

控制与决策

Control and Decision

基于随机配置网络的轻量级人体行为识别模型

南静, 宁传峰, 建中华, 代伟

引用本文:

南静, 宁传峰, 建中华, 代伟. 基于随机配置网络的轻量级人体行为识别模型[J]. *控制与决策*, 2023, 38(6): 1541–1550.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1767>

您可能感兴趣的其他文章

Articles you may be interested in

基于时域扩张残差网络和双分支结构的人体行为识别

Human behavior recognition based on time domain extended residual network and dual branching structure

控制与决策. 2022, 37(11): 2993–3002 <https://doi.org/10.13195/j.kzyjc.2021.0648>

基于增量式学习的正则化回声状态网络

Design of incremental regularized echo state network

控制与决策. 2022, 37(3): 661–668 <https://doi.org/10.13195/j.kzyjc.2020.1311>

基于通道信息对齐的素描行人重识别

Channel information alignment for sketch re-identification

控制与决策. 2022, 37(12): 3129–3138 <https://doi.org/10.13195/j.kzyjc.2021.0988>

基于随机配置网络的非线性系统智能建模方法

An intelligent modeling method for nonlinear systems based on random Configuration networks

控制与决策. 2022, 37(10): 2559–2564 <https://doi.org/10.13195/j.kzyjc.2021.0436>

基于CBAM-CNN的模拟电路故障诊断

CBAM-CNN based analog circuit fault diagnosis

控制与决策. 2022, 37(10): 2609–2618 <https://doi.org/10.13195/j.kzyjc.2021.1111>

基于随机配置网络的轻量级人体行为识别模型

南 静, 宁传峰, 建中华, 代 伟[†]

(中国矿业大学 信息与控制工程学院, 江苏 徐州 221116)

摘要: 针对智能手机受限的计算和存储环境等问题, 提出基于流形正则化和 QR 分解的轻量级随机配置网络人体行为识别模型. 首先, 利用流形正则化解决输入数据被随机映射到 SCNs 隐含层空间后出现难以预测的非线性分布问题, 以提升模型结构的轻量性; 其次, 采用 QR 分解降低输出权值计算复杂度, 进一步提高模型建模过程的轻量性; 最后, 在两个人体行为识别数据集上评估所提出模型在模型识别精度和轻量性方面的有效性. 实验结果表明, 与 SCNs、CNN 等相比, 所提出模型对于人体行为识别问题不仅可以实现识别精度的提高, 还能有效降低计算复杂度, 提高模型结构的紧致性.

关键词: 人体行为识别; 智能手机; 随机配置网络; 流形正则化; QR 分解; 轻量性

中图分类号: TP391.4

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1767

引用格式: 南静, 宁传峰, 建中华, 等. 基于随机配置网络的轻量级人体行为识别模型[J]. 控制与决策, 2023, 38(6): 1541-1550.

A lightweight model for human activity recognition using stochastic configuration networks

NAN Jing, NING Chuan-feng, JIAN Zhong-hua, DAI Wei[†]

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: Aiming at the limited computing and storage environment of smart phones, this paper proposes a lightweight human activity recognition model based on stochastic configuration network with manifold regularization and QR decomposition. Firstly, manifold regularization is used to solve the problem of unpredictable nonlinear distribution after the input data are randomly mapped to the hidden layer space of SCNs, so as to improve the lightweight of the model structure. Secondly, QR decomposition is used to reduce the computational complexity of the output weights and further improve the lightweight of the model modeling process. Finally, based on two human activity data sets, the effectiveness of the proposed model in model recognition accuracy and lightweight is evaluated. Experimental results show that, compared with SCNs, CNN, etc, the proposed model can not only improve the accuracy of activity recognition, but also effectively reduce the calculation complexity and improve the compactness of the model structure.

Keywords: human activity recognition; smartphone; stochastic configuration networks; manifold regularized; QR decomposition; lightweight

0 引言

人体行为识别(human activity recognition, HAR)是普适计算中一个十分重要的研究课题,其目的是通过与计算机进行交互来实现对人体行为的预测. 目前, HAR 已被广泛应用于各行各业, 从多个方面为人类生活提供了便利. 例如: 在智能建筑中, 对居住者行为的连续观察有助于改善建筑设施的智能化设计和提高建筑中能源利用率^[1-2]; 在医疗保健中, 患者的

日常行为信息能够帮助医护人员更加准确地评估他们的身体状况, 进而提高医疗质量和医疗资源使用率^[3-6].

目前, HAR 方法主要分为: 基于视频图像的 HAR 方法和基于可穿戴传感器的 HAR 方法. 前者依赖于摄像机采集行为图像数据, 故容易受到隐私性、光照和背景等因素影响^[7-8]; 而后者能够避免这些影响, 所以获得了更多关注^[9-10]. 但是, 可穿戴传感器存在部

收稿日期: 2021-10-14; 录用日期: 2022-01-28.

基金项目: 国家自然科学基金面上项目(61973306); 江苏省自然科学基金优秀青年项目(BK20200086).

[†]通讯作者. E-mail: weidai@cumt.edu.cn.

署繁琐、价格昂贵等问题,不利于广泛实际应用.近年来,智能手机由于具有普适性、经济性和支持传感器多样性等特点,吸引了HAR研究人员的极大关注^[11-12].

在基于智能手机的HAR研究中,智能手机传感器(三轴加速度和陀螺仪传感器)采集的行为数据因含有噪声而难以直接使用.为此,特征工程被广泛应用于各种HAR模型,实现从传感器数据中提取鲁棒性的人体行为特征.文献[13]设计了一款名为HuMAn的人体行为模式识别框架,首先利用传感器采集行为数据并提取特征,然后建立基于随机森林(random forest, RF)和朴素贝叶斯(naive Bayesian, NB)的HAR模型,并指出了RF具有更高的识别精度.文献[14]将人体行为数据与所处环境信息相结合,提出了一种基于环境感知的人体行为识别框架,通过使用决策树(decision tree, DT)、支持向量机(support vector machine, SVM)和 K -近邻(K -nearest neighbors, K -NN)等进行实验,表明了基于环境信息的行为识别框架有助于提高模型的识别性能.文献[15]针对不同领域的需求,提出了一种基于级联集成的人体行为识别学习模型.该模型中每一层都是由极端梯度提升树(extremely gradient boosting trees, EGBT)、RF、极端随机树(extremely randomized trees, ERT)和softmax回归组成.在第1层中使用传感器数据训练这4种模型,进而获得代表每个数据所属不同类别的概率向量;然后,将初始输入数据和概率向量串联在一起,作为下一层分类器的输入;最终根据最后一层分类器得到预测结果.实验结果表明,与现有识别方法相比,该方法获得了更好的识别精度,模型训练过程更简单有效.

此外,深度学习(deep learning, DL)也被应用于人体行为识别,其能够利用堆叠结构直接在原始传感器数据上自动提取代表性特征,并进行行为识别.文献[16]提出了一种一维卷积神经网络(Convolutional neural network, CNN)人体行为识别模型,并与标准RF模型进行了比较,结果表明,深度模型实现了更高的识别精度.文献[17]将CNN用于提取代表性特征,LSTM用于行为识别.文献[18]利用预处理方法将传感器数据分为垂直分量和水平分量两种,并在此基础上提出了增量式双向长短期记忆(bidirectional LSTM, BLSTM)网络人体行为识别模型;此外,其为了进一步增加模型性能,提出了可以处理不同数据的多类BLSTM.但深度学习模型存在固有缺陷,即:需

要巨大的训练集以及使用梯度法分析计算众多模型超参数等.因此,利用DL模型进行HAR建模需要消耗巨大的计算和存储资源.然而,智能手机在CPU和存储等方面的资源十分有限,因此,DL不适合在智能手机上进行HAR研究和应用.综上,对于基于智能手机的HAR而言,亟需找到一种轻量级的HAR学习模型.

随机学习算法是人们为了提高建模速度而提出并发展的一类方法.增量式随机向量函数链网络(incremental random vector functional-link neural network, IRVFLNs)作为该领域的代表之一,已在许多方面得到了广泛应用^[19-20].IRVFLNs从一个小网络开始,利用增量式方法逐个添加隐含层节点(隐含层节点参数在 $[-1, 1]$ 的固定范围内随机分配),直到找到满意的解决方案为止.虽然IRVFLNs提高了模型的建模速度,但不合理的分配范围和不恰当的随机分配方式给IRVFLNs模型网络结构的紧致性带来了严重影响.文献[21]证明了在固定范围内,随机分配隐含层参数很难保证IRVFLNs模型的无限逼近性.文献[22]从增量式随机学习算法的无限逼近性出发,结合不等式监督约束提出了一种具有建模速度快、结构紧致和泛化性良好等特点的随机学习模型——随机配置网络(stochastic configuration networks, SCNs).目前,SCNs已被成功地应用于数据驱动和光纤预警等众多领域^[23-25].从技术层面上讲,SCNs隐含层参数是根据不等式监督约束在一个可调区间内随机生成的,而模型输出权值是利用全局最优求解方法获得的,这些可以保证模型建模的快速性.从结构层面上讲,作为一种增量式学习模型,其网络结构可以在增量学习中自主确定,从而在极大地减少人为干预的同时增加模型结构的紧致性.假设SCNs的隐含层输出是一个特征空间,则SCNs使用的全局最优求解方法就是要在这个空间中找到一组线性分类超平面.但由于SCNs隐层参数带有随机性,这使得原始数据在SCNs特征空间往往难以处理的非线性分布形式存在,而全局最优求解方法在这种情况下难以发挥作用.因此,模型结构在紧致性方面会出现不足.此外,SCNs增量建模过程中每增加一个节点输出权值都需要重新进行求解,而由于线性优化求解方法涉及SVD计算,使得SCNs建模过程较为耗时.

综上所述,现有文献已经提出了诸多HAR模型,但仍缺少对模型轻量性的研究.本文针对智能手机资源有限性、SCNs中随机映射输入数据导致的数据

非线性分布以及输出权值计算耗时等问题,提出一种基于随机配置网络的轻量级HAR学习模型. 在该模型中,首先将流形正则化方法引入SCNs的增量构建过程中,解决输入数据被随机映射到SCNs隐含层输出空间后出现的非线性化分布问题,从模型结构方面提高轻量性;其次,利用QR分解代替原有的高复杂度计算输出权值的方法,解决模型增量构建过程中输出权值耗时问题,从模型建模过程上提高轻量性. 本文所提出的HAR模型包括以下3步: 1) 利用智能手机内置传感器采集行为数据; 2) 利用特征工程进行特征提取; 3) 采用本文所提出算法建立HAR模型. 本文在UCI HAR数据集和自建数据集上进行实验仿真,结果表明,本文所提出的模型是一种轻量级模型,它非常适合于基于智能手机的HAR研究.

1 基于MR-SCNs的人体识别模型

在HAR中,特征工程和识别模型是两个重要的研究步骤. 特征工程为模型建模和行为识别提供具有代表性的行为特征. 常用的特征包括时域和频域两种特征. 其中:时域特征有助于模型区分lying、standing等静态行为,其包括最大值、最小值和平均值等;频域特征可用于区分动态和静态行为,其包括峰度、偏度和向量夹角等. 具体特征如表1所示. 本文在特征工程所提出的关键行为特征基础上,针对智能手机有限的资源这一特性,基于SCNs网络,着重研究轻量化的识别模型,提出一种MR-SCNs模型,具体模型如下.

表1 特征表

域	特征
频域	峰度
	偏度
	最高频率分量
	两个向量夹角
	频率间隔能量
	加权平均
时域	平均值
	最大值
	最小值
	标准差
	中值绝对值
	信号幅度面积
	自回归系数
	相关系数
	四分位距
	平方和均值
信息熵	

1.1 MR-SCNs模型

SCNs是一种增量式的单隐层前馈神经网络随机学习模型,其包含3种实现算法,即SC-I、SC-II和SC-III^[22]. 由于SC-III中的输出权值是通过解决全局最优问题获得的,SC-III在泛化性和学习效率两方面优于其他两种. 所以,本文以SC-III为研究对象,文中所提SCNs皆指SC-III.

在增量构建中,SCNs基于监督机制(依赖数据)在可调区间内随机分配隐含层参数,进而保证其无限逼近性. 但SCNs随机分配隐含层参数的本质使得数据会在其特征空间被随机映射,这种随机映射会使得数据的内在结构呈现出一种非线性分布. 而全局最优求解方法作为一种线性方法难以解决这种非线性分布问题,进而会导致模型结构不紧致问题. 流形正则化是一种基于几何理论的数据表示方法,其通过邻接图来表示数据的内在几何结构特征,这些相邻信息能够使得原始数据在映射后依旧能够保留变化前的重要信息. 目前,流形正则化已经得到了广泛应用^[26-29]. 因此,本文将流形正则化理论引入SCNs,提出流形正则化随机配置网络(manifold regularized stochastic configuration networks, MR-SCNs)以解决数据非线性分布问题,并以此来提高模型紧致性.

MR-SCNs描述如下:

给定一个 $\text{span}(\Gamma)$,其表示由 Γ 构成的函数空间. 假设 $\text{span}(\Gamma)$ 在 L_2 空间上是稠密的且当 $b_g \in R^+$ 时 $\forall g \in \Gamma, 0 < \|g\| < b_g$. 给定 $0 < r < 1$,非负实数列 $\{\mu_L\}$ 满足 $\lim_{L \rightarrow \infty} \mu_L = 0$ 和 $\mu_L \leq (1 - r)$,目标函数 $f: R^d \rightarrow R^m$. 假设已构建好一个带有 $L - 1$ 个隐层节点的MR-SCNs,则其输出 f_{L-1} 可表示为

$$f_{L-1}(x) = \sum_{i=1}^{L-1} \beta_i g_i(w_i^T x + b_i),$$

$$f_0 = 0, L = 1, 2, \dots \quad (1)$$

其中: $x = \{x_1, x_2, \dots, x_N\}$ 表示训练集的输入样本, N 表示样本数量, $x_j \in R^d, j = 1, 2, \dots, N; \beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 表示与第 i 个隐层节点连接的输出层节点输出权值; g_i 是第 i 个隐层节点的激活函数; w_i, b_i 在可调区间 $[-\lambda, \lambda]^d$ 和 $[-\lambda, \lambda]$ 内随机分配产生, λ 从区间 $[\lambda_{\min} : \Delta\lambda : \lambda_{\max}]$ 内自动分配. 根据式(1)可以得到具有 $L - 1$ 个隐层节点的网络残差 e_{L-1} ,即

$$e_{L-1} = f - f_{L-1} = [e_{L-1,1}, e_{L-1,2}, \dots, e_{L-1,m}]. \quad (2)$$

本文基于流形正则化理论对不等式约束进行改进. 当第 L 个节点添加到网络时, 激活函数 g_L 需要满足下列带有流形正则化的不等式约束:

$$\langle e_{L-1,q}, g_L \rangle^2 \geq \delta_{L,q} \frac{(\|b_g\|^2 + C_1 b_g^T L^* b_g)^2}{(\|b_g\|^2 + 2C_1 b_g^T L^* b_g)}. \quad (3)$$

其中: $q = 1, 2, \dots, m$; $\delta_{L,q}$ 的形式如下:

$$\delta_{L,q} = (1 - r - \mu_L) \|e_{L-1,q}\|^2, \quad q = 1, 2, \dots, m. \quad (4)$$

带有 L 个节点的MR-SCNs网络输出权值可以通过求解如下目标函数获得:

$$\min : \frac{1}{2} \|H\beta - f\|^2 + \frac{C_1}{2} \text{tr}(\beta^T H^T L^* H \beta). \quad (5)$$

其中: C_1 为流形正则化系数,

$$\beta = [\beta_1; \beta_2; \dots; \beta_L]_{L \times m},$$

$$H = \begin{bmatrix} g(w_1^T x_1 + b_1) & \dots & g(w_L^T x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1^T x_N + b_1) & \dots & g(w_L^T x_N + b_L) \end{bmatrix}_{N \times L}$$

为隐含层输出矩阵, L^* 为拉普拉斯矩阵.

根据式(5), 先计算 L^* , 再求解输出权值. 在MR-SCNs特征空间中, 样本 x_i 被表示为 $h_i = [g(w_1^T x_i + b_1), \dots, g(w_L^T x_i + b_L)]$. 根据流形正则化理论, 其目标函数为

$$\min : \frac{1}{2} \sum_{i,j} v_{ij} \|f_i - f_j\|_2^2. \quad (6)$$

其中: f_i 和 f_j 分别表示 h_i 和 h_j 所对应的输出向量, v_{ij} 表示 h_i 和 h_j 的相似度. 这里采用 K -NN方法计算两者相似度, 步骤如下:

$$v_{ij} = \begin{cases} \exp(-\|h_i - h_j\|_2^2 / \rho), \\ e(h_i, h_j) = 1 \text{ and } c(h_i) = c(h_j); \\ 0, \text{ otherwise.} \end{cases} \quad (7)$$

其中: $e(h_i, h_j) = 1 \text{ and } c(h_i) = c(h_j)$ 表示两个隐含层输出向量相邻且来自同一类. 因此, 式(6)可以转化为如下形式:

$$\min : \text{tr}(f^T L^* f). \quad (8)$$

其中: $\text{tr}(\cdot)$ 表示矩阵的迹, f 表示由输出向量组成的矩阵. 由此可得

$$L^* = D - V, \quad (9)$$

其中 D 是一个对角矩阵, 通过下式获得:

$$D_{ii} = \sum_{j=1}^N V_{ij}. \quad (10)$$

对式(5)求导可得

$$\nabla = H^T(H\beta - f) + C_1(H^T L^* H \beta). \quad (11)$$

令 $\nabla = 0$, 可得MR-SCNs输出权值更新表达式

$$\beta^* = (H^T H + C_1 H^T L^* H)^{\dagger} H^T f, \quad (12)$$

其中 $\beta^* = [\beta_1^*; \beta_2^*; \dots; \beta_L^*]_{L \times m}$.

事实上, 当仅更新第 L 个节点的输出权值时, 网络的目标函数为

$$\min : \frac{1}{2} \|H_{L-1} \hat{\beta} + g_L \beta_L - f\|^2 + \frac{C_1}{2} \text{tr}(\beta_L^T g_L^T L^* g_L^T \beta_L). \quad (13)$$

其中: $H_{L-1} = [g_1, g_2, \dots, g_{L-1}]$, $\hat{\beta} = [\tilde{\beta}_1; \tilde{\beta}_2; \dots; \tilde{\beta}_{L-1}]$.

对式(13)求导可得

$$\nabla_1 = g_L^T (g_L \beta_L - f) + C_1 (g_L^T L^* g_L \beta_L). \quad (14)$$

令 $\nabla_1 = 0$, 则网络仅更新单个输出权值时表达式为

$$\tilde{\beta}_L = \frac{\langle e_{L-1}^*, g_L \rangle}{g_L^2 + C_1 g_L^T L^* g_L}. \quad (15)$$

其中: $\tilde{e}_L = e_{L-1}^* - \tilde{\beta}_L g_L$, $\tilde{\beta}_L = [\tilde{\beta}_{L,1}, \tilde{\beta}_{L,2}, \dots, \tilde{\beta}_{L,m}]^T$, $e_0^* = f$, $\tilde{\beta} = [\tilde{\beta}_1; \tilde{\beta}_2; \dots; \tilde{\beta}_L]$.

通过分析式(12)和(15)可知, 式(15)只对新增输出权值进行更新, 而对已构造的则固定不变. 因此, 相对于式(12)这种全局更新的方法是一种次优解.

1.2 MR-SCNs的收敛性分析与证明

定理1 假设 $\text{span}(\Gamma)$ 在 L_2 空间中是稠密的, 且当 $b_g \in R^+$ 时 $\forall g \in \Gamma, 0 < \|g\| < b_g$. 对于一个给定的正实数 C_1 , 记

$$\varepsilon = \frac{1}{(\|b_g\|^2 + C_1 b_g^T L^* b_g)^2 / (\|b_g\|^2 + 2C_1 b_g^T L^* b_g)},$$

$0 < \varepsilon < 1$. 给定 $0 < r < 1$, 非负实数序列 $\{\mu_L\}$ 满足 $\mu_L \leq (1 - r)$ 和 $\lim_{L \rightarrow \infty} \mu_L = 0$. 对 $L = 1, 2, \dots$, 做如下定义:

$$\delta_L^* = \sum_{q=1}^m \delta_{L,q}^*, \quad \delta_{L,q}^* = (1 - r - \mu_L) \|e_{L-1,q}^*\|^2. \quad (16)$$

新生成的随机基函数 g_L 满足如下不等式:

$$\langle e_{L-1,q}^*, g_L \rangle^2 \geq \frac{(b_g^2 + C_1 b_g^T L^* b_g)^2}{(b_g^2 + 2C_1 b_g^T L^* b_g)} \delta_{L,q}^*. \quad (17)$$

输出权值由式(12)计算获得, 从而有

$$\lim_{L \rightarrow +\infty} \|f - f_L\| = 0.$$

证明 对于输出权值, 利用式(15)所获得的 $\tilde{\beta}_L$ 可以被视为是利用式(12)所获得的 β^* 的一种次优解, 由此可得 $\|e_L^*\|^2 \leq \|\tilde{e}_L\|^2$. 又因 $\|\tilde{e}_L\|^2 = \|e_{L-1}^* - \tilde{\beta}_L g_L\|^2 \leq \|e_{L-1}^*\|^2$, 故 $\|e_L^*\|^2 \leq \|e_{L-1}^*\|^2$. $\{\|e_L^*\|^2\}$ 是单调递减且收敛的. 进而可得

$$\|e_L^*\|^2 - (r + \mu_L) \|e_{L-1}^*\|^2 \leq$$

$$\begin{aligned}
 & \|\tilde{e}_L\|^2 - (r + \mu_L)\|e_{L-1}^*\|^2 = \\
 & \sum_{q=1}^m \langle e_{L-1,q}^* - \tilde{\beta}_{L,q}g_L, e_{L-1,q}^* - \tilde{\beta}_{L,q}g_L \rangle - \\
 & \sum_{q=1}^m (r + \mu_L)\langle e_{L-1,q}^*, e_{L-1,q}^* \rangle = \\
 & \sum_{q=1}^m (1 - r - \mu_L)\langle e_{L-1,q}^*, e_{L-1,q}^* \rangle - \\
 & \sum_{q=1}^m 2\langle e_{L-1,q}^*, \tilde{\beta}_{L,q}g_L \rangle + \sum_{q=1}^m \langle \tilde{\beta}_{L,q}g_L, \tilde{\beta}_{L,q}g_L \rangle = \\
 & (1 - r - \mu_L)\|e_{L-1,q}^*\|^2 - \\
 & \quad \sum_{q=1}^m \langle e_{L-1,q}^*, g_L \rangle^2 \\
 & \frac{(\|g_L\|^2 + C_1g_L^T L^* g_L)^2 / (\|g_L\|^2 + 2C_1g_L^T L^* g_L)}{\|g_L\|^2 + C_1b_g^T L^* b_g} \leq \\
 & \delta_L^* - \frac{\sum_{q=1}^m \langle e_{L-1,q}^*, g_L \rangle^2}{(\|b_g\|^2 + C_1b_g^T L^* b_g)^2 / (\|b_g\|^2 + 2C_1b_g^T L^* b_g)} \leq 0.
 \end{aligned} \tag{18}$$

因此,可得

$$\|e_L^*\|^2 \leq r\|e_{L-1}^*\|^2 + \mu_L\|e_{L-1}^*\|^2, \tag{19}$$

其中 $\lim_{L \rightarrow \infty} \mu_L\|e_{L-1}^*\|^2 = 0$.

由式(19)可得 $\lim_{L \rightarrow \infty} \|e_L^*\|^2 = 0$, 因此有

$$\lim_{L \rightarrow +\infty} \|e_L^*\| = 0. \tag{20}$$

定理得证. □

1.3 QR分解计算输出权值

由式(12)可以看出,引入流形正则化解决数据在SCNs隐含层输出空间非线性化问题的同时,势必会增加模型计算复杂度.而智能手机资源(CPU、内存、电池电源)的有限性要求所用模型应保证轻量化.这也是CNN、LSTM等DL模型不适合基于智能手机HAR研究的主要原因.同时,MR-SCNs模型在构建过程中每次添加节点时,都需要利用式(12)求解输出权值.这种计算输出权值的方式是极其耗时的,特别是当需要大量隐含层节点进行建模时.因此,本文利用计算复杂度更低的QR分解^[30]计算MR-SCNs输出权值,具体过程如下.

令 $M = H^T H + C_1 H^T L^* H$, 则式(12)变为

$$M\beta^* = H^T f. \tag{21}$$

对 M 进行QR分解,有

$$M = QR. \tag{22}$$

其中: Q 为酉矩阵, R 为上三角矩阵. 基于式(21)和

(22),MR-SCNs的输出权值计算方式为

$$\beta^* = R^{-1}Q^T(H^T f), \tag{23}$$

其中 $Q^T = Q^{-1}$.

注1 在式(12)中,模型MR-SCNs的输出权值计算时一般采用SVD分解,其计算复杂度为 $O(N^3)$;而本文使用的QR分解方法的计算复杂度为 $O(2N^3/3)$,减少了1/3的计算复杂度.

1.4 所提模型伪代码

为了便于表达,引入变量 $\xi_{L,q} (q = 1, 2, \dots, m)$,

即

$$\begin{aligned}
 \xi_{L,q} = & \frac{(e_{L-1,q}(x) \cdot g_L(x))^2}{\kappa} - (1 - r - \\
 & \mu_L) \cdot e_{L-1,q}(x)^T e_{L-1,q}(x).
 \end{aligned} \tag{24}$$

其中

$$\begin{aligned}
 \kappa = & \frac{(\|g_L(x)\|^2 + C_1g_L(x)L^*g_L(x))^2}{(\|g_L(x)\|^2 + 2C_1g_L(x)^T L^*g_L(x))}, \\
 g_L(x) = & [g(w_L^T x_1 + b_L), \dots, g(w_L^T x_N + b_L)]^T.
 \end{aligned} \tag{25}$$

MR-SCNs行为识别模型学习算法包括网络初始化、隐层参数配置、输出权值优化和预测输出4个步骤,具体如下.

模型1 MR-SCNs人体行为识别模型.

输入: 人体行为数据集 $x = \{x_1, x_2, \dots, x_N\}, x_i \in R^d$;

输出: 人体行为类型 $f_i, i = 1, 2, \dots, 6$.

step 1: 网络初始化.

给定训练集 $\{x, f\}, x = \{x_1, x_2, \dots, x_N\}, x_i \in R^d, f = \{f_1, f_2, \dots, f_N\}, f_i \in R^m. T_{\max}$ 为最大的随机分配次数, L_{\max} 为最大的隐含层节点数, ε 为期望容差, $\gamma = \{\lambda_{\min} : \Delta\lambda : \lambda_{\max}\}$ 为一组正的标量. $e_0 = f, 0 < r < 1, \Omega$ 和 W 为空集.

step 2: 隐层参数配置.

step 2.1: for $\lambda \in \gamma$;

step 2.2: for $s = 1, 2, \dots, T_{\max}$;

step 2.3: 从区间 $[-\lambda, \lambda]^d$ 和 $[-\lambda, \lambda]$ 中随机分配 w_L, b_L ;

step 2.4: 根据式(24)、(25)计算 $\xi_{L,q}, g_L(x)$, 其中 $\mu_L = (1 - r)/(L + 1)$;

step 2.5: if $\min(\xi_{L,1}, \xi_{L,2}, \dots, \xi_{L,m}) \geq 0$;

step 2.6: 将 w_L 和 b_L 存储于 W 内, $\xi_L = \sum_{q=1}^m \xi_{L,q}$

存储于 Ω ;

step 2.7: else(返回 step 2.1);

step 2.8: end if;

step 2.9: end for;

step 2.10: if W 非空;

step 2.11: 在 Ω 中找到使 ξ_L 最大的隐层参数 w_L^* 和 b_L^* ; 令 $H_L = [g_1^*, g_2^*, \dots, g_L^*]$, 并计算拉普拉斯矩阵 L^* ;

step 2.12: break(跳转 step 3.2);

step 2.13: else;

step 2.14: 在 $\tau \in (0, 1 - r)$ 内随机选取 τ , 更新 $r = r + \tau$, 返回 step 2.2;

step 2.15: end if;

step 2.16: end for(返回 step 2.1).

step 3: 输出权值优化.

step 3.1: 利用式(23)计算网络输出权值 β^* ;

step 3.2: 计算网络残差 $e_L = f - H_L \beta^*$;

step 3.3: 更新 $e_0 = e_L, L = L + 1$;

step 3.4: 获得最优的 $\beta_1^*, \beta_2^*, \dots, \beta_L^*, w^* = \{w_1^*, \dots, w_L^*\}$ 和 $b^* = \{b_1^*, \dots, b_L^*\}$.

step 4: 预测输出.

计算预测输出值 $f^* = H^* \beta^*$.

2 实验分析

2.1 数据采集与处理

本文在实验部分使用一个公开数据集(UCI HAR数据集)和一个自建数据集来验证所提出模型在HAR上的有效性.

UCI HAR数据集^[31]: 该数据集采集了30名年龄在19~48岁之间的志愿者的行为数据,他(她)们每人腰间佩戴智能手机(三星Galaxy S II)进行6项活动(walking、upstairs、downstairs、sitting、standing、lying),利用智能手机内置的加速度计和陀螺仪传感器,在50 Hz的恒定速率下采集行为数据;然后,利用噪声滤波器对所获人体行为数据进行预处理,并在2.56 s和50%重叠(128个数据/窗口)的固定宽度滑动窗口下进行分割;最后,利用特征工程提取鲁棒性特征. 该数据集包括特征数为561的10 299条人体行为数据,其中训练集为7 209条,测试集为3 090条. UCI HAR是一个非平衡数据集,具体数据信息分布如图1所示.

自建数据集: 为了进一步探究所提出模型与其他先进模型在平衡数据集和非平衡数据集上的性能差异,本文利用iphone XR进行人体行为数据采集. 该数据集中包含特征数为102的4 200条人体行为数据集,其中训练集为2 940,测试集为1 260. 该数据集的数据采集涉及2个受试者,数据集的具体分布如图1

所示.

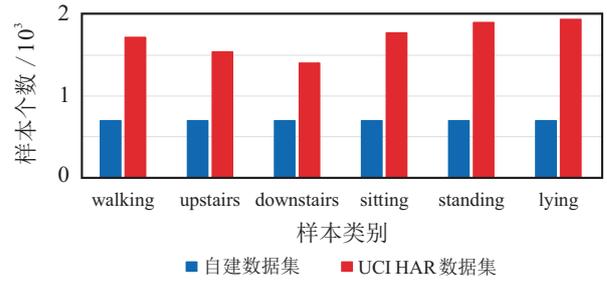


图1 数据集中各种人体行为的样本数

2.2 数据采集与处理

本文针对不同数据集的仿真实验均是在CPU为i7-9700, 3.00 GHz, RAM为8 GB的硬件平台上采用Matlab R2019b软件平台进行的. 实验中使用5折交叉验证来确定MR-SCNs模型的流形正则化参数 C_1 . 实验结果表明, $C_1 = 0.001$ 为最优. 为了验证所提出方法的有效性, 本文将其与SVM、IRVFLNs、SCNs、CNN以及LSTM等模型进行比较. 其中: SVM采用径向基函数为核函数. LSTM由一个含有200个隐含层节点的LSTM层、一个大小为6的全连接层和一个softmax层构成. CNN中包含3个卷积层、3个relu层、3个池化层、一个全连接层和一个softmax层. 同时, CNN和LSTM两种算法的一次训练中包含100个批次. 而IRVFLNs、SCNs以及MR-SCNs的激活函数与 L_{\max} 是一致的, 分别为sigmoid和500. SCNs和MR-SCNs中其余参数为 $\lambda = 1 : 1 : 10, \varepsilon = 0.05, T_{\max} = 20$. 此外, 为了保证各种学习模型公平对比, CNN、LSTM模型设置参考了Matlab官网对人体行为识别的解决方案^[32], 并通过交叉验证得到最优模型参数; IRVFLNs、SCNs、MR-SCNs的结构和参数是在文献[22]的基础上结合交叉验证得到.

2.3 实验结果

2.3.1 各种模型的性能比较

将本文所提出的MR-SCNs与SVM、IRVFLNs、CNN、LSTM和SCNs等其他几种先进模型进行对比, 结果如表2所示. 值得注意的是, 由于SVM不涉及权重和偏置的随机分配, 这使得它在多次运行后仍具有相同的精度. 对于SVM模型, 本文使用libsvm工具箱进行实现, 需要说明的是, 虽然其建模时间为10.62 s, 但该实验结果是在直接设置好模型超参数(0, 1, 1, 0.01)的情况下获得的, 而实际训练时间要远大于10.62 s. 对于CNN和LSTM模型, 由于需要大量且多次的参数调整, 它们的建模时间较长, 达到了672 s和1 559.67 s.

表 2 不同模型在UCI数据集上的行为识别精度

模型	平均精度 / %	最小精度 / %	最大精度 / %	节点数	建模时间 / s
SVM	93.87	—	—	—	10.62
CNN	91.85	91.09	92.32	—	672
LSTM	93.34	92.57	94.89	200	1559.67
IRVFLNs	90.12	90.06	91.28	500	123.72
SCNs	93.94	93.79	94.08	500	257.78
MR-SCNs	94.57	94.48	94.59	500	320.81

通过观察实验结果可知,当 IRVFLNs、SCNs 和 MR-SCNs 三种模型隐含层节点数相同时,SCNs 模型的识别精度在监督机制和可调参数分配区间的帮助下,比 IRVFLNs 模型更优. 而流形正则化能够保持数据内在结构在投影空间不变的特性,使得本文所提 MR-SCNs 的识别精度进一步得到改善. 然而,流形正则化也使得所提出模型比 SCNs 更耗时. 此外,为了比较 IRVFLNs、SCNs 和 MR-SCNs 这 3 种模型在相同精度下网络结构的紧致性,本文将 RMSE 停止值设置为 0.1,并绘制了这 3 种模型随隐含层节点增加的收敛曲线,如图 2 所示. 通过分析图 2 可知: IRVFLNs 模型所需隐含层节点最多,但模型收敛性远没有达到设定值;其余两种模型皆达到设定 RMSE 值,SCNs 模型需要 74 个隐含层节点,而 MR-SCNs 模型仅需要 67 个,节省了将近 9.3% 的隐含层节点. 因此,在满足相同精

度的情况下,MR-SCNs 需要的隐层节点更少,即模型结构更紧致(更轻量),更有利于 HAR 在智能手机上实现.

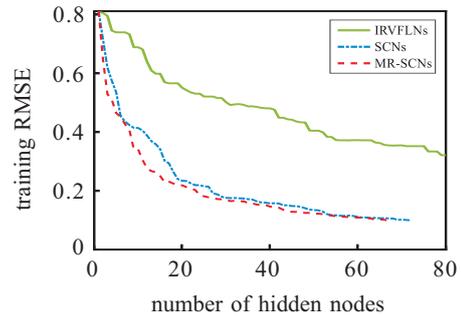


图 2 3 种模型的收敛曲线

为了更好地分析每种模型对于各种行为的识别能力,本文在图 3 中给出了这几种模型对不同行为的识别精度.

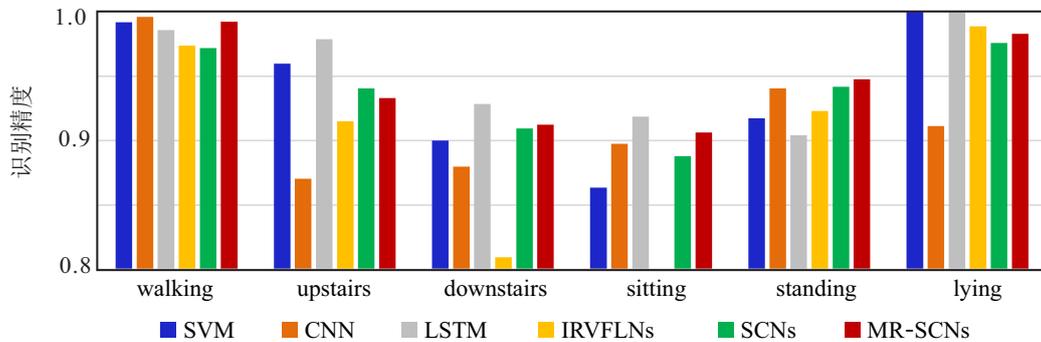


图 3 各种模型在 UCI 数据集上对不同行为的识别精度

从图 3 中可以看出,lying 和 walking 行为几乎是各种模型识别精度最好的,除了 CNN 模型对 lying 行为识别较低外,几乎都达到或接近 100% 的识别精度. 但是,sitting 和 downstairs 这两种行为最难区分. 其中,对 sitting 行为识别较差是因为它与 standing 行为相似,属于静止行为. 在这类行为中陀螺仪传感器的数值几乎为 0. 而仅仅依赖加速度传感器数据进行分类时极易产生误分类情况,因此,导致模型区分起来很有难度. 虽然在 upstairs 和 downstairs 等行行为中陀螺仪传感器数据不再为 0,但这些行为模式也稍

有相似,故区分起来也会有些难度. 此外,本文所提出的 MR-SCNs 模型对 6 种行为识别精度在所有实验模型中都达到了第 1 或者接近第 1 的结果,从而说明 MR-SCNs 模型对 HAR 具有很好的识别能力.

为了探究数据集的平衡与否对模型性能的影响,本文制作了数据平衡的 HAR 数据集并在其上面进行实验仿真,结果如表 3 所示. 通过分析表 3 可知,所有模型的整体识别精度都有了明显提高,这直接表明了平衡数据集的有效性. 值得注意:虽然 LSTM 模型达到了最好的识别精度,但它的建模时间也是最

高的,为609 s;而CNN的建模时间也高达309.33 s.这一结果再次说明DL模型并不适合基于智能手机的人体行为识别的实际应用.在考虑智能手机的资源有限性的前提下,本文所提出模型实现了最好的识别精度.另外,所提出模型的隐层节点数为266.51,小于SCNs的274.3.因此,可以说明本文所提出的模型网络结构更紧致.导致这一结果的主要原因是:1)自

建数据集的样本数为2940,远低于UCI HAR数据集的7209,而这两种模型的建模计算复杂度与样本数密切相关;2)自建数据集上两种算法的节点数为274.3和266.51,远低于UCI HAR数据集上500的节点数;3)自建数据集的特征数为102,远低于UCI HAR数据集上561的特征数.

表3 不同模型在自建数据集上的行为识别精度

模型	平均精度 / %	最小精度 / %	最大精度 / %	节点数	建模时间 / s
SVM	95.58	—	—	—	4.61
CNN	96.40	95.92	96.65	—	309.33
LSTM	99.57	99.52	99.67	200	609
IRVFLNs	97.20	97.02	97.57	500	40.16
SCNs	98.82	98.65	999.01	274.3	21.49
MR-SCNs	99.33	99.26	99.40	266.51	23.10

在平衡数据集上各种模型对不同行为的识别结果如图4所示.通过观察图4可知:downstairs和sitting这两种在非平衡数据集上识别精度最差的行为均达到90%以上的识别率;standing和upstairs这两种行为的识别精度从原来的平均不足95%,均达到了

95%以上;而原本识别结果最好的lying和walking行为的识别精度在平衡数据集上也有了明显提升.综上所述,对于HAR而言,平衡数据集较之非平衡数据集能更好地提高模型识别能力,建立更优的通用识别模型.

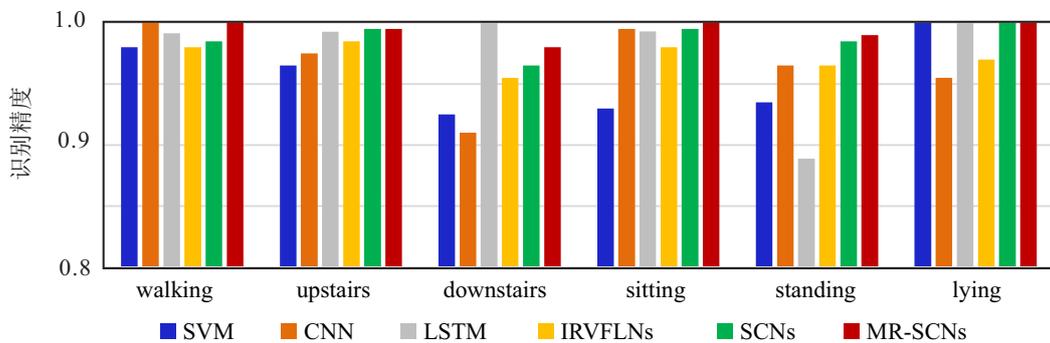


图4 各种模型在自建数据集上对不同行为的识别精度

2.3.2 引入QR分解前后的计算复杂度比较

为了清晰地阐明QR分解在解决引入流形正则化使得SCNs计算复杂度变大,而加剧智能手机设备计算负荷问题的能力,本文给出MR-SCNs有无QR时随隐含层节点增加的建模时间对比结果,如图5所示.可以看出:在QR分解的作用下,当隐含层节点数没有到达5之前,两者平均建模时间几乎相近;但从隐含层节点数为5时开始,两者平均建模时间差值逐渐增大,特别是到达12个隐含层节点时,两者差值达到了最大,为2.78 s.值得注意的是,在当隐含层节点数到达17之后,两者平均建模时间将保持相近的差值.这是因为在进行HAR建模过程中,模型需要先进行一段时间的模型调整时期,这一时期的模型结构还不

够稳定,因此,会出现这种先增大再保持相近的情况.

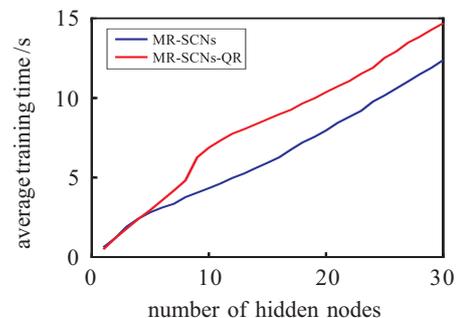


图5 有无增量式QR分解时的建模时间比较

此外,本文还基于UCI HAR数据集计算了MR-SCNs模型引入QR分解前后的整体建模时间,实验结果如表4所示.通过观察表4可知:在引入QR分解求

解输出权值之前,模型的建模时间最大需要348.25 s,最小也需要342.81 s,它们之间的差值将近6 s;而引入QR分解后,模型建模最大和最小建模时间分别为323.14 s和318.57 s,它们的差距缩小为4.57 s.出现这一结果的主要原因是,原有求解方法的计算复杂度会随着隐含层节点增多(隐含层输出矩阵变大)呈3次幂速度逐步增加,而QR分解的计算复杂度远低于原有计算方法,故相应差距也会变小.因此,模型建模时间从344.35 s降低到320.81 s,比原始模型建模时间减少了23.54 s.综上所述,QR分解有助于提高模型建模过程的轻量性.

表4 引入QR分解前后模型的建模时间

模型	平均时间/s	最小时间/s	最大时间/s
MR-SCNs	344.35	342.81	348.25
MR-SCNs-QR	320.81	318.57	323.14

为了进一步探讨学习模型的行为识别速度,本文计算了SVM、CNN、LSTM、IRVFLNs、SCNs和MR-SCNs等在UCI HAR数据集上的测试时间.它们分别为0.3932 s、0.7373 s、0.1630 s、0.0387 s、0.0381 s和0.0378 s.因3种随机模型的结构相同,故测试时间几乎一致.但高质量的隐层参数使得SCNs和MR-SCNs的测试时间更低.而CNN和LSTM两种模型由于网络结构较大和超参数较多,两者的测试时间较长.SVM虽然不涉及模型结构,但二分类的本质导致SVM一次只能识别一种行为,故在识别6种行为时需要较长的测试时间.这也说明了本文所建模型是一种轻量性模型.

3 结 论

本文主要针对智能手机因资源有限而引起对行为识别模型的紧致性和轻量性的高要求问题,基于随机配置网络模型,提出了一种带有流形正则化和QR分解的SCNs模型.首先,利用流形正则化能够在投影变换过程中保持数据结构不变的特性,解决由输入数据在SCNs隐含层输出空间非线性化分布而引起模型结构不紧致问题;其次,使用QR分解解决了MR-SCNs输出权值更新时计算复杂度大的问题;然后,将所提出模型与现有先进学习模型在2个真实的行为识别数据集上进行了比较.结果表明,在可接受的时间内,本文所提出的MR-SCNs模型在HAR方面优于其他先进模型.另外,本文还探究了数据集平衡与否对模型性能的影响.结果表明,相比于非平衡数据集,平衡数据集有助于提高模型的泛化性和通用性.最后,分析了QR分解方法的计算复杂度.结果表明,QR

分解方法能够有效降低模型计算复杂度,进而提高模型的轻量性,减少基于智能手机进行建模时的资源消耗.

本文研究的轻量化人体行为识别模型,更便于在嵌入式系统中实施,是实现可穿戴设备识别人体行为模式的一种算法工具.利用本文所提出的算法模型,针对特定的环境或任务,细化行为模式,建立识别模型是未来重点研究内容之一,如分析矿工的作业、休息等行为,可建立一套安全预警管理机制来保障井下作业人员的人身安全.

参考文献(References)

- [1] Zou H, Zhou Y X, Yang J F, et al. Towards occupant activity driven smart buildings via WiFi-enabled IoT devices and deep learning[J]. *Energy and Buildings*, 2018, 177: 12-22.
- [2] Kabir M H, Hoque M R, Thapa K, et al. Two-layer hidden Markov model for human activity recognition in home environments[J]. *International Journal of Distributed Sensor Networks*, 2016, 12(1): 4560365.
- [3] Torres-Huitzil C, Alvarez-Landero A. Accelerometer-based human activity recognition in smartphones for healthcare services[J]. *Mobile Health*, 2015: 147-169.
- [4] Wang Y, Cang S, Yu H N. A survey on wearable sensor modality centred human activity recognition in health care[J]. *Expert Systems With Applications*, 2019, 137: 167-190.
- [5] Shin J H, Lee B, Park K S. Detection of abnormal living patterns for elderly living alone using support vector data description[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2011, 15(3): 438-448.
- [6] Isho T, Tashiro H, Usuda S. Accelerometry-based gait characteristics evaluated using a smartphone and their association with fall risk in people with chronic stroke[J]. *Journal of Stroke and Cerebrovascular Diseases*, 2015, 24(6): 1305-1311.
- [7] 郭梓鑫, 衣杨, 李汉巨. 基于自适应特征融合的自然环境视频行为识别[J]. *计算机学报*, 2013, 36(11): 2330-2339.
(Guo Z X, Yi Y, Li H J. Recognizing actions from videos in the wild via adaptive feature fusion[J]. *Chinese Journal of Computers*, 2013, 36(11): 2330-2339.)
- [8] Ji S W, Xu W, Yang M, et al. 3D convolutional neural networks for human action recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(1): 221-231.
- [9] Bao L, Intille S S. Activity recognition from user-annotated acceleration data[C]. *Pervasive Computing*, Berlin: Springer, 2004: 21-23.
- [10] Wu W, Dasgupta S, Ramirez E E, et al. Classification accuracies of physical activities using smartphone motion sensors[J]. *Journal of Medical Internet Research*, 2012,

- 14(5): e130.
- [11] Anguita D, Ghio A, Oneto L, et al. Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine[C]. *Ambient Assisted Living and Home Care*, Berlin: Springer, 2012: 216-223.
- [12] Mohammad Y, Matsumoto K, Hoashi K. Selecting orientation-insensitive features for activity recognition from accelerometers[J]. *IEICE Transactions on Information and Systems*, 2019, E102.D: 104-115.
- [13] Bharti P, De D, Chellappan S, et al. HuMAn: Complex activity recognition with multi-modal multi-positional body sensing[J]. *IEEE Transactions on Mobile Computing*, 2019, 18(4): 857-870.
- [14] Asim Y, Azam M A, Ehatisham-ul-Haq M, et al. Context-aware human activity recognition(CAHAR) in-the-wild using smartphone accelerometer[J]. *IEEE Sensors Journal*, 2020, 20(8): 4361-4371.
- [15] Xu S, Tang Q, Jin L, et al. A cascade ensemble learning model for human activity recognition with smartphones[J]. *Sensors*, 2019, 19(10): E2307.
- [16] Lee S M, Yoon S M, Cho H. Human activity recognition from accelerometer data using Convolutional Neural Network[C]. *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)*. Jeju, 2017: 131-134.
- [17] Ordóñez F J, Roggen D. Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition[J]. *Sensors*, 2016, 16(1): E115.
- [18] Tao D P, Wen Y G, Hong R C. Multicolumn bidirectional long short-term memory for mobile devices-based human activity recognition[J]. *IEEE Internet of Things Journal*, 2016, 3(6): 1124-1134.
- [19] Qiu X H, Suganthan P N, Amaratunga G A J. Ensemble incremental learning random vector functional link network for short-term electric load forecasting[J]. *Knowledge-Based Systems*, 2018, 145: 182-196.
- [20] Zhou P, Jiang Y, Wen C Y, et al. Data modeling for quality prediction using improved orthogonal incremental random vector functional-link networks[J]. *Neurocomputing*, 2019, 365: 1-9.
- [21] Li M, Wang D H. Insights into randomized algorithms for neural networks: Practical issues and common pitfalls[J]. *Information Sciences*, 2017, 382/383: 170-178.
- [22] Wang D H, Li M. Stochastic configuration networks: Fundamentals and algorithms[J]. *IEEE Transactions on Cybernetics*, 2017, 47(10): 3466-3479.
- [23] Sheng Z Y, Zeng Z Q, Qu H Q, et al. Optical fiber intrusion signal recognition method based on TSVD-SCN[J]. *Optical Fiber Technology*, 2019, 48: 270-277.
- [24] Wang D H, Cui C H. Stochastic configuration networks ensemble with heterogeneous features for large-scale data analytics[J]. *Information Sciences*, 2017, 417: 55-71.
- [25] Wang D H, Li M. Robust stochastic configuration networks with kernel density estimation for uncertain data regression[J]. *Information Sciences*, 2017, 412/413: 210-222.
- [26] Xu Z L, King I, Lyu M R T, et al. Discriminative semi-supervised feature selection via manifold regularization[J]. *IEEE Transactions on Neural Networks*, 2010, 21(7): 1033-1047.
- [27] Luo Y, Tao D C, Xu C, et al. Multiview vector-valued manifold regularization for multilabel image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2013, 24(5): 709-722.
- [28] Belkin M, Niyogi P, Sindhvani V. Manifold regularization: A geometric framework for learning from labeled and unlabeled examples[J]. *Journal of Machine Learning Research*, 2006, 7: 2399-2434.
- [29] Hu H W, Ma B, Shen J B, et al. Manifold regularized correlation object tracking[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(5): 1786-1795.
- [30] Ye J P, Li Q. A two-stage linear discriminant analysis via QR-decomposition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(6): 929-941.
- [31] Anguita D, Ghio A, Oneto L, et al. Energy efficient smartphone-based activity recognition using fixed-point arithmetic[J]. *Journal of Universal Computer Science*, 2013, 19: 1295-1314.
- [32] MathWorks. Sequence-to-sequence classification using deep learning[EB/OL]. [2021-10-01]. <https://ww2.mathworks.cn/help/deeplearning/>.

作者简介

南静(1992—), 男, 博士生, 从事随机神经网络、普适计算、数据建模的研究, E-mail: jingn@cumt.edu.cn;

宁传峰(1995—), 男, 硕士生, 从事随机神经网络、数据建模的研究, E-mail: TS20060090A31@cumt.edu.cn;

建中华(1997—), 男, 硕士生, 从事随机神经网络、人体行为模式识别系统的研究, E-mail: TS20060077A31@cumt.edu.cn;

代伟(1984—), 男, 教授, 博士生导师, 从事智能与数据驱动的复杂工业过程建模、运行优化控制理论、随机神经网络与学习系统、增量联邦学习、工业大数据分析等研究, E-mail: weidai@cumt.edu.cn.