

改进粒子群优化 BP 神经网络粮食产量预测模型^①

宗宸生¹, 郑焕霞², 王林山¹

¹(中国海洋大学 数学科学学院, 青岛 266100)

²(山东省聊城市东昌府区郑家中学, 聊城 252053)

通讯作者: 王林山, E-mail: wangls@ouc.edu.cn

摘要: 综合考虑影响粮食产量的多种因素, 运用改进的粒子群算法优化 BP 神经网络的初始权重, 建立了适合小样本粮食产量的预测模型. 实验表明, 与 BP 神经网络粮食预测模型和 PSO-BP 神经网络粮食预测模型相比, 该模型具有更高的预测精度和较大的适应度.

关键词: 改进粒子群优化 BP 神经网络; 惯性权重; 学习因子; 粮食预测模型; 预测精度和适应度

引用格式: 宗宸生, 郑焕霞, 王林山. 改进粒子群优化 BP 神经网络粮食产量预测模型. 计算机系统应用, 2018, 27(12): 204-209. <http://www.c-s-a.org.cn/1003-3254/6651.html>

Grain Yield Prediction Based on BP Neural Network Optimized by Improved Particle Swarm Optimization

ZONG Chen-Sheng¹, ZHENG Huan-Xia², WANG Lin-Shan¹

¹(School of Mathematical Sciences, Ocean University of China, Qingdao 266100, China)

²(Zhengjia Middle School in Dongchangfu District, Liaocheng City, Shandong Province, Liaocheng 252035, China)

Abstract: This study considers comprehensively the various factors of grain production yield and optimizes primary BP neural network weights using the improved Particle Swarm Optimization (PSO) algorithm, then establishes a prediction model suitable for prediction of small sample grain yield. The experiment proves that this model has higher prediction precision and greater fitness than grain yield prediction model based on classical BP neural network and PSO-BP neural network.

Key words: BP neural network optimized by Particle Swarm Optimization (PSO); inertia weight; learning factor; grain prediction model; prediction precision and fitness

由于农业是国民经济的基础, 而粮食是基础的基础. 粮食不仅是人民群众最基本的生活资料, 也是关系到国家安全的重要战略物资, 我国是人口众多的大国, 解决好吃饭问题始终是治国理政的头等大事^[1]. 因此分析预测我国粮食生产过程的变化规律及其发展趋势, 为实施粮食生产过程的预测和决策、保证国家粮食安全提供理论依据, 具有重要的现实意义.

目前有多种粮食产量的预测方法^[2-5], 例如姚作芳

等建立的马尔可夫方法修正的灰色粮食预测模型, 这种方法简便易行, 需要数据少, 可以用于预测粮食产量的变化趋势. 然而, 还需要进一步提高预测精度. 另外, 还有基于线性方法的多元线性回归、时间序列分析等粮食预测模型. 由于, 粮食产量与其多种影响因素之间存在着复杂的非线性依赖关系, 具有不确定性和突变性, 往往线性模型难以适用较长时期预测且预测精度不高. 而人工神经网络模型具有非线性映射能力, 以及

① 基金项目: 国家自然科学基金 (11771014)

Foundation item: National Natural Science Foundation of China (11771014)

收稿时间: 2018-04-11; 修改时间: 2018-05-08; 采用时间: 2018-05-18; csa 在线出版时间: 2018-12-03

较强的鲁棒性和容错性^[6],因此已被广泛的应用于粮食产量预测问题^[7-9].例如吴炎将时间序列分析法和BP神经网络相结合,建立了江苏省粮食产量预测模型.这种方法较好的解决了神经网络收敛慢,但是仍需要改进易于陷入局部极小值的问题.另一方面,由于该方法只是利用粮食产量的数据建立模型,没有考虑影响粮食产量的其他因素,因而预测精度有待于进一步提高.且当前的研究大多没有基于粮食产量预测问题为小样本问题这一事实来改进预测模型.BP神经网络由于基于梯度的算法,存在如低的收敛速度且易陷入局部极小点,网络训练时对初始连接权值和阈值很敏感等缺陷.针对BP神经网络的不足,本文拟采用收敛速度快,具有好的鲁棒性及非常好的全局搜索能力的粒子群算法与BP神经网络相结合,并针对小样本问题对粒子群算法进行改进.最终以影响粮食产量的多种因素作为网络输入和粮食产量作为网络输出,建立了改进粒子群算法(IPSO)与BP神经网络相结合的多因素粮食产量预测模型——IPSO-BP模型.并与BP网络模型和PSO-BP网络模型进行对比.结果表明,IPSO-BP模型具有较高精度和算法稳定性,能够为粮食生产过程的预测和决策提供合理的理论依据.

本文根据1978~2015年《中国统计年鉴》,选取有效灌溉面积 X_1 (千公顷)、化肥施用量 X_2 (万吨)、农村用电量 X_3 (亿千瓦小时)、农业机械总动力 X_4 (万千瓦)、农林牧渔业劳动力 X_5 (万人)、粮食作物播种面积 X_6 (千公顷)和受灾面积 X_7 (千公顷)作为影响粮食产量的指标^[10-12](数据见附录1),作为网络输入,以粮食产量 Y (万吨)作为网络输出,构建IPSO-BP神经网络粮食预测模型.

1 IPSO-BP神经网络粮食预测模型的构建

IPSO-BP神经网络预测模型的特点:用IPSO算法优化BP神经网络的初始连接权值和阈值,IPSO算法结束时能够寻到全局最优附近的点;在此基础上,利用局部寻优能力较强的BP算法,从该点出发进行局部搜索,进而达到网络的训练目标,其结合了两种算法的优势,从而改进了传统BP神经网络的不足.

1.1 改进粒子群算法

粒子群算法(Particle Swarm Optimization)——PSO算法是一种群智能优化算法,由于其概念简明、收敛较快、实现方便,被广泛用于调度优化、数据挖

掘、神经网络训练、农业工程等方面^[13].

设 D 维欧氏空间中,由 N 个粒子组成群落,粒子对应位置为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T, i = 1, 2, \dots, N$,即问题的可能解.粒子速度为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})^T$,由其决定粒子的行进方向与距离,另外速度的每个分量受到最大速度 v_m 的限制,当 $v_{ij} > v_m$ 时,令 $v_{ij} = v_m(1 \leq i \leq N, 1 \leq j \leq D)$.同样 x_{ij} 受 x_m 的限制,当 $x_{ij} > x_m$ 时,令 $x_{ij} = x_m(1 \leq i \leq N, 1 \leq j \leq D)$.根据目标函数可以计算粒子在不同位置的适应度.粒子按下列迭代方法来更新速度和位移:

$$\begin{cases} v_i^{k+1} = wv_i^k + c_1r_1(p_i - x_i^k) + c_2r_2(p_g - x_i^k) \\ x_i^{k+1} = x_i^k + v_i^{k+1}, i = 1, 2, \dots, N \end{cases} \quad (1)$$

其中 $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})^T$ 为第 i 个粒子的个体极值点,表示第 i 个粒子在迭代过程中得到其最优适应度时所在的位置. $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})^T$ 为全局极值点,表示全体粒子在迭代过程中所得最优适应度时所在的位置. w 为惯性权重系数,较大的权重有利于提高算法的全局搜索能力,而较小的权重会增强算法的局部搜索能力, c_1 和 c_2 为学习因子, c_1 表示每个粒子受自身个体极值的影响,使粒子有了足够强的全局搜索能力,避免局部极小, c_2 表示粒子受当前全局极值的影响,体现粒子间的信息共享. w 、 c_1 和 c_2 共同决定了粒子的空间搜索能力. r_1 和 r_2 是介于 $(0, 1)$ 之间的随机数.

然而利用PSO算法优化BP神经网络初始权重时,也易于陷入局部最优解,往往得不到所需要的初始权重,因此在处理BP神经网络小样本训练问题时可能出现不尽人意的结果.

为进一步降低PSO算法陷入局部极值的可能性,针对不同问题有多种改进粒子群算法——IPSO算法^[14-17].其中黄璇提出了一种适用于小样本训练问题的改进方法,本文借鉴该方法修正了PSO算法中的相关参数,改进了IPSO-BP神经网络模型^[14]:

$$\begin{cases} w = [(w_0 - w_1) \cos(k/M\pi) + (w_0 + w_1)]/2 \\ c_1 = c_{10} + (k/M)(c_{11} - c_{10}) \\ c_2 = c_{20} + (k/M)(c_{21} - c_{20}) \end{cases} \quad (2)$$

对公式(1)中参数的修正方法如下:

w 、 k 和 M 分别表示惯性权重系数、当前迭代次数和最终迭代次数, w_0 和 w_1 为 w 的初始值和终止值,且 $w_0 > w_1$. c_1 表示控制粒子趋于局部极值的学习因子,其初始值为 c_{10} ,终止值为 c_{11} ; c_2 表示控制粒子趋于全局极值的学习因子,其初始值为 c_{20} ,终止值为 c_{21} . w 依

依赖于余弦函数变化的策略在于： w 在迭代次数 k 由 0 到 M 的过程中由 w_0 递减到 w_1 ，即迭代初期注重全局搜索，迭代后期加强了局部搜索，减小了过早落入局部寻优的可能，且 w 依赖于余弦函数变化时，迭代的前期和后期 w 的下降速度慢，使得迭代初期能快速全局寻优且持续较长时间，进一步减小了过早地陷入局部寻优的可能，在迭代后期可以较为平缓地进行精细搜索。对 c_1 、 c_2 的改进策略在于： c_1 随着迭代次数 k 以线性方式递减， c_2 则以线性方式递增。由此 c_{10} 大于 c_{11} ， c_{20} 小于 c_{21} 。并且 c_{10} 大于 c_{20} ， c_{11} 小于 c_{21} ，即迭代初期侧重于自身认知，末期侧重于全局认知，从而保证粒子对自身认知能力和全局认知能力的合理动态控制。

1.2 IPSO 算法优化 BP 神经网络的初始权重和阈值

IPSO-BP 算法流程如下：

① IPSO 算法所需参数和神经网络结构的确定

IPSO 算法所需参数包括种群规模 N ，粒子维度 D ，最终迭代次数 M ，惯性权重系数 w 的初始值和终止值 w_0 、 w_1 ，学习因子的初始值 c_{10} 、 c_{20} 和最终值 c_{11} 、 c_{21} ，最大速度 v_m ；BP 神经网络采用三层网络结构，每个粒子需包含全部的权值和阈值，即输入层与隐层、隐层与输出层的连接权重以及输出层和隐层的阈值。因此，粒子的维度 D 应为：

$$D = D_{in}D_h + D_hD_{out} + D_h + D_{out}, \quad (3)$$

式中， D_{in} 、 D_h 、 D_{out} 分别为输入层、隐层和输出层的节点数。

对于粮食产量预测问题，7 个影响因素对应输入层 7 个节点，网络输出为粮食产量，因此输出层节点数为 1，隐层有 15 个节点。如图 1 所示。




图 1 神经网络结构示意图

维度 $D=136$ 包含 120 个权值和 16 个阈值。对每一个粒子其位置 $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$ 的第 1 个到 105 个分

量、第 106 个到 120 个分量分别对应一个 15×7 、 1×15 的隐层的权重矩阵和输出层的权重矩阵，第 121 个到 135 个分量、第 136 个分量分别对应隐层节点和输出层节点的阈值向量。

② 适应度函数的确定

初始化 BP 神经网络，并将神经网络的实际输出和理想输出的均方差作为适应度函数：

其中 X 为网络的输入，即影响粮食产量的七个指标，采用 38 组数据训练和测试网络， y_i 、 y'_i 分别为网络训练的粮食输出值和实际粮食产量。

③ 迭代更新

$$\begin{cases} F(X, x_i) = (y_i - y'_i)^2, i = 1, 2, \dots, N \\ X = (X_1, X_2, \dots, X_7) \end{cases} \quad (4)$$

在 IPSO 优化阶段，在利用式 (1) 迭代时，利用式 (4) 计算每个粒子的适应度值 $F(X, x_i)$ ，若 $F(X, x_i) < F(p_i)$ ，则 $p_i = x_i$ ，若 $F(X, x_i) < F(p_g)$ ，则令 $p_g = x_i$ ，若上面两等式同时成立，则 $p_g = p_i = x_i$ ；然后根据公式 (2) 更新粒子的惯性权重系数 w 和学习因子 c_1 、 c_2 ，再利用式 (1) 对位置 x_i 和速度 v_i 进行更新，同时需保证 $x_{ij} \in [-x_m, x_m]$ ，且 $v_{ij} \in [-v_m, v_m]$ 。更新后，重新计算每个粒子的适应度 $F(X, x_i)$ ，并根据 $F(X, x_i)$ 更新 p_i 和 p_g 的取值。重复迭代操作，直至满足 $k=M$ ，从而获得最优解。

此时的全局极值点 p_g 即为最优解，由此作为 BP 神经网络的权重和阈值进行训练粮食预测模型。

2 基于 IPSO-BP 神经网络的粮食产量预测

2.1 IPSO-BP 神经网络模型的粮食产量预测

为了减小不同因子之间由于数据大小的差异和量纲的不同所引起的误差，在学习之前采用 MATLAB 中自带函数 `mapminmax` 对原始数据进行归一化处理。

本实验采用 MATLAB R2014a 神经网络工具箱进行测试实现^[18]，从样本数据中随机抽取 30 组作为训练数据，剩余 8 组 ($m_i = 1, 2, \dots, 8$) 作为测试数据。采用 IPSO-BP 神经网络模型的算法，经测试，确定参数 $N=70$ ， $M=50$ ， $w_0 = 1$ ， $w_1 = 0.1$ ， $c_{10} = 2.5$ ， $c_{11} = 1.25$ ， $c_{20} = 0.5$ ， $c_{21} = 2.5$ 。

IPSO-BP 神经网络模型预测结果如表 1 和图 2 所示。

由表 1 和图 2 可见，基于 IPSO-BP 神经网络建立的预测模型对粮食产量的预测结果较为准确，说明这种粒子群算法的改进方法比较适合粮食产量预测问题。

表1 IPSO-BP神经网络模型预测结果

	m_1	m_2	m_3	m_4	m_5	m_6	m_7	m_8
实际值	52 871	32 056	45 264	49 804	49 804	46 947	43 529	45 706
预测值	52 336	32 533	45 651	49 346	49 845	47 531	47 839	44 845




图2 IPSO-BP神经网络预测结果

2.2 IPSO-BP神经网络模型与其他方法预测精度对比

为了验证IPSO-BP神经网络对粮食产量预测精度的提升效果, 本文重新选取了30组数据, 分别建立了BP神经网络和PSO-BP神经网络来对粮食产量进行预测. IPSO-BP神经网络模型与BP神经网络模型及PSO-BP神经网络模型预测结果比较见图3.




图3 三种模型预测结果对比

此时BP神经网络、PSO-BP神经网络、IPSO-BP神经网络的预测输出相对误差如表2所示.

由表2可见, BP神经网络预测相对误差保持在0.0170到0.0800之间, 平均值为0.0375, PSO-BP神经网络预测相对误差保持在0.0021到0.0800之间, 平均值为0.0355, 相比之下, IPSO-BP神经网络预测相对误差保持在0.0041到0.0250之间, 平均值为0.0170.

表2 三种模型预测结果的相对误差

	BP模型相对误差	PSO-BP模型相对误差	IPSO-BP模型相对误差
m_1	0.0609	0.0706	0.0132
m_2	0.0796	0.0786	0.0216
m_3	0.0113	0.0452	0.0178
m_4	0.0114	0.0227	0.0215
m_5	0.0408	0.0198	0.0079
m_6	0.0311	0.0021	0.0249
m_7	0.0170	0.0087	0.0250
m_8	0.0481	0.0363	0.0041
平均值	0.0375	0.0355	0.0170

很明显, IPSO-BP神经网络预测结果的精度和稳定性大幅提高, 预测结果的相对误差基本可以保持在0.02左右, 有时可达到0.005以下.

由于样本数量少且样本数据维度较大, 易出现过拟合现象, 使预测模型的泛化能力不强. 考虑到样本数量较少, 因此可用留一法交叉验证对三种模型进行评估. 结果见图4.




图4 留一法交叉检验每次测试相对误差

由上图可知, 在留一法交叉验证中, IPSO-BP神经网络预测值的相对误差在38次测试中保持在0.00015—0.00082之间; 而PSO-BP神经网络的预测结果相对误差大部分保持在较低水平, 但存在数个较高的误差; BP神经网络预测结果则误差很大, 且波动较大.

由以上结果可以得出, 对于相同的样本数据, IPSO-BP神经网络比BP神经网络和PSO神经网络具有更高的预测精度, 且经过留一法交叉验证可验证, IPSO-BP神经网络的预测输出不但比其他两种方法精度高, 而且算法具有较高稳定性, 说明IPSO-BP神经网络有很强的泛化能力.

3 结语

本文根据粮食产量预测问题的特点,用合适的方法改进粒子群算法,并综合考虑粮食产量影响因素,构造适合粮食产量预测的模型,提高了粮食产量的预测精度.同时本模型对粮食产量的长期变化趋势预测能力偏弱,还需进行进一步研究.但总体来说本文提出的IPSO-BP神经网络模型可以较好的用于我国粮食产量预测问题,为制定粮食政策与实施粮食生产系统控制提供决策依据和理论支持.

参考文献

- 1 中共中央宣传部. 习近平总书记系列重要讲话读本. 中国民族语文翻译局, 译. 北京: 民族出版社, 2014. 68-69.
- 2 向昌盛, 张林峰. 灰色理论和马尔可夫相融合的粮食产量预测模型. 计算机科学, 2013, 40(2): 245-248. [doi: 10.3969/j.issn.1002-137X.2013.02.054]
- 3 田秀芹. 基于多元线性回归的粮食产量预测. 科技创新与应用, 2017, (16): 3-4.
- 4 姚作芳, 刘兴土, 杨飞, 等. 几种方法在粮食总产量预测中的对比. 干旱地区农业研究, 2010, 28(4): 264-268.
- 5 罗利娟, 丁宏飞. 基于 PSO-SVR 的粮食产量预测模型. 统计与决策, 2010, (22): 37-38.
- 6 王林山. 时滞递归神经网络. 北京: 科学出版社, 2008. 2-16
- 7 郑建安. 主成分和 BP 神经网络在粮食产量预测中的组合应用. 计算机系统应用, 2016, 25(11): 274-278. [doi: 10.15888/j.cnki.csa.005552]
- 8 林芳. 灰色神经网络在粮食产量预测中的应用. 计算机仿真, 2012, 29(4): 225-228, 267. [doi: 10.3969/j.issn.1006-9348.2012.04.055]
- 9 吴炎, 杜栋. 基于改进 BP 神经网络对江苏省粮食产量的仿真预测. 微型电脑应用, 2009, 25(6): 1-3. [doi: 10.3969/j.issn.1007-757X.2009.06.001]
- 10 魏津瑜, 陈锐, 刘曰波. 影响我国粮食产量的因素分析及对策研究. 中国农机化, 2008, (5): 56-59. [doi: 10.3969/j.issn.1006-7205.2008.05.016]
- 11 赵俊晔, 李秀峰, 王川. 近年我国粮食产量变化的主要影响因素分析. 中国食物与营养, 2006, (9): 9-12. [doi: 10.3969/j.issn.1006-9577.2006.09.003]
- 12 李雪. 基于粒子群的粮食产量预测神经网络优化研究[硕士学位论文]. 舟山: 浙江海洋大学, 2014.
- 13 钱锋. 粒子群算法及其工业应用. 北京: 科学出版社, 2013. 14-19.
- 14 黄璇, 郭立红, 李姜, 等. 改进粒子群优化 BP 神经网络的目标威胁估计. 吉林大学学报(工学版), 2017, 47(3): 996-1002.
- 15 唐泽, 吴敏, 吴桂兴, 等. 改进粒子群 BP 算法的四六级翻译评分模型. 计算机系统应用, 2015, 24(9): 140-145. [doi: 10.3969/j.issn.1003-3254.2015.09.024]
- 16 沈学利, 张红岩, 张纪锁. 改进粒子群算法对 BP 神经网络的优化. 计算机系统应用, 2010, 19(2): 57-61. [doi: 10.3969/j.issn.1003-3254.2010.02.014]
- 17 陈贵敏, 贾建援, 韩琪. 粒子群优化算法的惯性权值递减策略研究. 西安交通大学学报, 2006, 40(1): 53-56, 61. [doi: 10.3321/j.issn:0253-987X.2006.01.013]
- 18 飞思科技产品研发中心. 神经网络理论与 MATLAB 7 实现. 北京: 电子工业出版社, 2005. 271-280.

附录1

表1 粮食产量和各影响因素的部分数据

年份	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8
1978	44 965	884	253	11750	28 456	120 587	50 790	30 477
1979	45 003	1086	283	13 379	29 072	119 263	39 370	33 212
1980	44 888	1269	321	14 746	29 808	117 234	44 530	32 056
1981	44 573	1407	370	15 680	30 678	114 958	39 786	32 502
1982	44 177	1513	397	16 614	31 153	113 462	33 133	35 450
1983	44 644	1660	435	18 022	31 645	114 047	34 713	38 728
1984	44 453	1740	464	19 497	31 685	112 884	31 887	40 731
1985	44 036	1776	509	20 912	30 352	108 845	44 370	37 911
1986	44 225	1931	586	22 950	30 468	110 933	47 140	39 151
1987	44 403	1999	659	24 836	30 870	111 268	42 090	40 298
1988	44 376	2142	712	26 575	31 456	110 123	50 870	39 408
1989	44 917	2357	791	28 067	32 441	112 205	46 990	40 755
1990	47 403	2590	845	28 708	33 336	113 466	38 470	44 624
1991	47 822	2805	963	29 389	34 186	112 314	55 470	43 529
1992	48 590	2930	1107	30 308	34 037	110 560	51 330	44 266
1993	48 728	3151	1245	31 817	33 258	110 509	48 830	45 649
1994	48 759	3318	1474	33 803	32 690	109 544	55 040	44 510
1995	49 281	3594	1656	36 118	32 335	110 060	45 821	46 662
1996	50 381	3828	1813	38 547	32 260	112 548	46 989	50 454
1997	51 239	3981	1980	42 016	32 435	112 912	53 429	49 417
1998	52 296	4086	2042	45 208	32 626	113 787	50 145	51 230
1999	53 158	4124	2173	48 996	32 912	113 161	49 981	50 839
2000	53 820	4146	2421	52 574	32 798	108 463	54 688	46 218
2001	54 249	4254	2611	55 172	32 451	106 080	52 215	45 264
2002	54 355	4339	2993	57 930	31 991	103 891	47 119	45 706
2003	54 014	4412	3433	60 387	31 260	99 410	54 506	43 069
2004	54 478	4637	3933	64 028	30 596	101 606	37 106	46 947
2005	55 029	4766	4376	68 398	29 976	105 489	38 818	48 402
2006	55 750	4928	4896	72 522	29 418	104 958	41 091	49 804
2007	56 518	5108	5509	76 590	28 641	105 638	48 992	50 160
2008	58 472	5239	5713	82 190	28 364	106 793	39 990	52 871
2009	59 261	5404	6104	87 496	28 065	108 986	47 214	53 082
2010	60 348	5562	6632	92 780	27 695	109 876	37 426	54 648
2011	61 682	5704	7139	97 735	27 695	110 573	32 471	57 121
2012	62 491	5839	8105	102 559	27 695	111 205	2496	58 958
2013	63 473	5912	8550	103 907	27 695	111 956	31 350	60 194
2014	64 540	5996	8884	108 057	27 695	112 723	24 891	60 703
2015	65 873	6023	9027	111 728	27 695	113 343	21 770	62 144