



(12) 发明专利

(10) 授权公告号 CN 113190429 B

(45) 授权公告日 2022. 07. 19

(21) 申请号 202110620824.9

G06N 3/08 (2006.01)

(22) 申请日 2021.06.03

(56) 对比文件

(65) 同一申请的已公布的文献号

US 2017364614 A1, 2017.12.21

申请公布号 CN 113190429 A

WO 2020010717 A1, 2020.01.16

(43) 申请公布日 2021.07.30

审查员 张彪

(73) 专利权人 河北师范大学

地址 050024 河北省石家庄市南二环东路
20号

(72) 发明人 刘京 王余 田亮 陈栋

(74) 专利代理机构 河北国维致远知识产权代理

有限公司 13137

专利代理师 彭竞驰

(51) Int. Cl.

G06F 11/34 (2006.01)

G06N 3/04 (2006.01)

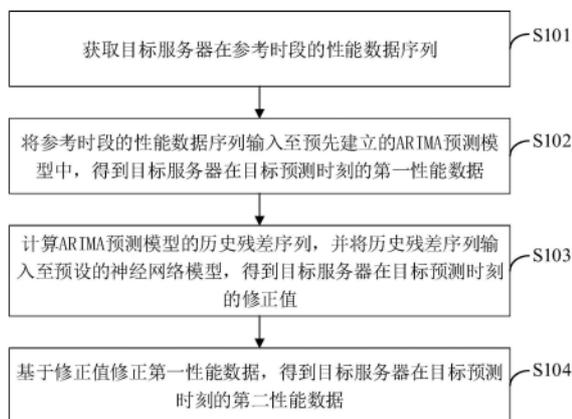
权利要求书2页 说明书12页 附图5页

(54) 发明名称

服务器性能预测方法、装置及终端设备

(57) 摘要

本发明适用于计算机技术领域,提供了一种服务器性能预测方法、装置及终端设备,该方法包括:获取目标服务器在参考时段的性能数据序列;将参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据;计算ARIMA预测模型的历史残差序列,并将历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值;基于修正值修正第一性能数据,得到目标服务器在目标预测时刻的第二性能数据。本发明能够提高对服务器性能预测的预测准确率。



1. 一种服务器性能预测方法,其特征在于,包括:

获取目标服务器在参考时段的性能数据序列;

将所述参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据;

计算所述ARIMA预测模型的历史残差序列,并将所述历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值;

基于所述修正值修正所述第一性能数据,得到目标服务器在目标预测时刻的第二性能数据;

所述ARIMA预测模型的建立方法包括:

获取目标服务器在历史时段的性能数据序列;

根据所述历史时段的性能数据序列,建立时间序列预测子模型和误差预测子模型,得到所述ARIMA预测模型;其中,所述时间序列预测子模型用于预测目标服务器在目标预测时刻的第一初始性能数据,所述误差预测子模型用于预测所述第一初始性能数据的误差,并根据所述误差对所述第一初始性能数据进行矫正,得到目标服务器在目标预测时刻的第一性能数据;

根据所述历史时段的性能数据序列建立误差预测子模型,包括:

S1021、根据所述时间序列预测子模型计算所述历史时段对应的性能预测数据,根据所述历史时段对应的性能预测数据、所述历史时段的性能数据序列计算所述时间序列预测子模型的真实预测误差;

S1022、根据所述真实预测误差建立误差预测子模型;

S1023、基于所述误差预测子模型对所述历史时段对应的性能预测数据进行矫正,并根据矫正后所述历史时段对应的性能预测数据、所述历史时段的性能数据序列,计算矫正后所述历史时段对应的性能预测数据的残差;

S1024:若矫正后所述历史时段对应的性能预测数据的残差在预设残差范围内,则将当前的误差预测子模型作为建立的误差预测子模型;若矫正后所述历史时段对应的性能预测值的残差不在预设残差范围内,则基于矫正后所述目标服务器的性能预测值的残差,建立残差预测子模型,根据 $E(t) = E_1(t) + E_2(t)$ 建立新的误差预测子模型,其中, $E(t)$ 为新的误差预测子模型, $E_1(t)$ 为当前的误差预测子模型, $E_2(t)$ 为残差预测子模型,并返回执行步骤S1023-S1024。

2. 如权利要求1所述的服务器性能预测方法,其特征在于,根据所述真实预测误差建立的误差预测子模型包括:

$$x_t = \frac{1}{t-1}(x_1 + x_2 + x_3 + \dots + x_{t-1})$$

式中, t 为预测时刻, x_t 为预测时刻所述时间序列预测子模型的预测误差。

3. 如权利要求1所述的服务器性能预测方法,其特征在于,基于所述误差预测子模型对所述历史时段对应的性能预测数据进行矫正,包括:

基于所述误差预测子模型,预测所述历史时段对应的预测误差;

根据预测的所述历史时段对应的预测误差,对所述历史时段对应的性能预测数据进行矫正。

4. 如权利要求1-3任一项所述的服务器性能预测方法,其特征在于,基于以下公式修正所述第一性能数据:

$$P(t) = P_0(t) + c(t)$$

式中, $P(t)$ 为目标预测时刻的第二性能数据, $P_0(t)$ 为目标预测时刻的第一性能数据, $c(t)$ 为目标预测时刻的修正值。

5. 一种服务器性能预测装置,其特征在于,包括:

获取模块,用于获取目标服务器在参考时段的性能数据序列;

第一预测模块,用于将所述参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据;

第二预测模块,用于计算所述ARIMA预测模型的历史残差序列,并将所述历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值;

修正模块,用于基于所述修正值修正所述第一性能数据,得到目标服务器在目标预测时刻的第二性能数据;

所述第一预测模块还用于:

获取目标服务器在历史时段的性能数据序列;

根据所述历史时段的性能数据序列,建立时间序列预测子模型和误差预测子模型,得到所述ARIMA预测模型;其中,所述时间序列预测子模型用于预测目标服务器在目标预测时刻的第一初始性能数据,所述误差预测子模型用于预测所述第一初始性能数据的误差,并根据所述误差对所述第一初始性能数据进行矫正,得到目标服务器在目标预测时刻的第一性能数据;

根据所述历史时段的性能数据序列建立误差预测子模型,包括:

S1021、根据所述时间序列预测子模型计算所述历史时段对应的性能预测数据,根据所述历史时段对应的性能预测数据、所述历史时段的性能数据序列计算所述时间序列预测子模型的真实预测误差;

S1022、根据所述真实预测误差建立误差预测子模型;

S1023、基于所述误差预测子模型对所述历史时段对应的性能预测数据进行矫正,并根据矫正后所述历史时段对应的性能预测数据、所述历史时段的性能数据序列,计算矫正后所述历史时段对应的性能预测数据的残差;

S1024:若矫正后所述历史时段对应的性能预测数据的残差在预设残差范围内,则将当前的误差预测子模型作为建立的误差预测子模型;若矫正后所述历史时段对应的性能预测值的残差不在预设残差范围内,则基于矫正后所述目标服务器的性能预测值的残差,建立残差预测子模型,根据 $E(t) = E_1(t) + E_2(t)$ 建立新的误差预测子模型,其中, $E(t)$ 为新的误差预测子模型, $E_1(t)$ 为当前的误差预测子模型, $E_2(t)$ 为残差预测子模型,并返回执行步骤S1023-S1024。

6. 一种终端设备,包括存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,其特征在于,所述处理器执行所述计算机程序时实现如权利要求1至4任一项所述方法的步骤。

7. 一种计算机可读存储介质,所述计算机可读存储介质存储有计算机程序,其特征在于,所述计算机程序被处理器执行时实现如权利要求1至4任一项所述方法的步骤。

服务器性能预测方法、装置及终端设备

技术领域

[0001] 本发明属于计算机技术领域,尤其涉及一种服务器性能预测方法、装置及终端设备。

背景技术

[0002] 服务器性能是服务器能否正常运行的重要参考指标,当性能数据过高时,服务器会变得卡顿导致无法正常工作。

[0003] 准确预测服务器的性能,能够对服务器故障进行预警,以提前做好相应的解决方案,保障服务器正常运行。然而,由于服务器性能数据具有线性和非线性拟合的特点,现有技术中的服务器性能预测方法无法对服务器性能数据的线性特征和非线性特征全部提取进行分析,预测准确率较低。

发明内容

[0004] 有鉴于此,本发明实施例提供了一种服务器性能预测方法、装置及终端设备,以提高对服务器性能预测的预测准确率。

[0005] 本发明实施例的第一方面提供了一种服务器性能预测方法,包括:

[0006] 获取目标服务器在参考时段的性能数据序列;

[0007] 将参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据;

[0008] 计算ARIMA预测模型的历史残差序列,并将历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值;

[0009] 基于修正值修正第一性能数据,得到目标服务器在目标预测时刻的第二性能数据。

[0010] 本发明实施例的第二方面提供了一种服务器性能预测装置,包括:

[0011] 获取模块,用于获取目标服务器在参考时段的性能数据序列;

[0012] 第一预测模块,用于将参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据;

[0013] 第二预测模块,用于计算ARIMA预测模型的历史残差序列,并将历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值;

[0014] 修正模块,用于基于修正值修正第一性能数据,得到目标服务器在目标预测时刻的第二性能数据。

[0015] 本发明实施例的第三方面提供了一种终端设备,包括存储器、处理器以及存储在存储器中并可在处理器上运行的计算机程序,处理器执行计算机程序时实现如上述服务器性能预测方法的步骤。

[0016] 本发明实施例的第四方面提供了一种计算机可读存储介质,计算机可读存储介质存储有计算机程序,计算机程序被处理器执行时实现如上述服务器性能预测方法的步骤。

[0017] 本发明实施例与现有技术相比存在的有益效果是：

[0018] 本发明实施例通过ARIMA预测模型来预测目标服务器在目标预测时刻的第一性能数据,然后将ARIMA预测模型的历史残差序列输入到神经网络预测模型中来预测目标服务器在目标预测时刻的修正值,根据修正值对第一性能数据进行修正,得到最终的目标预测时刻的第二性能数据。本发明利用ARIMA预测模型对线性数据具有较好的处理能力、神经网络预测模型对非线性数据具有较好的处理能力的特点,通过将ARIMA预测模型和神经网络预测模型组合进行预测的方式,能够对服务器性能数据的线性特征和非线性特征进行综合分析,提高了预测准确率。

附图说明

[0019] 为了更清楚地说明本发明实施例中的技术方案,下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动性的前提下,还可以根据这些附图获得其他的附图。

[0020] 图1是本发明实施例提供的服务器性能预测方法的实现流程示意图；

[0021] 图2是本发明实施例提供的传统ARIMA预测模型的示意图；

[0022] 图3是本发明实施例提供的改进ARIMA预测模型的示意图；

[0023] 图4是本发明实施例提供的服务器性能预测方法的整体流程示意图；

[0024] 图5是本发明实施例提供的服务器性能预测装置的结构示意图；

[0025] 图6是本发明实施例提供的终端设备的结构示意图。

具体实施方式

[0026] 以下描述中,为了说明而不是为了限定,提出了诸如特定系统结构、技术之类的具体细节,以便透彻理解本发明实施例。然而,本领域的技术人员应当清楚,在没有这些具体细节的其它实施例中也可以实现本发明。在其它情况中,省略对众所周知的系统、装置、电路以及方法的详细说明,以免不必要的细节妨碍本发明的描述。

[0027] 为了说明本发明所述的技术方案,下面通过具体实施例来进行说明。

[0028] 本发明实施例提供了一种服务器性能预测方法,参照图1所示,该方法包括以下步骤：

[0029] 步骤S101、获取目标服务器在参考时段的性能数据序列。

[0030] 在本发明实施例中,参考时段可以为目标预测时刻前某一时刻值至目标预测时刻之间的时段,通过将距离目标预测时刻比较近的服务器性能数据序列作为预测的依据,能够提高预测准确率。

[0031] 步骤S102、将参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据。

[0032] 可选的,作为一种可能的实施方式,ARIMA预测模型的建立方法可以详述为：

[0033] 获取目标服务器在历史时段的性能数据序列；

[0034] 根据历史时段的性能数据序列,建立时间序列预测子模型和误差预测子模型,得到ARIMA预测模型；其中,时间序列预测子模型用于预测目标服务器在目标预测时刻的第一

初始性能数据,误差预测子模型用于预测第一初始性能数据的误差,并根据误差对第一初始性能数据进行矫正,得到目标服务器在目标预测时刻的第一性能数据。

[0035] 在本发明实施例中,考虑到传统的ARIMA预测模型适用于线性数据预测,对非线性数据的预测效果不好。本发明对传统的ARIMA预测模型进行了改进,即在传统ARIMA预测模型建立的时间序列预测子模型的基础上,还建立了误差预测子模型,根据误差预测子模型能够对时间序列预测子模型的预测结果进行进一步修正,提高了ARIMA预测模型的预测准确率。

[0036] 可选的,作为一种可能的实施方式,本发明实施例中的时间序列预测子模型及其建立过程如下:

[0037] 时间序列预测子模型可以分为三类,即自回归模型(AR模型)、移动平均模型(MA模型)和自回归移动平均模型(ARMA模型)。

[0038] (1) AR模型

[0039] AR模型的思想是通过时间序列过去若干时刻的序列值的线性组合来描述未来某时刻的序列值。该模型要求数据是平稳的,因此AR模型属于平稳时间序列模型,模型公式如下:

$$[0040] \quad y_t = \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + \varepsilon_t$$

[0041] 这个模型叫做AR(p)模型,其中, $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_p$ 表示自回归的系数, ε_t 表示随机干扰序列,它是均值为0,方差为 σ^2 的白噪声序列。

[0042] (2) MA模型

[0043] MA模型的基本思想是根据时间序列资料、逐项推移,依次计算包含一定项数的序时平均值,以反映长期趋势,其也属于平稳时间序列模型。

[0044] 模型公式如下:

$$[0045] \quad y_t = \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q}$$

[0046] 这个模型叫做MA(q)模型,其中, $\beta_1, \beta_2, \dots, \beta_q$ 是移动平均系数, $\{\varepsilon_t\}$ 是不同时期的随机干扰项序列。

[0047] (3) ARMA模型

[0048] ARMA模型由自回归模型和移动平均模型组成,模型公式如下:

$$[0049] \quad x_t = a_0 + a_1 x_{t-1} + a_2 x_{t-2} + \dots + a_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

[0050] 这个模型叫做ARMA(p,q),其中,p和 $a_0, a_1, a_2, \dots, a_p$ 分别表示自回归的阶数和系数,q和 $\theta_1, \theta_2, \theta_3, \dots, \theta_q$ 分别表示移动平均的阶数和系数。

[0051] 参照图2所示,ARIMA预测模型建立时间序列预测子模型的过程包括以下步骤:

[0052] (1) 对性能数据序列进行平稳性检验,若序列不平稳,则对性能数据序列进行差分运算直至平稳;

[0053] (2) 对平稳序列进行白噪声检验,若序列为白噪声序列,则表明序列无规律性,分析结束;

[0054] (3) 若序列不是白噪声序列,则通过建立序列的ACF(自相关函数)和PACF(偏自相关函数)图来对模型进行识别和定阶。其中,识别规则为:当ACF拖尾、PACF截尾时,则建立AR(p)模型;当ACF截尾、PACF拖尾时,建立MA(q)模型;当ACF和PACF均拖尾时,建立ARMA(p,q)模型。

[0055] (4) 通常情况下会得到多个模型,即多个p值和q值,可以采用BIC准则选取最优模型,即测试p和q的不同组合,选择最佳的模型参数。

[0056] (5) 检验最优模型的残差序列是否为纯随机序列,即对残差序列进行白噪声检验,若序列为白噪声则说明模型符合要求,模型建立完成。

[0057] 可选的,作为一种可能的实施方式,根据历史时段的性能数据序列建立误差预测子模型,可以详述为:

[0058] S1021、根据时间序列预测子模型计算历史时段对应的性能预测数据,根据历史时段对应的性能预测数据、历史时段的性能数据序列计算时间序列预测子模型的真实预测误差;

[0059] S1022、根据真实预测误差建立误差预测子模型;

[0060] S1023、基于误差预测子模型对历史时段对应的性能预测数据进行矫正,并根据矫正后历史时段对应的性能预测数据、历史时段的性能数据序列,计算矫正后历史时段对应的性能预测数据的残差;

[0061] S1024:若矫正后历史时段对应的性能预测数据的残差在预设残差范围内,则将当前的误差预测子模型作为建立的误差预测子模型;若矫正后历史时段对应的性能预测值的残差不在预设残差范围内,则基于矫正后历史时段对应的性能预测数据的残差建立新的误差预测子模型,并返回执行步骤S1023。

[0062] 可选的,作为一种可能的实施方式,根据真实预测误差建立的误差预测子模型为:

$$[0063] \quad x_t = \frac{1}{t-1}(x_1 + x_2 + x_3 \dots + x_{t-1})$$

[0064] 式中,t为预测时刻, x_t 为预测时刻时间序列预测子模型的预测误差。

[0065] 可选的,作为一种可能的实施方式,基于误差预测子模型对历史时段对应的性能预测数据进行矫正,可以详述为:

[0066] 基于误差预测子模型,预测历史时段对应的预测误差;

[0067] 根据预测的历史时段对应的预测误差,对历史时段对应的性能预测数据进行矫正。

[0068] 可选的,作为一种可能的实施方式,基于矫正后历史时段对应的性能预测数据的残差建立新的误差预测子模型,可以详述为:

[0069] 基于矫正后目标服务器的性能预测值的残差,建立残差预测子模型;

[0070] 根据 $E(t) = E_1(t) + E_2(t)$ 建立新的误差预测子模型,其中, $E(t)$ 为新的误差预测子模型, $E_1(t)$ 为当前的误差预测子模型, $E_2(t)$ 为残差预测子模型。

[0071] 在本发明实施例中,通过建立误差预测子模型并不断对模型进行更新,最终输出预测精度满足要求的误差预测子模型。其中,精度评价可以采用平均绝对误差(Mean Absolute Error,MAE)、均方误差(Mean Squared Error,MSE)、均方根误差(Root Mean Squared Error, RMSE)来实现,不仅能够提高预测准确度,而且将传统的ARIMA模型转变为线性与非线性序列均可预测的模型。

$$[0072] \quad \text{平均绝对误差公式为: } MAE(y, \hat{y}) = \frac{1}{n} \left(\sum_{i=1}^n |y_i - \hat{y}_i| \right)$$

[0073] 均方误差公式为： $MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$

[0074] 均方根误差公式为： $RMSE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$

[0075] 其中， y_i 和 \hat{y}_i 分别代表真实值和预测值， n 代表个数，且MAE、MSE、RMSE的值越小，说明预测值越准确。

[0076] 相比于传统的ARIMA预测模型，本发明实施例中由时间序列预测子模型、误差预测子模型组合成的改进ARIMA预测模型能够更好的对非线性数据进行预测，提高预测精度。

[0077] 本发明实施例改进的ARIMA预测模型的建立过程如图3所示。

[0078] 步骤S103、计算ARIMA预测模型的历史残差序列，并将历史残差序列输入至预设的神经网络模型，得到目标服务器在目标预测时刻的修正值。

[0079] 在本发明实施例中，ARIMA预测模型的预测值与实际值之间有一定的残差，即改进的ARIMA预测模型没有完全提取数据的非线性特征。可以将ARIMA预测模型的残差序列输入至BP神经网络预测模型中，预测目标预测时刻的残差，即目标预测时刻的修正值，对目标预测时刻的性能预测值进行修正，利用神经网络模型的非线性拟合能力拟合服务器性能数据可能存在的非线性因素，提高预测的准确率。

[0080] 步骤S104、基于修正值修正第一性能数据，得到目标服务器在目标预测时刻的第二性能数据。

[0081] 可选的，作为一种可能的实施方式，基于以下公式修正第一性能数据：

[0082] $P(t) = P_0(t) + c(t)$

[0083] 式中， $P(t)$ 为目标预测时刻的第二性能数据， $P_0(t)$ 为目标预测时刻的第一性能数据， $c(t)$ 为目标预测时刻的修正值。

[0084] 本发明实施例提供的服务器性能预测方法的整体流程可以参考图4所示。本发明实施例通过ARIMA预测模型来预测目标服务器在目标预测时刻的第一性能数据，然后将ARIMA预测模型的历史残差序列输入到神经网络预测模型中来预测目标服务器在目标预测时刻的修正值，根据修正值对第一性能数据进行修正，得到最终的目标预测时刻的第二性能数据。本发明通过将ARIMA预测模型和神经网络预测模型组合进行预测的方式，能够对服务器性能数据的线性特征和非线性特征进行综合分析，提高了预测准确率。

[0085] 以下，通过示例验证本发明实施例提供的服务器性能预测方法的可行性。

[0086] 采集2020年12月2日0时0分-23时50分服务器的CPU、内存、网络带宽使用率三种数据，采集频率为1次/10分钟，24小时内每种数据各采集到144条，分别用来12月3日0时0分-0时50分的6条数据。

[0087] (1) CPU使用率预测

[0088] 对采集的CPU使用率数据绘制时间序列图进行平稳性检验，发现CPU使用率数据在增长过程中呈现波动趋势，是不平稳的，因此需要进行差分处理，阶数 d 取1。根据差分后CPU使用率的ACF图和PACF图，确定ACF拖尾，PACF5阶截尾，经过模型识别和优化后选择ARIMA(2,1,0)模型，经判断ARIMA(2,1,0)模型的残差序列是白噪声序列， p 值为0.729，显著大于0.05的检验水平，模型通过检验，ARIMA(2,1,0)模型即建立的时间序列预测子模型。接下来

对CPU使用率数据建立误差预测子模型,建立一次误差预测子模型后即达到精度。

[0089] 传统ARIMA预测模型的预测结果如表1所示,改进ARIMA预测模型的预测结果如表2所示,通过对比评价指标,可以看到本发明实施例提供的改进ARIMA预测模型的预测精度更高,且MAE值为3.83,小于预先设定的误差精度指标4.0,达到了误差精度要求。

[0090] 表1传统ARIMA预测模型预测结果

	时间	真实值	M 模型预测值	绝对误差	相对误差
[0091]	0 时 0 分	35	28	7	20%
	0 时 10 分	30	32	2	7%
	0 时 20 分	38	30	8	21%
	0 时 30 分	43	39	4	9%
	0 时 40 分	35	40	5	14%
	0 时 50 分	45	38	7	16%
	评价指标		值		
	MAE	5.50			
	MSE	34.50			
	RMSE	5.87			

[0092] 表2改进ARIMA预测模型预测结果

	真实值	真实值	第一次误差调整后预测值	绝对误差	相对误差
[0093]	0 时 0 分	35	30	5	14%
	0 时 10 分	30	28	2	7%
	0 时 20 分	38	35	3	8%
	0 时 30 分	43	40	3	7%
	0 时 40 分	35	41	6	17%
	0 时 50 分	45	41	4	9%
	评价指标		值		
	MAE	3.83			
	MSE	16.50			
	RMSE	4.06			

[0094] (2) 内存使用率预测

[0095] 对采集的内存使用率数据绘制时间序列图进行平稳性检验,发现内存使用率数据是不平稳的,因此需要进行差分处理,阶数d取1。根据差分后内存使用率的ACF图和PACF图,确定ACF、PACF均拖尾, $P=5, q=1$ 。经过模型识别和优化后选择ARIMA(1,1,1)模型,经判断ARIMA(1,1,1)模型的残差序列是白噪声序列,p值为0.378,显著大于0.05的检验水平模型,通过检验,ARIMA(1,1,1)模型即建立的时间序列预测子模型。接下来对内存使用率数据建立误差预测子模型,建立两次误差预测子模型后达到精度。

[0096] 传统ARIMA预测模型的预测结果如表3所示,改进ARIMA预测模型的预测结果如表4所示,通过对比评价指标,可以看到本发明实施例提供的改进ARIMA预测模型的预测精度更高,且MAE值为3.00,小于预先设定的误差精度指标4.0,达到误差精度要求。

[0097] 表3传统ARIMA预测模型预测结果

	时间	真实值	M 模型预测值	绝对误差	相对误差
[0098]	0 时 0 分	48	42	6	13%
	0 时 10 分	35	28	7	20%
	0 时 20 分	40	31	9	23%
	0 时 30 分	36	45	9	25%
	0 时 40 分	37	42	5	14%
	0 时 50 分	39	45	6	15%
	评价指标		值		
	MAE	7.00			
	MSE	51.33			
	RMSE	7.16			

[0099] 表4改进ARIMA预测模型预测结果

	时间	真实值	第二次误差调整后预测值	绝对误差	相对误差
[0100]	0 时 0 分	48	45	3	6%
	0 时 10 分	35	32	3	9%
	0 时 20 分	40	38	2	5%
	0 时 30 分	36	40	4	11%
	0 时 40 分	37	41	4	11%
	0 时 50 分	39	41	2	5%
	评价指标		值		
	MAE	3.00			
	MSE	9.67			
	RMSE	3.11			

[0101] (3) 网络带宽使用率预测

[0102] 对采集的网络带宽使用率数据绘制时间序列图进行平稳性检验,发现网络带宽使用率数据是不平稳的,因此需要进行差分处理,阶数d取1。根据差分后内存使用率的ACF图和PACF图,确定ACF、PACF均拖尾, $P=1, q=1, 2, 3$ 。经过模型识别和优化后选择ARIMA(1, 1, 1)模型,经判断ARIMA(1, 1, 1)模型的残差序列是白噪声序列,p值为0.844,显著大于0.05的检验水平,模型通过检验,ARIMA(1, 1, 1)模型即建立的时间序列预测子模型,接下来对网络带宽使用率数据建立误差预测子模型,建立两次误差预测子模型后达到精度。

[0103] 传统ARIMA预测模型的预测结果如表5所示,改进ARIMA预测模型的预测结果如表6所示,通过对比评价指标,可以看到本发明实施例提供的改进ARIMA预测模型的预测精度更高,且MAE值为3.17,小于预先设定的误差精度指标4.0,达到误差精度要求。

[0104] 表5传统ARIMA预测模型预测结果

	时间	真实值	M 模型预测值	绝对误差	相对误差
[0105]	0 时 0 分	42	50	8	19%
	0 时 10 分	55	50	5	9%
	0 时 20 分	58	50	8	14%
	0 时 30 分	52	58	6	12%
	0 时 40 分	35	41	6	17%
	0 时 50 分	54	55	1	2%
	评价指标	值			
	MAE	5.67			
	MSE	37.67			
	RMSE	6.14			

[0106] 表6改进ARIMA预测模型预测结果

	时间	真实值	第二次误差调整后预测值	绝对误差	相对误差
[0107]	0 时 0 分	42	45	3	7%
	0 时 10 分	55	52	3	5%
	0 时 20 分	58	56	2	3%
	0 时 30 分	52	56	4	8%
	0 时 40 分	35	31	4	11%
	0 时 50 分	54	57	3	6%
	评价指标	值			
	MAE	3.17			
	MSE	10.50			
	RMSE	3.24			

[0108] 可见,发明实施例提供的改进ARIMA预测模型,对非线性数据也有很好的预测能力,提高了预测精度。虽然改进ARIMA预测模型预测准确度有了很大的提高,但是对于服务器性能数据的非线性特征仍然没有全部提取出来,对此,通过增加BP神经网络预测模型,对服务器性能数据的非线性特征进行分析,即将改进ARIMA预测模型的历史残差序列输入到BP神经网络预测模型进行预测,得到修正值,并根据修正值对改进ARIMA预测模型的预测结果进行修正。

[0109] 最终得到改进后的ARIMA-BP预测模型预测的CPU使用率、内存使用率、网络带宽使用率的评价指标,并与传统ARIMA、改进后的ARIMA预测模型的评价指标进行对比,如表7、表8、表9所示。

[0110] 表7 CPU使用率比较分析

	评价指标	传统 ARIMA	改进后的 ARIMA	改进后的 ARIMA-BP
[0111]	MAE	5.50	3.83	2.17
	MSE	34.50	16.50	5.50
	RMSE	5.87	4.06	2.35

[0112] 表8内存使用率比较分析

	评价指标	传统 ARIMA	改进后的 ARIMA	改进后的 ARIMA-BP
[0113]	MAE	7.00	3.00	2.00
	MSE	51.33	9.67	4.67
	RMSE	7.16	3.11	2.16

[0114] 表9网络带宽使用率比较分析

	评价指标	传统 ARIMA	改进后的 ARIMA	改进后的 ARIMA-BP
[0115]	MAE	5.67	3.17	2.67
	MSE	37.67	10.50	8.00
	RMSE	6.14	3.24	2.83

[0116] 由表7、表8、表9可以看出,通过BP神经网络预测模型对改进ARIMA预测模型的预测结果进行修正后,预测准确率得到了进一步提升。

[0117] 应理解,上述实施例中各步骤的序号的大小并不意味着执行顺序的先后,各过程的执行顺序应以其功能和内在逻辑确定,而不应对本发明实施例的实施过程构成任何限定。

[0118] 本发明实施例的还提供了一种服务器性能预测装置,如图5所示,该装置50包括:

[0119] 获取模块51,用于获取目标服务器在参考时段的性能数据序列。

[0120] 第一预测模块52,用于将参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据。

[0121] 第二预测模块53,用于计算ARIMA预测模型的历史残差序列,并将历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值。

[0122] 修正模块54,用于基于修正值修正第一性能数据,得到目标服务器在目标预测时刻的第二性能数据。

[0123] 可选的,作为一种可能的实施方式,第一预测模块52用于:

[0124] 获取目标服务器在历史时段的性能数据序列;

[0125] 根据历史时段的性能数据序列,建立时间序列预测子模型和误差预测子模型,得到ARIMA预测模型;其中,时间序列预测子模型用于预测目标服务器在目标预测时刻的第一初始性能数据,误差预测子模型用于预测第一初始性能数据的误差,并根据误差对第一初始性能数据进行矫正,得到目标服务器在目标预测时刻的第一性能数据。

[0126] 可选的,作为一种可能的实施方式,第一预测模块52用于预先建立ARIMA预测模型,预先建立ARIMA预测模型的步骤如下:

[0127] S11021、根据时间序列预测子模型计算历史时段对应的性能预测数据,根据历史时段对应的性能预测数据、历史时段的性能数据序列计算时间序列预测子模型的真实预测误差;

[0128] S1022、根据真实预测误差建立误差预测子模型;

[0129] S1023、基于误差预测子模型对历史时段对应的性能预测数据进行矫正,并根据矫正后历史时段对应的性能预测数据、历史时段的性能数据序列,计算矫正后历史时段对应的性能预测数据的残差;

[0130] S1024:若矫正后历史时段对应的性能预测数据的残差在预设残差范围内,则将当前的误差预测子模型作为建立的误差预测子模型;若矫正后历史时段对应的性能预测值的残差不在预设残差范围内,则基于矫正后历史时段对应的性能预测数据的残差建立新的误差预测子模型,并返回执行步骤S1023。

[0131] 可选的,作为一种可能的实施方式,第一预测模块52用于,根据下式建立误差预测子模型:

$$[0132] \quad x_t = \frac{1}{t-1}(x_1 + x_2 + x_3 \dots + x_{t-1})$$

[0133] 式中,t为预测时刻, x_t 为预测时刻时间序列预测子模型的预测误差。

[0134] 可选的,作为一种可能的实施方式,第一预测模块52用于:

[0135] 基于误差预测子模型,预测历史时段对应的预测误差;

[0136] 根据预测的历史时段对应的预测误差,对历史时段对应的性能预测数据进行矫正。

[0137] 可选的,作为一种可能的实施方式,第一预测模块52用于:

[0138] 基于矫正后目标服务器的性能预测值的残差,建立残差预测子模型;

[0139] 根据 $E(t) = E_1(t) + E_2(t)$ 建立新的误差预测子模型,其中, $E(t)$ 为新的误差预测子模型, $E_1(t)$ 为当前的误差预测子模型, $E_2(t)$ 为残差预测子模型。

[0140] 可选的,作为一种可能的实施方式,修正模块54用于,基于以下公式修正第一性能数据:

$$[0141] \quad P(t) = P_0(t) + c(t)$$

[0142] 式中, $P(t)$ 为目标预测时刻的第二性能数据, $P_0(t)$ 为目标预测时刻的第一性能数据, $c(t)$ 为目标预测时刻的修正值。

[0143] 图6是本发明一实施例提供的终端设备60的示意图。如图6所示,该实施例的终端设备60包括:处理器61、存储器62以及存储在存储器62中并可在处理器61上运行的计算机程序63。处理器61执行计算机程序63时实现上述各个服务器性能预测方法实施例中的步骤,例如图1所示的步骤S101至S104。或者,处理器61执行计算机程序63时实现上述各装置实施例中各模块的功能,例如图5所示模块51至54的功能。

[0144] 示例性的,计算机程序63可以被分割成一个或多个模块/单元,一个或者多个模块/单元被存储在存储器62中,并由处理器61执行,以完成本发明。一个或多个模块/单元可以是能够完成特定功能的一系列计算机程序指令段,该指令段用于描述计算机程序63在终端设备60中的执行过程。例如,计算机程序63可以被分割成获取模块51、第一预测模块52、第二预测模块53、修正模块54(虚拟装置中的模块),各模块具体功能如下:

[0145] 获取模块51,用于获取目标服务器在参考时段的性能数据序列。

[0146] 第一预测模块52,用于将参考时段的性能数据序列输入至预先建立的ARIMA预测模型中,得到目标服务器在目标预测时刻的第一性能数据。

[0147] 第二预测模块53,用于计算ARIMA预测模型的历史残差序列,并将历史残差序列输入至预设的神经网络模型,得到目标服务器在目标预测时刻的修正值。

[0148] 修正模块54,用于基于修正值修正第一性能数据,得到目标服务器在目标预测时刻的第二性能数据。

[0149] 终端设备60可以是桌上型计算机、笔记本、掌上电脑及云端服务器等计算设备。终端设备60可包括,但不仅限于,处理器61、存储器62。本领域技术人员可以理解,图6仅仅是终端设备60的示例,并不构成对终端设备60的限定,可以包括比图示更多或更少的部件,或者组合某些部件,或者不同的部件,例如终端设备60还可以包括输入输出设备、网络接入设备、总线等。

[0150] 所称处理器61可以是中央处理单元(Central Processing Unit,CPU),还可以是其他通用处理器、数字信号处理器(Digital Signal Processor,DSP)、专用集成电路(Application Specific Integrated Circuit,ASIC)、现成可编程门阵列(Field-Programmable Gate Array,FPGA)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等。

[0151] 存储器62可以是终端设备60的内部存储单元,例如终端设备60的硬盘或内存。存储器62也可以是终端设备60的外部存储设备,例如终端设备60上配备的插接式硬盘,智能存储卡(Smart Media Card,SMC),安全数字(Secure Digital,SD)卡,闪存卡(Flash Card)等。进一步地,存储器62还可以既包括终端设备60的内部存储单元也包括外部存储设备。存储器62用于存储计算机程序以及终端设备60所需的其他程序和数据。存储器62还可以用于暂时地存储已经输出或者将要输出的数据。

[0152] 所属领域的技术人员可以清楚地了解到,为了描述的方便和简洁,仅以上述各功能单元、模块的划分进行举例说明,实际应用中,可以根据需要而将上述功能分配由不同的功能单元、模块完成,即将装置的内部结构划分成不同的功能单元或模块,以完成以上描述的全部或者部分功能。实施例中的各功能单元、模块可以集成在一个处理单元中,也可以是各个单元单独物理存在,也可以两个或两个以上单元集成在一个单元中,上述集成的单元既可以采用硬件的形式实现,也可以采用软件功能单元的形式实现。另外,各功能单元、模块的具体名称也只是为了便于相互区分,并不用于限制本申请的保护范围。上述系统中单元、模块的具体工作过程,可以参考前述方法实施例中的对应过程,在此不再赘述。

[0153] 在上述实施例中,对各个实施例的描述都各有侧重,某个实施例中未详述或记载的部分,可以参见其它实施例的相关描述。

[0154] 本领域普通技术人员可以意识到,结合本文中所公开的实施例描述的各示例的单元及算法步骤,能够以电子硬件、或者计算机软件和电子硬件的结合来实现。这些功能究竟以硬件还是软件方式来执行,取决于技术方案的特定应用和设计约束条件。专业技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能,但是这种实现不应认为超出本发明的范围。

[0155] 在本发明所提供的实施例中,应该理解到,所揭露的装置/终端设备和方法,可以通过其它的方式实现。例如,以上所描述的装置/终端设备实施例仅仅是示意性的,例如,模块或单元的划分,仅仅为一种逻辑功能划分,实际实现时可以有另外的划分方式,例如多个单元或组件可以结合或者可以集成到另一个系统,或一些特征可以忽略,或不执行。另一点,所显示或讨论的相互之间的耦合或直接耦合或通讯连接可以是通过一些接口,装置或单元的间接耦合或通讯连接,可以是电性,机械或其它的形式。

[0156] 作为分离部件说明的单元可以是或者也可以不是物理上分开的,作为单元显示的

部件可以是或者也可以不是物理单元,即可以位于一个地方,或者也可以分布到多个网络单元上。可以根据实际的需要选择其中的部分或者全部单元来实现本实施例方案的目的。

[0157] 另外,在本发明各个实施例中的各功能单元可以集成在一个处理单元中,也可以是各个单元单独物理存在,也可以两个或两个以上单元集成在一个单元中。上述集成的单元既可以采用硬件的形式实现,也可以采用软件功能单元的形式实现。

[0158] 集成的模块/单元如果以软件功能单元的形式实现并作为独立的产品销售或使用,可以存储在一个计算机可读取存储介质中。基于这样的理解,本发明实现上述实施例方法中的全部或部分流程,也可以通过计算机程序来指令相关的硬件来完成,的计算机程序可存储于一计算机可读存储介质中,该计算机程序在被处理器执行时,可实现上述各个方法实施例的步骤。其中,计算机程序包括计算机程序代码,计算机程序代码可以为源代码形式、对象代码形式、可执行文件或某些中间形式等。计算机可读介质可以包括:能够携带计算机程序代码的任何实体或装置、记录介质、U盘、移动硬盘、磁碟、光盘、计算机存储器、只读存储器(ROM,Read-Only Memory)、随机存取存储器(RAM,Random Access Memory)、电载波信号、电信信号以及软件分发介质等。需要说明的是,计算机可读介质包含的内容可以根据司法管辖区内立法和专利实践的要求进行适当的增减,例如在某些司法管辖区,根据立法和专利实践,计算机可读介质不包括电载波信号和电信信号。

[0159] 以上实施例仅用以说明本发明的技术方案,而非对其限制;尽管参照前述实施例对本发明进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本发明各实施例技术方案的精神和范围,均应包含在本发明的保护范围之内。

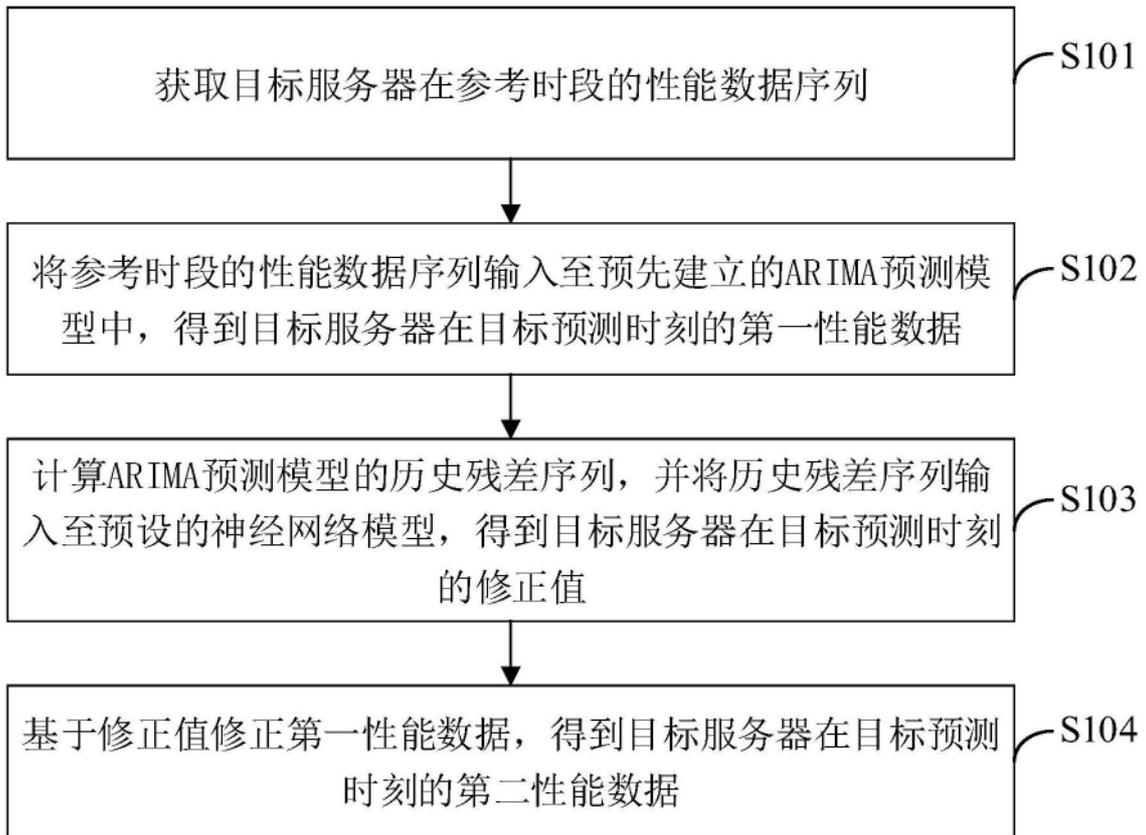


图1

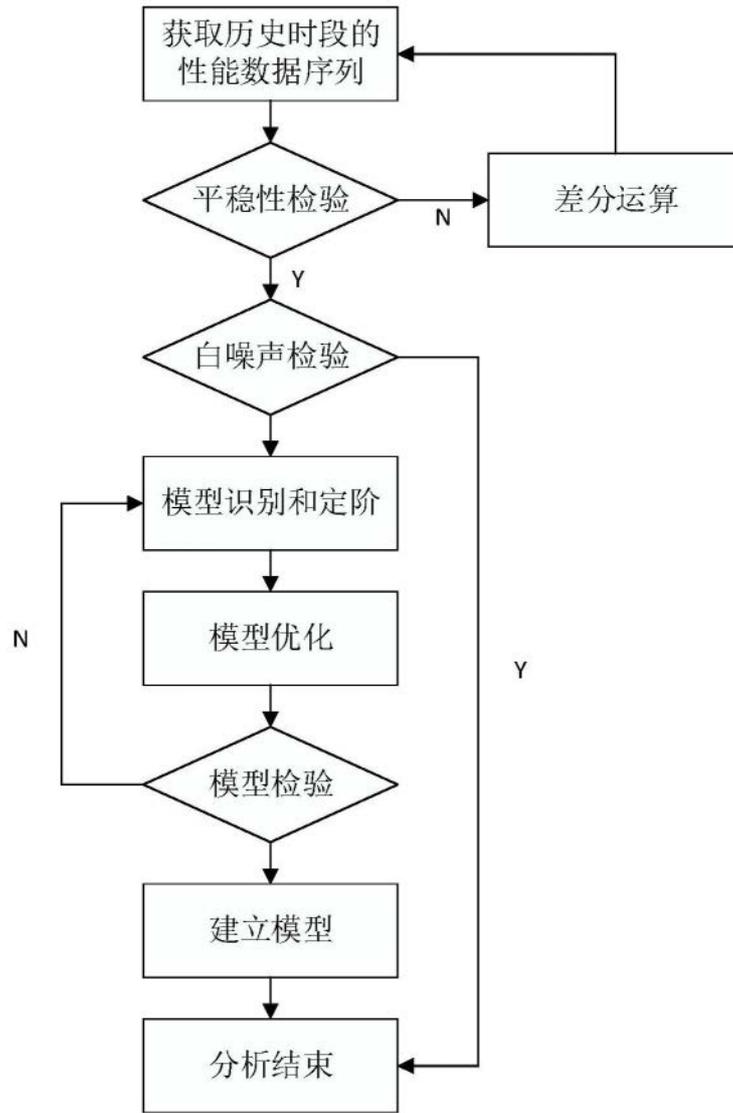


图2

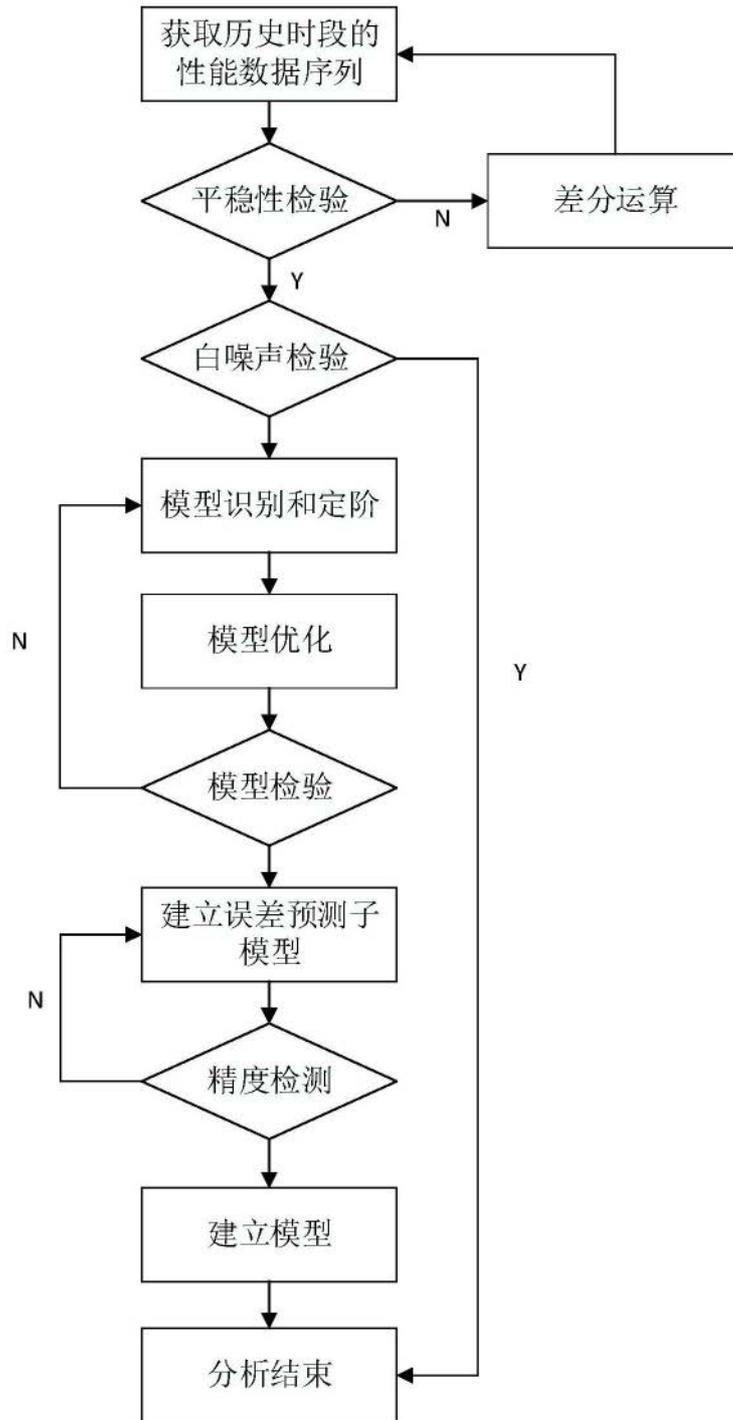


图3

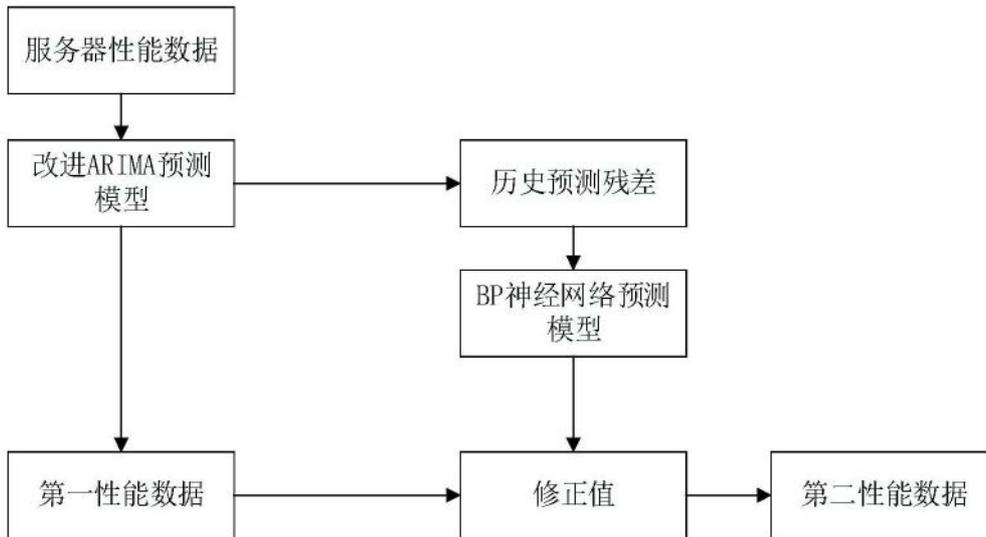


图4

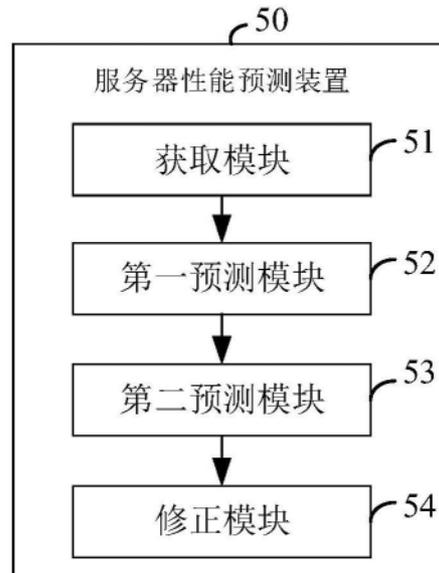


图5

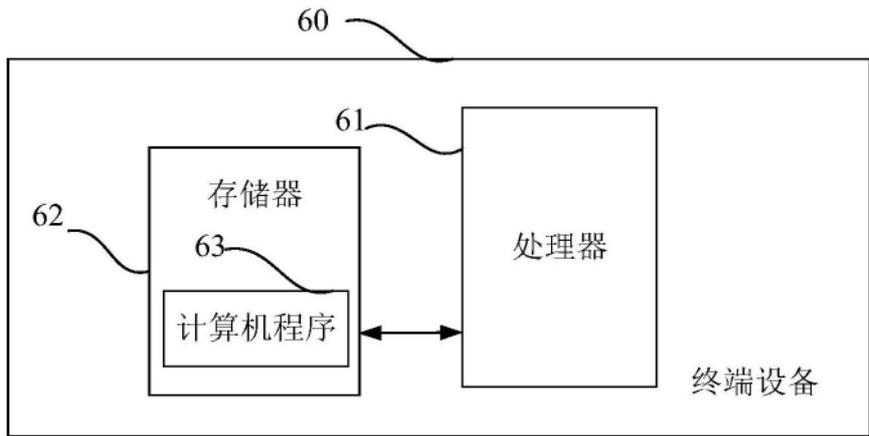


图6