

文章编号 1004 924X(2002)04 0346 08

光度信号的频域模式识别方法研究

周建华, 白 钊

(中国人民解放军 61369 部队, 吉林 长春 130022)

摘要: 通常目标的光度信号信噪比小, 测量误差大, 难以目标识别。本文采用数字信号处理和模式识别相结合的方法对目标光度信号进行识别。先将经过预处理的光度信号通过一种类似于 Gabor 变换的改进的离散傅里叶变换(DFT)转换到频域, 再滤波、划分频带; 然后将选出的小频带内能量作为特征向量, 在频域引入 Fisher 判别, 用已知类别数据得出判别函数矩阵, 建立判别规则; 最后将未知类别的数据代入判别函数矩阵, 通过判别规则完成识别。成功地对三颗卫星的光度信号进行了判别, 克服了其光度信号信噪比小、测量误差大、噪声模型难以建立的困难。

关键词: 亮度特征; 目标识别; 频域; Fisher 判别

中图分类号: TP391.41 文献标识码: A

1 引言

通过光度信号进行目标识别, 在国防和经济建设中都具有重要的意义。目前这方面的研究正在取得进展, 时域分析、频域分析以及小波变换都各有所长。在频域进行模式识别, 可以增强抗噪声性能, 对光度信号持续时间、稳定性要求降低, 识别效果提高。

在对卫星光度信号的目标识别中, 采取频域分析加模式识别的方法取得了良好的效果。

2 光度信号识别的方法

光度信号较其它信号(例如电信号、声音信号)有其自身的特点, 信号强度小、干扰大(主要是大气湍流、透过率等)、测量时严重的非线性, 而对于卫星等目标的光度信号, 还存在观测时间受限的问题。这些都对目标识别非常不利。

2.1 时域分析法

这种方法是通过理论计算仿真出信号源的光度变化曲线^[1], 再通过某种算法与实际记录的光度进行比对, 找出最匹配的类别作为判决结果。适合于目标是主动光源, 光度测量相当准确, 所受

干扰较小的场合。很明显它不适合于远距离、外形不规则的目标反射的自然光线进行识别。

2.2 频域分析法

在频域进行分析, 对于卫星类的光度信号, 分析受到很大的限制, 用数字信号处理方法困难较大。主要有两种原因: 一是噪声强, 信噪比小, 且噪声的频谱极不规则, 难用高斯白噪声或其它模型等效; 二是观测时间(信号持续时间)太短, 信号点数 N 太小, 造成频率分辨率(即频域采样间隔, 为 $\frac{1}{N}$) 不够高, 漏掉很多可能含有重要信息的频率分量。图 1 为一颗卫星的光度信号频谱图。




图 1 某颗卫星光度信号的频谱图

Fig. 1 Spectrum from a satellite's signal of its luminosity.

收稿日期: 2002-01-16; 修订日期: 2002-06-20

基金项目: 国家“863”项目(863_808_2_2)

2.3 小波变换法

用小波变换分析信号, 近来相当热门, 相关研究和报道很多。小波变换克服了基于 Fourier 变换的频域分析的一些不足之处, 其中对光度信号识别特别有利的是: 1) 小波分析能进行理想的时-频域分析, 而基于 Fourier 变换的频域分析无法做到这一点; 2) 小波分析适合处理急剧变化的不稳定信号, 而基于 Fourier 变换的频域分析仅适合相当平稳的周期信号。如引入小波包的概念, 能够改善小波对时频局部化的性能, 使得时频窗大小、频率和空间位置能各自独立地变化^[8]。但尚无小波分析法用于识别光度数据的报道, 即使采用小波变换也很难找到适合此类信号的波函数。

2.4 聚类分析法

将没有标出类别的模式样本集, 按照样本之间的相似程度, 相似的归为一类, 不相似的归为一类, 这种分类称为聚类分析。聚类分析按照不同对象之间的差异, 根据距离远近的程度作为模式分类的依据^[2]。经典的聚类方法有三种: 距离判别、Bayes 判别、Fisher 判别。其中 Fisher 判别对多元判别效果较好, 它广泛应用于生物、医学、化工、语音识别等领域。但尚未见 Fisher 判别应用于信号识别, 特别是光度信号识别的报道。

Fisher 判别的方法是通过已知类别的样本, 产生所需的线性判别函数矩阵, 该函数矩阵将样本映射到最有利于判别(聚类)的 m 维空间(通常 m 较小), 使同类样本聚到一起, 不同类分开。对于未知目标, 即新样本, 将其代入判别函数矩阵, 通过判断其在 m 维空间的位置, 就可知其类别, 完成识别。

2.5 频域模式识别

光度信号的频域模式识别的基本方法是: 先将原始数据进行预处理, 再进行“归一化”。然后, 根据信号长度选用不同长度的 DFT(加窗), 尽量减小截断效应和栅栏效应。最后划分频带、滤波, 将有用的特征频带内的功率谱(能量)作为特征向量, 按照主分量分析法, 取出对识别贡献大、相关性小的少数几个分量, 作为样本代入 Fisher 判别中进行计算。先用已知类别的样本数据产生判别函数矩阵, 通过判别函数矩阵将已知类别数据映射到判别空间, 找出各类的平均位置。对于新数据, 先将其映射到判别空间的某点上, 再计算该点与各类别平均位置之间的欧氏距离(或其平方),

通过一定的判别规则将其判入某类别, 或者无法判入任何已知的类别(称为判别不成功)。

3 频域模式识别方法的算法实现

3.1 理论分析

设序列 $x(n)$ 满足绝对可和条件, 即 $\sum_{n=-\infty}^{\infty} |x(n)| < \infty$,

则可以定义:

$$x(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n}, \quad (1)$$

为序列 $x(n)$ 的 Fourier 变换(以下称 F 变换)。于是 DFT 定义为:

$$X(k) = DFT[x(n)] = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi}{N}kn}, \quad k = 0, 1, \dots, N-1, \quad (2)$$

如果直接做原始光度信号数据 N 点的 DFT, 得到的频域结果杂乱无章, 除了对称性(由采样定理, 频谱关于对称 $\frac{f_s}{2}$, f_s 是采样频率)外, 似乎无任何规律(如图 1)。这就需要对此进行深入分析。

利用 DFT 对信号进行谱分析, 是先对连续信号 $x_a(t)$ 进行时域采样(在本问题中就是光度计 15Hz 的记录), 得到数据序列 $x(n) = x_a(nT)$ 。再对 $x(n)$ 进行 DFT, 得到的 $X(k)$ 则是 $x(n)$ 的 F 变换 $x(e^{j\omega})$ 在频率区间 $[0, 2\pi]$ 上的 N 点等间隔采样。这里 $x(n)$ 、 $X(k)$ 都是有限长序列。由 F 变换理论可知, 信号持续时间有限, 则其频谱无限宽, 若频谱有限宽, 则持续时间无限长。在工程上, 忽略很小的高频分量, 仍认为时间有限信号是个带限信号。

设连续信号 $x_a(t)$ 的持续时间 T_p 为(这里为卫星一圈的观测时间), 最高频率为 f_c 。 $x_a(t)$ 的 F 变换为:

$$x_a(jf) = FT[x_a(t)] = \int_{-\infty}^{\infty} x_a(t)e^{-j2\pi ft} dt, \quad (3)$$

对 $x_a(t)$ 以采样间隔 $T \leq \frac{1}{2f_c}$ (即 $f_s = \frac{1}{T} \geq 2f_c$) 采样得 $\overset{\leftarrow}{X}_a(t) = x_a(nT)$, 设共采样 N 点, 并对 $x_a(jf)$ 做零阶近似($t = nT, dt = T$), 得:

$$\overset{\leftarrow}{X}_a(jf) = T \sum_{n=0}^{N-1} x_a(nT)e^{-j2\pi fnT}, \quad (4)$$

$\overleftarrow{X}_a(jf)$ 是 f 的连续周期函数。对 $\overleftarrow{X}_a(jf)$ 在区间 $[0, f_s]$ (这里是 0~15Hz) 等间隔采样 N 点, 采样间隔为 F (即频率分辨率)。得到参数 f_s, T_p, N 和 F 满足如下关系式:

$$F = \frac{f_s}{N} = \frac{1}{NT}, \quad (5)$$

因为 $NT = T_p$, 所以 $F = \frac{1}{T_p}$ 。可见频率分辨率就是观测时间的倒数, 为了提高频率分辨率, 需要更长的观测时间。

除了信号本身的原因外, DFT 也会引入误差, 误差来自频率混叠、栅栏效应和截断效应。一般来讲采样频率都是能满足奈奎斯特采样定律的, 不会有明显的频率混叠现象。

N 点 DFT 是在频率区间 $[0, 2\pi]$ 上对信号的频谱进行 N 点等间隔采样。而采样点之间的频谱函数值是不知道的。这就好像从 $(N+1)$ 个栅栏的缝隙中观看信号频谱情况, 仅得到 N 个缝隙中的频谱函数值, 很可能漏掉了重要的频谱分量, 这就是所谓的栅栏效应。卫星光度数据的栅栏效应非常明显, 由于观测时间太短, 频率分辨率太低, 即两点间漏掉的频谱很宽。

由于实际的序列 $x(n)$ 是无限长, 所分析的只是用矩形窗截取的有限长序列: $y(n) = x(n) \cdot R_N(n)$, 其中 $R_N(n)$ 是宽度为 N 的矩形窗。

由卷积定理, 可得到:

$$\begin{aligned} Y(e^{j\omega}) &= FT[y(n)] = \frac{1}{2\pi} X(e^{j\omega}) \times R_N(e^{j\omega}) \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} X(e^{j\omega}) R_N(e^{j(\omega-\theta)}) d\theta, \end{aligned} \quad (6)$$

其中,

$$x(e^{j\omega}) = FT[x(n)],$$

$$R_N(e^{j\omega}) = FT[R_N(n)] = e^{j\omega \frac{N-1}{2}} \frac{\sin(\frac{\omega N}{2})}{\sin(\frac{\omega}{2})}, \quad (7)$$

$R_N(\omega) \sim \omega$ 关系如图 2, 可见截断效应表现在两个方面: 频率泄漏和谱间干扰。频率泄漏是因为截断后(频谱与钟形函数卷积)造成频谱向附近展宽, 使频谱模糊, 谱分辨率降低。谱间干扰是由于在主谱线两边形成很多旁瓣, 引起的不同频率分量之间的干扰^[3]。易知 N 点数据做 N 点 DFT 不会有截断效应, 但在序列末尾添 0 后则会发生。

为减小栅栏效应, 在已经得到序列的情况下, 采取在序列末尾添 0 的方法, 改变序列长度 N (即改变 DFT 变换区间长度), 从而增加频域采样点数和采样点位置, 使原来漏掉的频谱分量被检测出来(丢失的低频分量无法恢复)。但添 0 会带来截断效应, 再一次引入干扰, 本质上这是时频局部化之间的矛盾。可采用以下方法: 每个数据序列, 补 0 使 N 达到最近的一个 1200 的整数倍。这是因为: 1200 点以下的数据实在太短, 基本无法分析; 对一般数千点的数列, 补 1200 点产生的截断效应不会导致太大偏差; 这样补 0 后, 虽然长短序列“栅栏缝隙”个数不同, 但位置一致, 凡是短序列取到的频谱分量, 长序列也取到了, 最大限度减小误差和不确定因素, 提高了比较和统计的精度。这和加窗 F 变换(Gabor 变换)的思想不谋而合。当然, 1200 仅仅是在这一个问题中得出的经验值, 应根据不同情况, 取不同的值。




图 2 $R_N(\omega)$ 与 ω 之间关系曲线

Fig. 2 $R_N(\omega)$ versus ω .

用上述方法将光度信号转换到频域后, 进行频带划分, 以频带的能量为特征进行识别, 但从中不一定能直接发现类别内的共同点和类别间的区别, 这就要运用 Fisher 判别。得到了 k 各总体 S_1, S_2, \dots, S_k , 每个总体含有 n_1, n_2, \dots, n_k 个样本, $n_1 + n_2 + \dots + n_k = n$ (这里是 n 个频域特征向量), 相应的平均向量和协方差矩阵分别为 $u_t, v_t, t = 1, 2, \dots, k$ 。任给一个样本 x (待判别目标的特征向量), 要判断 x 应属于哪个总体(是哪颗星), 需要找到 x 的线性判别函数

$$y = \alpha^T x, \quad (8)$$

选择 α 的原则是使 $\alpha^T u_1, \alpha^T u_2, \dots, \alpha^T u_k$ 之间的离差平方和:

$$Q = \sum_{i=1}^k (\alpha^T u_i - \frac{1}{k} \sum_{i=1}^k \alpha^T u_i)^2, \quad (9)$$

尽量大。由于 α 长度的改变相当于乘以常数, 不影响判别, 可以令:

$$\alpha^T E \alpha = 1, \quad (10)$$

其中 $E = \sum_{i=1}^k n_i u_i u_i^T$, 在此约束条件下求 (9) 式的最大值。

设 $M = [u_1, u_2, \dots, u_k]$, 有: $\frac{1}{k} \sum_{i=1}^k \alpha^T u_i = \frac{1}{k} \alpha^T M I$, 这样, (9) 式可写成:

$$Q = \alpha^T M (I - \frac{1}{k} \Gamma \Gamma^T) M^T \alpha, \quad (11)$$

其中 I 是 k 阶单位阵, Γ 是 k 维 1 向量。令 $B = M (I - \frac{1}{k} \Gamma \Gamma^T) M^T$,

则

$$Q = \alpha^T B \alpha. \quad (12)$$

而 B 恰恰就是以 M 为原始数据的离差平方和矩阵, 所以

$$B = \sum_{i=1}^k n_i (u_i - \bar{u})(u_i - \bar{u})^T, \quad (13)$$

其中 $\bar{u} = \frac{1}{n} \sum_{i=1}^k n_i u_i$,

要在 (10) 式下求 (12) 式的最大值, 由拉格朗日待定系数法, 令:

$$L = \alpha^T B \alpha - \lambda (\alpha^T E \alpha - 1), \quad (14)$$

则 α 应满足 $\frac{\partial L}{\partial \alpha} = 0$, 而

$$\frac{\partial L}{\partial \alpha} = 2B\alpha - 2\lambda E\alpha, \quad (15)$$

有

$$B\alpha = \lambda E\alpha, \quad (16)$$

由线性代数知识, λ 是 B 相对于 E (即 $E^{-1}B$) 的特征根, α 是 λ 相应的特征向量^[5-6]。由于 (16) 式有 p 个特征根和特征向量, 按主分量分析思想, 应当取最大的 λ_i 及相应的 α_i 构成判别函数 $y = \alpha_i^T x$ 。为了加强判别效果, 采用 (16) 式前 m 个特征向量 $\lambda_1, \lambda_2, \dots, \lambda_m$ 对应的特征向量 $\alpha_1, \alpha_2, \dots, \alpha_m$ 构成 m 个判别函数:

$$\begin{cases} y_1 = \alpha_1^T x \\ \dots \\ y_i = \alpha_i^T x \\ \dots \\ y_m = \alpha_m^T x \quad (i = 1, 2, \dots, m), \end{cases} \quad (17)$$

这些特征函数构成了一个 m 维空间。如果将 S_1, S_2, \dots, S_k 中的各个样本代入判别函数, 则以各个样本的 $Y = (y_1, y_2, \dots, y_m)$ 作为点坐标, 应在 m 维空间上按类别聚集成 k 团, 同一类的聚集在一块, 不同类的分开。有了判别函数, 还要建立判别规则。这里采用欧氏距离平方加松弛变量的方法。将 (y_1, y_2, \dots, y_m) 看作 m 维空间的点, 将各总体的 u_i 作为 x 代入判别函数, 得到各总体在 m 维空间的平均位置。对新目标的特征 x_p , 代入判别函数, 得到它在 m 维空间的点坐标, 再求出它与各个总体平均位置之间的欧氏距离的平方, 与哪一类最近, 就最有可能划入哪一类。再与松弛变量 ϵ 相比较, 如大于 ϵ , 则认为哪类都不是, 无法归入上述三颗星中的任何一颗; 如小于 ϵ , 则判为是这一颗星^[7]。这样, 针对不同情况, 通过调节 ϵ , 就可在判别的成功率和判别的准确度之间做出选择。至此, 完成了整个判别过程。

3.2 具体算法

以下是采用频域模式识别方法对实际工作中收集的 $A、B、C$ 三个目标 (卫星) 数据进行一次判别全过程。

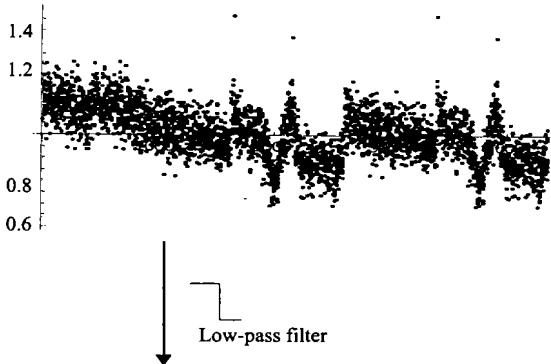
1) 数据情况: A 有 10 圈, 长度分别为: 9152、6122、19542、22830、21454、26614、20312、24790、8658、8264 点; B 有 8 圈, 长度分别为: 5762、3078、2600、5104、2566、3760、3042、3014 点; C 有 12 圈, 长度分别为: 4856、4496、3958、6966、5334、4542、4158、2344、5298、5488、7486、2124 点。数据采集是在晴朗无月的夜晚, 光度计以 15Hz 的频率对目标亮度进行采样, 然后将数据记入一个文件中, 单位是光子数, 也能转化为星等。

运用 Mathematica 软件编程, 从文件中提取所需数据, 进行数据预处理, 包括去除明显不合理的数据点 (特别是开头、结尾处), 对丢失的数据点酌情采用插值补点或截断的方法处理, 再进行“归一化”。由于不同时期采样的数据, 光度值 (光子数) 受天气等影响较大, 故将每点数据同时除以整个数列的平均值。这样在很大程度上能减弱天气的影响。注意到这种“归一化”后各点的数据很可能大于 1, 虽与传统的归一化 (除以数列各点总和) 在理论上效果相同, 但在以后的计算中能有效的减小舍入误差。这样就得到了原始数据序列 $x(n)$ 。


2) 给 $x(n)$ 加窗 (添 0), 使其达到最近的

1200 点的整数倍。Mathematica 软件提供了函数 Fourier[], 方便地对加窗后的数列进行 DFT, 将其转换到频域。

3) 光度计采样频率 $f_s = 15\text{Hz}$, 而目标光度截止频率远小于 $\frac{f_s}{2}$, 不会发生频率混叠现象。变换后频谱宽度是 15Hz ($0 \sim 15\text{Hz}$), 又由采样定律, 频谱是关于 $\frac{f_s}{2}$ 对称的, 只分析前 $\frac{f_s}{2}$ 的频谱, 即前 7.5Hz 的。将这 7.5Hz 的信号分成三个频段(低中高), 共计 24 个频带: 低频段 ($0 \sim 0.2625\text{Hz}$), 含 7 个频带, 每个宽 0.0375Hz ($15 \times \frac{3}{1200}\text{Hz}$), 中频段 ($0.2625 \sim 0.875\text{Hz}$), 含 7 个频带, 每个 0.0875Hz ($15 \times \frac{7}{1200}\text{Hz}$), 高频段 ($0.875 \sim 7.5\text{Hz}$), 10 个频带, 每个 0.6625Hz ($15 \times \frac{53}{1200}\text{Hz}$)。



(a) 原始数据
(a) Origin data



(b) 滤除高频分量之后
(b) Without high-frequency bands
图 3 滤去高频分量前后对照图

Fig. 3 Origin data passed through a low-pass filter.

由于目标光度变化频率主要集中在低、中频段(最明显的周期在分钟级), 而高频段主要是大气抖动(包括所谓的“星星眨眼睛”)和仪器误差带来的, 即使含有目标本身的信息, 也被这些噪音所淹没。为了提取目标特征效果更好, 将高于 2.8625Hz 以上的(最高的 5 个频带)的高频分量滤去。图 3 是某次观测数据滤去高频分量前后时域图的对照, 可见基本特征不但保留下来了, 而且更加明显。然后求出剩下 17 个频带内功率谱占总功率谱的百分比, 这样, 便得到了一个 17 维的特征向量, 它包含了目标的频谱特征。

4) 对于这样的频谱特征, 由于维数较多, 不能直接去做模式识别, 这里取出其中对判别贡献大、相关性较小的 8 个主分量^[4], 分别是第 1、3、5、7、9、13、15、17 频带。这 k 个 p 维类别 S_1, S_2, \dots, S_k , (三颗星、八维特征向量, $k = 3, p = 8$), 计算出均值向量 u_1, u_2, \dots, u_k , 协方差矩阵: V_1, V_2, \dots, V_k (均为非奇异矩阵, 要求 $\text{Min}(n_1, n_2, \dots, n_k) > p$), 求出:

$$\bar{u} = \frac{1}{n} \sum_{i=1}^k n_i u_i, \quad (18)$$

此为加权平均,

$$B = \sum_{i=1}^k n_i (u_i - \bar{u})(u_i - \bar{u})^T, \quad (19)$$

$$E = \sum_{i=1}^k n_i V_i. \quad (20)$$

得出矩阵 B 和 E 后, 可进一步求得矩阵 $E^{-1}B$, 取其前 m 个特征值(一般取值比较大的, 这里 $m = 2$), 它们对应 m 个特征向量 $\alpha_1, \alpha_2, \dots, \alpha_m$, 组成线性变换矩阵 $A = [\alpha_1, \alpha_2, \dots, \alpha_m]$, 而函数 $Y = X \cdot A$ (其中 $X = (x_1, x_2, \dots, x_p)$) 便是所需的判别函数^[5-6]。用已知样本的均值向量代入判别函数, 得出 Y_1, Y_2, \dots, Y_k , 对于未知目标, 代入判别函数, 得出 $Y?$, 再求出 $Y?$ 与 Y_1 至 Y_k 各类间的欧氏距离的平方, 与谁最接近, 就划入哪一类。最后, 引入松弛变量 ϵ ^[7], 令 $Y?$ 与最接近的一类的欧氏距离的平方小于 ϵ 时, 划入此类, 大于 ϵ 作为无法判断。这样, 通过调节 ϵ , 就可以使判别结果在可判别率和准确率之间调节。

3.3 软件编程及计算结果

使用 Mathematica 软件编程计算。统计出 8 个小频带功率谱百分比, 作为 8 个特征, 代入 Fisher 判别中计算, 得:

$$B = \begin{pmatrix} 0.023165 & 0.00032088 & 0.00080801 & 0.000268732 & -0.000362883 & -0.00122926 & -0.00850663 & -0.0120062 \\ 0.0032088 & 0.000460204 & 0.000132225 & 0.0000627249 & 0.0000237895 & -0.000156234 & -0.00120967 & -0.00189184 \\ 0.00080801 & 0.000132225 & 0.0000543935 & 0.0000422964 & 0.0000829539 & -0.000024748 & -0.000337172 & -0.000714119 \\ 0.000268732 & 0.0000627249 & 0.0000422964 & 0.0000444731 & 0.000115891 & 8.51256 \times 10^{-6} & -0.000149601 & -0.000510264 \\ -0.000362883 & 0.0000237895 & 0.0000829539 & 0.000115891 & 0.000354471 & 0.0000853915 & -0.0000143219 & -0.000889297 \\ -0.00122926 & -0.000156234 & -0.000024748 & 8.51256 \times 10^{-6} & 0.0000853915 & 0.0000777713 & 0.000423424 & 0.000432826 \\ -0.00850663 & -0.00120967 & -0.000337172 & -0.000149501 & -0.0000143219 & 0.000423424 & 0.00318624 & 0.00486476 \\ -0.0120062 & -0.00189184 & -0.000714119 & -0.000510264 & 0.000889297 & 0.000432826 & 0.00486476 & 0.0095506 \end{pmatrix}$$

$$E = \begin{pmatrix} 0.0379058 & 0.00173038 & 0.000980542 & -0.000917567 & -0.00213871 & -0.00161303 & -0.0108878 & -0.0111408 \\ 0.00173038 & 0.00111468 & 0.00034589 & 0.000188322 & 0.0000663005 & -0.000116913 & -0.00127042 & -0.00228789 \\ 0.000980542 & 0.000347589 & 0.000290826 & 0.000135862 & 0.00010212 & -0.0000462077 & -0.000558105 & -0.00154326 \\ -0.000917567 & 0.000188322 & 0.000135862 & 0.000210096 & 0.000273691 & 0.0000734884 & 0.000132487 & -0.00109496 \\ -0.00213871 & 0.0000663005 & 0.00010212 & 0.000273691 & 0.000745872 & 0.000169317 & 0.000698443 & -0.00202603 \\ -0.00161303 & -0.000116913 & -0.0000462077 & 0.0000734884 & 0.000169317 & 0.000233442 & 0.000655175 & -0.000251485 \\ -0.0108878 & -0.00127042 & -0.000558105 & 0.000132487 & 0.000698443 & 0.000655175 & 0.0051163 & 0.0017698 \\ -0.0111408 & -0.00228789 & -0.00154326 & -0.00109496 & -0.00202603 & -0.000251485 & 0.0017698 & 0.0212106 \end{pmatrix}$$

注意到它们都是对角阵。计算得,

$$E^{-1}B = \begin{pmatrix} -0.541552 & -0.0450956 & 0.019389 & 0.0422403 & 0.149299 & 0.0554572 & 0.139244 & -0.154596 \\ -0.385277 & -0.0234707 & 0.0251612 & 0.0440172 & 0.146846 & 0.0471446 & 0.0819006 & -0.235269 \\ -9.878 & -1.26833 & -0.215491 & 0.0475237 & 0.625542 & 0.613451 & 3.42818 & 3.66538 \\ 5.35525 & 0.751384 & 0.199162 & 0.0776602 & -0.0387748 & -0.275624 & -1.98564 & -2.91493 \\ -3.10445 & -0.2207639 & 0.178832 & 0.324644 & 1.09602 & 0.363339 & 0.696836 & -1.62631 \\ -5.0327 & -0.561044 & 0.0001472 & 0.162308 & 0.719749 & 0.388588 & 1.57692 & 0.628665 \\ -2.54746 & -0.338016 & -0.0696763 & -0.00545898 & 0.109876 & 0.148449 & 0.90587 & 1.10419 \\ -1.47796 & -0.167186 & -0.00308615 & 0.0437343 & 0.199953 & 0.111952 & 0.467925 & 0.219883 \end{pmatrix}$$

$\lambda = \{1.15567, 0.751837, 0, 0, 0, 0, 0, 0\}$ 后六个特征值为零是因为它们太小, 不到 10^{-14} , 可认为是

由计算误差引入的。取前两个特征值对应的特征向量 ($m=2$),

$$\alpha = \begin{pmatrix} -0.0263953 & -0.0130831 & -0.776266 & 0.46302 & -0.117667 & -0.339182 & -0.207417 & -0.101211 \\ 0.0980056 & 0.0954789 & 0.454464 & -0.0556588 & 0.713957 & 0.486203 & 0.0845348 & 0.135525 \end{pmatrix}$$

有判别函数: $Y = (y_1, y_2)$, 其中:

$$y_1 = -0.0263953x_1 - 0.0130831x_2 - 0.776266x_3 + 0.46302x_4 - 0.117667x_5 - 0.339182x_6 - 0.207417x_7 - 0.101211x_8,$$

$0.0507019\}$

$$u_3 = \{0.0468649, 0.0117633, 0.00889298, 0.00833883, 0.0170634, 0.0149119, 0.0961009, 0.0938122\}$$

$$y_2 = -0.0980056x_1 + 0.0954789x_2 + 0.454464x_3 - 0.556588x_4 + 0.713957x_5 + 0.486203x_6 + 0.0845348x_7 + 0.135535x_8,$$

代入, 得 A 的平均位置为: $\{-0.0351972, 0.0476951\}$, B 的平均位置为: $\{0.0353734, 0.051989\}$, C 的平均位置为: $\{-0.0409266, 0.049565\}$ 。对于一个新目标(数据长度 8400 点)

将三颗星的特征均值向量:

$$u_1 = \{0.108916, 0.0198536, 0.0104054, 0.0082397, 0.013713, 0.0111681, 0.0743209, 0.0689984\}$$

$$u_2 = \{0.0929697, 0.0194705, 0.0122063, 0.0110157, 0.0225617, 0.0136448, 0.0765383,$$

$$0.00913879, 0.0143979, 0.0128534, 0.0766209, 0.0603182\}$$
 代入判别函数, 得到其位置 $Y_2 = \{-0.0353381, 0.0472497\}$, 与各颗星 (A, B, C) 的欧氏距离的平方分别为: 2.18217×10^{-7} , $0.000224626, 0.0000365924$, 很明显它最接近于


A , 取 $\varepsilon = 2.4 \times 10^{-5}$, 则它应当被判入 A , 判别成功。事实上, 它确实是 A 的一圈数据, 判别正确。

4 实验结果及结论

上述计算结果证明, 同已有的方法相比, 频域模式识别方法无论在抗干扰性、判别能力、判别准确度方面都有很大提高。

当 $\varepsilon = 2.4 \times 10^{-5}$ 时, 结果为: 10 圈 A 数据, 全部判别成功且正确, 正确率 100%; 8 圈 B 数据, 有 2 圈无法判别, 1 圈误判, 正确率为: 62.5%; 12 圈 C 数据, 2 圈误判, 正确率为: 83.3%; 总共 30 圈数据, 正确率为: 83.3%。随着数据的积累, 判别效果会越来越好。

以上模式识别的过程也可理解成是把 p 维特征向量通过判别函数矩阵映射到最有利于聚类的 m 维空间的过程, 这里的 m 恰好为 2, 于是就可以直观地画出这 30 圈数据在一个平面上的聚类情况(图 4)。



五角星- 目标 C Star- Obj. C,

方块- 目标 B Box- Obj. B,

菱形- 目标 A Diamond- Obj. A

图 4 三个目标映射到二维空间的聚类图

Fig. 4 Objects were mapped into a 2-D space

其中, 菱形表示的 10 个点是 A 映射的结果, 方块表示的 8 个点是 B , 左边五角星表示的 12 个

点是 C 。可以看出, 这三个目标已经较好地分开了, A 聚类效果最好, 而 B 最差, 这和已有数据的情况是相符的。

5 频域模式识别方法的优势及改进

该方法来自于实践, 可行性较强。它不需要预先从理论上得到一个光度变化函数, 而是从已有数据中, 在频域上用模式识别的方法找到特征, 进行判别。

整个模型对天气变化、大气抖动、消光、仪器误差等有较好的抵抗能力。

相对于以前的方法, 所需的观测时间大大减少, 提高了实际工作中的可行性。

由于引入了松弛变量的概念, 判别结果可以按人的不同需要在能否判别和准确判别之间调节。

随着观测数据的积累, 模型判别正确率会逐渐提高。模式识别的方法具有“自学习”性, 即使目标特征发生变化, 通过引入新数据, 逐步修改判别函数和总体平均位置, 模型也能自适应。

但是, 这种方法只能从信号频域特征的角度做聚类分析, 无法直接得出目标外形、尺寸等物理特征。

在实际判别工作中, 影响判别最重要的因素是两点: 观测时间和光度信号本身受到的噪声、干扰。后者是频域模式识别方法改进的主要方向, 因此今后深入研究的是对背景光和大气干扰的处理。

其次是频率特征的选择。模式识别中特征的选取非常重要^[4], 限于篇幅, 这里没有就此详细讨论。实际上正确选择特征, 不但大大节省计算量, 还能提高判别正确率。

参考文献:

- [1] 佚名. 亮度特征目标识别[D]. 成都: 中科院成都光电研究所, 1995.
- [2] 沈继红, 施久玉, 高振滨, 等. 数学建模[M]. 哈尔滨: 哈尔滨工程大学出版社, 1998.
- [3] 一玉美, 高西全, 彭学愚. 数字信号处理[M]. 西安: 西安电子科技大学出版社, 1994.
- [4] 蔡元龙. 模式识别[M]. 西安: 西北电讯工程学院出版社, 1986.
- [5] 唐守正. 多元统计分析方法[M]. 北京: 中国林业出版社, 1986.

- [6] 孙文爽, 陈兰祥. 多元统计分析[M]. 北京: 高等教育出版社, 1994.
- [7] 白钊, 曾祥华, 李明星. DNA 序列的分类[D]. 郑州: 信息工程大学, 2000.
- [8] 李建平, 唐远炎. 小波分析方法的应用[M]. 重庆: 重庆大学出版社, 1999.

Modal identification of luminosity signals in frequency domain

ZHOU Jian_hua, BAI Zhao

(Unit 61369 of CPL Army, Changchun 130022, China)

Abstract: Object luminosity signals were identified by means of digital signal processing(DSP) and modal identification. Modified luminosity signal was transferred to frequency domain by special discrete fourier transfer(DFT) which is like gabor transfer. Then, signal was filtered and partitioned into fine frequency bands. After that, Fisher's discriminance was used in frequency domain with characters, which were energies of a group of selected fine frequency bands. The identification function matrix(IFM) was obtained through recognized data and identification rulers were given. After unidentified data had been put into the IFM, they were categorized under the rulers. Three satellites' luminosity signals were identified successfully and difficulties like low SNR, abnormal errors from measurement, complex model of noise were overcome.

Key words: luminosity character; object identification; frequency domain; Fisher's discriminance

作者简介:周建华(1966—),男,江苏人,工程师,现从事空间目标监测管理和识别研究;

白钊(1978—),男,重庆人,2001年毕业于解放军信息工程大学,学士,现从事频率合成和信号分析研究。