

基于流形学习的多源传感器体域网数据融合模型

张 俊 王 杨 李坤豪 李 昌 赵传信

安徽师范大学计算机与信息学院 安徽 芜湖 241003 (24991617@qq.com)



摘 要 无线体域网多传感器由于采集的数据量大、数据类型冗杂,难以有效进行多维度数据的融合。虽然传统流形及分解类型的数据融合方法(Isomap, MDS, PCA等)具备使距离较小点产生合理排斥梯度的能力和受异常影响较小的优点,但是针对无 线多传感器体域网的数据降维效果并不理想。对此,提出了一种基于流形学习的 T 分布式随机邻域嵌入(T-SNE)算法对多传 感器体域网数据进行融合。T-SNE 算法首先将高维数据点与其对应的低维数据点间的欧氏距离转换为条件概率矩阵,然后对 处理好的低维概率集合进行有限次迭代,最后更新低维概率矩阵,使距离较小点间产生合理的排斥梯度,从而构建了多维度体 域网数据融合模型。实验结果表明,在特定的体域网数据集下,T-SNE 算法的精度为 Isomap 的 1.11 倍, MDS 的 1.33 倍, PCA 的 1.21 倍,具有较好的数据降维效果。

关键词:流形学习;数据融合;传感器;体域网

中图法分类号 TP393

Multi-source Sensor Body Area Network Data Fusion Model Based on Manifold Learning

ZHANG Jun, WANG Yang, LI Kun-hao, LI Chang and ZHAO Chuan-xin School of Computer and Information, Anhui Normal University, Wuhu, Anhui 241003, China

Abstract Due to the problem of large amount of data collected by multi-sensors in wireless body area networks and redundant data types, it is difficult to effectively perform multi-dimensional data fusion. Although traditional manifold and decomposition data fusion methods (Isomap, MDS, PCA, etc.) have the ability to generate a reasonable rejection gradient at a small distance and are less affected by anomalies, the data dimension reduction effect for wireless multi-sensor volume domain networks is not ideal. Therefore, this paper proposed the T-SNE algorithm based on manifold learning to fuse multi-sensor body area network data. The T-SNE algorithm first converts the Euclidean distance between a high-dimensional data point and its corresponding low-dimensional data point into a conditional probability matrix, then iterates the processed low-dimensional probability set a finite number of times, and finally updates the low-dimensional probability matrix to make the distance more reasonable exclusion gradient be generated between the small points, and a multi-dimensional body area network data fusion model is constructed. Experimental results show that compared with the traditional manifold reduction algorithm and traditional decomposition dimensionality reduction algorithm under a specific body area network data set, the T-SNE algorithm has a precision of 1.11 times that of Isomap, 1.33 times that of MDS, and 1.21 times that of PCA, achieves a better data dimensionality reduction effect.

1 引言

随着社会经济的发展和生活水平的不断提高,人们开始 追求更加健康的美好生活。体域网作为一种提升生活品质的 方案,开始融入人们的现实生活。体域网将传感器节点部署 在人体的不同部位,用于采集人体各项指标、运动状态等能够 反映人体健康状态的数据,并通过数据分析等方法对人体健 康状态进行实时监测。但是,体域网中复杂多源的数据类型 为后续数据处理带来了极大的困难。因此,对多传感器采集 的数据进行快速有效的融合成为了当前研究的热点之一。

通信作者:王杨(wycap@126.com)

到稿日期:2019-10-08 返修日期:2020-04-12 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61871412);安徽省自然科学基金重点项目(KJ2019A0938);安徽省社科规划项目(AHSKY2017D42);安徽省高校 优秀青年人才支持计划一般项目(gxyq2017140);安徽省质量工程重大项目(2018jyxm0342);安徽省教育厅项目(gxyqZD2016593)

This work was supported by the National Natural Science Foundation of China (61871412), Natural Science Foundation of Anhui, China (KJ2019A0938), Scientific Research Fundation of the Education Department of Anhui Province, China (AHSKY2017D42), General Project of Anhui University Excellent Young Talents Support Plan (gxyq2017140), Anhui Province Quality Engineering Major Project (2018jyxm0342) and Anhui Province Department of Education Project (gxyqZD2016593).

多传感器体域网数据主要包括人体各类器官及稳态系统 所产生的数据(包括心率、温度、脉搏、血压、血氧和运动数据 等)。一般来说,用户对这些数据单独进行采集分析,通过数 据自身的特征即可有效推测身体健康水平。而在体域网环境 中则使用多传感器无线网络进行数据采集,由于传感器类型 较多,采集的数据易受外部噪声影响,且设备自身性能具有局 限性,采集到的数据普遍具有数据维度大、冗余数据多等特征。

降维,是处理高维数据的一种有效且普遍的方法。通过 降低高维数据的维数,可以有效地减少数据量,提高数据处理 的速度。流形学习是目前数据降维的常用方法之一。一般的 流行学习降维方法是将低维数据流形嵌入高维空间,但这种 处理方法难以在高维空间直接计算两点间的直线距离,计算 过程也带有误导性和不准确性。考虑体域网中的数据特点, 本文主要采用流形学习中的 T-SNE 数据降维方法,在合理处 理数据点之间距离的前提下,将体域网中采集到的大量高维 数据降至二维或三维,为后期数据的高效处理与分类提供了 可能,同时也便于数据的可视化。

2 相关工作

针对具有流形学习特性的数据融合问题,国内外研究人员开展了许多研究工作,并提出了可行的解决方案。

如何将数据进行流形嵌入,是流行学习需要解决的首要 问题。针对这一问题,Cheng等^[1]提出了一种过采样流形嵌 入方法,该方法中的统一计算框架能够减少流形嵌入空间到 原始数据空间反映射的计算代价和模式分类成本。Huang 等^[2]采用稀疏表示方法求出样本的稀疏系数,并选取来自同 一流形的点作为近邻点,然后构建相似图来表征多流形结构, 从而提升分类性能。Talmon等^[3]在引入潜在多传感器观测 的共同流形模型的基础上,提出并分析了一种基于交替扩散 的数据融合方法。

为了对数据降维方法进行良好的设计, Chen 等^[4]提出了 一种基于自适应密度聚类的非线性流形学习降维方法, 并利 用 MATLAB 设计实现了相关算法, 降维效果良好。Chen 等^[5]利用小波技术消除已收集数据的高斯白噪声并对数据进 行压缩; 同时利用最大、最小贴近度计算传感器数据的信噪 比, 并通过信噪比进行数据融合。

在多传感器数据采集方面,Le等^[6]提出了一种基于无线体域网远程生理参数采集的应用问题,利用 Zigbee 短距离无线通信方式实现体域网内通信和生理参数数据的采集,通过TCP/IP 通信方式实现生理参数的远程采集。Quwaider等^[7]提出了一种基于云的高效数据采集系统,使无线体域网的大规模监视数据以可靠的方式为最终用户或服务提供商应用。Liu等^[8]利用身体区域纳米网络将纳米传感器分布在人体中以测量各种身体参数(如血液中的葡萄糖、胆固醇和感染因子),收集相关的数据,并将这些数据传输到外部实体供进一步使用。

在 T-SNE 算法研究方面, Pezzotti 等^[9]引入了可控制的 T-SNE 近似算法(A-tsne),提高了速度和精度,实现了交互式 数据探索,并提供了实时可视化技术(包括基于密度的解决方 案和魔术镜头)来检查近似程度。Nguyen 等^[10]提出了"m-TSNE":将高维 MTS 数据投影到低维(二维或三维)空间,以 捕获基础数据属性,并可视化高维 MTS 数据。Han 等^[11]提出了一种多线性(N维)Tensor 监督邻域嵌入(称为 ND-TSNE)来判别特征表示,用于基于视图的对象识别。

3 相关理论

3.1 流形学习及 T-SNE 算法

流形是拓扑学中的概念,表示一个局部有欧几里德特性的拓扑空间。流形的本质是从拓扑空间的一个开集(邻域)到 欧氏空间的开子集的同胚映射,从而实现局部空间坐标 化^[12]。流行降维的普遍思路是:对于具有多维和多级特征的 数据,将低维流形嵌入该数据的高维空间中,试图在高维空间 中具有欧几里德特性的局部空间上建立降维映射关系,并且 将局部映射关系扩展到整个数据空间,以对其进行维度转换。 在此过程中,分类器不断学习训练集的高维数据,以合理预测 其低维分布。

在一般的线性降维算法中,通过变换函数把高维空间中 的数据在低维空间中重新进行映射表示;而在非线性流形降 维算法中,必须首先假设高维数据中存在一个流形结构。因 此,针对不同类型的数据,需要做出不同的假设。

线性降维算法是一种基于线性的高维空间到低维空间的 映射,其主要目的是训练学习并得出一个矩阵变换,将这个矩 阵与高维数据相乘以得到低维数据。常见的线性降维算法有 主成分分析(Principal Component Analysis, PCA)和线性判别 式分析(Linear Discriminant Analysis, LDA)等。

非线性降维算法则假设在高维空间中数据会呈现一种有 规律的低维流形排列,但是这种规律排列不能直接通过高维 空间的整体欧氏距离衡量。然而,高维度的数据排列规律却 可能在局部仍然具有欧氏空间的性质。基于这种假设,非线 性降维可以通过高维空间内的局部关系在低维空间中重新排 列,从而形成全新的低维数据点分布^[13]。常见的非线性降维 算法有等度量映射(Isometric Map,ISOMAP)和局部线性嵌 入(Locally Linear Embedding,LLE)等。

原始的 SNE 算法将高维和低维的样本分布视为高斯分 布,将欧氏距离转换为条件概率来表达点与点之间的相似度。 此方法的梯度计算复杂,且数据之间排布过于紧密,易产生 "拥挤问题"。

T-SNE 是由 SNE 算法衍生出的一种用于非线性降维的 算法,其将流形中的高维样本数据视为高斯分布,将低维样本 视为 T 分布。T-SNE 将欧氏距离转换为条件概率来表示点 与点之间的相似度,从而能够以概率分布的角度在高维空间 的局部建立降维映射关系,实现流形降维。其优势是改变了 传统流形算法中数据点间距离不变的概念,适用于将高维数 据降至二维或三维。通过二维或三维点对每个高维数据对象 进行建模,并通过附近点对近似点对象进行建模,针对不近似 的对象,则由远点以高概率方式建模。在将数据从高维映射 到低维时,T-SNE 确保了数据间的分布概率不变,并且将低 维度中的坐标视为 T 分布,这样做的优点是扩大了距离较远 的簇之间的距离,从而解决了拥挤问题。

3.2 体域网

人体局域网(Body Area Network, BAN), 简称体域网, 是 由人体各组织器官网络与多传感器网络共同构成的一种结合 医疗、传感网和数据处理的可长期监视和记录人体健康状况 信号的新兴技术。无线传感器网络(Wireless Sensor Networks,WSN)和延迟容忍网络(Delay Tolerant Network, DTN)是体域网的两大组成部分^[14]。BAN技术的基础是人 体感知,利用人体体征传感器将物理参数转换为电信号。这 些传感器可以分为3种类型:生理传感器,能够测量血压、血 糖、体温、血氧、心电、脑电和肌电等;生物动力学传感器,测量 加速度和人体移动产生的角速度等;环境传感器,能够测量湿 度、亮度、声音和温度等^[15]。体域网的基本结构如图1所示。



Fig. 1 Multi-sensor body area network

作为一门多学科融合的新兴技术,BAN 从诞生起就引起 了学术界和产业界的强烈兴趣。其在许多领域具有巨大的应 用潜力,如远程健康、军事、人身安全、体育竞技和游戏^[16]。 但是,BAN 的研究仍处于理论阶段,要实现广泛应用,还需要 克服很多困难^[17]。

4 数据融合模型

4.1 T-SNE 数据融合模型

针对 SNE 难以解决的数据点间的拥挤问题和优化问题, T-SNE 在低维空间下使用 T 分布来扩大距离较远的簇之间 的距离。

传统的 SNE 算法的高维分布概率为:

$$P_{j|i} = \frac{\exp(-\|X_i - X_j\|^2 / 2\sigma_i^2)}{\sum_{i \neq i} \exp(-\|X_i - X_k\|^2 / 2\sigma_i^2)}$$
(1)

其中,数据点 x_i 和 x_j 之间的高维分布概率为 $p_{j|i}$, σ_i 是以数据点 x_i 为中心的高斯方差。

低维中的分布概率矩阵计算如下:

$$\boldsymbol{q}_{j|i} = \frac{\exp(-\parallel y_i - y_j \parallel^2)}{\sum_{j \neq i} \exp(-\parallel y_i - y_k \parallel^2)}$$
(2)

其中,高维数据点 x_i 和 x_j 的低维对应点为 y_i 和 y_j ,通过 y_i 和 y_i 可以计算类似点低维中的分布概率矩阵 q_{ij_i} 。

采用 KL 散度可以计算两个不同概率分布之间的差距 C:

$$C = \sum_{i} KL(P_i \parallel Q_i) = \sum_{i} \sum_{j} p_{j|i} \log \frac{p_{j|i}}{q_{j|i}}$$
(3)

并以此计算梯度为:

$$\frac{\partial C}{\partial y_i} = 2\sum_j (p_{j|i} - q_{j|i} + p_{i|j}) (y_i - y_j)$$
(4)

可通过以下步骤构建 SNE:首先,在高维空间构建一个 数据对象间的概率分布,使相似的数据有更高的概率被选中, 而不相似的数据被选中的概率较低;其次,在低维空间下继续 构建这些点的概率分布,使得这两个概率分布尽可能地相似。

T-SNE 在高维分布下也使用高斯分布,而在较低维度分

布下则与 SNE 不同,采用更一般的 T 分布。与对称 SNE 类 似,T-SNE 也是以 Y 轴呈对称分布。在 T-SNE 算法下计算 得到低维分布概率矩阵:

$$I_{i|j} = \frac{(1+ \parallel y_i - y_j \parallel^2)^{-1}}{\sum\limits_{k \neq 1} (1+ \parallel y_i - y_j \parallel^2)^{-1}}$$
(5)

所计算出的梯度为:

$$\frac{\partial C}{\partial y_i} = 4 \sum_j (p_{ij} - q_{ij}) (y_i - y_j) (1 + || y_i - y_j ||^2)^{-1}$$
(6)

下面介绍 T-SNE 算法的详细过程。

首先,将高维数据 Data 表示为:

$$Data: X = x_1, \cdots, x_n \tag{7}$$

进而计算代价函数 cost function 的参数:困惑度 Perp。 之后需要对参数进行优化:主要设置迭代次数 T、学习速率 η 和动量 $\alpha(t)$; Y^T 为迭代 T 次后对应的低维数据表示。目标结 果的低维数据表示为:

$$Data: \mathbf{Y}^{T} = (Y_{1}, Y_{2}, \cdots, Y_{n})$$

$$\tag{8}$$

优化的具体步骤如下:

(1)计算给定 *Perp*下的条件概率 *p*_{j|i}(参见式(1));
(2)令

$$P_{ij} = \frac{P_{j|i} + P_{i|j}}{2n}$$
(9)

(3)N(0,10⁻⁴I)随机初始化Y;

(4)从 t = 1 迭代至 T,并进行如下操作:首先计算低维 度下的 q_{ij}(参见式(5)),再计算梯度(参见式(6)),并更新 等式:

$$Y^{t} = Y^{t-1} + \eta \frac{dC}{dY} + \alpha(t) (Y^{t-1} - Y^{t-2})$$
(10)

4.2 传统数据融合算法

流形学习中的经典数据融合算法有 MDS 和 Isomap。传 统数据融合算法有 PCA 算法。MDS 算法将高维坐标中的点 投影到低维坐标中,并保证降维之后两数据点间距离的变化 最小,以此选择最优的高维局部空间进行降维。在 MDS 算 法中,m个样本在原始维度空间的距离矩阵为 $D \in R^{m \times m}$,在 低维空间的距离矩阵为Z,选取好初始点后,用梯度下降法求 低维映射,使得 $\|D-Z\|$ 最小。MDS 无需对数据进行假设, 并可大规模处理数据,但计算周期长,样本多时会陷入局部 最优。

Isomap 所采用的核心算法与 MDS 相同,而 Isomap 算法 在计算非线性结构时,使用测地线距离反映真实的流形低维 结构。对于 N 维矩阵,Isomap 确定两点间的输入空间距离 $d_X(i,j)后,采用 Dijkstra 算法计算最短路径 <math>d_G(i,j)$ 并将其 作为测地线距离的估计。最后,将距离矩阵 D_G 作为 MDS 的 输入得出降维结果。向量数量 N 增大时,点对间距离更加接 近测地距离,但会花费更长的时间;若 N 过小,测地距离会不 精确。

PCA 算法被称为主成分分析法,其采用线性变换将原始数据变换到新的坐标系统中,以压缩原有数据规模。对于原始 m 维矩阵 X,算法须求出协方差矩阵 $C = \frac{1}{m} X X^{T}$,再通过协方差矩阵求出其特征值和特征向量;之后根据特征向量的特征值大小从上到下按行排列成矩阵,取前 k 行组成矩阵 P, Y = PX 即为降维至 k 维的结果。此算法执行速度快,但对非线性数据处理的难度较大。

5 实验及结果分析

5.1 数据集

326

AReM数据集^[19]是在每一间隙内对部署在人体上的 3 对传感器结点采集 6 个 RSS 样本,并对样本数据进行平均数 和方差计算所得到的。该数据集描述了人体的运动状态,主 要包括小跑、蹲下、行走和骑行等。

本实验使用 AReM 数据集对人体体域网中多传感器的 情形进行仿真,并基于此来研究 T-SNE 算法对体域网的数据 融合效果。

5.2 实验结果及分析

5.2.1 算法性能的比较

本实验将 AReM 数据集的前 500 行数据增至 1000 行, 每次数据量等量增加,比较不同算法在数据量增加时的降维 效果变化,以及数据量达到 1000 时各算法的降维效果。

在数据降维过程中,有多类算法可以用来评价处理数据的优劣。实验将 T-SNE 算法与传统的 Isomap, MDS 流形算 法和传统的 PCA 分解算法的实验结果进行比较,采用汉明损 失(Hamming Loss)、准确率(Accuracy Score)、召回率(Recall Score)和预测精度(Precision Score)这4个性能指标进行评价。汉明损失所得分数越低,代表降维效果越好;其他3个指标得分越高,性能越优。

4 次降维结果为算法参数默认条件下的性能比较,如图 2-图 5 所示。由图 2 可以看出,随着数据量的增加,T-SNE 算 法的汉明损失率的初始值较低,且增速较为缓慢;其汉明损失 波动幅度比其他 3 种算法更大,但它更好地保护了原始数据。 总体上,T-SNE 达到了较好的分类效果。



图 2 不同方法的 Hamming loss 对比(电子版为彩色) Fig. 2 Hamming loss comparison of different methods

从图 3 可以看出,随着数据量的不断增加,T-SNE 的降 维评判分数相比其他 3 种算法降速较缓,准确率也基本高于 其他 3 种算法,但得分波动幅度较大,不够稳定。总之,在准 确率方面,T-SNE 算法表现出了稳定的降维保真能力。



图 3 不同方法的 Accuracy score 对比

Fig. 3 Accuracy score comparison of different methods

由图 4 和图 5 可以看出,随着数据量的不断增加,召回率 和准确率在训练规模为 600 及 850 左右时出现较大规模的跌 幅,这是实验所用数据集特征导致的。当实验数据规模小于 600时,所用数据基本为下蹲动作数据,因此实验结果稳步增 长,证明所用方法切实有效。但当实验数据规模超过 600 时 又增添了其他种类的运动数据,因此 Recall score 和 Precision score 骤降,但在随后的训练过程中又逐渐恢复。当实验规模 为 850 左右时,出现了相似的情形。但是,从图 4 和图 5 也可 以看出,T-SNE 在召回率和精确度方面明显优于其他 3 种算 法,达到了较好的分类效果。



图 4 不同方法的 Recall score 对比(电子版为彩色) Fig. 4 Recall score comparison of different methods



图 5 不同方法的 Precision score 对比(电子版为彩色) Fig. 5 Precision score comparison of different methods

不同方法在1000行数据量下的降维性能比较如表1与 图6所示。可以看出,T-SNE在数据降维任务的各项指标中 获得了更低的损失和更高的评分,其他算法则表现一般。

分析表 2 和图 6 可得, T-SNE 算法的降维效果虽显著优于 MDS 算法,但其降维处理耗时较 Isomap 和 PCA 算法更长。因此, T-SNE 算法在大型数据处理时,会耗费大量时间, 对大型数据集的适应能力不强。

表1 不同方法在1000行数据量下的性能比较

Table 1 Comparison of performance of different methods in 1000 rows of data

算法	Hamming loss	Accuracy score	Recall score	Precision score
Isomap	0.241	0.759	0.724	0.795
MDS	0.360	0.640	0.605	0.664
T-SNE	0.145	0.855	0.816	0.881
PCA	0.311	0.689	0.645	0.731



图 6 不同方法在 1000 行数据量下的性能比较

Fig. 6 Performance comparison of different methods in 1000 rows

表 2 不同方法在 1000 行数据量下的执行时间比较

Table 2 Comparison of execution time of different methods in 1000 rows of data

			(単位:s)
算法	最长耗时	最短耗时	平均耗时
Isomap	1.165	0.916	0.975
MDS	48.825	30.133	40.529
T-SNE	11.187	8.041	9.455
PCA	0.367	0.242	0.261

图 7 为 Isomap, MDS, T-SNE, PCA 4 种降维算法对 AReM数据集前1000行数据进行100次降维训练及预测 所耗费的时间对比折线图。可以看出,4 种算法中耗时最长 的为 MDS 算法,且其处理时间波动较大,不够稳定;PCA 和 Isomap 处理时间相对较短;T-SNE 算法处理时间则处于中 等。表 2 详细记录了 4 种算法进行 100 次训练预测的最长耗 时、最短耗时和平均耗时。



图 7 不同算法的数据降维时间的比较

Fig. 7 Comparison of different algorithm data reduction time

5.2.2 T-SNE 降维

本节通过调整 T-SNE 算法中嵌入维度、混乱度、簇间距、 学习率和迭代次数等参数,产生了不同的降维效果。

图 8-图 12 展示了 T-SNE 算法在不同的参数下,对 AReM 数据集的降维效果。由实验数据可以看出,混乱度 (perplexity)的最佳取值为 12;早期夸大因子(early_exaggeration)的最佳取值为 6;学习率(learning_rate)的最佳取值 为 240;最大迭代次数(n_iter)的最佳取值为 900;远距离节点 角度(angle)的最佳取值为 0.3。由表 3 可以看出,当 AReM 数据集被降维至二维时 Hamming_loss, Accuracy, Recall 和 Precision 得分均最佳。



图 8 perplexity 参数变化时降维性能的比较 Fig. 8 Perplexity parameter change dimension reduction

performance comparison







图 10 learning_rate 参数变化时降维性能的比较

Fig. 10 Learning_rate parameter change dimension reduction performance comparison

本实验通过调整 T-SNE 算法的参数,进一步改善了 AReM数据集的降维效果,为多传感器体域网数据融合提供 了良好的思路。



图 11 n_iter 参数变化时降维性能的比较

Fig. 11 N_iter parameter change dimension reduction performance comparison



图 12 angle 参数变化时降维性能的比较

Fig. 12 Angle parameter change dimension reduction performance comparison

表 3 T-SNE 在不同降维参数下的指标得分

Table 3 T-SNE index scores under different dimensionality

reduction parameters

维度	$Hamming_loss$	Accuracy	Recall	Precision
一维	0.55	0.45	0.404	0.465
二维	0.149	0.851	0.812	0.873
三维	0.372	0.628	0.58	0.66

结束语 针对多传感器体域网环境下,采集的数据冗杂、 维数较大等问题,采用 T-SNE 算法对数据进行降维处理。实 验结果表明,基于流形学习的 T-SNE 算法对多传感器体域网 数据的降维质量更高,损失率更低,能为体域网数据融合提供 较好的解决方案。T-SNE 的训练速度虽然远远超过 MDS,但 是仍逊色于 Isomap 和 PCA 算法。后期将对如何优化算法, 提高训练速度,减少资源损耗等方面开展进一步研究。

参考文献

[1] CHENG J, YANG L K, CUI N, et al. A noval pattern classifica-

tion method for imbalanced data set based on manifold embedded over-samping [J]. Journal of China University of Mining &-Technology, 2018, 47(6): 1325-1333.

- [2] HUANG H, YANG Y Q, LUO Y L. Classification of Hyperspectral Images Based on Semi-supervised Sparse Multi-manifold Embedding [J]. Acta Photonica Sinica, 2016, 45(3):330001.
- [3] TALMON R.WU H T. Latent common manifold learning with alternating diffusion: Analysis and applications [J]. Applied and Computational Harmonic Analysis, 2019, 47(3): 848-892.
- [4] CHEN J Y,ZHENG H B,BAO X W. Research and Implementation of Dimension Reduction Method for Nonlinear Manifold Learning Based on Adaptive Density Clustering [J]. Small Microcomputer System, 2018, 39 (8):1641-1645.
- [5] CHEN Y, HU Y X, LIU Y N, et al. Processing and Fusion for Multi-sensorData [J]. Journal of Jilin University (Science Edition),2018,56(5):1170-1178.
- [6] LE S H. Design and Research on Remote Physiological Parameters Acquisition System Based on Body Area Network [D]. Nanchang: Nanchang University, 2015.
- [7] QUWAIDER M.JARARWEH Y. Cloudlet-based Efficient Data Collection in Wireless Body Area Networks[J]. Simulation Modelling Practice & Theory, 2015, 50:57-71.
- [8] LIU B, LU P, HAO X, et al. Data Collection Scheme Based on Wake-Up in Body Area Nanonetworks[C] // International Conference on Networking & Network Applications. IEEE, 2016.
- [9] PEZZOTTI N, LELIEVELDT B, VAN D M L, et al. Approximated and User Steerable tSNE for Progressive Visual Analytics [J]. IEEE Trans Vis Comput Graph, 2017, 23(7):1739-1752.
- [10] NGUYEN M, PURUSHOTHAM S, TO H, et al. m-TSNE: A Framework for Visualizing High-Dimensional Multivariate Time Series[J]. arXiv preprint arXiv:1708.07942,2017.
- [11] HAN X H.CHEN Y W.RUAN X. Multilinear Tensor Supervised Neighborhood Embedding Analysis for View-Based Object Recognition[C]//Pacific Rim Conference on Advances in Multimedia Information Processing. Springer-Verlag, 2010.
- [12] XU R,JIANG F,YAO H X. Overview of Manifold Learning[J]. Journal of Intelligent Systems, 2006,1(1):44-51.
- [13] CHEN T, LI G P, WANG X M. Visualizing Appropriation of Research Funding with t-SNE Algorithm [J]. Data Analysis and Knowledge Discovery, 2018, 2(8): 1-9.

- [14] HAYAJNEH T, AL-MASHAQBEH G A, ULLAH S, et al. A survey of wireless technologies coexistence in WBAN: analysis and open research issues[J]. Wireless Networks 2014, 20(8): 2165-2199.
- [15] LIN J C, BAI T, LI G Q, et al. Technological requirements and challenges of body area networks [J]. Journal of Internet of Things, 2018, 2(3): 11-20.
- [16] BADREDDINE W, KHERNANE N, POTOP-BUTUCARU M, et al. Convergecast in Wireless Body Area Networks[J]. Ad Hoc Networks, 2017, 66:40-51.
- [17] SHANKAR S K, TOMAR A S. A survey on wireless body area network and electronic-healthcare[C]//2017 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology. 2017.
- [18] PALUMBO F,GALLICCHIO C,PUCCI R, et al. Human activity recognition using multisensor data fusion based on Reservoir Computing[J]. Journal of Ambient Intelligence and Smart Environments, 2016, 8(2): 87-107.
- [19] FANG X, ZHANG S, SU X, et al. Blast furnace condition data clustering based on combination of T-distributed stochastic neighbor embedding and spectral clustering [C] // international Conference on Control and Automation. 2019;1608-1613.
- [20] SHEN X, ZHU X, JIANG X, et al. Visualization of non-metric relationships by adaptive learning multiple maps t-SNE regularization[C] // International Conference on Big Data. 2017; 3882-3887.



ZHANG Jun, born in 1980, master, associate professor. His main research interests include big data and so on.



WANG Yang, born in 1971, Ph.D professor. His main research interests include mobile computing, data mining and intelligence agent.