)	0.8583
钢材进口量(X_3)	0.6284
房地产开发投资(X_4)	0.6214
金属切削机床产量(X_5)	0.7666
拖拉机产量(X_6)	0.8416
全社会固定资产投资(X_7)	0.8757
车辆产量(X_8)	0.9390
全国建筑业总产值(X_9)	0.9638

根据表2中,计算出的关联度结果,取阈值等于0.7,将大于0.7的各因素作为选定指标.灰色关联度排序为:全国建筑业总产值(X_9)>国内生产总值(X_1)>车辆产量(X_8)>全社会固定资产投资(X_7)>钢材出口量(X_2)>拖拉机产量(X_6)>金属切削机床产量(X_5)>0.7.

2.3 主成分分析

由表1可知原数据为多维数据,由于数据间的耦合性导致并不是所有的数据都对钢材的销售量有很高的贡献率.如果直接将使用灰色关联分析选定的指标作为预测模型的输入节点,由于实验数据的复杂和冗余,网络的性能及模型的预测精度势必会受到影响^[28].为此本文选用主成分分析法对灰色关联分析选定的指标进行降维处理,确定输入指标,以减小变量间的耦合关系,保留对预测结果有价值的信息.

具体步骤如下:

(1) 建立相关矩阵 R

假设输入原始数据集为 X ,每个样本对应 P 个影响因素,即 $X = (X_1, X_2, \dots, X_P)$.则相关系数矩阵为:

$$R = (r_{ij})_{p \times p} \quad (16)$$

式中, r_{ij} 为因素 x_i 和 x_j 之间的相关系数, $r_{ij} = \text{cov}(x_i, x_j) = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i) \sum_{k=1}^n (x_{kj} - \bar{x}_j)}{n-1}$, $i, j = 1, 2, \dots, p$, n 为样本总数;
 \bar{x} 为 x 的平均值.

(2) 计算 R 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_p$ 和对应的特征向量 $\alpha_i = (\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{ip})$

(3) 确定主成分个数 $m(m < p)$

一般来说当累计贡献率达到75%–95%时,对应的前 m 个主成分就能够包含原始数据集的绝大多数的信息.方差贡献率和累计方差贡献率为:

$$\eta_i = \frac{\lambda_i}{\sum_{k=1}^p \lambda_k} \quad (17)$$

$$\eta(p) = \sum_{i=1}^m \eta_i \quad (18)$$

(4) 计算主成分得分

$$Y = (f_{bv})_{n \times m} \quad (19)$$

式中, $f_{bv} = \alpha_{v1}x_{b1} + \alpha_{v2}x_{b2} + \dots + \alpha_{vp}x_{bp}$, $b = 1, 2, \dots, n$, $v = 1, 2, \dots, m$.

将上述过程基于 Matlab 2018a 平台编写计算程序, 使用 princomp 函数, 得出各指标因素的贡献率, 如表 3.

表 3 影响因素的特征值及其方差贡献率

主成分	特征值	贡献率 (%)	累计贡献率 (%)
1	6.0981	87.1159	87.1159
2	0.5126	7.3231	94.4390
3	0.2682	3.8320	98.2710
4	0.1097	1.5668	99.8378
5	0.0082	0.1177	99.9555
6	0.0019	0.0270	99.9825
7	0.0012	0.0174	100.0000

由表 3 可知, 前 3 个主成分已包含了全部影响因素 95% 以上的信息. 故选取前 3 个主成分代替原灰色关联分析选定的因素作为最终的输入指标. 各主成分的得分值, 如表 4.

表 4 主成分得分表

年份	第1主成分	第2主成分	第3主成分
1994	-2.6038	-0.1997	-0.0343
1995	-2.5023	-0.1639	0.0406
1996	-2.4830	-0.2430	-0.0127
1997	-2.4440	-0.2371	-0.0087
1998	-2.5474	-0.4471	0.0603
1999	-2.4968	-0.4104	0.0450
2000	-2.4314	-0.3587	0.1279
2001	-2.3001	-0.2258	0.0206
2002	-2.1332	-0.1324	-0.0363
2003	-1.9896	-0.1988	-0.0190
2004	-1.4505	0.3185	-0.1459
2005	-1.1421	0.4198	-0.1178
2006	-0.5703	0.7382	0.3011
2007	-0.0188	0.9687	0.7112
2008	0.3801	1.0403	0.3916
2009	0.3765	0.1982	-0.6048
2010	1.0723	0.3459	-0.2263
2011	1.8387	0.6743	-0.3690
2012	2.4422	0.6479	-0.4543
2013	3.1632	0.5759	-0.5956
2014	3.7665	0.5977	0.2633
2015	4.0745	0.4729	0.7509
2016	3.0988	-1.1998	-1.6321
2017	3.5499	-1.2541	0.6671
2018	3.3506	-1.9273	0.8771

3 仿真实验

3.1 实验环境及参数设置

为全面验证算法性能, 以某钢铁企业钢材销售量数据集为例进行验证. 将主成分分析得到 3 个主成分的得分作为新样本, 在已有钢材销售量统计的 25 条数

据中, 随机抽取 18 条作为仿真训练集, 剩余 7 条作为仿真验证集, 用于验证误差. 算法程序是在 Matlab 2018a 的基础上实现, 在处理器为 Intel(R)Core(TM) i5-5200U CPU, RAM 为 4 GB, 运行环境为 Windows 10 (64 位) 的个人计算机上进行仿真测试. BP 神经网络隐含层传递函数采用 tansig 函数; 输出层传递函数采用 purlin 函数; 训练函数采用 trainlm 函数; 激活函数采用 Sigmoid 函数.

隐含层节点数的确定, 通常先用经验公式来计算节点范围, 再进行 BP 神经网络试算, 确定准确的节点数.

$$q = \sqrt{m+n+a} \quad (20)$$

式中, q 、 m 、 n 分别为隐含层、输入层及输出层的节点个数; a 为调节因子一般取 1-10. 通过不断增加隐含层节点数, 以网络输出误差最小为标准, 获取最佳隐含层节点数. 经过反复调整, 当隐含层节点数为 10 时, 输出误差最小, 网络拓扑结构为 8-10-1.

实验参数设置, 如表 5、表 6.

表 5 BP 神经网络参数设置

最大训练次数	期望误差	学习速率	间隔步数
1000	0.0001	0.1	5

表 6 免疫遗传算法参数设置

种群规模	进化代数	初始交叉概率	初始变异概率
100	100	0.75	0.2

3.2 网络性能分析

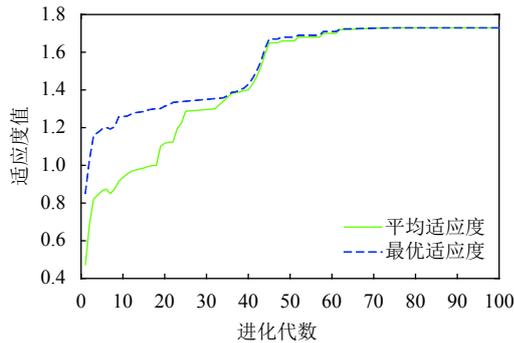
IGA 模型与 IIGA 模型的适应度函数进化曲线, 如图 3.

由图 3 可知, 改进的免疫遗传算法模型进化 54 代以后, 优化结果的适应度函数值逐渐趋于稳定, 约为 2.2961, 表明每个个体都在最优解附近. 免疫遗传算法模型适应度函数值从 76 代之后逐渐稳定在 1.7294 左右, 且进化后期曲线有振荡现象发生. 表明改进的免疫遗传算法模型在优化网络参数的效果上要优于经典的免疫遗传算法模型.

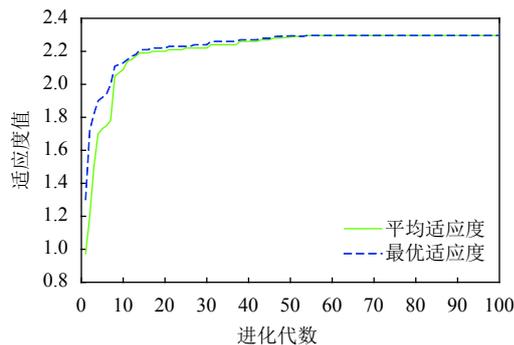
目标误差为 10^{-4} 时, BP、IGA-BP、IIGA-BP 三种网络模型训练误差曲线, 如图 4.

由图 4 可知, IIGA-BP 算法, 训练前期收敛速率最快, 曲线最陡峭, 在第 5 代左右摆脱局部最优解后, 又快速进入稳定状态, 这与本文的交叉算子、变异算子

的自适应设计有关. 而且, IIGA-BP神经网络经过23次进化后达到目标误差, IGA-BP神经网络经过65次进化后达到目标误差, 而BP神经网络经过100次进化后训练误差收敛于 6.253×10^{-3} 陷入局部最优且无法逃逸. 可见, 采用改进免疫遗传算法优化的BP神经网络, 在提高网络的收敛速度, 降低BP网络陷入局部极值的可能上具有很强的优越性.



(a) IGA模型适应度函数进化曲线



(b) IIGA模型适应度函数进化曲线

图3 适应度函数进化曲线图

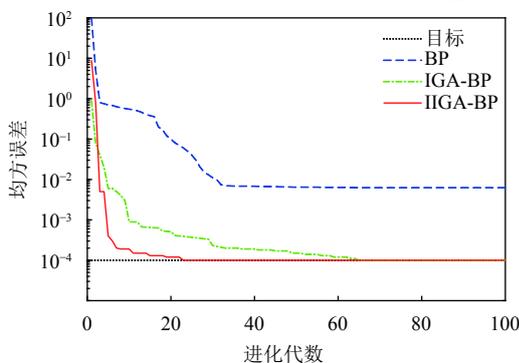


图4 3种网络模型训练误差曲线图

3.3 算法模型预测精度分析

为进一步比较3种模型的性能差异, 验证预测模

型的准确性、适用性, 对BP、IGA-BP、IIGA-BP神经网络进行仿真实验, 独立运行20次得到如图5、图6的仿真结果.

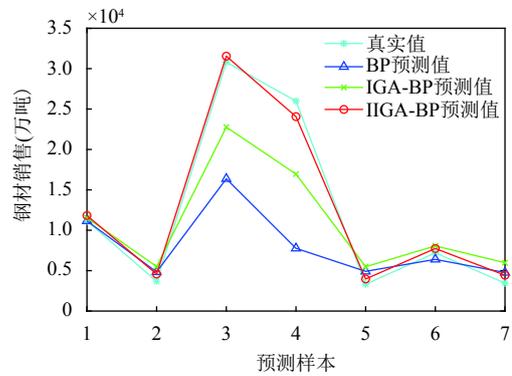


图5 3种网络模型预测输出对比图

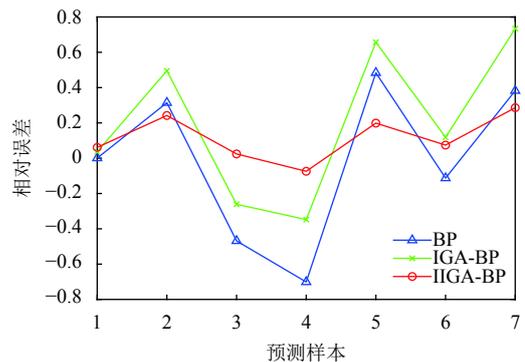


图6 3种网络模型预测相对误差对比图

由图5、图6可知, BP神经网络模型和IGA-BP神经网络模型预测离散度和误差波动幅度都较大; IIGA-BP神经网络模型预测离散度较小, 误差基本保持在 $[-0.25, 0.25]$ 之间, 预测效果更稳定, 预测精度大幅度提高.

为了更直观地显示3种模型的预测精度, 采用平均绝对百分比误差(MAPE)、均方根误差(RMSE)和纳什效率系数(NSE), 进一步评价3种网络模型的误差指标.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \quad (21)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (22)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (23)$$

式中, y_i 、 \hat{y}_i 分别为期望输出值与预测输出值; \bar{y} 为实测值的平均值; N 为预测样本数。

3种模型的预测值与真实值对比如表7所示。3种神经网络模型预测精度对比,如表8。

表7 3种网络模型预测值与真实值对比(万吨)

年份	真实值	BP预测值	BP预测平均 误差	IGA-BP预测值	IGA-BP预测平均 误差	IIGA-BP预测值	IIGA-BP预测平均 误差
2004	11 140.66	11 246.90	106.24	11 548.39	407.73	11 823.16	682.50
1997	3681.89	5039.38	1357.49	5404.13	1722.24	4572.67	890.78
2010	30 798.90	15 368.12	15 430.78	23 763.54	7035.36	31 544.44	745.54
2009	25 989.76	7564.83	18 424.93	17 948.37	8041.39	24 061.47	1928.29
1995	3311.23	5013.78	1702.55	5386.53	2075.30	3969.28	658.05
2002	7205.60	6193.65	1011.95	7959.45	753.85	7740.85	535.25
1996	3448.45	4776.73	1328.28	5959.06	2510.61	4435.11	986.66

表8 3种网络模型预测精度对比

神经网络	MAPE	RMSE	NSE
BP	0.3754	9142.7421	0.2596
IGA-BP	0.3574	4284.0378	0.8374
IIGA-BP	0.1372	1016.0461	0.9909

4 结论

本文针对BP神经网络在销售预测中的不足,提出了一种改进免疫遗传算法优化BP神经网络的销售预测模型。改进的免疫遗传算法提出了新的种群初始化方式、抗体浓度的调节机制及交叉算子、变异算子自适应策略的设计方法,保证了种群多样性,提高了算法的收敛能力和寻优能力。利用改进的免疫遗传算法扩大BP网络的权值搜索空间,获得最优权值和阈值,改善了BP网络易陷入局部极值的缺点。最后通过构建IIGA神经网络钢材销售预测模型并与BP、IGA-BP神经网络预测模型进行横向测评,实验表明改进免疫遗传算法优化后的BP神经网络具有较强的拟合能力和泛化能力,在提高模型预测精度和收敛速度的同时,也简化了网络结构,降低了进化代数,预测输出的稳定性较好。但由于网络的训练数据较少,网络训练不完善,导致模型预测精度不是太高。如需深入研究,可进一步扩大训练数据集,加强模型的学习效果,提高预测精度。

参考文献

1 Crawford S, Huang Y, Li NZ, et al. Customer concentration and public disclosure: Evidence from management earnings

由表8可知, IIGA-BP神经网络模型的MAPE为0.1372相对于BP神经网络模型预测精度提高了23.82%,也优于IGA-BP神经网络模型的预测精度。与另两种模型相比IIGA-BP神经网络模型的RMSE值最小,模型的误差小,泛化能力强。IIGA-BP神经网络模型的NSE为0.9909相比其它两种模型,本模型具有更好的非线性拟合能力,预测的稳定性更高。

and sales forecasts. Contemporary Accounting Research, 2020, 37(1): 131–159. [doi: 10.1111/1911-3846.12526]

2 Zhang GQ, Patuwo BE, Hu MY. Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 1998, 14(1): 35–62. [doi: 10.1016/S0169-2070(97)00044-7]

3 Martinez A, Schmuck C, Pereverzyev Jr S, et al. A machine learning framework for customer purchase prediction in the non-contractual setting. European Journal of Operational Research, 2020, 281(3): 588–596. [doi: 10.1016/j.ejor.2018.04.034]

4 周小溪, 徐行, 孟剑飞, 等. 服装销售预测方法研究进展. 针织工业, 2020, (3): 68–72. [doi: 10.3969/j.issn.1000-4033.2020.03.017]

5 Frank C, Garg A, Sztandera LM, et al. Forecasting women’s apparel sales using mathematical modeling. International Journal of Clothing Science and Technology, 2003, 15(2): 107–125. [doi: 10.1108/09556220310470097]

6 吴正佳, 王文, 周进. BP神经网络在备货型企业销售预测中的应用. 工业工程, 2010, 13(1): 105–107, 121. [doi: 10.3969/j.issn.1007-7375.2010.01.021]

7 Qin YQ, Li HM. Sales forecast based on BP neural network. 2011 IEEE 3rd International Conference on Communication Software and Networks. Xi’an: IEEE, 2011. 186–189. [doi: 10.1109/ICCSN.2011.6014419]

8 高文, 李富星, 牛永洁. 基于BP神经网络对房价预测的研究. 延安大学学报(自然科学版), 2018, 37(3): 37–40. [doi: 10.13876/J.cnki.ydnse.2018.03.037]

9 Bibaud-Alves J, Thomas P, El Haouzi H. Demand

- forecasting using artificial neuronal networks and time series: Application to a french furniture manufacturer case study. Proceedings of the 11th International Joint Conference on Computational Intelligence. Vienna: SCITEPRESS—Science and Technology Publications, 2019. 502–507. [doi: [10.5220/0008356705020507](https://doi.org/10.5220/0008356705020507)]
- 10 查刘根, 谢春萍. 基于免疫遗传算法的BP神经网络在纱线条干预测上的应用. *丝绸*, 2019, 56(2): 19–26. [doi: [10.3969/j.issn.1001-7003.2019.02.004](https://doi.org/10.3969/j.issn.1001-7003.2019.02.004)]
- 11 郑建刚, 王行愚, 牛玉刚. 基于改进免疫遗传算法的神经网络及其在股票预测中的应用. *华东理工大学学报(自然科学版)*, 2006, 32(11): 1342–1345. [doi: [10.3969/j.issn.1006-3080.2006.11.020](https://doi.org/10.3969/j.issn.1006-3080.2006.11.020)]
- 12 Cheng SY, Zhou XM. Network traffic prediction based on BPNN optimized by self-adaptive immune genetic algorithm. Proceedings 2013 International Conference on Mechatronic Sciences, Electric Engineering and Computer (MEC). Shenyang: IEEE, 2013. 1030–1033. [doi: [10.1109/MEC.2013.6885213](https://doi.org/10.1109/MEC.2013.6885213)]
- 13 朱玉, 张虹, 苏成. 基于免疫遗传算法的煤与瓦斯突出预测研究. *中国矿业大学学报*, 2009, 38(1): 125–130. [doi: [10.3321/j.issn:1000-1964.2009.01.024](https://doi.org/10.3321/j.issn:1000-1964.2009.01.024)]
- 14 Yang SX. Forecasting increasing rate of power consumption based on immune genetic algorithm combined with neural network. *Journal of Central South University of Technology*, 2008, 15(2): 327–330. [doi: [10.1007/s11771-008-0481-1](https://doi.org/10.1007/s11771-008-0481-1)]
- 15 张浩, 王国伟, 苑超, 等. 基于AIGA—BP神经网络的粮食产量预测研究. *中国农机化学报*, 2016, 37(6): 205–209. [doi: [10.13733/j.jcam.issn.2095-5553.2016.06.45](https://doi.org/10.13733/j.jcam.issn.2095-5553.2016.06.45)]
- 16 Wang YL. Optimizing of artificial neural network based on immune genetic algorithm in power load forecasting. Nguyen NT, Trawiński B, Jung JJ. *New Challenges for Intelligent Information and Database Systems*. Berlin: Springer, 2011. 329–338.
- 17 Yun J, Zeng DH. A father-keeping immune genetic algorithm based neural network model for properties prediction of carbon fiber. *Advanced Materials Research*, 2013, 699: 921–925. [doi: [10.4028/www.scientific.net/AMR.699.921](https://doi.org/10.4028/www.scientific.net/AMR.699.921)]
- 18 王华强, 胡平, 李海波. IGA-BP网络模型在高炉铁水硅含量预测中的应用. *合肥工业大学学报(自然科学版)*, 2007, 30(4): 413–415, 427.
- 19 Huang SZ. Immune genetic evolutionary algorithm of wavelet neural network to predict the performance in the centrifugal compressor and research. *Journal of Software*, 2011, 6(5): 908–914. [doi: [10.4304/jsw.6.5.908-914](https://doi.org/10.4304/jsw.6.5.908-914)]
- 20 付传秀, 周建新. 免疫遗传算法对中国区域经济协调发展的聚类及预测分析. *赤峰学院学报(自然科学版)*, 2017, 33(3): 98–100.
- 21 Hill RD, Conner JM. Transient heat transfer model of machine gun barrels. *Materials and Manufacturing Processes*, 2012, 27(8): 840–845. [doi: [10.1080/10426914.2011.648694](https://doi.org/10.1080/10426914.2011.648694)]
- 22 李国良, 李忠富, 谢洪涛, 等. 基于IGA-BP算法的小波神经网络模型及应用. *系统工程*, 2012, 30(10): 112–117.
- 23 李秀卿, 赵丽娜, 孟庆然, 等. IGA优化的神经网络计算配电网理论线损. *电力系统及其自动化学报*, 2009, 21(5): 87–91. [doi: [10.3969/j.issn.1003-8930.2009.05.016](https://doi.org/10.3969/j.issn.1003-8930.2009.05.016)]
- 24 吴利春. 基于遗传神经网络的故障诊断算法研究 [硕士学位论文]. 沈阳: 辽宁大学, 2012.
- 25 曹坤煜, 陈永当, 宋辛辛, 等. 改进免疫遗传算法求解柔性作业车间调度问题. *计算机技术与发展*, 2020, 30(11): 174–179. [doi: [10.3969/j.issn.1673-629X.2020.11.032](https://doi.org/10.3969/j.issn.1673-629X.2020.11.032)]
- 26 中国统计年鉴. <http://www.stats.gov.cn/tjsj/ndsj/>. [2020-05-29].
- 27 曹明霞. 灰色关联分析模型及其应用的研究 [硕士学位论文]. 南京: 南京航空航天大学, 2007.
- 28 杨开睿, 孟凡荣, 梁志贞. 一种自适应权值的PCA算法. *计算机工程与应用*, 2012, 48(3): 189–191. [doi: [10.3778/j.issn.1002-8331.2012.03.056](https://doi.org/10.3778/j.issn.1002-8331.2012.03.056)]