



(12)发明专利申请

(10)申请公布号 CN 110039373 A

(43)申请公布日 2019.07.23

(21)申请号 201910271442.2

(22)申请日 2019.04.04

(71)申请人 华中科技大学

地址 430074 湖北省武汉市洪山区珞喻路
1037号

(72)发明人 周会成 陈吉红 陈宇 高浩然

(74)专利代理机构 华中科技大学专利中心

42201

代理人 张彩锦 曹葆青

(51) Int. Cl.

B23Q 15/18(2006.01)

B23Q 17/00(2006.01)

G06F 17/50(2006.01)

G06N 3/04(2006.01)

G06N 3/08(2006.01)

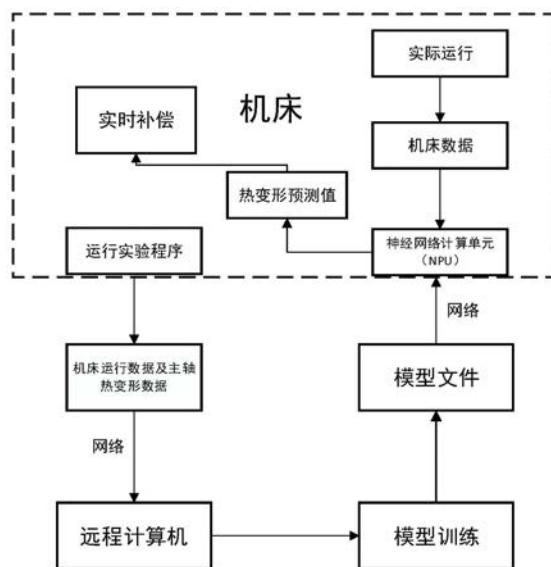
权利要求书2页 说明书6页 附图3页

(54)发明名称

一种数控机床主轴热变形预测方法及系统

(57)摘要

本发明属于机床热误差测量领域,并具体公开了一种数控机床主轴热变形预测方法及系统,其利用模型建立模块构建神经网络模型,该神经网络模型以机床当前时刻之前的运动状态数据和热变形状态数据作为输入,并以当前时刻之后一段时间内的主轴热变形量为输出;利用数据采集模块采集机床主轴电流、主轴速度和环境温度及主轴热变形量构建训练集;利用模型训练模块将训练集中的数据输入神经网络模型中进行训练;利用热变形预测模块实时获取待预测机床的运动状态和热变形状态数据,并将其输入已训练的神经网络模型中实现主轴热变形的预测。本发明预测效果好,可有效减小机床加工过程中热误差的影响,适用于无内置温度传感器的机床主轴热变形的预测。



1. 一种数控机床主轴热变形预测方法,其特征在于,包括如下步骤:

S1构建神经网络模型,该神经网络模型以机床当前时刻 t 之前的运动状态数据和热变形状态数据作为输入,并以当前时刻 t 之后的 τ 时间段内的主轴热变形量为输出,其中机床运动状态数据包括 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T ,热变形状态数据包括 $t-k\tau$ 至 t 时间段内的主轴热变形量, k 为正整数;

S2采集 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T 以及 $t-k\tau$ 至 t 时间段内的主轴热变形量以构建训练集用于模型训练;

S3将训练集中的数据输入构建的神经网络模型中进行模型训练,以训练获得用于主轴热变形预测的神经网络模型;

S4实时获取待测机床的运动状态数据和热变形状态数据,并将其输入训练获得的神经网络模型中以得到机床主轴热变形量,以此达到主轴热变形预测的目的。

2. 如权利要求1所述的数控机床主轴热变形预测方法,其特征在于,所述神经网络模型包括依次设置的第一卷积层、第一池化层、第二卷积层、第二池化层、隐藏层和全连接层。

3. 如权利要求1所述的数控机床主轴热变形预测方法,其特征在于,所述模型训练具体为将训练集中的数据输入构建的神经网络模型中并计算误差,根据所计算的误差更新神经网络模型中的参数,然后根据更新后的神经网络模型继续送入数据进行误差计算依此循环,直至神经网络模型对数据的预测精度达到预设要求,完成模型训练。

4. 如权利要求1所述的数控机床主轴热变形预测方法,其特征在于,模型训练在远程计算机中完成,采集获得的训练集中的数据首先通过机床的网络功能传输至远程计算机中存储以用于模型训练,模型训练完成后生成模型文件,然后经远程计算机将模型文件通过网络传输到机床本地。

5. 如权利要求4所述的数控机床主轴热变形预测方法,其特征在于,机床在实际加工过程中通过本地神经网络计算单元NPU运行模型文件并实时传入机床的运行状态数据和变形状态数据以计算得到机床主轴热变形数据。

6. 如权利要求1所述的数控机床主轴热变形预测方法,其特征在于, k 优选为3, τ 优选为1min。

7. 如权利要求1-6任一项所述的数控机床主轴热变形预测方法,其特征在于,还包括如下步骤:

S5利用获得的机床主轴热变形量对机床Z轴的运动轨迹进行补偿。

8. 一种数控机床主轴热变形预测系统,其特征在于,包括:

模型建立模块,用于构建神经网络模型,该神经网络模型以机床当前时刻 t 之前的运动状态数据和热变形状态数据作为输入,并以当前时刻 t 之后的 τ 时间段内的主轴热变形量为输出,其中机床运动状态数据包括 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T ,热变形状态数据包括 $t-k\tau$ 至 t 时间段内的主轴热变形量, k 为正整数;

数据采集模块,用于采集 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T 以及 $t-k\tau$ 至 t 时间段内的主轴热变形量以构建训练集用于模型训练;

模型训练模块,用于将训练集中的数据输入构建的神经网络模型中进行模型训练,以训练获得用于主轴热变形预测的神经网络模型;

热变形预测模块,用于实时获取待预测机床的运动状态数据和热变形状态数据,并将

其输入训练获得的神经网络模型中以得到机床主轴热变形量,以此达到主轴热变形预测的目的。

9.如权利要求8所述的数控机床主轴热变形预测系统,其特征在于,模型建立模块和模型训练模块设于远程计算机中,数据采集模块和热变形预测模块设于本地机床中。

10.如权利要求8所述的数控机床主轴热变形预测系统,其特征在于,还包括:补偿模块,用于将获得的机床主轴热变形量对机床Z轴的运动轨迹进行补偿。

一种数控机床主轴热变形预测方法及系统

技术领域

[0001] 本发明属于机床热误差测量领域,更具体地,涉及一种数控机床主轴热变形预测方法及系统。

背景技术

[0002] 数控机床在进行高速高精加工时,影响机床加工精度的误差来源有很多,如几何误差、装夹误差、热误差(即热变形所造成的误差)等,而热误差占总误差的40%~70%左右。因此,热误差对于机床的加工精度的影响不可忽略。目前,对于热变形的检测主要有温度场法,误差防止法以及热变形建模法等。

[0003] 温度场法是指在研究机床的热变形问题时,在机床的发热部件附近布置大量的温度传感器,然后通过分析机床热变形与温度传感器的相关性,找出与机床热变形相关性较大的几个温度敏感点,最后根据温度敏感点的温度数据建立机床的热变形模型如线性回归模型。此种方法需要对机床布置大量的温度传感器,因此需要一定的经济成本,此外理想情况下的传感器布置需要在部件附近进行打孔,因此需要在机床装配出厂之前完成,不适用于已经出厂的机床,同时针对不同型号机床需要重新选取敏感点。

[0004] 误差防止法是指通过设计和制造途径来消除或减少可能的热误差源,提高机床的制造精度,或者通过控制温度来满足加工精度的要求又或者简化传动系统的结构减少传动齿轮,传动轴,采用低摩擦系数的导轨和轴承,减少摩擦发热;采用对称结构设计,使部件均匀受热。虽然误差防止法对机床的热误差控制有着十分积极的效果,但是其却存在着很大的局限性,所带来的费用是非常大的,因此在一定程度上受到经济条件的制约。

[0005] 热变形建模法是指对机床部件的摩擦生热过程以及相应的散热过程和部件的热变形过程进行分析,并以机床运行过程中的速度电流等数据作为输入并基于一定的规律建立相应的热变形模型。此种方法需要比较精确的建模过程,因此在研究过程需要耗费大量时间,同时针对不同机床可能需要重新建模,所以模型不具有通用性。模型需要大量数据进行参数辨识,数据的存储以及参数辨识的运算过程需要占用大量的存储空间以及运算时间,都难以在机床主机实现。同时过于复杂的模型在运行过程中可能会消耗大量的机床CPU资源,影响数控系统正常运行。

发明内容

[0006] 针对高速高精加工中心在加工阶段由于高速运转造成的主轴部件因摩擦力升温而造成的主轴热变形较大进而造成的加工过程中热误差的问题,本发明提出了一种数控机床主轴热变形预测方法及系统,其以机床运动状态和热变形状态数据作为输入进行神经网络的训练,以此在机床实时运行过程中通过将实时获得的机床运动状态数据和热变形状态数据输入已训练的神经网络中即可计算得到主轴热变形的预测值,以达到实时预测与补偿的目的,预测效果好,可有效减小机床加工过程中热误差的影响,适用于无内置温度传感器的机床主轴热变形的预测。

[0007] 为实现上述目的,按照本发明的一个方面,提出了一种数控机床主轴热变形预测方法,其包括如下步骤:

[0008] S1构建神经网络模型,该神经网络模型以机床当前时刻 t 之前的运动状态数据和热变形状态数据作为输入,并以当前时刻 t 之后的 τ 时间段内的主轴热变形量为输出,其中机床运动状态数据包括 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T ,热变形状态数据包括 $t-k\tau$ 至 t 时间段内的主轴热变形量, k 为正整数;

[0009] S2采集 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T 以及 $t-k\tau$ 至 t 时间段内的主轴热变形量以构建训练集用于模型训练;

[0010] S3将训练集中的数据输入构建的神经网络模型中进行模型训练,以训练获得用于主轴热变形预测的神经网络模型;

[0011] S4实时获取待测机床的运动状态数据和热变形状态数据,并将其输入训练获得的神经网络模型中以得到机床主轴热变形量,以此达到主轴热变形预测的目的。

[0012] 作为进一步优选的,所述神经网络模型包括依次设置的第一卷积层、第一池化层、第二卷积层、第二池化层、隐藏层和全连接层,其中,第一卷积层、第一池化层、第二卷积层和第二池化层用于提取特征,隐藏层及全连接层用于将提取的特征与输出作对应的拟合关系。

[0013] 作为进一步优选的,所述模型训练具体为将训练集中的数据输入构建的神经网络模型中并计算误差,根据所计算的误差更新神经网络模型中的参数,然后根据更新后的神经网络模型继续送入数据进行误差计算依此循环,直至神经网络模型对数据的预测精度达到预设要求,完成模型训练。

[0014] 作为进一步优选的,模型训练在远程计算机中完成,采集获得的训练集中的数据首先通过机床的网络功能传输至远程计算机中存储以用于模型训练,模型训练完成后生成模型文件,然后经远程计算机将模型文件通过网络传输到机床本地。

[0015] 作为进一步优选的,机床在实际加工过程中通过本地神经网络计算单元NPU运行模型文件并实时传入机床的运行状态数据和变形状态数据以计算得到机床主轴热变形数据。

[0016] 作为进一步优选的, k 优选为3, τ 优选为1min。

[0017] 作为进一步优选的,还包括如下步骤:

[0018] S5利用获得的机床主轴热变形量对机床Z轴的运动轨迹进行补偿。

[0019] 按照本发明的另一方面,提供了一种数控机床主轴热变形预测系统,其包括:

[0020] 模型建立模块,用于构建神经网络模型,该神经网络模型以机床当前时刻 t 之前的运动状态数据和热变形状态数据作为输入,并以当前时刻 t 之后的 τ 时间段内的主轴热变形量为输出,其中机床运动状态数据包括 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T ,热变形状态数据包括 $t-k\tau$ 至 t 时间段内的主轴热变形量, k 为正整数;

[0021] 数据采集模块,用于采集 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T 以及 $t-k\tau$ 至 t 时间段内的主轴热变形量以构建训练集用于模型训练;

[0022] 模型训练模块,用于将训练集中的数据输入构建的神经网络模型中进行模型训练,以训练获得用于主轴热变形预测的神经网络模型;

[0023] 热变形预测模块,用于实时获取待预测机床的运动状态数据和热变形状态数据,

并将其输入训练获得的神经网络模型中以得到机床主轴热变形量,以此达到主轴热变形预测的目的。

[0024] 作为进一步优选的,模型建立模块和模型训练模块设于远程计算机中,数据采集模块和热变形预测模块设于本地机床中。

[0025] 作为进一步优选的,预测系统还包括:补偿模块,用于将获得的机床主轴热变形量对机床Z轴的运动轨迹进行补偿。

[0026] 总体而言,通过本发明所构思的以上技术方案与现有技术相比,主要具备以下的技术优点:

[0027] 1.本发明的方法基于机床自身的数据(主轴电流、主轴速度、环境温度)驱动,不需要大量的辅助设备以及温度传感器,相对于温度场方法节省了经济成本;并且依靠神经网络模型,相对于建模方法不需要对机床进行精确的热变形建模,同时模型易于学习,针对不同型号的机床只需重新学习训练即可得到适用于该型号机床的模型,省去了大量的机床主轴热变形建模时间,节省了机床经济成本以及人力成本。

[0028] 2.本发明采用远程计算机实现模型建立与训练获得模型文件,并采用本地NPU(神经网络计算单元)运行模型文件,避免了本地无法进行大数据存储以及长时间复杂运算的问题,同时本地NPU的使用可以避免实时预测过程中模型计算对于本地CPU资源的大量占用,避免了对数控系统实时性的影响,此外,NPU的使用使得本发明方法可以采用复杂的神经网络模型,并且由于NPU运算速度较快,运算过程较短,可以满足热误差预测过程中的实时性的要求。

附图说明

[0029] 图1是本发明实施例提供的数控机床主轴热变形预测方法的流程图;

[0030] 图2是本发明实施例提供的神经网络模型结构图;

[0031] 图3是本发明实施例提供的数据采集流程图;

[0032] 图4是本发明实施例提供的模型训练流程图;

[0033] 图5是本发明实施例提供的模型验证结果图;

[0034] 图6是本发明实施例提供的热变形预测流程图。

具体实施方式

[0035] 为了使本发明的目的、技术方案及优点更加清楚明白,以下结合附图及实施例,对本发明进行进一步详细说明。应当理解,此处所描述的具体实施例仅仅用以解释本发明,并不用于限定本发明。此外,下面所描述的本发明各个实施方式中所涉及到的技术特征只要彼此之间未构成冲突就可以相互组合。

[0036] 如图1所示,本发明实施例提供一种数控机床主轴热变形预测方法,其主要包括模型建立、数据采集、模型训练、模型应用(热变形预测)四个部分,其通过运行实验G代码,采集所研究机床主轴热变形量数据,并将机床运行过程中的实时数据(电流,速度,环境温度等)以及所测热变形量数据通过网络传输到远程计算机,然后在远程计算机中根据所获得的数据送入神经网络模型进行训练,再将训练好的模型文件通过网络传送到数控机床存储介质当中,最后在实际加工过程中通过相应的神经网络运算模块(NPU)运行神经网络模

型文件,并送入机床实时运行数据,得到主轴热变形预测值,以达到实时预测的目的。

[0037] 该方法具体包括如下步骤:

[0038] S1构建神经网络模型,该神经网络模型以机床当前时刻 t 之前的运动状态数据和热变形状态数据作为输入,并以当前时刻 t 之后的 τ 时间段内的主轴热变形量为输出,其中机床运动状态数据包括 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T ,热变形状态数据包括 $t-k\tau$ 至 t 时间段内的主轴热变形量, k 为正整数;

[0039] S2采集 $t-\tau$ 至 t 时间段内的机床主轴电流 i 、主轴速度 v 和环境温度 T 以及 $t-k\tau$ 至 t 时间段内的主轴热变形量以构建训练集用于模型训练;

[0040] S3将训练集中的数据输入构建的神经网络模型中进行模型训练,以训练获得用于主轴热变形预测的神经网络模型;

[0041] S4实时获取待预测机床的运动状态数据和热变形状态数据,并将其输入训练获得的神经网络模型中以得到机床主轴热变形量,以此达到主轴热变形预测的目的,其中,热变形状态数据的初始值为零,之后将由神经网络模型预测获得的当前时刻的主轴热变形量作为下一时刻的热变形状态数据。

[0042] 下面对各个部分进行详细说明和描述。

[0043] (1) 模型建立

[0044] 模型结构建立是指在对模型进行训练使用之前,要针对所研究的热误差问题的特性进行相应的神经网络模型的构造以及对于模型输入输出的选择。通过对机床部件热误差过程的分析,可以知道某一时刻的热变形不仅与在该时刻之前某一时间段的机床运动有关,还与机床在该时间段之间的热变形状态相关。如下式所示:

[0045]
$$y_t = f(x, y_{t-\tau}, y_{t-2\tau}, \dots, y_{t-k\tau})$$

[0046] 其中, y_t 是机床部件 $t+\tau$ 时间段内的热变形状态即热变形量, x 为机床在 $t-\tau$ 时刻到 t 时刻的运动状态信息数据矩阵, $y_{t-\tau}$ 是 $t-\tau$ 时刻到 t 时刻的热变形状态即热变形量, $y_{t-2\tau}$ 是 $t-2\tau$ 时刻到 $t-\tau$ 时刻的热变形状态即热变形量, $y_{t-k\tau}$ 是 $t-k\tau$ 时刻到 $t-(k-1)\tau$ 时刻的机床热变形状态即热变形量。

[0047] x 表示如下:

[0048] $x = (i, v, T)$

[0049] 其中, i 是机床运动中的主轴电流, v 是主轴速度, T 是环境温度。

[0050] 神经网络模型的作用是去训练学习得到热变形与机床数据的内在关系,即公式中 f 所代表的映射关系。观察该式可以发现热变形不仅与机床的运动状态信息有关,也与所预测时刻的前 τ 时刻,以及 2τ 时刻甚至 $k\tau$ 时刻的状态信息(即机床热变形量)有关。可以发现 k 的大小以及时间间隔 τ 的选取都不固定,不同的选取可能会影响模型结果的好坏,例如 k 的选取, k 如果过大导致输入信息过多,模型过复杂,不易学习与训练; k 过小,又可能导致模型输入信息不足,使得模型效果降低。

[0051] 因此,前期模型建立的主要工作在于通过对已有数据的分析以及模型的效果去调节 k 以及 τ 的大小,并且同时调整模型本身的结构,本发明经过研究最终确定 k 为3, τ 为一分钟,在该参数的选取下对于模型的预测效果有较好的提升。而模型的结构包括模型本身的层数,以及每层激活函数的选取,最终得到适用于机床热变形预测(不仅限于同一种型号的机床)的输入与输出以及神经网络模型。

[0052] 本发明研究得到的神经网络模型结构如图2所示:其初始输入数据的维度为 (6×600) ,输入神经网络模型结构后由 (6×600) 变为 (60×60) ,然后由第一层带有16个卷积核的第一卷积层得到 $16 \times (30 \times 30)$ 的数据,再经过第一池化层,数据维度不变,然后再经过包含32个卷积核的第二卷积层得到 $32 \times (15 \times 15)$ 的数据,再经过第二池化层,然后将数据格式变为一维,长度为7200,经过一层隐藏层变为1024,然后再经过一层全连接层输出长度60的预测结果。

[0053] 其中,输入数据的 (6×600) 中的6为电流 i ,速度 v ,环境温度 T ,当前时刻 t 至前一分钟时间段的热变形 $y_{t-\tau}$,前一分钟至前两分钟时间段的热变形 $y_{t-2\tau}$,前两分钟至前三分钟时间段的热变形 $y_{t-3\tau}$,即当前时刻 t 的前 τ 时间段的热变形 $y_{t-\tau}$,前 τ 至前 2τ 时间段的热变形 $y_{t-2\tau}$,前 2τ 至前 3τ 时间段的热变形 $y_{t-3\tau}$ 。600为输入数据的一分钟时间段的数据采样,其中采样频率为10HZ即一秒钟的数据量为10,一分钟为600,因此输入数据为 6×600 。输出数据为预测的当前时刻之后的一分钟时间内(即 t 至 $t+\tau$ 时间段内)的热变形量 y 。其中,每一秒钟对应一个预测量,因此输出数据的维度为60。

[0054] (2) 数据采集

[0055] 在数据采集过程中的数据是要送入模型进行训练,因此所采集数据即模型样本应当具有多样性,同时样本数据应当足够丰富,即应当涵盖主轴运动过程中的各个可能的速度大小,以及热变形量的大小。然而单一的重复性的机床运动过程的数据过于单一并不能满足以上要求,因此需要针对数据采集过程中的实验过程进行合理的实验设计以便通过较少次数的实验过程得到足够丰富的数据样本,以用于模型的训练。数据采集过程主要是架设热变形测量仪器,设计相应的主轴热变形实验,并将测量仪器的数据与数控机床进行直联,然后机床运行相应实验G代码,使得机床按照一定的规律运动,同时机床将机床运行过程中的主轴的电流 i ,速度 v ,以及环境温度 T 与热变形 y 等数据采集保存并通过机床的网络功能传输到远程计算机中存储并用于模型的训练,如图3所示。

[0056] 其中,针对电流 i ,速度 v ,环境温度 T 数据从机床直接获得,采集频率为1000hz进行滤波处理后按照10hz进行截断。热变形数据的采集与所使用采集仪器有关,采集频率与实验设计相关,大约为三分钟得到一次热变形量,考虑到热变形短时间内的变形曲线接近于线性,因此将两次测得热变形数据进行线性差分,使得每0.1秒中都有对应的热变形数据,并与电流 i ,速度 v ,环境温度 T 等数据对齐。

[0057] (3) 模型训练

[0058] 模型训练是指在远程计算机中将数据送入模型训练,如图4所示,首先将按照(1)部分中所得到的神经网络模型结构进行初始化,然后将(2)采集的数据送入模型中进行训练。具体的,将采集的数据送入模型中并计算误差,然后根据所计算误差按照一定算法更新模型中的参数,然后根据更新后的模型继续送入数据进行误差计算依此循环,直至模型对数据的预测精度(即误差)达到一定指标,至此模型训练过程结束,生成模型文件,然后远程计算机将模型文件通过网络传输到本地机床。

[0059] 具体而言,考虑模型表达式为:

$$[0060] \quad y_t = f(i, v, T, y_{t-\tau}, y_{t-2\tau}, y_{t-3\tau})$$

[0061] 在训练过程中,每次将 τ 时间段(即一分钟时间段)的电流 i ,速度 v ,环境温度 T ,热变形数据 $y_{t-\tau}, y_{t-2\tau}, y_{t-3\tau}$ (其中热变形数据为实际测得数据)输入模型当中,模型会计算得到

一个热变形的预测值,预测值用 y_t 表示为一维矩阵,实际值用 $y_{t_}$ 表示,同样也是一维矩阵,则预测误差为 $(y_{t_}-y_t)$,实际值 $y_{t_}$ 是在步骤(2)中通过运行实验G代码时通过相应的热变形采集仪器采集得到,热变形的采集方式有多种,比如对刀仪、涡流位移传感器等。考虑使用最小二乘表示优化目标,即优化目标为 $\frac{1}{2}(y_{t_}-y_t)^2$,即模型训练过程目的使优化目标尽可能的小。

在每一次训练过程中,输入一次数据计算误差,然后根据梯度下降法(有相应算法库可以实现,无需自己手动编写代码完成)更新模型的参数,然后判断当前模型的预测精度(即误差)是否满足要求,如果预测精度满足要求(具体要求根据实际需要限定)就停止训练,并将保存了模型结构与参数数值的文件保存下来,如果预测精度达不到要求则继续重复上述训练过程,直至满足要求,将保存了模型结构与参数数值的文件保存下来。

[0062] 模型训练后可进行模型验证,如图5所示,将训练后的模型根据验证数据进行验证,分别得到热变形量实际测量值曲线和模型预测值曲线,通过两条曲线对比可以验证本发明训练得到的模型具有较好的预测效果。

[0063] (4) 模型应用

[0064] 模型应用是将训练好的升级网络模型的模型文件通过网络传输到数控机床,当机床在实际加工过程中通过本地NPU(神经网络计算单元)运行模型文件并实时传入机床的运行数据(电流,速度等),然后通过计算进而得到机床的主轴热变形数据以达到热变形预测的目的。

[0065] 如图6所示,在机床刚开始时将机床运行过程中的电流 i ,速度 v ,环境温度 T 等数据送入模型中运算计算得到主轴变形量,所预测变形量将送入补偿环节,并同时与下一时间段的机床数据一同输入模型用于计算下一时刻的主轴热变形,并以此循环,达到实时预测与补偿的目的。值得注意的是在表达式中模型需要输入前三个时间段的热变形,但是由于机床在刚开始运行的时候, $t=0$,则 $t-\tau, t-2\tau, t-3\tau$ 小于零,小于零并非无意义,而是相对于机床当前开始运行时刻来说为开始运行之前的时刻。由于机床在开始运行之前处于静止状态,因此没有热误差,所以可以将该时刻热变形用零代替。即在机床开始运动的时候以及开始运动之前可以知道机床此时以及此时刻之前的热变形为零,故在第一次预测的时候所输入的前面时间段的热变形数据为零,然后预测出下面时刻的热变形量,接着将所预测出来的热变形量作为输入用以预测再下一时间段的热变形量,以此迭代预测。

[0066] 本领域的技术人员容易理解,以上所述仅为本发明的较佳实施例而已,并不用以限制本发明,凡在本发明的精神和原则之内所作的任何修改、等同替换和改进等,均应包含在本发明的保护范围之内。

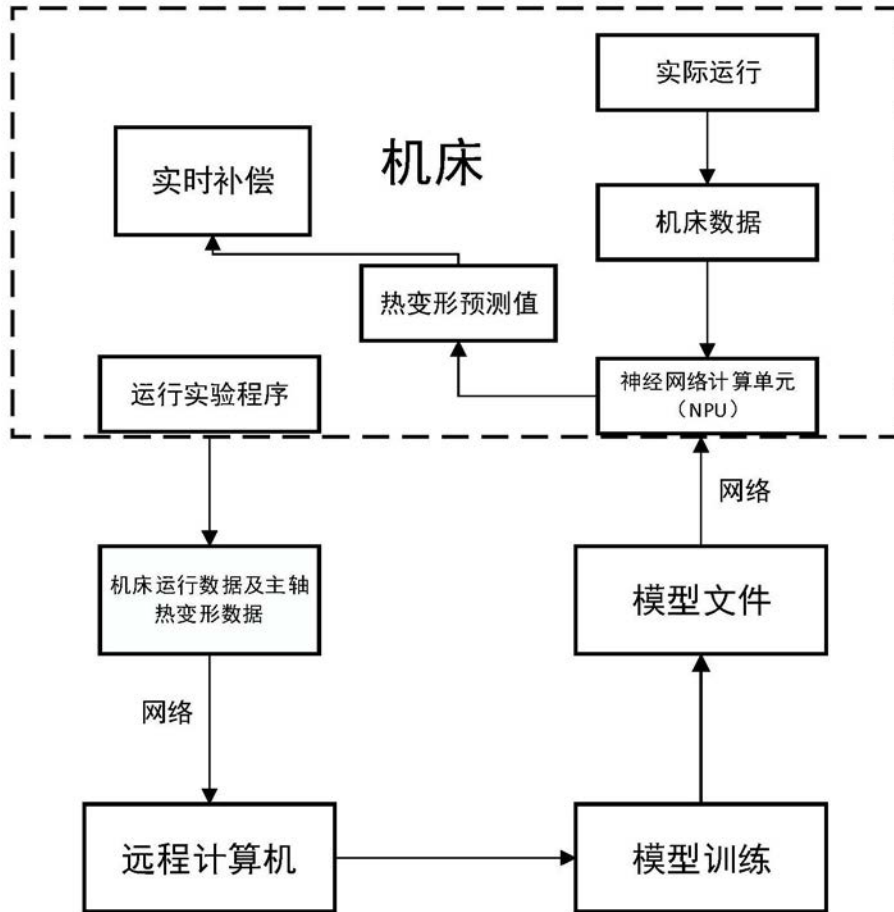


图1




图2

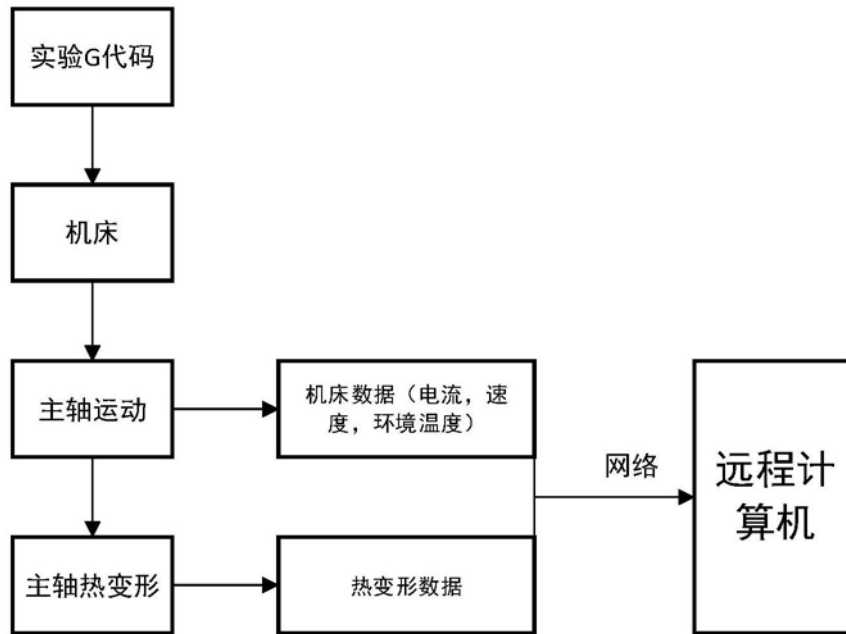


图3

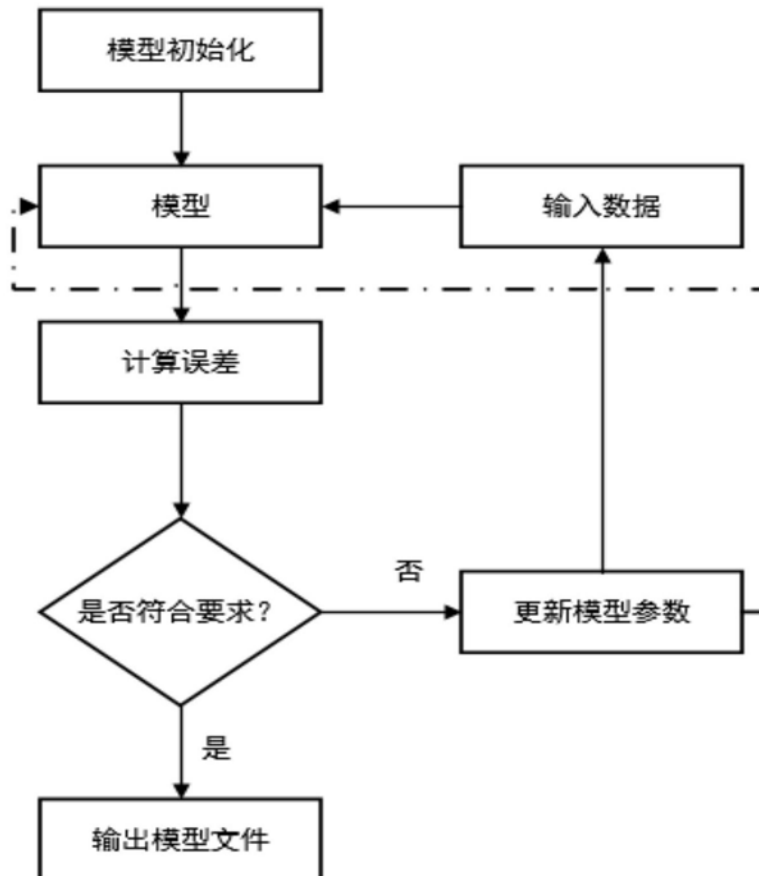


图4




图5

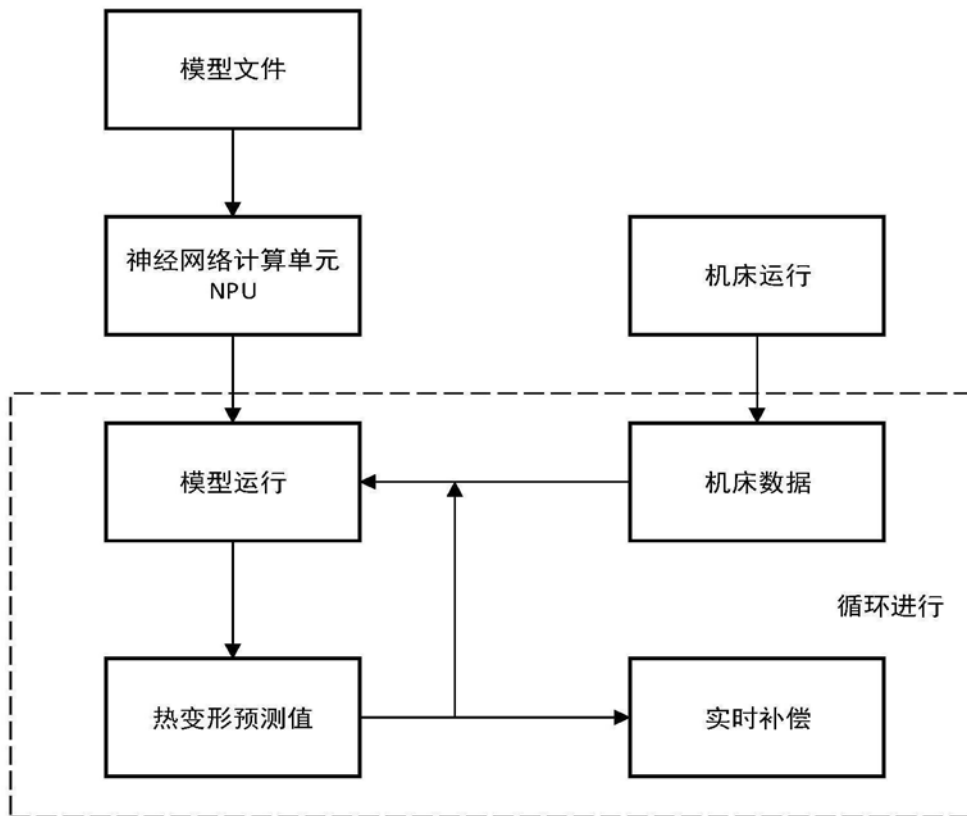


图6