

基于深度信念网络的医院门诊量预测

杨旭华 钟楠祎

(浙江工业大学计算机科学与技术学院 杭州 310023)

摘要 有效的医院门诊量预测是现代医院对医疗资源实现智能化管理的重要前提之一。现有的医院门诊量预测方法大多针对的是单一的数据集,缺少对数据的充分挖掘和深入分析。为此,提出一种基于深度信念网络的医院门诊量预测方法,用深度信念网络对医院各科室的门诊量数据进行无监督学习,完成对门诊量数据的特征提取,挖掘各临床科室门诊量数据间的相互关系,在网络的顶层叠加一个逻辑回归层并将提取出的数据特征作为输入来预测各科室未来的门诊量。仿真实验结果表明,基于深度学习的预测模型可以得到较高的门诊量预测精度,是一种可行且有效的预测方法。

关键词 深度信念网络,门诊量预测,数据特征,逻辑回归

中图分类号 TP183 文献标识码 A

Forecasting of Hospital Outpatient Based on Deep Belief Network

YANG Xu-hua ZHONG Nan-yi

(College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract Forecasting of hospital outpatient plays an important role in intelligent management of modern hospital medical resources. The existing researches on outpatient visit analysis and forecasting mostly aim at a single set of data, lacking in in-depth analysis of the data to fully tapped. Thus a hospital outpatient prediction method based on deep belief network (DBN) was proposed. The DBN can excute unsupervised learn from hospital out-patient departments of outpatient data and complete outpatient data feature extraction for mining hidden relationships between various out patient clinic outpatient data. On top of the network layer a logistic regression is added, and the extracted data is based to forecast the future outpatient clinic outpatient. The experimental results show that prediction model based on deep learning achieves better forecasting effect of traffic outpatient capacity.

Keywords Deep belief network, Outpatient prediction, Data characteristics, Logistic regression

1 引言

医院门诊是病患接受医院诊疗工作的第一个环节,是医院面向社会的窗口。对医院门诊量的精准预测有助于后续医疗工作的顺利展开。医院门诊量作为评价现代医院医疗工作情况的重要指标之一,可以充分地反映出一所医院的应诊能力、医疗质量以及服务水平。与此同时,医院门诊量预测对于医疗资源的管理和分配也有着重要的参考价值。随着医院诊疗工作越来越智能化、细致化和高效化,医院门诊量的预测工作正逐渐受到重视。

在过去的十来年中,与门诊量预测相关的研究文献逐渐增多,但是总体数量还是较少,而且研究的方法主要集中于 ARIMA 模型^[1,2]、GM(1,1)^[3] 预测模型和曲线回归拟合法^[4] 等单一预测方法。门诊量数据的波动受到许多因素的影响,由于大样本的门诊量数据及其影响因素难以收集和量化,导致过往的研究工作往往只能考虑其中的一种或几种因素,缺乏对门诊量数据的深度挖掘,这也和数据挖掘技术尚未在医

疗管理中真正大规模应用有关。

神经网络作为数据挖掘技术中较早应用成功的算法之一,在数据预测方面有着强大的优势^[5]。它通过网络训练数据样本,将数据中概括出来的知识分别存储于网络中的各神经元,以构成网络知识,再通过该知识来预测相似因素的结果。目前大多数基于神经网络的数据预测的研究采用了 BP 网络算法或者其它的浅层网络模型,而浅层网络模型容易陷入局部极值,也就是极值会收敛到局部的最小点,从而导致网络训练失败。深度学习^[6-8]作为一种新兴的机器学习算法,由神经网络模型发展而来,可以包含很多隐含层,能够在大规模的数据集中学习、识别数据的结构和分布。因为深层神经网络强大的特征学习能力,其在图像分类、语音识别、文本语言识别^[9-14]等方面都得到了极大的应用。同时深度学习作为一种神经网络模型的发展,它在数据预测的应用中也能得到很好的效果^[15]。Lv Y 等人^[16]提出了一种基于深度自编码网络模型的交通流预测模型,第一次将自编码模型堆叠起来提取的交通流特征用于预测并且取得了理想的预测精

本文受国家自然科学基金(61374152)资助。

杨旭华(1971-),男,博士,教授,主要研究方向为复杂网络、人工智能、深度学习, E-mail: xhyang@zjut.edu.cn; 钟楠祎(1992-),男,硕士生,主要研究方向为复杂网络、机器学习, E-mail: nyzhong815@163.com。

度;Hu 等人^[17]利用神经网络强大的非线性映射能力,成功地将深度学习理论应用到了短期风速预测中,并通过仿真实验证明了神经网络在风速预测中的优越性;张艳红等人^[18]提出了一种基于神经网络的社会媒体网络模型来预测社会媒体网络间的链接分析,该模型对描述网络间的整体特征有极大的帮助。Hossain M^[19]的团队建立了一个堆积降噪自编码模型来预测美国内达华州天气,得到了不错的结果。

本文提出了一个基于深度信念网络的医院门诊量预测模型,将某医院的门诊量数据作为样本训练模型并加以实现,仿真结果表明,这种方法在对医院门诊量数据的预测中取得了不错的准确率。

2 相关工作

医院门诊量预测的方法有很多,基本思想都是统计并分析过往的门诊量数据间的关系和规律来对未来某段时间间隔内的门诊量进行预测。当前有关医院门诊量预测的方法主要分为 3 类:基于历史数据的时间序列分析模型、基于人工智能的模型以及结合前两者方法的混合模型。

基于历史数据的时间序列分析模型的主要代表性方法就是自回归整合滑动平均模型(ARIMA)。ARIMA 模型通过找出医院门诊量随着时间变化而变化的规律从而实现预测,在月门诊量预测和季度门诊量预测中有十分不错的表现。耿娟^[20]通过 ARIMA 模型来研究医院的门诊量变化规律,并对门诊量进行建模拟合得到了预测精度平均相对误差在 5.28% 的预测模型。但是 ARIMA 模型假定数据间都是线性关系,因此当数据间存在非线性关系时,ARIMA 模型的性能将会变得较差。

基于人工智能的模型如人工神经网络(ANNs)、支持向量机(SVR)和遗传算法(GA)等,这些算法可以有效地模拟出医院门诊量之间的非线性关系,所以在数据预测中可以得到较好的结果。叶明全等人^[21]提出了一个基于季节性神经网络的医院门诊量曲线拟合与预测模型,得到了一个预测精度在 ARIMA 季节乘积模型之上的医院门诊量预测方法。

混合模型结合了两种以上方法来预测医院门诊量,既利用了不同方法的长处,同时也规避了不同方法的不足之处,所以其预测结果比单一方法要好得多。朱顺痣等^[22]提出了一个 ARMAX 模型与神经网络的混合模型,同时考虑了医院门诊量数据间的线性关系与非线性关系,并将混合模型与单一的 ARMAX 模型、神经网络相比较,体现出了混合模型的优越性。张筠莉等^[23]将 GM(1,1)和 RBF 神经网络相结合,减小了 GM(1,1)模型的理论误差,同时又利用灰色预测方法的预处理提高了 RBF 神经网络的训练速度和预测精度,此方法在短时医院门诊量预测中取得了不错的结果。

3 基于深度信念网络的门诊量预测模型

在每天的诊疗工作中,医院会产生大量的数据。在这些数据背后隐藏着一定的信息,通过一定的数据挖掘技术可以将这些信息提取出来。利用深度信念网络学习模型从无标签的医院数据中提取出共性特征来描述样本,并用少量的标签

数据对回归预测层进行训练,最终得到一个可以应用于实际的预测模型。

3.1 受限玻尔兹曼机

若一个二分图,每一层的节点之间没有连接,一层为可见层(v),即数据输入层,另一层是隐藏层(h),即特征提取层,并且假设所有节点都是随机二值变量节点(只能取值 0 或者 1),同时可见层和隐藏层之间通过对称矩阵进行全连接,全概率分布 $P(v, h)$ 满足玻尔兹曼分布,则这个模型就是一个受限玻尔兹曼机(RBM)。RBM 的结构图如图 1 所示。




图 1 RBM 的模型结构

对于一个 RBM 的模型来说,可见层的输入向量 v 和隐藏层输出向量 h 之间的能量函数是:

$$E(v, h) = -\sum_{i \in v} a_i v_i - \sum_{j \in h} b_j h_j - \sum_{i, j} v_i h_j w_{ij} \quad (1)$$

其中, v_i 是输入向量 i ; h_j 是特征向量 j ; a_i 和 b_j 分别是可见层和隐藏层的偏移量; w_{ij} 是可见层和隐藏层之间的权重矩阵。

当参数确定时,根据能量函数(1),可以得到 (v, h) 的联合概率分布:

$$p(v, h) = \frac{e^{-E(v, h)}}{Z} \quad (2)$$

其中, Z 是归一化因子,其表达式为:

$$Z = \sum_{v, h} e^{-E(v, h)} \quad (3)$$

由式(2)、式(3)可以推出向量 v 的概率分布函数为:

$$P(v) = \sum_h P(v, h) = \sum_h \frac{e^{-E(v, h)}}{Z} \quad (4)$$

令中间变量 $F(v)$ 为:

$$F(v) = -\log \sum_h e^{-E(v, h)} \quad (5)$$

则由式(4)、式(5), v 的概率分布可以改写为:

$$P(v) = \frac{e^{-F(v)}}{Z} \quad (6)$$

其中, $Z = \sum_v e^{-F(v)}$ 。

对式(6)求导取负后,则为:

$$-\frac{\partial \log p(x)}{\partial \theta} = \frac{\partial F(v)}{\partial \theta} - \sum_v p(\hat{v}) \frac{\partial F(\hat{v})}{\partial \theta} \quad (7)$$

从以上的推导中可知:要使一个 RBM 网络系统达到稳定,需要使系统的能量最小,即使式(1)达到最小值,则需要令 $F(v)$ 最小,或者说令 $P(v)$ 最大。

由 RBM 的特殊结构可知:当给定可见层单元的状态时,各隐藏层单元的激活状态之间是条件独立的。此时,第 j 个隐藏层单元的激活概率为:

$$P(h_j = 1 | v) = \frac{1}{1 + \exp(-a_j - \sum_{i=1}^n w_{ij} v_i)} \quad (8)$$

由于 RBM 的结构是对称的,当给定隐藏层单元的状态时,各可见层单元的激活状态之间条件独立,即第 i 个可见层单元的激活概率为:

$$P(v_i = 1 | h) = \frac{1}{1 + \exp(-b_i - \sum_{j=1}^n w_{ij} h_j)} \quad (9)$$

在RBM的学习训练中,需要对参数进行更新。常规方法是用极大似然函数来对参数的更新规则进行推导,但发现梯度很难计算。因此RBM采用Gibbs采样法来取得其近似值。Gibbs采样法是指将一个训练样本初始化其可见层的状态 v_0 ,然后根据式(8)获得隐藏层状态 h_0 ,再反过来利用式(9)采样出可见层的状态 v_1 ,由此交替数次得到服从RBM所定义的概率分布样本。一般来说,仅需要使用1次Gibbs采样便可以得到足够好的近似。因此可以得到参数的更新规则:

$$-W \leftarrow -W + \epsilon(P(h_{1i} = 1 | v_1) v_1^T - P(h_{2i} = 1 | v_2) v_2^T) \quad (10)$$

$$-a \leftarrow -a + \epsilon(v_1 - v_2) \quad (11)$$

$$-b \leftarrow -b + \epsilon(P(h_{1i} = 1 | v_1) - P(h_{2i} = 1 | v_2)) \quad (12)$$

其中, ϵ 表示学习速率。

3.2 深度信念网络

深度信念网络(Deep Belief Networks, DBN)是被广泛应用的深度学习模型之一。DBN是一个多隐层的概率生成模型,概率生成模型是指通过训练网络并调整神经元间的权重,使得整个神经网络以一个最大的概率来生成并还原输入数据。DBN由一堆受限玻尔兹曼机(RBM)组成,每一层的RBM训练出的输出将作为下一层RBM的输入。Geoffrey-Hinton的团队在2006年提出了一种训练多层深度神经网络的方法,即贪婪逐层训练方法,并证明了该方法可以克服深度神经网络的训练难题。

一个深度信念网络模型拥有1个输入层、 n 个隐层和1个输出层,在训练整个网络时,将输入层和第一个隐层作为一个RBM训练得到第一个隐层的输出,将这个输出作为第二个隐层的输入,训练得到下一层的输出。即将第 k 个隐层的输出作为第 $k+1$ 层的输入,用这种方法训练整个深度信念网络,具体情况如图2所示。




图2 DBN训练过程示意图

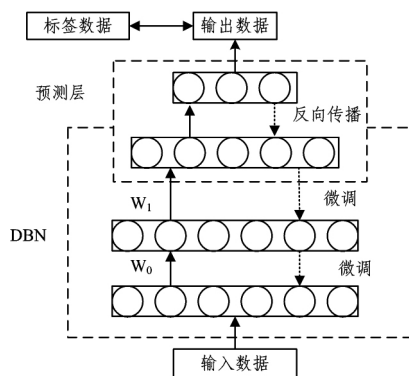


图3 门诊量预测的深度体系架构

深度信念网络在医院门诊量预测时,可以很好地提取出门诊量数据的特征向量,并将提取出的特征向量输入预测层。

本文选择在深度信念网络上再叠加一层逻辑回归层来做有监督的医院门诊量预测,这样,深度信念网络加上回归预测层就构成了医院门诊量预测的整个体系架构。建立的具体模型如图3所示。

3.3 训练算法

训练深度神经网络最简单的方法就是用BP算法,即基于梯度的优化方法。但是BP算法在深层网络的预训练中的表现十分不如人意。这是因为对于一个多层的神经网络,采用反向传播的机制会导致“梯度扩散”问题,即从顶层往下,误差校正信号越来越小。现在,深度神经网络的训练算法都采用Hinton团队提出的贪婪逐层算法。简单地说,该算法分为两步:1)用无标签的数据逐层训练网络;2)在预训练结束后,用BP算法自上而下地对参数进行调优。使特征表示 x 自下而上生成的高级特征表示 y 和由高级特征表示 y 自上而下生成的特征表示 x' 尽可能一致。具体的训练过程如下:

- 1)将输入向量 X 用CD算法训练第一层;
- 2)将第一层训练得到的输出作为输入向量训练第二层;
- 3)重复上述过程直到给定的层数位置;
- 4)最后一层RBM的输出作为顶层回归预测层的输入,随机初始化参数;
- 5)用有监督的BP算法由上而下的调整整个模型的参数。

这种训练算法远远优于过往神经网络直接使用的BP算法。原因在于,经过深度网络的预训练后,整个网络的参数已经得到优化,再用BP算法微调整个网络,只是将已知的参数进行一次局部的搜索,这样,无论效率还是结果都大大地优于原来的BP算法。

4 仿真实验和结果分析

4.1 数据说明

实验数据的来源是某市一家三甲级医院的病患就诊挂号信息。该数据中包含了病患姓名编号、挂号的门诊科室、患者的病情、挂号的日期、问诊的医师等病患信息。数据基本涵盖了医院内的所有门诊科室。仿真实验中,选取了医院主要的5个门诊科室(急诊、骨科、内分泌、心内科、中医科)的每日门诊量数据来做日度门诊量的数据预测。

由于医院的门诊量在节假日期间因种种原因会大幅减少,因此在做仿真实验的日门诊量预测时,将工作日门诊量数据和双休日门诊量数据分割开来,在做周门诊量预测以及月度门诊量预测时将门诊量极值(节假日)部分去除。

在日度门诊量预测和周门诊量预测中,将2013年全年和2014年1月-6月的门诊量作为训练集,将7月-8月份的数据作为测试集检测性能;在月门诊量预测中,将2011年-2013年门诊量作为训练集,将2014年的门诊量数据作为测试集测试网络性能。

4.2 评价指标

本文采用两个常见的性能参数来评价所提出的基于深度信念网络的门诊量预测方法:1)绝对平均误差(MAE);2)相对平均误差(MRE)。它们的具体表示如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - \bar{f}_i| \quad (13)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|f_i - \bar{f}_i|}{f_i} \quad (14)$$

其中, f_i 表示实际的值, \bar{f}_i 表示预测的值。

4.3 架构实现

在深度信念网络的架构中,需要确定网络输入层的大小,隐层的数量以及每一层隐藏层的神经元数目。对于网络输入层的大小,将统计好的医院门诊量作为输入,这里将急诊、骨科、内分泌、心内科和中医科 5 个门诊科室的前两个时间段的门诊量作为输入,将中医科的门诊量预测作为输出。即网络输入层的神经元数目为 10,逻辑回归层预测输出的神经元数目为 1。

在本文中,用所提出来的方法来预测医院的日门诊量、周门诊量和月门诊量。在仿真实验中,将隐藏层的数量限定在 1 到 6 之间,并且将每一层隐藏层的神经元数目限定在 10 到 100 之间。通过执行网格搜索算法后,可以得到最优结果的网络模型深度架构,如表 1 所列。

| 任务 | 隐藏层 | 神经元数目 |
|------|-----|------------------|
| 日门诊量 | 5 | [50,80,60,40,20] |
| 周门诊量 | 4 | [60,70,40,30] |
| 月门诊量 | 4 | [50,80,50,30] |

对于日门诊量预测来说,最优的深度结构包含了 5 层隐藏层,每一层隐藏层的神经元数目是[50,80,60,40,20];对于周门诊量预测来说,最优的深度结构包含了 4 层隐藏层,每一层隐藏层的神经元数目是[60,70,40,30];对于月门诊量预测来说,最优的深度结构包含了 4 层隐藏层,每一层隐藏层的神经元数目是[50,80,50,30]。从最终的结果可以看出,在本文中的门诊量预测仿真中,深度架构中的隐藏层的数量都在 4 层以上且 6 层以下。这揭示了深层神经网络的隐层数目既不能太多也不能太少。

图 4 为深层结构和浅层结构的神经网络对门诊量预测的效果图。其中横坐标表示第 i 个时间间隔(周),纵坐标表示门诊量的具体值(人)。从图中可以看出,深层结构的预测结果更加接近实际值。





图 4 不同深度结构的日门诊量预测结果

4.4 结果分析


图 5 展示了用所提方法对日门诊量、周门诊量和月门诊量进行预测的仿真结果,同时门诊量的实际观测值也在图 5 中。从图 5 中可以发现,预测值接近于实际值,另外,较为明显的是相比于周门诊量和月门诊量的仿真结果,日门诊量预测结果更加的接近实际观测值。也就是说,所提的方法对日门诊量的预测更加的适应。造成这种现象的原因是预测值与

实际观测值之间的误差会随着门诊量的不断累加而增大。但是在实际的应用预测中,医疗管理人员更加注重短时门诊量预测。所以,本方法在门诊量预测中有一定优越性。


在表 2 中,将所提的基于深度信念网络的门诊量预测模型和当前最流行的时间序列预测模型的 ARIMA 模型以及其他神经网络模型(BP 神经网络、SVM 算法、RBF 神经网络)进行对比。



(a)日门诊量预测



(b)周门诊量预测



(c)月门诊量预测

图 5 不同时间间隔的门诊量预测图

表 2 门诊量预测方法的比较

| | | 日门诊量 | 周门诊量 | 月门诊量 |
|-------|--------|-------|--------|---------|
| DBN | MAE | 23.72 | 2394.9 | 10955.5 |
| | MRE(%) | 3.8 | 4.5 | 5.8 |
| ARIMA | MAE | 36.8 | 3451.6 | 19414.4 |
| | MRE(%) | 5.3 | 6.0 | 6.7 |
| BP | MAE | 52.37 | 4034.4 | 24394 |
| | MRE(%) | 7.2 | 8.8 | 9.5 |
| SVM | MAE | 43.2 | 3685.8 | 25367 |
| | MRE(%) | 6.3 | 7.8 | 9.3 |
| RBF | MAE | 37.8 | 3475.2 | 21869 |
| | MRE(%) | 5.6 | 6.9 | 8.9 |

ARIMA 模型在实际应用中已经较为成熟,这里用 SPSS 数据分析软件构建 ARIMA 模型。在日门诊量预测和周门诊量预测中,忽略数据的季度性影响因素,因此选择建立非季节性 ARIMA(1,1,1)模型。对于月门诊量预测,需要考虑数据的季节性因素,因此采用 ARIMA 乘积模型(季节性 ARIMA 模型和非季节性 ARIMA 模型的结合),根据对数据的分析,得到模型 ARIMA(1,1,0)(0,1,1)₁₂。根据所建模型对训练集数据拟合,对测试集数据预测,预测精度如表 2 所列。从结

果可以看出 ARIMA 模型在医院门诊量预测中具有一定的精度,可以对门诊量数据进行较好的拟合,但是模型对数据间非线性关系的提取能力较弱,影响到预测的精度。

对于 BP 神经网络来说,它的门诊量预测的精度大致在 90%左右。对于 SVM 算法和 RBF 神经网络来说,它们的门诊量预测平均误差同样是随着门诊量的累加而增大。在日门诊量的预测中,BP 算法的预测精度只有 92.8%左右,而 SVM 算法和 RBF 神经网络的预测精度在 94%左右,深度信念网络则可以达到 96%以上。在周门诊量预测中,深度信念网络的预测精度同样远远高于 BP 算法、SVM 算法和 RBF 神经网络方法。后三者的平均相对误差在 7%~8%之间。而在月门诊量预测中预测精度的差距更大,其他方法的平均相对误差在 9%左右,而深度信念网络的预测精度比这 3 种方法高了 3%以上。

通过与当前数据预测方法的比较可以发现,本文所提出的基于深度信念网络的门诊量预测方法无论是在日门诊量、周门诊量还是月门诊量上的预测精度都高于其他方法,得到的结果更加接近事实。

结束语 本文提出了一个基于深度信念网络的门诊量预测方法,这是第一次将深度学习模型应用于医院门诊量的预测当中。与过往的门诊量预测方法只关注于门诊量浅层结构的数据关系不同,基于深度信念网络的门诊量预测方法可以挖掘门诊量数据之间潜在的特征关系(比如门诊量数据间的非线性关系等)。基于深度信念网络的门诊量预测方法首先用贪婪逐层的无监督算法训练整个深度信念网络,得到数据的良好特征表示。之后,为了提高网络的预测性能,使用 BP 有监督算法微调网络参数。完成深度信念网络的训练后,将该方法与过往的门诊量预测方法(BP 算法、SVM 算法、RBF 神经网络)进行了比较来衡量深度学习方法的预测性能。仿真对比说明了该方法是优于传统的数据预测方法的。在未来的研究中,考虑将与医院门诊量相关的其他变量加入到模型中,例如医院的地域因素、时间的季节因素以及病人的身体因素等对医院门诊量产生影响的因素。模型的应用可以推广到医疗数据挖掘的其他领域。另外,在本文中的预测层只是用了简单的逻辑回归层,也可以替换成例如 SVM 的其他预测模型。

参 考 文 献

- [1] Valipour M, Banihabib M E, Behbahani S M R. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir[J]. Journal of Hydrology, 2013, 476(2): 433-441
- [2] Khashei M, Bijari M. A novel hybridization of artificial neural networks and ARIMA models for time series forecasting[J]. Applied Soft Computing, 2011, 11(2): 2664-2675
- [3] Wang Y, Dang Y, Li Y, et al. An approach to increase prediction precision of GM(1,1) model based on optimization of the initial condition[M]// Continuous flows in the plane. Springer, 1974, 37(8): 5640-5644
- [4] Yin Z Y. Study on the fitting methods of logistic curve[J]. Application of Statistics and Management, 2002, 21(1): 41-46
- [5] 郭丽丽, 丁世飞. 深度学习研究进展[J]. 计算机科学, 2015, 42(5): 28-33
- [6] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444
- [7] Bengio Y. Learning Deep Architectures for AI[J]. Foundations & Trends in Machine Learning, 2009, 2(1): 1-127
- [8] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 1960, 18(7): 1527-1554
- [9] Leung M K, Xiong H Y, Lee L J, et al. Deep learning of the tissue-regulated splicing code[J]. Bioinformatics, 2014, 30(12): i121-i129
- [10] Xiong H Y, et al. RNA Splicing, The human splicing code reveals new insights into the genetic determinants of disease[J]. Science, 2015, 347(6218)
- [11] Collobert R, et al. Natural language processing (almost) from scratch[J]. Journal of Machine Learning Research, 2011, 12(1): 2493-2537
- [12] Sutskever I, Vinyals O, Le Q V. Sequence to sequence learning with neural networks[C]// Proc. Advances in Neural Information Processing Systems, 2014(27): 3104-3112
- [13] Bordes A, Chopra S, Weston J. Question Answering with Subgraph Embeddings[J]. Computer Science, 2014
- [14] Jean S, Cho K, Memisevic R, et al. On using very large target vocabulary for neural machine translation[C]// Proc. ACL-IJCNLP, 2015
- [15] Etemad-Shahidi A, Yasa R, Kazeminezhad M H. Prediction of wave-induced scour depth under submarine pipelines using machine learning approach[J]. Applied Ocean Research, 2011, 33(1): 54-59
- [16] Lv Y, Duan Y, Kang W, et al. Traffic Flow Prediction With Big Data: A Deep Learning Approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 1-9
- [17] Hu Q, Zhang R, Zhou Y. Transfer learning for short-term wind speed prediction with deep neural networks[J]. Renewable Energy, 2016, 85: 83-95
- [18] 张艳红, 王宝会. 基于深度神经网络的社会媒体网络分析[J]. 计算机科学, 2016, 43(4): 252-255
- [19] Hossain M, Rekabdar B, Louis S J, et al. Forecasting the weather of Nevada: A deep learning approach[C]// 2015 International Joint Conference on Neural Networks(IJCNN). 2015
- [20] 耿娟. ARIMA 模型在医院门诊量预测中的应用[J]. 中国卫生统计, 2014(4): 643-645
- [21] 叶明全, 胡学钢. 基于季节性神经网络的医院门诊量曲线拟合与预测[J]. 图学学报, 2005, 26(2): 83-86
- [22] 朱顺德, 王大寒, 何亚男, 等. 基于时间序列模型的医院门诊量分析与预测[J]. 中国科学技术大学学报, 2015, 45(10): 795-803
- [23] 张筠莉, 杨祯山. 现代医院门诊量的灰色 RBF 神经网络预测[J]. 计算机工程与应用, 2010, 46(29): 225-228