

用于 Android 手机活动识别的深度重构模型^①

王金甲^{②*} 田佩佩

(燕山大学信息科学与工程学院 秦皇岛 066004)

摘要 基于数据的流形假设,进行了 Android 手机的活动识别研究,提出了一种深度重构模型(DRMs),该模型无需基础几何的先验假设就能自动学习到当前类样本的复杂非线性曲面结构和几何特点。首先定义了一个深度重构模型(DRM)模板,通过高斯受限玻尔兹曼机(GRBMs)逐层贪婪训练以初始化 DRM 模板的权重。在训练阶段,根据每类样本分别微调初始化后的 DRM 模板便可得到特定类的 DRM。在测试阶段,基于测试样本与特定类 DRM 的最小重构误差决策活动类别。实验证明,该方法对 Android 手机数据集的活动识别正确率高达 99%。

关键词 活动识别,深度重构模型,自动编码器,Android 手机,高斯受限玻尔兹曼机(GRBMs)

0 引言

活动识别(activity recognition)是一个典型的时间序列分类问题,它可以定义为确定传感器数据流的某一连续部分是由哪种人体活动所产生^[1]。活动识别研究对人机交互、健康护理、老年人跌倒检测等具有重要意义。近年来,随着智能手机技术的快速发展和传感器技术的成熟,装有多种传感器的智能手机将会成为活动识别和运动监测的理想平台。

活动识别过程的主要步骤包括数据获取、预处理、特征提取与选择、分类决策。活动识别的研究方法大多采用特征提取与分类器相结合的框架模式,如 Liao 等考虑到加速度计数据的非线性、非平稳性,用经验模式分解(empirical mode decomposition, EMD)方法提取特征^[2]。他们将过程中获得的多种时间序列称为固有模态函数(intrinsic mode functions, IMF),通过计算前 3 个 IMF 的平均值和标准偏差来补充特征,AdaBoost 分类器用于最后的活动识别。Zheng 等则考虑每一个活动的最大振幅、频

率、信号的一维分解能量,通过傅里叶变换和小波变换获得不同活动的能量消耗,根据能量消耗模型识别活动^[3]。Acharjee 等结合条件阈值框,用 17 种函数最小化特征向量的维度,结合朴素贝叶斯分类器对 UCI 的一个标准人体活动数据集进行了识别,准确率高达 94%^[4]。上述研究方法有两种不足:(1)采用的是手工设计良好的特征提取器,这需要大量的工程技术和专业领域知识;(2)用到的模型都假设数据位于一定的几何面,即基于流形假设。

近年来,深度学习作为机器学习的新兴研究领域受到人们的广泛关注,通过深度学习构建的深度网络在无监督特征提取方面表现出了优异的性能。如 Yang 等通过卷积神经网络(convolutional neural networks, CNN)对多通道时间序列进行多次卷积和池化,提取到了具有识别意义的深层特征,结合 Softmax 分类器,其活动识别效果明显优于支持向量机(SVM)、深度信念网络(deep belief network, DBN)等方法^[5]。深度学习的蓬勃发展促使研究者们找出其成功的影响因素,研究者们认为其中一个

^① 国家自然科学基金(61273019,61473339),河北省自然科学基金(F2013203368),河北省青年拔尖人才支持计划([2013]17),河北省博士后专项资助项目(B2014010005)和中国博士后科学基金面上项目(2014M561202)资助。

^② 男,1978 年生,博士,教授;研究方向:传感器、信号处理与模式识别;联系人,E-mail: wjj@ysu.edu.cn
(收稿日期:2017-03-18)

可能的因素是高层神经网络流形数据的扁平化。随后 Brahma 等便提供了足量的实验证明了这一说法,即深度学习方法也可以用流形假设进行初步解释^[6]。于是,本研究提出了一种深层次的学习框架,该框架无需基础几何的先验假设就能自动发现当前类数据的复杂非线性曲面结构和几何特点,称之为深度重构模型 (deep reconstruction model, DRM)。

本研究的主要贡献有以下四点:(1)提出了一种自动提取深度特征的方法,而非手动特征提取;(2)通过深层重构模型的学习能自动发现数据的内在几何结构,无需基础几何的先验假设;(3)训练时,针对每一类训练样本单独建立相应的深度重构模型(DRM),而不是建立统一的训练模型,而且

DRM 的建立是一个无监督过程;(4)测试时,只通过计算测试样本与各个特定类的 DRM 的重构误差即可进行分类。

1 深度重构模型

深度重构模型(DRM)框架如图 1 所示。本研究首先定义了一个深度重构模型(DRM)模板,通过高斯受限玻尔兹曼机(Gaussian restricted Boltzmann machine, GRBM)的无监督分层预训练初始化 DRM 模板的权重,再根据每类训练样本进行微调,获得特定类的 DRM 模型。测试时,利用各个特定类的 DRM 模型重构每一个测试样本,计算重构误差,最后根据最小的重构误差决策出测试样本的标签,完成活动的识别。

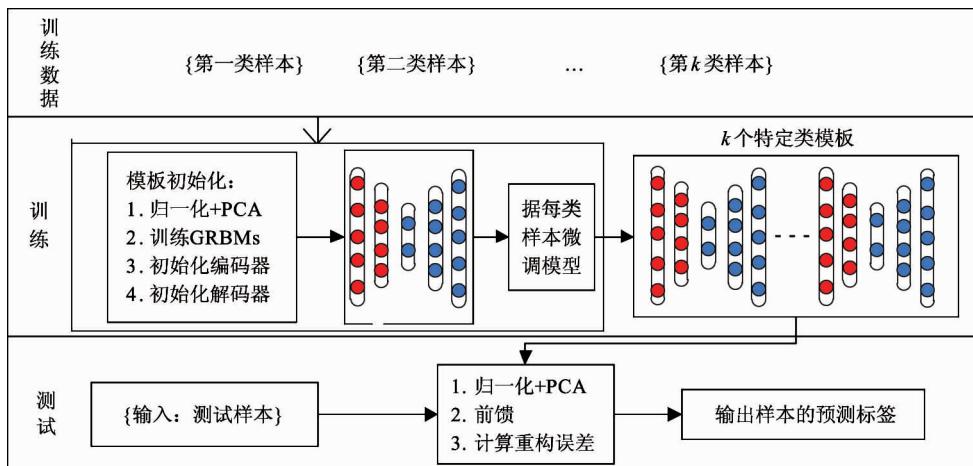


图 1 DRM 框架图

定义 DRM 模板,有助于学习数据的基本结构。图 2 总结了 DRM 模板的体系结构,该结构的细节参见 1.1 节。为了保证该深度网络能够正常运行,需要适当地初始化权重。我们采用高斯受限玻尔兹曼机(GRBM)逐层贪婪训练,以初始化 DRM 模板的权重(详情可参考 1.2 节)。完成 DRM 模板权重初始化之后,根据每类样本(假设一共有 k 类样本)再进行微调(详情可参考 1.3 节)。之后,我们会得到一个包含 k 类的完整的深度重构模型,最后把调整好的模型用于活动分类。

1.1 DRM 模板

如图 2 所示,我们的 DRM 模板基于一个自动编

码器(AE),该结构由两部分构成:编码器和译码器。编码器和译码器各有 3 个隐藏层,两者共用第 3 层(中心隐藏层)。DRM 模板的编码器得到的是输入数据的一种紧凑、低维而又有意义的表示。我们可以把编码器想象成一个由非线性激活函数 $s(\cdot)$ 连接的组合层, $s(\cdot)$ 函数的作用是将输入数据 x 映射到隐层 h ,过程如下:

$$\begin{aligned} \mathbf{h}_1 &= s(\mathbf{W}_e^{(1)}x + \mathbf{b}_e^{(1)}) \\ \mathbf{h}_2 &= s(\mathbf{W}_e^{(2)}\mathbf{h}_1 + \mathbf{b}_e^{(2)}) \\ \mathbf{h} &= s(\mathbf{W}_e^{(3)}\mathbf{h}_2 + \mathbf{b}_e^{(3)}) \end{aligned} \quad (1)$$

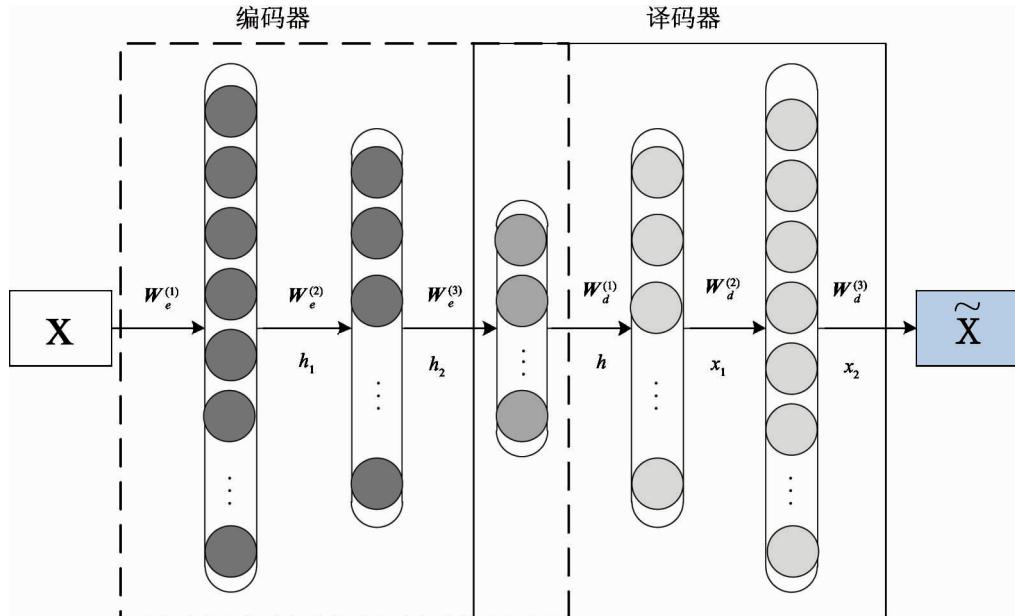


图 2 DRM 模板的体系结构

$\mathbf{W}_e^{(i)} \in R^{d_{i-1} \times d_i}$ 表示第 i 层编码器的权重矩阵, d_i 表示第 i 层的节点数, $\mathbf{b}_e^{(i)} \in R^{d_i}$ 是偏差向量, $s(\cdot)$ 是非线性激活函数。编码器参数的学习与编码器和解码器都有关系, 我们以代价函数最小化为目的来训练编码器 - 译码器结构, 进而重构输入数据(参见 1.3 节)。因此解码器可以被定义成一个由非线性激活函数联合在一起的层组合。该非线性激活函数可以根据编码器的输出 h 重构输入数据 x 。解码器重构的输出由下列式子给出:

$$\begin{aligned} \mathbf{x}_1 &= s(\mathbf{W}_d^{(1)} \mathbf{h} + \mathbf{b}_d^{(1)}) \\ \mathbf{x}_2 &= s(\mathbf{W}_d^{(2)} \mathbf{x}_1 + \mathbf{b}_d^{(2)}) \\ \tilde{\mathbf{x}} &= s(\mathbf{W}_d^{(3)} \mathbf{x}_2 + \mathbf{b}_d^{(3)}) \end{aligned} \quad (2)$$

本文用参数 $\theta_{\text{DRM 模板}} = \{\theta_w, \theta_b\}$ 表示完整的编码器 - 译码器结构(DRM 模板), 其中, $\theta_w = \{\mathbf{W}_e^{(i)}, \mathbf{W}_d^{(i)}\}_{i=1}^3, \theta_b = \{\mathbf{b}_e^{(i)}, \mathbf{b}_d^{(i)}\}_{i=1}^3$ 。在后面 1.3 节部分这个模板将会根据每类训练样本分别进行精细的调整。

1.2 DRM 模板参数初始化

用上述定义的 DRM 模板分别训练每一类训练样本, 可以得到特定类的 DRM。训练通过随机梯度下降反向传播来进行^[7]。如果初始化 DRM 模板时选择了不合适的权重值, 则训练可能失败。更直白一点说, 如果初始权重取值过大, 则有可能使网络陷入局部最小。相反, 如果初始权重取值太小, 则在初始层的反向传播过程中可能遇到梯度消失问题, 这样, 网络也将不能进行训练。因而, 模型的权重需要通过无监督预训练来进行初始化。于是, 我们采用了逐层贪婪算法和高斯受限玻尔兹曼机。下面, 我们首先简单介绍一下受限玻尔兹曼机, 然后解释它在 DRM 模板参数初始化时是如何被应用的。受限玻尔兹曼机^[8]的模型是二分图, 该二分图是一个拥有两组二进制随机节点的双向结构。这两组节点分别是可见节点()以及隐藏层节点($(v_i)_1^{N_v}, v_i \in \{0, 1\}$)以及隐藏层节点($(h_j)_1^{N_h}, h_j \in \{0, 1\}$)。可见层节点通过加权矩阵 $\mathbf{W} \in R^{N_v \times N_h}$ 与隐藏层节点对称连接。而与层内节点没有连接。受限玻尔兹曼机的联合概率密度 $p(\mathbf{v}, \mathbf{h})$ 由下式给出:

$$p(\mathbf{v}, \mathbf{h}) = 1/Z \exp(-E(\mathbf{v}, \mathbf{h})) \quad (3)$$

其中 Z 为划分函数(用作归一化常数), $E(\mathbf{v}, \mathbf{h})$ 是模型的能量函数:

$$E(\mathbf{v}, \mathbf{h}) = \sum_i b_i v_i - \sum_j c_j h_j - \sum_{ij} w_{ij} v_i h_j \quad (4)$$

上式中 \mathbf{b} 和 \mathbf{c} 分别是可见层与隐藏层的偏差。受限玻尔兹曼机的目的就是找到模型参数($\mathbf{W}, \mathbf{b}, \mathbf{c}$), 进而生成近似于训练数据的新数据。这个过程可通过最大化训练数据的可能性来实现。与大多数有向图模型不同, 由于限制了同层节点之间没有连

接,受限玻尔兹曼机的推理变得更加容易。这使得受限玻尔兹曼机在很多领域有着广泛的应用^[9-11],而其参数可以通过散度对比 (comparison of divergence, CD) 算法的数值方法进行求解^[12,13]。

适当修改模型的能量函数,标准受限玻尔兹曼机可由二进制随机数据扩展到实值数据。高斯受限玻尔兹曼机就是其中很流行的一种扩展。其能量函数是通过修改可见单元的偏差来定义的:

$$E_{GRBM}(\mathbf{v}, \mathbf{h}) = \sum_i \frac{(v_i - b_i)^2}{2\sigma_i^2} - \sum_j c_j h_j - \sum_{ij} w_{ij} \frac{v_i}{\sigma_i} h_j \quad (5)$$

其中 σ_i 是输入可见层节点 v_i 服从高斯分布的实数值的标准偏差。从每一个可见层单元都能够得到 σ_i ,但当运用散度对比 (CD) 方法计算高斯受限玻尔兹曼机的参数时,这将变得非常困难。在数据预处理阶段,我们采用一种可变的方法来调整 σ_i ,使其适合一个单元值。推断以及生成所需要的条件概率密度分布由下式给出:

$$p(h_j = 1 | \mathbf{v}) = s(\sum_j w_{ij} v_i + c_j) \quad (6)$$

$$p(v_i | \mathbf{h}) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{(v_i - u_i)^2}{2\sigma_i^2}\right)$$

$$\text{其中, } u_i = b_i + \sigma_i^2 \sum_j w_{ij} h_j \quad (7)$$

因为本实验的数据是实数值,所以可以运用高斯受限玻尔兹曼机来初始化 DRM 模板权值。同时考虑两层,就可以得到高斯受限玻尔兹曼机的参数。首先,我们将输入层节点视为可见单元 \mathbf{v} ,将第一隐藏层节点视为隐藏单元 \mathbf{h} 。这样就可以得到第一个高斯受限玻尔兹曼机及其参数。将第一个高斯受限玻尔兹曼机的隐藏单元激活作为输入,来训练第二个高斯受限玻尔兹曼机。将这一过程反复运用于 DRM 模板结构编码部分的 3 个隐藏层,将得到的编码层权重贴合到对应的译码层中去,即 $\mathbf{W}_d^{(3)} = \mathbf{W}_e^{(1)\top}, \mathbf{W}_d^{(2)} = \mathbf{W}_e^{(2)\top}, \mathbf{W}_d^{(1)} = \mathbf{W}_e^{(3)\top}$ (参见图 2)。

1.3 学习特定类的模型

通过训练带有初始权值的 DRM 模板结构可以得到特殊类的 DRM。而训练 DRM 可以使类中所有 m 个训练样本的重构误差最小:

$$J(\theta_{\text{DRM模板}}) = \frac{1}{m} \sum_{t=1}^m \| \mathbf{x}^{(t)} - \tilde{\mathbf{x}}^{(t)} \|^2 \quad (8)$$

为了避免过拟合并提高已经学习到的未知测试集的 DRM 的泛化度,我们引入了 DRM 模板代价函数中的正则项。增加一个权重衰减惩罚项 J_{wd} 以及一个稀疏约束项 J_{sp} ,经过调整后的代价函数变为

$$J_{\text{reg}}(\theta_{\text{DRM模板}}) = \frac{1}{m} \sum_{t=1}^m \| \mathbf{x}^{(t)} - \tilde{\mathbf{x}}^{(t)} \|^2 + \lambda_{\text{wd}} J_{\text{wd}} + \lambda_{\text{sp}} J_{\text{sp}} \quad (9)$$

其中 λ_{wd} 与 λ_{sp} 是正则化参数。 J_{wd} 用来保证所有隐藏单元权重的较小值。它由所有权重矩阵的平方 Frobenius 范数之和来定义:

$$J_{\text{wd}} = \sum_{i=1}^3 \| \mathbf{W}_e^{(i)} \|^2_F + \sum_{i=1}^3 \| \mathbf{W}_d^{(i)} \|^2_F \quad (10)$$

J_{sp} 迫使第 i 个隐藏层的第 j 个单元在平均激活参数 $\bar{\rho}_{i,j}$ (包括所有 m 个训练样本) 尽可能趋近于稀疏目标 ρ 。 J_{sp} 通过 KL 散度定义为:

$$J_{\text{sp}} = \sum_i^5 \sum_j \text{KL}(\rho \parallel \bar{\rho}_{i,j}) = \sum_i^5 \sum_j \rho \log_{10} \frac{\rho}{\bar{\rho}_{i,j}} + (1 - \rho) \log_{10} \frac{1 - \rho}{1 - \bar{\rho}_{i,j}} \quad (11)$$

这里 KL (kullback-leibler) 散度由均值 ρ 以及 $\bar{\rho}_{i,j}$ 来计算,其中稀疏目标 ρ 是一个常数(一般而言是一个极小的数,本实验中,我们把它定义为 10^{-3}),而 $\bar{\rho}_{i,j}$ 则由全部训练样本的隐藏单元的平均激活来定义(参见式(1)和式(2))。

当用训练 DRM 模板来得到特殊类的 DRM 时,可能由于某些类中只有较少的训练样本而得到不太理想的模型。为了克服这一问题,我们对这些较小的类(只含有较少训练样本的类)进行过采样,来产生一些合成的训练样本。具体而言,我们运用少数样本过采样拟合技术(synthetic minority over-sampling technique, SMOTE)^[14]。对每一个较小类中的样本,取其与其相邻样本的差异值,将差值乘以一个 0 到 1 之间的随机数,并加到原始样本上,这样就可以得到一个介于原样本与其相邻样本之间的一个合成样本。合成样本的数目由两个参数控制,这两个参数分别是原始样本相邻的样本数量和原始样本与相邻样本连线上生成点的数量。

2 DRM 用于活动识别

2.1 数据预处理

给定 k 类样本 x 和它们相应的类别标签 y , 样本 x 的特征数记为 d (本实验中 $d=6$)。样本预处理过程如图 3 所示。首先将样本进行归一化和主成分分

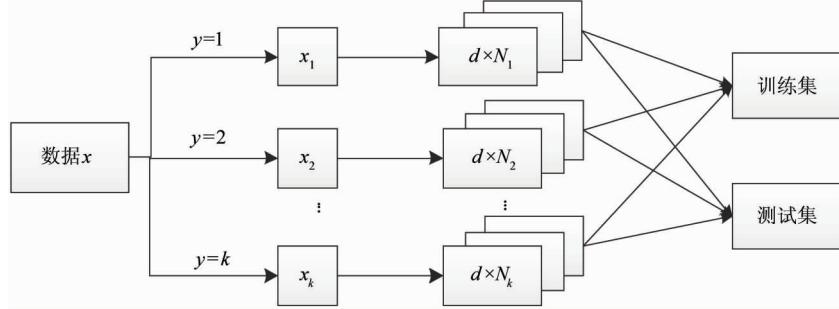


图 3 样本 x 的预处理示意图

2.2 活动识别过程

本文将 DRM 用于 Android 手机数据集的活动识别。如图 1 所示,该过程可分为两个阶段:(1)训练阶段,得到特定类的 DRM;(2)由训练阶段得到的 DRM 决定测试样本的类别。两个阶段的算法总结如下:

第一阶段:深度重构模型的学习

输入:训练样本:

1: 归一化

2:PCA 降维

3: \hat{x} :随机抽取部分训练样本

4:用 \hat{x} 训练 GRBM, 初始化 $\theta_{\text{DRM}} = \{\theta_w, \theta_b\}$

5: for $c = 1, \dots, k$

6: $\theta_c \leftarrow \min_{\theta_{\text{DRM}}} J_{\text{reg}}(\theta_{\text{DRM}}; x_c)$

7: end

输出:每一类的 DRM $\theta_1, \theta_2, \dots, \theta_k$

第二阶段:根据 DRM 进行活动识别

输入: 测试数据 $x_{\text{test}} = \{x^{(t)}; t = 1, 2, \dots, N_{\text{test}}\}$

每一类的 DRM $\theta_1, \theta_2, \dots, \theta_k$

1: 归一化

析(PCA),去掉样本的冗余信息,随后根据标记率计算出每类训练样本的数量 $N_c (c = 1, 2, \dots, k)$, 将每类样本处理成多个 $d \times N_c$ 大小的元胞数组 x_{cell} , 同时生成元胞标签 y_{cell} ,按照不同的标记率,随机选择相应数量的元胞数组作为训练集,剩余的作为测试集。

2: PCA 降维

3: for 每一个 $x^{(t)} \in x_{\text{test}}$

4: for $\theta_c = \theta_1, \dots, \theta_k$

5: $\{\mathbf{W}_e^{(i)}, \mathbf{W}_d^{(i)}, \mathbf{b}_e^{(i)}, \mathbf{b}_d^{(i)}\}_{i=1}^3 \leftarrow \theta_c$

6: $\mathbf{h}^{(t)} \leftarrow s(\mathbf{W}_e^{(3)} s(\mathbf{W}_e^{(2)} s(\mathbf{W}_e^{(1)} \mathbf{x}^{(t)} + \mathbf{b}_e^{(1)}) + \mathbf{b}_e^{(2)}) + \mathbf{b}_e^{(3)})$

7: $\tilde{\mathbf{x}}_e^{(t)} \leftarrow s(\mathbf{W}_d^{(3)} s(\mathbf{W}_d^{(2)} s(\mathbf{W}_d^{(1)} \mathbf{h}^{(t)} + \mathbf{b}_d^{(1)}) + \mathbf{b}_d^{(2)}) + \mathbf{b}_d^{(3)})$

8: $r_c(\mathbf{x}^{(t)}) \leftarrow \|\mathbf{x}^{(t)} - \tilde{\mathbf{x}}_e^{(t)}\|_2$

9: end

10: end

11: 取最小重构误差,投票决策

输出: x_{test} 的标签 y_{test}

由于本实验采用的数据聚集样本数较少,为了避免得到的参数不偏向样本数多的大类,数据归一化和 PCA 降维后,随机挑选部分样本 \hat{x} 初始化所有编码层的参数。得到初始权重后,再用每一类的训练样本分别微调参数 θ_{DRM} ,得到特定类的 DRM,分别记为: $\theta_1, \theta_2, \dots, \theta_k$ 。如下式所示:

$$\theta_c = \underset{\theta_{\text{DRM}}}{{\text{arcmin}}} J_{\text{reg}}(\theta_{\text{DRM}}; x) \quad (12)$$

特定类模型 θ_c 是在所有训练样本 x 的基础上优化代价函数 J_{reg} 得到的。

测试时,输入测试样本 $x_{\text{test}} = \{x^{(t)}; t = 1, 2, \dots,$

N_{test} }, 根据式(1)和式(2)从每个特定类模型 $\theta_c (c = 1, 2, \dots, k)$ 分别重构每个样本 $\mathbf{x}^{(t)}$, 从模型 θ_c 重构出的 $\mathbf{x}^{(t)}$ 记为 $\tilde{\mathbf{x}}_c^{(t)}$, 那么重构误差可由下式计算:

$$r_c(\mathbf{x}^{(t)}) = \|\mathbf{x}^{(t)} - \tilde{\mathbf{x}}_c^{(t)}\|_2 \quad (13)$$

根据重构误差的最小值, 预测出测试样本的标签 \tilde{c} , 即

$$\tilde{c} = \operatorname{argmin}_c r_c(\mathbf{x}^{(t)}) \quad (14)$$

3 实验与结果

本实验将 DRM 用于一个 Android 手机数据集上, 该数据集包含跑步、走路、停留三类活动, 记为 dataset, 如表 1 所示。这个数据集都是用户进行日常活动时通过 Android 智能手机获取的, 数据内容包括加速度、方向、磁场等信息。

表 1 使用数据集详情

数据集	特征数	活动类数	样本数	采集数据时用到的传感器
dataset	6	3	1107	加速度传感器

3.1 实验相关设置

DRM 模板的参数初始化和特定类模型学习阶段, 根据文献[15]、[16]的指导适当调整超参数, 通过交叉验证实验, 搜索最佳参数。实验中试用 GRBM 初始化 DRM 模板, 初始化的权重分布在 $[-0.005, 0.005]$ 之间。实验中随机选 $2/3$ 的训练样本训练 GRBM, 学习率固定为 10^{-3} , 训练重复 20 次, 在标记率 5%、10%、15% 的情况下分别进行实验。其中, 标记率定义为训练样本数占总样本数的百分比。

3.2 实验结果与分析

实验中不断调整编码层的节点数, 实验如表 2 ~ 表 7 所示, $PC(1:i) (i = 2, 3, 4, 5, 6)$ 表示选取了 i 个主特征。由表 2 ~ 表 7 可以看出, 编码层最优节点数为 50 20 10。

表 2 编码层节点数取 20 20 10 时的识别正确率 (%)

标记率	5%	10%	15%
PC(1:2)	59.61(± 0.95)	57.91(± 1.70)	60.31(± 1.79)
PC(1:3)	54.92(± 6.92)	58.45(± 3.50)	60.00(± 6.38)
PC(1:4)	57.42(± 4.49)	81.18(± 15.84)	96.25(± 7.49)
PC(1:5)	54.49(± 7.78)	76.82(± 16.83)	96.41(± 3.96)
PC(1:6)	62.23(± 16.24)	93.18(± 9.51)	99.06(± 1.47)

表 3 编码层节点数取 50 20 10 时的识别正确率 (%)

标记率	5%	10%	15%
PC(1:2)	64.83(± 0.93)	58.00(± 1.66)	61.25(± 1.87)
PC(1:3)	65.34(± 7.39)	74.09(± 15.78)	95.00(± 11.4)
PC(1:4)	82.63(± 11.82)	96.91(± 2.05)	99.69(± 0.096)
PC(1:5)	82.54(± 10.57)	95.18(± 3.35)	95.94(± 3.94)
PC(1:6)	90.30(± 8.31)	97.09(± 2.46)	98.75(± 1.87)

表 4 编码层节点数取 50 30 10 时的识别正确率 (%)

标记率	5%	10%	15%
PC(1:2)	59.84(± 0.93)	58.27(± 2.08)	60.94(± 1.90)
PC(1:3)	59.96(± 8.76)	71.91(± 14.94)	98.75(± 2.13)
PC(1:4)	64.14(± 14.04)	96.36(± 2.77)	98.57(± 1.20)
PC(1:5)	68.44(± 16.40)	95.36(± 2.39)	97.19(± 3.02)
PC(1:6)	77.77(± 17.26)	96.36(± 3.87)	98.91(± 2.10)

表 5 编码层节点数取 50 40 10 时的识别正确率 (%)

标记率	5%	10%	15%
PC(1:2)	59.53(± 0.86)	58.64(± 1.55)	60.63(± 2.36)
PC(1:3)	55.90(± 5.01)	85.45(± 13.83)	99.38(± 1.63)
PC(1:4)	70.70(± 16.91)	96.45(± 2.54)	98.59(± 2.14)
PC(1:5)	77.38(± 14.92)	94.82(± 3.25)	95.63(± 4.47)
PC(1:6)	82.93(± 13.18)	94.82(± 5.35)	94.53(± 7.78)

表 6 编码层节点数取 50 40 20 时的识别正确率 (%)

标记率	5%	10%	15%
PC(1:2)	59.73(± 0.86)	58.91(± 1.81)	60.78(± 2.14)
PC(1:3)	60.47(± 10.45)	71.27(± 17.71)	89.84(± 15.64)
PC(1:4)	66.29(± 16.03)	94.73(± 7.41)	98.59(± 1.89)
PC(1:5)	75.94(± 14.97)	95.00(± 2.49)	97.19(± 4.41)
PC(1:6)	80.23(± 16.34)	95.27(± 3.14)	99.38(± 1.28)

表 7 编码层节点数取 100 50 20 时的识别正确率(%)

标记率	5%	10%	15%
PC(1:2)	59.57 (±0.71)	59.82(±0.71)	60.63(±1.57)
PC(1:3)	72.81(±13.80)	98.18(±2.04)	98.28(±3.72)
PC(1:4)	88.79(±8.89)	94.00(±3.29)	95.47(±4.24)
PC(1:5)	87.54(±9.63)	90.27(±5.94)	93.59(±6.61)
PC(1:6)	90.59(±4.42)	94.64(±5.67)	95.16(±5.87)

表 8 与其他算法识别正确率(%) 的比较

标记率(%)	DRM	PCA + SS – ELM	Tsne – SS – ELM	SS – ELM	GLCT
5	90.30(±8.31)	95.03(±1.24)	92.09(±3.53)	94.98(±1.07)	86.34 (±11.11)
10	97.09(±2.46)	95.03(±1.82)	90.59(±2.86)	94.58(±1.50)	90.17 (±5.42)
15	99.69(±0.96)	95.03(±0.82)	93.44 (±2.38)	93.94(±1.58)	90.81 (±2.96)

由表 8 可以看出, 标记率较低(标记率为 5%) 时, 主成分分析(PCA)与半监督极限学习机(semi-supervised extreme learning machine, SS – ELM)结合时识别正确率较高; 但当标记率较高(标记率为 10% 和 15%) 时, DRM 活动识别效果优于其他 4 种算法, 从而充分证明了 DRM 算法在活动识别领域应用的巨大潜力。

4 结 论

本文提出了一种深度学习框架用于移动环境下的活动识别。具体而言, 引入自适应多层神经网络结构预先训练将参数合理地初始化, 然后根据每类样本微调模型, 学习特定类的深度重构模型。通过自动发现潜在的复杂非线性曲面结构和几何特点, DRM 就能根据每类样本准确建模。最后, 基于测试样本与特定类模型之间的最小重构误差识别活动, 将此框架应用于 Android 手机数据集的活动识别, 识别准确率达到了 99%。

在接下来的工作中, 会将该框架用于更加复杂的活动识别中, 也将探索卷积深度重构模型在活动识别领域的应用。

参考文献

[1] 史殿习, 李勇谋, 丁博. 无监督特征学习的人体活动识别. 国防科技大学学报, 2015, 5: 128-134

最后, 将实验结果与 Lee 和 Cho 在 2014 年提出的全面-局部合作训练(global-local co-training, GLCT) 算法^[17] 的结果及本文作者早期的工作结果进行了比较, 如表 8 所示。

- [2] Liao M, Guo Y, Qin Y. The application of EMD in activity recognition based on a single triaxialaccelerometer. *Bio-medical Materials and Engineering*, 2015, 26 (s1) : S1533-S1539
- [3] Zheng Y. An activity recognition algorithm based on energy expenditure model. In: Proceedings of the 3rd International Conference on Mechatronics, Robotics and Automation, Angkor Wat, Cambodia, 2015. 995-998
- [4] Acharjee D, Mukherjee A, Mandal J K, et al. Activity recognition system using inbuilt sensors of smart mobile phone and minimizing feature vectors. *Microsystem Technologies*, 2016, 22 (11) : 2715-2722
- [5] Yang J B, Nguyen M N, San P P, et al. Deep convolutional neural networks on multichannel time series for human activity recognition. In: Proceedings of the 24th International Conference on Artificial Intelligence, Buenos Aires, Argentina, 2015. 3995-4001
- [6] Brahma P P, Wu D, She Y. Why deep learning works: a manifold disentanglement perspective. *IEEE Transactions on Neural Networks & Learning Systems*, 2016, 27 (10) : 1997-2008
- [7] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief Nets. *Neural Computation*, 2006, 18 (7) : 1527-1554
- [8] Smolensky P. Information processing in dynamical systems: foundations of harmony theory. In: Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations. Massachusetts: MIT Press,

1986. 194-281
- [9] Lee H, Grosse R, Ranganath R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. In: Proceedings of the International Conference on Machine Learning, Montreal, Canada, 2009. 609-616
- [10] Taylor G W, Fergus R, Lecun Y, et al. Convolutional learning of spatio-temporal features. In: Proceedings of the 11th European Conference on Computer Vision: Part VI, Crete, Greece, 2010. 140-153
- [11] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks. *Science*, 2006, 313(5786):504-507
- [12] Hinton G, Osindero S, Welling M, et al. Unsupervised discovery of nonlinear structure using contrastive back-propagation. *Cognitive Science*, 2006, 30(4):725-731
- [13] Hinton G E, Osindero S, Yee-Whye T. A fast learning algorithm for deep belief nets. *Neural Computation*, 2016, 18(7): 1527-1554
- [14] Chawla N V, Bowyer K W, Hall L O, et al. SMOTE: synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 2011, 16(1):321-357
- [15] Hinton G E. A Practical Guide to Training Restricted Boltzmann Machines: [Ph. D Dissertation]. Toronto: Department of Computer Science, University of Toronto, 2010. 1-20
- [16] Bengio Y. Practical recommendations for gradient-based training of deep architectures. *Lecture Notes in Computer Science*, 2012, 7700:437-478
- [17] Lee Y S, Cho S B. Activity recognition with Android phone using mixture-of-experts co-trained with labeled and unlabeled data. *Neurocomputing*, 2014, 126 (3): 106-115

Deep reconstruction models for activity recognition using Android Phones

Wang Jinjia, Tian Peipei

(School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004)

Abstract

The activity recognition using Android phones is studied based on the assumption of the manifold-shaped data, and a deep reconstruction model (DRM) which can learn the complex nonlinear curved surface structure and geometric features of current class samples without a priori assumption of basic geometry is proposed. Firstly, a template of the DRM is defined, and its parameters are initialized by performing the unsupervised pre-training in a layer-wise fashion using Gaussian restricted Boltzmann machines. In the training stage, the initialized DRM template is then separately trained for training the samples of each class and the class-specific DRMs are learnt. In the testing stage, activities are recognized based on the minimum reconstruction error between the learnt class-specific models and the test samples. The experiment performed using the Android mobile phone dataset show that the correct rate of this method for activity recognition is up to 99%.

Key words: activity recognition, deep reconstruction model (DRM), auto-encoder, Android mobile phone, Gaussian restricted Boltzmann machines (GRBMs)