

# 一种基于并行化方法的自适应光学闭环预测控制器

史晓雨<sup>1</sup> 冯 勇<sup>1</sup> 陈 颖<sup>1</sup> 谭治英<sup>2</sup> 孙 治<sup>1</sup> 李新阳<sup>3</sup>

<sup>1</sup> 电子科技大学计算机科学与工程学院, 四川 成都 611731  
<sup>2</sup> 中国科学院成都计算机应用研究所, 四川 成都 610041  
<sup>3</sup> 中国科学院光电技术研究所自适应光学重点实验室, 四川 成都 610209

**摘要** 自适应光学系统的性能受限于伺服系统的延迟误差和波前传感器的光电子噪声。提出了一种多模型单变量预测模型, 该模型采用基于 Levenberg-Marquardt 学习算法的前馈型神经网络。利用计算机多核处理器, 设计了一个具有并行处理能力的预测控制器, 来实现对自适应光学闭环控制电压的预测, 以消除延迟误差的影响。通过数值仿真实验, 研究了预测控制器对控制电压和远场斯特雷尔比的影响, 与未采用预测控制器的系统进行了比较, 并对预测算法的并行性能进行了分析。实验结果表明, 使用并行化方法的预测控制器可以有效缩短系统的预测时间, 提高预测算法的加速比, 与经典比例积分 (PI) 控制算法相比可以更有效地降低系统由于伺服延迟引起的误差, 远场的斯特雷尔比有明显地提高。

**关键词** 大气光学; 自适应光学; 预测控制器; 多模型单变量预测模型; 并行化; 多核; 神经网络

**中图分类号** TP273.2 **文献标识码** A **doi**: 10.3788/AOS201232.0801005

## A Novel Predictive Controller in the Adaptive Optics Control System Based on Parallelization Method

Shi Xiaoyu<sup>1</sup> Feng Yong<sup>1</sup> Chen Ying<sup>1</sup> Tan Zhiying<sup>2</sup> Sun Zhi<sup>1</sup> Li Xinyang<sup>3</sup>

<sup>1</sup> School of Computer Science and Engineering, University of Electronic Science and Technology of China, Chengdu, Sichuan 611731, China

<sup>2</sup> Chengdu Institute of Computer Applications, Chinese Academy of Sciences, Chengdu, Sichuan 610041, China

<sup>3</sup> Key Laboratory on Adaptive Optics, Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China

**Abstract** Performance of adaptive optics (AO) system is limited by the delay errors caused by the servo system and photoelectron noise at the wavefront sensor. A multi-model univariate prediction model is proposed, which is based on the two-layer back propagation neural network with Levenberg-Marquardt learning algorithm. Using the multi-core processors, a novel predictive controller with parallel processing capabilities is designed that is able to predict the control voltage in the closed-loop AO system and eliminate the delay errors. Through numerical simulation, the prediction performance and parallel efficiency are studied. The control voltages of the AO system and the Strehl ratio are calculated and compared for the multi-model univariate prediction algorithm and proportional integral (PI) control algorithm. The results show that the residual error caused by servo delay in the system and Strehl ratio are improved effectively by using the predictive controller than by using the PI control algorithm. The prediction time is reduced by using multi-model univariate prediction algorithm.

**Key words** atmospheric optics; adaptive optics; predictive controller; multi-model univariate prediction model; parallelization; multi-core; neural network

**OCIS codes** 010.1080; 110.1080; 200.4260

收稿日期: 2012-01-05; 收到修改稿日期: 2012-04-09

基金项目: 国家自然科学基金(60978050, 91118001)、国家 973 项目(2011CB302402)和四川省青年科技基金(09ZQ026-014)资助课题。

作者简介: 史晓雨(1986—), 男, 博士研究生, 主要从事预测控制算法和自适应光学数值模拟等方面的研究。

E-mail: shixiaoyu0216@gmail.com

导师简介: 冯 勇(1965—), 男, 研究员, 博士生导师, 主要从事自动推理及油田模拟、自适应光学数值模拟等方面的研究。E-mail: yongfeng@casit.ac.cn

## 1 引 言

自适应光学(AO)系统可以实时校正由大气湍流作用引起的随机扰动波前,明显提高光束质量,目前已经被广泛应用于以透过大气的目标成像和激光大气传输为目的的光学系统中<sup>[1,2]</sup>。自适应光学系统是一类伺服系统,从波前探测到波前校正存在着固定的时间延迟,导致波前校正跟不上波前扰动的变化。这类由于时间延迟引起的误差往往是影响自适应光学校正能力和成像质量的一个重要因素。时间延迟主要包括波前传感器(WFS)数据采集时间延迟、读出光电子延迟、波前复原计算延迟、控制运算延迟等<sup>[3,4]</sup>。但是这类时间延迟可以通过使用预测控制技术得到很好的解决,达到改善自适应光学性能的目的。

使用预测技术的前提是大气湍流必须是可预测的。Jorgenson等<sup>[5]</sup>指出大气湍流的统计特性可以很好地用分数布朗运动来描述,其Hurst参数为 $5/6$ ,且大气通过望远镜或哈特曼传感器(HS)是一种空间滤波过程。根据该理论,大气的预测是可行的。目前已经有很多研究小组将预测技术成功地运用于自适应光学系统中。虽然研究的侧重点不同,但都取得了一定的改善效果。Johnson等<sup>[6]</sup>通过在自适应光学系统内部构造风速模型预测器来实现对波前的预测;Poyneer等<sup>[7]</sup>主要专注于使用基于卡尔曼滤波的傅里叶预测控制算法实现对波前的闭环预测;Montera等<sup>[8~10]</sup>将神经网络技术运用于对波前预测的研究上;Wild等<sup>[11,12]</sup>主要研究采用递归最小二乘算法的波前预测;Liu等<sup>[13~16]</sup>对最小递归二乘法的波前斜率和电压预测进行了研究。虽然采用神经网络技术的波前预测在开环情况下已经取得了不错的效果,但是由于训练网络需要多次的迭代和大量的数据,存在计算复杂度的问题,因此在自适应光学闭环条件下的预测并没有取得很好的应用。

本文提出了一种自适应光学闭环控制电压预测控制器,利用计算机多核处理器和多模型单变量神经网络预测模型,实现了对多个驱动器电压的并行化预测处理,以加快预测效率,解决采用神经网络预测时的计算复杂度问题。成功地将该预测控制器应用于61单元自适应光学系统中。

## 2 自适应光学电压预测的基本原理

根据Taylor湍流冻结假说,在某个非常短的时间内大气湍流相对空间位置保持不变,光波传输路

径上湍流介质的变化是由横向风的吹动所致。在经过波前传感器探测作用后,这些信息很好地反映在每个子孔径质心位置和畸变波前的斜率上,因此可以在波前传感器上直接利用波前斜率信息来预测将来某一时刻的波前。由于波前斜率信息是二维的,在波前传感器上进行预测会导致计算量增大,同时探测斜率受传感器读出噪声的影响较大。在采用直接斜率复原算法的自适应光学系统中,波前斜率和复原电压具有如下关系:

$$V = \mathbf{R}_{xy}^+ G, \quad (1)$$

式中 $\mathbf{R}_{xy}^+$ 为变形镜(DM)到哈特曼传感器的斜率响应矩阵 $\mathbf{R}_{xy}$ 的广义逆矩阵, $G$ 是需要校正的波前像差斜率测量值。

由于通过波前复原算法和控制器作用后,变形镜上电压变化比较平缓,受传感器读出噪声的影响也被削弱,有利于得到比较稳定的预测控制效果,而且电压信息是一维的,这样有利于减小系统计算的复杂度,因此,可以利用控制电压来达到预测波前的目的。控制电压预测算法正是利用每个驱动器本身及周围驱动器的历史电压数据来预测该驱动器将来某一时刻的电压值<sup>[14,15]</sup>。如图1所示,通常自适应光学系统从探测波前畸变到输出控制电压到变形镜进行校正,要延迟2~3个采样周期,校正电压与扰动电压之间存在着较大的控制残差。如果采用预测控制算法,利用每个驱动器及其周围驱动器离当前时刻最近的历史电压数据来对其将来某一时刻的电压值进行预测,可以达到很好的控制效果。比如根据 $t=1, 2, 3$ 帧时刻的驱动器电压值,通过预测算法,可以超前2帧计算出 $t=5$ 帧时刻的电压。由于预测作用,校正电压和扰动电压更加接近。文中采




图1 电压预测原理图

Fig. 1 Principle diagram for the control voltage prediction

用具有 54 个子孔径的哈特曼传感器和驱动器为 61 单元的变形镜,变形镜呈六边形布局。由于遮拦作用,中间的驱动器并不起作用,因此有效驱动器为 60 单元,如图 2 所示。

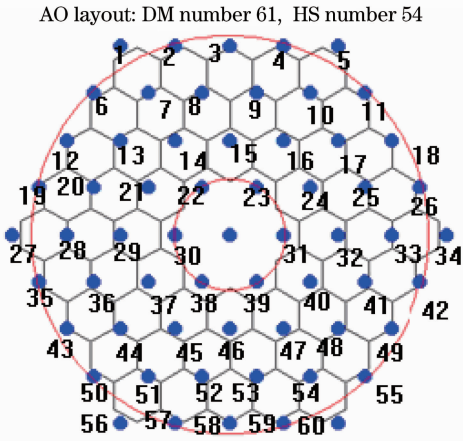


图 2 61 单元变形镜驱动器和哈特曼传感器子孔径排布  
Fig.2 Configuration of actuators of the 61-element deformable mirror (DM) and subapertures of Hartmann sensor (HS)

### 3 自适应光学闭环电压预测控制器

#### 3.1 自适应光学闭环电压预测系统

自适应光学负反馈闭环电压预测系统结构如图 3 所示,从目标或者导星发出的信标光波通过大气湍流,到达望远镜接收端并进入自适应光学系统。在自适应光学系统中,哈特曼波前传感器实时探测出波前畸变,此信号经过波前控制器的处理后产生控制电压信号,控制电压信号经过预测控制器的进一步处理,产生出预测电压信号并加到变形镜上,产生贴近当前时刻波前畸变的校正面形,使光波波前由于系统延迟产生的误差量得到最大程度的减少,




图 3 自适应光学闭环预测控制系统结构图  
Fig.3 Block diagram of closed-loop adaptive optics prediction control system

从而获得接近衍射极限的成像质量。在这里波前控制包括直接斜率复原算法和比例积分(PI)控制算法。下面重点研究的是预测控制器的设计与实现过程。

#### 3.2 预测模型的设计

相关定理已经证明只要具有足够多的节点数,隐含层传输函数为双曲正切 S 形函数,输出层传输函数为线性函数的二层前馈型神经网络(BP 神经网络)可以拟合任何复杂的非线性函数。这里采用基于 Levenberg-Marquardt 学习算法的二层前馈型神经网络进行控制电压预测,该学习算法是一种基于二阶泰勒级数的快速优化算法。对于变形镜具有  $M$  单元的自适应光学系统而言,如果采用传统的单模型多变量神经网络预测模型,神经网络输入端用  $M$  个节点来代表  $M$  个驱动器的控制电压,根据图 1 的预测原理可知,用  $K$  帧的回溯电压来预测前推  $Q$  帧的控制电压,那么将需要  $M \times K$  个节点作为网络的输入, $M$  个节点作为网络输出,根据 Kolmogorov 定理,如果输入变量的个数为  $n$ ,则隐含层节点数一般可以取  $2 \times n + 1$ ,这样单模型多变量神经网络的隐含层节点数  $H = 2 \times (M \times K) + 1$ 。训练整个网络所需要的参数为  $(H \times M \times K + M \times H + M + H)$ 。而且随着变形镜上的驱动器单元数  $M$  的增多,回溯帧数  $K$  和隐含层节点数  $H$  的增加,最终会导致训练网络所需要的参数无限制增大。因此,采用单模型多变量神经网络势必会导致网络规模庞大,极大地影响神经网络的运算速度和预测性能。对于 61 单元利用 3 帧回溯电压进行单模型多变量神经网络预测的结构如图 4 所示。如果隐含层的节点数为 361,那么网络的参数将达到 87061 个。

颜召军等<sup>[15]</sup>已经通过实验证明某一时刻的预测电压和自身驱动器的历史电压相关性最高,和离该驱动器最近的驱动器的历史电压的相关性次之,即变形镜在某一时刻的预测控制电压主要受距离时间较近的自身历史电压的影响。因此这里提出了一种多模型单变量神经网络预测模型,同样对于变形镜具有  $M$  单元的自适应光学系统,利用  $K$  帧的回溯电压来预测前推  $Q$  帧的控制电压,分别有  $M$  个结构各异的神经网络来实现对  $M$  个驱动器控制电压的预测,其中每个子网络只有一个驱动器控制电压的预测,这样每个子网络输入节点的个数  $n_i (i = 1 \sim M)$  将根据第  $i$  个驱动器所处的位置,由周围的驱动器个数而定 ( $n_i \leq 7$ ),子网络中隐含层节点数为  $H' (H' \ll H)$ ,输出层节点数为 1,这时训练网络所

需的参数则将降为 $(K \times n_i \times H' + H' + H' + 1)$ 。同样对于 61 单元利用 3 帧回溯电压进行电压预测而言,其多模型单变量神经网络预测结构如图 5 所示。如果输入节点数  $n_i = 7$ , 根据 Kolmogorov 定理,此时隐含层的节点数  $H' = 15$ , 训练网络所需要的参数

仅为 346 个,仅为单模型多变量模型的 1/250 左右。因此,采用多模型单变量预测模型可以很好地避免网络参数过多的情况,使得网络规模更加合理化。并且预测各驱动器的子网络是根据相关性原则制定的,它可以有效提高网络的预测性能。

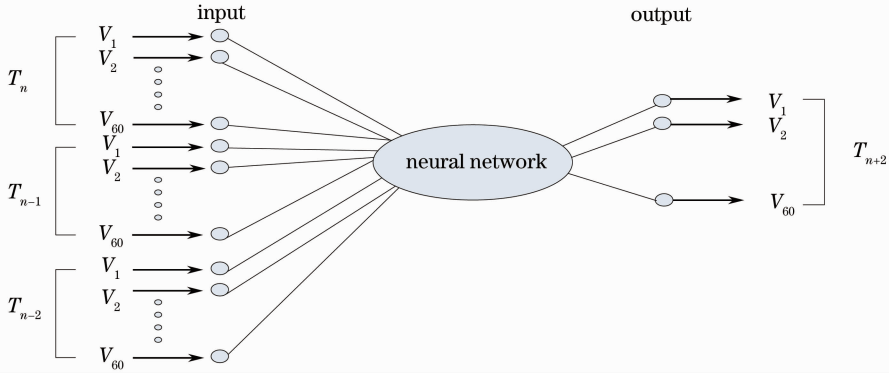


图 4 单模型多变量神经网络预测模型结构图

Fig. 4 Structure of single-model multivariate artificial neural network prediction model




图 5 多模型单变量神经网络预测模型结构图

Fig. 5 Structure of multi-model univariate artificial neural network prediction model

### 3.3 预测控制器的设计和工作原理

设计预测控制器的主要思想是充分利用计算机多核处理器的处理能力来实现预测模型的并行化计算,以此解决神经网络预测时的计算复杂度问题。预测控制器主要由一个控制组件和多个预测组件组成。控制组件负责与核心处理单元之间的通信和管理预测组件之间的调度顺序。预测组件利用基于 Levenberg-Marquardt 学习算法的 BP 神经网络来实现对驱动器电压的预测功能。对于拥有  $P$  个核心处理单元的计算机而言,训练数据到达预测控制器后,控制组件首先将训练数据按照变形镜上驱动器(总数为  $M$ )的布局进行分类,然后将分类好的数据

对应到  $M$  个不同的预测组件上,并按照一定顺序将  $M$  个预测组件分成  $P$  个队列,每个队列对应一个处理核心。这样  $P$  个预测组件可以在同一时刻被  $P$  个处理核心同时处理,实现预测控制器的并行化,加快预测控制器的执行效率。当每个处理核心计算完一个预测组件后,便会向控制组件发出空闲信号,这时控制组件负责把队列中的下一个预测组件分配给空闲的处理核心进行处理,直到队列中不再存在等待的预测组件。计算完毕后预测电压被传送到变形镜上进行波前校正。对于拥有 4 个核心处理单元的处理器而言,61 单元预测控制器详细内部结构如图 6 所示。

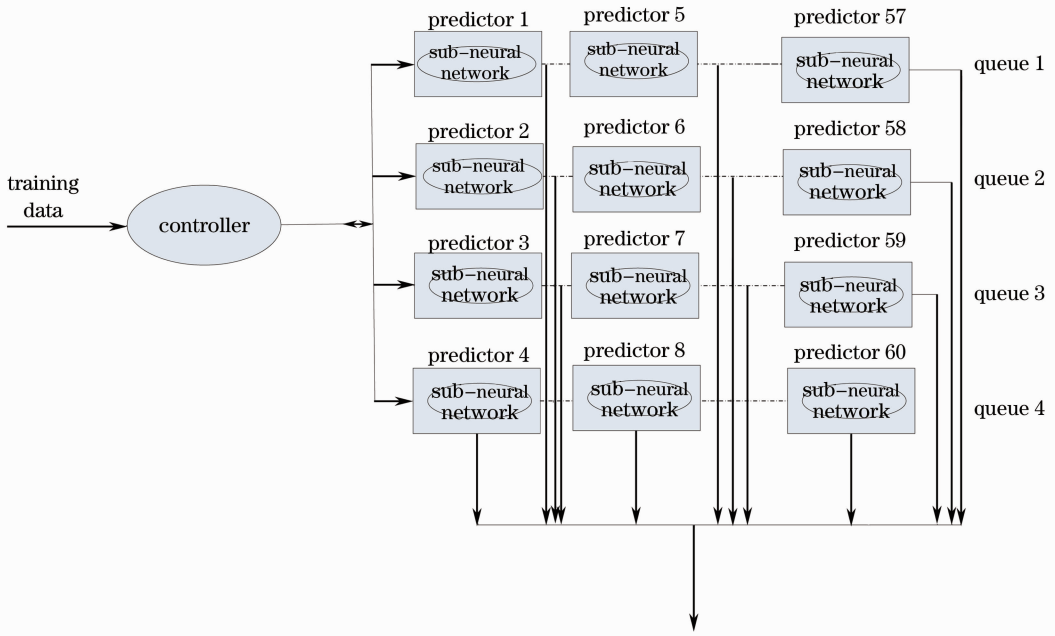


图 6 61 单元自适应光学预测控制器内部结构

Fig. 6 Inner structure of 61-element adaptive optics prediction controller

定义前  $N$  帧 ( $N \leq 200$ ) 作为仿真系统的预热阶段, 因为自适应光学系统在工作初期处于动态过程, 此时得到的控制电压信息波动较大。另外在预测控制器中定义一个可变大小的预测窗口。预测窗口的设立是为了保证每次训练网络时, 所用到的数据信息都是离当前时刻最近的电压信息, 这样可以保证由预测电压得到的校正面形能够跟得上大气湍流的动态变化过程, 保证电压预测的有效性。之所以将预测窗口设计为可变大小, 是因为神经网络在初次训练的时候往往需要大量的训练样本, 当经过第一次大规模训练后, 网络得到充分训练, 网络参数也趋

于稳定。随后预测窗口自动缩小并保持不变, 同时相应地减少迭代次数、缩短预测时间, 提高预测运算的速度。因此预测窗口刚开始选择一个比较大的数值  $d_1$ , 在接下来的预测中设置预测窗口大小为  $d_2$  ( $d_2 < d_1/2$ )。预测控制器的工作流程如图 7 所示, 当系统过了预热阶段, 预测窗口数据采集量达到窗口大小时, 网络便开始训练。训练结束以后利用训练好的网络和当前时刻的电压信息进行提前  $Q$  帧的电压预测。对于利用回溯 3 帧的控制电压来进行前推 2 帧电压预测的预测控制器, 其工作原理如图 7 所示。




图 7 回溯 3 帧, 前推 2 帧的预测控制器工作原理

Fig. 7 Principle diagram of prediction controller (look-back 3 frames and predict 2 frames)

## 4 数值仿真实验与分析

### 4.1 仿真条件

对口径 1.2 m (中心遮拦 40%) 望远镜中的 61

单元自适应光学系统在有无预测控制器情况下的性能进行数值仿真分析。观测目标为距地面垂直距离  $3.6 \times 10^4$  km 的静止目标, 目标波长为  $0.55 \mu\text{m}$ , 地

球大气层高度为 30 km, 设置 15 个湍流相屏层, 其中 1 km 以下每隔 200 m 设置一个湍流相屏层, 1~10 km 每隔 2 km 设置一个湍流相屏层, 10~30 km 每隔 3.8 km 设置一个湍流相屏层。大气湍流的功

率谱模型为 Von Karman 谱。大气折射率结构常数  $C_n^2$  随海拔高度  $H$  (单位: cm) 分布的物理模型如下式所示:

$$C_n^2(H) = 3.5 \times 10^{-28} \left( \frac{H}{1 \times 10^5} \right)^{160} \exp\left(-\frac{H}{7.8 \times 10^4}\right) + 1.0 \times 10^{-16} \exp\left(-\frac{H}{4.8 \times 10^5}\right) + 4.1 \times 10^{-15} \exp\left(-\frac{H}{0.8 \times 10^4}\right). \quad (2)$$

采用 Buffton 风速模型, 如下式所示, 大气相干长度  $r_0 = 8.72$  cm, 格林伍德频率  $f_G = 50.63$  Hz,

$$V = V_g + 30 \exp\{-[(H/100 - 9.4 \times 10^3)/4800]^2\}, \quad (3)$$

式中平均风速  $V_g = 2.2067$  m/s。

大气湍流的生成采用谱反演法, 移动采用经典的拖动法。首先根据谱反演法生成一个很大的符合 Von Karman 谱统计规律的相屏, 然后选择一个较小的有效口径区域, 每次迭代时根据风速计算出相屏的移动距离, 拖动相屏的移动, 生成一系列符合动态大气湍流统计特性的像差数据。

61 单元自适应光学系统结构如图 2 所示, 有 54 个子孔径的哈特曼传感器 CCD 采样频率为 838 Hz,

从哈特曼传感器探测到变形镜校正的时间延迟为 3 帧。计算网格为  $256 \times 256$ , 每个子孔径网格数为  $14 \times 13$ 。PI 控制系数  $a_0 = 0.99, b_0 = 0.45$ 。神经网络隐含层节点数为 22, 采用 Levenberg-Marquardt 学习算法。预测控制器的初始采样窗口大小为 500 帧, 经过训练后的窗口大小变为 50 帧, 仿真实验共进行  $1 \times 10^3$  帧迭代, 其中前 100 帧为系统的预测阶段。实验利用 4 帧的电压回溯信息, 对变形镜上的控制电压进行前推 3 帧预测。仿真模型如图 8 所示。




图 8 自适应光学负反馈预测控制系统仿真模型

Fig. 8 Simulation model of negative feedback adaptive optics prediction control system

图 8 中  $\phi_i$  表示经过大气湍流的扰动波前,  $\phi_c$  是经过 AO 处理的补偿波前,  $\phi_e$  是波前残差,  $g_e$  是经过哈特曼传感器探测得来的波前斜率残差,  $V_e$  为经过直接斜率法计算得来的复原电压,  $V$  为复原电压经过 PI 算法计算的控制电压,  $V_c$  为进一步经过预测控制器 P 计算得来的预测控制电压,  $z$  是复平面上定义的一个复变量, 通常称为  $z$  变换算子,  $d$  为系统响应时间延迟。

#### 4.2 预测控制器对变形镜控制电压的影响

延迟电压、预测电压和实时电压之间残差的计算公式为

$$E_{\text{lag}} = \langle \langle [V_i^{d=0}(t) - V_i^{d=n}(t)]^2 \rangle \rangle^{1/2}, \quad (4)$$

$$E_{\text{pre}} = \langle \langle [V_i^{d=0}(t) - V_{c,i}^{d=n}(t)]^2 \rangle \rangle^{1/2}, \quad (5)$$

式中  $V_i^{d=n}(t)$  为系统在延迟  $n$  帧的情况下, 第  $i$  个驱动器在  $t$  时刻的控制电压值;  $V_{c,i}^{d=n}(t)$  为系统在延迟  $n$  帧的情况下, 第  $i$  个驱动器在  $t$  时刻的预测控制电

压值;  $\langle \cdot \rangle$  为系统平均或者时间平均;  $E_{\text{lag}}$  为在无预测控制器 P 作用下的电压残差,  $E_{\text{pre}}$  表示使用预测控制器 P 后的电压残差。通过比较  $E$  值的大小来评价算法的优劣性,  $E$  值越小说明计算得到的控制电压值越接近于扰动电压。

700 帧时 61 单元自适应光学系统控制电压在不同情况下的分布如图 9 所示, 图 9(a) 是 60 个驱动器在 700 帧时的无延迟实时电压, 未采用预测控制器时 PI 控制算法计算所得延迟电压和经过预测控制器处理得到的预测电压分布情况, 图 9(b) 是 700 帧时延迟电压、控制电压与实时电压相比的绝对误差分布情况。其中单纯采用 PI 控制算法计算所得电压残差为 1.84。采用预测控制器以后, 系统的电压残差为 1.50。从图中可以看出基于 Levenberg-Marquardt 学习算法的神经网络预测模型具有很好的学习能力, 通过网络的学习和预测, 使系统的控制电压残差降低

了 18.5%。图 9(b) 中所示的边缘驱动器如 26, 57, 60 号驱动器与位于中心的驱动器相比, 在神经网络训练当中由于布局的关系, 可利用的周边驱动器信

息量较少, 因此导致部分边缘驱动器预测电压不如经典 PI 控制算法直接计算的效果好。

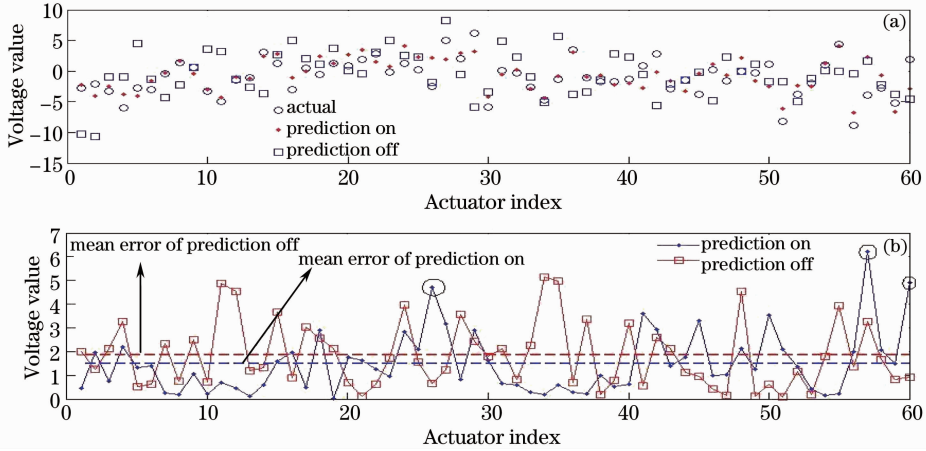


图 9 700 帧时变形镜上电压分布。(a) 无延迟实时电压、延迟电压和预测电压分布; (b) 延迟电压和预测电压相对于无延迟实时电压的绝对误差

Fig. 9 (a) Voltage values of 60 actuators without delay, with delay and prediction at the 700th frame; (b) absolute errors of the cases with prediction off and on relative to the value without delay at the 700th frame

21 号驱动器 800 帧到 1000 帧间的实时电压、延迟电压、预测电压以及绝对误差变化情况如图 10 所示。图 10(a) 是 21 号驱动器 800 帧到 1000 帧无延迟电压、延迟电压以及预测控制电压变化情况, 图 10(b) 是在 800 到 1000 帧间, 预测电压和延迟电压相比于实时电压的绝对误差变化情况。其中单纯采用 PI 控制算法的 21 号驱动器在 800 帧到 1000 帧间的电压残差为 1.43, 采用预测控制器的电压残差下降到 1.21。从图中可以看出, 采用预测控制器计

算所得电压值要比仅使用经典 PI 控制算法得到的电压值更加接近于无延迟实时电压, 经计算可知预测控制器相比于 PI 控制算法使电压残差降低了 15.4%。这说明预测控制器采用的神经网络模型具有很好的泛函能力, 能够很好地预测到前推 3 帧时刻的电压值。通常大气湍流的相干时间长度很短, 当预测窗口正好处于临界点时, 由于采集的信息过时, 会导致预测控制器的预测误差较大, 如图 10(b) 中所示, 在 803, 887, 908, 965 帧附近。但随着预测

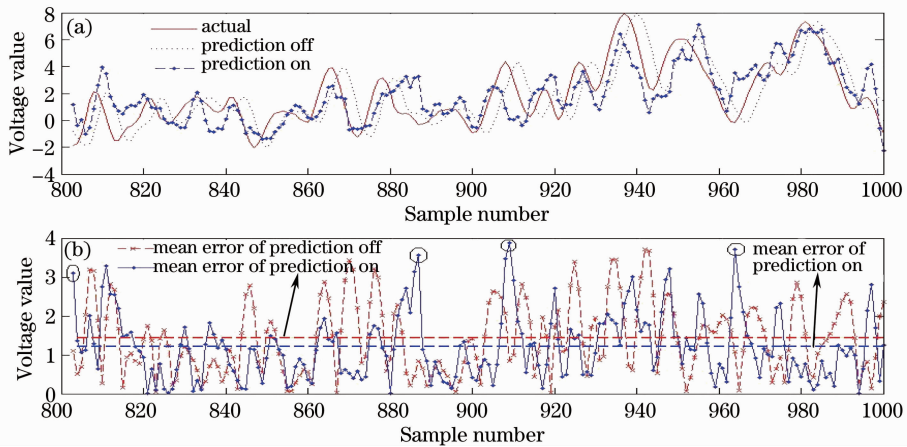


图 10 800~1000 帧时 21 号驱动器电压分布。(a) 无延迟实时电压, 延迟电压和预测电压分布; (b) 延迟电压和预测电压相对于无延迟实时电压的绝对误差

Fig. 10 (a) Voltage values of the 21st actuator without delay, with delay and prediction between the 800th and 1000th frames; (b) absolute errors of the cases with prediction off and on relative to the value without delay during this period

窗口的移动,采集的信息也逐渐准确,预测控制器的性能因此也得到改善。

### 4.3 预测控制器对远场靶平面成像的影响

在大气光学中常用斯特雷尔(Strehl)比作为评价光束大气传输效果的品质参数。对于文中的模拟计算采用两种不同 Strehl 比:Str 为靶面上最亮点的光强与真空传输时所得到的艾里斑中心光强之比;StrAA 为以靶面上最亮点为圆心,真空传输得到的艾里斑第一暗环尺寸为直径的圆内光强积分与大气传输同样直径内光强积分的环围能量之比。实验采用长时间曝光 Strehl 比作为平均计算结果,即把多次湍流所得的靶平面上的光强分布叠加在一起,然后对总平均光强的分布求出最亮点的位置和环围能量的大小,进而求出 Strehl 比。

图 11 是本次实验在运行  $1 \times 10^3$  帧后得到的靶

平面光场的纵截面曲线及光强的二维分布,望远镜在未使用自适应光学系统时,远场靶平面的光强分布如图 11(a)所示,由于大气湍流的扰动作用,靶平面的光强发散严重,光强最亮点长时间曝光的峰值 Strehl 比平均值为 0.009,最亮点环围能量 Strehl 比的平均值为 0.048。在望远镜使用 AO 系统后,经过 AO 闭环校正,远场靶平面的光场得到明显改善,Str 和 StrAA 分别为 0.084 和 0.251,如图 11(b)所示。当在自适应光学闭环系统中增加预测控制器以后,由于预测控制器的预测作用,有效地避免了自适应光学系统时间延迟的影响,波前校正残差得到更进一步的缩小,系统的性能也随之得到提升,远场光强的 Str 和 StrAA 分别提升了 26.2%和 35.1%,光强聚集效果更加明显,如图 11(c)所示。

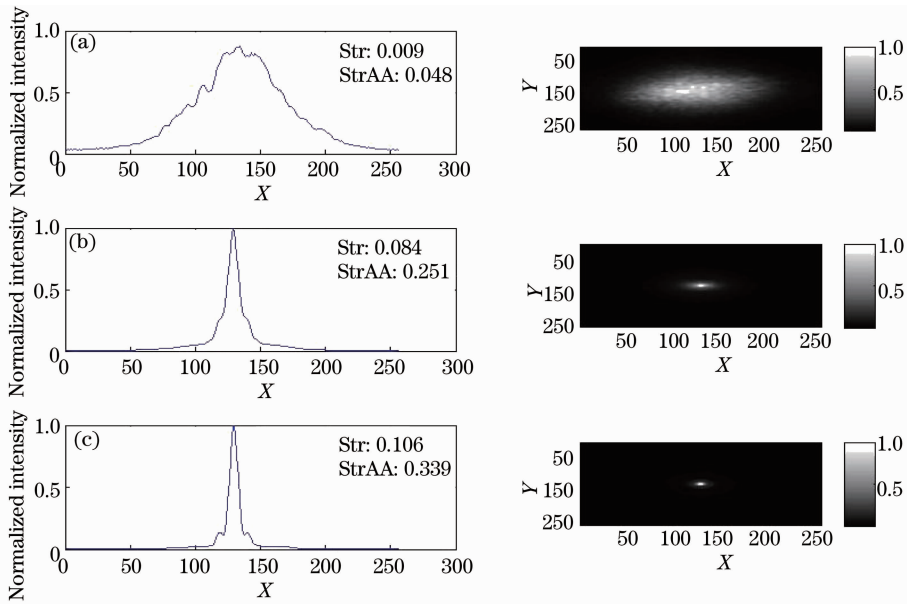


图 11 靶平面成像及光强的纵截面图。(a)无 AO 系统;(b)使用 PI 控制算法的 AO 闭环;(c)有预测控制器的 AO 闭环系统

Fig. 11 Images and its profile charts of the observation target along y axis. (a) Without AO; (b) with AO correction; (c) with prediction controller

### 4.4 预测控制器计算延迟对校正效果的影响

由于在传统 AO 系统中加入了预测控制器 P,增加了原有系统的计算复杂度,考虑到预测控制器需要占据一定的计算延迟,因此,这里在原有 AO 系统响应时间延迟为 3 帧不变的基础上,通过假设预测控制器的计算延迟  $T$  分别为 1,2,4 帧时,观察远场 Str 和 StrAA 的变化情况,来评估引入预测控制器对系统校正效果的影响。

图 12 分别是预测控制器计算延迟分别为 1,2,4 帧时,实验动态迭代  $1 \times 10^3$  帧后所得的靶平面光

强纵截面图。从图 12 中可以看出,与未考虑预测控制器计算延迟的情况[如图 11(c)]相比:当预测控制器计算延迟占系统响应时间延迟的 25%(即  $T=1$  frame)时,靶平面 Str 几乎没有发生变化(Str 为 0.105),StrAA 由 0.339 下降到 0.312,如图 12(a)所示;当预测控制器的计算延迟增加至占系统响应时间延迟的 40%( $T=2$  frame)时,靶平面的 Str 和 StrAA 已经发生明显变化,分别下降了 9.4%和 18.9%,如图 12(b)所示,但仍然优于使用 PI 控制算法的 AO 闭环系统(Str 为 0.084,StrAA 为



0.251);特别是如图 12(c)所示,在  $T=4$  frame 时,靶平面的 Str 和 StrAA 分别下降到 0.059 和 0.212,带有预测控制器的 AO 闭环系统校正性能已经低于使用 PI 控制算法的 AO 闭环系统。上述分析说明,对于带有预测控制器的 AO 闭环系统而言,预测控制器本身计算复杂度的大小对于系统的校正性能有一定的影响。当预测控制器的计算延迟超出系统响

应时间延迟 50%以上时,系统的校正能力和成像质量已经表现出低于无预测控制器系统的性能。因此,要求设计的预测控制器具有响应时间短、预测算法计算速度快的特点。而并行化技术和计算机多核处理器的运用可以有效缩短预测算法的计算时间,提高预测控制器的响应时间。

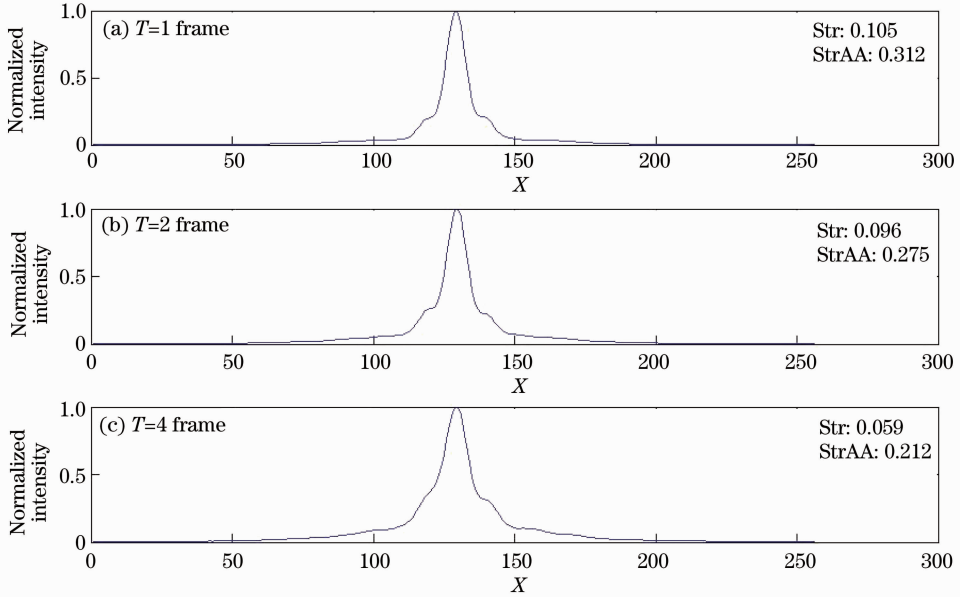


图 12 不同预测控制器计算延迟  $T$  作用下,靶平面光强的纵截面图

Fig. 12 Profile charts of the observation target along  $y$  axis according to the different calculating times ( $T$ ) of predictive controller

#### 4.5 预测算法的并行化效率分析

实验采用主流的 Intel 多核计算平台,具体配置如下。

Operation system: Microsoft Windows XP Professional 32 bit

Experimental environment: Matlab2011(a)

CPU: Intel Core i7-2600 (Quad-core, eight thread)

CPU clock frequency: 3.40 GHz

L1 Cache (dual-channel):  $2 \times 32 \text{ kB} \times 4$

L2 Cache: 256 kB  $\times 4$

L3 Cache: 8 MB

Memory: 4096 MB DDR3, 1333 MHz

这里定义预测控制器的加速比  $S_p$  为

$$S_p = T_1 / T_p, \quad (6)$$

式中  $T_1$  为单处理器下的运行效率,  $T_p$  为在有  $p$  个处理器并行系统中的运行时间。

使用并行化的多模型单变量预测算法来预测变

形镜上全部 60 个驱动器电压的运行性能,如图 13 所示,其中神经网络隐含层节点数为 22,输出层节点数为 1,采用 Levenberg-Marquardt 学习算法。图 13(a)为使用单核时,预测算法以串行化方式执行,CPU 的使用率和各个核心的运行情况记录。这时 CPU 的平均使用率为 26%,只有 1 个处理核心得到利用,其他 3 个并没有得到很好的利用,算法的并行性能完全没有得到发挥。在 2 核和 3 核情况下,CPU 的利用率同样也没有达到理想的效果,分别为 50%和 76%,预测算法的并行化程度也不是最佳。当在 4 核情况下运行时,系统的多核性能和算法的并行性在现有条件下得到最大程度的发挥。这时 CPU 的平均使用率达到了 100%,4 个核心全部运行在满负荷状态,如图 13(d)所示。从图 14 中可以看出,随着处理核心的增加,预测控制器的并行化程度得到不同程度的加强,当使用 2 个处理核心时近似达到 2 倍的线性加速度,当处理核心的数量为 3 和 4 时,预测算法的加速比分别为 2.72 和 3.73。

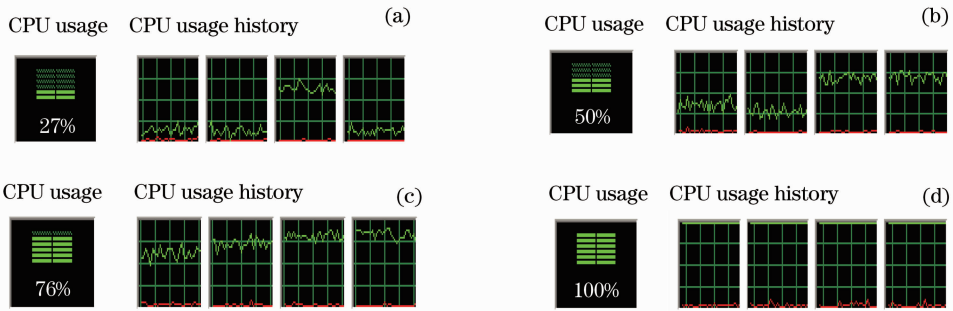


图 13 使用不同处理核心运行多模型单变量预测算法时的任务管理器。(a) 1 核; (b) 2 核; (c) 3 核; (d) 4 核  
Fig. 13 Running diagram of task manager when running the multi-model univariate prediction algorithm. (a) One core; (b) two cores; (c) three cores; (d) four cores




图 14 多模型单变量预测算法的加速比  
Fig. 14 Speedup diagram of multi-model univariate prediction algorithm

## 5 结 论

提出了一种多模型单变量神经网络预测模型,利用计算机的多核处理器,设计了一个并行化的自适应光学预测控制器。在对实际大气传输中的场景进行仿真的基础上,对使用预测控制器与使用经典PI控制算法得到的控制电压进行了仿真对比,讨论了使用预测控制器以及本身计算延迟时间的变化对远场靶平面 Strehl 的影响,并研究了预测控制器的并行化性能。仿真结果表明,使用预测控制器可以有效减少系统由伺服延迟引起的误差,并且利用并行化技术,可以缩短预测控制器的预测时间,进一步提高预测控制器的性能,克服了利用神经网络进行电压预测时计算复杂度高的缺点。如何使预测控制器始终保持较优的预测效果,以及考虑在加入噪声的情况下对使用预测控制器的自适应光学系统动态性能进行分析将是下一步工作的重点。同时,进一步提高预测控制器的运算速度也是关注的重点。

## 参 考 文 献

- 1 R. K. Tyson. Principles of Adaptive Optics [M]. San Diego: Academic Press, 1991. 1~23, 53~97
- 2 Jiang Wenhan, Zhang Yudong, Rao Changhui *et al.*. Progress on adaptive optics of Institute of Optics and Electronics, Chinese Academy of Sciences[J]. *Acta Optica Sinica*, 2011, **31**(9): 0900106  
姜文汉, 张雨东, 饶长辉等. 中国科学院光电技术研究所的自适应光学研究进展[J]. *光学学报*, 2011, **31**(9): 0900106
- 3 Li Min, Chen Bo, Li Xinyang *et al.*. Close-loop experiment of an adaptive optics system on the dynamic aberrations based on linear phase retrieval technique[J]. *Chinese J. Lasers*, 2010, **37**(4): 954~958  
李敏, 陈波, 李新阳等. 基于线性相位反演技术的自适应光学动态像差校正闭环实验研究[J]. *中国激光*, 2010, **37**(4): 954~958
- 4 Li Xinyang, Jiang Wenhan. Analysis of the residual servo variance for an adaptive optics system[J]. *Acta Optica Sinica*, 2000, **20**(10): 1328~1334  
李新阳, 姜文汉. 自适应光学系统的控制残余方差分析[J]. *光学学报*, 2000, **20**(10): 1328~1334
- 5 M. B. Jorgenson, G. J. M. Aitken. Prediction of atmospherically induced wave-front degradations[J]. *Opt. Lett.*, 1992, **17**(7): 466~468
- 6 L. C. Johnson, D. T. Gavel, D. M. Wiberg. Bulk wind estimation and prediction for adaptive optics control systems [J]. *J. Opt. Soc. Am. A*, 2011, **28**(8): 1566~1577
- 7 L. Poyneer, J. P. Véran. Predictive wavefront control for adaptive optics with arbitrary control loop delays[J]. *J. Opt. Soc. Am. A*, 2008, **25**(7): 1486~1496
- 8 M. R. D. Montera, B. Welsh, D. Ruck. Processing wave-front slope measurements using artificial neural networks [J]. *Appl. Opt.*, 1996, **35**(21): 4238~4251
- 9 R. M. Brockie, M. Wells, P. Gallant *et al.*. Predictors in the servo-loop of an AO system [C]. *SPIE*, 1998, **3353**: 1186~1192
- 10 P. J. Gallant, G. J. M. Aitken. Genetic algorithm design of neural network wavefront predictors [C]. *SPIE*, 2003, **4884**: 282~290
- 11 W. J. Wild. Predictive optimal estimators for adaptive optics systems [J]. *Opt. Lett.*, 1996, **21**(18): 1433~1435
- 12 C. Dessenne, P. Y. Mader, G. Rousset. Modal prediction for closed-loop adaptive optics [J]. *Opt. Lett.*, 1997, **22**(20): 1535~1537
- 13 Chao Liu, Lifa Hu, Zhaoliang Cao *et al.*. Zonal slope prediction for open-loop adaptive optics [J]. *Opt. Lett.*, 2011, **36**(22):

4461~4463

- 14 Zhang Xiujian, Li Xinyang, Zhang Huimin. Prediction algorithm for atmosphere turbulence with control voltage of deformable mirror [J]. *High Power Laser and Particle Beams*, 2006, **18**(5): 757~760  
张秀娟, 李新阳, 张慧敏. 利用复原电压预测大气湍流畸变波前方法[J]. *强激光与粒子束*, 2006, **18**(5): 757~760
- 15 Yan Zhaojun, Li Xinyang. Neural network prediction algorithm for control voltage of deformable mirror in adaptive optical system

[J]. *Acta Optica Sinica*, 2010, **30**(4): 911~916

- 颜召军, 李新阳. 基于神经网络的自适应光学系统变形镜控制电压预测方法[J]. *光学学报*, 2010, **30**(4): 911~916
- 16 Yan Zhaojun, Li Xinyang, Rao Changhui. Numerical simulation of a prediction control algorithm for close-loop adaptive optical system[J]. *Acta Optica Sinica*, 2011, **31**(1): 0101003  
颜召军, 李新阳, 饶长辉. 一种自适应光学闭环系统预测控制算法的仿真研究[J]. *光学学报*, 2011, **31**(1): 0101003

栏目编辑: 王晓琰