

# 一种基于综合调优的数据库性能趋势预测方法

王小玲<sup>1</sup>, 张小芳<sup>1,2</sup>, 李宁<sup>1,2</sup>, 韩承枫<sup>1,2</sup>, 袁祝平<sup>3</sup>, 高环宇<sup>3</sup>

(1.西北工业大学 计算机学院, 陕西 西安 710027;  
2.大数据存储与管理工业和信息化部重点实验室, 陕西 西安 710072;  
3.交通银行股份有限公司, 上海 310115)

**摘要:**云数据库智能运维中的重要应用场景之一是对监控采集的大量性能时序数据进行趋势预测。提出一种基于 Prophet 模型和 ARIMA 模型的综合调优智能趋势预测方法 AutoPA4DB (auto prophet and ARIMA for database)。该方法根据数据库性能监控数据的特征,进行了原始监控数据的预处理、预测模型自动调参和模型优化。采用加权的时序预测准确性度量 WMC (weighted MAPE coverage), 基于多个企业级数据库实例 (包含 10 种性能指标) 进行了实验验证。实验对比了 5 种不同时序模型的预测效果,结果表明在单调变化模式 (如磁盘使用量) 的数据中,文中提出的 AutoPA4DB 方法时序预测准确性最高;然而在震荡模式的数据中,预测效果不太稳定,例如内存使用率趋势预测效果较好,但数据库连接数趋势预测效果不理想。

**关键词:**智能运维;时序数据;Prophet 模型;ARIMA 模型;数据库性能监控

**中图分类号:**TP311.13

**文献标志码:**A

**文章编号:**1000-2758(2020)05-1030-08

近年来,智能运维<sup>[1-2]</sup>受到了工业界和学术界的广泛关注。智能运维是指在自动化运维的基础上增加一个基于机器学习的大脑,指挥监测系统采集大脑决策所需的数据,做出分析、决策并指挥自动化脚本去执行大脑的决策,从而达到运维系统的整体目标。智能运维的主要应用场景包括:趋势预测、异常检测、预警管理、故障处理以及智能推荐等。在数据库 (database, DB) 运维的智能化过程中,云数据库<sup>[3]</sup>作为数据管理领域的新型数据库发展迅速,积极推动着运维的智能化进程。

本文以云数据库智能运维中的性能时序数据变化趋势预测展开研究。时序数据是指按照时间顺序采集的数据序列。它通常是在相等间隔的时间段内,依照给定的采样率,对某种潜在过程进行观测的结果<sup>[4]</sup>。Jan 等<sup>[5]</sup>总结了传统时序预测的各种模型和方法,包括传统的差分自回归移动平均模型 (ARIMA),指数平滑模型等。ARIMA 模型<sup>[6]</sup>同大部分传统时序预测模型相同,一般先对非平稳序列

进行差分处理直到序列平稳,本质是适用于平稳序列的模型。建立 ARIMA 模型通常包括模型定阶,参数估计和模型检验 3 个步骤。Facebook 公司在 2018 年公开了其最新的时序预测框架 Prophet<sup>[7]</sup>,该模型是一个可分解的时间序列预测模型,包含趋势性、季节性和假期性 3 个主要组件。该模型对趋势性、周期性较强的数据预测效果较好,对节假日和突变点有很强的适应力,对时间序列的平稳性没有要求,易于使用,其形式化描述如公式(1)所示。

$$Y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (1)$$

式中:  $g(t)$  表示趋势函数,模拟时间序列值的非周期性变化;  $s(t)$  表示周期性变化 (如每周/年等的季节性);  $h(t)$  表示不定期假期的影响;最后的误差项表示不适用前 3 项的任何特殊变化。

云数据库监测的数据库实例指标通常包括磁盘使用量、内存使用率、CPU 使用率、数据库连接数、网络 IO 字节数等,可以通过预测这些性能指标在未来一段时间内 (如 1 个月内) 的趋势变化,帮助运维

收稿日期:2019-11-05

基金项目:国家自然科学基金(61732014,61672434)资助

作者简介:王小玲(1994—),女,西北工业大学硕士研究生,主要从事数据库智能运维研究。

通信作者:李宁(1978—),女,西北工业大学博士、副教授,主要从事软件库挖掘、数据库研究。

人员及时调整云资源,使得资源配置最优,有效节约运维成本。本文针对数据库运维性能指标时序数据提出了一种针对性更强的 AutoPA4DB 预测方法。该方法以 Prophet 算法和 ARIMA 算法为基础,针对数据库监控指标的数据特点进行了综合优化。本文在 6 个企业级数据库实例数据集上和 6 个竞赛数据库实例数据集上分别进行了实验验证,结果表明 AutoPA4DB 模型在磁盘使用量、内存使用率、CPU 使用率等部分性能指标趋势性预测中的预测准确度较高,且预测准确度高于优化前模型和其他对比模型。但在 TPS(每秒处理的事物数)及数据库连接数等指标中,预测效果并不理想。

# 1 性能趋势预测方法 AutoPA4DB

## 1.1 方法概述

图 1 描述了本文提出的基于 Prophet 和 ARIMA 模型的数据库性能指标综合趋势预测方法 AutoPA4DB 的基本框架。图中粗斜体部分为本文重点优化的部分。主要分为数据预处理、数据建模与预测以及动态调参优化三大部分。图 2 和图 3 展示了使用本方法得到的 2 种性能指标预测结果。

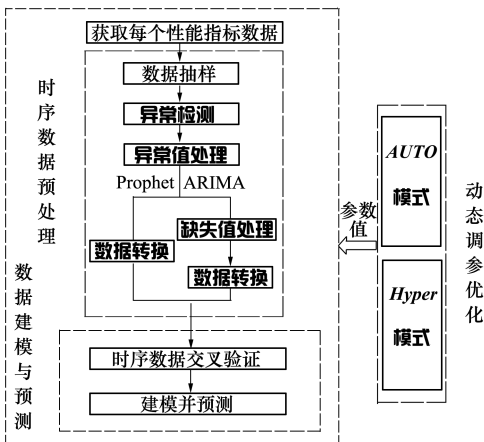



图 1 AutoPA4DB 框架图(粗体字部分为本文优化内容)



(深色点表示真实值,次深色点表示预测值,浅色点表示预测区间)  
图 2 磁盘使用量/GB 趋势预测图

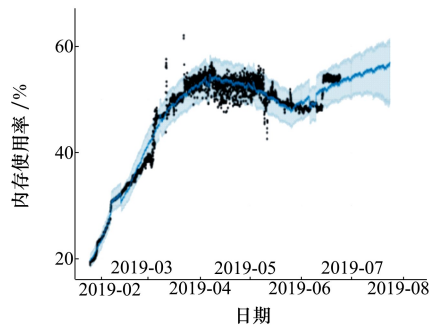


图 3 内存使用率/%趋势预测图

### 1.1.1 数据预处理

数据预处理过程包括数据抽样、异常检测<sup>[8]</sup>、异常值处理、缺失值处理以及数据变换。

#### 1) 数据抽样

由于各种数据库监测平台采集性能数据的时间间隔可能不同,本方法可按照统一的方式按指定时间间隔抽样,例如 1 分钟,30 分钟,60 分钟等。

#### 2) 异常检测与处理

异常值通常会改变 KPI 曲线的形状,进而影响趋势预测,因此需要检测并去除异常点。图 4 以 DS1 中的 CPU 使用率为例展示了异常值分布情况。本文利用常见的箱型图方法进行异常值检测,并将检测出的异常值设为缺失值。

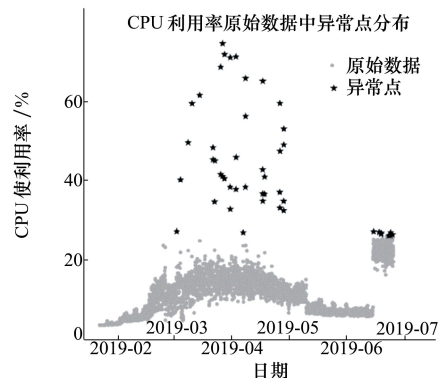


图 4 DS1 中 CPU 利用率异常点分布

#### 3) 缺失值处理

由于 Prophet 算法已经包含了关于缺失值的填充处理,本文仅在采用 ARIMA 方法时针对缺失值通过拉格朗日插值法进行填充。

#### 4) 数据变换

为了使数据更加平稳,本文采用对数变换的方法对原始数据进行变换。

由于不同的数据预处理方法以及各种预处理组

合对最终的预测准确度有一定的影响,本文的 Auto-PA4DB 中采用基于 1.1.3 小节的动态调参的思想对各种预处理组合进行了动态组合调优,具体每种预处理涉及的可调节参数参考第 3.2 小节。

### 1.1.2 数据建模与预测

在数据建模与预测中,首先分别基于 Prophet 模型和 ARIMA 模型进行建模。在建模过程中,针对数据库监控性能指标数据的特征对 Prophet 模型进行了优化(参见第 2 小节)。此外,为了提高预测模型度量的可靠性,本方法采用了与 Prophet 模型一致的时序交叉验证的方法,将多次时序交叉验证的模型准确性度量平均值作为整个模型的预测准确性。最后,基于自动调优得到的最优模型进行数据库性能指标数据的趋势预测。

### 1.1.3 动态调参优化

为了获得最优预测结果,机器学习中通常需要进行参数调优。常见的调参方式是网格搜索、随机搜索和贝叶斯搜索。网格搜索速度较慢,随机搜索虽然速度快,但是可能错过重要参数值,本方法使用了基于贝叶斯优化<sup>[9]</sup>的 Hyperopt 调参技术。该调参方法将待调参数以及其取值范围设定为参数空间,在参数空间中选择并组合,通过最小化损失函数寻找最佳参数组合。本文调参中的损失函数为公式(4)定义的预测准确性度量 WMC(公式中用  $W_{MC}$  表示)。当目标函数的返回值最小时,对应的各个参数值则为模型的最佳参数。

## 1.2 模型预测准确度评估

时序数据趋势预测模型的准确性度量通常包括均方误差(MSE)、均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)。由于 MAPE 的易理解性,本文采用加权的时序预测准确性作为预测模型的预测准确性度量标准。MAPE 在公式中采用  $E_{MAP}$  形式表示真实值与预测值之间的绝对误差占真实值的百分比,覆盖率  $C$  表示真实值落入预测值的上下界范围内的数据个数占总数据数的百分比。具体如公式(2)~(4)所示:

$$E_{MAP} = \frac{O_{observed_i} - P_{predicted_i}}{O_{observed_i}} \times \frac{100}{n} \quad (2)$$

式中:observed 表示观察值;predicted 表示预测值。 $E_{MAP}$  值越小,表示预测误差越小,模型越好。

$$C = \frac{n_i}{N} \times 100\%$$

$$n_i = \begin{cases} 1, & \text{if } O_{observed_i} \in [P_{predicted_l}, P_{predicted_u}] \\ 0, & \text{if } O_{observed_i} \notin [P_{predicted_l}, P_{predicted_u}] \end{cases} \quad (3)$$

式中:predicted<sub>l</sub> 表示预测值的下界;predicted<sub>u</sub> 表示预测值的上界; $N$  表示总数据点个数。 $C$  值越大,表示覆盖率越高,模型越好。

$$W_{MC} = w \times E_{MAP} + (1 - w) \times (1 - C) \quad (4)$$

式中: $w$  表示 MAPE 所占权重。由于对于预测模型而言,误差 MAPE 更加重要,因此本文中测试了  $w$  取值分别为 0.5, 0.6, 0.7, 0.8 的情况,结果表明为对本文所有实验数据, $w = 0.8$  时预测效果更符合预期。在应用于其他数据集时,可根据具体情况考虑  $w$  的取值。

## 2 预测模型优化

本部分面向数据库监控性能指标趋势预测的具体问题和具体数据特征,针对原始的 Prophet 模型和 ARIMA 模型进行了优化。

### 2.1 预测算法调参方法优化

由于资源限制,基于贝叶斯的自动调参迭代次数不能设定过大,因此仍然可能会遗漏某些重要的参数取值。为了解决该问题,本文提供了一种综合调参策略,将基于贝叶斯的自动调参 Hyper 模式与人工自定义调参 Auto 模式进行融合。

Hyper 模式表示基于贝叶斯的自动调参模式,可事先设定 AutoPA4DB 中的预处理参数以及预测模型的参数,以及每个参数的调参范围。Auto 模式是对 Hyper 模式的重要补充,可手动事先设定 Hyper 模式可能无法覆盖,但根据经验得出的重要参数组合,批量执行调参。AutoPA4DB 将综合 Hyper 模式与 Auto 模式的调优结果,依据目标函数选出最终的最优参数。

### 2.2 预测相关参数优化

在 Prophet 预测模型中,当趋势增长函数使用逻辑回归模型时,cap 参数可设定预测值的上限。本文针对不同影响因素的敏感性分析结果表明,cap 值对预测准确性影响较大,且与原始数据取值范围密切相关。为了使得该参数取值更加有效,在 Auto-PA4DB 中,每个数据库性能指标从其对应原始数据中自动获取 cap 范围。Hyper 模式中,cap 值的有效调参区间将设置为  $[0.8 * \max, 1.2 * \max]$ ,其中 max 表示原始数据中最大值。在 Auto 模式中,由于 cap

值只能设定为一个确定值,将设置  $cap = 1.2 * max$ 。

此外,在数据预处理和数据预测中,由于数据库监控指标的真实值一定是大于 0 的正数。当数据处理得到负数时,将强制设为 0.01。

### 3 实验设计

本文期望根据历史监控数据预测云数据库性能指标在未来短时间内(如 1 个月内)的变化趋势,以指导运维人员动态调整资源。

#### 3.1 实验数据集

实验中使用了某企业 2019/01/25-2019/06/25 的 6 个云数据库实例的性能指标监控数据和运维竞赛的 6 个数据库实例性能监控数据作为实验对象,如表 1 所示。

DS1 是企业真实数据集,包含 10 种指标,分别是磁盘使用量(GB),CPU 利用率(%),内存使用率(%),网络输入吞吐量(byte/s),网络输出吞吐量(byte/s),数据库总连接数(个数),当前活跃连接数(个数),IOPS(次数/秒),QPS(次数/秒),TPS(次

数/秒),每种指标 6 个实例。由于性能指标数据采集间隔设置为分钟级时对云数据库厂商的存储造成巨大压力,因此通常设定为按照小时粒度采集数据。

表 1 KPI 数据集描述

数据集名	KPI 个数	数据库实例数	采集时间间隔/min	持续时长/h	数据长度
DS1	10	6	60	3 600	3 693
DS2	1	6	1	6	360

为了同时验证 AutoPA4DB 方法在分钟级别采集的性能数据预测上的有效性,本文还使用一个运维竞赛提供的真实数据集 DS2 中的内存已用容量(GB)进行了实验验证。

图 5 和图 6 展示了 DS1 中部分性能指标数据分布图,图 7 展示了 DS2 中指标数据的分布图,由图可知每个 KPI 数据分布情况差异较大。根据原始数据分布规律,将指标分为 2 大类:有显著单调变化趋势,如磁盘使用量(GB);无显著单调变化趋势,有震荡变化,如内存使用率(%)等。




图 5 DS1 内存使用率(%) 原始数据分布图




图 6 DS2 内存已用容量(GB) 原始数据分布图

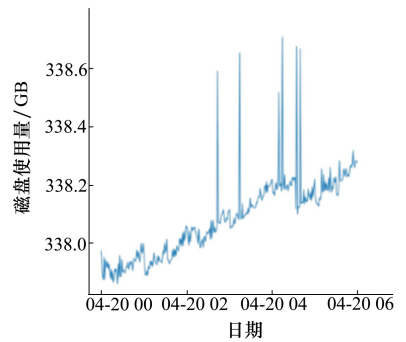


图 7 DS1 磁盘使用量(GB) 原始数据分布图

#### 3.2 自动调优参数及调参取值范围

本小节描述实验中自动调优的主要参数及其调参范围。表 2 列出了数据预处理的主要调优参数。此外,由于 Prophet 模型的默认参数通常不能获得最优预测,表 3 列出了 Prophet 模型的调优参数。

表 2 预处理调优参数

参数	含义	参数取值
last_day	训练数据天数	90,150
outlier	异常检测方法	boxplot, ksigma
missing	缺失值处理	remove, avg
transform	数据变换方式	none, log

表 3 Prophet 模型调优参数

参数	调参范围
growth	linear, logistic
changepoints	[ ] (默认值:25)
n_changepoints	[5,25] 步长:2
changepoint_range	0.8
yearly_seasonality	auto
weekly_seasonality	auto
daily_seasonality	auto
seasonality_mode	additive, multiplicative
holidays	holiday.csv
seasonality_prior_scale	[0.1,20] 步长:0.5

续表 3

参数	调参范围
holidays_prior_scale	[0.1, 20] 步长:0.5
changepoint_prior_scale	[0.1, 20] 步长:0.5
mcmc_samples	0
interval_width	0.8 或 0.95
uncertainty_samples	1 000 或 2 000

注:该表各参数的含义参考 Prophet 模型官方说明<sup>[7]</sup>。

### 3.3 时序交叉验证

本实验中采用 Prophet 算法中的时序交叉验证方法。DS1 根据需求设定每折测试集包含 30 天数据,训练集是测试集起始日期之前的所有数据。每折中的测试集向前回退 7 天,训练集随之改变,直到训练集仅包含整个数据集最初的 30 天数据为止。最终,经计算共进行 13 折交叉验证,即最终采用了 13 次的平均值作为该模型的预测准确性。DS2 设定方法同 DS1,表 4 是 DS1 和 DS2 交叉验证数据集设定。

表 4 DS1 和 DS2 交叉验证数据集设定

数据集名	交叉验证折数	初始训练集/h	测试集/h	测试集间隔/h
DS1	13	720	720	168
DS2	4	3	1	0.5

## 4 实验结果

由于篇幅限制,本文主要以 DS1 中磁盘使用量和内存使用率以及 DS2 的内存已用容量为代表进行实验结果的展示。

### 4.1 预测模型优化效果

图 8 以 DS1 中磁盘使用量为例,展示了 Prophet 模型在应用了 2.1 和 2.2 小节优化策略前后的效果对比。其中横轴表示 6 个不同的数据库实例,纵轴表示在预测时长为 30 天的情况下,磁盘使用量变化趋势预测的准确性 WMC。由图 8 可知,本文提出的优化策略使得在 Prophet 算法中,磁盘使用量的预测准确率平均提升了 9% 左右。其中数据预处理部分的优化提升了 2% 左右,预测模型优化提升了 7% 左右。图 9 以 DS2 中内存已用容量为例,展示了优化前后效果对比。纵轴表示在预测时长为 1 小时的情况下,内存已用容量的预测准确性 WMC。由图 9 可知,优化策略使得内存已用容量预测准确率平均提升了 8% 左右,其中预处理部分的优化提升了 2%

左右,预测模型优化提升了 6% 左右。




图 8 DS1 中模型优化前后磁盘使用量预测准确性对比图




图 9 DS2 中模型优化前后内存已用容量预测准确性对比图

### 4.2 不同预测模型对比

图 10 展示了 DS1 的 6 个数据库实例中磁盘使用量的预测结果,注意图 10 的 prophet 和 auto\_arma 是经过 AutoPA4DB 优化后的模型。同时参考论文<sup>[6,10]</sup>本文对比了 3 种常用的时序预测算法:基于指数平滑模型自动预测的 ets 算法,基于随机游走模型的 snaive 算法和基于 TBATS 模型的 tbats 算法。实验结果表明优化后的 Prophet 模型预测准确度最高,其中 MAPE 低于 5%,覆盖率在 95% 左右。




图 10 DS1 中磁盘使用量预测准确性对比图

对于内存使用率, CPU 使用率等震荡数据模式, AutoPA4DB 预测效果不稳定。在部分性能指标中表现较好, 如内存使用率, 部分指标中表现较差, 如数据库连接数。图 11 展示了不同预测算法的内存使用率预测准确性。由该图可知, 即使是预测效果较好的内存使用率, 也是在部分实例中表现较好, 部分实例中表现一般。




图 11 DS1 中内存使用率预测准确性对比图

表 5 DS2 内存已用容量不同预测模型的加权准确度 WMC

模型名称	实例 1	实例 2	实例 3	实例 4	实例 5	实例 6	均值
prophet	0.001 14	0.000 05	0.001 07	0.001 04	0.000 17	0.000 03	0.000 58
snaive	0.053 70	0.000 05	0.000 06	0.001 96	0.000 85	0.000 37	0.000 95
tbats	0.013 40	0.000 04	0.003 78	0.032 97	0.029 97	0.012 81	0.015 49
ets	0.023 15	0.000 04	0.003 17	0.031 13	0.079 90	0.012 99	0.025 06
auto_arima	0.004 07	0.000 04	0.002 04	0.002 85	0.034 95	0.003 36	0.007 89

对于内存已用容量, 如表 5 所示, 在其趋势预测结果中, AutoPA4DB 优化后的 prophet 模型的预测准确度 WMC 平均为 0.000 58, 远低于其他预测算法, 预测效果最好。

### 4.3 不同预测周期的对比

实验中建立预测模型后, 用每个模型分别预测了 7 天, 14 天, 21 天和 30 天的数据库性能数据, 图 12 以 DS1 中磁盘使用量为例, 展示了不同预测周期下的模型预测准确性。该图显示预测周期越短时, 趋势预测准确性越高。该结果也符合人们的认知常识。因此在实践中, 云数据库厂商可以仅提供较短周期内的预测结果给客户或供内部决策使用。




图 12 不同预测周期下 DS1 磁盘使用量预测准确性对比图

### 4.4 异常点和突变点分析

异常点是指原始数据中的明显离群点, 常会影响数据变化的整体规律, 通常在预处理阶段去除。变化点 (changepoint) 是指变化率有明显变化的突变点 (Prophet 模型在默认设置下会自动检测 25 个变化点)。为了防止异常点去除对突变点检测产生影响, 本小节用实验进行了验证。图 13 以 DS1 中实例 1 的 CPU 利用率展示了本算法中检测到的异常点和突变点。由图可知, 本算法的异常点检测基本准确, 且去除异常点对数据中的正常变化点检测没有影响。




图 13 DS1 中 CPU 利用率实例 1 的异常点与变化点分布图

### 4.5 算法消耗时间分析

本小节分析了 AutoPA4DB 算法耗时数据。表 4 以 DS1 中实例 1 的 CPU 使用率 (包含 3 595 条数据, 13 次交叉验证) 预测为例, 记录了每步处理的时间。实验计算机环境: 处理器 Inter (R) Core (TM) i7-9700K 八核 3.6GHz, 内存 16G。

表 6 AutoPA4DB 算法消耗时间

阶段	包含处理	时间/s
数据预处理	数据抽样, 异常值, 缺失值, 数据变化等处理	1.896
	模型拟合	1.006
Prophet 模型	模型交叉验证	85.985
	模型预测 (含画图)	10.889
ARIMA 模型	模型拟合	1.007
	模型交叉验证	36.813
	模型预测	1.206

从表 6 中数据可知, Prophet 模型的预测所需时间多于 ARIMA 模型, 但在 2 分钟之内可以完成, 属于可接受范围。整体 AutoPA4DB 的一次预测调优在 3 分钟之内完成。

### 5 结 论

本文针对云数据库运维监控获得的性能指标时序数据, 基于 Prophet 和 ARIMA 算法设计了一种综合趋势预测方法 AutoPA4DB。用实际企业数据 DS1 和运维竞赛数据 DS2 对数据库性能指标进行了趋势预测, 并与 *snaive*, *tbats*, *ets* 算法进行了对比, 主要结论如下:

1) AutoPA4DB 针对数据库性能数据进行了预测优化, 比原始 Prophet 模型预测准确度提高了约 9%, 其中预处理部分准确度提高了 2%, 预测模型优化准确度提高了 7%, 表明该模型优化效果明显。

2) AutoPA4DB 方法在单调变化模式的时序数据中预测准确度高, 以磁盘使用量 (GB) 为例, MAPE 误差在 2% 左右, 覆盖率在 95% 以上, 且优于其他对比模型。但在震荡模式的数据中预测效果不稳定, 部分指标预测较好, 部分指标预测极差。

本研究中还存在一些不足之处: 如异常检测方法应针对数据库性能时序数据有针对性的改进。另外, 实验数据虽然满足预测方法需求, 但是为了提高结果的可扩展性, 还应在数据量更大的数据集上测试。最后, 震荡模式数据中预测效果不稳定的问题将是我们后续研究的重点。

### 参考文献:

[1] DANG Y, LIN Q, HUANG P. AIOps: Real-World Challenges and Research Innovations[C]//Proceedings of the 41st International Conference on Software Engineering: Companion Proceedings, 2019

[2] 裴丹, 张圣林, 裴昶华, 等. 基于机器学习的智能运维[J]. 中国计算机学会通讯, 2017, 13(12): 68-72  
PEI Dan, ZHANG Shenglin, PEI Changhua, et al. Intelligent Operation and Maintenance Based on Machine Learning[J]. Communications of the CCF, 2017, 13(12): 68-72 (in Chinese)

[3] 林子雨, 赖永炫, 林琛, 等. 云数据库研究[J]. 软件学报, 2012, 23(5): 1148-1166  
LIN Ziyu, LAI Yongxuan, LIN Chen, et al. Research on Cloud Databases[J]. Journal of Software, 2012, 23(5): 1148-1166 (in Chinese)

[4] 原继东, 王志海. 时间序列的表示与分类算法综述[J]. 计算机科学, 2015, 42(3): 1-7  
YUAN Jidong, WANG Zhihai. Review of Time Series Representation and Classification Techniques[J]. Computer Science, 2015, 42(3): 1-7 (in Chinese)

[5] JAN G. DE Gooijer, ROB J. Hyndman. 25 Years of Time Series Forecasting[J]. International Journal of Forecasting, 2006, 22(3): 443-473

[6] 杨海民, 潘志松, 白玮. 时间序列预测方法综述[J]. 计算机科学, 2019, 46(1): 21-28  
YANG Haimin, PAN Zhisong, BAI Wei. Review of Time Series Prediction Methods[J]. Computer Science, 2019, 46(1): 21-28 (in Chinese)

[7] TAYLOR S J, LETHAM B. Forecasting at Scale[J]. The American Statistician, 2018, 72(1): 37-45

[8] 韩东明, 郭方舟, 潘嘉铨, 等. 面向时序数据异常检测的可视分析综述[J]. 计算机研究与发展, 2018, 55(9): 1843-1852

- HAN Dongming, GUO Fangzhou, Pan Jiacheng, et al. Visual Analysis for Anomaly Detection in Time-Series: a Survey[J]. Computer Research and Development, 2018, 55(9): 1843-1852 (in Chinese)
- [9] 崔佳旭,杨博. 贝叶斯优化方法和应用综述[J]. 软件学报,2018,29(10):3068-3090  
CUI Jiaxu, YANG Bo. Survey on Bayesian Aptimization Methodology and Applications[J]. Journal of Software, 2018, 29(10): 3068-3090 (in Chinese)
- [10] ROB J H, ANNE B K, RALPH D S, et al. A State Space Framework for Automatic Forecasting Using Exponential Smoothing Methods[J]. International Journal of Forecasting, 2002,18(3): 439-454

## A Time Series Prediction Approach Based on Hybrid Tuning for Database Performance Indicator in AIOps

WANG Xiaoling<sup>1</sup>, ZHANG Xiaofang<sup>1,2</sup>, LI Ning<sup>1,2</sup>, HAN Chengfeng<sup>1,2</sup>,  
YUAN Zhuping<sup>3</sup>, GAO Huanyu<sup>3</sup>

(1.School of Computer, Northwestern Polytechnical University, Xi'an 710072, China;  
2.Key Laboratory of Big Data Storage and Management, Ministry of Industry and Information Technology, Xi'an 710072, China;  
3.Bank of Communication, Shanghai 310115, China

**Abstract:** One of the most important applications of the intelligent operation and maintenance of a cloud database is its trend prediction of key performance indicators (KPI), such as disk use, memory use, etc. We propose a method named AutoPA4DB (Auto Prophet and ARIMA for Database) to predict the trend of the KPIs of the cloud database based on the Prophet model and the ARIMA model. Our AutoPA4DB method includes data preprocessing, model building, parameter tuning and optimization. We employ the weighted MAPE coverage to measure its accuracy and use 6 industrial datasets including 10 KPIs to compare the AutoPA4DB method with other three time-series trend prediction algorithms. The experimental results show that our AutoPA4DB method performs best in predicting monotonic variation data, e.g.disk use trend prediction. But it is unstable in predicting oscillatory variation data; for example, it is acceptable in memory use trend prediction but has poor accuracy in predicting the number of database connection trends.

**Keywords:** intelligent operation and maintenance; time series; prophet; ARIMA; database performance monitor