

# 权利要求书

---

1. 一种面向智能电网多源异构数据的桥联检测与异常溯源方法，其特征在于，该方法包括以下步骤：

步骤 1：对智能电网多源异构数据集进行数据清洗、预处理；

步骤 2：利用预处理后的智能电网多源异构数据集，基于子空间表示模型计算出抗原集内各子空间的抗原密度，进行密度筛选，从而实现抗原集的划分；

步骤 3：利用步骤 2 中所得的各子空间内抗原密度，基于免疫耐受计算，在高密度低维子空间中生成异构检测器；

步骤 4：基于图卷积网络编码网络结构获得检测器在低维向量空间中的节点特征，选择步骤 3 中检测效果排名前 20% 的异构检测器作为特征检测器；

步骤 5：基于互信息最大化原理进行节点与全局对比进行具有聚类一致性优化的节点聚类，实现特征检测器聚类；

步骤 6：基于生物免疫中双特异性抗体偶联原理，将不同维度下的特征检测器进行向量映射拼接，生成桥联检测器；

步骤 7：通过神经网络训练，在每一个特征检测器的检测计算结果上赋予权重；

步骤 8：使用桥联检测器进行总检测计算，结合步骤 7 中的权重进行加权计算，得到检测评价，判断数据是否异常；

步骤 9：若数据异常，对于每一个维度下的特征检测器基于欧式计算进一步判断异常维度，实现溯源。

2. 根据权利要求 1 所述的面向智能电网多源异构数据的桥联检测与异常溯源方法，其特征在于，所述异构检测器的生成方法包括：

步骤 1.1：首先基于子空间表示模型，对抗原集进行特征提取，获得子空间模板，利用方差解释率方法计算得出子空间的维度；

步骤 1.2：基于步骤 1.1 所获得的子空间模板，利用欧式距离计算每个抗原与子空间模板的相似度，实现抗原集的划分；

步骤 1.3：在步骤 1.2 所划分后的各子空间内采用离散化方法，计算每个离散空间内数据点的个数，以实现抗原密度的计算；

步骤 1.4：通过人工免疫算法，利用步骤 1.3 中的抗原密度，基于免疫耐受计算，实现在高密度低维子空间中生成高效的异构检测器；为消除冗余检测器，选择抗体抑制率作为终止条件，通过设定饱和阈值，计算免疫检测器饱和度，采用惩罚机制，对子空间内免疫检测器进行动态调整，获得在各个子空间下合格的异构检测器集合。

## 权 利 要 求 书

3.根据权利要求 2 所述的面向智能电网多源异构数据的桥联检测与异常溯源方法，其特征在于，所述桥联检测器的生成方法包括：

步骤 2.1：使用图卷积网络编码网络结构和节点特征到低维向量空间，并通过重建网络结构的方式学习节点表，基于互信息最大化原理进行节点与全局对比进行具有聚类一致性优化的节点聚类，具体操作如下：

首先，输入特定子空间中生成的异构检测器作为原始图节点，对原始图 $G = \{X, A\}$ 的网络结构使用图扩散方法得到扩散图 $G' = \{X, A'\}$ ，其中， $X \in \mathbb{R}^{N \times d}$ 表示节点特征矩阵， $\mathbb{R}$ 表示域， $N$ 表示节点数量， $d$  表示每个节点的特征维度， $A \in \mathbb{R}^{N \times N}$ 表示网络结构的邻接矩阵， $A' \in \mathbb{R}^{N \times N}$ 表示扩散后的网络结构邻接矩阵；

然后，将两个图分别置于不共享权重的图卷积网络中提取节点表示 $\mathbf{Z}$ 和 $\mathbf{Z}'$ ，并经过平均池化获得全局图表示 $\mathbf{s}$ 和 $\mathbf{s}'$ ；

接着，基于互信息最大化原理，通过最大化节点表示 $\mathbf{Z}$ 和全局图表示 $\mathbf{s}'$ ，节点表示 $\mathbf{Z}'$ 和全局图 $\mathbf{s}$ 表示间的一致性最大化两个图间的互信息，使节点表示 $\mathbf{Z}$ 和 $\mathbf{Z}'$ 同时学习局部和全局邻居信息；

同时，在异构检测器空间中预先构造一个可学习的聚类矩阵 $\mathbf{C} \in \mathbb{R}^{d' \times k}$ ，其中， $d'$ 表示数据点的特征数， $k$ 表示聚类中心数量，它由 $k$ 个聚类质心向量 $\mathbf{c}_i \in \mathbb{R}^{d' \times 1}$ 组成，其中， $i = 1, 2, \dots, k$ ，节点表示 $\mathbf{Z}$ 和 $\mathbf{Z}'$ 经过 $\mathbf{C}$ 得到聚类分配表示 $\mathbf{Q}$ 和 $\mathbf{Q}'$ ，最大化聚类分配表示间的一致性可以挖掘节点表示间潜在的语义信息，将语义相似的节点聚类到同一个簇；通过在各维度下使用聚类，生成不同维度的特征检测器；

步骤 2.2：基于生物学中双特异性抗体偶联原理，对不同维度下的特征检测器进行映射拼接实现桥联，其中主选择器为映射拼接后生成的不同维度的异构检测器集合，视为桥联检测器，用于对操作域中同时涌入的大量智能电网多源异构数据进行检测，副选择器则为生成的某一维度下异构数据的特征检测器集合；抗体偶联中连接器的设计，在异常检测中类比成桥联器的设计，桥联器将不同维度的特征检测器进行向量映射，生成一个桥联检测器，同时处理来自多个维度的异常数据。

4.根据权利要求 3 所述的面向智能电网多源异构数据的桥联检测与异常溯源方法，其特征在于，所述步骤 8 和 9 中异常数据检验、溯源的方法包括：

步骤 3.1：通过神经网络训练，在每一个特征检测器的检测计算结果上赋予权重，利用已

# 权 利 要 求 书

有的智能电网多源异构数据自体非自体数据集，对于不同维度下特征检测器  $d_1, d_2, \dots, d_n$  分别进行欧式距离计算，其中， $n$  表示维度的大小， $d_j$  表示第  $j$  个维度下的特征检测器， $j = 1, 2, \dots, n$ ，而对于每个维度下的欧式距离计算结果分别随机赋予一个初始化权重  $w_1, w_2, \dots, w_n$ ，其中，欧式距离计算公式如下：

$$dist_j = \sqrt{\sum_{j=1}^n (Detect_j - Anti_j)^2}$$

上式中， $dist_j$  表示第  $j$  个维度下计算所得的欧式距离， $Detect_j$  表示第  $j$  个维度下检测样本的特征值， $Anti_j$  表示第  $j$  个维度下检测样本的特征值；

步骤 3.2：当输入新的智能电网多源异构数据集时，使用桥联检测器进行总检测计算，结合步骤 3.1 赋予的权重进行加权运算，得到一个检测评价  $W$ ，检测评价公式如下：

$$W = \sum_{j=1}^n (dist_j - r_j) w_j$$

其中， $r_j$  表示第  $j$  个维度下检测异常的检测器覆盖半径；

然后，将计算得到的检测评价  $W$  使用 *sigmoid* 激活函数输出类别标签，并与该数据的真实标签进行比对，然后计算预测结果与真实结果的二值交叉熵作为损失函数，*Sigmoid* 激活函数、二值交叉熵计算公式分别如下：

$$\sigma = \frac{1}{1+e^{-W}}$$

$$L(y, \hat{y}) = -\sum_{i=1}^N (y_i \log(\hat{y}_i) + (1-y_i) \log(1-\hat{y}_i))$$

其中， $\sigma$  表示 *Sigmoid* 激活函数， $e$  表示自然常数， $W$  表示上述步骤所得的检测评价，二值交叉熵表示为  $L(y, \hat{y})$ ， $y$  表示数据的真实标签，其中每个元素表示样本属于对应类别的概率， $y_i$  表示输出样本属于第  $i$  类别的概率； $\hat{y}$  表示数据的输出标签，其中每个元素表示样本属于对应类别的概率， $\hat{y}_i$  表示输出样本属于第  $i$  类别的概率，这里  $\hat{y}$  即  $\sigma$ ， $\log$  表示自然对数，即以  $e$  为底的对数运算符；

根据上述步骤计算得到的损失值，基于梯度下降算法，计算损失函数对于参数矩阵中的  $W^{(l)}$  的梯度  $\frac{\partial L(y, \hat{y})}{\partial W^{(l)}}$ ，其中  $W^{(l)}$  表示神经网络中连接第  $l$  层和第  $l+1$  层之间的权重矩阵，然后

## 权 利 要 求 书

---

沿着梯度的反方向更新权重矩阵  $W^{(l)}$  的数值，使得损失函数的值逐步减小，通过不断迭代更新  $W^{(l)}$ ，实现异常数据检测模型逐渐学习到适合的权重，训练生成高效准确的桥联检测器；

步骤 3.3：经过误差反复迭代后训练出桥联检测器，此时输入一条实时待检测的智能电网多源异构数据，进行检测计算得到检测评价  $W$ ，若  $W \geq 0.5$ ，检测为自体抗原，即检测数据正常；反之  $W < 0.5$ ，抗原则为非自体，检测数据异常；并且对于每一个维度  $j$  下的特征检测器  $d_j$ ，我们可以判断其是否满足  $(dist_j - r_j)w_j < 0$ ，若满足则可认为当前数据异常的维度为  $j$ ，基于此完成桥联器的设计，实现异常数据的溯源。

# 说 明 书

## 面向智能电网多源异构数据的桥联检测与异常溯源方法

### 技术领域

本发明涉及人工智能、数据安全、计算机免疫等领域，特别涉及一种面向智能电网多源异构数据的桥联检测与异常溯源方法。

### 背景技术

随着通信技术的发展和电力物联网的建设，智能电网逐步兴起。然而智能电网环境下形成的海量异构电力数据给智能电网异常数据检测带来了困难，限制了智能电网发展的同时，也带来了极大的电网安全隐患。仅以牵引变电站为例，其辅助监测系统会收到来自隔离开关、避雷器、牵引变压器、电流电压互感器等设备的数据信息，各数据间又普遍存在异构问题，大大增加了系统进行异常检测的难度。目前，智能电网成为现代能源系统的关键组成部分，成为世界各国竞相发展的一个重点领域，对其中异构电力数据是否异常进行有效的检测是保障智能电网得以稳步发展的必要前提。

现有的智能电网多源异构数据检测技术通常采用直接将数据融合为整体后再识别处理的方法，其中涉及特征提取、特征关联、特征融合、目标感知等步骤。识别处理的过程大多采用基于欧氏空间距离计算的检测方法。融合检测通常采用神经网络、聚类分析等方法。神经网络通过学习复杂数据表示和特征融合，将多源数据映射到共同的特征空间，通过训练神经网络对正常数据进行建模，可将异常数据识别为与模型不匹配的数据点；聚类分析通过对原始数据源进行预处理，使其具有一致的特征表示，实现数据的整合分组，从而识别出相似的数据样本形成群集或簇并进行标记或处理，利用特征数据集可识别异常数据点。

现有的检测技术存在数据量较大时融合速度慢、高维数据运算复杂度高的问题，导致整体检测效率不高。同时，由于将多源异构数据直接融合时会损失一定特征信息，导致检测准确度不高。并且，传统深度神经网络无法反映具体错误数据，数据融合结果缺乏解释性，导致检测技术没有异常溯源能力。

本发明针对现有技术存在的问题提供一种基于生物免疫的源异构数据的桥联检测与异常溯源方法，通过设计桥联检测器对异构数据进行不同维度的检测，以期检测器并行工作提高检测效率的同时有效避免因数据融合而导致的特征信息的丢失，同时对不同维度下检测器检测结果的训练，实现异常数据的精确溯源，为智能电网进行数据检测维持正常运维提供技术支撑。

### 发明内容

# 说 明 书

---

传统的智能电网多源异构数据检测方法通常为数据融合再处理，这一处理模式继承了数据融合方法特征信息丢失的局限，同时海量的多源异构数据融合必然导致速率下降、准确度降低。于是面向海量智能电网异构数据时，如何在保证检测效率及准确率的情况下实现异常数据的高效检测及智能溯源，是传统检测方法面临的技术瓶颈，必须寻求新的思路。

本发明基于生物免疫桥联抗体原理，创新性地提出一种针对智能电网多源异构数据的桥联检测与异常溯源方法，其核心思想是模拟生物学双特异性抗体偶联过程，将特征检测器进行映射拼接，生成桥联检测器，期望桥联检测器如同双特异性抗体一样获得对海量多源数据桥联检测的能力。

本发明提出了一种面向智能电网多源异构数据的桥联检测与异常溯源方法，该方法包括如下步骤：

步骤 1：对智能电网多源异构数据集进行数据清洗、预处理。

步骤 2：利用预处理后的智能电网多源异构数据集，基于子空间表示模型计算出抗原集内各子空间的抗原密度，进行密度筛选，从而实现抗原集的划分。

步骤 3：利用步骤 2 中所得的各子空间内抗原密度，基于免疫耐受计算，在高密度低维子空间中生成异构检测器。

步骤 4：基于图卷积网络编码网络结构获得检测器在低维向量空间中的节点特征，选择步骤 3 中检测效果排名前 20% 的异构检测器作为特征检测器。

步骤 5：基于互信息最大化原理进行节点与全局对比进行具有聚类一致性优化的节点聚类（参见“汤乾, 武浩, 基于互信息最大化和聚类感知的节点表示学习[J/OL], 云南大学学报(自然科学版):1-8[2024-02-06], <http://kns.cnki.net/kcms/detail/53.1045.N.20230906.0907.002.html>”），实现特征检测器聚类。

步骤 6：基于生物免疫中双特异性抗体偶联原理，将不同维度下的特征检测器进行向量映射拼接，生成桥联检测器。

步骤 7：通过神经网络训练，在每一个特征检测器的检测计算结果上赋予权重。

步骤 8：使用桥联检测器进行总检测计算，结合步骤 7 中的权重进行加权计算，得到检测评价，判断数据是否异常。

步骤 9：若数据异常，对于每一个维度下的特征检测器基于欧式计算进一步判断异常维度，实现溯源。

本发明相比现有技术具有以下优点：

# 说 明 书

(1) 本发明基于抗原密度的实值 NSA (ASD-RNSA) 来生成子检测器，可对低维子空间内抗原实现有效捕捉，解决传统 NSAs 不考虑抗原分布，无法有效区分抗原的缺点，解决了传统 NSAs 算法覆盖时存在的采样点数量不足、多样性不足的缺点，避免生成过程在高维空间过早收敛的弊端。

(2) 本发明基于生物学双特异性抗体和偶联机理，将特征检测器映射拼接，生成桥联检测器，提高了检测效率的同时，避免了将待检测数据直接融合，保留了特征信息，从而可以进一步进行异常溯源。

## 附图说明

图 1 为本发明的总技术路线图。

图 2 为异构检测器生成方法示意图。

图 3 为桥联检测器生成方法示意图。

图 4 为异常数据检测、溯源方法示意图。

## 具体实施方式

下面结合附图对本发明的具体实施方式以及工作原理作进一步详细说明。

本实施例提供了一种面向智能电网多源异构数据的桥联检测与异常溯源方法，技术路线图如附图 1 所示，该方法通过三种理论研究实现三个理论模型，具体流程如下：

步骤 1：对智能电网多源异构数据集进行数据清洗、预处理。

步骤 2：利用预处理后的智能电网多源异构数据集，基于子空间表示模型计算出抗原集内各子空间的抗原密度，进行密度筛选，从而实现抗原集的划分。

步骤 3：利用步骤 2 中所得的各子空间内抗原密度，基于免疫耐受计算，在高密度低维子空间中生成异构检测器。

步骤 4：基于图卷积网络编码网络结构获得检测器在低维向量空间中的节点特征，选择步骤 3 中检测效果排名前 20% 的异构检测器作为特征检测器。

步骤 5：基于互信息最大化原理进行节点与全局对比进行具有聚类一致性优化的节点聚类，实现特征检测器聚类。

步骤 6：基于生物免疫中双特异性抗体偶联原理，将不同维度下的特征检测器进行向量映射拼接，生成桥联检测器。

步骤 7：通过神经网络训练，在每一个特征检测器的检测计算结果上赋予权重。

步骤 8：使用桥联检测器进行总检测计算，结合步骤 7 中的权重进行加权计算，得到检测

# 说 明 书

---

评价，判断数据是否异常。

步骤 9：若数据异常，对于每一个维度下的特征检测器基于欧式计算进一步判断异常维度，实现溯源。

如图 2 所示，异构检测器生成方法主要包括对抗原集密度筛选，在各子空间内基于免疫耐受计算生成检测器两个环节，具体步骤如下：

步骤 1.1：首先基于子空间表示模型，对抗原集进行特征提取，获得子空间模板，利用方差解释率方法计算得出子空间的维度。

步骤 1.2：基于步骤 1.1 所获得的子空间模板，利用欧式距离计算每个抗原与子空间模板的相似度，实现抗原集的划分。

步骤 1.3：在步骤 1.2 所划分后的各子空间内采用离散化方法，计算每个离散空间内数据点的个数，以实现抗原密度的计算。

步骤 1.4：通过人工免疫算法，利用步骤 1.3 中的抗原密度，基于免疫耐受计算，实现在高密度低维子空间中生成高效的异构数据检测器；为消除冗余检测器，选择抗体抑制率作为终止条件，通过设定饱和阈值，计算免疫检测器饱和度，采用惩罚机制，对子空间内免疫检测器进行动态调整，获得在各个子空间下合格的异构检测器集合。

如图 3 所示，桥联检测器生成方法主要包括对异构检测器的特征提取，基于互信息最大化原理的节点聚类，对不同维度下的特征检测器映射拼接三个环节，具体步骤如下：

步骤 2.1：使用图卷积网络编码网络结构和节点特征到低维向量空间，并通过重建网络结构的方式学习节点表，基于互信息最大化原理进行节点与全局对比进行具有聚类一致性优化的节点聚类。具体操作如下：

首先，输入特定子空间中生成的异构检测器作为原始图节点，对原始图  $G = \{X, A\}$ （其中， $X \in \mathbb{R}^{N \times d}$  表示节点特征矩阵， $\mathbb{R}$  表示域， $N$  表示节点数量， $d$  表示每个节点的特征维度， $A \in \mathbb{R}^{N \times N}$  表示网络结构的邻接矩阵）的网络结构使用图扩散方法得到扩散图  $G' = \{X, A'\}$ （ $A' \in \mathbb{R}^{N \times N}$  表示扩散后的网络结构邻接矩阵）。然后，将两个图分别置于不共享权重的图卷积网络中提取节点表示  $\mathbf{Z}$  和  $\mathbf{Z}'$ ，并经过平均池化获得全局图表示  $\mathbf{s}$  和  $\mathbf{s}'$ 。接着，基于互信息最大化原理，通过最大化节点表示  $\mathbf{Z}$  和 全局图表示  $\mathbf{s}'$ ，节点表示  $\mathbf{Z}'$  和 全局图  $\mathbf{s}$  表示间的一致性最大化两个图间的互信息，使节点表示  $\mathbf{Z}$  和  $\mathbf{Z}'$  同时学习局部和全局邻居信息。同时，在异构检测器空间中预先构造一个可学习的聚类矩阵  $\mathbf{C} \in \mathbb{R}^{d' \times k}$ （其中， $d'$  表示数据点的特征数， $k$  表示聚类中心

## 说 明 书

---

数量,  $\mathbb{R}$  表示域), 它由  $k$  个聚类质心向量  $\mathbf{c}_i \in \mathbb{R}^{d' \times 1}$  (其中,  $i = 1, 2, \dots, k$ ) 组成, 节点表示  $\mathbf{Z}$  和  $\mathbf{Z}'$  经过  $\mathbf{C}$  得到聚类分配表示  $\mathbf{Q}$  和  $\mathbf{Q}'$ , 最大化聚类分配表示间的一致性可以挖掘节点表示间潜在的语义信息, 将语义相似的节点聚类到同一个簇。通过在各维度下使用聚类, 可以生成不同维度的特征检测器。

步骤 2.2: 基于生物学中双特异性抗体偶联原理, 对不同维度下的特征检测器进行映射拼接实现桥联, 其中主选择器为映射拼接后生成的不同维度的异构检测器集合, 可视为桥联检测器, 用于对操作域中同时涌入的大量智能电网多源异构数据进行检测, 副选择器则为上文中生成的某一维度下异构数据的特征检测器集合。抗体偶联中连接器的设计, 可在异常检测中类比成桥联器的设计。桥联器可以将不同维度的特征检测器进行向量映射, 生成一个桥联检测器, 同时处理来自多个维度的异常数据。

如图 4 所示, 异常数据检验、溯源方法主要包括参数训练和异常溯源两个环节, 具体步骤如下:

步骤 3.1: 通过神经网络训练, 在每一个特征检测器的检测计算结果上赋予权重, 利用已有的智能电网多源异构数据自体非自体数据集, 对于不同维度下特征检测器  $d_1, d_2, \dots, d_n$  分别进行欧式距离计算 (其中,  $n$  表示维度的大小,  $d_j$  表示第  $j$  个维度下的特征检测器,  $j = 1, 2, \dots, n$ ), 并对于每个维度下的欧式距离计算结果分别随机赋予一个初始化权重  $w_1, w_2, \dots, w_n$ 。

其中, 欧式距离计算公式如下:

$$dist_j = \sqrt{\sum_{j=1}^n (Detect_j - Anti_j)^2}$$

上式中,  $dist_j$  表示第  $j$  个维度下计算所得的欧式距离,  $Detect_j$  表示第  $j$  个维度下检测样本的特征值,  $Anti_j$  表示第  $j$  个维度下检测样本的特征值。

步骤 3.2: 当输入新的智能电网多源异构数据集时, 使用桥联检测器进行总检测计算, 结合步骤 3.1 赋予的权重进行加权运算, 我们会得到一个检测评价  $W$ 。检测评价公式如下:

$$W = \sum_{j=1}^n (dist_j - r_j) w_j$$

其中,  $dist_j$  表示第  $j$  个维度下计算所得的欧式距离,  $r_j$  表示第  $j$  个维度下检测异常的检测器覆盖半径。

## 说 明 书

然后，我们将计算得出的检测评价  $W$  使用  $sigmoid$  激活函数输出类别标签，并与该数据的真实标签进行比对，然后计算预测结果与真实结果的二值交叉熵作为损失函数。Sigmoid 激活函数、二值交叉熵计算公式分别如下：

$$\sigma = \frac{1}{1+e^{-W}}$$

$$L(y, \hat{y}) = -\sum_{i=1}^N (y_i \log(\hat{y}_i) + (1-y_i) \log(1-\hat{y}_i))$$

其中， $\sigma$  表示 Sigmoid 激活函数， $e$  表示自然常数， $W$  表示上述步骤所得的检测评价，二值交叉熵表示为  $L(y, \hat{y})$ ， $y$  表示数据的真实标签，其中每个元素表示样本属于对应类别的概率， $y_i$  表示输出样本属于第  $i$  类别的概率， $\hat{y}$ （即  $\sigma$ ）表示数据的输出标签，其中每个元素表示样本属于对应类别的概率， $\hat{y}_i$  表示输出样本属于第  $i$  类别的概率， $\log$  表示自然对数，即以  $e$  为底的对数运算符。

根据上述步骤计算得到的损失值，我们基于梯度下降算法，计算损失函数对于参数矩阵中的  $W^{(l)}$  的梯度  $\frac{\partial L(y, \hat{y})}{\partial W^{(l)}}$ （其中  $W^{(l)}$  表示神经网络中连接第  $l$  层和第  $l+1$  层之间的权重矩阵， $L(y, \hat{y})$  表示二值交叉熵即损失函数）然后沿着梯度的反方向更新权重矩阵  $W^{(l)}$  的数值，使得损失函数的值逐步减小。通过不断迭代更新  $W^{(l)}$ ，可以实现异常数据检测模型逐渐学习到适合的权重，训练生成高效准确的桥联检测器。

步骤 3.3：经过误差反复迭代后训练出桥联检测器，此时我们再输入一条实时待检测的智能电网多源异构数据，进行检测计算得到检测评价  $W$ 。若  $W \geq 0.5$ ，检测为自体抗原，即检测数据正常，反之  $W < 0.5$ ，抗原则为非自体，检测数据异常。并且对于每一个维度  $j$  下的特征检测器  $d_j$ ，我们可以判断其是否满足  $(dist_j - r_j)w_j < 0$ ，若满足则可认为当前数据异常的维度为  $j$ ，基于此可以实现桥联器的设计，实现异常数据的溯源。

本发明基于抗原密度的实值 NSA (ASD-RNSA) 来生成子检测器，可对低维子空间内抗原实现有效捕捉，解决传统 NSAs 不考虑抗原分布，无法有效区分抗原的缺点，解决了传统 NSAs 算法覆盖时存在的采样点数量不足、多样性不足的缺点，避免生成过程在高维空间过早收敛的弊端。另外，本发明基于生物学双特异性抗体和偶联机理，将特征检测器映射拼接，生成桥联检测器，提高了检测效率的同时，避免了将待检测数据直接融合，保留了特征信息，

## 说 明 书

---

从而可以进一步进行异常溯源。

以上所述，仅为本发明的具体实施方式，本说明书中所公开的任一特征，除非特别叙述，均可被其他等效或具有类似目的的替代特征加以替换；所公开的所有特征、或所有方法或过程中的步骤，除了互相排斥的特征和/或步骤以外，均可以任何方式组合；本领域的技术人员根据本发明技术方案的技术特征所做出的任何非本质的添加、替换，均属于本发明的保护范围。

# 说 明 书 附 图

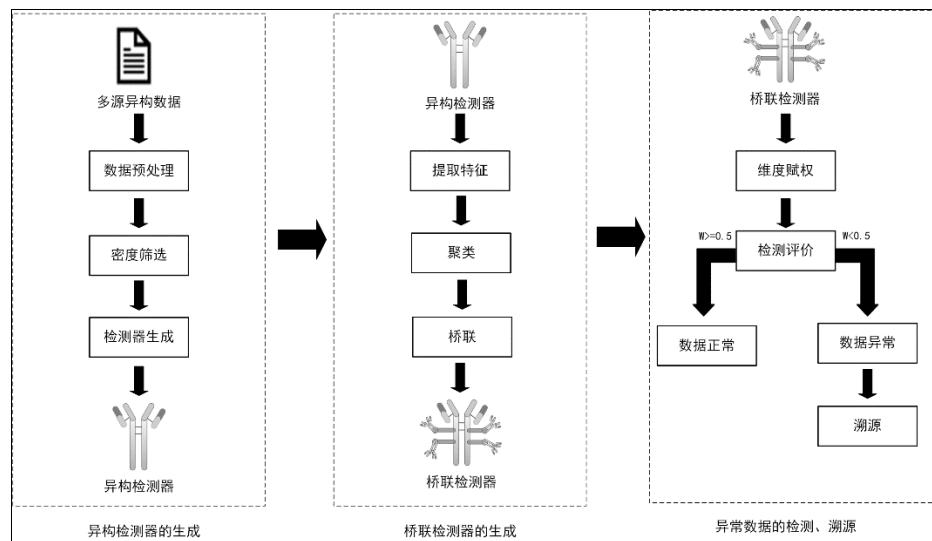


图 1

# 说 明 书 附 图

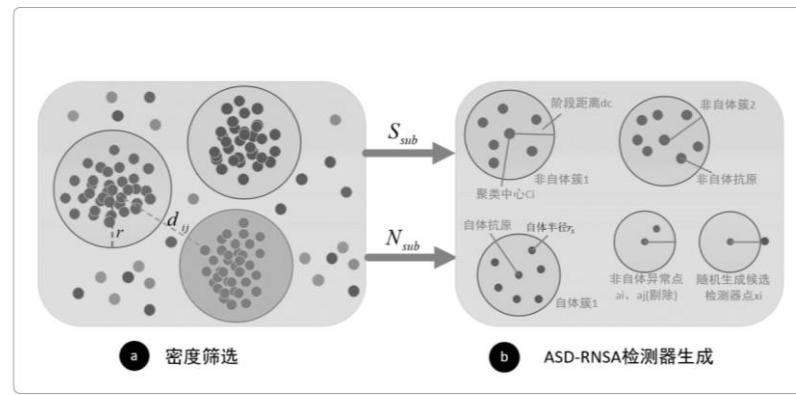


图 2

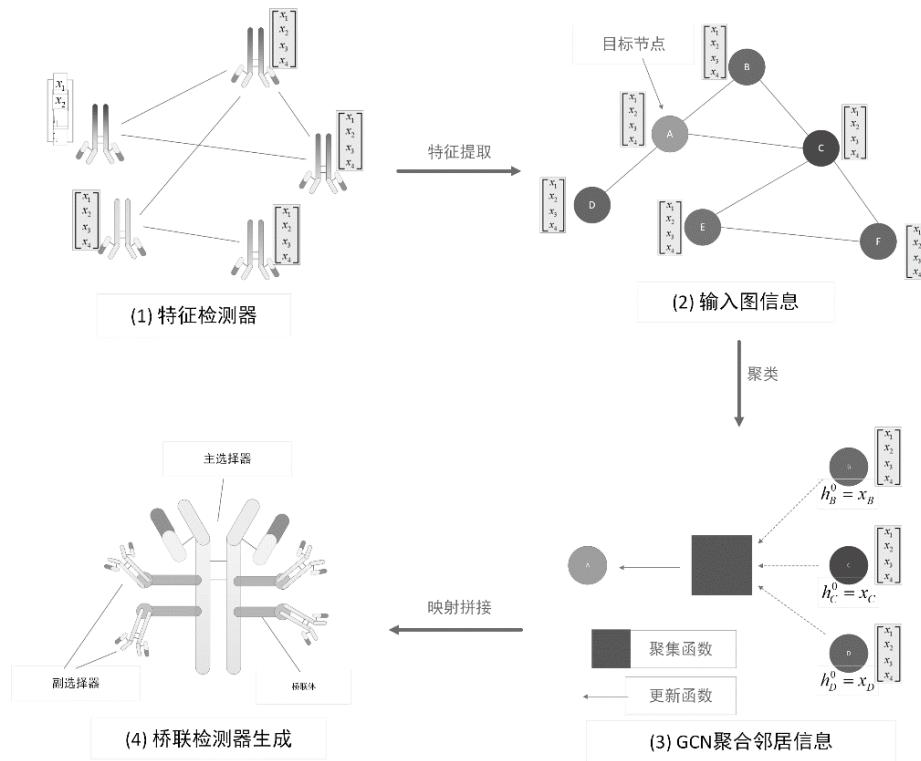


图 3

## 说 明 书 附 图

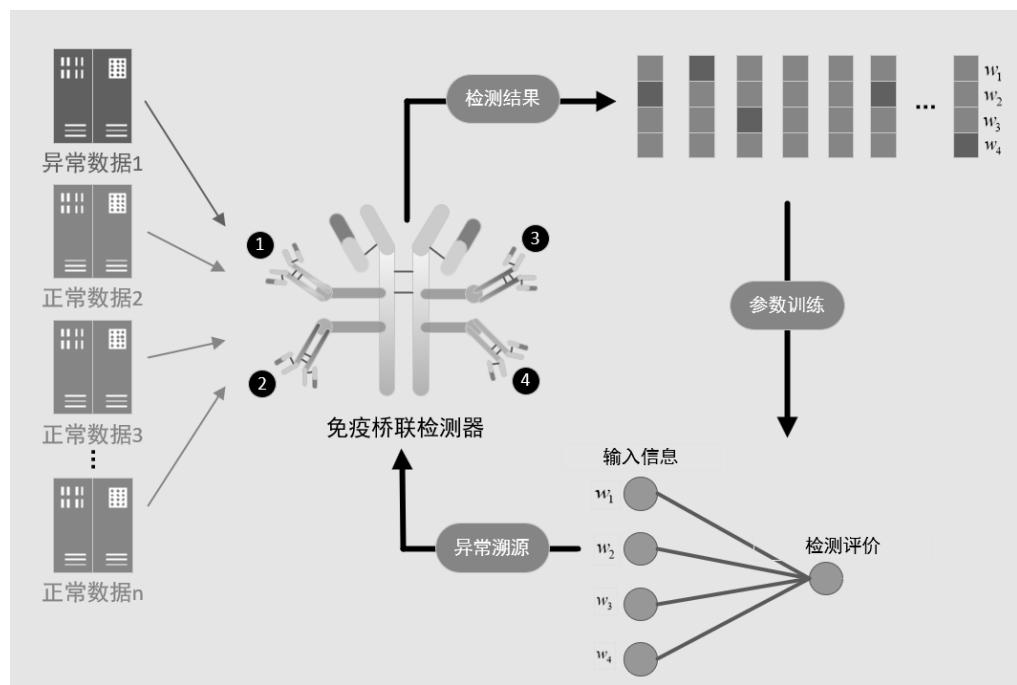


图 4

## 说 明 书 摘 要

---

本发明公开了一种面向智能电网多源异构数据的桥联检测与异常溯源方法，该方法包括异构检测器的生产，桥联检测器的生成以及异常数据的检测、溯源，该方法基于生物免疫桥联抗体原理，模拟生物学双特异性抗体偶联过程，将特征检测器进行映射拼接，生成桥联检测器，期望桥联检测器如同双特异性抗体一样获得对海量多源数据桥联检测的能力。本发明可对低维子空间内抗原实现有效捕捉，解决传统 NSAs 不考虑抗原分布，无法有效区分抗原，以及传统 NSAs 算法覆盖时存在的采样点数量不足、多样性不足的缺点，避免生成过程在高维空间过早收敛。同时，提高了检测效率，避免了将待检测数据直接融合，保留了特征信息，从而可以进一步进行异常溯源。

## 摘要附图

