

基于非单点模糊正则网络的图像预测编码

史耀媛¹, 宋 恒²

(1. 西北工业大学 自动化学院, 陕西 西安 710072; 2. 空军工程大学 工程学院, 陕西 西安 710038)

(songhengyang@163.com)

摘 要:提出了一种利用非单点模糊正则网络构建预测器的图像压缩预测编码算法。该算法将非单点模糊化技术引入正则神经网络,在自学习的过程中,能够自动滤除训练数据中的噪声,获取准确的信息。通过仿真试验,并传统预测编码方法、神经网络预测编码方法进行比较,结果证明该算法具有抗干扰能力强、预测精度高、恢复图像效果好等突出优点。

关键词:预测编码;非单点模糊系统;神经网络;相空间重构

中图分类号: TP391; TP18 **文献标识码:** A

Predictive coding based on non-singleton fuzzy regular network

SHI Yao-yuan¹, SONG Heng²

(1. College of Automation, Northwestern Polytechnical University, Xi'an Shaanxi 710072, China;

2. College of Engineering, Air Force Engineering University, Xi'an Shaanxi 710038, China)

Abstract: A predictive coding model based on non-singleton fuzzy regular network (NSFRN) was presented. In this model, non-singleton fuzzier was introduced into regular neural network, so that noise could be removed from train data adaptively. After being simulated and compared with other predictive coding models, the model shows much better performance on anti-jamming capability, prediction precision and the quality of reconstruction pictures.

Key words: predictive coding; non-singleton fuzzy system; neural network; phase-space reconstruction

0 引言

随着信息技术,特别是通信技术的发展,图像数据压缩的重要性日益突出,而传统的图像压缩技术已经无法满足需要。近年来,人们将神经网络应用于图像预测编码取得了较好的效果^[1~3]。但神经网络结构复杂,不易调整,当训练数据受噪声污染时,很容易陷入过学习和欠学习问题,使网络的推广能力下降,造成恢复图像信噪比降低。尽管有文章提出用遗传算法调整网络的内部参数,但也并不能从本质上解决问题。这使得基于神经网络的图像压缩方法很难得到实际应用。基于此,本文提出一种基于非单点模糊正则网络(Non-Singleton Fuzzy Regular Network, NSFRN)的图像预测编码算法。该预测算法将非单点模糊系统和神经网络相结合,能够根据数据的噪声概率分布自动处理噪声,具有很强的抗噪声能力,推广能力强。通过仿真实验,并传统预测编码方法、神经网络预测编码方法进行了比较,结果证明了本文提出算法的有效性。

1 预测编码基本原理

预测编码^[4]是统计冗余数据压缩理论的三个重要分支之一,它的理论基础是现代统计学和控制论。预测编码主要是减少数据在时间和空间上的相关性,因而对于时间序列数据有广泛的应用价值。最常用的预测编码方法是差分编码调制(Differential Pulse Code Modulation, DPCM)。

图 1 中,信源输出序列 \bar{x}_i 即为 DPCM 输入序列。 \bar{x}_i 与预

测值 \hat{x}_i 相减得误差值 e_i ,再将 e_i 量化成数字序列 e'_i 。在接收端将接收到的 e'_i 与在接收端形成的预测值 \hat{x}_i 相加,可得恢复后的信源序列 x_i ,同时又将 x_i 反馈到接收端线性预测器,以求得下一瞬间的预测值 \hat{x}_{i+1} 。由于预测误差 e_i 的熵(或方差)远低于输入序列 \bar{x}_i 的熵(或差值),所以经预测后可以很大程度地提高压缩信源的数码率。

预测编码中预测器的设计是关键,对于含噪声图像来说,预测算法的抗干扰能力决定了恢复图像的准确性。本文的工作就是利用 NSFRN 设计一种具有强抗干扰能力的非线性自适应预测器。而编码器则采用无失真的 Huffman 编码。




图 1 DPCM 原理

2 基于 NSFRN 的预测器设计

信源数据常常具有非线性,混沌理论提出的相空间重构、动力学建模等是处理和分析非线性系统的良好方法,因此本文运用非线性混沌时间序列预测的思想,将信源样本数据进行相空间重构,再通过 NSFRN 拟合其时间序列动力学映射函数,同时采用梯度下降法调整网络内部参数,构建出具有较强抗干扰能力的非线性自适应预测器。

2.1 混沌相空间重构技术

Takens 定理^[5,6]指出:在由一维观测序列及其适当延时值

所构成的维数合适的相空间中,系统演化的动力学行为可由此空间中点的演化轨迹无歧义地表达出来。这个由观测值及其延时值所构成的空间称为重构相空间,这种由一维数据构造系统等价相空间的方法就叫作相空间重构技术。例如,利用延迟-嵌入定理^[5],可把一维时间序列嵌入到 m 维空间中:

$$x(t) \Rightarrow [x(t), x(t-\tau), x(t-2\tau), \dots, x(t-(m-1)\tau)]^T \quad (1)$$

$x(t)$ 表示 t 时刻系统的动力学状态,其中 τ 为时滞, m 为嵌入空间中点集的维数。

Takens 定理指出系统原始状态变量构成的相空间和一维观测值重构相空间里的动力学行为等价,两个相空间中的混沌吸引子微分同胚,即一维观测值中包含有系统所有状态变量演化的全部信息。利用此演化规律可以得到系统下一时刻状态,从而得到时间序列下一时刻预测值。即:

$$x(t) = f(x(t-\tau), x(t-2\tau), \dots, x(t-(m-1)\tau)) \quad (2)$$

文献[6]对 τ 和 m 的选取进行了深入细致的研究。时延值 τ 的选取可采用最小互信息量法确定,以新加入的点能带来最多的新信息为准,避免延时过小时相邻两点相关性太强导致重构相空间中吸引子压缩,同时避免延时过大时相邻两点几乎不相关导致重构相空间中吸引子弥散。嵌入维数 m 的选取可采用最小伪邻近点法,使得重构相空间吸引子能无二义性地反映系统动力学行为,同时 m 要尽可能小。本文运用最小互信息量法和最小伪邻近点法对仿真试验样本数据进行相空间重构,选定 τ 为 3, m 为 4。

2.2 非单点模糊正则网络预测器

本文设计的 NSFRN 预测器是一种采用正则神经网络结构实现的非单点模糊系统,结合了神经网络的自学习能力^[7]、非单点模糊系统的启发式搜索能力和抗干扰能力^[8,9],具有很强的非线性逼近性能和抗噪声性能。




图2 NSFRN 预测器结构

由图2可见,NSFRN 的输入为:

$$x(t) = [x(t-\tau), x(t-2\tau), \dots, x(t-(m-1)\tau)]^T \quad (3)$$

NSFRN 本质上是一个正则神经网络实现的多输入单输出非单点模糊系统,其模糊规则可表述如下:

$$R^l: \text{If } x(t-\tau) \text{ is } F_1^l \text{ and } \dots \text{ and } x(t-(m-1)\tau) \text{ is } F_{m-1}^l \\ \text{Then } x'(t) \text{ is } G^l \quad (4)$$

式中, F_i^l 和 G^l 分别为 $U_i \subset R$ 和 $V \subset R$ 上的模糊集合, $l = 1, 2, \dots, S$ 为模糊规则数。

非单点模糊系统的概念是由 Zadeh 在 20 世纪 70 年代提出的,指采用非单点模糊器的模糊系统^[10]。模糊系统一般由模糊器、模糊推理机和解模糊器组成。其中模糊器的作用是将确定的输入 $X(t)$ 映射为输入空间 U 上的一个模糊集合 A' 。对于单点模糊化, A' 为模糊单值,则对 $X(t) = X(t')$, 有 $u_{A'}(X(t')) = 1$, 而对其余 $X(t) \neq X(t')$, 有 $u_{A'}(X(t)) = 0$ 。但在非单点模糊产生器中, $u_{A'}(X(t')) = 1$, 随着 $X(t)$ 偏离

$X(t')$, $u_{A'}(X(t))$ 逐渐减少,被映射成模糊数,模糊隶属函数与 $X(t)$ 相关,则有:

$$u_{A'}(X(t)) = u_{x(t-\tau)}(x(t-\tau)) * \dots * u_{x(t-(m-1)\tau)}(x(t-(m-1)\tau)) \quad (5)$$

本文采用 $\sup * (*$ 取代数积算子)合成运算,则有:

$$\sup \left[\prod_{k=1}^{m-1} u_{x(t-k\tau)}(x(t-k\tau)) u_{F_k^l}(x(t-k\tau)) \right] = \sup \left[\prod_{k=1}^{m-1} [u_{Q_k^l}(x(t-k\tau))] \right] \quad (6)$$

本文取隶属度函数为高斯函数,求解 $\sup[]$ 得:

$$x(t-k\tau)_{\max}^l = (\sigma_{x(t-k\tau)}^2 m_{F_k^l} + \sigma_{F_k^l}^2 m_{x(t-k\tau)}) / (\sigma_{x(t-k\tau)}^2 + \sigma_{F_k^l}^2) \quad (7)$$

将 $\sup[]$ 的解(7)式代回(6)式,便完成了输入信号的非单点模糊化。再经过正则化单元,并经过加权平均过程,便得到 NSFRN 的输入输出关系如下(设输入信号 $x(t-k\tau)$ 具有相同的不确定性,为 σ_x):

$$x'(t) = \sum_{l=1}^S w_l \frac{\prod_{k=1}^{m-1} \exp[-(x(t-k\tau) - m_{F_k^l})^2 / (2\sigma_{x(t-k\tau)}^2 + 2\sigma_{F_k^l}^2)]}{\sum_{l=1}^S \prod_{k=1}^{m-1} \exp[-(x(t-k\tau) - m_{F_k^l})^2 / (2\sigma_{x(t-k\tau)}^2 + 2\sigma_{F_k^l}^2)]} \\ = \sum_{l=1}^S w_l \frac{\prod_{k=1}^{m-1} \exp[-(x(t-k\tau) - m_{F_k^l})^2 / (2\sigma_x^2 + 2\sigma_{F_k^l}^2)]}{\sum_{l=1}^S \prod_{k=1}^{m-1} \exp[-(x(t-k\tau) - m_{F_k^l})^2 / (2\sigma_x^2 + 2\sigma_{F_k^l}^2)]} \quad (8)$$

由于信源可能具有非平稳特性,要求预测器应当具有自适应性。本文根据均方误差最小准则,采用梯度下降算法自适应调整 NSFRN 内部参数 w_l , $m_{F_k^l}$, σ_x , $\sigma_{F_k^l}$ (推导过程省略):

$$\psi(e(t)) = \partial \phi(e(t)) / \partial e(t) \approx e(t) = x(t) - x'(t) \quad (9)$$

$$P_l(X(t)) = \frac{\prod_{k=1}^{m-1} \exp[-(x(t-k\tau) - m_{F_k^l})^2 / (2\sigma_x^2 + 2\sigma_{F_k^l}^2)]}{\sum_{l=1}^S \prod_{k=1}^{m-1} \exp[-(x(t-k\tau) - m_{F_k^l})^2 / (2\sigma_x^2 + 2\sigma_{F_k^l}^2)]} \quad (10)$$

$$w_l(t+1) = w_l(t) + \eta_w \psi(e(t)) P_l(X(t)) \quad (11)$$

$$m_{F_k^l}(t+1) = m_{F_k^l}(t) + \eta_m \psi(e(t))$$

$$[w_l(t) - x'(t)] \left[\frac{x(t-k\tau) - m_{F_k^l}(t)}{\sigma_x^2(t) + \sigma_{F_k^l}^2(t)} \right] P_l(X(t)) \quad (12)$$

$$\sigma_{F_k^l}(t+1) = \sigma_{F_k^l}(t) + \eta_\sigma \sigma_{F_k^l} \psi(e(t))$$

$$[w_l(t) - x'(t)] \left[\frac{x(t-k\tau) - m_{F_k^l}(t)}{\sigma_x^2(t) + \sigma_{F_k^l}^2(t)} \right]^2 P_l(X(t)) \quad (13)$$

$$\sigma_x(t+1) = \sigma_x(t) + \eta_\sigma \sigma_x(t) \psi(e(t))$$

$$[w_l(t) - x'(t)] \left[\frac{x(t-k\tau) - m_{F_k^l}(t)}{\sigma_x^2(t) + \sigma_{F_k^l}^2(t)} \right]^2 P_l(X(t)) \quad (14)$$

本文在仿真实验中,对内部参数的初始值采用减法聚类的方法确定,对所有步长 $\eta_w, \eta_m, \eta_\sigma, \eta_x$ 简单地采用定步长。

2.3 NSFRN 预测器的抗噪声性能分析

在工程处理中,用精确输入 $x(t-k\tau)$ 代替模糊输入集合的均值 $m_{x(t-k\tau)}$,式(7)变为:

$$x(t-k\tau)_{\max}^l = (\sigma_x^2 m_{F_k^l} + \sigma_{F_k^l}^2 x(t-k\tau)) / (\sigma_x^2 + \sigma_{F_k^l}^2) \quad (15)$$

从(15)式可以看出,当输入变量 $x(t-k\tau)$ 没有受到噪声污染,即 $\sigma_x^2 = 0$ 时, $x(t-k\tau)_{\max}^l = x(t-k\tau)$,非单点模糊化与单点模糊化等价;当输入变量 $x(t-k\tau)$ 受到噪声污染时,

设 $x(t-k\tau) = x_0(t-k\tau) + N(t-k\tau)$ (其中 $x_0(t-k\tau)$ 为有用信号, $N(t-k\tau)$ 为噪声), 将其代入式得:

$$x(t-k\tau)_{\max} = \left(\sigma_x^2 m_{F_k^l} + \sigma_{F_k^l}^2 x_0(t-k\tau) \right) / \left(\sigma_x^2 + \sigma_{F_k^l}^2 \right) + \sigma_{F_k^l}^2 N(t-k\tau) / \left(\sigma_x^2 + \sigma_{F_k^l}^2 \right) \quad (16)$$

由(16)式可见, 噪声穿过非单点模糊器时, 会被因子 $\sigma_{F_k^l}^2 / (\sigma_x^2 + \sigma_{F_k^l}^2)$ 所克服。如果 $\sigma_x \gg \sigma_{F_k^l}$, 噪声将会在很大程度上被抑制。所以, NSFRN 预测器具有很强的抗干扰能力。

3 仿真实验

为了验证本文提出算法的有效性, 我们把传统预测编码方法(P阶自回归模型)、神经网络预测编码方法分别用于图像的压缩编码, 并比较各自的编码效果。实验中, 采用信噪比(Signal Noise Ratio, SNR)作为描述码本性能的指标。对于 $N_1 \times N_2$ 像素的图像, 定义 SNR 为:

$$SNR = 10 \lg \frac{\sum_{i=1}^{N_1-1} \sum_{j=1}^{N_2-1} \hat{r}_{i,j}^2}{\sum_{i=1}^{N_1-1} \sum_{j=1}^{N_2-1} (r_{i,j}^2 - \hat{r}_{i,j}^2)^2} \quad (17)$$

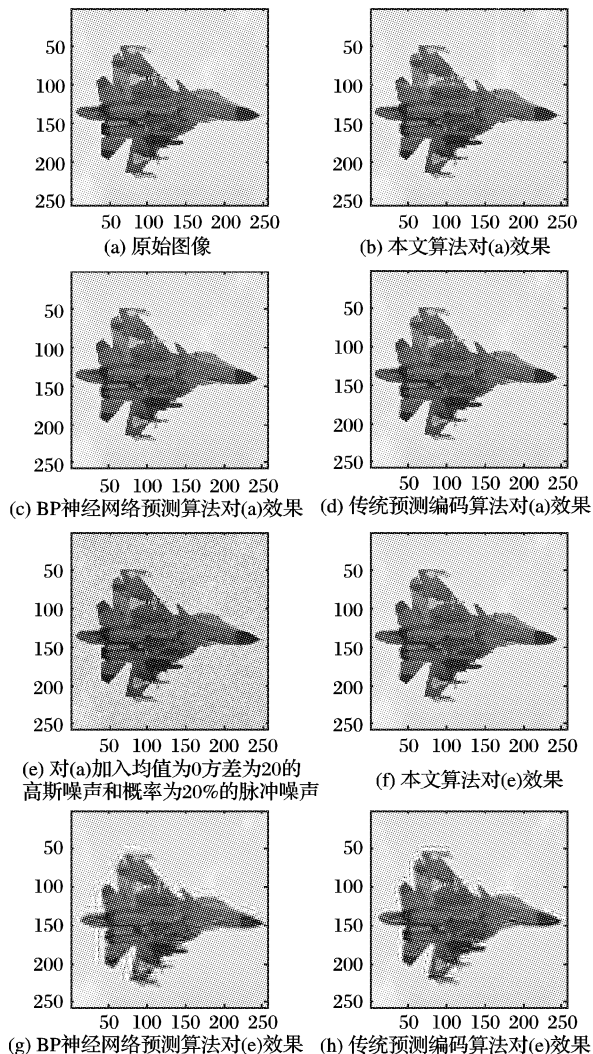


图3 不同预测编码方法的恢复图像效果

其中原始图像像素为 $I_{i,j}$, 而重构图像像素为 $\hat{I}_{i,j}$ 。

选取 256×256 的标准灰度图像 Barbara, Lena, Tire, Couple 和 Su-30 飞机图像进行编解码实验, 在 Matlab 6.1 平台上进行

仿真。在相同的压缩比下, 分不含噪声和加入噪声两种情况, 均以恢复图像的峰值信噪比来进行比较, 结果表明本文提出的算法是有效的。下面取出 Su-30 飞机图像的实验结果进行说明。Su-30 飞机图像的实验结果如图3和表1所示。

表1 Su-30 飞机图像压缩预测编码方法比较

预测编码方法	无噪声图像		含噪声图像	
	$E_{MSE}(\%)$	SNR/dB	$E_{MSE}(\%)$	SNR/dB
传统预测编码	2.02	28.3670	7.35	24.5809
神经网络预测编码	1.60	28.9890	8.44	23.6430
NSFRN 预测编码	1.51	29.0981	2.82	27.4652

从图3和表1可以看出, 对于无噪声图像, 基于 NSFRN 的预测编码方法同传统预测编码方法和神经网络预测编码方法一样有效; 而对于含有噪声的图像, 基于 NSFRN 的预测编码方法显示出了明显的优越性: 预测精度高, 恢复图像与原始图像的信噪比大, 恢复图像效果好。这正是 NSFRN 预测器在数据学习的过程中自动滤除了噪声, 具有更好的推广能力的结果。

4 结语

本文提出了一种基于 NSFRN 的图像预测编码算法。该预测算法将非单点模糊系统和正则神经网络相结合, 能够根据数据的噪声概率分布自动处理噪声, 具有很强的抗噪声能力。通过仿真实验, 并同传统预测编码方法、神经网络预测编码方法进行比较, 结果证明该算法抗干扰能力强, 预测精度高, 恢复图像与原始图像的信噪比大, 恢复图像效果好。

参考文献:

- [1] 许锋, 卢建刚, 孙优贤, 等. 一种基于 PCA/SOFM 混合神经网络的图像压缩算法[J]. 中国图象图形学报, 2003, 8(9): 1100 - 1104.
- [2] FANG WC, SHEU BJ, CHEN OT. A neural network based VLSI vector quantizer for real-time compression[A]. Proceedings Data Compression Conference [C]. Snowbird, Utah, USA, 1991. 342 - 351.
- [3] 黎洪松, 全子一. 一种基于自组织神经网络的图像压缩编码算法[J]. 电子学报, 1996, 24(1): 6 - 11.
- [4] 田丽华. 编码理论[M]. 西安: 西安电子科技大学出版社, 2003.
- [5] TAKENS F. On the numerical determination of the dimension of an attractor[A]. Dynamical Systems and Turbulence, Lecture Notes in Mathematics 898[C]. Berlin: Springer-Verlag, 1981. 230 - 241.
- [6] ABARBANEL DI. Analysis of Observed Chaotic Data [M]. New York: Springer-Verlag, 1996.
- [7] ABDALLAH AS. Artificial neural network for forecasting residential electrical energy [J]. International Journal of Energy Research, 1999, 23(8): 649 - 661.
- [8] MITRA S, GUPTA MM, KRASKE WF. Neural and Fuzzy System [M]. USA: SPIE Press, 1994.
- [9] 王立新. 模糊系统与模糊控制[M]. 北京: 清华大学出版社, 2003.
- [10] ZADEH LA. Outline of a new approach to the analysis of complex systems and decision processes[J]. IEEE Transactions on Systems, Man and Cybernetics, 1973, 3(1): 28 - 44.