

DOI: 10.13382/j.jemi.B2002929

基于卷积长短时深度神经网络行为识别方法^{*}

王丽君¹ 刘彦戎¹ 王丽静²

(1. 陕西国际商贸学院 咸阳 712046; 2. 西安石油大学 西安 710300)

摘要:传统的人员行为识别中,通过人工特征对人员行为进行分类。这些方法仅能够利用较浅层次的特征,其识别准确率有限。提出通过卷积长短时深度神经网络(convolutional long short-term deep neural networks, CLDNN)进行人员行为识别,并用新的GRU门控单元代替传统的LSTM门控单元提高网络效率。利用该网络结构,既可提取惯性数据中多层次特征,也可充分利用时间序列相关性。通过开源数据集的实验证明,该方法相比于传统的卷积网络和基于LSTM门控循环神经网络的识别准确率分别提高了约3%和7%;用GRU门控单元代替LSTM单元后,所需的训练时间和前向的识别时间分别下降了14%和10%。

关键词: 人员行为识别;惯性数据;深度神经网络

中图分类号: TP24;TN96 **文献标识码:** A **国家标准学科分类代码:** 510.51040

CLDNN based human activity recognition method

Wang Lijun¹ Liu Yanrong¹ Wang Lijing²

(1. Shaanxi Institute of International Trade& Commerce, Xianyang 712046, China;

2. Xi'an Shiyou University, Xi'an 710300, China)

Abstract: Traditional machine learning based methods use hand-crafted features in the inertial data to achieve the task of human activity recognition (HAR). However, as these features are normally without abstract high-level knowledge, the recognition rate is thus limited. Deep learning based methods, on the other hand, can avoid the aforementioned disadvantage by learning high-level features through labeled data. In this paper, the convolutional long short-term deep neural networks (CLDNN) is adopted for solving the HAR problem. This network has the features of both the convolutional neural network (CNN) and the recurrent neural network (RNN), which can extract features of different levels and can adopt the correlations in time sequences. Moreover, we use the GRU instead of LSTM as the gated cell of the RNN, which can make the network lighter. Through experiments adopting open source data, we can show that our method has 3% and 7% better recognition rate than CNN and RNN respectively, the training time and forward recognition time has decreased by 14% and 10% respectively, if replace the LSTM with GRU cell.

Keywords: human activity recognition; inertial data; deep neural network

0 引言

通过对人员的行为进行识别,可以为医疗健康、智能家居等热门应用提供有用的信息参考,近年来成为了研究的热点。通常来说,根据识别需要部署的传感器种类的不同,人员行为识别大致可以分为3类^[1],基于视觉的、基于环境设备的和基于惯性传感器的。

其中基于视觉的方式,由于需要在环境中安装摄像头等监控设备,存在一定的隐私问题,并且通过图像作为信息源输入识别算法,在人员密度较高,遮挡较高时其识别精度大大下降,甚至失效^[2-3]。基于环境设备的方式中,通常需要在人员经常活动的场所中,较为密集布置传感器,如压力传感器、WiFi路由传感器等。压力传感器的配置中,通过收集多传感器的反馈的压力信息进行行为识别^[4]。WiFi路由传感器配置中,通过

收稿日期:2020-01-15 Received Date: 2020-01-15

^{*} 基金项目:陕西省教育厅专项科学研究(18JK1041)、物联网与智能技术科技创新团队建设项目(SSY18TD05)资助

监测 WiFi 路由发射和接收器之间的信道状态,从而对人员的行为进行识别,但是容易受到其他电磁信号的干扰^[5]。基于环境设备方式中,整体来说,由于需要密集的传感器布置,成本较高,并且通常来说识别率较低。基于惯性传感器的方式中,通过可穿戴设备或智能手机(通常包含惯性传感器)等收集人员采集的惯性观测数据,从而对人员的行为进行识别分类^[6-7]。由于惯性观测数据直接反应了人员的运动方式,因此该方式的识别率较高。并且由于可穿戴设备或智能手机的普及,获取数据的成本降低。

基于惯性传感器的人员行为识别在上述几种人员行为识别方式当中,有着较为广泛的实际应用价值。在医疗健康领域,可通过人员惯性数据观测检测病人是否中风、老人的是否跌倒^[8]等。另外,基于惯性数据的人员行为识别作为室内惯性人员定位预处理过程。可以为室内人员定位提供辅助信息^[9],从而根据不同的人员行为设计不同的室内定位算法,从而使得室内人员定位的精度更高。比如,可以根据人员不同的行为,设计不同的策略估计人员的行走步长与行走方向,从而通过经典的步行者航位推算(pedestrian dead reckoning, PDR)算法估计室内人员的精确位置^[10]。文献[11]利用通过循环神经网络(recurrent neural network, RNN)对人员行为进行运动单元(action unit)检测,能够对左转、右转和不同步幅进行检测识别,为后续的定位提供依据。该方法中的识别准确率达到97%,但是其目的是应用于后续的定位过程,因此行为识别的种类十分有限。

传统的基于惯性传感器的人员行为识别方法通常通过人工提取数据中的特征进行行为识别。文献[12]通过信号的能量、方差和短时傅里叶变换的谱特征作为分类的特征向量,再通过多变量决策树分类器进行分类。该文献还开源了基于惯性人员行为识别的相关数据集,该数据集中,包含了3种有限的人员行为,分别为行走、跑步和静止站立,同时也包含了惯性传感器在不同位置的测量,包含静止手持、摇摆手持、随身口袋和背包中。通过决策树和支撑向量机方法进行识别后,识别准确率仅约77%。文献[13]通过时域的惯性传感器测量,以2 s的时间窗位作为样本,提取特征向量,再利用支持向量机(SVM)分类器对人员进行分类识别。但是,该方法在仅有5类的数据集中,识别率仅有88%。文献[14]尝试利用了多种分类的方法,如决策树、SVM、贝叶斯分类器和马尔可夫模型等进行人员行为分类。但是,这些方法在一定条件下虽然能够完成一定的人员行为识别分类的任务。但是,这些分类方法严重依赖于人工选取的特征向量,这些特征向量中的元素通常具有具体的物理意义,如前文提到的信号能量、方差等。正是由于这些特征通过人工定义并且提取,更加本质、更加深层次的分类特征通

常未充分利用^[15]。

由于深度学习技术能够从大量数据中学习到不同尺度、不同层次的特征,在图像、语音识别等领域中被证明相比于传统方法有准确的识别率^[16]。其分类依靠的特征通过数据进行学习,无需人为定义相关特征,因此通常来说有更好的分类效果。深度学习技术也被应用到了人员行为识别的领域。文献[17]利用了深度卷积网络(convolutional neural network, CNN),通过多层的卷积滤波器提取惯性数据中不同尺度、不同层次的特征,最后通过全连接层、池化层和 Softmax 层对行为进行分类,得到每一个行为的概率,并且通过最大概率确定当前惯性数据的行为。文献[18]RNN 提取惯性数据中的时间的相关性进行识别。为了降低 RNN 的复杂度,并且使得信息能够在时间域进行传播,长短期记忆网络单元被提出。可以将之看成神经网络中的神经元,通过时间上的展开,可以学习出时间上的相关性。由于其具有此特性,在自然语言处理领域得到了广泛应用。

本文结合了深度卷积网络和循环神经网络,将应用到语音处理的卷积长短时深度神经网络(convolutional long short-term deep neural networks, CLDNN)^[19]应用到人员行为识别领域。该网络既可以通过数据学习到深层次的高抽象度的特征,同时可以学习到时间的相关性用于分类任务。由于本文的应用中,惯性观测数据本质上是时间序列,因此适合利用该网络。本文在具体应用中改进了 CLDNN,前2层与传统的 CLDNN 一样是卷积层,后2层为将传统的级联 LSTM 单元换为了门循环单元(gated recurrent unit, GRU)层。GRU 单元与 LSTM 单元相比,内部的网络的层数由4层减少到了3层,同样能够支持信息在时间上的流动,并且使得网络的学习效率更佳。最后,本文通过开源数据集的实验,证明了本文用到的 CLDNN 网络相对于传统的决策树、SVM 方法以及普通的 CNN 网络和 RNN 网络,有更好的识别准确度。并且,相比于利用 LSTM 单元的传统 CLDNN 网络,虽然本文提出的利用 GRU 单元的 CLDNN 网络的识别率大致相同,但是复杂度降低,所需要的训练时间减少,前向的识别更快,更加适合实时的人员行为识别。

1 方法

本文通过 CLDNN 网络根据惯性观测数据对人员行为进行分类。CLDNN 网络特点是结合了卷积网络 CNN、循环神经网络的相关特征。因此,其具有 CNN 网络中能够方便提取输入信息不同尺度的特征,并且具有一定的空间和时间的不变性的特征,也能够像循环神经网络 RNN 一样利用信息的时间相关性。分别介绍卷积网络 CNN 和循环网络 RNN 的特点以及在人员识别分类中的

应用特点,再介绍两者结合的 CLDNN 网络在本方法中的应用。

1.1 卷积神经网络基础

卷积网络中,通过卷积运算代替普通的网络层级中的矩阵乘法运算。卷积神经网络中,通过一定的卷积核对上一层的输出或输入数据进行滑动的卷积运算,得到卷积后的输出。通常来说,卷积核又可以称作卷积滤波器,同一层级的卷积层中,通常采用多个不同的卷积核进行运算,可以提取到输入数据中不同类型的特征,从而有助于分类的任务。通过卷积运算后,再通过池化层对输出的部分进行降采样或较小邻域内统计特征的提取,达到减小计算量的效果。

卷积网络的主要优点或特征主要有 3 点^[16]:1) 稀疏交互,相比于全联接的矩阵相乘,卷积核较小,所需要的权值参数相对减少;2) 参数共享,对相同的卷积核,共享一个卷积核的参数,并且可以对所有输入数据进行处理;3) 等变表示,对输入数据做较小时间或空间上的平移,对分类的影响较小。这些特点决定了卷积网络的优点,总结起来就是对不同尺度特征提取的有效性,降低学习测试成本,并且对输入在时间和空间上的变换不敏感。

本文用到的数据为人员的惯性数据,可能相同的人员行为中,惯性数据存在时间上的不对齐、更深尺度的特征(如行走过程中包含不同的速度、方向等)等,适合利用卷积网络提取特征。

1.2 循环神经网络基础

循环神经网络 RNN 通过在时间域对计算图的展开获得序列输入数据的依赖关系。在时间的展开过程中,由于不同时刻对应的输入数据经过相同的 RNN 计算单元的处理,并且这些单元共享权值,使得网络能够学习到上下文的相关性^[16]。但是,正是由于时间上的展开时的权值共享特性,导致 RNN 存在较为严重的梯度消失和梯度爆炸问题^[20]。为了解决该问题,使得 RNN 网络更加实用,文献[16]提出了基于门控的循环神经网络(gated RNN)。该网络中,将需要通过时间展开的运算重新设计,使得网络既能够积累之前时间的信息,也能够逐渐忘记之前时间较为不重要的信息,从而减少冗余。最常用到的门控单元为长短期记忆(LSTM)门控单元。如图 1 所示,每个 LSTM 门控单元包含 3 个门,输入门、遗忘门和输出门。输入门处理输入的数据:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1)$$

式中: h_{t-1} 表示从前一时刻的门控单元的记忆输出,也可以看做上下文向量; x_t 表示当前时刻的输入; $\sigma(\cdot)$ 通常为 Sigmoid 激活函数。输出门分别处理得到当前单元的输出 o_t 和当前单元输入到下一单元的上下文向量 h_t :

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (3)$$

式中: C_t 表示根据遗忘门得到的状态。遗忘门的处理表示如下:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{C}_t \quad (4)$$

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

LSTM 门控单元由于可较为有效地避免梯度消失或爆炸问题,因此在 RNN 中应用广泛,然而由于一个 LSTM 中包含上述的 3 种不同的门运算,因此其训练成本仍然较大。




图 1 LSTM 门控单元模型

Fig. 1 The model of the LSTM gated cell

本文利用 GRU^[21]代替传统的 LSTM 单元。GRU 单元是对 LSTM 一种改进,其内部仅包含 2 个门控制,重设门和更新门,其框图如 2 所示。GRU 单元的更新门包含了 LSTM 单元中输入门和遗忘门的功能。




图 2 GRU 门控单元模型

Fig. 2 The model of the GRU gated cell

重设门为:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (6)$$

更新门为:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (7)$$

GRU 单元的输出为:

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \hat{h}_t \quad (8)$$

其中 $\hat{h}_t$ 为:

$$\hat{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t]) \quad (9)$$

1.3 本文用到的神经网络模型

本文结合了经典的卷积神经网络 CNN 和循环神经

网络 RNN 的模型,将应用到语音处理的卷积长短时深度神经网络 CLDNN^[19]应用到人员行为识别领域。本文应用的数据是人员行走时的惯性数据,包含 3 轴的线性加速度、3 轴的加速度、3 轴的陀螺仪输出(即为 3 轴的角速度),总共 9 轴的惯性数据。这些惯性数据在时间上进行采样,取 128 个采样点的 9 轴的数据作为一个样本,进行分类。因此,若不考虑训练时的批处理大小的维度,输入到 CLDNN 网络的样本数据维度为 [128,9]。

本文采用的 CLDNN 的结构如图 3 所示。首先将数据输入 2 层卷积层,2 层卷积层中的卷积核大小均为 3×3 ,深度均为 10,2 层中均包含 max pooling 操作,从而减小计算量。2 层卷积层后,展开连接至线性层,将线性层的输出作为 GRU 单元的输入。本文采取 2 层 GRU 单元级连的形式,每 1 层的 GRU 单元在时间上分别进行各自展开。本文 2 层 GRU 单元的输出展开后,一层全联接层和 Softmax 层,最终得到样本属于不同行为类别的概率。




图 3 CLDNN 网络模型

Fig. 3 CLDNN network based model

根据上述的网络,本文分别建立训练数据集与测试数据集。本文所用到的数据集中的样本,从本质上来说,是时间序列。在生成样本时,为了避免在时间上粗暴地截断,从而影响时间序列的相关性,本文采取了样本时间序列重叠的方法,重叠率为 50%。

2 实验及结果分析

2.1 实验数据描述

本文的实验采用了 UCI 大学的人员行为识别开源数据集,可以方便地进行不同方法识别率的比较。

该数据集通过不同年龄的人群,由腰载的智能手机录取得到。该数据集中,总共包含 6 类不同的人员行为平地行走、上楼、下楼、静止站立、坐下和平躺。手机采集人员的 9 轴惯性测量,包含 3 轴的线性加速度、3 轴的加速度和 3 轴的角速度。该数据中,每个样本包含上述的 9 轴数据的 128 个时间采样点,采样率为 50 Hz,并且每个样本的在时间上存在重叠,重叠率为 50%。一个样本的采样点形成的 9 轴惯性数据的曲线如图 4 所示,该样本从训练集中取出,并且对应的人员行为为上楼。该数据集中,随机选择其中的 70% 作为训练数据,剩下的 30% 作为测试集。




图 4 本文所用的数据集一个样本对应的 9 轴惯性数据(该样本对应的人员行为为上楼)

Fig. 4 A 9-axis inertial data sample in the dataset (this sample corresponds to going upstairs)

2.2 实验结果

本文在训练过程中,将训练样本划分为 1 500 的较小批输入 CLDNN 神经网络进行训练。用到的代价函数为交叉熵代价函数,并且用到的优化器为 Adam(adaptive moment estimation)优化器,可以自适应地得到学习率,相比于许多其他的优化器有更好的稳健性。本文用到的深度学习框架为开源的 Tensorflow 框架,集成了较好的深度学习 API,非常适用深度学习的相关研究。

本文的方法的测试集的相对于训练识别率曲线如图 5 所示。由图 5 可以看出,当训练的循环数达到约 510 000 次时,测试集的识别率基本达到稳定,增加训练的循环次数,能够继续降低学习的代价,但是对测试集识别率的提高效果不明显。本文采用循环次数达到 510 000 时的网络作为测试的神经网络,此时测试集的识别准确率约为 96%。本文方法中得到的测试集中不同行为识别的归一化混淆矩阵如图 6 所示。注意,此处将不同种类的识别率或错误识别率进行了四舍五入进行显示。由图 6 可以看出,两种行为的混淆较大,分别是坐下和站立,坐下的情况下有约 5% 被识别为静止站立,静止站立的

情况下约 6% 被识别为坐下。可能是由于该两种行为都是静止行为,反映在惯性观测数据上不存在较大波动,并且由于可能两种行为中,手机的姿态差别较小,从上述的 9 轴运动数据中较难区分,因此分别存在 5% (从坐下混淆为站立) 和 6% (从站立混淆为坐下) 的识别率误差。




图 5 测试数据识别率曲线

Fig. 5 The recognition accuracy curve against training epochs




图 6 混淆矩阵

Fig. 6 Confusion matrix

2.3 结果对比

本文主要提出 2 个指标对不同方法的效果进行对比,分别为识别准确率 (accuracy) 与查全率 (recall)。识别准确率表示所有类别中的正确识别的样本数目之和与总样本数目的比例,该比例越高说明该方法效果越好。另一个指标为查全率,表示某类中正确识别的样本数目与该类样本的总数的比例。本文中的样本中存在多个类,因此本文中采用多类的平均查全率表示。一般来说,查全率越高对应方法的效果越好。

表 1 为传统的决策树、SVM 和基于深度学习技术的方法本文用到的 CLDNN 网络、普通的利用 LSTM 门控单元的 RNN 网络和普通的 CNN 网络方法的测试集识别准确率对比。可以看出,总体来说,基于深度学习技术的识别准确率和查全率相比于传统的方法更高。在基于深度学习的方法中,本文所用到的 CLDNN 网络存在更高的识别准确率,达到 96%。相比于普通的 RNN 网络和 CNN 网络,分别提高了 3% 和 7%;而查全率分别提高了约 3% 和 6%。

表 1 不同方法识别准确率对比
Table 1 Comparison of recognition accuracy of different methods (%)

方法	准确率	查全率
CLDNN (本文)	96	98
RNN (LSTM 门控)	93	95
CNN	89	92
决策树	82	85
SVM	87	90

表 2 为本文用到的 CLDNN 网络,用 GRU 门控单元替代了传统的 LSTM 门控单元,和传统的利用 LSTM 门控单元形成的 CLDNN 网络的识别准确率、训练时间和前向识别时间的对比。可以看出,通过 GRU 单元替代了传统的 LSTM 单元后,识别率几乎一样,然而总的训练时间有了较大的下降,下降了约 14%。前向的识别时间也存在了明显的下降,下降了 24 ms,达到约 10%。这是由于,GRU 门控单元相比于传统的 LSTM 门控单元,减少了门控数目,从而带来了训练参数的减少,导致了训练时间和前向识别时间的降低。这相当于在性能差别不大的情况下,将神经网络轻量化。该轻量化特性有利于神经网络的部署和实际应用。

表 2 相同网络 GRU 门控单元与 LSTM 门控单元性能对比
Table 2 Performance comparison between GRU and LSTM gating unit in the same network

项目	LSTM	GRU
识别准确率/%	95	96
训练时间/s	1 029	886
平均前向识别时间/ms	235	211

3 结 论

人员行为识别在医疗健康、智能家居等领域有着巨大的应用需求。基于惯性测量的人员行为识别方式

由于部署简单,有着较强的实用性。由于深度神经网络在提取数据特征中有着较好的效果,十分适合应用于基于惯性数据的人员行为识别。本文提出一种基于CLDNN网络的人员行为识别方法。该网络既有卷积神经网络中可以提取不同尺度的能力,同时也能够充分利用序列的相关性,从而适合处理时间序列。同时本文利用GRU门控单元替代CLDNN网络中用到的传统的LSTM门控单元,使得网络更加轻量化。本文通过公开数据集对本文中的方法进行验证,通过实验可以看出,本文用到的CLDNN网络相比传统方法效果更好,并且对于普通的卷积神经网络和利用LSTM单元的循环神经网络,有着更高的识别准确率,分别提高了3%和7%。用GRU门控单元代替LSTM单元后,网络更加轻量化,所需的训练时间和前向的识别时间都有所下降,时间下降的百分比分别为14%和10%,但是识别准确率却基本不变。


参考文献

- [1] 唐薇. 基于单节点惯性传感器的人体行为监测[D]. 成都:电子科技大学,2016.
TANG W. Single node based human activity monitor using an inertial measurement unit [D]. Chengdu: University of Electronic Science and Technology, 2016.
- [2] SHU Z, ZHI W, JIE N, et al. A review on human activity recognition using vision-based method [J]. Journal of Healthcare Engineering, 2017, 20(7):1-31.
- [3] ROSHTKHARI M J, LEVINE M D. Human activity recognition in videos using a single example[J]. Image & Vision Computing, 2013, 31(11):864-876.
- [4] 石欣,熊庆宇,雷璐宁. 一种基于压力传感器的人体运动识别方法研究[J]. 仪器仪表学报, 2010, 31(6):1429-1434.
SHI X, XIONG Q Y, LEI L N. A human activity recognition method using a pressure sensor[J]. Chinese Journal of Scientific Instrument, 2010, 31(6):1429-1434.
- [5] ARSHAD S, FENG C, LIU Y, et al. Wi-chase: A WiFi based human activity recognition system for sensorless environments[C]. IEEE 18th International Symposium on A World of Wireless, Mobile and Multimedia Networks (WoWMoM), 2017: 44-58.
- [6] ZHU C, SHENG W. Recognizing human daily activity using a single inertial sensor [C]. IEEE Intelligent Control & Automation, 2010: 107-119.
- [7] WU D, ZHANG H, CONG N, et al. Inertial sensor based human activity recognition via reduced kernel PCA[C]. Advances in Body Area Networks, 2019(2): 12-19.
- [8] AHN S, SHIN I, KIM Y. Pre-impact fall detection using an inertial sensor unit [J]. Journal of Foot and Ankle Research, 2014, 7(6): 124-130.
- [9] KASEBZADEH P, HENDEBY G, FRITSCHKE C. IMU dataset for motion and device mode classification [C]. International Conference on Indoor Positioning & Indoor Navigation, 2017: 168-179.
- [10] CHEN W, CHEN R, CHEN Y. An effective pedestrian dead reckoning algorithm using a unified heading, error model[C]. Position Location & Navigation Symposium, 2010: 100-114.
- [11] HUSSAIN G, JABBAR M S, CHO J. Indoor positioning system: A new approach based on LSTM and two stage activity classification [J]. Electronics, 2019, 8(4): 49-56.
- [12] WAGSTAFF B, PERETROUKHIN V, KELLY J. Improving foot-mounted inertial navigation through real-time motion classification [C]. International Conference on Indoor Positioning and Indoor Navigation, 2017, 10(4): 112-121.
- [13] 谢国亚,刘宇,路永乐. 基于MEMS惯性传感器时域特征的人体行为识别[J]. 压电与声光, 2019, 41(2):60-63.
XIE G Y, LIU Y, LU Y J. Human activity recognition based on inertial data features in the time domain[J]. Piezoelectrics & Acoustooptics, 2019, 41(2):60-63.
- [14] LARA O D, LABRADOR M A. A survey on human activity recognition using wearable sensors [J]. IEEE Communications Surveys & Tutorials, 2013, 15(3): 1192-1209.
- [15] WANG J, CHEN Y, HAO S. Deep learning for sensor-based activity recognition: A survey [J]. Pattern Recognition Letters, 2018, DOI: 10.1016/j.patrec.2018.02.010.
- [16] IAN G, YOSHUA B, ARON C. Deep Learning [M]. Cambridge:MIT Press, 2016: 1023-1238.
- [17] MOHAMMED S, TASHEV I. Unsupervised deep representation learning to remove motion artifacts in free-mode body sensor networks[C]. IEEE 14th International Conference on Wearable and Implantable Body Sensor Networks (BSN), 2017: 109-118.
- [18] ABDULMAJID M, JAEY P. Deep recurrent neural networks for human activity recognition [J]. Sensors, 2017, 17(11):2556.
- [19] SAINATH T N, VINYALS O, SENIOR A. Convolutional, long short-term memory, fully connected deep neural networks[C]. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP),

2015:309-316.

- [20] GRAVES A. A novel connectionist system for unconstrained handwriting recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 10(5): 31-43.
- [21] CHO K, VAN M B, GULCEHRE C. Learning phrase representations using RNN encoder-decoder for statistical machine translation [J]. Computer Science, 2014, 6(10): 67-79.

作者简介



王丽君, 2005 年于西安科技大学获得学士学位, 2009 年于西安科技大学获得硕士学位, 现为陕西国际商贸学院专职教师, 主要研究方向为信号处理、光电子。

E-mail: lisa_junwang@163.com

Wang Lijun received her B. Sc. degree from Xi'an University of Science and Technology in 2005, and M. Sc. degree from Xi'an University of Science and Technology in 2009. Now she is a full-time teacher at Shaanxi Institute of International Trade and Commerce. Her main research interests include signal processing and photoelectron.



刘彦戎, 2005 于空军工程大学获得学士学位, 2015 年于陕西科技大学获得硕士学位, 现为陕西国际商贸学院专职教师, 主要研究方向为网络安全、数据挖掘。

E-mail: dby_1982@163.com

Liu Yanrong received her B. Sc. degree from Air Force Engineering University in 2005, and M. Sc. degree from Shaanxi University of Science and Technology in 2015. Now she is a full-time teacher at Shaanxi International Business and Business University. Her main research interests include network security and data mining.



王丽静, 2014 年于西安交通大学城市学院获得学士学位, 2019 年于西安石油大学获得硕士学位, 主要研究方向为电力电子与电力传动。

E-mail: qingxin7357@163.com

Wang Lijing received her B. Sc. degree from Xi'an Jiaotong University City College in 2014, and M. Sc. degree from Xi'an Shiyou University in 2019. Her main research interests include power electronics and power transmission.