

一种基于复杂网络的脑功能磁共振图像分类方法

申请号：[201110392269.5](#)

申请日：2011-12-01

申请(专利权)人 [中国科学院自动化研究所](#)
地址 100190 北京市海淀区中关村东路95号
发明(设计)人 [田捷](#) [白丽君](#) [刘振宇](#)
主分类号 [G06K9/66\(2006.01\)I](#)
分类号 [G06K9/66\(2006.01\)I](#)
公开(公告)号 102509123A
公开(公告)日 2012-06-20
专利代理机构 [中科专利商标代理有限责任公司](#) 11021
代理人 [周国城](#)



(12) 发明专利

(10) 授权公告号 CN 102509123 B

(45) 授权公告日 2013. 03. 20

(21) 申请号 201110392269. 5

US 2006/0013475 A1, 2006. 01. 19, 全文.

(22) 申请日 2011. 12. 01

审查员 王晓敏

(73) 专利权人 中国科学院自动化研究所
地址 100190 北京市海淀区中关村东路 95 号

(72) 发明人 田捷 白丽君 刘振宇

(74) 专利代理机构 中科专利商标代理有限责任
公司 11021
代理人 周国城

(51) Int. Cl.
G06K 9/66 (2006. 01)

(56) 对比文件
CN 1632830 A, 2005. 06. 29, 全文.
CN 101226589 A, 2008. 07. 23, 全文.

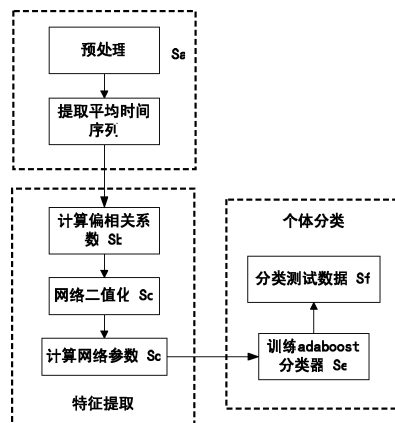
权利要求书 2 页 说明书 6 页 附图 1 页

(54) 发明名称

一种基于复杂网络的脑功能磁共振图像分类方法

(57) 摘要

本发明是一种基于复杂网络的脑功能磁共振图像分类方法,该方法包括以下步骤:对训练样本图像和测试样本图像进行预处理,并进行区域分割,提取每个区域的平均时间序列;计算该平均时间序列间的偏相关系数,将所述偏相关系数矩阵二值化,得到复杂网络模型,计算该复杂网络模型的特征路径长度、成本和集群度,分别得到训练样本图像和测试样本图像的网络特征;利用训练得到的该自适应提高(adaboost)分类器;利用训练得到的该自适应提高(adaboost)分类器对测试样本图像进行分类。本发明利用了脑功能磁共振图像中尽可能多的信息,能够精确的对脑功能磁共振图像进行分类。



1. 一种基于复杂网络的脑功能磁共振图像分类方法,其特征在于,包括以下步骤:

步骤 Sa :对训练样本图像和测试样本图像进行预处理,然后进行脑区分割,并提取各个脑区的平均时间序列,其中提取脑区平均时间序列的步骤为:

首先按照标准脑结构模板将全脑分为 90 个脑区,分别提取每个脑区内部各个体素在不同时间点上的激活值,再将各个体素的激活值进行平均,得到脑区平均时间序列;

步骤 Sb :计算各个平均时间序列之间的偏相关系数,得到偏相关系数矩阵,该步骤为:

首先计算各个平均时间序列之间的协方差矩阵 S,该协方差矩阵维度为 90×90 ,S 的每个元素 $s_{i,j}$ 为第 i 个和第 j 个时间序列之间的协方差系数,

$$s_{i,j} = \frac{1}{M} \sum_{t=1}^M (x_i(t) - \bar{x}_i)(x_j(t) - \bar{x}_j),$$

其中, M 为时间点数目, $x_i(t)$ ($i = 1, \dots, M$) 为第 i 个时间序列, \bar{x}_i 为第 i 个时间序列的平均值, \bar{x}_j 为第 j 个时间序列的平均值;

然后,计算平均时间序列间的偏相关系数矩阵 R,该偏相关系数矩阵 R 的维度为 90×90 ,R 的每个元素 $r_{i,j}$ 为:

$$r_{i,j} = -\frac{s_{i,j}^{-1}}{\sqrt{s_{i,i}^{-1} s_{j,j}^{-1}}};$$

其中, $s_{i,j}^{-1}$ 为协方差矩阵 S 的逆矩阵的第 {i, j} 个元素;

最后,对偏相关系数进行 Fisher 变换,得到经过 Fisher 变换后的偏相关系数矩阵 F 该变换后的偏相关系数矩阵维度为 90×90 ;

步骤 Sc :将所述偏相关系数矩阵二值化,得到复杂网络模型,该步骤为:

选取阈值将经过 Fisher 变换的偏相关系数矩阵 F 二值化,该变换后的偏相关系数矩阵维度为 90×90 ,二值化后 1 表示两个脑区之间有连接,即网络中两个节点之间的边存在,0 则表示两个脑区之间没有连接,即网络中的两个节点之间没有边;

阈值选取的方法为:使选用此阈值进行了二值化后的网络中实际存在的边的数量是网络中最多可能存在的边的数量的十分之一

步骤 Sd :计算该复杂网络模型的特征路径长度、成本和集群度作为功能磁共振图像的特征,其中,

计算该复杂网络模型的特征路径长度的步骤为:

用特征路径长度矩阵描述网络中任意两个节点 i, j 的特征路径长度 l_{ij} ,网络平均特征路径长度 L 描述了网络中任意两个节点的特征路径长度的平均值,即

$$L = \frac{1}{N(N-1)} \sum_{i,j \in V, i \neq j} l_{ij}$$

其中, N 为网络中节点的个数,即分割的脑区数 90; l_{ij} 为节点 i, j 之间的特征路径长度, V 为网络中所有节点的集合;

计算该复杂网络模型的成本的步骤为:

用网络中实际存在的所有边的数量比上网络中最多可能存在的边的数量,即:

$$K = \frac{\sum K_i}{\frac{2}{N(N-1)}} = \frac{1}{N(N-1)} \sum K_i,$$

其中, N 为网络中节点的个数, K_i 为网络中连接到节点 i 的边的数量;

计算该复杂网络模型的集群度的步骤为:

某一节点 i 的集群度 C_i 的值等于它的相邻节点之间存在的边的数目与它们之间所有可能的边数的比值, 即

$$C_i = \frac{e_i}{\frac{k_i(k_i-1)}{2}} = \frac{2e_i}{k_i(k_i-1)}$$

其中, e_i 表示节点 i 的邻点之间存在的边数, k_i 表示节点 i 的邻点的数目, $\frac{k_i(k_i-1)}{2}$ 就表示节点 i 的邻点之间可能存在的边数;

步骤 Se: 利用训练样本图像的特征路径长度、成本和集群度作为该功能磁共振图像的特征中的训练样本图像的特征, 来训练一自适应提高 (adaboost) 分类器, 包括如下步骤:

首先将特征路径长度、成本和集群度作为三个线性分类器, 用这三个线性分类器的加权和组成一个新的自适应提高 (adaboost) 分类器, 最初每个分类器的权重设为 $\frac{1}{m}$, m 为样本图像的数目, 自适应提高 (adaboost) 分类器在训练过程中逐渐调整三个线性分类器的权重, 最后得到一个最优的自适应提高 (adaboost) 分类器, 具体实施步骤如下:

对给定的样本 $(x_1, y_1), \dots, (x_m, y_m)$, 其中 $x_i \in X, y_i \in Y = (-1, 1)$, x 为训练样本图像的网络特征, Y 为图像类别, 首先设定初始化分类器的权重为 $D(i) = \frac{1}{m}$, 之后进行 T 次迭代, 迭代过程如下:

变量 t 从 1 开始增加到 T , 每次迭代首先计算每个特征 h_t 对训练样本图像进行分类得到的分类误差 ε_t , 然后计算新的样本权重,

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right),$$

最后, 更新各线性分类器的权重,

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \begin{cases} e^{-\alpha_t}, & h_t(x_i) = y_i \\ e^{\alpha_t}, & h_t(x_i) \neq y_i \end{cases},$$

其中 Z_t 为归一化因子;

循环结束后得到最优自适应提高 (adaboost) 分类器:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right);$$

步骤 Sf: 利用训练好的该自适应提高 (adaboost) 分类器对测试样本图像进行分类。

2. 如权利要求 1 所述的基于复杂网络的脑功能磁共振图像分类方法, 其特征在于, 所述对训练样本图像和测试样本图像进行预处理, 是在保留脑功能图像细节的同时, 使用脑功能图像与标准模板进行仿射配准变换方式的预处理, 并提高脑功能图像的信噪比。

一种基于复杂网络的脑功能磁共振图像分类方法

技术领域

[0001] 本发明属于图像处理技术领域,具体涉及一种基于复杂网络的脑功能磁共振图像分类方法。

背景技术

[0002] 功能磁共振成像 (functional Magnetic Resonance Imaging, fMRI) 以其高时空分辨率,非侵入式等特点在神经疾病诊断治疗方面得到了广泛应用。fMRI 一般指基于血氧水平依赖 (blood oxygen level-dependent, BOLD) 的磁共振成像,它通过测量由神经活动引起的脑血流和脑血氧等成分变化而造成的磁共振信号变化来反应脑活动。脑是一个复杂的系统,在受到刺激条件或经历病变时脑的磁共振图像会发生相应的变化。利用图像分类方法,计算脑功能磁共振图像具有某种属性的可能性大小,或者自动判别图像类别属性,是计算机辅助分析的一个重要应用。

[0003] 传统的功能磁共振图像分类方法主要有感兴趣区域 (ROI) 方式和体素 (voxel) 方式两种分类方法。感兴趣区域方式的分类方法依据目标结构的先验知识,将样本和目标分割成多个目标区域,并据此对目标进行分类;体素方式的分类方法采用复杂的非线性配准,以最大限度地实现个体间的精确对应,然后以图像的每一个空间单位(体素)作为分类依据。这两种方法都假设目标与样本的内部组织结构是一一对应的。前者认为先验的图像区域存在于每一个目标图像当中,并且能够准确分割;后者假定非线性配准后的体素是一一对应的。然而,这样的假设在很多情况下并不合理。人在不同状态下的脑功能磁共振图像会受到多方面因素的干扰,传统的分类方法都不是根据脑的固有属性对脑功能磁共振图像进行分类的,因此都会导致分类性能的下降。

发明内容

[0004] (一) 要解决的技术问题

[0005] 为了克服已有技术的不足,本发明所要解决的技术问题是设计一种分类准确率高、泛化性能强的脑功能磁共振图像分类方法。

[0006] (二) 技术方案

[0007] 为实现上述目的,本发明提出一种基于复杂网络的脑功能磁共振图像分类方法,包括以下步骤:

[0008] 步骤 Sa:对训练样本图像和测试样本图像进行预处理,然后进行脑区分割,并提取各个脑区的平均时间序列;

[0009] 步骤 Sb:计算各个平均时间序列之间的偏相关系数,得到偏相关系数矩阵;

[0010] 步骤 Sc:将所述偏相关系数矩阵二值化,得到复杂网络模型;

[0011] 步骤 Sd:计算该复杂网络模型的特征路径长度、成本和集群度作为功能磁共振图像的特征;

[0012] 步骤 Se:利用训练样本图像的网络参数作为该功能磁共振图像的特征中的训练

样本图像的特征,来训练一自适应提高 (adaboost) 分类器;

[0013] 步骤 Sf :利用训练好的该自适应提高 (adaboost) 分类器对测试样本图像进行分类。

[0014] (三) 有益效果

[0015] 本发明针对脑功能磁共振图像分类问题,通过构建脑网络模型、计算网络特征参数、训练自适应提高 (adaboost) 分类器等方法有效提高了图像分类的准确性和稳定性。

[0016] 本发明能够利用脑功能磁共振图像中尽可能多的信息,脑网络参数能够从本质上反应脑的活动,弥补了传统分类方法不能体现脑活动固有属性的不足,能够精确的对脑功能磁共振图像进行分类。

附图说明

[0017] 图 1 是本发明提供的基于复杂网络的脑功能磁共振图像分类的方法流程图;

[0018] 图 2 是依照本发明实施例使用本发明所述分类方法 (方法 A) 对比现有的基于局部特征的分类方法 (方法 B),分类受试者操作特性 (ROC) 的对比曲线。

具体实施方式

[0019] 为使本发明的目的、技术方案和优点更加清楚明白,以下结合具体实施例,并参照附图,对本发明进一步详细说明。

[0020] 基于复杂网络的脑功能磁共振图像分类是一种全新的脑功能磁共振图像分类方法。该方法首先建立复杂脑网络模型,计算脑网络的特征路径长度和集群度,用以表征不同的图像模式;然后利用该特征路径长度和集群度来训练一个自适应提高 (adaboost) 分类器;最后利用训练好的该自适应提高 (adaboost) 分类器对测试样本图像进行分类。

[0021] 参照图 1,根据本发明所述的一种人脑功能磁共振成像图像分类方法,能够依据训练样本图像来确定测试样本图像类别,具体实施步骤如下:

[0022] 步骤 Sa,对训练样本图像和测试样本图像进行预处理,然后进行脑区分割,并提取各个脑区的平均时间序列;

[0023] 1. 脑功能磁共振图像的预处理

[0024] 由于磁共振扫描过程中各种各样的噪声的影响,被试个体自身存在尺度和位置上的差异,非常有必要在分析数据之前对数据做一定的预处理。在整个的实验的数据获取中,主要的噪声信息来源有:(1) 物理头动;(2) 图像内层间扫描时间差别;(3) 外在磁场的均匀性等。脑功能磁共振图像预处理的常见步骤有:切片扫描时间对齐,图像序列对齐,联合配准,标准化(或称均一化),空间平滑滤波和时间平滑滤波等。

[0025] 2. 脑功能磁共振图像的分割

[0026] 采用国际通用的结构标记模板(AAL),将全脑分为90个脑区。结构标记模板是脑功能磁共振图像研究领域使用最为广泛的脑结构模板。

[0027] 3. 提取各脑区的平均时间序列

[0028] 依据预处理后的脑功能磁共振图像的数据,提取包含于相应脑区内部的各个体素在不同时间点上激活值的时间序列 Y (矩阵维数 $D \times N$),其中 D 为包含于球体内部的体素数目, N 为时间点数。所述激活值是指各个体素在不同时间点的血氧水平依赖(BOLD)强度。

[0029] 步骤 Sb :计算平均各个时间序列之间的偏相关系数。该步骤 Sb 具体包括如下步骤 :

[0030] 1. 计算平均时间序列间的协方差系数

[0031] 依据步骤 Sa 提取的各个脑区的时间序列,计算各个平均时间序列之间的协方差矩阵 S, S 的每个元素 $s_{i,j}$ 为第 i 个和第 j 个时间序列之间的协方差系数,

$$[0032] \quad s_{i,j} = \frac{1}{M} \sum_{t=1}^M (x_i(t) - \bar{x}_i)(x_j(t) - \bar{x}_j)$$

[0033] 其中, M 为时间点数目, $x_i(t)$ ($i = 1, \dots, M$) 为第 i 个时间序列, \bar{x}_i 为第 i 个时间序列的平均值, \bar{x}_j 为第 j 个时间序列的平均值。

[0034] 2. 计算平均时间序列间的偏相关系数

[0035] 依据时间序列间的协方差系数矩阵 S (矩阵维度为 90×90), 计算时间序列间的偏相关系数矩阵 R (矩阵维度为 90×90), R 的每个元素 $r_{i,j}$ 为 :

$$[0036] \quad r_{i,j} = -\frac{s_{i,j}^{-1}}{\sqrt{s_{i,i}^{-1}s_{j,j}^{-1}}}$$

[0037] 其中, $s_{i,j}^{-1}$ 为协方差矩阵 S (矩阵维度为 90×90) 的逆矩阵的第 $\{i, j\}$ 个元素。

[0038] 3. 对偏相关系数进行 Fisher 变换

[0039] 依据偏相关系数矩阵 R (矩阵维度为 90×90), 计算经过 Fisher 变换的偏相关系数矩阵 F (矩阵维度为 90×90), F 的每个元素 f_{ij} 为 :

$$[0040] \quad f_{i,j} = \frac{1}{2} \left(\frac{1+r_{i,j}}{1-r_{i,j}} \right),$$

[0041] 其中, f_{ij} 为经过 Fisher 变换后的偏相关系数矩阵 F (矩阵维度为 90×90) 的第 $\{i, j\}$ 个元素, r_{ij} 为偏相关系数矩阵 R (矩阵维度为 90×90) 的第 $\{i, j\}$ 个元素。

[0042] 步骤 Sc :将偏相关系数矩阵二值化, 得到复杂网络模型 ;

[0043] 设定阈值 T' , 令经过 Fisher 变换后的偏相关系数矩阵 F (矩阵维度为 90×90) 中大于等于 T' 的值为 1, 小于 T' 的值为 0, 得到复杂网络模型。二值化后的矩阵中 1 表示两个脑区之间有连接, 即网络中两个节点之间的边存在, 0 则表示两个脑区之间没有连接, 即网络中的两个节点之间没有边。阈值选取的方法为 :使网络中实际存在的边的数量是网络中可能存在的边的数量 ($\frac{N(N-1)}{2}$, 其中 N 为网络中节点的数目) 的十分之一。二值化的过程可描述为令

$$[0044] \quad w_{i,j} = \begin{cases} 1, & |f_{i,j}| \geq T' \\ 0, & |f_{i,j}| < T' \end{cases},$$

[0045] 其中, w_{ij} 为二值化后的网络的第 $\{i, j\}$ 个元素, f_{ij} 为经过 Fisher 变换的偏相关系数矩阵 F (矩阵维度为 90×90) 的第 $\{i, j\}$ 个元素, T' 为选取的阈值, $|\cdot|$ 为绝对值计算符号。

[0046] 步骤 Sd :计算该复杂网络模型的特征路径长度、成本和集群度作为功能磁共振图像的特征 ;

[0047] 依据复杂网络模型,计算该复杂网络模型的特征路径长度、成本和集群度,作为功能磁共振图像的特征。

[0048] 特征路径长度提供了网络中某一节点的信息到达另一节点的最优路径。我们可以用特征路径长度矩阵描述网络中任意两个节点 i, j 的特征路径长度 l_{ij} 。网络平均特征路径长度 L 描述了网络中任意两个节点的特征路径长度的平均值,即

$$[0049] \quad L = \frac{1}{N(N-1)} \sum_{i,j \in V, i \neq j} l_{ij}$$

[0050] 其中, N 为网络中节点的个数,即分割的脑区数 90 ; l_{ij} 为节点 i, j 之间的特征路径长度, V 为网络中所有节点的集合。

[0051] 成本是度量网络性质的一个重要参数,用来衡量构建网络所需要付出的总体代价。计算方法是网络中实际存在的所有边的数量比上网络中最多可能存在的边的数量,即 :

$$[0052] \quad K = \frac{\sum K_i}{\frac{N(N-1)}{2}} = \frac{1}{N(N-1)} \sum K_i,$$

[0053] 其中, N 为网络中节点的个数, K_i 为网络中连接到节点 i 的边的数量, K 即为网络的成本。

[0054] 集群度是度量网络性质的另一个重要特征,用来量度某一节点的相邻节点互为邻居的可能性。某一节点 i 的集群度 C_i 的值等于它的相邻节点之间存在的边的数目与它们之间所有可能的边数的比值,即

$$[0055] \quad C_i = \frac{e_i}{\frac{k_i(k_i-1)}{2}} = \frac{2e_i}{k_i(k_i-1)}$$

[0056] 其中, e_i 表示节点 i 的邻点之间存在的边数, k_i 表示节点 i 的邻点的数目, $\frac{k_i(k_i-1)}{2}$ 就表示节点 i 的邻点之间可能存在的边数。

[0057] 步骤 Se :利用训练样本图像的网络参数作为该功能磁共振图像的特征中的训练样本图像的特征,来训练一自适应提高 (adaboost) 分类器。

[0058] 得到训练样本图像的特征后,首先将特征路径长度、成本和集群度作为三个线性分类器,用这三个线性分类器的加权和组成一个新的自适应提高 (adaboost) 分类器,最初每个分类器的权重设为 $\frac{1}{m}$ (m 为样本图像的数目),自适应提高 (adaboost) 分类器在训练过程中逐渐调整三个线性分类器的权重,最后得到一个最优的自适应提高 (adaboost) 分类器。具体实施步骤如下 :

[0059] 对给定的样本 $(x_1, y_1), \dots, (x_m, y_m)$, 其中 $x_i \in X, y_i \in Y = (-1, 1), X$ 为训练样本图像的网络特征, Y 为图像类别,首先设定初始化分类器的权重为 $D(i) = \frac{1}{m}$, 之后进行 T 次迭代,迭代过程如下 :

[0060] 变量 t 从 1 开始增加到 T , 每次迭代首先计算每个特征 h_t 对训练样本图像进行分类得到的分类误差 ε_t , 然后计算新的样本权重,

$$[0061] \quad \alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right),$$

[0062] 最后, 更新各线性分类器的权重,

$$[0063] \quad D_{t+1}(i) = \frac{D_t(i)}{Z_t} \begin{cases} e^{-\alpha_t}, & h_t(x_i) = y_i \\ e^{\alpha_t}, & h_t(x_i) \neq y_i \end{cases},$$

[0064] 其中 Z_t 为归一化因子。

[0065] 循环结束后得到最优自适应提高 (adaboost) 分类器:

$$[0066] \quad H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right).$$

[0067] 步骤 Sf: 利用训练得到的最优自适应提高 (adaboost) 分类器对测试样本图像进行分类。

[0068] 将测试样本输入上述步骤得到的最优自适应提高 (adaboost) 分类器, 对测试样本图像进行分类, 分类结果通过分类正确率、真阳性率和假阳性率输出。

[0069] 本发明所述的基于复杂网络的脑功能磁共振图像分类方法的效果, 可通过真实的脑功能磁共振脑成像数据得以说明:

[0070] (1) 真实数据实验过程

[0071] 为展示本发明的效果, 在实施方案中采用真实数据集作测试, 共 39 个被试参与了实验, 20 男、19 女。被试年龄段及临床痴呆分级信息见表格 1。实验采用 T2* 加权梯度回波平面成像 (Echo-Planar Imaging, EPI) 序列获取针刺刺激后 BOLD fMRI 静息数据。

[0072] 采用统计参数图 (SPM) 软件 (<http://www.fil.ion.ucl.ac.uk/spm/>) 对数据进行预处理, 包括切片扫描时间对齐, 图像序列对齐, 联合配准, 标准化 (或称均一化)、空间平滑滤波。使用本发明所述方法 (方法 A) 对比现有的基于局部特征的分类方法 (方法 B), 获取分类方法的受试者操作特性 (ROC) 曲线及其曲线下面积 (AUC), 并将 ROC 曲线和 AUC 作为分类器性能的度量。

[0073] 表格 1 被试信息

[0074]	年龄段(岁)	CDR	组 C1 容量	组 C2 容量
	49-78	1	26	13

[0075] (2) 实验结果

[0076] 在真实实验数据集上两种方法的分类 ROC 曲线分别在图 2 中显示, 其中, 图 2 中的真阳性率是指实际为阳性而按该筛检试验的标准被正确地判为阳性的百分比, 假阳性率是指实际为阴性而按该筛检试验的标准被错误地判为阳性的百分比。如图 2 所示, 方法 A 的 ROC 曲线在大部分阈值范围内高于方法 B; AUC 值对比情况: 方法 A 的 AUC 值为 0.85, 方法 B 的 AUC 值为 0.78。曲线下面积 (AUC) 能度量总体分类性能、后验概率和排序性能, AUC 值越大, 则该分类方法的总体性能越好。由此, 方法 A 效果好于方法 B。

[0077] 实验结果说明, 本发明所述的基于复杂网络的脑功能磁共振图像分类方法, 有效

地提高了脑功能磁共振图像的分类性能。

[0078] 以上所述,仅为本发明中的具体实施方式,但本发明的保护范围并不局限于此,任何熟悉该技术的人在本发明所揭露的技术范围内,可理解想到的变换或替换,都应涵盖在本发明的权利要求书的保护范围之内。

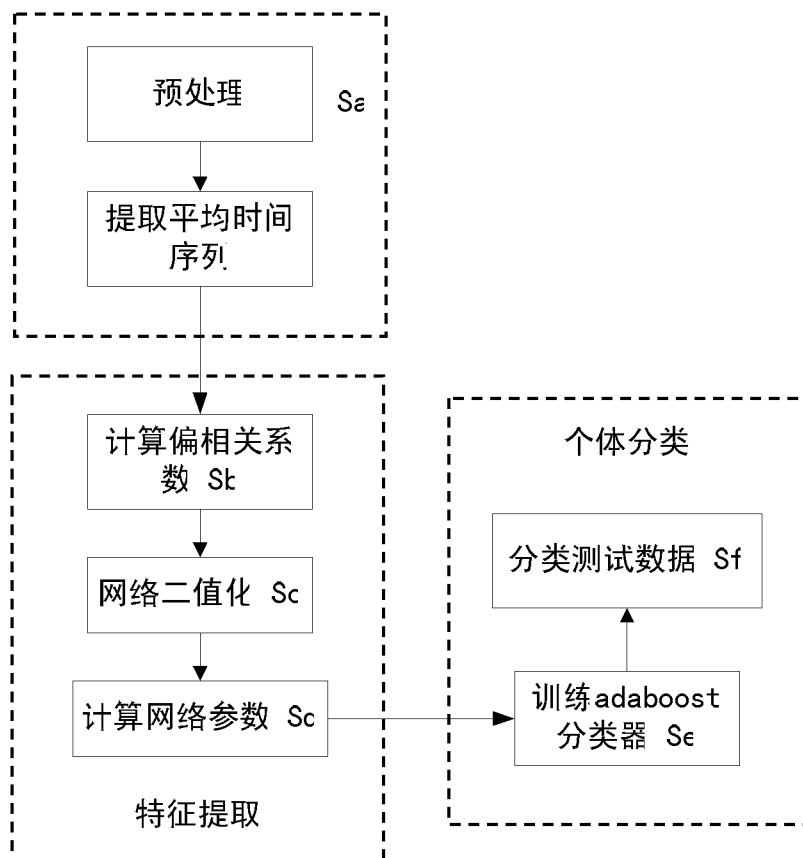


图 1




图 2