



(12) 发明专利

(10) 授权公告号 CN 101299004 B

(45) 授权公告日 2010.09.01

(21) 申请号 200810028981.5

学学报 40 5. 2006, 40(5), 558-562.

(22) 申请日 2008.06.24

Cong Wang etc. Learning from neural control. IEEE transaction on neural network17 1. 2006, 17(1), 130-144.

(73) 专利权人 华南理工大学

地址 510640 广东省广州市天河区五山路 381 号

审查员 巴晓艳

(72) 发明人 王聪 陈填锐

(74) 专利代理机构 广州粤高专利商标代理有限公司 44102

代理人 何淑珍

(51) Int. Cl.

G01M 7/02 (2006.01)

G06N 3/08 (2006.01)

(56) 对比文件

CN 1514209 A, 2004.07.21, 说明书全文.

CN 1718995 A, 2006.01.11, 说明书全文.

CN 1920511 A, 2007.02.28, 说明书全文.

雷亚国, 何正嘉, 訾艳阳, 胡桥. 基于特征评估何神经网络的机械故障诊断模型. 西安交通大


权利要求书 2 页 说明书 6 页 附图 5 页

(54) 发明名称

一种基于确定学习理论的振动故障诊断方法

(57) 摘要

本发明公开了一种基于确定学习理论的振动故障诊断方法,其包括如下步骤:(1)对被诊断系统正常模式和故障模式进行学习训练;(2)建立模式库(包括正常和故障模式);(3)建立动态估计器;(4)利用动态估计器的状态与被检测系统的状态进行比较,产生残差;(5)对残差进行评估,从而发现和分离故障。该方法适用于对复杂的未知的非线性振动系统的故障诊断,可以对未知的正常模式和故障模式进行学习,建立模式库,从而进行快速的故障发现与分离。



1. 一种基于确定学习理论的振动故障诊断方法,所述振动是指确定性振动,这种振动发生时被诊断系统的状态轨迹是周期的、类周期的或混沌的轨迹,其特征在于该方法包括如下步骤:

(1) 振动模式的学习训练:采用 RBF 神经网络,对被诊断系统在正常情况和各种故障情况下的各个振动模式进行学习训练,所述学习训练采用基于李亚普诺夫的学习方法并根据确定学习理论,实现 RBF 神经网络的权值收敛和 RBF 神经网络对系统振动模式的内部动态的逼近;

(2) 建立模式库:取步骤(1)中所述权值收敛后的一段时间内各权值的均值作为学习训练结果,将其存贮于模式库中;

(3) 建立动态估计器:利用步骤(2)所述模式库中的权值建立常数 RBF 神经网络,然后利用该常数 RBF 神经网络建立动态估计器,每一个动态估计器对应一种振动模式,当动态估计器对应的模式发生时,常数 RBF 神经网络能快速回忆已学到的知识,提供该振动模式的内部动态信息;

(4) 构造残差:将每个动态估计器的状态分别与被诊断系统的状态进行比较,将它们之间的误差作为残差;

(5) 残差评估:设定一个阈值,如果只有一个残差在大于一个周期的时间内小于该阈值,则判断该残差所对应的动态估计器在这段时间内与被诊断系统相匹配,如果有多个残差在同段时间内小于该阈值,则对每一个残差取平均 l_1 范数,选择其中最小的平均 l_1 范数所对应的动态估计器作为与被诊断系统相匹配的动态估计器,如果被诊断系统与代表正常模式的动态估计器相匹配,就说明被诊断系统工作正常,如果被诊断系统与代表某个故障的动态估计器相匹配,就说明该故障发生。

2. 根据权利要求 1 所述的方法,其特征在于步骤(1)中权值收敛有两种情况:

一种是沿系统轨迹的 RBF 神经网络的神经元满足持续激励条件,其权值收敛到最优值;另一种是远离系统轨迹的 RBF 神经网络的神经元不受激励,其权值基本为零。

3. 根据权利要求 1 所述的方法,其特征在于步骤(1)中所述逼近是沿系统轨迹的内部动态的逼近,而远离系统轨迹的内部动态不被逼近。

4. 根据权利要求 1~3 任一项所述的方法,其特征在于步骤(1)所述的学习训练是知识获得的过程,所述知识是以常数 RBF 神经网络权值来表达的,每组权值对应一种振动模式,作为这种振动模式的静态表达。

5. 根据权利要求 4 所述的方法,其特征在于步骤(3)所述的动态估计器是对所述知识的再利用,作为振动模式的动态表达,再现所对应的振动模式的动态行为。

6. 根据权利要求 5 所述的方法,其特征在于如果步骤(5)所述残差评估过程没有动态估计器与被诊断系统相匹配,则认为有新故障发生,这时再次启动步骤(1)所述的学习训练过程来学习新故障。

7. 根据权利要求 5 所述的方法,其特征在于步骤(3)、(4)和(5)是对系统振动故障的监测过程,对所有故障的监测是并行、动态和实时的过程。

8. 根据权利要求 5 所述的方法,其特征在于步骤(5)所述的匹配是指被诊断系统与动态估计器之间具有相似性,其相似性的衡量因素为:i) 被诊断系统的状态与动态估计器的状态的差异;ii) 沿着被诊断系统的轨迹,被诊断系统的系统内部动态与动态估计器的系

统内部动态之间的差异。

一种基于确定学习理论的振动故障诊断方法

技术领域

[0001] 本发明属于系统故障诊断领域,具体涉及一种基于确定学习理论的振动故障诊断方法。

背景技术

[0002] 故障诊断对现代工程技术系统具有十分重要的意义。小故障会使得产生过程中断、产品被破坏,大故障会造成灾难性后果,如人员受伤、系统瘫痪等。目前,关于故障诊断的方法可以分为基于解析模型的方法、基于信号处理的方法和基于知识的方法(见周东华、叶银忠著,《现代故障诊断与容错控制》,清华大学出版社,2000)。基于解析模型的方法需要建立被监测系统的数学模型,但实际上,系统特别是复杂系统的数学模型是很难获得的。基于信号处理的方法不需要系统的数学模型,但这样就缺乏了对系统故障的深入认识,特别是对系统非线性动态特性的认识。基于知识的方法,如专家系统在自动学习知识、自动应用知识方面还存在较大的困难。

[0003] 径向基(radial basis function)神经网络,简称RBF神经网络,具有任意精度的泛函逼近能力,和最佳逼近特性,在故障诊断领域得到了较多的应用。目前这种方法主要的缺点在于难以理解神经网络的物理意义,难以保证神经网络权值收敛到最优值,以及难以保证神经网络真正逼近动态系统进而对故障进行建模。

[0004] 振动广泛存在于工程系统的运行中,振动可分为随机振动和确定性振动。随机振动是没有规律的,而确定性振动是有规律的,是由确定性系统产生的。

[0005] 确定性学习理论在近期被用于非线性动态系统在周期或者循环运动的鉴定中。通过采用局部RBF神经网络,证明部分持续激励条件能够被满足,如RBF中沿着循环系统轨迹的某些回归子向量的持续激励条件,这个部分持续激励条件可以使得沿着循环系统轨迹的误差鉴定系统满足指数稳定。因此,可在沿系统循环轨迹的局部区域获得对系统动态准确神经网络逼近。

[0006] 系统的状态轨迹是指系统的状态向量随时间的变化在状态空间中形成的轨迹。本发明所考虑的系统是全状态可测的系统。

[0007] 持续激励条件是系统辨识领域的一个重要的概念,对未知参数的辨别只有满足持续激励条件才能估计到其最值。

[0008] 从本质上来说,故障诊断的基本问题是难以对系统进行建模。如果避开建模问题而只是从症状、特征参数进行诊断的话,则容易造成误判漏判,无法保证诊断结果的可靠性。同时,绝大部分系统的行为是一种动态的非线性的行为,对其进行建模是了解故障行为和性质的关键。

发明内容

[0009] 本发明的目的在于克服上述现有技术的缺点和不足,提供一种基于确定学习理论的振动故障诊断方法,该方法可针对未知的非线性振动系统的进行故障建模。传统上,建模

是建立系统的数学模型,但对非线性系统工程建模是一个难题。在这里,我们是对产生振荡行为的非线性系统建立一个模式库。这个模式库包含了大量系统运行时的模式,包括正常情况和各种故障情况下的模式。每一种正常情况或故障情况都对应一种模式。这里的模式是指动态模式,由两个方面的因素构成,一是系统的轨迹,二是沿系统轨迹的内部动态。模式可以从历史数据或者实时数据中获得。有新故障发生时可以进行新模式的学习和升级模式库。对各种模式的建模过程是根据确定学习理论。

[0010] 本发明的技术方案由如下步骤实现:

[0011] 一种基于确定学习理论的振动故障诊断方法,所述振动是指确定性振动,这种振动发生时系统的状态轨迹是周期的、类周期的或混沌的轨迹,该方法包括如下步骤:

[0012] (1) 振动模式的学习训练:采用 RBF 神经网络,对振动系统在正常情况和各种故障情况下的各个振动模式进行学习训练,所述学习训练采用基于李亚普诺夫的学习方法并根据确定学习理论,实现 RBF 神经网络的权值收敛和 RBF 神经网络对系统振动模式的内部动态的逼近;

[0013] (2) 建立模式库:取步骤(1)中所述权值收敛后的一段时间内各权值的均值作为学习训练结果,将其存贮于模式库中;

[0014] (3) 建立动态估计器:利用步骤(2)所述模式库中的权值建立常数 RBF 神经网络,然后利用该常数 RBF 神经网络建立动态估计器,每一个动态估计器对应一种振动模式,当动态估计器对应的模式发生时,常数 RBF 神经网络能快速回忆已学到的知识,提供该振动模式的内部动态信息;

[0015] (4) 构造残差:将每个动态估计器的状态分别与检测系统的状态进行比较,将它们之间的误差作为残差;

[0016] (5) 残差评估:设定一个阈值,如果只有一个残差在大于一个周期的时间内小于该阈值,则判断该残差所对应的动态估计器在这段时间内与被诊断系统相匹配,如果有多个残差在同段时间内小于该阈值,则对每一个残差取平均 l_1 范数,选择其中最小的平均 l_1 范数所对应的动态估计器作为与被诊断系统相匹配的动态估计器,如果被检测系统与代表正常模式的动态估计器相匹配,就说明被检测系统工作正常,如果被检测系统与代表某个故障的动态估计器相匹配,就说明该故障发生。

[0017] 上述方法中,步骤(1)中权值收敛有两种情况:

[0018] 一种是沿系统轨迹的 RBF 神经网络的神经元满足持续激励条件,其权值收敛到最优值;另一种是远离系统轨迹的 RBF 神经网络的神经元不受激励,其权值基本为零。

[0019] 上述方法中,步骤(1)中所述逼近是沿系统轨迹的内部动态的逼近,而远离系统轨迹的内部动态不被逼近。

[0020] 上述方法中,步骤(1)所述的学习训练是知识获得的过程,所述知识是以常数 RBF 神经网络权值来表达的,每组权值对应一种振动模式,作为这种振动模式的静态表达。

[0021] 上述方法中,步骤(3)所述的动态估计器是对所述知识的再利用,作为振动模式的动态表达,再现所对应的振动模式的动态行为。

[0022] 上述方法中,如果步骤(5)所述残差评估过程没有动态估计器与被诊断系统相匹配,则认为有新故障发生,这时再次启动步骤(1)所述的学习训练过程来学习新故障。

[0023] 上述方法中,步骤(3)、(4)和(5)是对系统振动故障的监测过程,对所有故障的监

测是并行、动态和实时的过程。

[0024] 上述方法中,步骤(5)所述的匹配是指被诊断系统与动态估计器之间具有相似性,其相似性的衡量因素为:i)被诊断系统的状态与动态估计器的状态的差异;ii)沿着被诊断系统的轨迹,被诊断系统的系统内部动态与动态估计器的系统内部动态之间的差异。

[0025] 本发明与现有技术相比,有如下优点:

[0026] 1、建立模式库要比建立数学模型可行,因为每一种模式只是对应一种系统行为,模式库通过大量的模式对系统的行为进行描述,同时模式库还可以通过不停的升级来应对新故障的发生。而数学模型只是靠一个模型来表达系统的行为,这要求训练时的数据需要遍历整个系统的运行空间,这样的数据在实际过程中是很难获得的,而且可能是没必要的,因为系统可能只是在一条或几条轨迹上运行。另一方面,如果数据足够充分,数据量将十分大,同时进行训练将是十分困难的事情。

[0027] 2、与基于特征参数的方法相比,基于确定学习理论的振动故障诊断方法更全面的存贮了数据。提取特征参数,势必丢失大量信息,其中包括有用的信息。在基于确定学习理论的方法中,神经网络通过确定学习,可精确逼近未知系统在正常及各种故障情况下沿系统轨迹的系统内部动态。这样系统的行为过程可被完整的保存下来。

[0028] 3、基于确定学习理论的振动故障诊断方法是一种对系统进行动态监测的方法,可反映系统瞬态行为和非线性特性。

[0029] 4、基于确定学习理论的振动故障诊断方法可以利用神经网络进行自动学习,并用最小残差法自动进行诊断,从而大大提高故障诊断过程的自动化程度。

[0030] 5、与传统神经网络学习相比,该方法中的神经网络有具体的物理意义,实际上它是建立了沿轨迹的数学模型,所以它是精确而全面的描述了系统的动态过程,可以帮助人们对系统和故障的机理进行深入的认识,同时判断诊断过程的可靠性。而传统的神经网络学习不具有物理意义,无法达到这样的效果。

[0031] 6、由于神经网络有强大的逼近能力,并通过确定学习,可对系统的动态模式进行精确建模,因此可以发现微小的故障。小故障的诊断是故障诊断中十分重要的事情,因为许多灾难性的故障都是由小故障发展起来的。只有在故障发生的早期阶段发现故障才可避免灾难性事故的发生。

[0032] 7、与传统神经网络的学习训练相比,本发明真正的获得了知识,并有效的利用了知识。描述未知故障模式的知识是通过确定学习来获得的,这种知识以常数神经网络权值来表达。利用知识的过程是一种并行的、动态的和快速的过程。

附图说明

[0033] 图1是RBF神经网络对未知动态系统学习的系统结构简图。

[0034] 图2是本发明所采用的RBF神经网络示意图。

[0035] 图3是本发明实施例中利用动态估计器产生残差的结构简图。

[0036] 图4是实施例中正常模式的状态轨迹。

[0037] 图5是实施例中故障1的状态轨迹。

[0038] 图6是实施例中故障2的状态轨迹。

[0039] 图7是实施例中正常模式学习训练时个别权值的收敛情况。

[0040] 图 8 是实施例中正常模式学习训练后 RBF 神经网络沿系统轨迹逼近被诊断系统的内部动态。

[0041] 图 9 是实施例中被诊断系统正常工作时的内部动态以及代表正常模式的动态估计器的常数 RBF 神经网络的输出的情况。

[0042] 图 10a 是实施例中代表正常模式的动态估计器与被诊断系统之间的残差的时域图。

[0043] 图 10b 是实施例中代表故障 1 的动态估计器与被诊断系统之间的残差的时域图。

[0044] 图 10c 是实施例中代表故障 2 的动态估计器与被诊断系统之间的残差的时域图。

具体实施方式

[0045] 下面结合实施例及附图,对本发明的具体实施方式作进一步地说明。

[0046] 实施例

[0047] 考虑如下被诊断系统:

$$[0048] \quad x_1 = x_2, s = 0, 1, 2 \quad (1)$$

$$[0049] \quad \dot{x}_2 = \phi_2^s(x_1, x_2)$$

[0050] 其中 x_1, x_2 是系统状态, $\phi_2^0(x_1, x_2) = 1.08(0.95x_1^2 - 1)x_2 - 0.81x_1$ 表示正常情况下的未知内部动态, $\phi_2^1(x_1, x_2) = 1.08(0.95x_1^2 - 1)x_2 - 0.81x_1 + 0.75 \sin(x_1)$,

[0051] $\phi_2^2(x_1, x_2) = 1.08(0.95x_1^2 - 1)x_2 - 0.81x_1 + 0.75 \cos(x_1)$ 分别表示系统在发生故障 1 和故障 2 情况下的未知内部动态。本实施例中正常模式、故障 1 和故障 2 的状态轨迹分别如图 4 图、5 和图 6 所示。图中 x_1, x_2 是系统状态。

[0052] 采用基于确定学习理论的振动故障诊断方法的步骤如下:

[0053] (1) 振动模式的学习训练:

[0054] 采用神经网络对未知系统学习训练的系统结构简图如图 1 所示。其中 x 是系统状态, \hat{x} 是 RBF 神经网络学习器的输出。

[0055] 将所测得的系统状态作为神经网络的输入,神经网络采用高斯径向基网络,如图 2 所示,其中 x_1, x_2, \dots, x_n 是神经网络的输入, y 是神经网络的输出,本实施例中只有 x_1, x_2 两个输入。

[0056] RBF 神经网络学习器由如下方程表示:

$$[0057] \quad \dot{\hat{x}}_2 = -a(\hat{x}_2 - x_2) + \hat{W}_2^T S(x_1, x_2) \quad (2)$$

[0058] 其中 \hat{x}_2 是 RBF 神经网络学习器的状态, x_1, x_2 是系统 (1) 的状态, $a = 5$ 是设计的常数, $\hat{W}_2^T S(x_1, x_2)$ 是 RBF 神经网络,用来逼近系统 (1) 中的未知函数 $\phi_2^s(x_1, x_2)$ 。

[0059] 式 (2) 中的估计权重 \hat{W}_2 用基于李亚普诺夫 (Lyapunov) 的学习方法:

$$[0060] \quad \dot{\hat{W}}_2 = -\Gamma S(x_1, x_2) \tilde{x}_2 - \sigma \Gamma \hat{W}_2 \quad (3)$$

[0061] 其中 $\tilde{x}_2 = \hat{x}_2 - x_2$, $\Gamma = 2$, $\sigma = 0.001$ 。

[0062] 根据确定学习理论,如图 7 所示,靠近系统轨迹的神经元的权值满足部分持续激励条件,从而收敛到最优值,而远离系统轨迹的神经元受激励的程度很小,基本上保持在很小的值的范围内。另一方面,沿系统轨迹,RBF 神经网络逼近被诊断系统的内部动态,如图 8

所示。

[0063] (2) 建立模式库：

[0064] 当 RBF 神经网络权值收敛时，取收敛后的一段时间的权值均值为学习结果：

$$[0065] \quad \bar{W}_2 = \text{mean}_{t \in [t_a, t_b]} \hat{W}_2(t) \quad (4)$$

[0066] 其中 $t_b > t_a > 0$ 表示这个收敛过程后的一段时间。这样我们就获得神经网络权重的常数向量 \bar{W}_2 ，将其存贮于模式库中。

[0067] 本实施有三个振动模式，按步骤 (1) (2) 对这三个振动模式进行学习训练，最后就获得三组权值： \bar{W}_2^s , $s = 0, 1, 2$ 。每组权值对应一个振动模式，作为对应振动模式的静态表达。同时这三组权值构成一个模式库。如果学习训练的振动模式更多，模式库就有更多组权值。

[0068] (3) 建立动态估计器：

[0069] 从模式库中调出权值，将这些权值赋值给 RBF 神经网络，这样就建立起三个常数 RBF 神经网络。这三个常数 RBF 神经网络的表达式为：

$$[0070] \quad \bar{W}_2^{sT} S(x_1, x_2), s = 0, 1, 2$$

[0071] 利用这三个常数 RBF 神经网络建立动态估计器。动态估计器可由如下方程描述：

$$[0072] \quad \dot{\bar{x}}_2^s = -b(\bar{x}_2^s - x_2) + \bar{W}_2^{sT} S(x_1, x_2), s = 0, 1, 2 \quad (5)$$

[0073] 其中 \bar{x}_2 是动态估计器的状态。 x_1, x_2 是系统 (1) 的状态， $b > 0$ 通常小于 a (a 在 (2) 中给出)。 $\bar{W}_2^{sT} S(x_1, x_2)$ 是通过确定性学习获得的常数 RBF 神经网络，当动态估计器对应的振动模式发生时，常数 RBF 神经网络能快速回忆已学到的知识，提供该振动模式的内部动态信息。如图 9 所示，当被诊断系统工作正常时，被诊断系统的内部动态随时间的变化如图中实线所示，代表正常模式的动态估计器中常数 RBF 神经网络的输出如图中虚线所示，两条线近似重叠在一起，表明代表正常模式的动态估计器中常数 RBF 神经网络的输出逼近于被诊断系统的内部动态。

[0074] (4) 构造残差：

[0075] 动态估计器与被检测系统之间的同步误差作为残差，其系统结构简图如图 3 所示。其中 x 是系统 (1) 的状态， \bar{x}^s ($s = 0, 1, 2$) 是动态估计器的状态， $\tilde{x}^s = \bar{x}^s - x$ ($s = 0, 1, 2$) 是动态估计器与被检测系统之间的残差。

[0076] (5) 残差评估：

[0077] 设定一个阈值，这个阈值跟据动态估计器与被诊断系统匹配时残差的最大值来设定，本实施设定为 0.1。

[0078] 图 10 表明当故障 1 在 20 秒时刻发生时各动态估计器与被诊断系统之间的残差的情况。在 22 秒之前只有动态估计器 0 的残差不会大于阈值，因此在这段时间内可判断系统正常工作；在 22 秒之后只有动态估计器 1 的残差不会大于阈值，因此可判断 22 秒之后故障 1 发生。本实施例中没有出现多个残差在大于一个周期的时间内都小阈值的情况，因此不必进一步辨别动态估计器。

[0079] 如果出现多个残差在大于一个周期的时间内都小阈值的情况，就需要对这些残差取平均 l_1 范数。

[0080] 对残差取平均 l_1 范数按如下公式计算：

$$[0081] \quad \|\tilde{x}_2^s(t)\|_{1T} = \frac{1}{T} \int_{-T}^t |\tilde{x}_2^s(\tau)| d\tau, t > T, s = 0, 1, 2 \quad (6)$$

[0082] 式 (6) 中 T 是被诊断系统的周期。

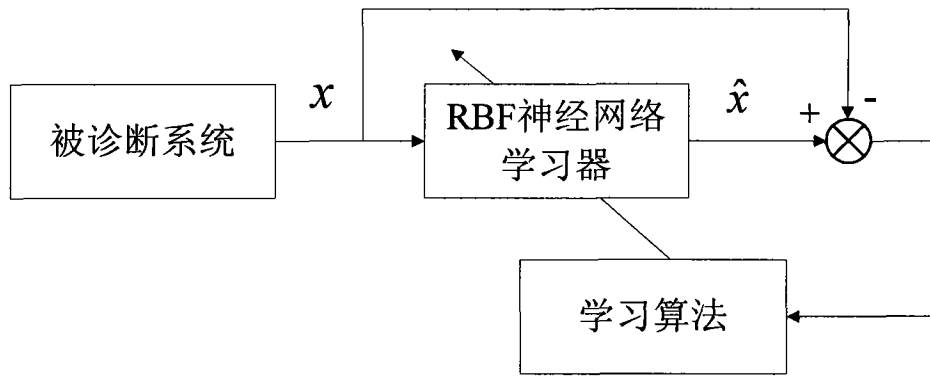


图 1




图 2

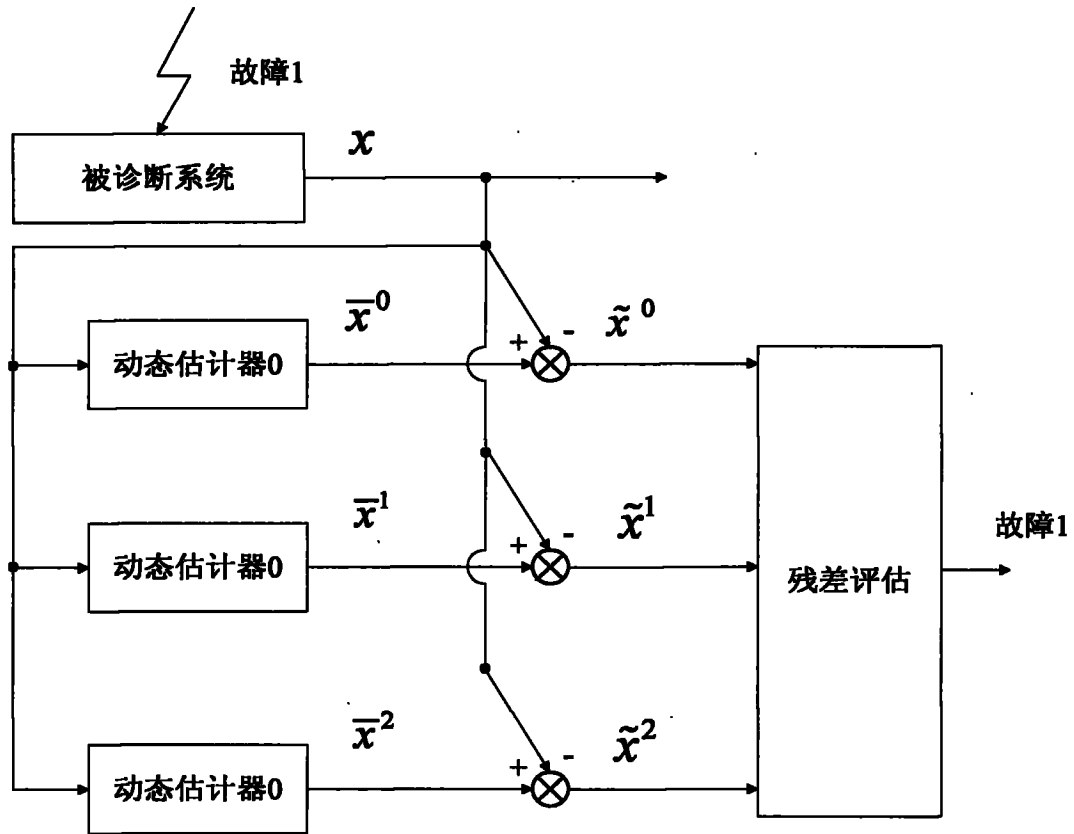


图 3




图 4




图 5




图 6




图 7




图 8




图9




图10a




图10b




图10c