

自联想神经网络的遥感图象主分量提取

王耀南 谢勇 毛建旭 李树涛

(湖南大学电气与信息工程系, 长沙 410082)

(中国科学院模式识别国家重点实验室, 北京 100080)

摘要 提出了一种自联想神经网络的遥感图象主分量提取方法. 这种方法可以应用于图象的压缩、特征提取和图象滤波中. 实验结果表明: 自联想神经网络算法简单、易于实现, 其压缩效果与 K-L 变换相当.

关键词 遥感 神经网络 图象压缩

中图分类号: TP751 文献标识码: A 文章编号: 1006-8961(2000)01-0025-05

Principal Component Extraction for Remote Sensing Image Using Auto-Association Neural Network

WANG Yao-nan, XIE Yong, MAO Jian-xu, LI Shu-tao

(Department of Electrical and Information Engineering, Hunan University, Changsha 410082)

(National Laboratory of Pattern Recognition, Chinese Academy of Sciences, Beijing 100080)

Abstract A new method of principal component extraction for remote sensing image based on auto-association neural network is presented in this paper. The proposed method is applied to the image data compression, feature extraction and filtering. Experiments show that auto-association neural network for extracting the principal components of the image is as good as the conventional K-L transform.

Keywords Remote sensing, Neural network, Image compression

0 引言

遥感图象信息的主分量分析,基本上在于求出一个标准的转换矩阵,经过变换到一组新的主分量“波段”上.在特征域中这些新的主分量波段彼此之间可以是不相关的,即相互独立的.这种主分量提取的用途是:(1)在图象处理中,可以大大减少信息量的传输;(2)可以在少量的主分量图象上进行全面综合,识别所有的图象信息^[1,2].例如,遥感图象4个波段彼此之间存在着相关性,它们提供了相关的卫星相片图象.这些波段的图象信息不是相互独立的,如果想要综合所有的信息就必须对不同波段的卫片进行全面的分析.但是可以设法把4个波段的信息压缩到一个主分量“波段”或两个相互独立的主

分量“波段”上,让这些新的主分量“波段”图象信息保持原来所有波段上的图象信息的绝大部分.这样就可以用较少的一两个主分量图象来保留原来4个波段上的原始图象信息,这就是主分量提取的目的所在.目前遥感图象信息的主分量提取主要采用 K-L 变换.但是这种变换方法的计算量很大,而且变换矩阵也不具有可分解性,使得 K-L 变换在实际应用中大受限制.为此,我们提出了一种基于自联想神经网络的主分量提取方法.

1 基于自联想神经网络的主分量提取方法

1.1 自联想神经网络模型

图1给出了自联想神经网络模型,这种网络是

一种自动编码或识别映射的二层网络,它具有双向输入模式,输入输出层有 N 个节点,隐层由 P 个线性节点组成, $P < N$, \hat{W}_1 和 \hat{W}_2 分别为输入层到隐层和隐层到输出层的连接权值矩阵. 这种网络的特点

是:通过网络的训练(调整 W_1 和 W_2),能使输入节点的信息压缩在隐层节点上,这些压缩的信息又能在输出层重构输入的信息,即 $X(n) \approx Y(n)$.




图1 自联想神经网络

网络的输入输出映射关系

$$y_i(n) = w_{2i}^T(n) \cdot h_i(n) \quad (1)$$

$$h_i(n) = w_{1i}^T(n) \cdot x_i(n) \quad (2)$$

$$y_i(n) = w_{2i}(n) \cdot w_{1i}^T(n) \cdot x_i(n) \quad (3)$$

假如网络经过训练分别得到优化的权值 \hat{W}_1 和 \hat{W}_2 , 那么有

$$\hat{W}_1 = T U_p \quad (4)$$

$$\hat{W}_2 = U_p^T \cdot T^{-1} \quad (5)$$

其中, U_p 表示矩阵, 它的每行由输入协方差矩阵的 p 个特征向量组成; T 表示一个 $p \times p$ 维的非奇异矩阵. 从上述两个方程可知, 神经网络的全局映射是由它的协方差矩阵的 p 个主特征向量扩展成输入空间的正交分量组成. 即网络的输入模式与输出模

式重构, 有

$$\hat{W}_2 = \hat{W}_1^T, \quad T^{-1} = T^T \quad (6)$$

1.2 基于 RLS 学习算法的主分量提取

在这里, 我们引入 RLS 算法^[6,7] 来进行主分量提取.

(1) 提取第一个主分量

图2给出了由一个隐节点组成的线性自联想神经网络结构图, 假定输入是一个均值为零的定长向量, 它的协方差矩阵具有 N 个正的特征值, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$. 用 RLS 算法学习的目标是调整第一层的权值, 求出与最大特征值 λ_1 有关的特征向量 $\hat{W}_1(n)$, 并能使第二层输出得到优化的数据重构.




图2 第一个主分量提取的自联想神经网络结构

设 n 时刻的输入向量为

$$X(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T \quad (7)$$

主分量提取的第一层权值向量为

$$W_1(n-1) = [w_{11}(n-1), w_{12}(n-1), \dots, w_{1N}(n-1)]^T \quad (8)$$

用于重构的网络第二层权值向量为

$$W_2(n-1) = W_1^T(n-1) \quad (9)$$

网络的线性隐节点的输出为

$$h_1(n) = W_1^T(n-1) \cdot X(n) \quad (10)$$

相应的网络输出为

$$\begin{aligned} Y(n) &= W_2(n-1)h_1(n) \\ &= W_2(n-1)W_1^T(n-1)X(n) \end{aligned} \quad (11)$$

定义网络的训练指标函数 J_1 为

$$\begin{aligned} J_1(n) &= \sum_{k=1}^n \epsilon_1^T(k) \cdot \epsilon_1(k) \\ &= \sum_{k=1}^n (X(k) - Y(k))^T (X(k) - Y(k)) \\ &= \sum_{k=1}^n (X(k) - W_1(k-1)h_1(k))^T \cdot \\ &\quad (X(k) - W_1(k-1)h_1(k)) \end{aligned} \quad (12)$$

$$\sum_{k=1}^n h_1(k) \cdot \epsilon_1(k) = 0$$

有

$$\sum_{k=1}^n h_1(k) \cdot (X(k) - \hat{W}_1(n)h_1(k)) = 0 \quad (13)$$

其中 $\hat{W}_1(n)$ 表示 $W_1(n)$ 的估计值。

(13) 式写成向量形式

$$h_1^T(n) \cdot E_1(n) = 0 \quad (14)$$

其中 $E_1(n)$ 表示总的误差矩阵 ($n \times N$ 维), 即,

$$E_1(n) = [\epsilon_1(1), \epsilon_1(2), \dots, \epsilon_1(n)]^T$$

$$h_1(n) = [h_1(1), h_1(2), \dots, h_1(n)]^T$$

定义期望输出矩阵为

$$D(n) = X(n) = [x(1), x(2), \dots, x(n)]^T \quad (15)$$

由(13) 式得

$$h_1^T(n)(x(n) - h_1(n)\hat{W}_1^T(n)) = 0 \quad (16)$$

解出第二层的优化权值向量 $\hat{W}_1(n)$ 为

$$\hat{W}_1^T(n) = (h_1^T(n) \cdot h_1(n))^{-1} \cdot h_1^T(n) \cdot X(n) \quad (17)$$

或者第一层权值向量

$$\hat{W}_1^T(n) = (h_1^T(n) \cdot h_1(n))^{-1} \cdot X^T(n) \cdot h_1(n) \quad (18)$$

利用 RLS 算法可计算出 $\hat{W}_1(n)$ 权值向量

$$h_1(n) = \hat{W}_1^T(n-1)X(n) \quad (19)$$

$$k_1(n) = \frac{p_1(n-1)h_1(n)}{1 + h_1^T(n) \cdot p_1(n-1)} \quad (20)$$

$$\begin{aligned} \hat{W}_1(n) &= \hat{W}_1(n-1) + k_1(n)[X(n) - \\ &\quad h_1(n)\hat{W}_1(n-1)] \end{aligned} \quad (21)$$

$$p_1(n) = [1 - k_1(n)h_1(n)]p_1(n-1) \quad (22)$$

其中 $p_1(n)$ 为第一层第一个神经元输出的协方差逆, 即

$$p_1(n) = \left| \sum_{l=1}^n h_1^2(l) \right|^{-1} \quad (23)$$

$k_1(n)$ 为 Kalman 增益(修正步距), 初值取 $p_1(0) = 0.5, \hat{W}_1(0) = 0$ 。

(2) 提取最后分量

图 3 所示给出了主分量提取的序列线性感知器结构。




图 3 主分量提取序列的线性感知器

设 n 时刻的输入向量为

$$X(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T \quad (24)$$

第 m 个节点的权值向量为

$$\begin{aligned} W_m(n) &= [w_{m1}(n), w_{m2}(n), \dots, w_{mN}(n)]^T \\ m &= 1, 2, \dots, p \end{aligned} \quad (25)$$

第 m 个隐节点的输出为

$$h_m(n) = W_m^T(n-1) \cdot X(n) \quad (26)$$

假定在 $(m-1)$ 个以前的节点已经受过训练, 它们的权值已经收敛到最优权值向量 $\hat{W}_i, i = 1, 2, \dots, m-1$, 那么, 可用如下式提取主分量:

$$\hat{h}_i(n) = \hat{W}_i^T \cdot X(n), \quad i = 1, 2, \dots, m-1 \quad (27)$$

为了在第 m 个节点的输出提取第 m 个主分量, 网络经过自联想, 即应在 n 次迭代后, 使该节点的期望输出为:

$$d_m(n) \approx X(n) - \sum_{i=1}^{m-1} \hat{h}_i(n) \cdot \hat{W}_i \quad (28)$$

定义训练网络的性能指标为

$$\begin{aligned} J_m(n) &= \sum_{k=1}^n (d_m(k) - h_m(k) \cdot W_m(n))^T \times \\ &\quad |d_m(k) - h_m(k)W_m(n)| \\ &= \sum_{k=1}^n \left| X(k) - \sum_{i=1}^{m-1} \hat{h}_i(k)\hat{W}_i - h_m(k)W_m(n) \right|^T \times \\ &\quad \left| X(k) - \sum_{i=1}^{m-1} \hat{h}_i(k)\hat{W}_i - h_m(k)W_m(n) \right| \end{aligned} \quad (29)$$

其中, $W_m(n)$ 均用在 $W_m(k)$, $k=1, 2, \dots, n-1$ 时刻.

假如期望输出矩阵为

$$D_m(n) = [d_m(1), d_m(2), \dots, d_m(n)]^T \quad (30)$$

那么, 使性能指标 $J_m(n)$ 最小, 可求出最优化权值向量 $\hat{W}_m(n)$, 即

$$\hat{W}_m(n) = (h_m^T(n) \cdot h_m(n))^{-1} D_m^T(n) \cdot h_m(n) \quad (31)$$

其中,

$$h_m(n) = [h_m(1), h_m(2), \dots, h_m(n)]^T \quad (32)$$

现在, 利用 RLS 算法可训练优化的权值向量 $\hat{W}_m(n)$, 对于第 m 个神经元, 有

$$h_m(n) = W_m^T(n-1)X(n) \quad (33)$$

$$k_m(n) = \frac{P_m(n-1)h_m(n)}{|1 + h_m^2(n) \cdot P_m(n-1)|} \quad (34)$$

$$\begin{aligned} \hat{W}_m(n) &= \hat{W}_m(n-1) + k_m(n)d_m(n) - h_m(n)\hat{W}_m(n-1) \\ &= \hat{W}_m(n-1) + k_m(n) \left| X(n) - \sum_{i=1}^{m-1} \hat{h}_i(n)\hat{W}_i - h_m(n)\hat{W}_m(n-1) \right| \end{aligned} \quad (35)$$

$$P_m(n) = |1 - k_m(n)h_m(n)| P_m(n-1) \quad (36)$$

其中, $P_m(n)$ 为第一层第 m 个神经元输出的协方差逆, 即

$$P_m(n) \approx \left| \sum_{i=1}^n h_m^2(l) \right|^{-1} \quad (37)$$

2 图象数据压缩和特征提取的实验结果

(1) 图象数据压缩和特征提取

为了验证所提方法的有效性, 我们采用一幅具有 256 个灰度级的 512×512 分辨率的多光谱遥感图象作为测试图象数据. 原图象如图 4 所示, 首先将原图象分成不重叠的 8×8 分辨率的子图象集 (64 块), 然后将 $8 \times 8 = 64$ 个象点按行或列排成一维的输入向量 $X_i = [x_1, x_2, \dots, x_{64}]_6$, 从中抽取 $64 \times 64 = 4096$ 个训练数据作为学习样本, 从每个数据向量中减去训练数据的均值, 得到均值为零的训练输入数据. 神经网络的结构为 $64-16-64$, 输入输出层取 64 个节点, 隐层节点取 16 个. 初始权值 $W_1(0)$ 随机给定, $P_m(0) = 0.5$. 利用 RLS 算法训练第一层神经网络的权值 $W_1(n)$, 使 $W_1(n)$ 收敛于 $\hat{W}_1(n)$, 此时在隐层节点的输出提取输入图象的 16 个主分量值. 我们可以用 K-L 变换计算出输入协方差矩阵的特征值分布 ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{16}$), 原始图象在第 K 个分

量中所包括的能量百分比为:

$$\text{能量} = \frac{1}{K} \sum_{i=1}^K \frac{\lambda_i}{\delta^2} \times \% \quad (38)$$

其中, λ_i 表示第 i 个分量的方差, 或是输入协方差矩阵的第 i 个特征值; δ^2 表示原始图象的方差, 可以计算得 $\delta^2 = 2209$, 第一批 16 个主分量的能量占总能量的百分比为 94%. 因此, 只要神经网络训练过程结束, 我们就可以使用第一批 16 个主特征向量所对应的收敛权值 $\hat{W}_1(n)$ 和 16 个神经元 (节点), 把每个 8×8 块子图象压缩到 16 个主分量上, 从而完成图象压缩功能. 当要恢复原图象时, 可使用第二层神经网络, 令 $\hat{W}_2(n) = \hat{W}_1^T(n)$, 用 $y_1(n) = \sum \hat{h}_i(n)\hat{W}_2(n)$ 重构出原图象. 用 K-L 变换压缩的图象如图 5 所示, 用自联想神经网络压缩的图象如图 6 所示. 从两图中可看出用自联想神经网络压缩的图象与 K-L 变换压缩的图象相比, 压缩效果更好, 信噪比 $\text{SNR} = 21\text{db}$, 这是因为 16 个主分量包括了原图象的 $3/4$ 分量, 因此原图象经过压缩, 又重构, 能够完全恢复出原始图象.




图 4 原始图象

事实上, 在实际应用中, 用测试图象的样本训练好的神经网络, 它的收敛权值 $\hat{W}(n)$ 和主特征分量仍可用于压缩其它图象. 这一特点有利于雷达和卫星图象的实时图片处理.

(2) 图象滤波的应用

图 7 是一幅 512×512 分辨率、具有 256 种灰度、带有噪声的高光谱遥感图象. 我们首先将这幅图象分成 64 块, 每块大小为 8×8 个象素点, 利用前面介绍的 RLS 算法, 训练神经网络 ($64-16-64$) 的第一层权值 (输入层 64 个节点, 输出层 16 个节点), 然后用收敛的权值向量将原图象变换到它的 16 个主分量上去, 重构的图象如图 8 所示, 可以看出重构的图象已去掉了噪声, 图象显得清楚, 起到了图象滤波的作用.




图 5 采用 K-L 变换压缩后重构的图象




图 6 采用自联想神经网络压缩后重构的图象




图 7 原图象



图 8 去噪重构处理的图象

参 考 文 献

- 1 Zhou Y-T, Chellappa R, Vaid A *et al.* Image restoration using neural network. *IEEE Trans Speech, Signal Processing*, 1988, 36(7): 1141~ 1151.
- 2 Chua L O, Yang L. Cellular neural network: theory. *IEEE Trans Circuits and Systems*, 1998, 35(10): 1257~ 1272.
- 3 Chua L O, Yang L. Cellular neural network: application. *IEEE Trans on Circuits and Systems*, 1998, 35(10): 1272~ 1290.
- 4 Lee Chi-Chien, Jose pineda de Gyvez. Color image processing in a cellular neural network environment. *IEEE Trans Neural Network*, 1996, 10(5): 1086~ 1096.
- 5 Paola J D, Schwengerdt R A. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imager. *INT J Remote Sensing*, 1995, 16(16): 3033~ 3058.
- 6 Paola J D, Schowengerdt R A. A detailed comparison of back-

propagation neural network and maximum-likelihood classifiers for Urban Land use classification. *IEEE Trans Geoscience and Remote Sensing*, 1994, 33(4): 1066~ 1172.

- 7 Yu Chang Tzang, Chen K S. A dynamic learning neural network for remote sensing applications. *IEEE Trans Geoscience and Remote Sensing*, 1995, 33(5): 1096~ 1102.
- 8 Foody G M. Using prior knowledge in artificial neural network classification with a minimal training set. *INT J Remote Sensing*, 1995, 16(2): 301~ 312.

谢 勇 1963 年生, 博士生. 主要从事计算机应用、图象处理、计算机视觉检测等研究工作.



王耀南 1957 年生, 现为湖南大学电气与信息工程系教授, 博士生导师. 主要研究方向为计算机视觉、智能控制理论与应用、计算机 CIMS、计算机应用等.



毛建旭 1974 年生, 现为湖南大学电气与信息工程系博士研究生. 主要研究方向为计算机视觉、计算机 CIMS、计算机应用等.