

基于 ARIMA-RNN 组合模型的云服务器老化预测方法

孟海宁^{1,2}, 童新宇¹, 石月开¹, 朱磊¹, 冯锴¹, 黑新宏¹

(1. 西安理工大学计算机科学与工程学院, 陕西 西安 710048; 2. 陕西省网络计算与安全技术重点实验室, 陕西 西安 710048)

摘要: 针对云服务器系统运行环境具有非线性、随机性和突发性的特点, 提出了基于整合移动平均自回归和循环神经网络组合模型 (ARIMA-RNN) 的软件老化预测方法。首先, 采用 ARIMA 模型对云服务器时间序列数据进行老化预测; 然后, 利用灰色关联度分析法计算时间序列数据的相关性, 确定 RNN 模型的输入维度; 最后, 将 ARIMA 模型预测值和历史数据作为 RNN 模型的输入进行二次老化预测, 从而克服了 ARIMA 模型对波动较大的时间序列数据预测精度较低的局限性。实验结果表明, ARIMA-RNN 组合模型比 ARIMA 模型及 RNN 模型的预测精度高, 且比 RNN 模型预测收敛速度快。

关键词: 软件老化; 云服务器; 预测方法; ARIMA 模型; RNN 模型

中图分类号: TP311.1

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021015

Cloud server aging prediction method based on hybrid model of auto-regressive integrated moving average and recurrent neural network

MENG Haining^{1,2}, TONG Xinyu¹, SHI Yuekai¹, ZHU Lei¹, FENG Kai¹, HEI Xinhong¹

1. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

2. Shaanxi Key Lab Network Computer and Security Technology, Xi'an 710048, China

Abstract: In view of the nonlinear, stochastic and sudden characteristics of operating environment of cloud server system, a software aging prediction method based on hybrid auto-regressive integrated moving average and recurrent neural network model (ARIMA-RNN) was proposed. Firstly, the ARIMA model performs software aging prediction of time series data in cloud server. Then the grey relation analysis method was used to calculate the correlation of the time series data to determine the input dimension of RNN model. Finally, the predicted value of ARIMA model and historical data were used as the input of RNN model for secondary aging prediction, which overcomes the limitation that ARIMA model has low prediction accuracy for time series data with large fluctuation. The experimental results show that the proposed ARIMA-RNN model has higher prediction accuracy than ARIMA model and RNN model, and has faster prediction convergence speed than RNN model.

Keywords: software aging, cloud server, prediction method, auto-regressive integrated moving average model, recurrent neural network model

1 引言

软件老化是影响软件系统可靠性的潜在因素,

当长期运行的软件系统存在软件老化现象时, 系统将出现性能下降、异常和错误增加, 甚至死机^[1]。

软件老化是由操作系统可分配资源匮乏、碎片化严

收稿日期: 2020-09-10; 修回日期: 2020-11-22

通信作者: 黑新宏, heixinhong@xaut.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61602375, No.61773313); 陕西省自然科学基金基础研究计划基金资助项目 (No.2019JQ-749)

Foundation Items: The National Natural Science Foundation of China (No.61602375, No.61773313), The Natural Science Basic Research Plan in Shaanxi Province of China (No.2019JQ-749)

重以及内部错误积累（如内存泄漏和未释放的文件资源）造成的，而这些错误在软件测试阶段难以检测和消除^[2]。云计算系统的体系结构复杂，系统内计算资源的申请和释放较为频繁，且云系统长期运行为用户提供服务，因此云系统更容易出现软件老化现象，影响系统可用性和可靠性。

为了避免软件老化，Huang 等^[3]提出了软件再生。它是一种主动预防性的容错技术，通过重置软件系统内部状态，防止系统未来发生重大故障。该过程通过有计划地重启系统，清理系统运行环境，使系统恢复到初始健康状态。然而软件再生操作将带来额外的系统开销，因此需要选择最佳时机进行软件再生。

为了减少软件再生给系统带来的时间和资源消耗的成本，学者们对软件老化趋势进行预测，计算老化阈值，在系统重大故障发生之前对系统进行软件再生。其中，Okamura 等^[4]构造了基于马尔可夫链的响应时间序列，评估分布式服务器系统的软件老化趋势。Matos 等^[5]针对 Eucalyptus 云系统老化现象，提出了基于多阈值的时间序列预测方法，该方法求解得到最优再生时机，可减少系统停机时间并提高系统可靠性。Islam 等^[6]针对亚马逊 EC2 云系统，采用神经网络和线性回归的方法，预测系统资源使用情况，为资源配置策略提供参考依据。Langner 等^[7]发现运行于同一个基于内核的虚拟机（KVM, kernel-based virtual machine）之上的 3 个虚拟机（VM, virtual machine）的 CPU 占用率逐步升高，物理内存和交换区使用量逐渐消耗，继而出现 VM 上 HTTP 请求响应缓慢，最终导致整个系统老化。Kousiouris 等^[8]采用人工神经网络的方法，预测云系统中 VM 的性能。郑鹏飞等^[9]提出运用多元时间序列模型分析软件老化的方法。林己杰等^[10]针对服务器软件老化现象，提出了一种基于 BP 神经网络和马尔可夫模型结合的方法对服务器关键资源进行预测。

综上所述，大多数学者关注时间序列分析或智能算法来预测软件老化趋势。时间序列分析法采用自回归移动平均（ARMA, autoregressive moving average）、粒子滤波等模型进行趋势预测^[11-13]，模型简单，但所需数据量大且对于波动较大的数据预测精度较低。智能算法包括神经网络、支持向量机等^[14-15]，该类算法在预测时间序列数据时，预测精度不高且收敛较慢。因此，仅采用单一模型进行软件老化预测，很难获得比较精确的预测结果。

本文探究基于 OpenStack^[16-17]的云服务器系统的软件老化问题，为实现软件再生机制提供理论依据。本文将整合移动平均自回归（ARIMA, autoregressive integrated moving average）模型与循环神经网络（RNN, recurrent neural network）模型结合，得到 ARIMA-RNN 组合模型，对云服务器系统老化趋势进行预测。该方法克服了 ARIMA 模型对波动较大的数据预测精度较低的限制，解决了 RNN 模型预测收敛速度慢的问题，最终实现对云服务器系统的老化预测。此外，本文设计了负载实验方案，模拟云服务器系统实际工作状况，选择云服务器的性能服务参数响应时间和系统参数 CPU 使用率作为衡量系统老化的重要指标，验证软件老化现象的存在，并预测系统老化趋势。

2 ARIMA-RNN 组合模型预测方法

基于 ARIMA-RNN 组合模型的云服务器老化预测方法的工作流程包括 4 个基本步骤：数据预处理、ARIMA 模型构建及数据拟合、RNN 模型构建，以及 ARIMA-RNN 组合模型构建及数据预测。

2.1 数据预处理

对云服务器进行老化预测前，需对数据进行归一化预处理。这是因为云服务器系统性能参数的时间序列数据分布不均匀且数据变化幅度（标准差）较大，数据中含有奇异样本数据，预测时会减慢网络的学习和收敛速度。因此本文采用归一化处理方法，将云服务器原始数据映射到 $[-1,1]$ ，使预测模型收敛速度快，映射转换过程如式(1)所示。

$$\dot{X} = \frac{X - x_{\text{mean}}}{x_{\text{max}}} \quad (1)$$

其中， x_{max} 是数据的最大值， x_{mean} 是数据的平均值， X 是原始时间序列数据， \dot{X} 是预处理后的时间序列数据。

2.2 ARIMA 模型构建及数据拟合

构建 ARIMA 模型时，需确定 ARIMA 模型中的参数 p 、 d 、 q 。首先，通过单位根检验方法，对序列数据进行平稳性检验，若序列数据为非平稳时间序列则需反复进行差分处理，直到差分后的时间序列平稳为止。然后，计算自相关和偏自相关函数，确定自回归项 p 和移动平均项 q 的取值范围。最后，采用赤池信息量准则（AIC, Akaike information criterion）对 p 和 q 的取值进行最佳估计，计算对应

ARIMA 模型的 AIC 值，从而得到最佳 ARIMA 模型。其中 AIC 值反映了数据的拟合效果，AIC 值越小，则数据拟合效果越好。采用 ARIMA 模型的数据预测过程如图 1 所示。

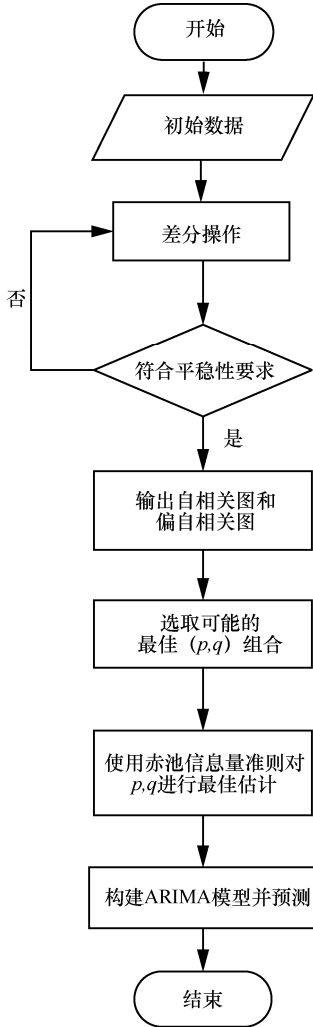


图 1 ARIMA 模型预测流程

2.3 RNN 模型构建

1) RNN 隐藏层数

首先，RNN 与前馈神经网络 (FNN, feedforward neural network) 结构相似，具备与 FNN 相似的数据拟合能力。其次，Hornik 等^[18]已证明 FNN 只需具备单个隐藏层和有限个神经元，即能较高精度地拟合任意复杂度的函数。因此本文将 RNN 模型的隐藏层数设置为 1。

2) RNN 输入层节点数

RNN 模型利用历史数据 $x(t-1), x(t-2), \dots, x(t-n)$ 对 $x(t)$ 进行预测 (其中 $x(t)$ 为时刻 t 的数据值， n 为历史数据的个数)。因此，RNN 模型中输入层节点

的数量由选取的历史数据个数决定。灰色关联分析法^[19]是衡量序列数据相关程度的方法，灰色关联系数越大，则序列数据的相关性越强。本文采用灰色关联分析法，计算序列数据中每个数据与若干历史数据的平均相关性，确定与 $x(t)$ 相关性较强的历史数据作为 RNN 模型的输入，从而确定 RNN 网络输入层节点个数，具体过程如算法 1 所示。

算法 1 时间序列数据灰色关联分析法

输入 经预处理的时间序列数据

输出 时间序列数据中 t 时刻的值与历史值的平均相关系数

步骤 1 用大小为 m ($0 < m < N$ | $m \in \mathbf{Z}^+$, N 为数据个数) 的滑动窗口遍历原始时间序列数据，构造输入特征向量，即时刻 t ($t=m, m+1, \dots, N-1$) 的特征向量为 $\mathbf{X}_t = [x_{t-1}, x_{t-2}, \dots, x_{t-m}]$ ， t 时刻的标签数据记为 y_t ，且 $y_t = x_t$ ，则获得训练数据集为

$$\text{data} = \{\mathbf{X}_t, y_t | t=0, 1, 2, \dots, N-m\}$$

步骤 2 用步骤 1 得到数据集的标签数据依次减去对应特征向量的特征值，得到每个数据与 m 个数据的差，再取绝对值，即 $T = \{|y_t - \mathbf{X}_t| | t=0, 1, 2, \dots, N-m\}$ ，其中 $|y_t - \mathbf{X}_t| = [|y_t - x_{t-1}|, |y_t - x_{t-2}|, \dots, |y_t - x_{t-m}|]$ 。

步骤 3 求步骤 2 中的最大差 $m_{\max} = \max_t \max_m(T)$ 与最小差 $m_{\min} = \min_t \min_m(T)$ ，设分辨系数 $\rho = 0.5$ 。

步骤 4 求解所有数据与 m 个数据的相关系数 $kis = \frac{m_{\min} + \rho \times m_{\max}}{T + \rho \times m_{\max}}$ 。

步骤 5 求平均相关系数 $\overline{kis} = \frac{1}{N-m} \sum_{i=1}^{N-m} kis[i]$ 。

3) RNN 隐藏层节点数

本文采用经验法确定神经网络隐藏层节点数，经验法如式(2)所示。

$$h = \sqrt{m+n} + \alpha \quad (2)$$

其中， h 为 RNN 模型中隐藏层神经元的个数， m 为输入层神经元的个数， n 为输出层神经元的个数， $\alpha \in \{0 \leq x \leq 10, x \in \mathbf{Z}\}$ 。

2.4 ARIMA-RNN 组合模型构建及数据预测

ARIMA-RNN 组合模型的拓扑结构如图 2 所示，预测过程如算法 2 所示。ARIMA-RNN 组合模型的输入数据由两部分构成：ARIMA 模型对 $x(t)$ 的预测值和 $x(t)$ 的历史数据 $x(t-1), x(t-2), \dots, x(t-n)$ 。

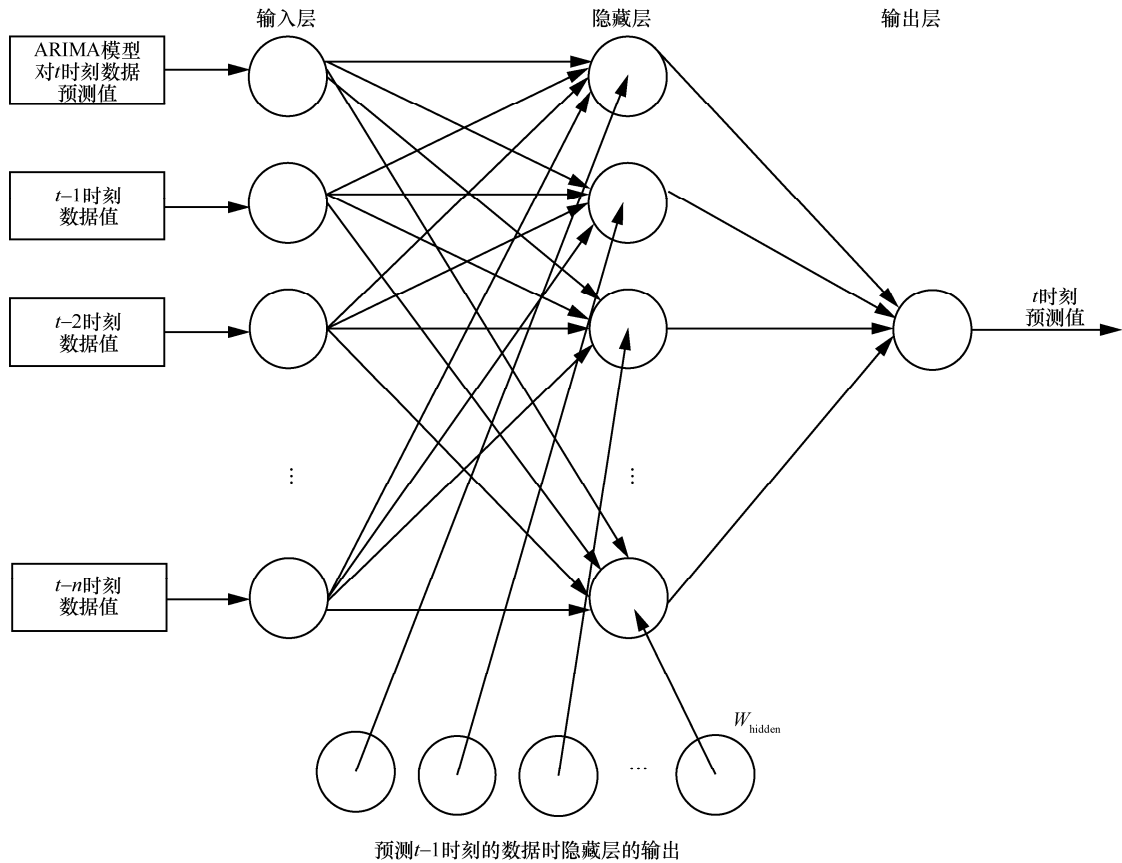


图 2 ARIMA-RNN 组合模型拓扑结构

RNN 模型训练过程中，误差函数采用均方误差 (MSE, mean square error) 函数，如式(3)所示。

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_{\text{predictive}}[i] - y_{\text{true}}[i])^2 \quad (3)$$

其中， y_{true} 为实际输出， $y_{\text{predictive}}$ 为期望输出。

算法 2 ARIMA-RNN 组合模型预测算法

输入 预处理的时间序列数据与 ARIMA 模型预测值

输出 预测结果

步骤 1 使用大小为 m ($m < N$, 其中 N 为数据个数) 的滑动窗口遍历序列数据，构造输入特征向量，即时刻 t ($t=0, 1, \dots, N-1$) 数据的特征向量为 $\mathbf{X}'_t = [x_{t-1}, x_{t-2}, \dots, x_{t-m}]$ ，时刻 t 的标签记为 y_t ，有 $y_t = x_t$ ，则训练数据集为 $\{\mathbf{X}'_t, y_t \mid t=m, m+1, m+2, \dots, N\}$ 。

步骤 2 将 ARIMA 模型预测得到的数据通过式(1)映射到区间 $[-1, 1]$ 。

步骤 3 将步骤 2 得到的序列数据截断，从第 m 个时刻开始取值，即 $\alpha = \{\alpha_m, \alpha_{m+1}, \dots, \alpha_N\}$ ，使截断后的 ARIMA 预测数据与步骤 1 的标签数据

$\mathbf{y} = \{y_m, y_{m+1}, \dots, y_N\}$ 相对应。

步骤 4 将步骤 3 得到的数据加入步骤 1 数据集的特征向量，得到 $\mathbf{X}_t = [x_{t-1}, x_{t-2}, \dots, x_{t-m}, \alpha_t]$ ， $t=m, m+1, \dots, n$ ，则 ARIMA-RNN 模型的数据集为 $\{\mathbf{X}_t, y_t \mid t=m, m+1, m+2, \dots, N\}$ 。

步骤 5 初始化 RNN 各个权重矩阵和偏移向量的值。

步骤 6 计算数据集特征向量 \mathbf{X}_t 在 ARIMA-RNN 组合模型中的输出值。

步骤 7 依据式(3)，计算步骤 6 中得到预测序列与期望序列之间的误差，利用反向传播算法调整各个权重矩阵和偏移向量的值，使误差达到最小。

步骤 8 判断训练次数是否达到最大值或误差达到阈值，若是则保存调整好的权重矩阵和偏移向量，转步骤 6 并输出预测结果；否则转至步骤 7。

2.5 时间复杂度分析

基于 ARIMA-RNN 组合模型的云服务器老化预测方法在预测时间序列数据时，将 ARIMA 模型的预测值和 $t-1, t-2, \dots, t-d$ 时刻的历史数据作为 RNN 模型的输入特征向量。首先通过 ARIMA 模型

对序列数据进行预测，ARIMA 模型预测方法的时间复杂度为 $O(n)$ ；然后将特征矩阵 X （维度为 $[n, d]$ ）输入 RNN 模型，与 RNN 的隐藏层权重矩阵（维度为 $[d, w_1]$ ）相乘，则时间复杂度为 $O(ndw_1)$ ；最后将相乘结果与输出层权重矩阵（维度为 $[w_1, 1]$ ）相乘，则时间复杂度为 $O(nw_1)$ 。所以总的时间复杂度为

$$O(n) + O(ndw_1) + O(nw_1) = O(n)$$

因此本文提出的 ARIMA-RNN 组合模型的时间复杂度为 $O(n)$ ，即线性时间复杂度。

3 实验结果与分析

为探究基于 OpenStack 云服务器的软件老化现象，实验中设计负载发生方案模拟云服务器的实际负载，并收集云服务器的资源和性能数据，作为研究软件老化的实验数据。通过对云服务器的资源和性能数据进行老化预测，为软件再生机制的部署提供理论依据。

本实验基于 OpenStack 框架和 QEMU/KVM 管理程序，实验系统由一台云服务器、一台 MySQL 数据库服务器及一组模拟客户端组成，如图 3 所示。云服务器配置环境为 Intel (R) Core (TM) i5-4590 CPU 四核 3.3GHz、8GB RAM，操作系统为 18.04.1-Ubuntux86_64，云服务器虚拟机上运行的操作系统为 Redhat 7.3_64。云服务器端部署了一个基于 Webbench 基准测试的 Web 网站系统。在客户端编写负载脚本，依照 Webbench 规范向云服务器发送网站商品查询的请求，同时监控并收集云服务器的性能参数和服务参数。实验以响应时间作为老化特征参数，实验样本数据为 2 230 个，采样时间间隔为 3 s。

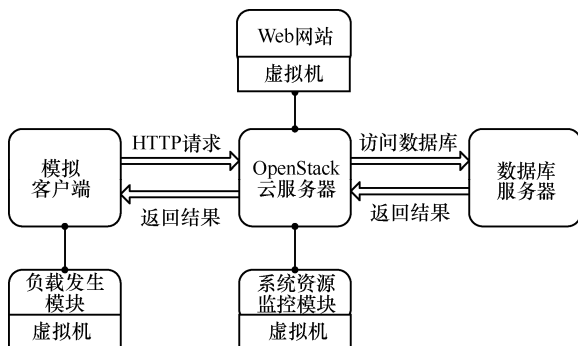


图 3 实验平台

首先，检验云服务器系统是否存在软件老化。响应时间的数据变化反映了云服务器系统运行性能表现状况，若响应时间随着系统运行时间的增长

而增加，则可认定系统处于老化状态^[20]。为了分析云服务器系统的老化状态，本文采用线性回归方法拟合响应时间数据的变化趋势，得到参数 $w=0.017$ ， $b=-0.71$ 。原始序列数据和线性回归趋势如图 4 所示，可以看出，云服务器在工作负载整体恒定的情况下，随着时间的推移，服务器的响应时间逐步上升，验证了云服务器出现软件老化现象。




图 4 云服务器响应时间数据趋势

其次，实验中应用 ARIMA-RNN 组合模型进行预测，将响应时间数据集划分为训练集和测试集(其中训练集为前 80%的数据集，测试集为后 20%的数据集)。采用组合模型进行二步老化预测，第一步采用 ARIMA 模型对响应时间 t 时刻的数据值做出预测，第二步将 ARIMA 模型预测结果值和 t 时刻之前的响应时间数据一并输入到 RNN 模型，得到响应时间 t 时刻的最终预测值。

3.1 ARIMA 模型预测结果及分析

用 ARIMA 模型对响应时间预测时，首先，采用单位根检验方法，对响应时间的序列数据进行平稳性检验，确定 ARIMA 模型中参数 d 的值。经过一次差分处理后，单位根检验结果如表 1 所示。表 1 中统计量为 -20.5675 ，小于 3 个置信度(1%，5%，10%)的临界统计值， $P=0$ ，表示拒绝原假设，因此 ARIMA 模型差分系数 $d=1$ 。

表 1 单位根检验结果	
检验项目	值(保留 4 位小数)
统计量	-20.5675
P 值	0
临界统计值(1%)	-3.4333
临界统计值(5%)	-2.8628
临界统计值(10%)	-2.5675

其次，通过偏自相关和自相关分析，确定自回归项 p 和移动平均项 q 的取值范围。如图 5 所示，偏自相关分析显示滞后阶数为 1~12 阶时，偏自相关系数超出了置信边界，滞后阶数大于 12 阶后偏自相关系数缩小至接近 0。自相关分析显示滞后阶数大于 5 阶后，自相关系数处于置信区间。因此 p 的值可能为 11 或 12， q 的值可能为 5 或 7。




图 5 偏自相关和自相关分析

最后，依据 AIC 准则对待选参数 p 和 q 进行最佳估计。将响应时间数据作为输入，用 p 和 q 的可能值构建 ARIMA 模型，分别计算模型对应的 AIC 值，如表 2 所示。可以看出，ARIMA(12,1,7)的 AIC 值最小，因此，选择 ARIMA(12,1,7)模型对响应时间进行预测，预测结果如图 6 所示。

模型	AIC 值(保留 3 位小数)
ARIMA(11,1,5)	16 230.849
ARIMA(11,1,7)	16 288.716
ARIMA(12,1,5)	16 225.668
ARIMA(12,1,7)	16 216.571

此外，图 7 给出了响应时间实际值的变化率，即响应时间随时间序列数据的斜率变化曲线，其值越大表示响应时间变化越明显。时间序列数据为 0~500 时，响应时间变化率较小，表明该段序列数

据变化较为平缓；时间序列数据为 1 000~1 500 时，响应时间变化率较大，表明该段序列数据变化剧烈。图 8 给出了 ARIMA 模型对响应时间进行预测的绝对误差。可以看出，波动平缓的数据（时间序列数据为 0~500）预测绝对误差较小，而波动剧烈的数据（时间序列数据 1 000~1 500）预测绝对误差较大。因此，可以判断对于波动剧烈的时间序列数据，用 ARIMA 模型预测效果较差。




图 6 ARIMA 模型预测结果




图 7 响应时间实际值的变化率




图 8 响应时间预测绝对误差

综上，由于云服务器系统性能数据和资源数据具有突发性、变化剧烈以及周期性的特点，对于变化剧烈的时间序列数据，用 ARIMA 模型预测效果较差。因此仅采用单一的 ARIMA 模型对云服务器进行老化预测，效果并不理想。

3.2 ARIMA-RNN 组合模型预测结果及分析

构建 ARIMA-RNN 组合模型，需确定 RNN 网络结构。首先，采用算法 1 计算响应时间序列数据的相关性，如图 9 所示，平均相关系数呈波动下降的趋势，当历史数据个数为 10 时数据的相关性最强，因此 ARIMA-RNN 组合模型的输入层节点数为 10。然后，根据式(2)得到隐藏层节点数的最佳取值区间，并经过反复实验测试，得到隐藏层节点数最优值为 20。此外，本实验 RNN 网络中激活函数选取 tanh 函数，该函数值域为 $[-1,1]$ ，对于特征相差大的数据处理效果较好。




图 9 响应时间序列数据的相关性

然后，使用 ARIMA-RNN 组合模型、ARIMA 模型^[21]以及 RNN 模型^[22]对响应时间进行预测，预测结果如图 10(a)所示。训练数据集区间为 $[0,1784]$ ，测试数据集区间为 $[1785, 2230]$ 。由于数据量大且数据变化较为剧烈，为了显示清晰每隔 50 个数据点输出结果。可以看出，ARIMA-RNN 组合模型拟合效果最好。3 种模型的预测结果误差对比情况，如图 10(b)所示。可见 ARIMA 模型和 RNN 模型各有优势，在数据较平稳的区间数据，如 0~500 区间数据，ARIMA 模型的预测精度优于 RNN 模型预测精度；而在数据波动较为剧烈的区间数据，如 1500~2000 区间数据，RNN 模型预测精度优于 ARIMA 模型。ARIMA-RNN 组合模型结合了这两者的优势，预测精度最高。

3.3 预测性能评价


本文从预测精度、预测收敛速度及可扩展性 3 个方面，对本文所提预测方法进行性能评价。首先，在评判算法预测精度方面，采用均方根误差 RMSE、平均绝对误差 MAE 及平均绝对百分比误差 MAPE 作为评价指标，计算式如下所示。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_{\text{predictive}}[i] - y_{\text{true}}[i])^2} \quad (4)$$

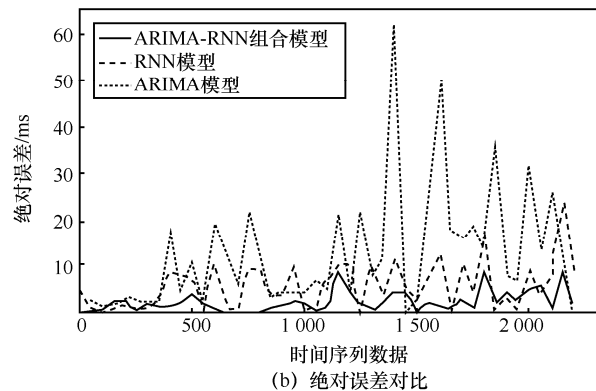
$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{\text{predictive}}[i] - y_{\text{true}}[i]| \quad (5)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_{\text{predictive}}[i] - y_{\text{true}}[i]}{y_{\text{true}}[i]} \right| \quad (6)$$

其中， n 为数据样本的个数， $y_{\text{predictive}}$ 为预测序列数据， y_{true} 为实际序列数据。



(a) 预测结果对比



(b) 绝对误差对比

图 10 响应时间预测及误差对比

使用 ARIMA-RNN 组合模型、ARIMA 模型^[21]和 RNN 模型^[22]，对响应时间数据进行预测精度对比，如表 3 所示。ARIMA-RNN 组合模型的 RMSE、MAE 和 MAPE 值均最小，其次是 RNN 模型，ARIMA 模型预测误差最大。而 ARIMA-RNN 组合模型相较 ARIMA 模型和 RNN 模型，RMSE 分别降低了 83.90%和 76.61%，MAE

分别降低了 86.10%和 74.24%，MAPE 分别降低了 81.23%和 71.47%。可见，本文所提 ARIMA-RNN 组合模型，在预测云服务器性能数据时比 ARIMA 模型和 RNN 模型的预测精度更高。原因是本文针对 OpenStack 云服务器的系统性能参数在运行时的数据变化特点，设计 ARIMA-RNN 组合模型进行系统老化预测，克服了 ARIMA 模型对于波动较大数据预测精度较低的限制性，因而提高了预测精度。

表 3 各模型误差对比

预测模型	RMSE	MAE	MAPE
ARIMA 模型 ^[21]	13.79	11.01	170.94%
RNN 模型 ^[22]	9.49	5.94	112.46%
ARIMA-RNN 组合模型	2.22	1.53	32.08%

其次，在评价预测收敛速度方面，将本文所提的 ARIMA-RNN 组合模型与 RNN 模型进行了对比，网络训练过程的收敛趋势如图 11 所示。本文基于 ARIMA-RNN 组合模型的预测方法，在模型训练过程中，当训练次数为 10 时，均方误差 MSE 值已小于 0.0015，之后收敛趋于稳定，相较 RNN 模型预测方法，本文基于 ARIMA-RNN 组合模型的预测方法收敛速度更快且误差更小。原因是本文预测方法在 RNN 网络训练前，采用灰色关联分析方法，将相关性分析后的时间序列数据作为模型输入再进行预测，减少了相关性较差数据的输入，从而提高了预测收敛速度。

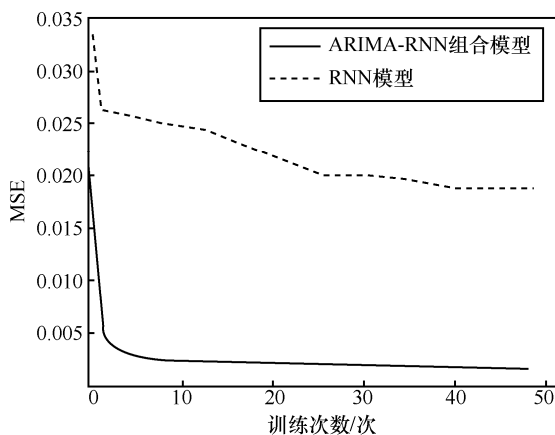


图 11 模型训练收敛趋势对比

最后，在评价预测方法的可扩展性方面，使用 ARIMA-RNN 组合模型、ARIMA 模型和 RNN 模型，对云服务器的 CPU 使用率时间序列进行预测并对

比，如图 12 所示。从图 12 可以看出，本文 ARIMA-RNN 组合模型，较单一的 ARIMA 模型和 RNN 模型，具有更好的预测效果。

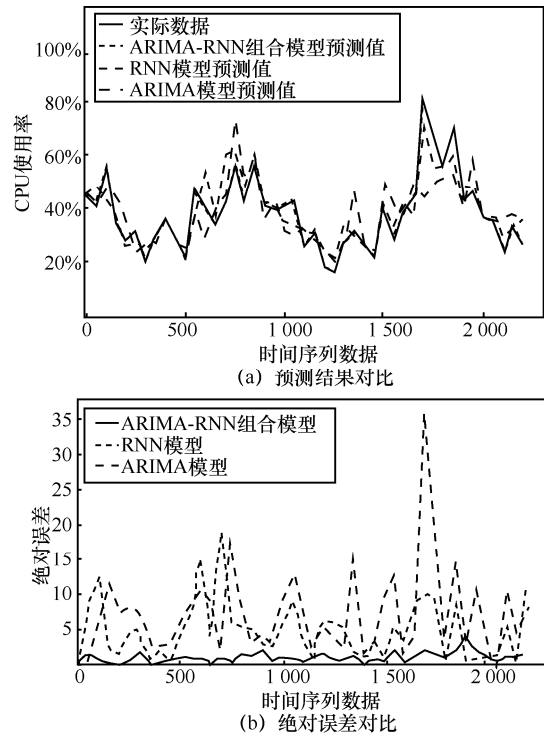


图 12 CPU 使用率预测及误差对比

综上，云服务器处于动态变化的复杂环境中，系统性能参数的时间序列波动变化，本文针对数据波动平缓和剧烈 2 种情况，结合 ARIMA 模型和 RNN 模型，预测云服务器系统的老化趋势，预测精度更高，同时，采用灰色关联度分析法，计算时间序列数据的相关性，预测收敛速度更快。

4 结束语

软件老化问题一直受到学术界和工业界的关注。软件老化预测及分析可以保障云服务器系统可靠运行，降低系统风险和损失。针对收集到的 OpenStack 云服务器性能数据，本文提出一种基于 ARIMA-RNN 组合模型的预测方法，对云服务器的性能资源进行老化预测，并验证了软件老化现象的存在。实验结果表明，ARIMA-RNN 组合模型提高了预测精度和收敛速度，为云服务器再生部署提供了参考依据。

下一步将研究预测模型对于数据变化情况下的敏感性问题，使数据出现急剧变化时，仍能获得较为精确的预测结果。

参考文献:

- [1] GROTTKE M, MATIAS R, TRIVEDI K S. The fundamentals of software aging[C]//2008 IEEE International Conference on Software Reliability Engineering Workshops. Piscataway: IEEE, 2008: 1-6.
- [2] GROTTKE M, TRIVEDI K S. Fighting bugs: remove, retry, replicate, and rejuvenate[J]. Computer, 2007, 40: 107-109.
- [3] HUANG Y, KINTALA C, KOLETTIS N, et al. Software rejuvenation: analysis, module and applications[C]//1995 Twenty-Fifth International Symposium on Fault-Tolerant Computing. Piscataway: IEEE Press, 1995: 381-390.
- [4] OKAMURA H, LUO C, DOHI T. Estimating response time distribution of server application in software aging phenomenon[C]//2013 International Symposium On Software Reliability Engineering Workshops. Piscataway: IEEE Press, 2013: 281-284.
- [5] MATOS R, ARAUJO J, MACIEL P, et al. A hybrid method based on multiple thresholds and time series prediction. international transaction on systems science and applications[J]. Software Rejuvenation in Eucalyptus Cloud Computing Infrastructure, 2012, 8: 1-16.
- [6] ISLAM S, KEUNG J, LEE K, LIU A. Empirical prediction models for adaptive resource provisioning in the cloud[J]. Future Generation Computer Systems, 2012, 28(1): 155-162.
- [7] LANGNER F, ANDRZEJAK A. Detecting software aging in a cloud computing framework by comparing development versions[C]//2013 International Symposium on Integrated Network Management. Piscataway: IEEE Press, 2013: 896-899.
- [8] KOUSIOURIS G, CUCINOTTA T, VARVARIGOU T. The effects of scheduling, workload type and consolidation scenarios on virtual machine performance and their prediction through optimized artificial neural networks[J]. Journal of Systems and Software, 2011, 84(8): 1270-1291.
- [9] 郑鹏飞, 齐勇, 陈鹏飞. 软件老化的多元时间序列分析方法[J]. 计算机科学与探索, 2012(2): 33-41.
ZHENG P F, QI Y, CHEN P F. Multivariate time series analysis of software aging[J]. Journal of Frontiers of Computer Science & Technology, 2012(2): 33-41.
- [10] 林已杰, 赖清, 周敏. 基于 BP 神经网络和马尔可夫模型的服务器软件老化预测方法[J]. 西南师范大学学报(自然科学版), 2011, 36(4): 193-197.
LIN Y J, LAI Q, ZHOU M. A study on software aging forecasting of web server in BP neural network methods & Markov model methods[J]. Journal of Southwest China Normal University(Natural Science Edition), 2011, 36(4): 193-197.
- [11] ABU A I A S, MAGHARI A Y A. Forecasting groundwater production and rain amounts using ARIMA-hybrid ARIMA: case study of deir El-Balah City in GAZA[C]// 2018 International Conference on Promising Electronic Technologies. Piscataway: IEEE Press, 2018: 135-140.
- [12] YANG H, PAN Z, TAO Q. Online learning for vector autoregressive moving-average time series prediction[J]. Neurocomputing, 2018, 315: 9-17.
- [13] TRIANTAFYLLOPOULOS K, SHAKANDLI M, CAMPBELL M. Count time series prediction using particle filters[J]. Quality and Reliability Engineering International, 2019, 35(4): 1445-1449.
- [14] SAOUD L S, GHORBANI R. Metacognitive octonion-valued neural networks as they relate to time series analysis[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(2): 539-548.
- [15] ESKANDARPOUR R, KHODAEI A. Leveraging accuracy-uncertainty tradeoff in SVM to achieve highly accurate outage predictions[J]. IEEE Transactions on Power Systems, 2017, 33(1): 1139-1141.
- [16] LAMOURINE M. OpenStack[J]. Login: the Magazine of USENIX & SAGE, 2014, 39: 17-20.
- [17] ALBAROODI H, MANICKAM S, SINGH P. Critical review of OpenStack security: issues and weaknesses[J]. Journal of Computer Science, 2014, 10(1): 1032.
- [18] HORNIK K. Approximation capabilities of multilayer feedforward networks[J]. Neural Networks, 1991, 4(2): 251-257.
- [19] 刘思峰, 蔡华, 杨英杰, 等. 灰色关联分析模型研究进展[J]. 系统工程理论与实践, 2013(8): 2041-2046.
LIU S F, CAI H, YANG Y J, et al. Advance in grey incidence analysis modelling[J]. Systems Engineering-Theory & Practice, 2013(8): 2041-2046.
- [20] TORQUATO M, MACIEL P, ARAUJO J, et al. An approach to investigate aging symptoms and rejuvenation effectiveness on software systems[C]//2017 12th Iberian Conference on Information System and Technologies. Piscataway: IEEE Press, 2017: 1-6.
- [21] WIDIYANINGTYAS T, MULADI, QONITA A. Use of ARIMA method to predict the number of train passenger in Malang City[C]//2019 International Conference of Artificial Intelligence and Information Technology. Piscataway: IEEE Press, 2019: 359-364.
- [22] TOKGÖZ, ÜNAL G. A RNN based time series approach for forecasting turkish electricity load[C]//2018 26th Signal Processing and Communications Applications Conference. Piscataway: IEEE Press, 2018: 1-4.

[作者简介]



孟海宁(1979-),女,内蒙古乌海人,博士,西安理工大学副教授、硕士生导师,主要研究方向为云计算系统可靠性评估。

董新宇(1996-),男,陕西西安人,西安理工大学硕士生,主要研究方向为云计算系统性能预测。

石月开(1995-),男,陕西榆林人,西安理工大学硕士生,主要研究方向为云系统性能监控与故障诊断。

朱磊(1983-),男,陕西咸阳人,博士,西安理工大学讲师,主要研究方向为数据挖掘。

冯锴(1997-),男,内蒙古锡林浩特人,西安理工大学硕士生,主要研究方向为数据挖掘。

黑新宏(1976-),男,陕西延安人,博士,西安理工大学教授、博士生导师,主要研究方向为系统可靠性和安全性评估。