

自适应光学系统的自学习控制模型及其验证

许振兴^{1,2,3,4**}, 杨平^{1,3,4*}, 程涛^{1,3,4}, 许冰^{1,3,4}, 李和平²

¹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;

²电子科技大学光电科学与工程学院, 四川 成都 610054;

³中国科学院光电技术研究所, 四川 成都 610209;

⁴中国科学院大学, 北京 100039

摘要 在自适应光学系统中,传统比例-积分控制模型依赖于变形镜的响应矩阵,系统状态的改变会对变形镜响应矩阵造成影响,导致波前校正性能下降。通过重新定义 BP(back-propagation)神经网络结构实现哈特曼斜率数据到控制信号的输出,并建立了控制模型。实验结果表明,所提模型摆脱了传统固定模型的限制,具有在线更新控制模型的特点,控制模型收敛性能良好,能适应系统状态变化,有较强的鲁棒性,同时提高了控制精度,一定程度上改善了控制性能。

关键词 自适应光学; 神经网络; 响应矩阵; 波前校正

中图分类号 TP183

文献标志码 A

doi: 10.3788/CJL202047.0105001

Self-Learning Control Model for Adaptive Optics Systems and Experimental Verification

Xu Zhenxing^{1,2,3,4**}, Yang Ping^{1,3,4*}, Cheng Tao^{1,3,4}, Xu Bing^{1,3,4}, Li Heping²

¹Key Laboratory on Adaptive Optics, Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;

²School of Optoelectronic Science and Engineering, University of Electronic Science and Technology of China, Chengdu, Sichuan 610054, China;

³Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;

⁴University of Chinese Academy of Sciences, Beijing 100039, China

Abstract In adaptive optics systems, the traditional proportional-integral control model relies on the response matrix of the deformable mirror, which is sensitive to changes in the system state. When the response matrix is altered, the wavefront correction performance is degraded. In this paper, the output of control signal from Hartman slope data is realized by redefining the back-propagation neural network structure, and a control model is established. Experimental results show that the proposed model eliminates the limitation of the traditional fixed model and acquires the characteristics of an online real-time update response model. The control model delivers high convergence performance, can adapt to environmental changes, and is robust. It also improves the control precision and the control performance to a certain extent.

Key words adaptive optics; neural network; response matrix; wavefront correction

OCIS codes 010.1080; 110.1080; 140.3300

1 引言

自适应光学系统一般采用哈特曼(H-S)波前传感器来测量像差斜率数据,然后计算控制电压,并驱

动变形镜对像差进行补偿,从而改善光束质量^[1-3]。在这些控制系统中,比例积分(PI)控制是最直接的方法,并取得了良好的控制效果。传统PI控制严格依赖于变形镜的响应矩阵,当建立的模型出现偏差

收稿日期: 2019-06-26; 修回日期: 2019-07-22; 录用日期: 2019-09-26

基金项目: 国家自然科学基金(61805251,61875203)、中国科学院青年创新促进会(2017429)

* E-mail: pingyang2516@163.com; ** E-mail: xyhf2009@foxmail.com

时需要变形镜的响应矩阵进行重新标定,来消除影响。由于变形镜的热惯性小,受温度影响显著,再加上对准误差等因素的影响,在实际运行过程中变形镜会偏离标定的响应模型。传统离线标定方法采用了变形镜的静态数据,未考虑时变因素的影响,不能准确描述实际运行状态下变形镜的响应模型^[4-5],在一个时刻测量的响应矩阵,在另外时刻可能会不准确,从而降低了 PI 控制器的性能。以随机并行梯度下降(SPGD)算法^[5]为代表的无模型算法包含了变形镜的当前运行状态信息和斜率差分信息,能够感知系统运行状态的变化,蕴含系统模型信息,并以随机化、并行化优化控制性能指标。但是 SPGD 算法迭代次数过多,难以满足大带宽要求。

本文利用由 SPGD 得到的系统状态信息和斜率差分信息,对重新定义的神经网络进行梯度引导。

神经网络是模拟人脑思维方式的数学模型,是 20 世纪 80 年代末期发展起来的自动控制领域的前沿科学之一,是智能控制领域的一个重要分支^[6-9]。在不牺牲控制带宽的前提下,为了使控制模型能够自适应响应模型的变化同时提高控制精度,提出了基于梯度反向传播的自学习控制(NI)模型用于控制变形镜。梯度反向传播是神经网络能学习映射关系的基石,本文提出的 NI 模型由前馈网络、代价函数、样本空间和梯度估计构成。NI 模型兼顾收敛速度和自适应性,可根据变形镜的实际状态在线自学习控制模型,具有自学习能力,同时可提高控制精度。

2 基本原理

2.1 典型控制方法

典型自适应光学控制系统如图 1 所示。

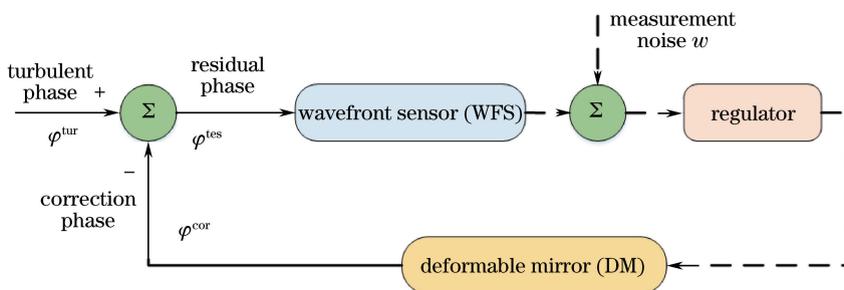


图 1 典型自适应光学系统

Fig. 1 Typical adaptive optical systems

由图 1 可知,自适应光学系统由波前传感器(WFS)、变形镜(DM)与控制器组成。本文采用 H-S 波前传感器探测波前斜率信息,利用直接斜率法实现波前复原,所用控制器为 PI 控制器,由 PI 控制器输出的控制信号经过高压放大器使变形镜和倾斜镜产生需要的补偿。直接斜率法^[10-11]的基本原理如下:首先,通过 H-S 波前传感器得到质心斜率 \mathbf{S} ;其次,经过线性计算得到波前校正器的控制电压。若略去探测噪声,哈特曼子孔径斜率 \mathbf{S} 与控制电压 Φ 的关系可以描述为

$$\mathbf{S} = \mathbf{B}\Phi, \quad (1)$$

式中: \mathbf{B} 为变形镜与 H-S 传感器之间的斜率响应矩阵,可通过测量得到,通常根据对驱动器单元施加单位电压时的斜率响应获得。然后,利用奇异值分解求出响应矩阵 \mathbf{B} 的广义逆矩阵 \mathbf{B}^+ ,可得到最小二乘意义下斜率余量最小且控制能量也最小的控制电压:

$$\Phi = \mathbf{B}^+ \mathbf{S}. \quad (2)$$

得到残差波前的控制电压 Φ 后,利用 PI 控制器即可求解出加载至波前校正器的总控制电压。从(1)

式和(2)式可知,自适应光学系统的工作稳定性和误差传递与所采用的波前复原算法紧密相关。PI 控制器在 k 时刻施加于变形镜的控制电压 Φ_{end} 的计算公式为

$$\Phi_{\text{end}} = a\Phi(k-1) + b\Phi(k), \quad (3)$$

式中: a, b 为增益系数。将(2)式代入(3)式,得

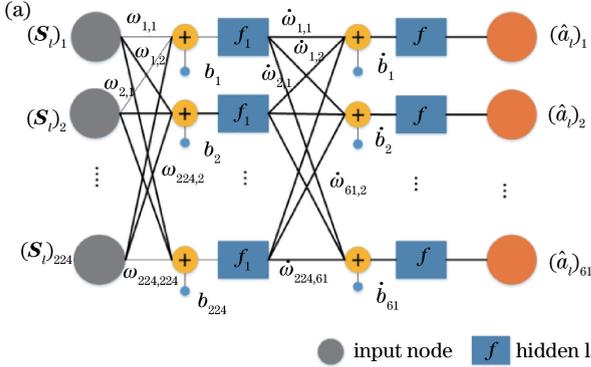
$$\Phi_{\text{end}} = \mathbf{B}^+ [a\mathbf{S}(k-1) + b\mathbf{S}(k)]. \quad (4)$$

由(4)式可知,控制电压 Φ_{end} 受到 \mathbf{B}^+ 的影响,根据张东阁等^[4]的研究,在系统实际运行中各种因素会使得响应矩阵 \mathbf{B}^+ 偏离最优,从而影响控制电压 Φ_{end} 的精度,这是因为 \mathbf{B}^+ 是根据稳态数据得到的,如果系统在运行过程中工作状态改变,则 \mathbf{B}^+ 并不能适应当前的系统状态。本文希望控制系统不仅能够反映当前系统状态,而且可以感知系统运行状态的变化。这要求响应矩阵 \mathbf{B}^+ 不能由稳态数据得到,而是需要根据系统实际运行过程中的动态数据得到。

2.2 自学习控制模型

为使提出的 NI 模型不牺牲控制带宽,又能在

一定程度上感知系统运行状态的变化,通过简化计算结构改进了 BP(back propagation)网络,同时定义了样本获取方式。图 2 所示为传统 BP 网络结构与改进后的网络结构^[12]。图 2(a)为标准多输入多输出 BP 网络,由输入层、隐含层和输出层构成。BP 网络是一种多层前馈网络,基于随机梯度下降法来训练网络,可以学习输入输出的映射关系,使得在线学习系统运行状态成为可能。 $\omega_{i,j}$ 和 $\dot{\omega}_{i,j}$ 为网络层



之间的权值(i 节点和 j 节点), b_j 为神经元的偏置(j 节点)。隐含层层数和激活函数的选择要从网络精度和训练时间综合考虑,对于较简单的映射关系可以选择单隐含层,以加快速度;对于复杂的映射关系,则可以选择多隐含层,以提高网络的预测精度。图 2(b)为改进后的网络模型,没有隐含层,输入层通过权值 θ 和偏置 b 连接输出层, $\theta_{i,j}$ 为网络层之间的权值(i 节点和 j 节点), b_j 为神经元的偏置(j 节点)。

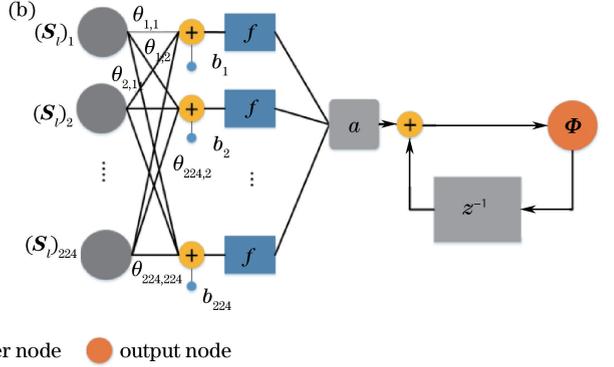


图 2 网络结构。(a)标准 BP 神经网络;(b)改进后的网络

Fig. 2 Network structures. (a) Standard BP neural network; (b) proposed network

激活函数 f 的选择方案有很多种,比如 sigmoid、tanh 函数等,但是 sigmoid、tanh 激活函数的计算量大,为了不影响控制带宽和动态在线更新模型,线性激活函数的优势变得很明显。事实上,没有隐含层的网络没有非线性映射能力,所以激活函数也没有被选择的必要。改进后的网络结构只需要系统实际运行过程中的动态数据,就可以方便快速地训练模型。图 2(b)中网络输入 $S(k)$ 为 k 时刻的质心斜率向量,网络输出 $\Phi_\theta[S(k)]$ 经滞后环节 z^{-1} 变为 $\Phi_\theta[S(k-1)]$,展开得到模型输出 Φ :

$$\Phi = \Phi_\theta[S(k-1)] + a\Phi_\theta[S(k)], \quad (5)$$

参数 a 的选择非常重要,参数 a 越大,系统收敛越快,同时也可能导致超调量大,系统闭环不稳定。对于实际系统,选择合适的参数 a ,可以保证系统稳定。通过(5)式定义的网络结构,需要实现在线采集样本和网络训练。

2.3 构建样本空间和梯度估计

自适应光学系统 t 时刻的控制电压 Φ_t 和斜率 S_t 的关系式可表示为

$$\Phi_t = \mathbf{R}S_t, \quad (6)$$

式中: \mathbf{R} 为变形镜与哈特曼传感器之间的斜率响应矩阵。添加一个扰动电压 $\Delta\Phi_t$, 可得到

$$\Phi_t + \Delta\Phi_t = \mathbf{R}(S_t + \Delta S_t), \quad (7)$$

式中: ΔS_t 为斜率扰动量。(7)式减去(6)式,可以在

线得到训练样本 $(\Delta\Phi_t, \Delta S_t)$ 。按照系统运行时间序列可以依次得到 t 至 $t+n$ 时刻的训练样本 $M = \langle (\Delta\Phi_t, \Delta S_t), (\Delta\Phi_{t+1}, \Delta S_{t+1}), (\Delta\Phi_{t+2}, \Delta S_{t+2}), \dots, (\Delta\Phi_{t+n}, \Delta S_{t+n}) \rangle$ ($\langle \cdot \rangle$ 表示样本空间), M 的样本空间大小为 n , 当样本空间 M 新增一个样本 $(\Delta\Phi_{t+n+1}, \Delta S_{t+n+1})$ 时,就去掉最旧样本 $(\Delta\Phi_t, \Delta S_t)$, M 为队列数据结构。在多次间隔采样更新之后,样本空间 M 保存了系统的实际运行数据,包含了当前变形镜的状态信息。

通过训练样本空间 M 可以使模型适应当前系统状态。样本空间 M 的学习使用梯度下降法来训练网络^[13],虽然这种学习方式可以方便地在线更新模型但是模型不够精确,等价于最小二乘下的线性映射,当前状态下学习到的映射只是近似估计。为了进一步提高模型精度,可以利用(7)式蕴含的梯度信息,进一步优化网络参数。具体来说,使用代价函数的梯度引导实现当前状态下更为精确的模型输出。

由 SPGD 算法^[14]可知,只要定义合适的代价函数便可以估计梯度。对于 H-S 波前传感器,当波前斜率信息残差最优时,波前残差校正达到最优,自适应光学系统波前校正的实质就是最小化残余波前。所以可以利用波前斜率信息 S_t 构建代价函数 J , 定义为

$$J(S_t) = \frac{\|S_t\|_2^2}{n \times 2}. \quad (8)$$

要使用代价函数 J 来引导网络更新就需要求解梯度 $\nabla_{\Phi} J$, 然后通过链式法得到模型输出 Φ 对网络参数 θ 的梯度:

$$\nabla_{\theta} J = \nabla_{\Phi} J \cdot \nabla_{\theta} \Phi(\theta), \quad (9)$$

使用梯度下降方法更新网络参数, 即

$$\theta = \theta - \epsilon \nabla_{\theta} J, \quad (10)$$

式中: ϵ 为学习速率。梯度估计的准确性直接影响系统的收敛性能, 是决定系统性能的核心因素。在自适应光学系统^[15]中, 有许多成熟的梯度估计方法, 从早期的爬山法^[16]和多变量高频振动法到 SPGD 算法。由 SPGD 算法可知, 只要计算扰动前后的代价函数 $J(S_i)$, 就可以得到梯度 $\nabla_{\Phi} J$ 。计算流程 1 如下:

- 1) 计算当前控制电压 Φ_i 的代价函数 $J(S_i)$;
- 2) 生成扰动电压 $\Delta\Phi_i$;
- 3) 加载 $\Phi_i + \Delta\Phi_i$ 控制电压并计算代价函数 $J(S_{i+1})$;
- 4) 得到梯度 $\nabla_{\Phi} J = [J(S_{i+1}) - J(S_i)] \Delta\Phi_i$ 。

通过上述流程可知, 网络输出只需要添加一次扰动电压 $\Delta\Phi_i$ 就可以得到样本 $(\Delta\Phi_i, \Delta S_i)$, 更新一次样本空间 M , 同时可以得到梯度 $\nabla_{\Phi} J$, 并通过 (10) 式更新一次网络参数。为了防止模型频繁进行

样本学习, 增加计算负担, 采用时间间隔 T 来对样本空间进行学习。

综上所述, NI 模型的实现流程如下:

- 1) 初始化网络 $\Phi(\theta)$ 及样本空间 M , 样本空间大小为 n ;
- 2) 网络 $\Phi(\theta)$ 输出控制电压 Φ_i ;
- 3) 通过流程 1 计算梯度 $\nabla_{\Phi} J$;
- 4) 计算梯度 $\nabla_{\theta} J = \nabla_{\Phi} J \nabla_{\theta} \Phi(\theta)$;
- 5) 得到样本 $(\Delta\Phi_i, \Delta S_i)$, 并更新样本空间 M ;
- 6) 更新网络参数 $\theta = \theta - \epsilon \nabla_{\theta} J$;
- 7) 返回步骤 2), 并间隔时间 T 后通过样本空间更新网络参数。

经过上述流程就可以实现在线更新模型并校正波前畸变。

3 实验与结果

本文使用实际自适应光学(AO)系统和数值计算相结合的方法来验证提出的 NI 模型, 实际系统所采用的结构如图 3 所示, 实际平台如图 4 所示。该实验平台由激光器、变形镜(DM1, DM2)、倾斜镜(TM)和复合传感器组成。图 3 中的 ψ, φ, φ 均表示波前函数。

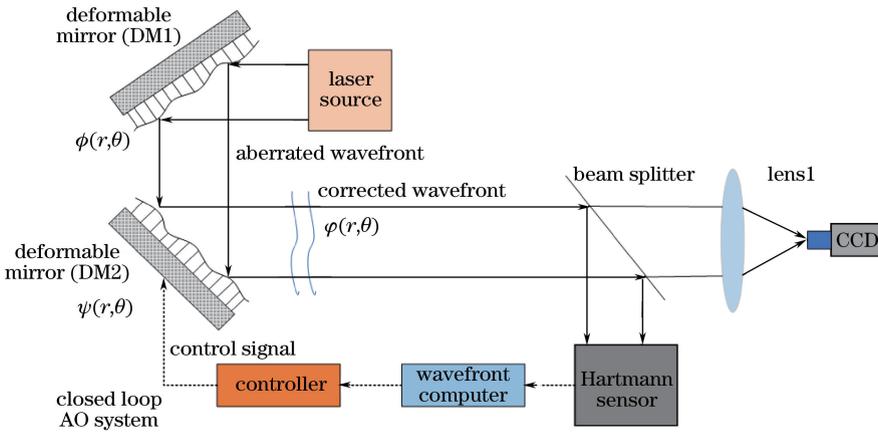


图 3 自适应光学硬件平台结构图

Fig. 3 Structural diagram of adaptive optical hardware platform

图 4 中光源采用 671 nm 的激光器, 激光束通过变形镜 DM1 入射到变形镜 DM2, 然后经 DM2 入射到复合传感器。变形镜 DM1 和 DM2 有 59 个驱动器单元, 其中 DM1 用来生成像差, DM2 用来校正 DM1 生成的像差, 倾斜镜用来校正倾斜。复合传感器由分光镜、H-S 波前传感器、远场 CCD 和近场 CCD 组成, 分光镜将一部分光束通过透镜聚焦到远

场 CCD, 远场 CCD 用来测量光束校正前后的光斑, CCD 的像素为 200 pixel × 200 pixel; H-S 波前传感器由 12 × 12 的透镜阵列和一个 372 pixel × 372 pixel 的 CCD 相机组成(每个子孔径大小为 31 pixel × 31 pixel), 其中 CCD 相机的采样频率为 500 Hz, 每个子孔径有两个测量方向: X 轴方向和 Y 轴方向。

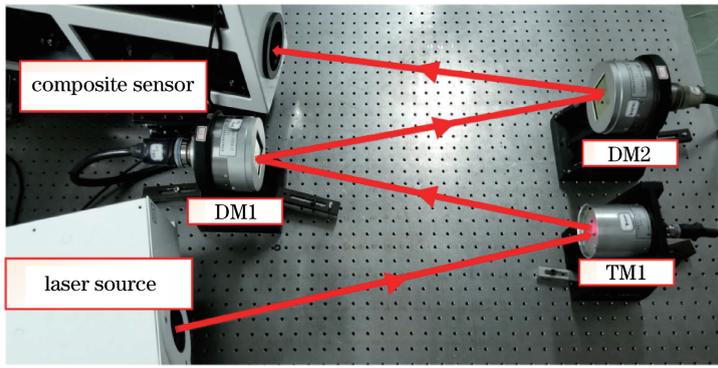


图 4 自适应光学硬件平台

Fig. 4 Adaptive optical hardware platform

为了比较 PI($a=0.98, b=0.1$)和 NI($a=0.1, \epsilon=0.0001$)两种控制模型,设置样本空间 \mathbf{M} 大小为 60, H-S 传感器采样频率为 100 Hz。首先随机生成用于驱动 DM1 的电压样本 100 个,作为模型的测试电压,将模型输出到 DM2 的电压作为校正电压。将两种模型得到的校正电压与实际电压的均方误差 (MSE) 作比较。对 100 组数据的 MSE 求取平均值,PI 模型校正的平均 MSE 为 6.387。

NI 模型通过样本数据在线更新,系统收敛后 NI 模型的平均 MSE 为 3.431。NI 模型校正电压的 MSE 比 PI 模型小,说明 NI 学到的模型要比 PI 好,模型输出的控制电压更接近于生成的测试电压。当系统运行一段时间后,对 NI 模型的网络参数进行可视化,发现 NI 模型的网络参数比广义逆矩阵 \mathbf{B}^+ 要平滑(图 5),对变形镜的驱动单元有更好的响应特性。

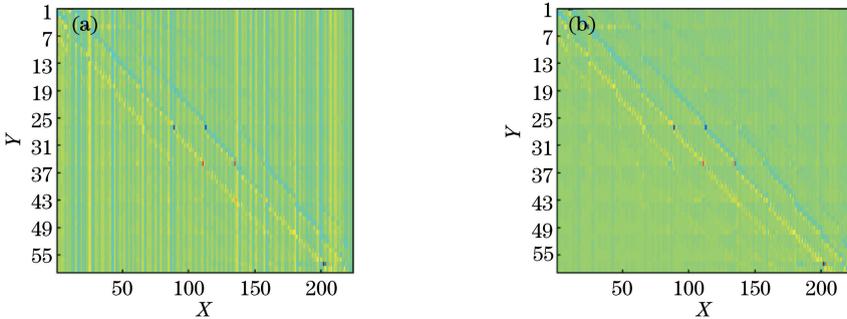


图 5 可视化参数。(a)可视化广义逆矩阵;(b)可视化自学习后的网络参数

Fig. 5 Visualized parameter. (a) Visualized generalized inverse matrix; (b) visualized network parameters after self-learning

实际 AO 系统通过 PI($a=0.98, b=0.1$)和 NI ($a=0.1, \epsilon=0.0001$)两种方法对系统进行像差校正,对校正的效果进行了比较,如图 6 所示。H-S 采样频率为 100 Hz,样本空间 \mathbf{M} 大小为 60,使用由波前斜率信息构建的代价函数 J 作为性能指标,指标 J 的值越小表示波前残差越小,校正效果越好,反之校正效果越差,结果如图 6 所示,显然 NI 模型的校正性能较好。常规 PI 模型的性能指标 J 的平均值为 0.882,标准偏差(Std)为 0.048,NI 的性能指标 J 的平均值为 0.807,Std 为 0.043,说明 NI 的校正精度比传统控制方法 PI 的要高,平稳性也更好。由 NI 的收敛曲线可以看出 NI 的收敛精度随着迭代次数的增加而慢慢提升,说明 NI 模型在梯度的引导下越来越精确,收敛精度也随之提升。图 7 所示为

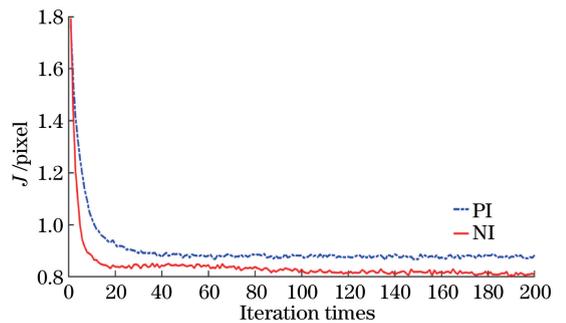


图 6 实际 AO 系统下 PI 和 NI 模型的校正性能

Fig. 6 Correction performances of PI and NI models under actual AO system

两种方法对系统像差校正后的斯特尔比(SR)值,其中 NI 的 SR 值为 0.967,PI 的 SR 值为 0.921,相对于 PI 校正后的 SR 值,NI 校正后的 SR

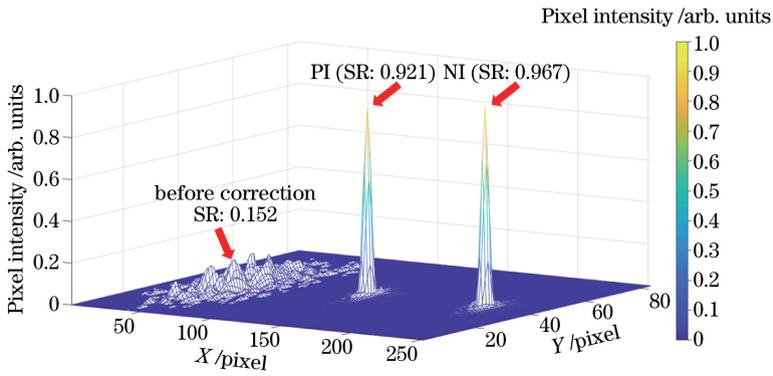


图 7 系统收敛后 PI 和 NI 模型的 SR 值

Fig. 7 SR values of PI and NI models after system convergence

值提高了 0.046。

由于传统的离线标定方法采用了变形镜的静态数据,未考虑时变因素的影响,不能准确描述实际运行状态下变形镜的响应模型,为了验证 PI 和 NI 的性能差异,通过数值计算的方式随机产生时变对准误差,并将其用于闭环校正,设变形镜的驱动单元间距为 d ,变形镜与哈特曼传感器随机产生水平对准误差 Δx ,垂直对准误差 Δy 和旋转对准误差 $\Delta \alpha$,误差范围为 $[-4d, 4d]$ 。其中 PI 的参数设置为 $a =$

$0.98, b = 0.1$, NI 的参数设置为 $a = 0.1, \epsilon = 0.0001$ 。当控制周期开始时每迭代 10 次随机产生一次对准误差,以检验控制模型对系统产生偏差时的自适应性,结果如图 8 所示。常规 PI 的性能指标 J 的 Std 为 1.755, SR 值的 Std 为 0.366, 计算时间为 0.053 ms。NI 的性能指标 J 的 Std 为 0.606, SR 值的 Std 为 0.082, 有效计算时间为 0.042 ms(模型前向计算时间和反向计算时间的平均值),表明 NI 模型比 PI 模型具有更高的稳定性。

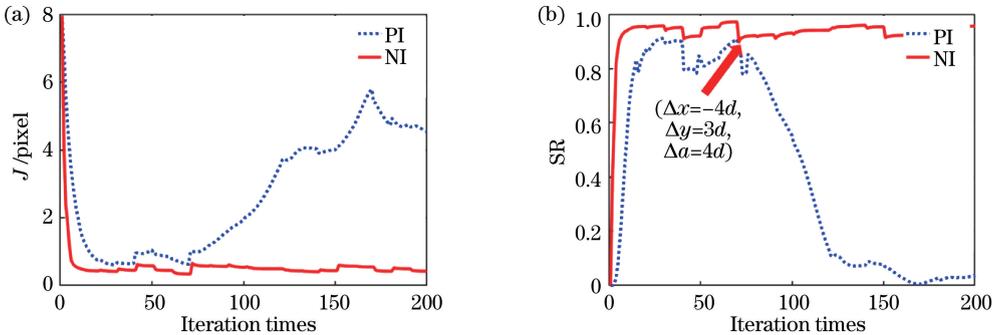


图 8 控制模型收敛性能。(a)系统产生随机对准误差时指标 J 的迭代过程;(b)系统产生随机对准误差时 SR 的迭代过程

Fig. 8 Convergence performance of control model. (a) Iterative process of index J when system produces random alignment error; (b) iterative process of index SR when system produces random alignment error

图 8(b)箭头指出如果对准误差太大,则会导致 PI 闭环不稳定,这是因为静态测量的响应矩阵不适应当前系统状态,使得控制对象偏离控制目标,控制模型 NI 在箭头位置虽然性能突降,但通过自学习保证了自适应性,在控制带宽不受影响的情况下,保持了控制稳定性和控制精度。

采集样本并学习样本,模型不需要标定变形镜的响应矩阵,因此无需对其响应矩阵进行校准。质心斜率所定义的成本函数关系到控制精度,虽然所提模型需要收集样本和估计梯度,但并不影响在线操作,同时适当地采用并行结构可以进一步提升计算速度,提高模型训练效率。

4 结 论

提出的控制模型具有良好的收敛性和控制精度,控制系统能够感知系统运行状态的变化,提高了系统的自适应性。采用稳定的梯度估计方法是提高学习效率、保证模型稳定的关键。控制模型可在线

参 考 文 献

[1] Zheng Z Y, Li C W, Li B M, et al. Analysis and demonstration of PID algorithm based on arranging the transient process for adaptive optics[J]. Chinese Optics Letters, 2013, 11(11): 110101.

- [2] Yan Z J, Li X Y, Rao C H. Multi-channel adaptive control algorithm for closed-loop adaptive optics system [J]. *Acta Optica Sinica*, 2013, 33 (3): 0301002.
颜召军, 李新阳, 饶长辉. 自适应光学闭环系统实时多路自适应控制算法[J]. *光学学报*, 2013, 33(3): 0301002.
- [3] Tesch J, Truong T, Burruss R, et al. On-sky demonstration of optimal control for adaptive optics at Palomar Observatory [J]. *Optics Letters*, 2015, 40(7): 1575-1578.
- [4] Zhang D G, Fu Y T. Deformable mirror modeling and control based on on-line least square support vector machine [J]. *Infrared and Laser Engineering*, 2016, 45(11): 1118007.
张东阁, 傅雨田. 基于在线最小二乘支持向量机的变形镜建模与控制[J]. *红外与激光工程*, 2016, 45(11): 1118007.
- [5] Guo Y M, Rao C H, Bao H, et al. Direct computation of the interaction matrix of adaptive optical system [J]. *Acta Physica Sinica*, 2014, 63 (14): 149501.
郭友明, 饶长辉, 鲍华, 等. 一种自适应光学系统响应矩阵的直接计算方法[J]. *物理学报*, 2014, 63(14): 149501.
- [6] Levine S. Exploring deep and recurrent architectures for optimal control [J/OL]. (2013-11-07) [2019-06-25]. <https://arxiv.org/abs/1311.1761>.
- [7] Vdovin G V. Model of an adaptive optical system controlled by a neural network [J]. *Optical Engineering*, 1995, 34(11): 3249-3254.
- [8] Jorgenson M B, Aitken G J M. Neural network prediction of turbulence-induced wavefront degradations with applications to adaptive optics [J]. *Proceedings of SPIE*, 1992, 1706: 113-121.
- [9] Zhang J M, Wang N, Wang S Q. An neuron model-free controller with the adaptive gain regulated by the PID algorithm [J]. *Mechanical & Electrical Engineering Magazine*, 1999(5): 72-73, II.
张建明, 王宁, 王树青. PID自适应调整增益的神经元非模型控制[J]. *机电工程*, 1999(5): 72-73, II.
- [10] Jiang W H. Overview of adaptive optics development [J]. *Opto-Electronic Engineering*, 2018, 45(3): 7-21.
姜文汉. 自适应光学发展综述[J]. *光电工程*, 2018, 45(3): 7-21.
- [11] Korn G, LeGarrec B, Rus B. ELI extreme light infrastructure science and technology with ultra-intense lasers [C] // *CLEO: 2013, San Jose, June 9-14, 2013, San Jose, CA, USA. Washington, D.C. : OSA, 2013: CTu2D.7.*
- [12] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [13] Hecht-Nielsen R. Theory of the backpropagation neural network [C] // *International Joint Conference on Neural Networks, June 18-22, 1989, Washington, DC, USA. New York: IEEE, 1989: 593-605.*
- [14] Vorontsov M A, Carhart G W, Ricklin J C. Adaptive phase-distortion correction based on parallel gradient-descent optimization [J]. *Optics Letters*, 1997, 22 (12): 907-909.
- [15] Xiang W D, Yang P, Wang S, et al. Underwater image enhancement based on red channel weighted compensation and gamma correction model [J]. *Opto-Electronic Advances*, 2018, 1(10): 180024.
- [16] Jiang W H, Huang S F, Ling N, et al. Hill-climbing wavefront correction system for large laser engineering [J]. *Proceedings of SPIE*, 1989, 965: 266-272.