

结合小波变换和 RBF 神经网络进行光谱自动分类^{*})

姜育刚 郭 平

(北京师范大学计算机科学系 北京 100875)

摘 要 本文提出了一种基于小波变换和 RBF 神经网络的天体光谱分类方法。首先利用小波变换除去谱线中的噪声、提取特征谱线;然后使用 RBF 神经网络分类,RBF 网络的输入为提取的特征谱线。实验结果显示该方法具有良好的鲁棒性,算法效率很高,正确分类率(CCR)远远高于经常采用的主成分分析特征提取方法,因此特别适合于低信噪比的光谱数据分类。

关键词 小波变换,RBF 神经网络,光谱数据,主成分分析(PCA)

1 引言

当前广泛开展的大规模巡天观测将产生大量的天体光谱数据。对于海量的光谱数据,手工分类是不可能的,而广泛采用的模板匹配自动分类技术由于实测光谱的信噪比较低、测量误差等限制很难得到理想的识别率。针对存在的这些问题,我们提出了这种分类方法。

模式识别过程一般包括以下几个方面:预处理、特征提取和分类决策。天体光谱预处理的主要工作就是去除噪声。由于实测光谱的噪声很大,因此采用了在信号处理领域应用广泛的小波变换进行降噪,我们结合了两种小波降噪方法,取得了很好的效果;然后利用小波变换的多分辨率分析的特点提取特征谱线。由于 RBF 神经网络避免了 BP 网络冗长繁琐的计算学习,具有良好的泛化能力,最后我们选择 RBF 神经网络完成分类。

2 基本原理

2.1 小波变换及多分辨率分析

小波是小波变换的分析函数,它是在有限区间内积分为零并满足可容许条件的小波母函数 $\Psi(t)$ 通过平移和伸缩产生的函数簇:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (1)$$

其中 a 为尺度因子, b 为平移因子。

实际应用经常采用离散小波变换,即将尺度因子 a 和平移因子 b 离散化。设 $f(t)$ 是一给定信号,离散小波变换定义为:

$$\Psi_{m,n}(t) = 2^{-m/2} \Psi(2^{-m}t - n) \quad (2)$$

$$WT_f(m,n) = \int_{\mathbb{R}} f(t) \overline{\Psi_{m,n}(t)} dt \quad (3)$$

计算实现离散小波变换通常采用 Mallat 提出

的多分辨率信号分解算法^[1]。将 $\Psi_{m,n}(t)$ 离散地表示为一对 $H = \{h_l\}$ 和 $G = \{g_l\}$, ($l \in \mathbb{Z}$) 滤波器,正交小波分解的实现可以写成:

$$C^j(k) = \sum_{l \in \mathbb{Z}} h(1-2k) C^{j-1}(l) \quad (4)$$

$$D^j(k) = \sum_{l \in \mathbb{Z}} g(1-2k) C^{j-1}(l) \quad (5)$$

其中, $j=0,1,\dots,J$ 。 J 为最高分解级数。上述分解可以表示为:

$$\begin{array}{ccccccc} C^0(k) & \rightarrow & C^1(k) & \rightarrow & C^2(k) & \rightarrow & \dots \rightarrow C^J(k) \\ & & \searrow & & \searrow & & \searrow \\ & & D^1(k) & & D^2(k) & \dots & D^J(k) \end{array}$$

由于分解具有正交性,由 C^J 和 $D^1, D^2, \dots, D^J$ 可以重构得到原始信号 C^0 。其中 C^j 是 C^{j-1} 的逼近, D^{j+1} 是 C^j 的高频细节。

基于上述算法的应用称为多分辨率分析,采用该方法进行降噪主要有两种处理方法。一种是小波系数阈值处理方法,文[2]对此作了详细解释。另外,由于通常实测光谱的噪声频率较高,信号频率较低,因此可以通过对原始光谱进行一定级数的分解,分离信号和噪声,移去高频噪声,从而得到高信噪比的谱线。本文的降噪过程通过结合上述两种方法来完成。

2.2 RBF 神经网络

径向基函数 RBF(Radial - Basis Function)神经网络是一种三层前向网络,输入层由输入数据源节点组成;第二层为隐含层,隐单元的个数有所描述的问题而定,隐单元的变换函数是对中心点径向对称且衰减的非负线性函数;第三层为输出层,它对输入模式做出响应^[3]。

RBF 神经网络的结构如图 1 所示。输入层节点只是传递输入到隐层,隐层节点由如高斯核函数类型的辐射状作用函数构成,而输出层节点通常是简单的线性函数。

^{*})国家自然科学基金(60275002)和国家 863 计划(2003AA133060)资助课题。




图1 RBF网络基本结构

隐层节点中的核函数对输入信号将在局部产生响应,即当输入数据离高斯核函数的中心较近时,该隐层节点将产生较大的输出,反之输出则较小。

RBF神经网络的输出为隐层节点输出的线性组合,即:

$$h(x) = \sum_{p=1}^H \omega_p \phi(\|x - x_p\|) \quad (6)$$

其中 ω_p 是输出权重,第一个隐层节点为偏置神经元,即 $\phi_0(\|x - \mu_0\|) = 1$,可以初始化每一个径向基函数的中心值 μ ,求得式(8)的 ϕ 矩阵。权值矩阵 W 可以由式(7)求得:

$$\widetilde{W} = T\phi^+ \quad (7)$$

其中 ϕ^+ 是 ϕ 的伪逆矩阵,而是对称矩阵。

$$\phi = \begin{pmatrix} \phi_0(\|x_1 - \mu_0\|) & \cdots & \phi_0(\|x_n - \mu_0\|) \\ \vdots & \ddots & \vdots \\ \phi_H(\|x_1 - \mu_H\|) & \cdots & \phi_H(\|x_n - \mu_H\|) \end{pmatrix} \quad (8)$$

本文中选择的基函数 ϕ 为高斯型:

$$\phi_j(\|x - \mu_j\|) = \exp\left[-\frac{1}{2\gamma_j^2} \|x - \mu_j\|^2\right] \quad (9)$$

其中, ϕ_j 是第 j 个隐层节点的输出, x 是输入样本, μ_j 是高斯函数的中心值, γ_j 是标准化常数。每个基函数都可以选择不同的 μ_j 和 γ_j 。

RBF神经网络的学习过程如下:

Step 1: 根据所有的输入样本决定隐层各节点的高斯核函数的中心值 μ_j 和标准化常数 γ_j 。

Step 2: 在决定完隐层的参数后,根据样本期望输出和 ϕ 矩阵,由式(7)求出输出层的权值 W 。

在完成第二步后,还可以根据确定的参数和 W 求出网络输出,计算网络输出与理想输出的误差并利用梯度下降法调整隐层参数,以提高网络精度。

3 实验结果及讨论

实验中采用 Jacoby (1984) 公布的光谱数据^[4], 总共有 161 条恒星光谱。谱线的波长范围为 3510 到 7427 埃,分辨率大约为 1.4 埃。按照温度由高到低,七类恒星名称如下: O、B、A、F、G、K 和 M。我们采用的光谱数据中 B 类 33 条、A 类 23 条、O 类 19

条、F 类和 G 类各 29 条、K 类和 M 类各 14 条(见图 2)。




图2 典型的七类恒星光谱

首先我们对每条谱线作归一化处理。然后,采用传统的小波系数阈值处理方法对原始光谱进行降噪,阈值降噪效果如图 3(中)所示。




图3 小波阈值降噪(中)、结合方法(下)

不同尺度的小波系数代表了谱线的不同频率成分的信息,可以通过提取部分尺度的小波系数得到谱线中的有用的信息,因此小波变换的多分辨率分析方法十分适合于光谱信号的处理^[5]。我们使用 Mallat 算法对每条谱线做了 7 次小波分解,每条谱线的分解都产生了 7 个尺度的小波系数和最后一次分解的剩余系数。

采用第 7 次分解的剩余系数重构得到拟合的连续谱线^[6];由于实测光谱信噪比很低,我们舍弃了前 4 次分解的小波系数,也就是谱线中的高频成分,以达到进一步降噪的目的,采用第 5、6、7 次分解得到的小波系数重构得到特征谱线。

图 3 为结合两种降噪方法的谱线,结果证明该方法优于使用 Kalman 滤波^[7]降噪。连续谱线、特征谱线的拟合结果如图 4 所示。

由 Mallat 的算法可知,通过舍去 4 个尺度的小波系数,降噪的同时也达到了降维的目的,特征谱线

降到 181 维,大约是原始谱线维数的 1/16。

得到的特征谱线作为 RBF 神经网络的输入,网




图 4 原始谱(上)、连续谱(中)、特征谱(下)

络的目标输出向量采用 One - of - K 方法^[3],即: A 类, $T = (0, 0, 0, 0, 0, 0, 1)$; G 类, $T = (0, 0, 0, 0, 0, 1, 0)$; F 类, $T = (0, 0, 0, 0, 1, 0, 0)$; B 类, $T = (0, 0, 0, 1, 0, 0, 0)$; O 类, $T = (0, 0, 1, 0, 0, 0, 0)$; K 类, $T = (0, 1, 0, 0, 0, 0, 0)$; M 类, $T = (1, 0, 0, 0, 0, 0, 0)$ 。表 1 给出了隐层节点为 30 个神经元(包括一个偏置神经元)时网络的输出举例。实验中随机选择 87 条谱线作为训练样本(A、G、F、B 各 15 条, O、K、M 各 9 条),其余作为测试样本。

表 1 RBF 网络的部分输出

类别	输出向量
A	(0.01, 0.01, 0.04, 0.18, 0.01, 0.02, 0.80)
G	(0.04, -0.04, -0.00, 0.05, 0.08, 0.84, 0.01)
B	(0.01, 0.01, -0.16, 1.10, -0.01, 0.01, 0.03)
K	(0.06, 0.84, -0.01, 0.08, -0.01, -0.01, 0.02)

在实验中我们发现, RBF 网络的结构对分类结果影响很大,通过选择合适的隐层节点数可以得到较高的 CCR。表 2 给出了不同网络隐层节点数时的 CCR 对比。

表 2 不同隐层节点的 RBF 网络 CCR 比较

节点数	10	20	30	60
CCR	73.0%	90.5%	93.2%	91.9%

主成分分析(PCA)^[8]作为一种常用的特征提取方法在很多领域得到广泛的应用,表 3 给出当 RBF 网络的输入为 PCA 降维方法提取的特征向量时的 CCR,结果表明本文提出的特征提取方法比 PCA 特征提取得到的 CCR 要高得多。

表 3 不同特征提取方法 CCR 比较 (30 个 RBF 隐层节点)

	小波变换	PCA (降至 181 维)
CCR	93.2%	75.7%

结束语 从上述讨论可知,通过结合小波变换和 RBF 神经网络,可以达到较为理想的正确分类率,实验表明该方法比 PCA 特征提取结合 RBF 神经网络分类的识别率提高很多,而且该算法具有很好的鲁棒性、降噪能力很强。因此,这种方法非常适合大规模巡天观测得到的信噪比较低的天体光谱自动识别,具有较高的应用价值。

参考文献

- 1 Mallat S. A theory of multiresolution signal decomposition: The wavelet transform. IEEE Trans., 1989, PAMI - 11 (7): 674 ~ 693
- 2 Donoho D L. De - noising by soft - thresholding. IEEE Transaction on Information Theory, 1995, 41: 613 ~ 607
- 3 Bishop C M. Neural Networks for Pattern Recognition. Oxford: Oxford University Press, 1995
- 4 Jacoby G H, Hunter D A, Christian C A. A library of stellar spectra. Astrophysical Journal Supplement, 1985, 59: 33
- 5 Starck J L, Murtagh F, Bijaoui A. Multiresolution and Astronomical Image Processing. Astronomical Data Analysis Software and Systems IV, ASP Conference Series, 1995, 77: 279 ~ 288
- 6 Starck J L, Siebenmorgen R, Gredel R. Spectral analysis by the wavelet transform. Astrophysical Journal, 1997, 482: 1011 ~ 1020
- 7 Wu W, Rutan S C, Baldwin A. Feature Selection using the Kalman Filter for Classification of Multivariate Data. Anal. Chem. Acta, 1996, 335: 11 ~ 22
- 8 Jolliffe I T. Principal Component Analysis. New York: Springer - Verlag, 1986