

面向应用性能管理系统的运行负载预测

马健钦

(四川幼儿师范高等专科学校, 四川 江油 621700)

摘要: 在应用性能管理系统中, 系统未来的负载情况对运维调度有重要的指导意义; 在云计算环境下, 弹性伸缩计算能力为调整系统规模提供了可能, 根据系统将来的负载情况可以提前做出相应的调整; 可以在负载加重前扩展好集群, 保证服务质量; 在负载降低之后若预测一定时间内没有负载加重的情况, 则可以及时缩减集群规模, 降低企业运营成本; 在金融领域, ARIMA模型是常用的时序预测模型, 但其应用需要人工介入分析时序的平稳性, 调参过程过于复杂; 近年来神经网络技术的发展带动了人工更智能技术的发展, 文章设计并测试了 ANN、RNN、GRU、LSTM 等神经网络的负载预测的效果; 实验结果表明 LSTM 网络预测精准且表现稳定, 是系统负载预测的理想模型。

关键词: 应用负载; 负载预测; 神经网络; 时间序列预测

Operational Load Forecasting for Application Performance Management Systems

Ma Jianqin

(Sichuan Preschool Educators College, Jiangyou 621700, China)

Abstract: In the application performance management system, the future load situation of the system has important guiding significance for the operation and maintenance scheduling. In the cloud computing environment, the elastic scaling computing capability provides the possibility to adjust the system scale. According to the future load conditions of the system, it can be adjusted in advance: You can expand the cluster before the load is increased to ensure the quality of service; after the load is reduced, if no load is expected to increase in a certain period of time, the scale of the cluster can be reduced in time and the operating cost of the enterprise can be reduced. In the financial field, the ARIMA model is a commonly used time-series prediction model, but its application requires manual intervention to analyze the temporal stability, and the adjustment process is too complicated. In recent years, the development of neural network technology has led to the development of artificially more intelligent technologies. This paper designed and tested the effect of neural network load prediction such as ANN, RNN, GRU, and LSTM. Experimental results show that the LSTM network is accurate and stable in performance and is an ideal model for system load prediction.

Keywords: application load; load prediction; neural network; time series prediction

0 引言

在云计算环境下, 弹性计算^[1]能力使用户按需使用计算资源成为了可能。按需分配计算资源可以有效提高计算资源的使用效率, 降低用户的使用成本。然而, 应用的计算需求是处于不断变化之中的, 当低估应用未来的系统负载时, 会因为计算能力欠缺无法保证可靠服务, 乃至因为系统负载过大而造成宕机事故^[2]; 当高估未来系统负载时, 申请过多的计算资源往往会造成计算资源的浪费, 增加企业运行成本^[3]。准确预测出应用在未来一段时间内的系统负载成为弹性计算的重要一环。

时序数据^[4]是应用运行过程中常见的数据形式, 应用在单位时间内的执行指令数、网络连接数磁盘读写数、内存占用率、数据读写量等是常见时序数据, 针对具体应用还可能会有在线用户数、单位时间内交易数等指标。这些

时序数据描述了应用在运行过程中的负载波动情况。不同应用的负载波动规律往往不是不同的, 通过收集并分析应用运行时的负载时序数据可以挖掘出应用负载的波动变化规律并以此预测应用未来的负载情况。

时序预测方法有多种, 比如自回归移动平均 (autoregressive integrated moving average, ARIMA)^[5]、多元线性回归 (multiple linear regression, MLR)^[6] 和 BP 神经网络 (back propagation neural network, BPNN)^[7]。其中平稳自回归模型在应用时需要针对具体时间序列分析其平稳性, 并根据差分后平稳性结论给出模型参数, 在应用时需要太多人工介入, 可用性差。多元线性回归模型可以挖掘出多元时间段的线性关系, 无法挖掘非线性关系, 拟合误差很大。BP 神经网络的预测算法提供了非线性拟合能力并避免了 ARIMA 模型需要太多人工介入分析的繁琐, 但由于 BP 神经网络模型没有记忆能力, 无法解决时序预测中的长跨度依赖的问题。

近年来, 深度学习技术的发展给时序数据预测提供了新的解决问题的思路 and 工具; 深度学习模型借助其多层非

收稿日期: 2018-04-09; 修回日期: 2018-05-10。

作者简介: 马健钦(1981-), 男, 四川岳池人, 硕士, 讲师, 主要从事负载均衡算法, 射频识别技术等方向的研究。

线性映射层，能够抽象出数据更深层次的潜在规律^[8]。循环神经网络（recurrent neural networks, RNN）引入了定向循环，网络会记忆之前的输入信息并应用于当前的计算中，这就产生了时序的概念；长短期记忆网络（long short-term memory, LSTM）^[9]是 RNN 的一种，其解决了传统 RNN 梯度消失、记忆跨度较短的问题；门控循环单元（gated recurrent unit, GRU）是 LSTM 的变种，其简化了 LSTM 的门控方式，两者在时序处理上不分伯仲。

本文针对弹性伸缩计算中的应用负载预测提出了使用三层 LSTM 隐层和一层 BP 层构成的神经网络结构，使用从实验室服务器上采集到的应用运行监控数据训练模型，并设计对比实验比较其他时间序列预测模型的预测效果。实验表明本文设计的神经网络模型的预测误差更小。

1 神经网络相关技术简介

1.1 BP 神经网络

BP 神经网络^[10]是应用最广泛的神经网络结构。对于输入序列 $\vec{x} = (x_1, \dots, x_N)$ ，BP 网络节点计算输出 $y = f(\omega^T x + b)$ ，其中 ω 是权重向量； b 是偏置； f 为激活函数，例如 sigmoid 函数， \tanh 函数。当激活函数为分线性函数时，多层神经网络能够无限逼近任意函数^[11]，具有强大的表达能力。在 BP 神经网络中，由于输入和输出是一一对应的，没有记忆能力，网络的上一次输入对本次的预测结果不会产生任何影响，无法处理时序数据中前后关联的关系。

1.2 循环神经网络

循环神经网络（RNN）^[12]在结构上与前馈神经网络非常相似，但是 RNN 中隐藏层的反馈除了进入输出端，还会进入到下一个时间结点的隐藏层，从而影响下一时间步的各个权重。

RNN 网络不同于 BP 神经网络，其内部存在隐藏状态 h ，内部状态参与节点输出值得计算，并根据输入值和内部隐藏状态更新隐藏状态。隐藏状态的出现使 RNN 具有了记忆能力，这意味着历史输入信息能够影响后续的输出结果。RNN 的这种特性非常适合于处理具有前后关联特征的时序数据。如图 1 所示，左边的图是 RNN 结构的折叠图，右边是 RNN 结构展开图。从图中可以看出，在每个时间步 t ，每个神经元同时接收输入层数据 $x(t)$ 和前一个时间步隐藏层节点的输出 $h(t)$ 。




图 1 RNN 结构图

RNN 在前向传播的过程中，主要分为输入层到隐藏层、隐藏层到输出层两部分。传播过程为：

输入层→隐藏层：

$$h(t) = h(x_t^T \cdot W_x + h_{t-1}^T \cdot W_h + b) \quad (1)$$

隐藏层→输出层：

$$y_t = f(c + W_y h_t) \quad (2)$$

其中： W_x 和 W_h 分别表示输入 x_t 的权重和前一个时间步隐层输出 h_{t-1} 的权重； W_y 是隐藏层输出的权重。

循环神经网络的计算过程虽然添加了上一时刻隐藏层的输入，但是当步长过长时，后面的节点对前面时间节点的感知能力下降，即 RNN 存在的长期依赖问题。

1.3 长短时记忆神经网络

长短期记忆网络（LSTM）是 RNN 的一种，解决了普通 RNN 梯度消失的问题。LSTM 神经元内部存在输入门、忘记门、输出门用来计算信息的重要程度，并据此对信息进行筛选。LSTM 通过门限控制解决了传统 RNN 的梯度消失问题^[13]，这样就为构建大型 LSTM 网络提供了可能。LSTM 能够挖掘时序数据中的长跨度关联关系，是时序处理的理想模型。LSTM 是建立在 RNN 基础上的一种特殊类型的网络结构，它的提出主要是未来克服 RNN 中存在的长期依赖导致梯度消失而设计的。LSTM 的核心是细胞（cell）的状态，而在 LSTM 元中内部设计了输入门（Input gate）、输出门（Output gate）和遗忘门（Forget gate），设计“门”的目的是清除或增加信息到细胞状态中。LSTM 的内部结构相比 RNN 更复杂，单个 LSTM 神经元的内部结构如图 2 所示。

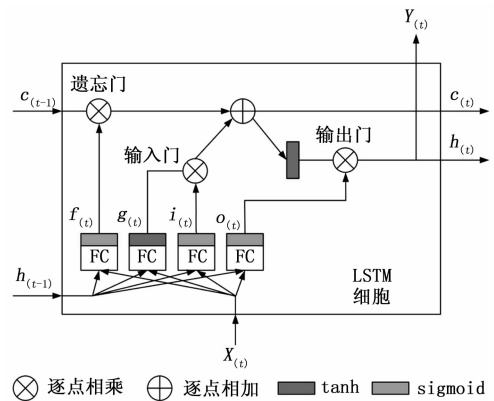


图 2 LSTM 内存单元

为了更好地理解 LSTM 神经元的内部结构，首先对神经元内部的符号进行假设。本文假设 h 为 LSTM 单元的输出， c 为 LSTM 内存单元的值， x 为输入数据。LSTM 单元的更新与前向传播一样，可以分为以下几个步骤。

步骤 1：首先，本文先计算当前时刻的输入结点 $g(t)$ ， W_{xg} 、 W_{hg} 和 W_{cg} 分别是输入数据和上一时刻 LSTM 单元输出的权值：

$$\alpha'_g = W_{xg}^T x(t) + W_{hg}^T h_{(t-1)} + b_g \quad (3)$$

$$g(t) = \tanh(\alpha'_g) \quad (4)$$

步骤 2：计算输入门的值 $i(t)$ 。输入门用来控制当前输入数据对记忆单元状态值的影响。所有门的计算受当前输

入数据 $x_{(t)}$ 和上一时刻 LSTM 单元输出值 $h_{(t-1)}$ 影响。

$$\alpha'_i = W_{xi}^T x_{(t)} + W_{hi}^T h_{(t-1)} + W_{ci}^T c_{(t-1)} + b_i \quad (5)$$

$$i_{(t)} = \sigma(\alpha'_i) \quad (6)$$

步骤 3: 计算遗忘门的值 $f_{(t)}$ 。遗忘门主要用来控制历史信息对当前记忆单元状态值的影响, 为记忆单元提供了重置的方式。

$$\alpha'_f = W_{xf}^T x_{(t)} + W_{hf}^T h_{(t-1)} + b_f \quad (7)$$

$$f_{(t)} = \sigma(\alpha'_f) \quad (8)$$

步骤 4: 计算当前时刻记忆单元的状态值 $c_{(t)}$ 。记忆单元是整个 LSTM 神经元的核心结点。记忆单元的状态更新主要由自身状态 $c_{(t-1)}$ 和当前时刻的输入结点的值 $g_{(t)}$, 并且利用乘法门通过输入门和遗忘门分别对这两部分因素进行调节。乘法门的目的是使 LSTM 存储单元存储和访问时间较长的信息, 从而减轻消失的梯度。

$$c_{(t)} = f_{(t)} \otimes c_{(t-1)} + i_{(t)} \otimes g_{(t)} \quad (9)$$

其中: \otimes 表示逐点乘积。

步骤 5: 计算输出门 $o_{(t)}$ 。输出门用来控制记忆单元状态值的输出。

$$\alpha'_o = W_{xo}^T x_{(t)} + W_{ho}^T h_{(t-1)} + b_o \quad (10)$$

$$o_{(t)} = \sigma(\alpha'_o) \quad (11)$$

步骤 6: 最后计算 LSTM 单元的输出。

$$h_{(t-1)} = o_{(t)} \otimes \tanh(c_{(t)}) \quad (12)$$

步骤 7: 更新当前序列索引预测输出。

2 模型构建

系统关键负载指标的预测模型如图 3 所示。模型的输入数据包括 CPU、硬盘和网络等负载指标数据, 预测输出的负载指标为 `cpu_usr`, `net_rcv_pkts`, `disk_all_tps`。预测模型分为归一化层, 神经网络层, 和逆归一化层。归一化层将各个参数数据转化到 $[0, 1]$ 区间上, 逆归一化层将预测所得数据映射到数据原有值域。提供预测功能的神经网络层有分为两部分, LSTM 网络层和 BP 全连接层; LSTM 网络层提供对时间序列的特征提取、记忆和特征组合的功能; BP 全连接层将最后一层 LSTM 网络输出的特征向量转化成为输出结果。

2.1 数据处理的和归一化相关处理

公式 (13) 表示的是预测模型的输入输出关系: \tilde{a}_{i+l}^k 为第 k 元时序时刻 $i+l$ 时的预测值, l 为预测跨度; 输入为 $n \times m$ 的矩阵, 表示输入有 n 元时间序列连续 m 时间片的观测值; θ 为预测模型内的变量。在数据格式转化时, 需要整理出公式 (1) 中出现的输入矩阵, 在训练过程中还需要整理出 $\tilde{a}_{i+1}^k, \tilde{a}_{i+1}^k, \tilde{a}_{i+1}^k$ 的对应观测值 $a_{i+1}^k, a_{i+1}^k, a_{i+1}^k$ 用于计算预测误差。

$$f \left(\begin{matrix} \tilde{a}_{i+1}^k, \tilde{a}_{i+1}^k, \tilde{a}_{i+1}^k, \theta_{i+1} \end{matrix} \right) = \left[\begin{matrix} a_{u-m+1}^1 & a_{u-m+2}^1 & \cdots & a_i^1 \\ a_{u-m+1}^2 & a_{u-m+2}^2 & \cdots & a_i^2 \\ \cdots & \cdots & \cdots & \cdots \\ a_{u-m+1}^n & a_{u-m+2}^n & \cdots & a_i^n \end{matrix} \right]; \theta_i \quad (13)$$

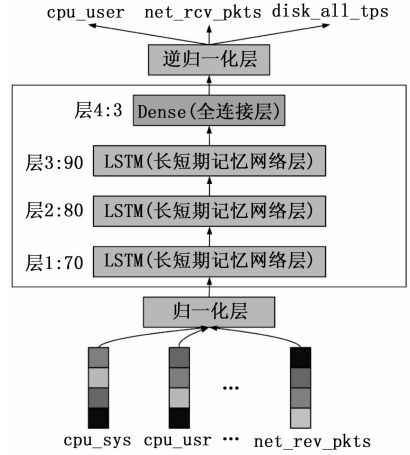


图 3 关键负载指标预测模型示意图

由于系统负载指标在数值上不在同一个值域, 将数据进行归一化能够保证训练过程的稳定性, 更容易训练得到最优解。归一化层和逆归一化层完成参数在值域上的转化操作。

2.2 长短期记忆网络层

长短期记忆网络层接受归一化后的时序数据并对时序数据进行特征提取并可以通过其记忆功能在内部状态向量中保留部分和历史输入相关的信息并最终向全连接层提供和未来关键负载指标相关的特征向量。在本模型中 LSTM 网络层有三层, 最下层网络接受归一化的多元时序片段, 对其进行特征变换和时序中关键信息的记忆功能, 生成的特征向量提供给上层 LSTM 网络。上层的 LSTM 网络对下层生成的特征向量进行特征组合、变换、记忆、忘记生成更高一层的特征向量, 上层 LSTM 网络层能够从更大维度上描述时序的特征。上层 LSTM 网络输出的向量的是下层 LSTM 网络输出特征向量的组合。由于高层神经网络往往存在梯度消失、梯度爆炸、训练复杂度过于复杂的问题, LSTM 的层数不是越多越好, 本模型根据模型训练的实际效果使用了三层 LSTM 网络。由于上层 LSTM 层所输出的特征向量是下层 LSTM 层输出特征向量的组合, 上层所能表达的特征数多于下层, 因此三层 LSTM 层中的神经元数目从下到上是递增的。这样保证了上层 LSTM 层能够提取出足够多的特征而又不会因为模型过于复杂造成难以训练的问题。

2.3 全连接层

全连接层位于预测模型的最顶层, 完成把最后一层 LSTM 层产生的特征向量映射为输出向量的功能。由于 LSTM 层也能够提供分线性函数变换的功能, 在该模型中使用单层全连接网络已经能够满足需求。该层没有选择使用 LSTM 网络层, 是因为 LSTM 为了解决不饱和记忆的问题, 门限控制的激活函数倾向于输出 0 或者 1, 即完全忘记或者完全记住, 这样就会造成输出结果的连续性变差; 另一方面, 由于最顶层的 LSTM 节点个数很少, 所能够提供的记忆能力十分有限; 再者, LSTM 网络的结构比全连接

层要复杂很多，训练时将更加困难。

2.4 神经网络的优化方法

神经网络的损失函数为均方误差 (mean-square error, MSE)^[14]。神经网络的优化方法有很多，如 SGD^[15]、Ada-grad^[16]、AdaDelta^[17]、Adam^[18]等。其中 Adam 算法整体表现优异，在实际应用中效果良好。

3 实验验证

使用实际服务器中应用运行负载指标的时序序列训练模型并分析模型的训练和预测误差。实验中，首先使用不同模型参数分析拟合方均根差，找到相对合理的模型；之后对比其它时序预测模型和本论文中设计的模型的预测效果，验证模型的优点。

3.1 神经网络超参数选取

超参数选取作为设计神经网络模型的重要一环，对模型的实际输出效果有重大的影响。神经网络的层数、每层中的节点类型、节点个数是影响神经性能的几个重要参数。

图 4 所示的为应用在运行过程中，归一化后的对不同硬件资源的消耗情况。观察改图不难发现，cpu_user 和 cpu_sys 存在周期性波动的情况，而且两者存在着某种“同步”变化，这就是说这两者之间存在着数值上的关联性。实验中，预测 cpu_user, net_rcv_pkts, disk_all_tps 三个指标的未来 8 个时间单位的负载需求。

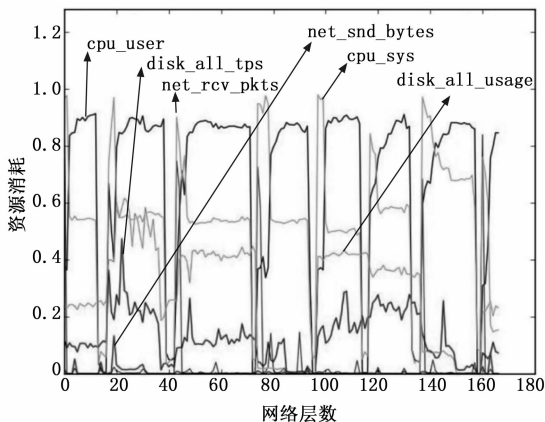


图 4 关键负载指标时序数据

在表 1 中的网络参数一栏中从左至右的数字部分表示神经网络层从下至上各层的节点个数，数字后面的 L 代表该层为长短期记忆网络层，D 代表该层为全连接层。分析表中的数据可知：

- 1) 模型最后一层用全连接层会获得比较好的拟合效果；
- 2) 使用三层长短期记忆网络层取到比较好的效果；
- 3) 当模型中的长短期记忆网络层中的节点数从底层到上层逐渐增加效果优于节点数逐渐减少的模型。

对比不同参数条件下的拟合方均根差、模型复杂度选择预测模型中的网络类型和网络节点数量，设计了如图 3 中的关键负载预测指标模型。

表 1 不同参数的模型拟合误差

模型参数	拟合方均根差
(30L, 40L, 60L, 90L, 3D)	113.007e-3
(20L, 30L, 50L, 3D)	19.854e-3
(30L, 90L, 3L)	68.265e-3
(30L, 42L, 90L, 3D)	5.293e-3
(50L, 70L, 90L, 3D)	4.846e-3
(70L, 80L, 90L, 3D)	4.614e-3
(90L, 80L, 70L, 3D)	13.446e-3
(24L, 60L, 3D)	32.665e-3
(24L, 36L, 60L, 3D)	7.634e-3
(30L, 42L, 90L, 3L)	132.137e-3
(30L, 50L, 100L, 3D)	9.542e-3
(30L, 60L, 100L, 3D)	4.935e-3
(90L, 90L, 90L, 3D)	4.789e-3
(60L, 36L, 24L, 3D)	11.942e-3

3.2 对比实验

为了进一步验证论文中设计神经网络预测模型对时间序列的优势，使用不同时序预测模型进行对比。首先从易用性的角度排除了 ARIMA 模型，ARIMA 模型由于需要具体分析时序的平稳性，需要太多人工干预，单一参数的适用性太差。在实验中具体比较了多元线性回归 (MLR)、BP 神经网络，将图 3 中的 LSTM 替换为普通 RNN 和 GRU，不断调整参数达到最优后和论文介绍的模型输出结果进行对比，验证模型的优越性。

表 2 不同模型实验结果对比

模型类型	结构	训练均方误差	预测均方误差
MLR	NA	172.991e-3	172.166e-3
BP 神经网络	(90D, 100D, 64D, 3D)	58.741e-3	60.837e-3
LSTM	(70L, 80L, 90L, 3D)	4.614e-3	5.426e-3
RNN	(100R, 105R, 120R, 3D)	24.243e-3	23.529e-3
GRU	(90G, 90G, 90G, 3D)	14.085e-3	16.353e-3

由于没有备激活函数，不具备拟合非线性函数的能力，只能挖掘输出数据和输入数据之间的线性关联关系，在数据集上的表现不理想，误差较大。BP 神经网络能够拟合非线性函数，但由于其每次输出的结果仅仅依赖于该次输入数据，不能挖掘非输入时序数据和输出的关联关系。RNN 和 GRU 这两种模型虽然具备一定的记忆能力，普通 RNN 存在梯度消失的问题，不能挖掘时间序列中长跨度依赖关系；GRU 是 LSTM 的简化版本，在很多问题上两者不相伯仲，实验结果表明，该模型稍逊于 LSTM，这是由于 GRU 模型在训练过程中抖动比较严重，而 LSTM 表现稳定，损失保持相对稳定下降。

4 结论

本文给出了基于 LSTM 循环神经网络的应用运行关键负载指标的预测模型，并设计了相关实验比较了其它预测

模型的预测效果。实验结果表明，本论文提出的基于 LSTM 的神经网络模型的预测效果更优，精度更高。论文初步验证了应用运行负载指标日志并在线预测未来应用关键负载指标的可行性，可以为弹性计算根据预测负载调整集群容量提供参考。

参考文献：

[1] 吴和生, 王崇骏, 谢俊元. TeraPELB: 云计算中基于预测的弹性负载均衡算法 [J]. 系统仿真学报, 2013, 25 (8): 1751 - 1760.

[2] 张建东, 杨进, 刘才铭, 等. 改进的 AHP 算法在 Web 集群系统负载均衡中的应用 [J]. 计算机工程与应用, 2015, 51 (7): 93 - 97.

[3] 邓雪刚, 王嘉, 赵壤, 等. 大型电子政务应用系统负载均衡的设计与实现 [J]. 云南大学学报 (自然科学版), 2013, 35 (S2): 233 - 236.

[4] 赵颖, 王权, 黄叶子, 等. 多视图合作的网络流量时序数据可视分析 [J]. 软件学报, 2016, 27 (5): 1188 - 1198.

[5] 孙轶轩, 邵春福, 计寻, 等. 基于 ARIMA 与信息粒化 SVR 组合模型的交通事故时序预测 [J]. 清华大学学报 (自然科学版), 2014, 54 (3): 348 - 353.

[6] Majidpour M, Qiu C, Chu P, et al. Fast prediction for sparse time series: Demand forecast of EV charging stations for cell phone applications [J]. IEEE Transactions on Industrial Informatics, 2015, 11 (1): 242 - 250.

[7] 陆文昊. 基于时间序列预测模型的电视剧收视率预测 [J]. 电子世界, 2018 (1): 39 - 40.

[8] 何正义, 曾宪华, 曲省卫, 等. 基于集成深度学习的时间序

列预测模型 [J]. 山东大学学报 (工学版), 2016, 46 (6): 40 - 47.

[9] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用 [J]. 电力信息与通信技术, 2017, 15 (5): 8 - 11.

[10] 李克文, 刘洪太. 基于时序数据的软件可靠性模型组合新方法 [J]. 计算机应用, 2014, 34 (2): 208 - 210.

[11] 李华, 屈丹, 张文林, 王炳锡, 等. 结合全局词向量特征的循环神经网络语言模型 [J]. 信号处理, 2016, 32 (6): 715 - 723.

[12] 魏子昂, 秦霆镐. 基于多层神经网络的 PID 热熔接面板解耦控制系统 [J]. 工业控制计算机, 2018, 31 (2): 62 - 63.

[13] 梁军, 柴玉梅, 原慧斌, 等. 基于极性转移和 LSTM 递归网络的情感分析 [J]. 中文信息学报, 2015, 29 (5): 152 - 159.

[14] 李季. 改进误差反向传播 (BP) 神经网络在图像压缩中的应用 [J]. 应用光学, 2013, 34 (6): 974 - 979.

[15] 王功鹏, 段萌, 牛常勇. 基于卷积神经网络的随机梯度下降算法 [J]. 计算机工程与设计, 2018, 39 (2): 441 - 445.

[16] Ganin Y, Ustinova E, Ajakan H, et al. Domain - adversarial training of neural networks [J]. The Journal of Machine Learning Research, 2016, 17 (1): 2096 - 2030.

[17] Mahendran A, Vedaldi A. Visualizing deep convolutional neural networks using natural pre - images [J]. International Journal of Computer Vision, 2016, 120 (3): 233 - 255.

[18] 杨子文, 曾上游, 杨远飞. 基于二叉树型卷积神经网络信息融合的人脸验证 [J]. 计算机应用, 2017, 37 (S2): 155 - 159.

(上接第 202 页)

表 1 无线语音通信系统 5 m 通信距离测试情况

通信路数	1	2	3	4
通话质量	音质好, 无杂音	音质好, 无杂音	音质好, 稍有杂音	音质好, 少量杂音
语音延迟	无延迟	无延迟	无延迟	无延迟

表 2 无线语音通信系统 15 m 通信距离测试情况

通信路数	1	2	3	4
通话质量	轻微失真, 无杂音	轻微失真, 无杂音	轻微失真, 稍有杂音	轻微失真, 少量杂音
语音延迟	无延迟	无延迟	无延迟	无延迟

5 结束语

基于蓝牙技术的载人航天器舱内无线语音系统实现了高质量的无线语音通话效果，可支持多名航天员同时与地面通话，以及航天员之间互相通话等功能。利用航天器语音处理设备模拟件建立无线语音测试系统并开展测试试验，结果表明，该系统可实现多路无线语音通信，语音清晰易懂，且具备实时性高，操作简便等优点，可以满足航天员在轨语音通信使用需求。

参考文献：

[1] 王永志. 实施我国载人空间站工程推动载人航天事业科学发展 [J]. 载人航天, 2011, 17 (1): 1 - 4.

[2] 郑世宝, 杨华, 张重阳, 等. 空间站航天员的生活和健康保障技术研究 [J]. 电视技术, 2013, 37 (20): 87 - 91.

[3] 张鹏, 王颖, 杨军. 无线音频技术综述 [J]. 电声技术, 2011, 35 (3): 54 - 60.

[4] 任岳颖. 基于蓝牙的无线语音通信技术研究 [D]. 西安: 西安电子科技大学, 2009.

[5] 宋绪龙. 基于 $\mu\text{C}/\text{OS} - \text{II}$ 操作系统的蓝牙音频应用系统设计 [D]. 武汉: 华中科技大学, 2014.

[6] 钱志鸿, 刘丹. 蓝牙技术数据传输综述 [J]. 通信学报, 2012, 33 (4): 143 - 151.

[7] 陈雅会. 蓝牙散射网及文件传输的研究与实现 [D]. 西安: 西安电子科技大学, 2008.

[8] 卢利颖. 蓝牙散射网音频传输系统研究与实现 [D]. 北京: 北京交通大学, 2016.

[9] 郭峰. 蓝牙数据传输性能增强技术研究 [D]. 西安: 西安电子科技大学, 2007.

[10] 丁晓敏. 强噪声环境下语音增强算法的研究及其 DSP 实现 [D]. 南京: 南京航空航天大学, 2010.

[11] 吕晓宇. 车载蓝牙免提系统研究 [J]. 长春理工大学学报 (自然科学版), 2008, 31 (1): 124 - 126.