

文章编号 1004-924X(2010)06-1444-08

基于径向基函数神经网络的超分辨率图像重建

朱福珍, 李金宗, 朱 兵, 李冬冬, 杨学峰

(哈尔滨工业大学 图像信息与工程研究所, 黑龙江 哈尔滨 150001)

摘要: 为了突破成像极限, 经济可行地获取高质量的卫星图像, 提出了一种基于径向基神经网络的超分辨率图像重建算法。以径向基神经网络为基础, 依据卫星图像退化模型获取网络训练所需的学习样本图像, 采用向量映射的方式加速网络收敛。其中, 径向基函数的中心、宽度及网络的隐含层数、连接权值是决定径向基神经网络的关键参数, 直接关系到网络的重建性能。采用最近邻聚类算法, 动态地建立起基函数的中心及宽度, 自适应地确定网络的隐含层数及连接权值。建立起的径向基函数神经网络显著地提高了图像重建性能和网络收敛速度(221 s 即可收敛)。仿真实验和泛化实验表明, 训练好的径向基神经网络可以有效地进行卫星图像的超分辨率重建, 效率高, 误差小。

关键词: 图像重建; 超分辨率; 径向基神经网络; 最近邻聚类; 向量映射

中图分类号: TP183; TP391.4 **文献标识码:** A **doi:** 10.3788/OPE.20101806.1444

Super-resolution image reconstruction based on RBF neural network

ZHU Fu-zhen; LI Jin-zong; ZHU Bing; LI Dong-dong; YANG Xue-feng

(*Institute of Image Information Technology and Engineering, Harbin Institute of Technology, Harbin 150001, China*)

Abstract: In order to break through the limitations of imaging devices and to resolve the problems of Super-Resolution Reconstruction (SRR) of a satellite image, an image reconstruction based on the Radial Basis Function Neural Network (RBFNN) is proposed. First, learning sample images are acquired according to a satellite image observation model and the vector mapping is established to speed up the convergence of RBFNN. Then, the nearest neighbor clustering algorithm is used to dynamically establish the centers and widths of RBF, and decide adaptively the number of hidden layers and connection weights of a net, which are very important parameters for RBFNN. The method can improve the performance of SRR of satellite image and speed up the convergence of RBFNN to 221 s. Experimental results of simulation and generalization indicate that the well-trained RBFNN can realize the SRR of satellite images in higher spatial resolutions, higher efficiencies and lower errors.

Key words: image reconstruction; super-resolution; RBF neural network; the nearest neighbor clustering algorithm; vector mapping

收稿日期: 2009-07-02; 修订日期: 2009-09-30.

基金项目: 国家“十一五”计划重点资助项目 (No. 51322020703)

1 引言

图像超分辨率重建(Super-Resolution Reconstruction, SRR)技术是指从一系列分辨率较低、质量较差的图像重建出一帧空间分辨率更高、质量更好的图像,同时还能够消除加性噪声以及由有限检测器尺寸和光学元件产生的模糊^[1]。这项技术已经广泛应用于遥感、医学成像和高清晰度电视等多个领域。

图像超分辨率技术主要可以分为两类:基于重建的超分辨率技术和基于学习的超分辨率技术^[2]。基于重建的方法是指所有可用信息都从输入数据中得到,没有任何附加的背景知识,整个解决过程相当于一个信息提取和信息融合的问题。基于重建的超分辨率技术通过频域和空域超分辨率重建算法实现,最典型的方法有迭代反投影法(IBM)^[3]、凸集投影法(POCS)^[4]和最大后验概率法(MAP)^[5]等。基于学习的超分辨率技术最早是由 Simon Baker 和 Takeo Kanade^[6]在 2000 年提出的,他们分析了基于重建的超分辨率技术在分辨率增强上存在极限,即随着分辨率放大系数的增加,需要提供的输入图像样本数量急剧增加,达到放大系数的上限后,无论增加多少输入样本图像,都无法改善重建效果。针对重建,基于学习的超分辨率图像重建是指已知图像含义,从大量的训练样本集中获取先验知识作为超分辨率的依据。训练样本以输入图像为依据,用学习过程中获得的知识对输入图像中的信息进行补充。基于学习的方法充分利用了图像本身的先验知识,在不增加输入样本数量的情况下,仍能产生新的高频细节,获得比基于重建的算法更好的复原结果。最典型的学习模型有马尔科夫随机场模型^[7]、图像金字塔模型^[8]、主成分分析模型和神经网络模型^[9]等。

神经网络作为一种基于学习的超分辨率重建方法已经广泛应用于超分辨率图像重建中,最初应用的超分辨率图像重建的是 Hopfield 神经网络^[10-12],该网络用于超分辨的缺点是网络结构复杂,节点多,效率低;近年来应用较多的是 BPNN,但该网络收敛速度慢,易陷入局部最小点。而 RBFNN 具有收敛速度快,泛化能力强,不存在局部极小点等优点,因此,有必要对其加以研究,并

在超分辨率图像重建方面加以应用。

2 径向基函数神经网络(RBFNN)

2.1 RBFNN 基本结构

RBFNN 是一种三层前向网络,即输入层、隐含层和输出层,其拓扑结构如图 1 所示^[13]。RBF 网络从输入层到隐含层的变换是非线性的,该变换将原始数据映射到隐层空间。输入层节点只将输入信号传递到隐含层,隐含层节点通常采用高斯函数,其表达式如下:

$$r_{i(x)} = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right) \quad i=1,2,\dots,m, \quad (1)$$

其中: x 是 n 维输入向量; c_i 是第 i 个基函数的中心,与 x 具有相同维数的向量; σ_i 是高斯核的宽度参数,它决定了该基函数围绕中心点的宽度; m 是感知单元的个数(隐含层节点数), $\|x - c_i\|$ 表示 x 与 c_i 之间的距离; $r_{i(x)}$ 在 c_i 处有一个唯一的最大值,随着 $\|x - c_i\|$ 的增大, $r_{i(x)}$ 迅速衰减到零。隐含层到输出层的变换是线性的,该变换是对隐层节点基函数的线性加和。




图1 径向基函数神经网络结构图

Fig. 1 Structure of RBFNN

如果 RBFNN 被用于多帧图像的超分辨率重建,必须要解决两个问题:

- (1) 如何获取训练 RBFNN 的学习样本图像。
- (2) 如何确定径向基函数的中心、宽度和权重。

2.2 RBFNN 学习样本的获取

图像超分辨是一个融合多帧低分辨率图像(LRIs)中的互补信息模拟生成一帧高分辨率图

像(HRI)的过程,其数学模型可以表述为^[14-15]:

$$Y_k = H_k X + n_k \quad 1 \leq k \leq p, \quad (1)$$

其中: p 为可得到的LRI的帧数,是第 k 帧LRI, X 是HRI, n_k 是附加噪声, H_k 表示图像质量退化过程,是一个表示包含相对参考帧运动、模糊化、欠采样等因素在内的一个系数矩阵。

原图像 X 经过系数矩阵 H_k 的作用并附加噪声 n_k ,可得到一个LRI序列 Y_1, Y_2, \dots, Y_k ,选取此LRI序列作为RBFNN的输入样本图像,原图像 X 作为输出样本图像,经过网络的多次学习和训练,得到逼近输出样本图像的高分辨率图像。然而在实际的超分辨问题中,作为网络输出的HRI往往是未知的,不能直接进行上述超分辨神经网络模型的训练。但是退化模型是已知的,即可对HRI进行模糊、欠采样等操作,故可选取一逼近HRI的样本 X' 为NN的输出,对 X' 通过成像系统矩阵 H 的作用得到的LRI序列 Y_1', Y_2', \dots, Y_k' 作为NN的输入,用训练成功后得到的网络参数重构高分辨率图像 X' 。

本文任取一帧HRI为输出样本图像,对该HRI进行欠采样和亚像素位移(Undersampled and subpixel-shifted, USS)操作^[12],同时附加均值为0、方差为0.01的高斯噪声,得到一个LRI序列,任取该序列中的4帧作为网络的样本输入图像。具体的USS过程如图2所示:HRI每 2×2 个像素(左图)对应着LRI中的一个像素(右图),黑点代表着USS图像序列的初始位置,黑颜色的圆圈代表将该区域像素的平均值赋给第1帧LRI的第一个像素。同理,其他颜色圆圈覆盖的像素分别代表第2,3,4帧LRI的第一个像素的获得来源。以 256×256 的HRI生成的LRI序列的USS过程为例,亚像素位移值(0.5, 0.5):首先以原图像F的左顶点为起点,每个像素求平均值,并将所得平均值赋给第一帧LRI中相应位置的像素值。依此类推,将图像F分别整体右移一个像素、下移一个像素、同时向右向下移一个像素,分别以此为起点按照如上操作进行退化处理,得到另外3帧LRIs,从而完成了图像F的 $1/2 \times 2$ USS过程。这些亚像素位移图像的初始相位不同,所以它们相似但不相同。因此,USS得到的低分辨率图像序列更适合进行图像超分辨率重建。




图2 256×256 的HRI生成4帧 128×128 LRI序列的USS过程

Fig. 2 USS process of 4 LRIs in sizes of 128×128 formed by a HRI in size of 256×256

2.3 径向基函数中心、宽度及权值的确定

构造RBFNN的关键是确定网络要学习的参数:即基函数的中心、宽度以及隐含层到输出层之间的权值。一般预先确定径向基函数数目,RBF的中心从训练集中随机选取或由训练集以某种无监督或有监督的学习方式确定。这样处理方法简单方便,至今仍被使用,但它常常依赖于个人经验,容易导致网络庞大、性能较差。为了克服这一缺点,本文采用最近邻聚类算法^[16-17],该算法是一种在线自适应聚类算法,不需要事先确定隐含层神经元的数量,而是根据输入样本有针对性地动态建立起需要的中心点。该算法需要调控的参数少,故计算量小,能显著提高聚类速度,建立起一个性能良好的RBFNN。

具体过程如下:

(1) 选择一个适当的高斯函数宽度 r ,定义一个矢量 $A(l)$ 用于存放属于各类的输出矢量之和,定义一个计数器 $B(l)$ 用于统计属于各类的样本个数,其中 l 为类别数。

(2) 从第1个样本数据对 (x_1, y_1) 开始,在 x_1 上建立一个聚类中心,令 $c_1 = x_1, A(1) = y_1, B(1) = 1$ 。这样建立的RBFNN只有一个隐含单元,该隐单元的中心是 c_1 ,到输出层的权矢量为 $w_1 = A(1)/B(1)$ 。

(3) 考虑第2个样本数据对 (x_2, y_2) ,求出 x_2 到聚类中心 c_1 的距离 $\|x_2 - c_1\|$ 。若 $\|x_2 - c_1\| \leq r$,则 c_1 为 x_2 的最近邻聚类,且令 $A(1) = y_1 + y_2, B(1) = 2, w_1 = A(1)/B(1)$;若 $\|x_2 - c_1\| > r$,

则将 x_2 作为一个新的聚类中心,并令 $c_2 = x_2, A(2) = y_2, B(2) = 1$ 。在上述建立的 RBFNN 中再添加一个隐单元,该隐单元到输出层的权矢量为 $w_2 = A(2)/B(2)$ 。

(4) 假设 k 个样本数据对 $(x_k, y_k), (k = 3, 4, \dots, N)$, 存在 M 个聚类中心,分别为 c_1, c_2, \dots, c_M , 上述建立的 RBFNN 中已有 M 个隐单元。再分别求 x_k 到这 M 个聚类中心的距离 $\|x_k - c_i\|, i = 1, 2, \dots, M$, 设 $\|x_k - c_j\|$ 为这些距离中的最小距离,则 c_j 为 x_k 的最近聚类,则:

若 $\|x_k - c_j\| > r$, 则将 x_k 作为一个新的聚类中心。令 $c_{M+1} = x_k, M = M + 1, A(M) = y_k, B(M) = 1$, 并保持 $A(i), B(i)$ 的值不变, $i = 1, 2, \dots, M - 1$, 在已经建立的 RBFNN 中再添加第 M 个隐单元,该隐单元到输出层的权矢量为 $w_M = A(M)/B(M)$ 。

若 $\|x_k - c_j\| \leq r$, 则作如下计算: $A(j) = A(j) + y_k, B(j) = B(j) + 1$ 。当 $i \neq j$ 时, $i = 1, 2, \dots, M$, 保持 $A(i), B(i)$ 的值不变。隐单元到输出层的权矢量为 $w_i = A(i)/B(i), i = 1, 2, \dots, M$ 。

3 RBFNN 的设计与仿真结果

3.1 RBFNN 的设计与仿真实验

本文以 256×256 的标准 Lena 图像为实验参考图像。对该图像进行 2×2 的 USS 操作,得到 4 帧 128×128 的图像序列。将此 128×128 的图像序列作为 RBFNN 的低分辨率样本输入图像,将 256×256 的标准 Lena 图像作为 RBFNN 的高分辨率输出样本图像。为了提高网络映射能力,加快网络收敛速度,输入输出样本采用向量映射(Vector Mapping, VM)的方式,即:输入、输出样本图像分别被分割成数量相等的小块,对应的图像块中的像素构成一组映射。具体的向量映射过程如图 3 所示。

下面以 n 帧 LRIs 超分辨率重建成一帧 HRI 的过程为例,说明向量映射的过程:设输入样本图像为 128×128 的 LRIs 序列,每帧都按 4×4 的小块进行划分,共被分成 $32 \times 32 = 1024$ 个小块,则




图3 LRI序列实现超分辨的向量映射过程

Fig. 3 Vector mapping between input-output samples of NNs

n 帧 LRIs 共被分成 $1024 \times n$ 个小块;输出样本图像大小为 256×256 的 HRI,将其按 8×8 的小块进行划分,共被分成 $32 \times 32 = 1024$ 个小块;这样,LRIs 序列中相同位置的小块一同被用作 NN 的输入样本,与之对应的 HRI 中小块被用作 NN 的输出样本,二者构成一组向量映射对。

本文以 Matlab7.0 为开发平台,对 RBFNN 进行了设计和实现。首先,以图像退化模型为基础,获取亚像素位移欠采样的低分辨率图像序列;然后依据输入输出样本图像的向量映射过程,将输入、输出样本图像分别分成数量相等的图像块,并将图像块转换成列矢量,构成 RBFNN 的输入矢量 P 和目标矢量 T ;以列矢量 P 和 T 为基础,将其作为最近邻聚类的样本数据,实现最近邻聚类算法,确定 RBFNN 的聚类中心(即径向基函数的中心),连接权值及隐层神经元的数量;最后将获得的各项参数与 NN Toolbox 相结合,完成对径向基神经网络的训练和仿真。

网络训练 221 s 结束,仿真实验结果如图 4 所示。其中,(a)为模拟图像退化过程生成的 4 帧带有模糊和噪声的 USS 图像,均作为 RBFNN 的输入样本图像,大小均为 128×128 ;(b)为 RBFNN 训练后输出的超分辨率重建图像,大小为 256×256 ,限于篇幅将其缩小 50% 显示;(c)为网络输出样本图像与超分辨率重建图像之间的误差图像,大小为 256×256 ,限于篇幅将其缩小 50% 显示。与笔者前期做过的 BPNN 超分辨率图像重建的仿真实验相比,网络训练时间短一半左右,仿真效果较好。




(a) 输入样本图像

(a) Input sample images



(b) RBFNN 仿真重建图像

(b) Simulation image of RBFNN SRR



(c) RBFNN 的仿真误差图像

(c) Simulation error image of RBFNN SRR

图 4 网络仿真实验

Fig. 4 Simulation results of RBFNN

3.2 RBFNN 的泛化性实验

神经网络的泛化性是指训练好的网络对检测样本(训练样本之外的样本)的预测能力,是评价网络性能的一项重要指标^[18]。泛化性能的好坏直接关系到网络能否实际应用,直接关系到研究的网络是否有实用意义。

本文在设计和实现 RBFNN 时,由于采用了向量映射的方式,LRI_s 序列到 HRI 之间的映射过程是以图像处理过程为基础的,而不是仅仅依赖于具体的图像,因此训练好的 RBFNN 能够代表这种从 LRI_s 到 HRI 的超分辨率模式映射过程。网络一旦训练成功,就可以保存下来(即保存了训练好的网络结构和参数),直接用来实现与本文有着一致退化模型的其他 LRI_s 的超分辨率图像重建问题,而不用再次学习和训练。即训练好的 RBFNN 有很强的泛化能力。

为了验证网络的泛化能力,本文将多次训练后达到最优的 RBFNN 保存下来,对 50 多帧各种类型灰度图像进行了实验,对 128×128 到 256×256 的超分辨率图像重建,平均重建时间为 2.25 s,而且重建效果较好。其中的两组泛化实验结果如图 5 所示。其中,(a,d)为 RBFNN 输入样本图像中的一帧,Mary 头像和卫星图像大小均为 128×128 ;(b,e)为 RBFNN 的超分辨率重建图像,大小为 256×256 ,限于篇幅将其缩小 50% 显示;(c,f)为 BPNN 的超分辨率重建图像,大小为 256×256 ,限于篇幅将其缩小 50% 显示。



(a) 女士头像,输入样本图像中的一帧

(a) Lady photo, one of input sample images



(b) RBFNN 超分辨重建图像

(b) Lady photo of RBFNN SRR



(c) BPNN 超分辨重建图像
(c) Lady photo of BPNN SRR



(f) BPNN 超分辨重建图像
(f) Satellite image of BPNN SRR



(d) 卫星图像,输入样本图像中的一帧
(d) Satellite image, one of input sample images



(e) RBFNN 超分辨重建图像
(e) Satellite image of RBFNN SRR

图 5 网络的泛化性实验

Fig. 5 Generalization results of BPNN and RBFNN

4 结 论

本文提出了一种径向基函数神经网络(RBFNN)超分辨率图像重建方法,是对基于学习的超分辨率重建方法的进一步探索。径向基函数的中心、宽度及网络的隐层数量、连接权值的确定采用最近邻聚类的算法,该算法根据输入样本数据自适应地确定网络所必需的参数,快速地训练出有效的网络模型。网络训练所需的学习样本采用亚像素位移欠采样(USS)的图像处理方法获取,输入、输出样本间采用向量映射(VM)的方式以加快网络收敛。仿真实验和泛化实验结果表明,建立起的RBFNN规模小,收敛速度快,221 s即可完成网络训练,泛化能力强,可直接用来实现有着一致退化模型的其他LRI序列的超分辨率重建问题。

参考文献:

- [1] SUNG C P, MIN K P, MOON G K. Super-resolution image reconstruction: a technical overview [J]. *IEEE Signal Processing Magazine*, 2003, 20(3): 21-36.
- [2] 郑丽贤,何小海,吴炜,等. 基于学习的超分辨率技术[J]. *计算机工程*, 2008, 34(5): 193-195.
ZHENG L X, HE X H, WU W, et al.. Learning-based super-resolution technique [J]. *Computer En-*

gineering, 2008, 34(5): 193-195. (in Chinese)

- [3] IRANI M, PELEG S. Improving resolution by image registration[C]. *Graphical Models and Image Processing*, 1991, 53(3): 231-239.
- [4] PATTI A, SEZAN M, TEKALP A. Super-resolution video reconstruction with arbitrary sampling lattices and nonzero aperture time [J]. *IEEE Trans. on Image Processing*, 1997, 6(8): 1064-1076.
- [5] SCHULTZ R, STEVENSON R. Extraction of

- high-resolution frames from video sequences [J]. *IEEE Trans. on Image Processing*, 1996, 5(6): 996-1011.
- [6] BAKER S, KANADE T. Limits on super-resolution and how to break them [J]. *Computer Vision and Pattern Recognition*, 2002, 24(9): 1167-1183.
- [7] FREEMAN W T, JONES T R, PASZTOR E C. Example-based super-resolution [J]. *IEEE Computer Graphics and Applications*, 2002, 22(2): 56-65.
- [8] BURT P J, ADELSON E H. The laplacian pyramid as a compact image Code [J]. *IEEE Trans. on Communications*, 1983, 31(4): 532-540.
- [9] VARSHA H, PATIL. Super resolution using neural network [C]. *Second Asia International Conference on Modelling & Simulation*, 2008, 492-496.
- [10] SUN Y. Hopfield neural network based on algorithms for image restoration and reconstruction-Part I: Algorithms and simulations [J]. *IEEE Trans. on Signal Processing*, 2000, 48(7): 2105 - 2118.
- [11] SUN Y. Hopfield neural network based on algorithms for image restoration and reconstruction-Part II: Performance and Analysis [J]. *IEEE Trans. on Signal Processing*, 2000, 48(7): 2119-2131.
- [12] YAO L, MINORU I, MARIA D C V. Super-resolution of the undersampled and subpixel shifted image sequence by a neural network [J]. *Imaging Systems and Technology*, 2004, 14(1): 8-15.
- [13] 吴明圣. 径向基神经网络和支持向量机的参数优化方法研究和应用[D]. 长沙:中南大学, 2007.
- WU M SH. *Parameter optimization method research and application of RBF neural network and SVM* [D]. Graduate University of the Central South University, 2007. (in Chinese)
- [14] ELAD M, FEUER A. Superresolution restoration of an image sequence: adaptive filtering approach [J]. *IEEE Trans. on Image Processing*, 1999, 8(3): 387- 395.
- [15] 刘梅, 刘慧念, 刘伟东, 等. 一种基于神经网络的超分辨率图像重构方法[J]. 哈尔滨工业大学学报, 2003, 35(6): 707-710.
- LIU M, LIU H N, LIU W D, *et al.*. Reconstruction of super-resolution image based on neural network[J]. *Journal of Harbin Institute of Technology*, 2003, 35(6): 707-710. (in Chinese)
- [16] 朱明星, 张德龙. RBF 网络基函数中心选取算法的研究[J]. 安徽大学学报(自然科学版), 2000, 24(1): 72-78.
- ZHU M X, ZHANG D L. Study on the algorithms of selecting the radial basis function center [J]. *Journal of Anhui University (Natural Sciences)*, 2000, 24(1): 72-78. (in Chinese)
- [17] 洪喜, 续志军, 杨宁. 基于径向基函数网络的光电编码器误差补偿法[J]. 光学 精密工程, 2008, 16(4): 598-604.
- HONG X, XU ZH J, YANG N. Error compensation of optical encoder based on RBF network[J]. *Opt. Precision Eng.*, 2008, 16(4): 598-604. (in Chinese)
- [18] 阎平凡. 人工神经网络的容量、学习与计算复杂性 [J]. 电子学报: 1995, 23(4): 63-67.
- YAN P F. Capacity, learning and computational complexity of artificial neural networks [J]. *Chinese Journal of Electronics*, 1995, 23(4): 63-67. (in Chinese)

作者简介:



朱福珍(1978—),女,黑龙江佳木斯人,博士研究生,2001年于哈尔滨工业大学获得学士学位,2006年于西南科技大学获得硕士学位,主要从事数字图像处理,图像超分辨率重建,神经网络技术方面的研究。Email: zhufuzhen_1978@163.com



朱 兵(1976—),男,江苏南京人,博士,讲师,主要从事图像处理、模式识别、高精度目标识别和跟踪以及交会对接等方面的研究。E-mail: zhub2004@163.com

导师简介:



李冬冬(1968—),女,黑龙江哈尔滨人,讲师,主要从事图像处理和空间交会对接等方面的研究。E-mail: lidd@hit.edu.cn



李金宗(1941—),男,安徽砀山人,教授,博士生导师,主要从事 D3S 技术、图像处理、超分辨率图像重建、模式识别和空间交会对接等方面的研究。E-mail: jzli@hit.edu.cn



杨学峰(1976—),男,河南商丘人,博士研究生,2004年于中国科学院获得硕士学位,主要从事图像处理、模式识别、图像复原及超分辨方面的研究。E-mail: yxf768@163.com

(本栏目编辑:白雨虹)

●下期预告

振动诱导聚合物塑化过程中熔体温度分布的预测

张冬至,杨艳娟,蔡 军

(华南理工大学 机械与汽车工程学院,广东 广州 510640)

在振动力场诱导聚合物塑化成型作用下,建立了聚合物熔融挤出过程的熔体温度分布模型,研究了模头温度,振动力场的振幅、频率等工艺参数对挤出过程中熔体温度的影响。提出基于多项式和高斯 RBF 核函数变换的两种非线性岭回归模型(PT-RR 和 GRBF-RR),对具有非线性、非等温、强耦合特征熔融过程的熔体温度分布进行研究。该建模方法实现了多变量输入样本的高维特征空间非线性映射与重构,充分挖掘了多影响因素之间的耦合信息。然后,基于 GRBF-RR 模型的数值模拟,分析了不同工艺参数对熔体温度分布的交叉耦合影响。仿真和实验结果表明了 PT-RR 和 GRBF-RR 模型的有效性,其回归预测值与实验测量值之间的相关系数均值分别为 0.994 0 和 1,取得了满意的模型精度。该模型可为提高精密挤出制品质量及优化配置各工艺参数提供决策依据。