# 基于测点时空特征的工程安全监测网络划分方法

毛莺池 程杨堃 齐 海

(河海大学计算机与信息学院 南京 211100)

**摘 要**大量传感器测点部署在大型土木结构体中观测多种类型物理量,直接根据海量监测数据评判工程运行状态存在困难.在实际应用中,采用分而治之的思想,根据结构体工程规范、设计资料和工程经验划分成若干区域,融合局部评价结果实现整体评判.但是,其没有考虑测点空间分布信息和监测数据时序变化规律,无法满足结构体安全监测实时评判要求.为了使安全监测网络划分结果能够及时反映结构体物理量动态变化规律,本文考虑监测网络中测点监测数据之间的相关性,提出时序降噪自动编码器(TSDA)压缩高维监测数据,以表征测点时空特征.在此基础上,提出基于测点时空特征的监测网络划分算法(NPA),该算法引入辅助目标变量优化网络划分目标函数,使网络划分结果反映大坝运行物理规律.利用公开数据集和某大坝实测数据进行实验验证,实验结果表明提出的基于测点时空特征的监测区域划分算法 NPA 在轮廓系数上较 TSDA+K-Means 和 TSDA+GMM 分别提高 45.1%和58.4%;在CH指标上,较 TSDA+K-Means 和 TSDA+GMM 分别提高 30.8%和61.6%,说明其可以得到很好的工程安全监测网络的划分结果.

关键词 无线传感网;自动编码器;时空特征;网络划分;安全监测 中图法分类号 TP393 **DOI号** 10.11897/SP.J.1016.2020.00631

# Sensor Network Partition Based on the Spatial-Temporal Features for Structure Safety Monitoring

MAO Ying-Chi CHENG Yang-Kun QI Hai

(School of Computer and Information, Hohai University, Nanjing 211100)

**Abstract** With the rapid development of Internet of Things (IoT) technologies, many various types of sensor node have been deployed in the huge civil engineering to measure the different physical quantities and monitor their changes in various regions of the structure, such as formation, stress, strain, etc. In the safety monitoring systems of a huge civil engineering, the massive monitoring data are generated from the deployed sensor nodes. However, it is difficult to process a large amount of data with the traditional mechanical models, so it is impossible to directly evaluate the safe operation states of the engineering. In real applications, divide and conquer strategy is adopted. The sensor network is divided into multiple regions according to the design specifications, simulation data, and engineering experience. The local results from sub-regions are integrated to achieve overall evaluation. Due to management specifications, instrument failures, environmental changes, and actual monitoring requirements, the spatial distribution of sensor nodes will change. Meanwhile, during the operation period, the measured data and their temporal feature dynamically changes over time. The existing network partition based on the mechanical models ignored the spatial distribution of sensor nodes and their variations of time series, which can not reflect the spatial-temporal features of the measured data

收稿日期:2019-05-01;在线出版日期:2020-02-07.本课题得到国家重点研发课题(No. 2018YFC0407105)、国家自然科学基金重点项目 (No. 61832005)、华能集团重点研发课题(No. HNKJ17-21)资助. 毛莺池(通信作者),博士,教授,CCF高级会员,主要研究领域为物联 网、分布计算与并行处理、边缘智能计算.E-mail: yingchimao@hhu.edu.cn. 程杨堃,硕士研究生,主要研究领域为物联网、边缘智能计 算.齐 海(通信作者),硕士研究生,主要研究领域为物联网、边缘智能计算.E-mail; qihai@qq.com.

change in a real-time manner, resulting in the low accurate evaluation performance. The monitoring data in the large civil engineering is high-dimensional and dynamic spatial-temporal data. The network partitions can timely reflect the dynamic changes of engineering structure, it should consider the similarity of structure and force in the local area of the engineering, and the correlation among the monitoring data. In this paper, a time series denoising autoencoder (TSDA) is proposed to represent the spatial and temporal features of sensor nodes. Considering the correlation among the spatial positions of the different sensor nodes and the change law of the time series, the auxiliary distribution variables are introduced to optimize the objective function of deep clustering. Finally, the Network Partition Algorithm based on TSDA (NPA) is presented to cluster all sensor nodes and partition the sensor network into the different regions based on the spatial-temporal features of nodes. The clustering results can better reflect the physical laws of the large civil engineering. We compare our NPA partition algorithm, with several baseline and state-of-the-art algorithms, including K-Means, AE+K-Means, GMM, AE+GMM, on the public datasets (MNIST, Fashion-MNIST, STL-10, and Reuters) and a real data set from an arch dam. The evaluation metrics are Clustering Accuracy (ACC), Normalized Mutual Information (NMI) and Adjusted Rand Index (ARI). Experimental results demonstrate that the proposed network partition algorithm NPA can achieve better partition performance. On the public data set (CIFAR-10), NPA can enhanceACC 49.4% and 59.1% higher, NMI 46.5% and 54.1% higher, and ARI 47.0% and 41.3% higher than the AE+K-Means and AE+GMM, respectively. On therealdata set, the NPA can improve Silhouette Coefficient 45.1% and 58.4% higher than the TSDA+K-Means and TSDA+GMM, respectively. In the Calinski-Harabaz Index, the NPA can increase by 30.8% and 61.6%, respectively.

**Keywords** wireless sensor network; autoencoder; spatial-temporal feature; network partition; safety monitoring

# 1 引 言

传感器和物联网技术的快速发展,使大型土木 工程结构体的监测手段越来越丰富.结构体中部署多 类型传感器,监测多种物理量,如位移、变形、开合 度、压力、应力等,来感知结构体各个区域的物理量变 化.结构体空间结构巨大,部署测点数量多,产生海 量监测数据.然而,传统专业模型难以处理大量监测 数据,无法直接利用测点数据对结构体安全运行状态 评判.在实际应用中,通常根据结构体工程规范、设 计资料和工程经验将安全监测网络划分为若干区 域,融合单域评价结果实现整体综合评判[12]. 以大 坝为例,根据坝段和高程分别进行横向和纵向划分, 得到若干个网格化区域.图1所示为某拱坝所采用 的安全监测网络网格化区域划分示意图,不同灰度颜 色实心圆点对应不同类型测点,横向和纵向虚线分别 表示坝段和高程.利用网格内的测点数据评价网格 区域的运行状态,参照专家为不同网格区域赋权重, 加权融合局部评价进行全局安全综合评判.



由于管理规范、仪器故障、环境变化、实际监测 需求等原因,测点空间分布存在变动;结构体运行期 间,监测数据动态变化,其数据特征也随着时间推移 而改变.现有的网格化监测网络划分方法依赖于人 工经验和设计资料,无法反映测点的空间特征(测点 空间分布)和时间特征(监测数据时序变化规律),根 据这种网络划分方法所得到的结果也就不能准确体 现结构体物理量的动态变化规律.此外,网格化划 分方法比较粗略,网格大小依赖于工程经验,不具有

普遍性.针对现有的网格化划分方法所存在的问题, 基于工程结构和受力的相似性,本文提出一种时序降 噪自动编码器(Time Series Denoising Autoencoder, TSDA),用于压缩高维监测数据,从而反映监测网 络的测点时空特征.基于测点监测数据时空特征,提 出一种基于测点时空特征的工程安全监测网络划分 算法 (Network Partitioning Algorithm based on Spatial-temporal Features, NPA),引入辅助目标变 量优化区域划分目标函数,对监测测点聚类,使监测 网络划分结果能够较好地反映大坝运行的物理规 律,如图2所示,不同虑线框所围起来的实心圆点对 应NPA所划分出的不同区域.从图2可以看出,相 较于网格化区域划分结果,NPA划分结果一是体现 了结构体的特征,所划分出的区域在水平方向上左 右对称,竖直方向上划分结果与坝段相对应,反映出 了某拱坝的结构特征与受力特征;二是体现了测点 的特征,NPA划分结果基本上将同一灰度颜色的实 心圆点(即同一类型的测点)划分到了同一区域中.



图2 基于测点特征的大坝区域划分示意图

本文结构如下:第2部分讨论传感网络划分方 法的相关研究工作,第3部分陈述问题描述,第4和 第5部分详细介绍基于时序降噪自动编码器的数据 时空特征表示及基于时空特征的监测网络划分算 法,第6部分进行实验验证与分析,最后总结全文.

## 2 相关工作

大量传感器广泛分布于大型土木工程结构体中,监测其运行过程中物理量变化.通常采用"分而 治之"的思想,根据监测网络中监测数据的时空特征 将其划分为若干个区域,把复杂的全局评判问题分 治到局部区域上.区域划分思想在图像处理、特征 选择、传感器网络、数据流聚类等场景中均有广泛应 用.在图片特征编码中,可利用平均区域划分法<sup>[3]</sup>将 图片划分为单独的区域块,对局部图像区域进行编 码,最终融合局部编码得到图片特征编码.基于子空间聚类的无监督特征选择方法<sup>[4]</sup>将样本表示到子空间,通过子空间聚类反映数据分布情况.针对传感器网络监测场景的准确性要求,采用分层聚合分类协议<sup>[5]</sup>,节点在本地进行事件分类并传输至汇点,构建聚合分类树得到事件分类结果.在无线传感器网络中依据节点特征和相关性将网络拓扑结构划分成多个区域,减少能耗,改善网络负载均衡<sup>[6]</sup>.文献[7]根据节点冗余部署特性构造差分模式树,利用骨干节点完成事件分类以减少计算成本和通信开销.聚合簇头节点监测数据能够快速对网络整体进行评判.基于区域划分的数据流子空间聚类方法<sup>[8]</sup>,考虑各维度上数据点的分布情况,以网格单元为基础进行区域划分,采用自底向上的策略得到最终聚类结果.

安全监测网络划分的本质是根据测点的监测数 据特征进行测点聚类,所得的区域内部测点特征相 似性高,区域间测点特征相异性高.传统聚类方法 主要有基于划分聚类、模糊聚类、基于层次聚类、基 于密度聚类等,应用最广泛的聚类算法包括K均值 聚类(K-Means)、高斯混合模型(Gaussian Mixture Model, GMM)<sup>[9]</sup>和模糊聚类分析等. K-Means 通过 迭代搜索优化K个质心的位置进行聚类.GMM和 模糊聚类学习出某种概率分布函数,给出样本属于 每个类别的概率, 传统聚类方法在处理高维数据 时,存在收敛时间长、聚类准确率低等问题.自动编 码器 (Autoencoder, AE)能够压缩高维数据(例如: 天文、气象、图片、长时间序列等)表示其特征[10-12]. 针对处理图片、文本等高维数据,深度聚类网络 (Deep Clustering Network, DCN)能够学习复杂的 概率分布函数[13],但是复杂网络结构和参数调整带 来额外开销.基于数据特征进行聚类的方法,目前 也有很多研究.判别式K均值聚类(DisKmeans)<sup>[14]</sup> 在K-means中加入线性判别分析(LDA),相较于Kmeans提高了聚类的性能.此外,同时考虑数据聚类 和特征提取任务,以提高聚类质量[15].但是, DisKmeans方法在处理高维数据时受限于线性嵌入 函数的性能.TAGnet<sup>[16]</sup>在聚类算法中加入两层稀 疏编码,使用交替学习的方式进行训练,稀疏编码的 推理复杂性使得此方法在对数据进行降维处理时忽 略数据的原始分布,从而降低聚类的性能.Yang等 人提出一个基于循环框架的聚类模型 JULE<sup>[17]</sup>,利 用卷积神经网络表示数据,通过凝聚聚类算法对数 据进行迭代聚类,并提出了一个统一的损失函数;但 由于需要调整大量超参数,这种方法并不适用于工 程中的聚类任务.

针对工程结构体监测数据具有高维、动态可变的特点,本文采用自动编码器提取测点时空特征,考虑测点空间位置和时间序列变化规律的相关性,引入辅助分布变量优化深度聚类目标函数,根据时空特征对测点聚类,实现监测传感器网络划分,能够较好地反映工程运行的物理规律.

## 3 问题陈述

设安全监测网络中包含测点总数为n,定义所

有测点集合 X = { $x_i | i = 1, ..., n$ },其中 $x_i \in \mathbb{R}^{d_x}$ 代表 测点原始特征,包括空间特征(位置坐标信息和测点 属性等)和时序特征(监测数据时间序列), $d_x$ 为时空 特征维数.监测网络划分过程如图3所示,通过编码 映射  $\varphi$ : X → Z 将测点原始特征映射至隐特征空间 (Latent Feature Space),得到原始时序特征和空间 特征表示 Z = { $z_i | i = 1, ..., n$ };然后基于隐特征数据  $z_i$ ,利用特征映射 $f_{\Theta}$ : Z → P计算测点 $x_i$ 属于区域 $r_j$ 的 概率 $p_{ij}$ ,其中 $\Theta$ 为参数集.



#### 图3 结构体区域划分过程

在测点原始特征中,空间特征多为静态属性,时 序数据是高维度、连续变化的.编码映射 $\varphi$ :X→Z 可以实现时序数据降维与特征表示.隐特征数据为  $z_i \in \mathbb{R}^{d_x}$ ,特征维数 $d_z \ll d_x$ ,其中 $z_i$ 由测点时序特征 与空间特征组成.自动编码器实现时序数据降维和 压缩,利用归一化方法处理测点空间特征数据.

因此,安全监测网络划分问题可等价于将n个测点划分到m个区域中,设最终划分得到的区域集 合为 $R = \{r_j | j = 1, \dots, m\}$ .利用公式(1)计算测点 $x_i$ 属于区域 $r_j$ 的概率 $p_{ij}$ .

$$p_{ij} = f(z_i, \Theta) = \frac{e^{\theta_j^T z_i}}{\sum_{j=1}^m e^{\theta_j^T z_i}}$$
(1)

采用Softmax激活函数( $f_{\Theta} = \frac{e^{x_i}}{\sum e^{x_i}}$ )计算概率,

其中 $\Theta = [\theta_1, \dots, \theta_m] \in \mathbb{R}^{d_i \times m}$ ,再利用梯度方法优化 参数.当 $p_{ij} = \max \{ p_{ij} | j = 1, \dots, m \}$ ,即 $p_{ij'}$ 为最大 概率时,测点 $x_i$ 被划分至单域 $r_j$ .

## 4 测点时空特征表示

#### 4.1 时序特征表示

测点监测时间序列数据为长度可变的一维序 列,具有周期性.为了完整地表示测点的时序特征 变化规律,选取超过一个观测周期(如一年)中的监 测数据作为样本.与低维、离散的测点空间特征不 同,监测数据时间序列为高维、连续变化值.受到测 点自身、环境和网络因素影响,时间序列中可能存在 大量异常值和缺失值等噪声数据,需要进行特征压 缩和降噪处理.

针对高维度、多噪声的测点时序数据,本文提出 一种时序降噪自动编码器(Time Series Denoising Autoencoder, TSDA),其结构如图4所示.为了增 强TSDA的抗噪能力,在训练过程中向样本数据集 中加入随机噪声数据.编码阶段利用卷积层 (Conv2D)和最大池化层(MaxPooling2D)实现时序 数据特征压缩表示,解码阶段采用与编码过程相对 的卷积层和上采样层(UpSampling2D)将压缩表示 重构为原始输入.TSDA的输入和输出相同,其目 标函数为重构误差,以此优化编码器和解码器.

(1)序列输入:选取测点 $x_i$ 长度为 $\lambda$ 时间序列 (已归一化) $T_{x_i} = [t_1, t_2, \dots, t_{\lambda}]$ ,为了便于后续卷积、 池化、上采样操作,通过Reshape操作将 $T_{x_i}$ 转变为 二维矩阵 $T'_{x_i}$ ,同时向 $T'_{x_i}$ 中加入高斯随机噪声,得到 TSDA输入.

(2)编码阶段:多个卷积层和最大池化层交替 堆叠,压缩输入数据得到特征表示.

(3)解码阶段:多个卷积层和上采样层交替堆 叠,将数据特征表示还原为重构输入.

(4)目标函数:原始输入和重构输入的误差作为 损失函数.

TSDA训练完成后保存权重,仅使用其中的编



图4 时序降噪自动编码器 TSDA

码器完成时间序列特征压缩表示.

设 $x_i$ 的时序特征(Feature of Time series, FT) 表示为 $FT_{x_i} = [ft_1, ft_2, \dots, ft_{t_x}], t_x$ 为时序特征维数, 且 $t_x \ll \lambda$ (TSDA具有降维作用).

#### 4.2 空间特征表示

测点空间特征数据包括位置坐标信息、测点重要程度、仪器类型等,利用归一化方法进行处理.记 $x_i$ 空间特征表示(Feature of Space, FS)为 $FS_{x_i}$ =

 $[fs_1, fs_2, \dots, fs_{s_x}], s_x$ 为特征维数.

## 4.2.1 位置坐标信息特征表示

测点原始空间位置由测量坐标系中经度(e)、纬 度(n)、高度(h)三个坐标值测定,通常数值分化较 大,且量纲单位不同,测点之间相对位置关系难以用 确定的量描述.通过去除量纲和大数值的影响,有 效保留测点相对位置信息,加快后续训练的收敛速 度.具体做法如下:

(1)统一量纲:通过坐标系内的单位换算,将坐标值量纲统一(通常将单位统一为米);

(2)非线性归一化:由于结构体所占空位范围 较大,导致各测点位置坐标数据分化大,利用函数  $y = sgn(x) \times \frac{\ln(|x|)}{\ln(\max|x|)}$ 进行转换,其中sgn(x)为 符号函数,避免某些坐标系中选择的坐标原点不同 而导致坐标值出现负值.

4.2.2 离散值和连续值特征表示

(1)离散值:通过One-Hot编码表示.如测点关注程度若分为重要、一般,则用两个状态位表示,对应编码为[0,1]和[1,0].

(2)连续值:利用非线性归一化表示.

#### 4.3 测点时空特征表示实例

测点时序特征动态变化,而空间特征为静态属性.结合某大坝实测数据,选择观测周期为2017-01-01至2017-12-31,利用TSDA将测点时序数据(已归一化,长度365)进行特征编码得到1×15的特征表示向量,以余弦相似度衡量时序特征编码相似性.以位于大坝中部的测点P04616(编号)为基准,与大坝其他测点进行比较.根据测点间空间位置信息不同,其时序特征编码存在以下情况:

(1) 空间位置不对称且距离较远:以测点 P04616与P00002、P07981为例,测点空间分布和时 间序列过程线如图5所示.三测点空间位置不相关, 相应过程线变化趋势、波动范围完全相异如图5(b) 所示.P04616与P00002、P07981时序编码余弦相似 度分别为-0.017和0.248,由此可见,空间特征差 异很大的测点,其时序编码相似度也很低.

(2)空间距离接近:以P04616 与P04615、 P04617为例,三者位于同一个观测间,所观测物理 量分别为位移、位移、压力.测点位置分布和对应的 时序过程线如图6所示.P04616和P04617观测物理 量不同,但时序过程线数值接近,变化趋势基本一 致,对应特征向量余弦相似度为0.991.P04615的过 程线则与P04616存在明显差异,两者余弦相似度为 0.266.因此,即便是空间距离接近的测点,其时间 序列数据相似性也存在差异.

(3) 空间位置对称:以P04616、P02023和 P06656为例,测点空间分布如图7(a)所示,P02023 和P06656在垂直方向上以P04616为中心对称.图 7(b)中P02023和P06656的过程线变化趋势相似, 相应的余弦相似度为0.831.P06656与P04616余弦 相似度为-0.134,特征差异大.结构体局部区域空





图 5 测点 P04616、P07981 和 P00002 时空特征比较





间结构和受力情况存在对称相似性,如拱坝中呈现 中心对称的两侧坝段.在空间位置上对称的两个测 点,其时序特征变化规律也会有强相似性.

从图5至图7可以看出,测点时序特征和空间特征相互影响.若仅利用时序特征划分易导致空间位置分散的测点被划分至同一区域,如P02023和



图 7 测点 P04616、P02023 和 P06656 时空特征比较

P06656. 若仅依据空间特征划分会导致时序特征相 异的点被划分至同一区域,如 P04616、P04615和 P04617. 因此,基于测点时空特征进行合理划分,得 到单个网络区域内聚程度高,分布相对均匀.

## 5 基于时空特征的监测网络划分

#### 5.1 划分目标

测点时序特征被时序降噪自动编码器 TSDA 表示为 $FT_{x_i}$ ,空间特征经过归一化等操作被表示为  $FS_{x_i}$ ,则特征映射为 $\varphi(x_i) = \{FT_{x_i}, FS_{x_i}\} = z_i$ ,将测 点原始特征映射到隐特征空间.记测点 $x_i$ 属于区域  $r_j$ 的预测概率为 $p_{ij}$ ,实际概率为 $q_{ij}$ .设 $p_{ij}$ 服从某种概 率分布  $\mathbf{P}, q_{ij}$ 服从某种概率分布  $\mathbf{Q}, 则 \mathbf{P}$ 为测点属于 区域概率分布的预测值, $\mathbf{Q}$ 为测点被划分至各区域的 实际概率分布.监测网络划分过程转化为优化参数 过程,采用最大期望值(Expectation-Maximization, EM)方法,使得预测分布  $\mathbf{P}$ 尽可能接近真实概率分 布  $\mathbf{Q},$ 即引入辅助变量  $\mathbf{Q}$ 来求解  $\mathbf{P},$ 因此  $\mathbf{P}$ 和  $\mathbf{Q}$ 具体 属于哪种概率分布并不会影响到预测分布  $\mathbf{P}$ 求解的 过程与结果.使用 KL 散度(KL-Divergence)描述预 测分布  $\mathbf{P}$ 与实际分布  $\mathbf{Q}$ 之间的距离,如公式(2) 所示;

$$KL(\mathbf{Q}/\!/\mathbf{P}) = \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log \frac{q_{ij}}{p_{ij}}$$
(2)

借助实际目标分布变量Q迭代地优化和加强区 域划分概率分布P,从而提高监测网络划分精度.为 了避免P陷入局部最优解(大多数测点被划分至少数 区域)和退化解(测点被错误划分至某区域),向实际 目标分布变量Q中加入正则项,设Q的经验分布为:

$$\Gamma_j = \frac{1}{n} \sum_{i=1}^n q_{ij} \tag{3}$$

式(3)中,Γ<sub>i</sub>代表区域划分结果中测点属于区域 r<sub>i</sub>的经验概率分布,将其加入目标中以增强区域划 分性能.设经验分布Γ的先验分布为H,若存在关于 区域划分的领域先验知识,可以利用任意分布来初 始化先验分布,如均匀分布、二项分布、高斯分布 等.定义目标函数为:

$$\begin{aligned} \mathcal{L} &= KL(\mathbf{Q}/\!/\mathbf{P}) + KL(\Gamma/\!/\mathbf{H}) \\ &= \left[\frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log \frac{q_{ij}}{p_{ij}}\right] + \left[\frac{1}{n} \sum_{j=1}^{m} \Gamma_{j} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}}\right]_{(4)} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \mathcal{K}(\mathbf{Q}/\!/\mathbf{P}) + \mathcal{K}(\Gamma/\!/\mathbf{H}) \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \mathcal{K}(\mathbf{Q}/\!/\mathbf{P}) + \mathcal{K}(\Gamma/\!/\mathbf{H}) \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \mathcal{K}(\mathbf{Q}/\!/\mathbf{P}) + \mathcal{K}(\Gamma/\!/\mathbf{H}) \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{q_{ij}}{p_{ij}} + q_{ij} \log \frac{\Gamma_{j}}{\mathbf{H}_{j}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{j=1}^{n} q_{ij} \log \frac{\Gamma_{j}}{p_{ij}} \\ &= \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{j=1}^$$

**Q**和预测概率分布**P**尽可能接近,第二项 $q_{ij}\log \frac{\Gamma_j}{\Pi}$ 

为正则项,平衡各区域中划分的测点数量,避免陷入 局部最优解和退化解.通过优化式(4)求解区域划 分概率分布 P.

#### 5.2 迭代求解

监测网络划分目标函数中包含隐变量(目标分 布Q、经验分布Γ及其先验分布为H),采用EM方法 迭代求解,具体步骤如下:

(1)固定参数估计目标分布

测点 $x_i$ 被划分至区域的概率之和为1,目标分 布**Q**满足概率约束 $\sum_{i=1}^{m} q_{ii} = 1$ .求偏导得:

$$\frac{\partial \mathcal{L}}{\partial q_{ij}} = \frac{q_{ij}}{\sum_{i=1}^{n} q_{ij}} + \log\left(\frac{q_{ij}\Gamma_j}{p_{ij}}\right) + 1 \tag{5}$$

令公式(5)偏导数为0,此时无法求出 $q_{ij}$ 的闭式 解 . 考虑到测点数量较多, *n*足够大时  $\lim_{n \to \infty} (q_{ij} / \sum_{i=1}^{n} q_{ij}) = 0, 移除第一项解得到式(6),$ 用于更新目标分布**Q**.

$$q_{ij} = \psi(p_{ij}, \Theta) = \frac{p_{ij} \left(\sum_{i'=1}^{n} p_{ij}\right)^{-\frac{1}{2}}}{\sum_{j'=1}^{m} p_{ij'} \left(\sum_{i'=1}^{n} p_{ij'}\right)^{-\frac{1}{2}}} \quad (6)$$

(2)固定目标分布更新参数

当目标分布已知时,通过梯度法更新参数集 $\Theta$ , 最小化标准交叉熵函数  $-\frac{1}{n}\sum_{i=1}^{n}\sum_{j=1}^{m} q_{ij}\log p_{ij}$ . 迭代 过程中交替执行上述两个步骤,直至收敛.

#### 5.3 区域划分算法

本文采用基于时空特征的区域划分算法 (Network Partitioning Algorithm based on Spatiotemporal Features, NPA),利用测点特征进行无监 督聚类,将测点划分到不同局部区域中,可以较好地 反映大坝运行的物理规律.

监测网络的测点特征集合 X =  $\{x_i | i = 1, ..., n\}$ 作为 NPA 算法的输入,测点属于各区域的概率分 布  $\{p_{ij} | i = 1, ..., n; j = 1, ..., m\}$ 作为输出.NPA 算法中需手动设定的超参数包括训练批次、最大 迭代次数、迭代误差阈值.NPA 利用测点时空进 行无监督聚类,无需指定区域数量 m,详细步骤见 算法.

**算法1.** 基于时空特征的区域划分算法 (NPA).

输入:测点特征集合X= $\{x_i | i = 1, \dots, n\}$ 

输出:测点属于各区域概率 { *p*<sub>ij</sub>|*i*=1,…,*n*; *j*=1,…,*n*;

1. 将测点原始特征映射到隐特征空间, φ: X→Z

2. 利用一种聚类算法初始化目标分布Q

3. WHILE NOT converged:

4. 固定目标分布  $\min_{\Theta} - \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{m} q_{ij} \log p_{ij}$ 更 新参数  $\Theta$ 

5. 计算测点属于区域的概率 $p_{ij} = f(z_i, \Theta)$ ,更新P

6. 固定参数,计算更新目标分布Q

7. END WHILE

8. RETURN{  $p_{ij}|i=1, ..., n; j=1, ..., m$  }

特征映射 φ: X→Z 通过时序降噪自动编码器 TSDA压缩表示测点时序特征,利用归一化方法表 示空间特征,即将测点原始特征映射至隐特征空 间.通常选择一种聚类算法(如K-Means、高斯混合 模型等)的结果初始化目标分布Q,避免随机初始化 的不确定性,加快收敛过程.由于Q是测点属于各 区域概率的实际分布,不同聚类算法初始化对其不 影响.EM方法迭代求解,由于目标分布Q已初始 化,第4行进行EM方法更新参数Θ和所求概率分 布P,接着固定参数更新目标分布Q.NPA返回测点 属于各区域的概率集合.

# 6 实验验证

#### 6.1 实验准备

6.1.1 数据集

#### (1)实测数据集

实测数据来源于某拱坝2017年1月1日至2017 年12月31日的工程安全监测数据,对其进行处理得 到约35万条测点数据记录,每条记录中包含测点时间 序列数据和空间特征(测点空间坐标信息、仪器类型、 受力信息等).该大坝包含964个测点,观测的物理量 包括应力、压力、位移、开合度、沉降渗流、温度等.

#### (2)公开数据集

实验所用公开数据集来自Keras框架<sup>[18]</sup>和UCI 机器学习数据库<sup>[19]</sup>. 详见表1.

表1 实验所用公开数据集

数据集	数据量/条	属性/个	类别/类	说明
MNIST	70000	$28 \times 28$	10	手写数字图片数据集
Fashion-MNIST	70000	28×28	10	时尚物品图片数据集
CIFAR-10	60000	$32 \times 32 \times 3$	10	彩色图片数据集
Reuters	11228	\	46	新闻文本数据集

## 6.1.2 基准方法

对 K 均值聚类(K-Means)和高斯混合模型 (Gaussian Mixture Model)加入自动编码器(AE)进 行改良后作为基于时空特征的区域划分算法 (NPA)的基准方法.在公开数据集上实验时,使用 AE+K-Means、AE+GMM,以及普通深度聚类网 络(Deep Clustering Network, DCN)作为对比,同时 也保留 K-Means 以及 GMM 的实验结果;在大坝实 测数据集上实验时,由于在 NPA 中采用时序降噪自 动编码器(TSDA)提取特征,进一步将 K-Means 和 GMM 改良为 TSDA+K-Means 和 TSDA+GMM 作为对比.

### 6.1.3 实验与评价指标

基于上述方法进行实验:

(1)公开数据集实验:采用聚类准确率(Accuracy, ACC)、标准互信息(Normalized Mutual)

Information, NMI)和调整兰德系数(Adjusted Rand Index, ARI)评估聚类性能.

聚类准确率 ACC 和标准互信息取值范围 [0,1],越大表示聚类准确率越高.调整兰德系数取 值范围[-1,1],负值表示聚类性能差,1表示最佳 聚类性能.

(2)实测数据集实验:选择TSDA+K-Means、 TSDA+GMM和NPA在大坝实测数据集上进行实 验,采用轮廓系数(Silhouette Coefficient, SC)、CH指标(Calinski-Harabaz Index, CH)评估区域划分性能.

轮廓系数SC量化测点分布情况,SC∈[-1,0) 表示区域划分性能基本错误,0代表陷入局部最优 解,SC∈(0,1]时取值越高表明测点分布越合理和 均匀.CH指标衡量区域内聚程度,取值越大表明内 聚程度越高.

实验内容如表2所示.

表2 实验内容表

实验内容	数据集	基准方法	评价指标	
公开数据集实验	MNIST	AE+K-Moons	NCC	
	Fashion-MNIST	AE+GMM	NMI	
	CIFAR-10	DCN	ARI	
	Reuters			
实测数据集实验	某拱坝2017年全年工程安全	TSDA+K-Means	SC	
	监测数据	TSDA+GMM	СН	

#### 6.2 公开数据集实验结果

选用现有方法K-Means、AE+K-Means、 GMM、AE+GMM和本文方法NPA在公开数据集 MNIST、Fashion-MNIST、CIFAR-10、Reuters上进 行实验.评价指标为聚类准确率ACC、标准互信息 NMI和调整兰德系数ARI,分别代表聚类正确程度、聚类结果含真实信息量和聚类纯度.实验结果如表3所示.

6.2.1 自动编码器对聚类性能影响

K-Means 在 MNIST、Fashion-MNIST、CIFAR-

表3 公开数据集实验结果							
数据集	指标	K-Means	AE+K-Means	GMM	AE+GMM	DCN	NPA
MNIST	ACC	0.732	0.887	0.716	0.863	0.813	0.910
	NMI	0.627	0.812	0.637	0.827	0.729	0.876
	ARI	0.541	0.791	0.537	0.762	0.614	0.837
Fashion-MNIST	ACC	0.587	0.613	0.495	0.601	0.590	0.635
	NMI	0.567	0.607	0.494	0.582	0.576	0.652
	ARI	0.405	0.524	0.321	0.478	0.453	0.563
	ACC	0.489	0.557	0.472	0.523	0.521	0.832
CIFAR-10	NMI	0.432	0.531	0.462	0.505	0.492	0.778
	ARI	0.378	0.470	0.417	0.489	0.436	0.691
Reuters	ACC	0.521	0.762	0.534	0.638	0.607	0.782
	NMI	0.312	0.537	0.371	0.482	0.446	0.674
	ARI	0.218	0.438	0.339	0.443	0.386	0.591

10、Reuters上的分类准确率分别为0.732、0.587、 0.489、0.521,AE+K-Means的ACC取值分别为 0.887、0.613、0.557、0.762.自动编码器(AE)将K-Means的聚类准确率分别提高21.2%、4.4%、 13.9%、46.3%.从整体上看,K-Means逊于AE+K -Means.

GMM 在四个数据集上的分类准确率分别为 0.716、0.495、0.472、0.534, AE+GMM 的 ACC 取 值分别为 0.863、0.601、0.523、0.638, AE将 GMM 准确率分别提高 20.5%、21.4%、10.8%、19.5%.

普通深度聚类网络 DCN 与使用自动编码器的 AE+K-Means、AE+GMM 相比较,整体性能 DCN <AE+GMM<AE+K-Means. DCN 仅在 Fashion-MNIST (ACC 为 0.590 和 0.601, NMI 为 0.576 和 0.582)和 CIFAR-10(ACC 为 0.521 和 0.523)上与 AE+GMM 稍微接近,但仍逊于 AE+GMM.

自动编码器能显著提高K-Means和GMM在四个数据集上的聚类准确率,对于评价指标NMI和ARI,AE仍能提升性能指标数值.MNIST、Fashion-MNIST、CIFAR-10为图片数据,Reuters为文本单词向量数据,图片和文本特征都是高维数据.AE将能够有效压缩高维特征数据,避免原始高维度数据在计算过程中出现的各种误差,同时低维度压缩特征也能够加快算法收敛过程.

6.2.2 NPA聚类性能分析

以 MNIST 为例, AE+K-Means、AE+GMM 和 NPA 的分类准确率 ACC 分别为 0.887、0.863、 0.910, 标 准 互 信 息 NMI 分 别 为 0.812、0.827、 0.876, 调整兰德指数分别为 0.791、0.762、0.837. AE+K-Means、AE+GMM 和 NPA 都采用自动编 码器进行特征压缩表示,因而能够获得更好的聚类性能.表4列出NPA与AE+K-Means、NPA与AE+GMM的详细对比.

表4 NPA与AE+K-Means和AE+GMM性能比较

粉捉住	北标	NPA vs AE+K-	NPA vs	
奴16未	1日 1小	Means	AE+GMM	
	ACC	2.6%	5.4%	
MNIST	NMI	7.9%	5.9%	
	ARI	5.8%	9.8%	
	ACC	3.6%	5.7%	
Fashion-MNIST	NMI	7.4%	12.0%	
	ARI	7.4%	17.8%	
	ACC	49.4%	59.1%	
CIFAR-10	NMI	46.5%	54.1%	
	ARI	47.0%	41.3%	
	ACC	2.6%	22.6%	
Reuters	NMI	25.5%	39.8%	
	ARI	34.9%	33.4%	

从表4中可看出,在全部四个数据集上,NPA 的分类准确率ACC、标准互信息NMI和调整兰德 系数ARI均有所提高.ACC衡量数据被正确划分到 相应类别的程度,NPA准确率均高于AE+K-Means和AE+GMM.NMI代表算法聚类结果包含 真实聚类结果的信息量,NPA聚类结果较其余两个 方法包含更多聚类信息.ARI越大表示聚类效果准 确性和类内纯度越高,NPA在此方面同样有所提 升.总的来说,NPA在聚类准确性、聚类真实信息 量和聚类纯度等三个方面都优于AE+K-Means和 AE+GMM.

#### 6.3 实测数据集实验结果

大坝测点空间分布正视图如图8所示,实心圆

点代表测点.坝顶测点数量相对少,呈现均匀分布. 坝肩测点数量较稀疏,大坝两侧山体受力不同导致 两侧坝肩测点分布不对称.图中竖直虚线划分坝 段,测点沿坝段密集分布.在垂直方向,测点从大坝 两侧到中间,测点分布逐渐增加.位于大坝中间的 测点受力变化幅度较大,其位移、变形、应力等物理 量变化存在相关性.坝基测点数量较多,监测大坝 沉降、压力、渗流等物理量.坝基从两侧至中间,测 点分布由稀疏变为稠密.坝踵位于大坝中间底部, 其受力情况对大坝整体结构安全起关键作用,故而 测点分布密集.



图8 大坝测点空间分布图

根据大坝安全监测设计规范,同一坝段(虚线)、 坝基、坝踵的测点密度大,多数测点间相关性高,所 划分的区域内聚性应尽量高.坝顶和两侧坝肩测点 分散,所划分的区域范围相应较大.此外,图8中大 坝整体结构对称,安全监测网络划分结果也应呈现 对称效果.

NPA采用TSDA提取测点时序特征,采用修改后的TSDA+K-Means和TSDA+GMM进行对比实验.NPA属于无监督聚类,无需预设区域数量 m.TSDA+K-Means和TSDA+GMM需要预先设定待划分区域数量,利用Canopy算法和Affinity Propagation聚类算法进行估计为51和53,大坝相关人员估计其为48,取三者中位数设定m=51.

基于大坝2017年实测数据,NPA、TSDA+K-Means和TSDA+GMM对964个测点进行区域划分,实验结果如图9所示.

图9中测点灰度着色表示不同区域,属于同一 区域的测点颜色相同.从整体上看,TSDA+NPA 所划分各区域以大坝中心对称.同一坝段、坝基、 坝踵中的区域高内聚;坝顶和坝肩测点相对分散, 所划分的区域范围大,测点分布合理.TSDA+K-Means和TSDA+GMM所划分区域整体上不对



(a)NPA划分结果



(b)TSDA+K-Means划分结果



(c)TSDA+GMM划分结果

图9 某拱坝采用三种方法监测网络划分结果

称.同一坝段、坝踵测点常被划分至多个区域,内 聚程度差.坝顶与坝段中的区域存在交叉,测点分 布不合理.

以轮廓系数SC量化测点分布情况,CH指标衡量区域内聚程度,两者取值越大则相应性能越好. 计算NPA、TSDA+K-Means和TSDA+GMM的平均SC和CH指标,如表5所示.

表5 TSDA+K-Means、TSDA+GMM和NPA实测结果

指标	TSDA+K-Means	TSDA+GMM	NPA
SC	0.502	0.548	0.795
СН	580.7	717.1	938.3

如表5所示,NPA的SC和CH指标均显著高于 TSDA+K-Means和TSDA+GMM. 三种方法的轮 廓系数均在(0,1]区间内,NPA的SC较TSDA+K-Means 和 TSDA+GMM 分别提高45.1%和 58.4%,表明NPA的区域划分结果更好. 在CH指标上,NPA以30.8%和61.6%的幅度领先,说明其 划分的区域内聚程度高,单域内测点相关性高,单域 间相关性低.表5所表达的结果与图9所示一致, NPA的区域划分结果在区域内聚和测点分布上均 优于TSDA+K-Means和TSDA+GMM.

#### 6.4 实验结论

在公开数据集 MNIST、Fashion - MNIST、 CIFAR-10、Reuters上进行实验验证,NPA采用自动编码器方法提取测点时序特征,可以有效避免处 理高维度数据引起的误差.实验结果表明自动编码器(AE)对经典聚类方法K-Means和GMM的聚类 准确率、类内聚程度和样本分布上均有提升.同时, NPA在各个性能指标均领先AE+K-Means、AE+ GMM和DCN.

对于大坝实测数据集,进行监测网络区域划分 实验.NPA根据测点数据特征分布,自动设置区域; TSDA+K-Means和TSDA+GMM则需要结合人 工设定和算法估计,设定区域数量,不具备一般性. 以轮廓系数SC和CH指标分别衡量整体划分效果 和区域内聚性,NPA算法的SC和CH均优于 TSDA+K-Means和TSDA+GMM,其监测网络区 域划分效果更好.

## 7 总 结

为了使工程安全监测网络划分能够及时反映结 构体物理量动态变化规律,针对结构工程局部区域 结构和受力的相似性,测点监测数据之间的相关性, 本文提出时序降噪自动编码器(TSDA),压缩高维 监测数据表征测点数据时空特征.在此基础上,采 用基于测点时空特征的监测网络划分算法(NPA), 引入辅助目标变量优化区域划分目标函数,使监测 网络划分结果反映工程运行物理规律,将全局安全 评判问题分治到多个局部单域上.实验结果表明, 提出的基于测点时空特征的监测区域划分算法可以 得到较好的工程安全监测网络划分结果,及时响应 结构体物理特征变化. **致 谢** 感谢华能澜沧江水电股份有限公司提供实 测监测数据与工程专业知识.

#### 参考文献

- [1] Zheng Fu-Gang, You Qiang-Qiang. Multi-level fuzzy comprehensive dam safety evaluation method based on dam safety monitoring systems. Journal of Hohai University (Natural Science), 2011, 39(4): 407-414 (in Chinese) (郑付刚,游强强.基于安全监测系统的大坝安全多层次模 糊综合评判方法.河海大学学报(自然科学版), 2011, 39 (4):407-414)
- [2] Zhu Zhao-Hui, Liu Jian, Li Xin. Statistical model analysis of dam deformation monitoring based on robust estimation. Journal of China Institute of Water Resources and Hydropower Research, 2018, 16(2): 28-35 (in Chinese) (朱赵辉, 刘健, 李新. 基于稳健估计的大坝变形监测统计模 型分析.中国水利水电科学研究院学报, 2018, 16(2): 28-35)
- [3] Wan Yuan, Shi Ying, Wu Ke-Fang, Chen Xiao-Li. Laplacian sparse coding by incorporating locality and non-negativity for image classification. Pattern Recognition &. Artificial Intelligence, 2017, 30(6): 481-488 (in Chinese)
  (万源,史莹,吴克风,陈晓丽.融合局部性和非负性的 Laplacian稀疏编码的图像分类.模式识别与人工智能, 2017, 30(6): 481-488)
- [4] Zhu Peng-Fei, Zhu Wen-Cheng, Hu Qing-Hua, Zhang Chang-Qing, Zuo Wang-Meng. Subspace clustering guided unsupervised feature selection. Pattern Recognition, 2017, 364-374
- [5] Jiang Wen-Jun, Miao Cheng-Lin, Su Lu, Li Qi, Hu Shao-Han. Towards quality aware information integration in distributed sensing systems. IEEE Transactions on Parallel and Distributed Systems, 2018, 29(1): 198-211
- [6] Yang Hao, Wang Xi-Wei. Data Gathering Based on Regionalized Compressive Sensing in WSN. Chinese Journal of Computers, 2017, 40(8): 1933-1945 (in Chinese) (杨浩,王喜玮.基于区域化压缩感知的无线传感器网络数 据收集方法.计算机学报, 2017, 40(8): 1933-1945)
- [7] Bhuiyan M Z A, Wu J, Weiss G M. Hayajneh T, Wang T, Wang G J. Event detection through differential pattern mining in cyber-physical systems. IEEE Transactions on Big Data, 2017, doi: 10.1109/TBDATA.2017.2731838
- [8] Yu Xiang, Yin Gui-Sheng, Xu Xian-Dong, Wang Jian-Wei. A data stream subspace clustering algorithm based on region partition. Journal of Computer Research and Development, 2014, 51(1):88-95 (in Chinese)
  (于翔,印桂生,许宪东.一种基于区域划分的数据流子空间 聚类方法.计算机研究与发展, 2014, 51(1):88-95)
- [9] Zivkovic Z. Improved Adaptive gaussian mixture model for background Subtraction//Proceedings of the17th International

Conference on Pattern Recognition(ICPR). Cambridge, UK, 2004:1-4

- [10] Klampanos I A, Davvetas A, Andronopoulos S., Autoencoder-driven weather clustering for source estimation during nuclear events. Environmental Modelling & Software, 2018, 102;84-93
- [11] Dizaji K G, Herandi A, Deng C, Cai W, Huang H. Deep clustering via joint convolutional autoencoder embedding and relative entropy minimization. //Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy, 2017; 1-13
- [12] Mikalsen K, Bianchi F M, Soguero-RuizC, Jenssen R. Time series cluster kernel for learning similarities between multivariate time series with missing data. Pattern Recognition, Apr. 2018, 76: 569-581
- [13] Hershey J R, Chen Z, Le Roux J, et al. Deep clustering: Discriminative embeddings for segmentation and separation [C]//Proceedings of 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Shanghai, China, 2016: 31-35
- [14] Ye J, Zhao Z, Wu M, et al. Discriminative K-means for



MAO Ying-Chi, Ph. D. professor, CCF senior member. Her research interest includes distributed computing and parallel processing, IoT, and edge intelligence computing. Clustering [C]//Proceedings of Twenty-First Annual Conference on Neural Information Processing Systems (NIPS 2008). Vancouver, B.C., Canada, 2008: 1649-1656

- [15] Wang D, Nie F, Huang H. Unsupervised feature selection via unified trace ratio formulation and k-means clustering (track) [C]//Proceedings of Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin, Germany, 2014: 306-321
- [16] Wang Z., Chang S., Zhou J., Wang M., and Huang T. S.. Learning a task-specific deep architecture for clustering.[C]// Proceedings of 2016 SIAM International Conference on Data Mining(SDM).Miami, USA,2016: 369-377
- [17] Yang J., Parikh D., and BatraD.. Joint unsupervised learning of deep representations and image clusters. [C]//Proceedings of 29th IEEE Conference on Computer Vision and Pattern Recognition(CVPR).Las Vegas, USA, 2016: 5147-5156
- [18] Chollet, F, et al. (2015) Keras, https://github.com/fchollet/ keras
- [19] Dua, Graff, C.D. (2019). UCI Machine Learning Repository. Irvine, CA: University of California, School of Information and Computer Science[http://archive.ics.uci.edu/ml]

**CHENG Yang - Kun**, M. S. candidate. His research interest includes IoT and edge intelligence computing.

**QI Hai**, M. S. candidate. His research interest includes IoT and edge intelligence computing.

#### Background

There are more large-scale civil buildings all over the world, such as bridges, signal towers, dams, tunnels, etc. It's necessary to evaluate the global safety of the civil structures. Many various types of sensors have been deployed to monitor the deformation, stress, and stain in the huge civil engineering. It is difficult to directly evaluate the operation status of the engineering based on the massive monitoring data. In real applications, divide and conquer strategy is adopted. The sensor network is divided into multiple regions according to the design specifications, simulation data, and engineering experience. The local results from sub-regions are integrated to achieve overall evaluation. However, it ignores the spatial distribution of sensors and the variation of time series, which cannot meet the real-time evaluation for the engineering safety monitoring. In order to the network partitions can timely reflect the dynamic changes of engineering structure, it should consider the similarity of structure and force in the local area of the engineering, and the correlation among the monitoring data. A Time Series Denoising Autoencoder (TSDA) is proposed to represent the spatial and temporal characteristics of the node by compressing high-dimensional monitoring data. Then, a Network Partitioning Algorithm based on Spatiotemporal Features (NPA) based on TSDA is presented. NPA ensures that the partition results can reflect the physical change laws by introducing the auxiliary objective variable to optimize the network partition objective function. Experimental results on the open data sets and a real data set from an arch dam demonstrate that the proposed network partition algorithm NPA can achieve better partition performance. The NPA can improve Silhouette Coefficient 45.1% and 58.4% higher than the TSDA+K-Means and TSDA+GMM, respectively. In the Calinski-Harabaz Index, the NPA can increase by 30.8%and 61.6%, respectively.