

DOI: 10.11992/tis.201710013

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20180408.1522.018.html>

基于递归神经网络的跌倒检测系统

牛德姣, 刘亚文, 蔡涛, 彭长生, 詹永照, 梁军

(江苏大学 计算机科学与通信工程学院, 江苏 镇江 212013)

摘要:针对现有跌倒检测方法存在适应性差和功能较单一等问题, 引入递归神经网络, 通过发掘位置传感器数据之间的内在联系提高检测跌倒行为的效果。首先, 设计了传感器、训练与检测输入数据的序列化表示方法, 为发掘其中与跌倒和接近跌倒行为相关的内在关联提供了基础; 接着, 给出了用于跌倒检测的 RNN 训练算法以及基于 RNN 的跌倒检测算法, 将跌倒检测转换为输入序列的分类问题; 最后, 在前期实现的基于分布式神经元大规模 RNN 系统的基础上, 在 Spark 平台上实现了基于 RNN 的跌倒检测系统, 使用 Fall_adl_data 数据集进行了测试与分析, 验证了其能有效提高跌倒检测的准确率和召回率, F 值相比现有跌倒检测系统提高 12% 和 7%, 同时能有效检测出接近跌倒的行为, 有助于及时采取保护措施减少伤害。

关键词: 跌倒检测; 接近跌倒检测; 传感器数据; 递归神经网络; 大数据; 跌倒检测算法; 训练算法; RNNFD

中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2018)03-0380-08

中文引用格式: 牛德姣, 刘亚文, 蔡涛, 等. 基于递归神经网络的跌倒检测系统[J]. 智能系统学报, 2018, 13(3): 380-387.

英文引用格式: NIU Dejiao, LIU Yawen, CAI Tao, et al. Fall detection system based on recurrent neural network[J]. CAAI transactions on intelligent systems, 2018, 13(3): 380-387.

Fall detection system based on recurrent neural network

NIU Dejiao, LIU Yawen, CAI Tao, PENG Changsheng, ZHAN Yongzhao, LIANG Jun

(School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang 212001, China)

Abstract: The existing methods of fall detection have poor adaptability and limited functions. In this paper, a recurrent neural network based fall detection system is introduced to improve the performance of fall detection and to make it able to identify more dangerous near-falls by exploring the relationship of the position sensor data. Firstly, a serialization representation method on position sensor data, training and test data is designed as the basis for intrinsic relationship exploration. Then, the training algorithm for RNN based fall detection is proposed, where the fall detection is transformed into a classification problem of the input sequence. Finally, using the large-scale RNN system based on distributed neurons, the fall detection system is implemented on the Spark platform. Evaluations are carried out on Fall_adl_data. The experimental results prove that the proposed system can improve the precision and recall of fall detection effectively. Compared with the existing fall detection systems, F -measure has improved by 12% and 7%, respectively. Moreover, the system is also able to detect the near-fall behavior effectively which helps provide timely protective measures to reduce the damage caused by falls.

Keywords: fall detection; near fall detection; sensor data; recurrent neural network; big data; fall detection algorithm; training algorithm; RNNFD

收稿日期: 2017-10-17. 网络出版日期: 2018-04-09.

基金项目: 江苏省科技厅重点研发计划产业前瞻与共性关键技术项目 (BE2015137); 江苏省自然科学基金项目 (BK20140570); 中国博士后基金项目 (2016M601737).

通信作者: 牛德姣. E-mail: djniu@ujs.edu.cn.

跌倒行为会对人体造成伤害, 特别是对老人、小孩和病人等群体造成的伤害尤其严重。如何对可能出现的跌倒行为进行及时的预警, 从而减少和避免其带来的伤害就显得非常重要。当前国内外相关

的研究主要包括用户自主启动型报警设备^[1]、基于视觉的跌倒检测系统^[2]和基于可穿戴设备的跌倒检测系统^[3]等类型。用户自主启动型报警设备对使用者和使用条件有很多限制,基于视觉的跌倒检测则涉及用户隐私等问题,而基于可穿戴设备的跌倒检测系统具有使用方便、个人隐私性好等优势,成为当前跌倒检测研究和开发中的热点。

阈值法^[4]是最常用的跌倒检测算法,设定一个或多个阈值,通过可穿戴设备传感器获取加速度和角速度等信息进行分类;较低的时间与空间复杂度是其最重要的优点,但如何确定阈值非常困难,同时在应用于差异较大的不同个体时存在准确度差等问题。近年来研究者开始将隐马尔可夫链^[5-6]、动态朴素贝叶斯网络^[7]、支持向量机^[8]、随机森林^[9]和K最近邻^[10]等方法应用到跌倒检测中,这些方法对传感器采集的数据进行抽象后建模用于跌倒行为的分类,具有较强的适应能力。但由于只是使用了传感器数据的某个或某些特性用于检测,仍存在检测精度不足等问题。此外,为了提高准确率,大部分跌倒检测系统只是简单地判断未跌倒和跌倒两种状态,未区分实用价值很高的接近跌倒状态^[11]。

与传统建模或少量数据的训练不同,借助大数据技术,通过大量数据的训练,神经网络模型能挖掘和学习数据内部的复杂结构,从而极大提高分类系统的适应能力和精度,因此基于大数据的神经网络已迅速成为当前研究与开发的热点。与CNN通过滑动窗口保留部分历史输入不同,递归神经网络(RNN)能保留所有的历史输入,通过抽象历史输入之间的关联,具有很高的分类准确性,已被成功应用于自然语言处理领域中,取得了良好的效果。跌倒检测与自然语言处理具有很多相似之处,利用多个传感器的关联关系进行跌倒检测能有效提高检测的准确性,减少个体差异的影响;本文将RNN引入到跌倒检测系统中,主要完成以下几个方面的工作。

1) 根据RNN的特性,对可穿戴设备传感器获取的数据进行重组,转变为适合RNN的输入序列。

2) 借助RNN能够保存历史信息特性,利用其发现和抽象序列内在关系的能力,充分发掘位置传感器数据之间的内在联系,设计了基于RNN的迭代算法,提高了跌倒检测的效果。

3) 在Spark平台上,利用基于RNN的迭代算法,实现了基于RNN的跌倒检测系统,除了与现有跌倒检测系统一样能区分正常和跌倒行为之外,还能准确识别出更具危险性的接近跌倒行为。

4) 使用Fall_adl_data^[12]作为测试数据集进行验

证,相比在同一数据集上的其他算法^[13-14],基于RNN的跌倒检测系统的F值分别提高了12%与8%,并能正确检测出接近跌倒行为,从而更好地提供预警信息。

1 相关工作

1.1 跌倒检测

Vaidehi等^[15]提出了基于人体静态特征的视频检测方法,通过阈值法判断是否跌倒;Bosch等^[16]通过广角摄像头进行跌倒检测,采集人体倾斜角度的变化速度等信息作为特征,通过支持向量机的方法进行跌倒判断,识别率达到97%;佟丽娜等^[17]利用加速度信息作为时间序列,然后使用该时间序列作为训练样本训练隐马尔可夫模型,通过分析当前的输入序列与模型的匹配程度进行跌倒预测并取得良好的预测效果;R. M. Gibson等^[18]比较小波阈值下降强度检测法与PCA决策树两种不同的算法,得出PCA决策树算法具有更好的准确性和鲁棒性;L. Chen等^[7]利用贝叶斯网络来实现人体姿态预测,通过姿态预测结合识别算法来提高预测时间,之后又通过支持向量机的方法进行摔倒识别,召回率与准确率分别达到96.2%与87.3%;D. Luo等^[19]提出了基于随机森林的跌倒检测算法,最终获得95.2%的准确率、90.6%的敏感度和93.5%的特异性,并对比得出优于SVM和反向传播(BP)神经网络检测算法的结论;S. Z. Erdogan等^[10]利用数据挖掘中的K近邻的方法进行跌倒检测,也取得了不错的识别效果。

1.2 递归神经网络的应用

递归神经网络是深度学习领域研究热点之一,近年来,它在语音识别、机器翻译、文本语言处理等领域表现出了巨大的成功^[20-22]。它主要解决了如何处理时间序列上的变化的问题。递归神经网络的应用主要有3个方面:1) 自然语言处理,包括语言模型^[23]、机器翻译^[24]、语音识别^[25]、会话模型^[26]等;2) 计算机视觉方面,包括物体识别^[27]、视频跟踪^[28]、视频分析^[29]等;3) 自然语言处理与计算机视觉相结合,包括图片字幕^[30]、视频字幕^[31]、视觉问题回答^[32]、机器人技术^[33]等。

2 基于RNN的跌倒检测算法

与RNN使用效果较好的自然语言处理领域类似,个体的差异使得单个传感器数据对跌倒行为检测非常有限,甚至会产生负面影响;由多个传感器获取不同数据序列之间的关联性是检测跌倒行为的

关键,本文引入 RNN 来学习和表示这类内在关联关系,设计新型的跌倒检测算法,主要包括传感器数据序列化、RNN 跌倒检测训练算法等部分。

2.1 传感器数据的序列化

在设计 RNN 实现跌倒检测算法时,如何发挥 RNN 在处理序列信息方面的优势是一个关键问题。在跌倒检测中所使用的均是位置传感器,本文定义位置传感器数据序列 SS,包含 XS、YS 和 ZS 3 个传感器值,其中 XS 表示该位置传感器在空间中 X 轴的坐标值,YS 表示该位置传感器在空间中

Y 轴的坐标值,ZS 表示该位置传感器在空间中 Z 轴的坐标值;由此将位置传感器所采集的空间位置信息转为了一个由 3 个坐标值构成的数据序列。

再定义行为训练序列组 AS(SS₁, ..., SS_n, action),其中 SS₁, ..., SS_n 是 n 个位置传感器数据序列组,每个 SS 包含 3 个传感器值;action 表示当前行为的类型,0 表示非跌倒,1 表示跌倒,2 表示接近跌倒。图 1 给出了个体包含两个位置传感器时,分别处于非跌倒和跌倒状态时所对应行为训练序列组的示意图,其中 AS₁ 对应非跌倒状态,AS₂ 对应跌倒状态。




图 1 位置传感器序列产生行为训练序列组 AS 示意图

Fig. 1 AS schematic of the position sensor sequence generates the behavior training sequence group

由此,由同一时刻的所有位置传感器所采集数据和当前的行为类型构建了行为训练序列组,作为 RNN 的输入,利用 RNN 能发现和抽象输入序列中各单元关联关系的优势,获取多个位置传感器之间关联关系的抽象,为提高跌倒检测的准确率和适应能力提供基础。

2.2 用于跌倒检测的 RNN 训练算法

本文以 AS 为单位,将 AS 包含的每个 SS 中的 3 个传感器数值以及 action 作为独立输入单元,然后将该独立输入单元作为输入层的输入用于跌倒检测的 RNN 的训练,输出层计算行为训练序列组当前的概率 p_t ,并统计每个 AS 的总概率 P 作为训练和检测的依据。

用于跌倒检测的 RNN 如图 2 所示,其中 x_t 表示所有行为训练序列组 AS 中第 t 个输入项, y_t 表示第 t 个输入所对应输出向量, U 表示输入层与隐藏层之间的权值矩阵, V 表示隐藏层与输出层之间的权值矩阵, W 表示隐藏层与上一次隐藏层之间的权值矩阵, P 表示 AS 所对应的概率^[34]。




图 2 用于跌倒检测的 RNN 示意图

Fig. 2 RNN schematic for fall detection

训练用于跌倒检测 RNN 之前,将 t 的值初始化为 0,然后将 y_t 的值也初始化为 0,同时随机初始化 U 、 V 和 W 。

对行为训练序列组 AS 中每个输入单元 x_t ,使

用式 (1) 更新隐藏层,其中 f 是 sigmoid 函数,计算方式如式 (2);sigmoid 函数的作用是引入随机性,同时将结果的值映射到 (0, 1)。

$$s_t = f(Ux_t + Ws_{t-1}) \quad (1)$$

$$f(z) = 1/(1 + e^{-z}) \quad (2)$$

然后使用式 (3) 更新输出层,其中 g 是 softmax 函数,计算方式如式 (4);softmax 函数能使输出值在 (0,1),且所有输出值的和为 1,同时使得输出值向 1 或 0 靠近,从而为分类提供方便。

$$y_t = g(Vs_t) \quad (3)$$

$$g(z_m) = \frac{e^{z_m}}{\sum_k e^{z_k}} \quad (4)$$

用 e_o 表示输出层的误差,对 AS 中的每个单元使用式 (5) 进行计算,其中 d_t 是 AS 对应的目标输出向量, y_t 是当前用于跌倒检测 RNN 实际输出向量。

$$e_o(t) = d_t - y_t \quad (5)$$

接着使用式 (6) 计算隐藏层的误差 e_h ,其中 d_h 使用式 (7) 进行计算。

$$e_h(t) = d_h(e_o(t)^T V, t) \quad (6)$$

$$d_h(x, t) = xs_t(1 - s_t) \quad (7)$$

在 RNN 的训练过程中,需要将隐藏层的误差进行递归传递。在每个 AS 训练结束后,使用式 (8) 递归反向传播误差,传播的长度与 AS 包含的单元个数相等。

$$e_h(t - \tau - 1) = d_h(e_h(t - \tau)^T W, t - \tau - 1) \quad (8)$$

此外,针对 AS 中的每个输入单元,使用式 (9) 更新隐藏层与输出层之间的权重矩阵,使用式 (10) 更新输入层与隐藏层之间的权重矩阵,使用式 (11) 更新上一次隐藏层与当前隐藏层之间的权重矩阵。

$$V(t+1) = V(t) + \alpha e_o(t) \cdot s_t^T - \beta V(t) \quad (9)$$

$$U(t+1) = U(t) + \sum_{z=0}^T \alpha e_h(t-z) \cdot x_{t-z}^T - \beta U(t) \quad (10)$$

$$W(t+1) = W(t) + \sum_{z=0}^T \alpha e_h(t-z) s(t-z-1)^T - \beta W(t) \quad (11)$$

式中: β 是正规化参数, α 是学习率, T 是反向传播的步数。当所有的 AS 组成的训练集被用于跌倒检测 RNN 训练后, 调整学习率 α , 若当前训练误差小于给定阈值, 则继续使用相同的 α 值进行训练; 反之则减小 α 的值进行训练。困惑度 (PPL) 是用于衡量跌倒检测 RNN 有效性的重要指标, 在每完成一次所有 AS 的训练后使用式 (12) 进行 PPL 的计算, PPL 值越小, 说明跌倒检测 RNN 的表现越好; 当 PPL 值达到系统设置阈值时, 结束跌倒检测 RNN 的训练。

$$\text{PPL} = \sqrt[k]{\prod_{i=1}^k \frac{1}{y(x_i|x_1 \cdots x_{i-1})}} \quad (12)$$

在以上的训练算法中, 所有的历史数据通过隐藏层都得到了保存, 因此可以全面利用每一条数据信息, 进而为充分发掘位置传感器数据之间的内在联系奠定了基础, 从而在一定程度上提高了跌倒检测的效果。




图3 位置传感器序列产生行为检测序列组 DS 示意图

Fig. 3 DS schematic of the position sensor sequence generates the behavior detection sequence group

接着将所产生的 DS_1 、 DS_2 和 DS_3 作为输入, 送入用于跌倒检测 RNN, 分别计算 DS_1 、 DS_2 和 DS_3 所对应的概率值, 并进行比较, 选取概率值最大的一个 DS, 根据其中 type 的值判断该状态下用户行为的类型。本文在图 4 中以 DS_2 为例, 给出使用跌倒检测 RNN 进行检测的示意, P_7 是 DS_2 整体的概率值。




图4 对行为训练序列组进行训练的示意图

Fig. 4 Schematic diagram of a training sequence of behavior training sequences

行为训练序列组当前的概率 P 使用式 (13) 进行计算, 其中 m 表示该行为训练序列组中的第 m 个单元, 每个 DS 的训练相互独立, 处理完 DS 中的

2.3 基于 RNN 的跌倒检测算法

在使用用于跌倒检测 RNN 判断用户行为时, 本文把跌倒检测转化为一个分类问题, 通过比较用户行为为非跌倒、跌倒、接近跌倒这 3 种状态的概率, 判断用户行为的类型。

定义行为判断序列组 $DS(SS_1, \dots, SS_n, \text{type})$, 其中 SS_1, \dots, SS_n 是 n 个位置传感器数据序列组, 每个 SS 包含 3 个传感器值; type 表示预测行为的类型, 0 表示非跌倒, 1 表示跌倒, 2 表示接近跌倒。

在使用用于跌倒检测 RNN 进行检测之前, 首先使用某一时刻的个体所有位置传感器数据序列组的数据, 分别将 type 值设置为 0、1 和 2, 构建 3 个对应的行为判断序列组。图 3 给出了个体包含两个位置传感器时, 从一组位置传感器数据序列 SS_1 和 SS_2 所产生的 3 个行为判断序列组 DS_1 、 DS_2 和 DS_3 , 其中 DS_1 对应非跌倒状态, DS_2 对应跌倒状态, DS_3 对应接近跌倒状态。由此构建了包含所有位置传感器所采集数据和预测行为类型的行为判断序列组, 作为用于跌倒检测 RNN 判断行为类型的输入, 利用 RNN 能抽象和保存序列中各输入单元之间的关联关系, 通过判断多个位置传感器之间的关联关系, 提高跌倒检测的准确率和适应能力。

type 之后得到该 DS 整体概率。

$$P(x_1, x_2, \dots, x_m) = \prod_{i=1}^m y(x_i|x_1, x_2, \dots, x_{i-1}) \quad (13)$$

3 基于 RNN 的跌倒检测系统

在基于 RNN 跌倒检测算法的基础上, 本文实现了基于 RNN 的跌倒检测系统 (RNNFD), 并构建了测试平台, 使用跌倒检测的标准数据集进行了测试, 依据通用评价指标进行分析。

3.1 原型系统的实现

RNN 的训练时间开销非常大, 本文利用之前所实现的基于分布式神经元的大规模 RNN 系统^[22], 在 Spark 平台上实现基于 RNN 的跌倒检测系统 (RNNFD), 通过分布式内存计算平台减少 RNNFD 的训练时间开销。

RNNFD 的隐藏层中神经元数量是决定跌倒检测准确率的关键因素, 同样也是带来大量训练时间

开销的重要因素, 本文将神经元的数量设置为 200, 正规化参数 β 设置为 10^{-6} , 学习率 α 的初始值设置

为 0.1。

RNNFD 的示意图如图 5 所示。




图 5 RNNFD 的示意图

Fig. 5 Schematic diagram of RNNFD

在训练时, RNNFD 首先将训练集中的位置传感器数据转化为行为训练序列组, 输入后进行训练; 训练完全部行为训练序列组后, 使用验证集中的数据进行验证, 决定是否需要继续训练。

RNNFD 训练完成后, 可以使用测试集中的位置传感器, 转换为行为测试序列组后, 输入 RNNFD

后选择概率最高的行为测试序列组, 根据其中的 type 值, 获得判断的行为类型。

3.2 测试环境与评价指标

3.2.1 测试环境

本文使用 3 台服务器搭建了 RNNFD 的测试环境, 服务器的配置如表 1 所示。

表 1 RNNFD 的测试环境配置

Table 1 RNNFD test environment configuration

配置	服务器 1	服务器 2	服务器 3
CPU 与核心数	48 core	48 core	48 core
内存	64 GB	64 GB	64 GB
操作系统版本	Centos 6.7	Centos 6.7	Centos 6.7
Spark 版本	RDMA-Spark-0.9.1	RDMA-Spark-0.9.1	RDMA-Spark-0.9.1
网络	40 GB Infiniband	40 GB Infiniband	40 GB Infiniband
通信协议	RDMA	RDMA	RDMA

使用 Fall_adl_data 数据集进行测试与分析, 该数据集采集了 18~51 岁 6 名女性与 36 名男性的 42 个样本, 他们的年龄、身高及体重的均值与方差分别为 (24.1 ± 5.7) 岁, (172.2 ± 6.7) cm 和 (69.7 ± 13.1) kg, 每个样本包含 16 万条位置传感器和状态数据, 包括跌倒、接近跌倒、日常活动等状态, 总计 672 万条数据, 能满足 RNNFD 的训练与测试要求。

在构建训练集时, 本文选取了 3 个男性的样本, 具体信息如表 2 所示, 体型特征包括正常、矮胖和高瘦 3 种类型, 具有一定的代表性。RNNFD 的训练集包括 476 858 条行为训练序列组, 每条行为训练序列组包含 4 个传感器数据和 1 个状态信息共 13 个独立输入单元, 整个训练集共计包含 6 199 154 个输入单元。同时, 随机选取了训练集中的 167 953 条行为训练序列组构建验证集, 用于调整学习率, 共计 2 183 389 个输入单元。虽然仅选了 3 个男性样本构建训练集, 但行为训练序列组的数量已经达到 47 万多条, 能较好满足 RNNFD 的训练要求, 避免样本个数较小带来的过拟合现象; 而且, 仅使用 3 个男性样本进行训练, RNNFD 就能够发现行为训

练数据的内在关联, 并与现有算法比较在较大规模的测试集上的准确率。

表 2 训练集的构建

Table 2 Training set construction

样本	年龄/岁	身高/cm	体重/kg	性别
样本 1	23	174	75	男
样本 2	19	168	84	男
样本 3	21	185	82	男

此外, 从余下的 39 个样本中随机抽取 273 条传感器数据构建了 5 个测试集用于测试, 共计 819 条行为检测序列组, 包含 10 647 个输入单元。

3.2.2 评价指标

使用以下几个量化指标评测基于 RNN 的跌倒检测系统。

TP: 能够检测出的跌倒次数。

FP: 误判为跌倒的次数。

TN: 没有误判为跌倒的次数。

FN: 没有判断出来的跌倒次数。

准确率: $PP = TP / (TP + FP)$

召回率: $R = TP / (TP + FN)$

准确率与召回率是用在信息检索、分类、识别等领域的基本指标,用来评价结果的质量;准确率用来衡量一个系统的查准率,召回率用来衡量一个系统的查全率。

$$F_{\gamma} = \frac{(\gamma^2 + 1)PP \times R}{\gamma^2(PP + R)}$$

式中: γ 是参数, PP 与 R 分别是准确率与召回率,本文取 $\gamma = 1$, 其值此时表示为 $F = (2 \times PP \times R) / (PP + R)$ 。因此 F 值综合了准确率与召回率,是准确率与召回率的调和平均值,也是综合二者指标的评估指标,用于综合反映整体的指标; F 值越高说明跌倒检测方法越有效。

3.3 测试与分析

测试 RNNFD 检测跌倒行为的准确性并把结果与相关算法进行比较,同时测试 RNNFD 检测接近跌倒状态的结果。

3.3.1 检测跌倒行为的效果

使用 5 个测试集测试 RNNFD 识别跌倒行为的效果,结果如表 3 所示。

表 3 RNNFD 检测跌倒行为的测试结果

Table 3 RNNFD test results for falls behavior

测试集	TP	FP	TN	FN	PP/%	R/%	F/%
测试集 1	45	3	10	5	93.75	90	91.84
测试集 2	13	1	9	2	92.86	87	89.66
测试集 3	20	2	18	2	90.1	90.1	90.1
测试集 4	43	5	6	8	85.58	84.31	86.87
测试集 5	50	3	21	7	94.54	90.91	92.59
总计	171	14	64	24	92.43	87.69	90

从实验结果可以发现, RNNFD 能保持较高的准确率与 F 值, 准确率的平均值在 92% 左右, F 值的平均值在 90% 左右。同时, 还可以通过增加隐藏层中神经元数量的方式, 进一步提高识别跌倒行为的效果; 此外, 也可以通过增加训练样本的方式, 提高 RNNFD 的检测效果。这表明, RNNFD 能在仅使用少量个体样本数据进行训练时, 就能在大其 10 倍的测试数据集上取得较高的准确性, 验证了 RNNFD 具有很强的检测能力; 同时在训练时仅使用了 19~23 岁的男性样本, 但仍然能检验出测试集中的 18~51 岁的女性和男性行为, 说明 RNNFD 能有效地发掘行为训练序列组中 4 个传感器数据和 1 个状态信息的内在关联, 具有良好的适应能力。

3.3.2 与其他跌倒检测算法的比较

本文将 RNNFD 与文献[13-14]中的跌倒检测算法进行比较, 相应的 F 值如表 4 所示。

表 4 不同跌倒检测算法的比较

Table 4 Comparison of different falling detection algorithms

算法	F/%
LI ET ^[14]	79
CHEN ET ^[13]	83
RNNFD	90

从表 4 的结果可以发现, RNNFD 相比文献[13]和[14]中的算法, 能有效地提高 F 值, 达到了 90%, 相对文献[14]的 F 值提高了 12%, 相对文献[13]的 F 值提高了 7%。这说明, RNNFD 相比现有的跌倒检测算法具有更高的查准率与查全率。同时也说明, 相比于其他算法 RNNFD 能够更加有效地发现和抽象数据的内在关联, 能更好地实现跌倒行为的检测。

3.3.3 检测接近跌倒的结果

再测试 RNNFD 识别接近跌倒行为检测序列组效果, 同样也使用 5 个测试集, 测试结果如表 5 所示。

表 5 接近跌倒的检测情况

Table 5 The detection of near falls

数据集	总行为检测 序列数组	接近跌倒行为 检测序列数组	预测正确 条数	准确率 /%
测试集 1	189	26	22	84.46
测试集 2	75	5	5	100
测试集 3	126	10	10	100
测试集 4	126	30	24	80
测试集 5	243	8	8	100
总计	819	79	69	87.34

从表 5 的结果中可以发现, RNNFD 能有效地识别出接近跌倒的行为检测序列组, 平均准确率达到 87.3%, 这表明 RNNFD 在进行接近跌倒的行为检测时, 也表现出了很强的适应性, 能够有效地利用检测的数据并且最大可能地发掘状态信息之间的内在关联性; 同时也说明, RNNFD 具有比其他跌倒检测系统更强的检测能力, 能识别出具有很大危险性同时也是很难区分出的接近跌倒状态, 为提前采取相应防护措施提供了基础, 从而能有效减少跌倒带来的危害。

4 结束语

本文将 RNN 引入到跌倒检测的研究中, 利用 RNN 能发现和抽象序列中内在关联关系的特性, 通过发掘位置传感器数据之间内在关联关系, 这些内

在关联关系是难以用现有的方法准确表达出来的,通过以上方法提高跌倒检测的准确性。在分析跌倒检测要求的基础上,针对RNN的特点,设计了序列化的传感器数据、RNN训练与检测输入表示方法,给出了用于跌倒检测的RNN训练算法以及基于RNN的跌倒检测算法,将跌倒检测转换为输入序列的分类问题;并在本文前期所实现的基于分布式神经元大规模RNN系统的基础上,在Spark平台上实现了基于RNN的跌倒检测系统,使用Fall_adl_data数据集进行了检测效果和对接近跌倒数据检测能力的测试与分析,验证了RNNFD能有效提高跌倒检测的准确率, F 值相比现有跌倒检测系统能提高12%和7%,并且能够检测出接近跌倒行为。


下一步将进一步优化用于跌倒检测RNN的训练方法,同时考虑使用LSTM减少时间开销,提高准确率。

参考文献:

- [1] 吴天昊. 基于3轴加速度传感器及陀螺仪的老年人摔倒识别[D]. 北京: 北京工业大学, 2013: 2-3.
WU Tianhao. Identification of old people's fall-downing based on 3-axis acceleration sensor and gyroscope[D]. Beijing, China: Beijing University of Technology, 2013: 2-3.
- [2] ROUGIER C, MEUNIER J, ST-ARNAUD A. 3D head tracking for fall-down detection using a single calibrated camera[J]. Image and Vision Computing, 2013, 31(3): 246-254.
- [3] MUBASHIR M, SHAO L, SEED L. A survey on fall-down detection: Principles and approaches[J]. Neurocomputing, 2013, 100(2): 144-152.
- [4] MATHIE M J, BASILAKIS J, CELLER B G. A system for monitoring posture and physical activity using accelerometers[C]//International Conference of the IEEE Engineering in Medicine and Biology Society. Istanbul, Turkey, 2001: 3654-3657.
- [5] 卢先领, 王洪斌, 王莹莹, 等. 一种基于加速度传感器的人体跌倒识别方法[J]. 计算机应用研究, 2013, 30(4): 1109-1111.
LU Xianling, WANG Hongbin, WANG Yingying, et al. Human fall-downing detection based on accelerometer[J]. Computer Application Research, 2013, 30(4): 1109-1111.
- [6] FANG-YIE LEU, CHIA-YIN KO, YI-CHEN LIN, et al. Smart Sensors Networks[M]. United Kingdom: Mara Conner, 2017: 205-237.
- [7] CHEN L, MA H T, LIU S, et al. Posture estimation by Bayesian Network with Belief Propagation[C]//TENCON 2013-2013 IEEE Region 10 Conference. Xi'an, China, 2013: 1-4.
- [8] Duan K B, Keerthi S S. Which is the best multiclass SVM method? An empirical study[M]// Multiple Classifier Systems. Springer Berlin Heidelberg, 2005: 278-285.
- [9] BREIMAN L. Random forest[J]. Machine learning, 2001, 45(1): 5-32.
- [10] SZ Erdogan, TT Bilgin, J Cho. Fall-down detection by using K-nearest neighbor algorithm on WSN data[C]// GLOBECOM Workshops. Houston, USA, 2011: 2054-2058.
- [11] WU G, XUE S. Portable preimpact fall-down detector with inertial sensors[J]. IEEE Transactions on Neural Systems & Rehabilitation Engineering, 2008, 16(2): 178-183.
- [12] OJETOLA O, GAURA E, BRUSEY J. Data set for fall-down events and daily activities from inertial sensors [C]//ACM Multimedia Systems Conference. Oregon, USA, 2015: 243-248.
- [13] CHEN J, KWONG K, CHANG D, et al. Wearable sensors for reliable fall-down detection[C]//International Conference of the IEEE, NEW YORK, USA, 2006: 3551-3554.
- [14] LI Q, STANKOVIC J A, HANSON M A, et al. Accurate fast fall-down detection using gyroscopes and accelerometer-derived posture information[C]//Sixth International Workshop on Wearable and Implantable Body Sensor Networks. CA, USA, 2009: 138-143.
- [15] VAIDEHI V, GANAPATHY K, MOHAN K, et al. Video based automatic fall-down detection in indoor environment[C]// International Conference on Recent Trends in Information Technology. Chennai, INDIA, 2011: 1016-1020.
- [16] BOSCH-JORGE M, SÁNCHEZ-SALMERÓN A J, ÁNGEL VALERA, et al. Fall-down detection based on the gravity vector using a wide-angle camera[J]. Expert Systems with Applications, 2014, 41(17): 7980-7986.
- [17] 佟丽娜, 宋全军, 葛运建. 基于时序分析的人体摔倒预测方法[J]. 模式识别与人工智能, 2012, 25(2): 273-279.
TONG Linna, SONG Quanjun, GE Yunjian. Time series analysis based human fall-down prediction method[J]. Pattern Recognition & Artificial Intelligence, 2012, 25(2): 273-279.
- [18] GIBSON R M, AMIRA A, CASASECA-DE-LA-HIGUERA P, et al. An efficient user-customisable multiresolution classifier fall-down detection and diagnostic system[C]//International Conference on Microelectronics. Changchun, China, 2015: 228-231.
- [19] LUO D, LUO H, SCHOOL I. Fall-down detection algorithm based on random forest[J]. Journal of computer applications, 2015, 35(11): 3157-3160.
- [20] 胡二雷, 冯瑞. 基于深度学习的图像检索系统[J]. 计算机系统应用, 2017, 26(3): 8-19.
HU Erlei, FENG Rui. Image retrieval system based on

- deep learning[J]. Computer systems and applications, 2017, 26(3): 8–19.
- [21] 焦李成, 杨淑媛, 刘芳, 等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(8): 1697–1716.
- JIAO Licheng, YANG Shuyuan, LIU Fang, et al. Seventy years beyond neural networks: retrospect and prospect[J]. Chinese Journal of Computers, 2016, 39(8): 1697–1716.
- [22] DEJIAO NIU, RUI XUE, TAO CAI, HAI LI, EFFAH KINGSLEY. The new large-scale RNNLM system based on distributed neuron[C]//Parallel and Distributed Processing Symposium Workshops. Florida, USA, 2017: 433–436.
- [23] YONG Z, MENG J E, VENKATESAN R, et al. Sentiment classification using comprehensive attention recurrent models[C]//International Joint Conference on Neural Networks. Vancouver, Canada, 2016: 1562–1569.
- [24] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN Encoder-Decoder for statistical machine translation[C]//Conference on Empirical Methods in Natural Language Processing. Doha, Qatar, 2014: 1724–1734.
- [25] 张舸, 张鹏远, 潘接林, 等. 基于递归神经网络的语音识别快速解码算法[J]. 电子与信息学报, 2017, 39(4): 930–937.
- ZHANG Ge, ZHANG Pengyuan, PAN Jieli, et al. Fast decoding algorithm of speech recognition based on recursive neural network[J]. Journal of Electronics Information Technology, 2017, 39(4): 930–937.
- [26] MEI H, BANSAL M, WALTER M R. Coherent dialogue with attention-based language models[C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence. San Francisco, America, 2017: 3252–3258.
- [27] BAI J, WU Y. SAE-RNN Deep learning for RGB-D based object recognition[C]//International Conference on Intelligent Computing. Odisha, India, 2014: 235–240.
- [28] FAN H, LING H. Sanet: structure-aware network for visual tracking[C]//Computer Vision and Pattern Recognition Workshops. Honolulu, USA, 2017: 2217–2224.
- [29] 蔡政. 面向社交网络的 GIF 视频情感标注与分析技术研究[D]. 福建: 厦门大学, 2016: 10–15.
- CAI Zheng. Research on the emotional annotation and analysis of GIF video for social network[D]. Fujian: Xiamen University, 2016: 10–15.
- [30] ZHANG H, LI J, JI Y, et al. A character-level sequence-to-sequence method for subtitle learning[C]//International Conference on Industrial Informatics. Poitiers, France, 2016: 780–783.
- [31] SHETTY R, LAAKSONEN J. Video captioning with recurrent networks based on frame- and video-level features and visual content classification [C]. Santiago, ICCV workshop, 2015.
- [32] MALINOWSKI M, ROHRBACH M, FRITZ M. Ask your neurons: a deep learning approach to visual question answering[J]. International Journal of Computer Vision, 2017, 125(1–3): 110–135.
- [33] 姜春福, 余跃庆. 基于状态延迟动态递归神经网络的机器人动态自适应跟踪辨识[J]. 自动化学报, 2003, 29(5): 741–747.
- JIANG Chun-Fu, YU Yue-Qing. Sddrnn based dynamical adaptive tracking identification of robot manipulators[J]. Proceedings of the CSU-EPSCA, 2003, 29(5): 741–747.
- [34] MIKOLOV T A. Statistical language models based on neural networks[D]. Brno, Czech Republic: Brno University of Technology, 2012: 27–43.

作者简介:



牛德姣, 女, 1978 年生, 副教授, 博士, 主要研究方向为神经网络、新型非易失存储器。发表 SCI 和 EI 检索论文 10 余篇。



刘亚文, 女, 1994 年生, 硕士研究生, 主要研究方向为神经网络、大数据计算。



蔡涛, 男, 1976 年生, 副教授, 博士, CCF 会员, 主要研究方向为面向大数据人工智能和新型非易失存储器。发表 SCI 和 EI 检索论文 30 余篇。