



(12)发明专利申请

(10)申请公布号 CN 106295709 A

(43)申请公布日 2017.01.04

(21)申请号 201610687766.0

(22)申请日 2016.08.18

(71)申请人 太原理工大学

地址 030024 山西省太原市迎泽西大街79号

(72)发明人 郭浩 曹锐 王彬 相洁 李海芳 陈俊杰

(74)专利代理机构 太原科卫专利事务所(普通合伙) 14100

代理人 朱源 王勇

(51)Int.Cl.

G06K 9/62(2006.01)


权利要求书3页 说明书4页 附图1页

(54)发明名称

基于多尺度脑网络特征的功能磁共振影像数据分类方法

(57)摘要

本发明涉及图像处理技术,具体是一种基于多尺度脑网络特征的功能磁共振影像数据分类方法。本发明解决了传统磁共振影像数据分类方法分类准确率低的问题。基于多尺度脑网络特征的功能磁共振影像数据分类方法,该方法是采用如下步骤实现的:步骤S1:对静息态功能磁共振影像进行预处理;步骤S2:采用动态随机种子方法对影像进行区域分割,并对所分割的脑区进行平均时间序列提取;步骤S3:计算各脑区平均时间序列两两间的关联程度;步骤S4:对关联矩阵进行二值化处理;步骤S5:计算静息态功能脑网络的局部属性及其在特定阈值空间的AUC值;步骤S6:进行分类器构建;步骤S7:量化所选特征在分类器中的重要度和冗余度。本发明适用于磁共振影像数据分类。



1.一种基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:该方法是采用如下步骤实现的:

步骤S1:对静息态功能磁共振影像进行预处理;

步骤S2:根据选定的标准化脑图谱,采用动态随机种子方法对预处理后的静息态功能磁共振影像进行区域分割,分割尺度分别为90,256,497,1003,1501,然后对所分割的各脑区进行平均时间序列的提取;

步骤S3:采用皮尔逊相关方法,计算各脑区的平均时间序列两两间的关联程度,由此得到关联矩阵;

步骤S4:设定阈值,然后根据阈值对关联矩阵进行二值化处理,由此得到静息态功能脑网络模型;

步骤S5:计算静息态功能脑网络模型的局部属性及局部属性在特定阈值空间内的AUC值;所述局部属性包括:静息态功能脑网络模型中各节点的度、节点效率、中间中心度;

步骤S6:采用支持向量机分类算法,选择静息态功能脑网络模型的局部属性作为分类特征,由此进行分类器的构建,然后采用交叉验证方法对构建的分类器进行检验;

步骤S7:采用互信息分析方法,对所选特征在分类器中的重要度和冗余度进行量化,然后根据量化结果对所选特征进行二次筛选,由此对静息态功能脑网络模型进行优化。

2.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S1中,预处理采用SPM软件进行,预处理步骤具体包括:时间层校正、头动校正、联合配准、空间标准化、低频滤波。

3.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S2中,标准化脑图谱采用AAL模板;

区域分割步骤具体包括:首先,计算AAL模板中每个脑区占有所有脑区的体素比例V;然后,计算AAL模板中原有脑区在节点规模N下可细化的子区域个数k, $k=VN$;然后,对相应脑区设置k个随机种子体素,并依次计算所有剩余体素与种子体素的距离;然后,采用动态随机种子点的设置方法,将当前体素与距离最近的体素组合形成新的子区域,并将新的物理中心设置为新的种子体素;依次循环,直至脑区内所有体素均分割完成;

平均时间序列的提取步骤具体包括:提取AAL模板中每个脑区所包含的所有体素在不同时间点上的BOLD强度,并将各体素在不同时间点上的BOLD强度进行算术平均,由此得到各脑区的平均时间序列。

4.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S3中,计算公式具体表示如下:

$$r_{ij} = \frac{\sum_{t=1}^n (x_i(t) - \bar{x}_i)(x_j(t) - \bar{x}_j)}{\sqrt{\sum_{t=1}^n (x_i(t) - \bar{x}_i)^2} \sqrt{\sum_{t=1}^n (x_j(t) - \bar{x}_j)^2}} \quad (1);$$

公式(1)中: r_{ij} 表示关联矩阵中第i行第j列的元素;n表示时间点个数; $x_i(t)$ 表示第i个脑区的时间序列; \bar{x}_i 表示第i个脑区的时间序列的平均值; $x_j(t)$ 表示第j个脑区的时间序列; \bar{x}_j 表示第j个脑区的时间序列的平均值;关联矩阵的维度分别为 90×90 , 256×256 , 497

×497,1003×1003,1501×1501。

5.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S4中,二值化处理公式具体表示如下:

$$b_{ij} = \begin{cases} 1, r_{ij} \geq \tau \\ 0, r_{ij} < \tau \end{cases} \quad (2);$$

公式(2)中: b_{ij} 表示静息态功能脑网络模型中第*i*行第*j*列的元素; r_{ij} 表示关联矩阵中第*i*行第*j*列的元素; τ 表示阈值;静息态功能脑网络模型的维度分别为90×90,256×256,497×497,1003×1003,1501×1501。

6.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S5中,计算公式具体表示如下:

$$k_i = \sum_{j \in G} a_{ij} \quad (3);$$

公式(3)中: k_i 表示静息态功能脑网络模型中任意一节点*i*的度; a_{ij} 表示静息态功能脑网络模型中节点*i*与节点*j*之间的连接;

$$e_i = \frac{1}{N-1} \sum_{j \neq i \in G} \frac{1}{d_{ij}} \quad (4);$$

公式(4)中: e_i 表示静息态功能脑网络模型中任意一节点*i*的节点效率; d_{ij} 表示静息态功能脑网络模型中节点*i*与节点*j*之间的最短路径长度;

$$b_i = \sum_{m \neq i \neq n \in G} \frac{\sigma_{mn}(i)}{\sigma_{mn}} \quad (5);$$

公式(5)中: b_i 表示静息态功能脑网络模型中任意一节点*i*的中间中心度; σ_{mn} 表示从节点*m*到节点*n*的最短路径的数量; $\sigma_{mn}(i)$ 表示从节点*m*到节点*n*经过节点*i*的最短路径的数量;

$$Y^{AUC} = \sum_{k=1}^{n-1} [Y(S_k) + Y(S_{k-1})] \times \Delta S / 2 \quad (6);$$

公式(6)中: Y^{AUC} 表示各局部属性值在特定阈值空间内的AUC值; $Y(S_k)$ 表示阈值 S_k 对应的局部属性值; $Y(S_{k-1})$ 表示阈值 S_{k-1} 对应的局部属性值; ΔS 表示两个阈值之间的间隔。

7.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S6中,分类器的构建步骤具体包括:采用RBF核函数,选择双样本T检验后具有显著组间差异的局部属性的AUC值作为分类特征,由此进行分类器的构建;

检验步骤具体包括:从样本集中随机选择90%的样本作为训练样本,剩余10%的样本作为测试样本,由此进行分类测试并得到分类准确率;将重复进行100次分类测试后得到的分类准确率进行算术平均,然后将算术平均值作为分类器的分类准确率。

8.根据权利要求1所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法,其特征在于:所述步骤S7中,量化公式具体表示如下:

$$D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i, c) \quad (7);$$

公式(7)中: D 表示所选特征在分类器中的重要度; S 表示所有特征的集合; $|S|$ 表示*S*中特征的个数; x_i 表示所选特征; c 表示样本的类别标签; $I(x_i, c)$ 表示所选特征与样本的类别标签*c*的互信息;

$$R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \quad (8);$$

公式(8)中:R表示所选特征在分类器中的冗余度;S表示所有特征的集合;|S|表示S中特征的个数; x_i 表示所选特征; x_j 表示其它特征; $I(x_i, x_j)$ 表示所选特征与其它特征的互信息;

二次筛选步骤具体包括:分别按照重要度大小和冗余度大小对所选特征进行排名,然后筛选出重要度较大且冗余度较小的特征。

基于多尺度脑网络特征的功能磁共振影像数据分类方法

技术领域

[0001] 本发明涉及图像处理技术,具体是一种基于多尺度脑网络特征的功能磁共振影像数据分类方法。

背景技术

[0002] 作为功能磁共振成像(functional Magnetic Resonance Imaging, fMRI)技术与复杂网络理论相结合,磁共振影像数据分类方法当前已经成为脑科学领域的热点之一。然而,传统磁共振影像数据分类方法由于自身原理所限,仅能够对单一尺度的脑网络进行描述,由此导致其分类准确率低,从而严重影响其应用价值。基于此,有必要发明一种全新的磁共振影像数据分类方法,以解决传统磁共振影像数据分类方法存在的上述问题。

发明内容

[0003] 本发明为了解决传统磁共振影像数据分类方法分类准确率低的问题,提供了一种基于多尺度脑网络特征的功能磁共振影像数据分类方法。

[0004] 本发明是采用如下技术方案实现的:

[0005] 基于多尺度脑网络特征的功能磁共振影像数据分类方法,该方法是采用如下步骤实现的:

[0006] 步骤S1:对静息态功能磁共振影像进行预处理;

[0007] 步骤S2:根据选定的标准化脑图谱,采用动态随机种子方法对预处理后的静息态功能磁共振影像进行区域分割,分割尺度分别为90,256,497,1003,1501,然后对所分割的各脑区进行平均时间序列的提取;

[0008] 步骤S3:采用皮尔逊相关方法,计算各脑区的平均时间序列两两间的关联程度,由此得到关联矩阵;

[0009] 步骤S4:设定阈值,然后根据阈值对关联矩阵进行二值化处理,由此得到静息态功能脑网络模型;

[0010] 步骤S5:计算静息态功能脑网络模型的局部属性及局部属性在特定阈值空间内的AUC值;所述局部属性包括:静息态功能脑网络模型中各节点的度、节点效率、中间中心度;

[0011] 步骤S6:采用支持向量机分类算法,选择静息态功能脑网络模型的局部属性作为分类特征,由此进行分类器的构建,然后采用交叉验证方法对构建的分类器进行检验;

[0012] 步骤S7:采用互信息分析方法,对所选特征在分类器中的重要度和冗余度进行量化,然后根据量化结果对所选特征进行二次筛选,由此对静息态功能脑网络模型进行优化。

[0013] 与传统磁共振影像数据分类方法相比,本发明所述的基于多尺度脑网络特征的功能磁共振影像数据分类方法通过采用动态随机种子方法、皮尔逊相关方法、支持向量机分类算法、交叉验证方法、互信息分析方法,实现了对多尺度的脑网络进行描述,由此大幅提高了分类准确率(如图1所示,本发明的分类准确率明显高于传统磁共振影像数据分类方法的分类准确率),从而使得应用价值更高。

[0014] 本发明有效解决了传统磁共振影像数据分类方法分类准确率低的问题,适用于磁共振影像数据分类。

附图说明

[0015] 图1是本发明与传统磁共振影像数据分类方法的对比示意图。

具体实施方式

[0016] 基于多尺度脑网络特征的功能磁共振影像数据分类方法,该方法是采用如下步骤实现的:

[0017] 步骤S1:对静息态功能磁共振影像进行预处理;

[0018] 步骤S2:根据选定的标准化脑图谱,采用动态随机种子方法对预处理后的静息态功能磁共振影像进行区域分割,分割尺度分别为90,256,497,1003,1501,然后对所分割的各脑区进行平均时间序列的提取;

[0019] 步骤S3:采用皮尔逊相关方法,计算各脑区的平均时间序列两两间的关联程度,由此得到关联矩阵;

[0020] 步骤S4:设定阈值,然后根据阈值对关联矩阵进行二值化处理,由此得到静息态功能脑网络模型;

[0021] 步骤S5:计算静息态功能脑网络模型的局部属性及局部属性在特定阈值空间内的AUC值;所述局部属性包括:静息态功能脑网络模型中各节点的度、节点效率、中间中心度;

[0022] 步骤S6:采用支持向量机分类算法,选择静息态功能脑网络模型的局部属性作为分类特征,由此进行分类器的构建,然后采用交叉验证方法对构建的分类器进行检验;

[0023] 步骤S7:采用互信息分析方法,对所选特征在分类器中的重要度和冗余度进行量化,然后根据量化结果对所选特征进行二次筛选,由此对静息态功能脑网络模型进行优化。

[0024] 所述步骤S1中,预处理采用SPM软件进行,预处理步骤具体包括:时间层校正、头动校正、联合配准、空间标准化、低频滤波。

[0025] 所述步骤S2中,标准化脑图谱采用AAL模板;

[0026] 区域分割步骤具体包括:首先,计算AAL模板中每个脑区占有所有脑区的体素比例 V ;然后,计算AAL模板中原有脑区在节点规模 N 下可细化的子区域个数 k , $k=VN$;然后,对相应脑区设置 k 个随机种子体素,并依次计算所有剩余体素与种子体素的距离;然后,采用动态随机种子点的设置方法,将当前体素与距离最近的体素组合形成新的子区域,并将新的物理中心设置为新的种子体素;依次循环,直至脑区内所有体素均分割完成;

[0027] 平均时间序列的提取步骤具体包括:提取AAL模板中每个脑区所包含的所有体素在不同时间点上的BOLD强度,并将各体素在不同时间点上的BOLD强度进行算术平均,由此得到各脑区的平均时间序列。

[0028] 所述步骤S3中,计算公式具体表示如下:

[0029]

$$r_{ij} = \frac{\sum_{t=1}^n (x_i(t) - \bar{x}_i)(x_j(t) - \bar{x}_j)}{\sqrt{\sum_{t=1}^n (x_i(t) - \bar{x}_i)^2} \sqrt{\sum_{t=1}^n (x_j(t) - \bar{x}_j)^2}} \quad (1);$$

[0030] 公式(1)中： r_{ij} 表示关联矩阵中第*i*行第*j*列的元素；*n*表示时间点个数； $x_i(t)$ 表示第*i*个脑区的时间序列； \bar{x}_i 表示第*i*个脑区的时间序列的平均值； $x_j(t)$ 表示第*j*个脑区的时间序列； \bar{x}_j 表示第*j*个脑区的时间序列的平均值；关联矩阵的维度分别为 90×90 ， 256×256 ， 497×497 ， 1003×1003 ， 1501×1501 。

[0031] 所述步骤S4中，二值化处理公式具体表示如下：

[0032]

$$b_{ij} = \begin{cases} 1, r_{ij} \geq \tau \\ 0, r_{ij} < \tau \end{cases} \quad (2);$$

[0033] 公式(2)中： b_{ij} 表示静息态功能脑网络模型中第*i*行第*j*列的元素； r_{ij} 表示关联矩阵中第*i*行第*j*列的元素； τ 表示阈值；静息态功能脑网络模型的维度分别为 90×90 ， 256×256 ， 497×497 ， 1003×1003 ， 1501×1501 。

[0034] 所述步骤S5中，计算公式具体表示如下：

[0035]

$$k_i = \sum_{j \in G} a_{ij} \quad (3);$$

[0036] 公式(3)中： k_i 表示静息态功能脑网络模型中任意一节点*i*的度； a_{ij} 表示静息态功能脑网络模型中节点*i*与节点*j*之间的连接；

[0037]

$$e_i = \frac{1}{N-1} \sum_{j \neq i \in G} \frac{1}{d_{ij}} \quad (4);$$

[0038] 公式(4)中： e_i 表示静息态功能脑网络模型中任意一节点*i*的节点效率； d_{ij} 表示静息态功能脑网络模型中节点*i*与节点*j*之间的最短路径长度；

[0039]

$$b_i = \sum_{m \neq i \neq n \in G} \frac{\sigma_{mn}(i)}{\sigma_{mn}} \quad (5);$$

[0040] 公式(5)中： b_i 表示静息态功能脑网络模型中任意一节点*i*的中间中心度； σ_{mn} 表示从节点*m*到节点*n*的最短路径的数量； $\sigma_{mn}(i)$ 表示从节点*m*到节点*n*经过节点*i*的最短路径的数量；

[0041]

$$Y^{AUC} = \sum_{k=1}^{n-1} [Y(S_k) + Y(S_{k-1})] \times \Delta S / 2 \quad (6);$$

[0042] 公式(6)中： Y^{AUC} 表示各局部属性值在特定阈值空间内的AUC值； $Y(S_k)$ 表示阈值 S_k 对应的局部属性值； $Y(S_{k-1})$ 表示阈值 S_{k-1} 对应的局部属性值； ΔS 表示两个阈值之间的间隔。

[0043] 所述步骤S6中，分类器的构建步骤具体包括：采用RBF核函数，选择双样本T检验后

具有显著组间差异的局部属性的AUC值作为分类特征,由此进行分类器的构建;

[0044] 检验步骤具体包括:从样本集中随机选择90%的样本作为训练样本,剩余10%的样本作为测试样本,由此进行分类测试并得到分类准确率;将重复进行100次分类测试后得到的分类准确率进行算术平均,然后将算术平均值作为分类器的分类准确率。

[0045] 所述步骤S7中,量化公式具体表示如下:

[0046]

$$D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i, c) \quad (7);$$

[0047] 公式(7)中:D表示所选特征在分类器中的重要度;S表示所有特征的集合;|S|表示S中特征的个数; x_i 表示所选特征;c表示样本的类别标签; $I(x_i, c)$ 表示所选特征与样本的类别标签c的互信息;

[0048]

$$R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \quad (8);$$

[0049] 公式(8)中:R表示所选特征在分类器中的冗余度;S表示所有特征的集合;|S|表示S中特征的个数; x_i 表示所选特征; x_j 表示其它特征; $I(x_i, x_j)$ 表示所选特征与其它特征的互信息;

[0050] 二次筛选步骤具体包括:分别按照重要度大小和冗余度大小对所选特征进行排名,然后筛选出重要度较大且冗余度较小的特征。




图1