

基于实数编码遗传算法的神经网络成本预测模型及其应用

刘 威, 李小平, 毛慧欧, 柴天佑

(东北大学 自动化研究中心, 辽宁 沈阳 110004)

摘要: 在生产过程中, 影响产品成本的因素多而复杂, 因素之间相互影响, 存在耦合现象, 因此准确预测成本是一个重要又难以解决的问题. 通过遗传算法 (Genetic Algorithm) 与误差反向传播 (Error Back Propagation) 神经网络相结合, 提出了用实数编码的自适应变异遗传算法训练神经网络权重的混合算法, 避免了传统神经网络易陷入局部极小的缺点. 以矩阵形式表示产品成本组成, 建立了产品成本组成模型, 以此为基础建立了考虑成本因素之间互相影响的神经网络产品成本预测模型, 并成功应用于某钢铁企业产品成本的预测, 提高了预测精度.

关键词: 成本预测; 遗传算法; 神经网络; 实数编码

中图分类号: TP9 **文献标识码:** A

Neural network cost prediction model based on real-coded genetic algorithm and its application

LIU Wei, LI Xiao-ping, MAO Hui-ou, CHAI Tian-you

(Research Center of Automation, Northeastern University, Shenyang Liaoning 110004, China)

Abstract: In production process, many complex factors which influence cost affect each other and the coupling phenomenon exists, so it is important and difficult to predict the cost. By combining genetic algorithm with error back propagation neural network, a hybrid algorithm that trained neural network weight by real-coded adaptive mutation genetic algorithm is presented, and it overcomes the disadvantage that traditional neural network is easy to fall into local minima. The product cost composition is expressed by matrix, the product cost composition model is established, on the basis of the model, the product cost prediction model based on neural network is established, and the interactions among cost factors are taken into account. Furthermore, the model is successfully applied to cost prediction in some iron and steel enterprise, and the prediction precision is improved.

Key words: cost prediction; genetic algorithm; neural network; real-coded

1 引言 (Introduction)

企业成本管理中生产成本的控制是一项极其重要的工作, 它是一项综合性经济技术指标, 它集中反映了企业生产技术和经营管理水平的高低. 然而, 成本控制涉及大量的工艺参数, 以及成本构成的分散性、生产过程的复杂性、成本发生的随机性、人为因素的能动性等特点的影响, 使得成本的发生与控制具有大系统的特征. 为此, 国内外都将成本控制作为一个系统, 在系统环境下利用信息集成技术研究了成本控制的方法, 开发了相应的成本控制软件包^[1,2]. 成本预测作为成本控制系统的组成部分, 一方面为制定成本计划提供了依据, 另一方面为监视成本指标变化趋势、动态在线控制成本提供了

信息. 因此, 对成本的动态跟踪和准确预测已经成为企业成本控制的关键环节. 目前, 比较常见的成本预测方法有线性回归、非线性回归、趋势预测等^[3]. 这些方法的缺点就是必须写出常规的数学模型或人为地确定一些参数. 由于影响生产成本的因素多而复杂, 成本因素之间相互影响, 这些因素之间的关系难以用常规数学模型建立, 即使人为确定一些参数, 所预测的数据也很不客观. 因此, 上述方法精度不高. BP 网络由于其良好的非线性逼近能力, 具有较高的预测精度, 在成本预测中也有应用^[4,5]. 本文将遗传算法和神经网络相结合, 提出了一种混合训练方法, 建立了考虑成本因素之间相互影响的成本预测模型, 并将其应用到某钢铁公司炼钢厂普碳方坯产品

成本的预测,取得了较好的效果.

2 面向神经网络权重学习的实数编码遗传算法 (Neural network weight training based on real-coded genetic algorithm)

2.1 编码方式 (Coding method)

为保证网络学习精度,避免权重步进变化,本文采用实数编码.前馈型神经网络的结构见图1. 隐含层转移函数为 Sigmoid 函数.在编码过程中,以神经网络的所有权值和阈值作为染色体的基因,各个基因组成染色体向量 $V = [v_1, \dots, v_k, \dots, v_L]$, v_k 为染色体中第 k 个基因.




图1 三层BP网络
Fig. 1 Three-layer BP network

2.2 适应度函数 (Fitness function)

本文采用误差平方测度进行适应度评价,形式如下:

$$f_i = 1/E = P / \sum_p \sum_k (t_k - y_k)^2. \quad (1)$$

其中, P 为训练样本个数, p 为当前学习样本, t_k 为节点 k 的理想输出, y_k 为节点 k 的实际输出,这里采用的是批处理法训练样本.

2.3 交叉操作 (Crossover operation)

交叉操作是按一定的交叉概率 P_c 选择参与交叉的父代染色体,本文采用随机选用算术交叉或基于方向的交叉,算术交叉可以保证产生的后代位于两个父代染色体之间,而基于方向的交叉可以有效扩展搜索空间:

a) 算术交叉:

$$\begin{aligned} V_1' &= \alpha V_1 + (1 - \alpha) V_2, \\ V_2' &= \alpha V_2 + (1 - \alpha) V_1. \end{aligned} \quad (2)$$

b) 基于方向的交叉:

$$\begin{aligned} V_1' &= \alpha (V_1 - V_2) + V_1, \\ V_2' &= \alpha (V_2 - V_1) + V_2. \end{aligned} \quad (3)$$

式中 V_1, V_2 为染色体向量, α 为 $[0, 1]$ 之间的随机数.

2.4 变异操作 (Mutation operation)

本文采用文献[6]提出的自适应变异算子,对变异率进行动态自适应调整.其目的是自适应调整搜

索区域,提高其搜索能力,改善收敛性能,提高遗传算法的收敛速度.

2.5 基于遗传算法的神经网络算法 (Neural network algorithm based on the genetic algorithm)

本文提出的混合算法其流程如图2所示,图中 $eg1, eg2$ 为设定的目标误差, $sse1$ 为 GA 误差平方和, $sse2$ 为神经网络误差平方和.




图2 GA和BP结合的流程图
Fig. 2 Flow chart combined BP with GA

3 神经网络成本预测模型 (Neural network cost prediction model)

3.1 产品成本组成模型 (Product cost composition model)

冶金工业企业大多是连续的流程工业,企业有多种产品,每种产品成本由多个成本指标组成,每个成本指标又包含许多成本因素,以矩阵形式表示产品成本组成:

$$Y_{m \times l} = \begin{bmatrix} \bar{y}_1 \\ \bar{y}_2 \\ \vdots \\ \bar{y}_m \end{bmatrix} = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1l} \\ y_{21} & y_{22} & \cdots & y_{2l} \\ \vdots & \vdots & \cdots & \vdots \\ y_{m1} & y_{m2} & \cdots & y_{ml} \end{bmatrix},$$

$$l = \max \{ \dim(\bar{y}_1), \dim(\bar{y}_2), \dots, \dim(\bar{y}_m) \}.$$

其中: $\bar{y}_i$ 表示构成产品成本的第 i 个成本指标向量; y_i 表示构成产品成本的第 i 个成本指标; y_{ij} 表示第 i 个成本指标向量的第 j 个成本因素.

如果 $\dim(\bar{y}_i) = q < l$, 则 $y_{iq+1}, y_{iq+2}, \dots, y_{il}$ 均等于零,即认为第 i 个成本指标由 q 个成本因素构成.则产品成本可以表示为

$$y = \sum_{i=1}^m y_i = \sum_{i=1}^m \sum_{j=1}^l y_{ij}. \quad (4)$$

每个指标成本可以表示为

$$y_i = \sum_{j=1}^l y_{ij}. \quad (5)$$

3.2 产品成本预测模型(Product cost prediction model)

模型 1 历史值预测模型,即仅以产品成本的历史值预测,预测模型如下:

$y'(t) = f(y(t-n), y(t-n+1), \dots, y(t-1))$. 其中, $y'(t)$ 表示预测产品成本,为神经网络输出; $y(t-k)$ ($k = 1, 2, \dots, n$) 表示 y 的历史成本,为神经网络输入.该模型为多输入单输出模型.

模型 2 影响因素预测模型,即以影响产品成本的因素来预测.在考虑影响产品成本的因素时,应该注意因素的概括性和动态性,力求全面、客观的反映影响产品成本的主要因素.设有 m 种指标成本因素影响产品成本,则预测模型如下:

$$\begin{aligned} y'(t) &= \sum_{i=1}^m y'_i(t), \\ y'_i(t) &= f_i(y_1(t-1), y_1(t-2), \dots, \\ &\quad y_1(t-k), \dots, y_m(t-1), \\ &\quad y_m(t-2), \dots, y_m(t-k)). \end{aligned}$$

其中: $y'(t)$ 表示预测产品成本; $y'_i(t)$ 表示预测指标成本,为神经网络输出; $y_i(t-k)$ ($i = 1, \dots, m$) 表示影响产品成本的 m 种指标的历史成本,为神经网络输入.该模型为多输入多输出模型.

4 钢铁产品动态成本预测应用研究 (Appli-

$$\begin{bmatrix} y'_1(t) \\ y'_2(t) \\ \vdots \\ y'_5(t) \end{bmatrix} = \begin{bmatrix} f_1(x_1(t-k) & x_1(t-k+1) & \cdots & x_1(t-1) & \cdots & x_5(t-k) & x_5(t-k+1) & \cdots & x_5(t-1)) \\ f_2(x_1(t-k) & x_1(t-k+1) & \cdots & x_1(t-1) & \cdots & x_5(t-k) & x_5(t-k+1) & \cdots & x_5(t-1)) \\ \vdots & \vdots & & \vdots & & \vdots & \vdots & & \vdots \\ f_5(x_1(t-k) & x_1(t-k+1) & \cdots & x_1(t-1) & \cdots & x_5(t-k) & x_5(t-k+1) & \cdots & x_5(t-1)) \end{bmatrix}$$

根据产品组成模型, $y'(t) = \sum_{i=1}^5 y'_i(t)$. 其中 x_i, y'_i 分别为神经网络输入、输出,具体含义如下:

x_1 : 原材料历史成本; y'_1 : 原材料预测成本; x_2 : 辅助材料历史成本; y'_2 : 辅助材料预测成本; x_3 : 燃料历史成本; y'_3 : 燃料预测成本; x_4 : 工资历史成本; y'_4 : 工资预测成本; x_5 : 制造费用历史成本; y'_5 : 制造费用预测成本.

考虑到市场和生产条件的不断变化,在本文中 $k = 2$,即以相互影响的 5 项指标的两个历史数据来预测该 5 项指标成本.

4.1 输入值与目标值的预处理 (Pretreatment of input value and target value)

从生产现场收集用于学习的样本的原始数据如

cation research of dynamic cost prediction on iron and steel product)

准确地预测成本对于合理地组织生产,对生产过程成本进行超前控制意义重大.以往现场采用的成本预测模型多为线性回归模型(认为成本和产量有关)、时间序列模型(趋势预测),这些模型的特点是简便易用.但是由于成本预测是一种多因素、不确定性、非线性问题,成本构成的因素之间互相影响,存在耦合现象(如冶金企业中原材料铁矿石品位的高低将影响燃料动力的消耗、辅助材料的消耗.品位低的铁矿石降低了原料成本,却增加了燃料动力成本、辅助材料成本),上述方法没有考虑成本构成因素之间的耦合,因此预测精度低.现以流程工业中的冶金工业为例,建立神经网络模型,并将上述算法与模型应用到某钢铁公司动态成本控制软件包中.应用时用户可以根据需要自己选择训练样本、预测指标,系统根据用户选择自动确定网络结构.

在本文中以该钢铁公司炼钢厂普碳方坯产品的月成本预测为例,预测构成普碳方坯成本中相互影响的五项指标成本,由此得出产品的制造成本,并将其与前两种方法预测结果进行了比较,结果表明该模型预测精度优于前两种模型.考虑指标的历史因素及指标间的相互影响,本文综合历史值预测模型和因素预测模型,建立多指标预测的多输入、多输出模型,模型如下:

表 1 所示(鉴于篇幅所限,这里仅列出部分).其中原材料成本包括钢铁料、合金料和铁矿石成本.工资中包括工资和福利费.表中成本数据均为单位成本,单位为元.

表 1 学习样本的原始数据

Table 1 Original data of training sample

月份	原材料	辅助材料	燃料动力	工资	制造费用
1	1070.73	40.97	58.76	17.54	62.98
2	1071.9	43.45	57.31	17.44	63.51
3	1072.77	43.05	58.69	20.62	57.51
4	1071.97	40.57	57.66	18.08	61.02
5	1071.69	42.20	59.69	22.12	58.9
6	1058.99	38.74	62.47	22.09	65.01
7	1056.93	41.31	58.73	20.59	70.5
8	1060.14	43.77	58.44	18.18	61.97
9	1040.74	38.87	58.40	22.74	62.55

根据 Sigmoid 型变换函数值的输出范围,有必要将输入值与目标值按下式进行变换:

$$x_i' = [(x_i + x_{i\max} - 2x_{i\min}) / (x_{i\max} - x_{i\min}) - 1] \times d_1 + d_2.$$

其中 d_1, d_2 为参数, $d_2 = (1 - d_1) / 2$, 这里 d_1 取 0.9, 使其归一化后的输入值落在 0.05 ~ 0.95 之间, 这样靠近数据变化区间端点的网络输出值就有一波动范围, 使得网络的性能较好. $x_{i\max}, x_{i\min}$ 为第 i 个指标的最大、最小值.

4.2 学习样本的整理 (Treatment of training sample)

学习样本从成本历史资料中获取. 在用历史成本数据进行预测时, 应先对成本数据进行分类. 例如, 某些月份大修, 则应用历史上大修月份的成本数据来预测大修月份的成本, 这样预测才能准确. 用来预测的历史数据应选择企业稳定经营时期的数据. 预测的方式有多种, 既可以预测总成本, 也可以预测某项指标的成本. 鉴于成本构成的因素间具有耦合性, 本文以某两个月的成本指标数据 ($x_1(t-1), x_1(t), \dots, x_5(t-1), x_5(t)$) 作为一组输入, 以其下一月的成本指标数据 ($x_1(t+1), x_2(t+1), \dots, x_5(t+1)$) 作为一组输出, 这样构成一个学习样本. 依此类推, 形成一组学习样本. 这样处理的好处在于将各

项成本指标之间的耦合由模型自身来处理, 避免了由于不考虑耦合所带来的预测误差 (如仅由原材料历史成本预测原材料成本).

4.3 预测结果 (Prediction result)

本文选择的参数: 输入层神经元个数为 10, 隐含层神经元个数为 14, 输出层神经元个数为 5, 种群大小 $N = 80$, 遗传代数 $G = 200$, 交叉概率 $P_c = 0.6$; 遗传算法误差 $eg1 = 0.01$, BP 网络误差 $eg2 = 0.0001$. 以 8、9 月份成本数据预测该公司 10 月份成本, 预测结果列于表 2. 同时给出现场采用的回归分析和时间序列方法预测的结果, 其中回归分析采用的是二元回归 $y(t) = a + bx(t)$ (其中 y 为某月某项指标预测成本, x 是某月计划产量); 时间序列预测采用的是加权移动平均, 其公式为 $y(t) = \sum_{i=1}^4 a_i x(t-i)$ (其中 y 为某月某项指标预测成本, $x(t-i)$ 是某项指标的历史成本, a_i 为加权系数, 临近预测月份的加权值取值较大). 从表 2 可以看出, 由于考虑了成本指标的耦合, 因此本文提出的方法与线性回归、时间序列方法相比, 在预测精度上有较大提高, 单位制造成本预测更加贴近实际值.

表 2 神经网络、线性回归、时间序列预测结果

Table 2 Result of neural network, linear regression and time series prediction

预测对象	实际值	神经网络		线性回归		时间序列	
		预测值	误差 (%)	预测值	误差 (%)	预测值	误差 (%)
单位原材料	1025.48	1033.32	-0.8	1060.98	-3.5	1051.62	-2.5
单位辅助材料	39.32	38.2	2.8	41.46	-5.4	40.82	-3.8
单位燃料动力	56.19	57.37	-2.1	59.29	-5.5	58.89	-4.8
单位工资	21.15	22.01	-4.1	21.51	-1.7	20.88	1.3
单位制造费用	57.8	60.03	-3.9	63.01	-9	64.21	-11.1
单位制造成本	1199.93	1210.93	-0.9	1231.98	-2.7	1236.42	-3

5 结语 (Conclusion)

本文建立了产品成本的神经网络预测模型, 该模型不仅考虑了产品成本构成因素之间的相互影响, 而且采用实数编码的遗传算法和神经网络相结合的混合算法优化神经网络, 克服了传统神经网络优化方法易陷入局部极小的缺陷, 使得动态成本的预测精度较其它方法有较大提高, 为全过程动态成本的准确预测提供了一种实用的方法.

参考文献 (References):

[1] LI X N, CHAI T Y. Dynamic cost control method in production process and its application [C] // *Proc of the 15th IFAC World*

Congress. Barcelona: Elsevier Science Ltd, 2002.

- [2] ABUDAYYEH O, TEMEL B. An intranet-based cost control system [J]. *Advances in Engineering Software*, 2001, 32(2): 87-94.
- [3] NAG P K, MALY W, JACOBS H. Advanced forecasting of cost and yield [J]. *Semiconductor International*, 1998, 21(8): 163-170.
- [4] WANG Q, STOCKTON D J, BAGULEY P. Using neural networks in cost model development process [C] // *Proc of the 16th National Conf on Manufacturing Research*. UK: Professional Engineering, 2000: 59-63.
- [5] SMITH A E, MASON A K. Cost estimation predictive modeling: regression versus neural [J]. *Engineering Economist*, 1997, 42(2): 137-161.
- [6] 周明, 孙树栋. 遗传算法原理及应用 [M]. 北京: 国防工业出版社, 2000: 56-58.

(下转第 431 页)

- [6] OTT E. *Chaos in Dynamical Systems* [M]. Cambridge: Cambridge University Press, 1992: 326 – 380.
- [7] BIHAM O, WENZEL W. Unstable periodic orbits and the symbolic dynamics of the complex Henon map [J]. *Physical Review A*, 1990, 42(10): 4639 – 4646.
- [8] HANSEN K. Alternative method to find orbits in chaotic systems [J]. *Physical Review E*, 1995, 52(9): 2388 – 2391.
- [9] CVITANOVIC P, GUNARATNE G H, PROCACCIA H. Topological and metric properties of Henon-type strange attractors [J]. *Physical Review A*, 1988, 38(8): 1503 – 1520.
- [10] SCHMELCHER P, DIAKONOS F K. General approach to the localization of unstable periodic orbits in chaotic dynamical systems [J]. *Physical Review E*, 1998, 57(3): 2739 – 2746.
- [11] SCHMELCHER P, DIAKONOS F K. Detecting unstable periodic orbits of chaotic dynamical systems [J]. *Physical Review Letters*, 1997, 78(6): 4733 – 4736.
- [12] GUTZWILLER M C. *Chaos in Classical and Quantum Mechanics* [M]. Berlin: Springer-Verlag, 1990.
- [13] TORCINI A, POLITI A, PUCCIONI G P, et al. Fractal dimension of spatially extended systems [J]. *Physica-D*, 1991, 53(10): 85 – 101.
- [14] JACKSON E, KODOGEORGION A. Entrainment and migration controls of two-dimensional maps [J]. *Physica-D*, 1992, 54(1): 253 – 265.
- [15] DAVIDCHACK R, LAI Ying-cheng. Characterization of transition to chaos with multiple positive Lyapunov exponents by unstable periodic orbits [J]. *Physics Letters A*, 2000, 270(6): 308 – 313.

作者简介:

岳毅宏 (1975 —), 男, 在天津大学管理学院作博士后研究工作, 主要研究方向: 非线性系统理论, 混沌系统理论及其控制, E-mail: Kevinyue@eyou.com; yh_yue@sina.com;

韩文秀 (1938 —), 女, 天津大学管理学院博士生导师, 主要研究方向: 复杂系统, 混沌系统理论及其控制, E-mail: hanwx@tju.edu.cn.

(上接第 426 页)

(ZHOU Ming, SUN Shudong. *The Application and Principle of Genetic Algorithm* [M]. Beijing: National Defence Industry Press, 2000: 56 – 58.)

作者简介:

刘 威 (1975 —), 男, 东北大学博士研究生, 主要研究方向为冶金企业动态成本控制的理论、模型、方法研究及软件应用, E-mail: liu0wei@tom.com 或 liu0wei@21cn.com;

李小平 (1957 —), 男, 东北大学研究员, 研究方向为综合自动化系统设计与实施, E-mail: lxt_513@163.com;

毛慧欧 (1971 —), 男, 副教授, 在东北大学从事博士后研究工作, 研究方向为智能建模与智能控制及其在动态生产成本、污水处理中的应用, E-mail: maohuiou@yahoo.com;

柴天佑 (1947 —), 男, 中国工程院院士教授, 博士生导师, 主要从事自适应控制, 多变量智能解耦控制, 流程工业工程综合自动化理论、方法、技术及应用等方面的教学及科研工作, E-mail: tycail@mail.neu.edu.cn.