

# 光学学报

## 基于深度学习的主动光学校正算法研究

亢超<sup>1,2</sup>, 李文祥<sup>1,2\*\*</sup>, 黄岫<sup>3</sup>, 管恒睿<sup>1,2</sup>, 赵金标<sup>3</sup>, 朱庆生<sup>1,2,3\*</sup>

<sup>1</sup>中国科学院南京天文仪器研制中心, 江苏 南京 210042;

<sup>2</sup>中国科学技术大学, 安徽 合肥 230026;

<sup>3</sup>中国科学院南京天文仪器有限公司, 江苏 南京 210042

**摘要** 主动光学是现代大型反射式光学望远镜领域的一项关键技术, 能够有效减少像差, 提升成像质量, 然而, 现有校正算法严重依赖系统的响应矩阵和物理参数; 由于实际望远镜系统的误差具有一定的随机性和非线性, 往往难以获得精确的响应矩阵和物理参数模型, 从而导致校正精度不理想或者需要多次校正。针对这些问题, 提出一种不依赖响应矩阵和物理参数模型的深度学习校准(DLCM)算法。该算法借助深度神经网络强大的预测和自学习能力, 建立校正算法所需的动力学模型网络、策略网络和决策单元, 只需要结合相应设备就可以让控制系统自动学习并自动优化, 从而完成镜面校正工作。最后, 使用 ANSYS 有限元仿真对 DLCM 算法进行验证, 结果表明, 本文算法能够快速精准地完成校正工作, 并且, 无论校准速度还是校准精度, 均优于传统校准算法。

**关键词** 成像系统; 主动光学; 深度学习; 卷积神经网络; 启发式搜索; 进化策略

中图分类号 TH751

文献标志码 A

doi: 10.3788/AOS202141.0611004

## Research on Active Optical Correction Algorithm Based on Deep Learning

Kang Chao<sup>1,2</sup>, Li Wenxiang<sup>1,2\*\*</sup>, Huang Sheng<sup>3</sup>, Guan Hengrui<sup>1,2</sup>,  
Zhao Jinbiao<sup>3</sup>, Zhu Qingsheng<sup>1,2,3\*</sup>

<sup>1</sup>CAS Nanjing Astronomical Instruments Research Center, Nanjing, Jiangsu 210042, China;

<sup>2</sup>University of Science and Technology of China, Hefei, Anhui 230026, China;

<sup>3</sup>CAS Nanjing Astronomical Instruments Co., LTD., Nanjing, Jiangsu 210042, China

**Abstract** Active optics is a key technology in the field of modern large reflective optical telescopes, which can effectively reduce the aberration and improve the imaging quality. The calibration algorithm depends heavily on the response matrix and physical parameters of the system. Due to the randomness and nonlinearity of the errors of the actual telescope system, the accurate response matrix and physical parameter model are often difficult to obtain, which leads to the unsatisfactory correction accuracy or the need for multiple corrections. To solve these problems, this paper proposes a deep learning calibration algorithm (DLCM) which does not depend on response matrix and physical parameter model. With the powerful prediction and self-learning ability of the deep neural network, this algorithm establishes the dynamic model network, strategy network, and decision-making unit needed by the correction algorithm. The control system can learn and optimize automatically by combining the corresponding equipment, so as to complete the mirror calibration work. Finally, using ANSYS finite element simulation to verify the DLCM algorithm, the results show that the proposed control algorithm can quickly and accurately complete the calibration work, and the calibration speed and accuracy are better than the traditional calibration algorithm.

**Key words** imaging systems; active optics; deep learning; convolution neural network; heuristic search; evolutionary strategy

**OCIS codes** 110.6770; 120.4640; 220.1000

收稿日期: 2020-08-25; 修回日期: 2020-09-22; 录用日期: 2020-11-05

基金项目: 国家自然科学基金(12003067)、上海市星系与宇宙学半解析研究重点实验室开放课题(SKLA1901)

\* E-mail: 85482014@163.com; \*\* E-mail: lwxiang@mail.ustc.edu.cn

## 1 引言

随着望远镜口径的不断增大,主镜由于受到重力和温度梯度等因素影响,产生的变形也显著增加<sup>[1]</sup>,传统被动式支撑已经很难保证主镜的面形精度,因此目前世界上 3 m 以上口径的望远镜大多采用了主动光学技术。在观测的同时使用哈特曼-夏克<sup>[2]</sup>波前传感器检测望远镜面形误差,并根据波前误差对主镜面形进行校正,控制望远镜始终运行在成像良好的状态;如 3.5 m NTT 望远镜<sup>[3]</sup>、3.5 m SORT 望远镜<sup>[4]</sup>、3.67 m AEOS 望远镜<sup>[5]</sup>、6.5 m MMT 望远镜<sup>[6]</sup>、8 m Subaru 望远镜<sup>[7]</sup>、8.2 m VLT 望远镜<sup>[8]</sup>、8.4 m LBT 望远镜<sup>[9]</sup>以及采用拼接镜面的 LAMOST 望远镜<sup>[10]</sup>等,都使用了主动光学技术。传统主动校准算法大多采用最小二乘法与阻尼最小二乘法<sup>[11-12]</sup>,然而这两种方法都需要精准的系统响应矩阵和物理参数模型,实际操作起来比较困难,更糟糕的是,现实中的系统往往具有一定的非线性,难以用简单公式进行描述,因而造成传统校正算法校准精度低,且需要多次反复校准才能满足需求<sup>[13-14]</sup>。

近年来,许多研究人员致力于将深度学习技术应用在系统辨识问题中,并取得了不错的成果<sup>[15]</sup>。如使用深度神经网络代替系统的物理模型,将系统辨识问题转化为深度神经网络中参数的优化问题。此外,一些研究人员甚至发现深度学习能够代替 PID 控制器完成控制任务<sup>[16]</sup>。这表明,深度学习能够应用在主动光学控制策略算法问题上。

本文算法使用深度学习来建立控制系统,该算法主要由 3 部分组成:策略网络、动力学模型和决策单元。其中,策略网络用于生成初始控制策略;决策单元采用启发式搜索<sup>[17]</sup>对初始策略进行优化,找到最优的控制策略;动力学模型用于模拟镜面受力变形过程,为决策单元提供状态预测功能。各个部分均随机初始化并在训练过程中不断学习和优化,从而实现在没有系统响应矩阵、力促动器与传感器物理参数的情况下,完成镜面校正任务。

## 2 基本原理

### 2.1 传统校准算法

传统主动光学校准通常采用最小二乘法和阻尼最小二乘法,这两种方法主要基于两个假设:假设 1,镜面的形变符合线性叠加原理;假设 2,镜面变形量与初始状态无关,仅与力的大小和方向有关。即

$$\nabla s = \sum_{i=1}^n \nabla f_i s_i(x, y) \cos \theta, \quad (1)$$

式中: $\nabla s$ 为镜面的变形量; $n$ 为促动器的个数; $\nabla f_i$ 为促动器*i*输出的作用力大小; $s_i(x, y)$ 是促动器*i*输出单位力时在点 $(x, y)$ 引起的变形量; $\theta$ 为促动器作用力与镜面轴向夹角。设备安装时,通常保持促动器输出与镜面垂直,即 $\cos \theta = 1$ 。

由于镜面在空间上连续且可微,因而可以通过有限数量的特征点来描述和计算整个镜面的几何形状,具体方法是:在镜面均匀标记*m*个特征点位置,依次控制每一个力促动器单独输出,记录特征点相对于每一个促动器的变形系数,整理成偏导数形式并组合起来即可得到系统的刚度矩阵 $C$ <sup>[18-19]</sup>,其表达式为

$$C = \begin{bmatrix} \frac{\partial s_1}{\partial f_1}, & \frac{\partial s_1}{\partial f_2} & \cdots & \frac{\partial s_1}{\partial f_n} \\ \frac{\partial s_2}{\partial f_1}, & \frac{\partial s_2}{\partial f_2} & \cdots & \frac{\partial s_2}{\partial f_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial s_m}{\partial f_1}, & \frac{\partial s_m}{\partial f_2} & \cdots & \frac{\partial s_m}{\partial f_n} \end{bmatrix}. \quad (2)$$

为了便于计算,通常认为促动器输出较小时可以取

$$\frac{\partial s_i}{\partial f_i} \approx \frac{\nabla s_i}{\nabla f_i}. \quad (3)$$

定义波前误差为零时的镜面面形为目标面形,根据目标面形与传感器测量到的面形计算出当前的面形误差*E*,为了消除误差,所有力促动器输出*f*作用在镜面上产生的形变为 $\nabla s = -E$ <sup>[20]</sup>,即满足

$$Cf = -E. \quad (4)$$

写成矩阵形式为

$$\begin{bmatrix} \frac{\partial s_1}{\partial f_1}, & \frac{\partial s_1}{\partial f_2} & \cdots & \frac{\partial s_1}{\partial f_n} \\ \frac{\partial s_2}{\partial f_1}, & \frac{\partial s_2}{\partial f_2} & \cdots & \frac{\partial s_2}{\partial f_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial s_m}{\partial f_1}, & \frac{\partial s_m}{\partial f_2} & \cdots & \frac{\partial s_m}{\partial f_n} \end{bmatrix} \times \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_n \end{bmatrix} = \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_m \end{bmatrix}. \quad (5)$$

使用最小二乘法求解此矩阵表达式,可以得出为了校正面形所需要输出的力为

$$f = -(C^T C)^{-1} C^T E. \quad (6)$$

然而求解上式可能得到一个波动很大的力,即 $|\nabla f|$ 波动很大,如果直接输出将带来较大的超调量,造成主镜和光学系统振荡,严重时损坏镜面和光学系统。为了解决上述问题,可以增加一个阻尼

因子来限制振荡问题,得到阻尼最小二乘法求解公式<sup>[21-22]</sup>为

$$f = -(C^T C - P I)^{-1} C^T s, \quad (7)$$

式中: $P$ 为阻尼因子(正数); $I$ 为一个单位矩阵,实验中选取合适的 $P$ 值,使计算得出的作用力落在系统承载范围内。将此作用力加载到力促动器上,待系统稳定后测量镜面面形误差,如不满足要求则重复调整过程,直至满足要求为止。

## 2.2 基于深度学习的控制算法

基于深度学习的 DLCM 算法主要由 3 个部分

组成:动力学模型网络、策略网络和决策单元。如图 1 所示,动力学模型网络从实际的镜面校正数据中学习,为决策单元提供状态预测功能。策略网络为决策单元提供初始策略,并不断学习决策单元的输出,提高策略质量。决策单元使用启发式搜索对策略网络提供的初始策略进行扩充得到策略池,并将策略池中的元素依次在模型网络中进行预测验证,得到最优策略。然后将该最优策略输出并从外界获得反馈。

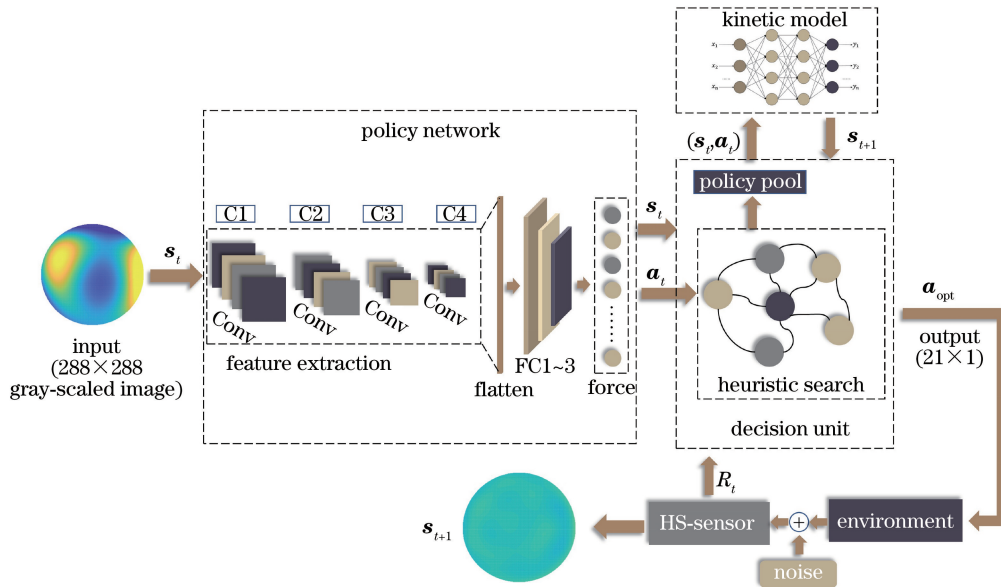


图 1 DLCM 算法框架图

Fig. 1 Framework of DLCM algorithm

本文算法的运行过程如下:

1) 预先训练动力学模型网络,使之能够基本预测镜面受力变形的情况;

2) 随机初始化策略网络和决策单元,或者通过迁移学习等进行预初始化;

3) 策略网络根据当前状态  $s_t$  计算初始策略  $a_t$ ;

4) 决策单元使用启发式搜索对初始策略  $a_t$  的邻域进行搜索,用模型网络对搜索到的每个策略进行预测,找到具有最高奖励值[均方根(RMS)最小]的策略,标记为优化策略  $a_{opt}$ ;

5) 实际执行策略  $a_{opt}$ , 并获取设备真实的状态输出  $s_{t+1}$  和奖励值  $R_t$  (RMS 值), 计算出实际状态与预测状态奖励的差值。将  $s_t - a_{opt} - s_{t+1}$  数据加入模型网络的训练集。将此  $s_t - a_{opt}$  数据加入策略网络的训练集;

6) 如果新产生的数据达到 10 组,控制模型网络和策略网络进行参数更新;

7) 如果状态达到,且稳定在控制目标,则训练结束,否则返回步骤 3。

### 2.2.1 动力学模型网络

动力学模型网络简称模型网络,由神经网络构成,主要作用是镜面面形状态预测,即根据大量现有数据来模拟镜面的受力变形情况。输入为当前状态(288×288 灰度图)与控制策略(21×1 力向量),输出为调整后状态(288×288 灰度图)。激活函数可以根据实验效果在 sigmoid 函数、ReLU 函数或 tanh 函数选择。模型网络的主要功能是为启发式搜索提供状态预测,用于判断当前策略搜索方向是否正确。其状态转移函数为

$$s_{t+1} = f_{\theta^s}(s_t, a_t). \quad (8)$$

当前时刻的状态  $s_t$  和动作  $a_t$  作为输入,下一时刻的状态  $s_{t+1}$  作为输出, $\theta^s$  为模型网络中的参数。其网络框架以及参数如图 2 所示。

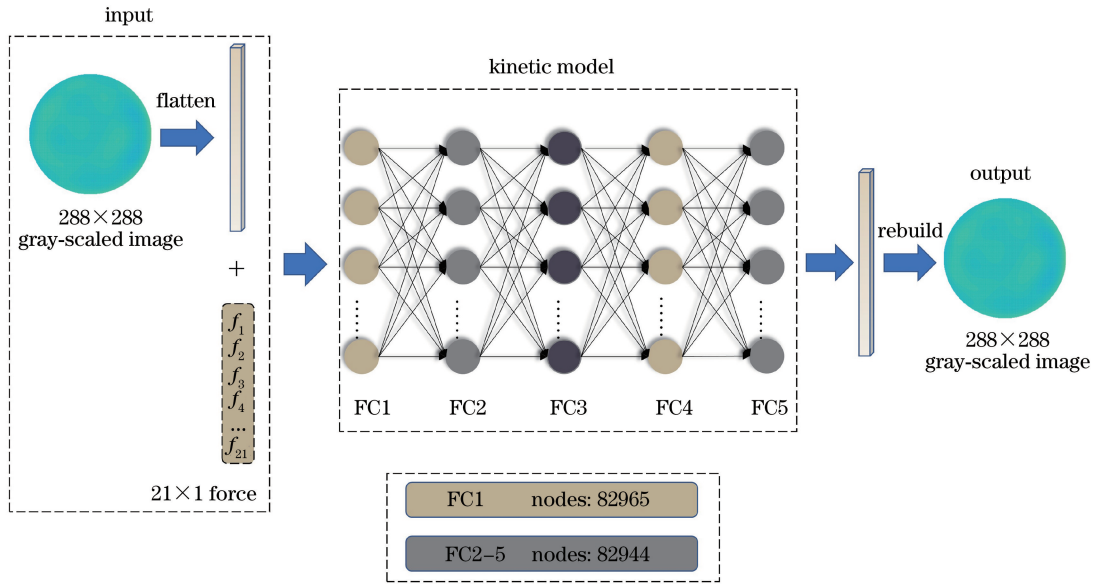


图 2 模型网络框架与参数

Fig. 2 Framework and parameters of kinetic model

定义模型网络的损失函数为

$$L(\theta^s) = \|s'_{t+1} - s_{t+1}\|, \quad (9)$$

式中:  $s'_{t+1}$  为模型网络的预测状态;  $s_{t+1}$  为下一时刻的实际状态;  $L(\theta^s)$  为模型网络的损失函数, 通过最小化  $L(\theta^s)$ , 从而使状态预测更加准确。

根据光学镜面的刚度矩阵与作用力, 存在等式

$$s = C f. \quad (10)$$

给作用力  $f$  叠加一个  $\Delta f$ , 等式将变为

$$\Delta s + s = C(f + \Delta f). \quad (11)$$

于是, 根据(10)式和(11)式可以得到

$$\Delta s = C \Delta f. \quad (12)$$

即可以通过在面形上额外施加一个作用力, 从而获得用于模型网络训练的数据  $(\Delta s_t, \Delta f, \Delta s_{t+1})$ 。使用预先训练的模型网络能够在很大程度上加速启发式搜索的收敛速度。根据(12)式, 可以很方便生成 50000 组数据用于模型网络的训练。将 50000 组数据按照 4:1 分为训练集和验证集。

根据工程经验, 镜面状态预测一般使用 3~6 层全连接(FC)网络即可, 从上述数据集中随机选取 4000 组训练数据与 1000 组测试数据进行实验验证, 统一设置 learning\_rate 取值 0.001, batch\_size 取值 50, 训练 50 个 epoch 后使用测试集进行验证, 定义校正率为 RMS 减少量与原始 RMS 的比值, 得到的平均校正率如表 1 所示。

由表 1 可以看出, 采用 5 层或 6 层全连接网络时准确率接近且表现较好, 考虑到层数越多运算速度越慢且容易产生过拟合问题, 最终选择 5 层全连

接网络构建模型网络。此外, 为了防止模型网络出现过拟合以及增加稳定性和鲁棒性, 可以在全连接网络中增加一定概率的 Dropout 节点<sup>[23]</sup>。Dropout 密度通常选择 0.3、0.4、0.5, 因此可以使用实验来验证每一种 Dropout 密度下模型网络的表现效果, 得到数据见表 2。

表 1 模型网络层数与准确率关系

Table 1 Relationship between model network layers and accuracy

Number of layers	3	4	5	6
Accuracy / %	91.35	95.14	97.54	97.60

表 2 模型网络 Dropout 密度与准确率关系

Table 2 Relationship between model network dropout density and accuracy

Dropout density	0.3	0.4	0.5
Accuracy / %	98.41	98.37	98.18

从表 2 可以看出, 在增加了不同密度的 Dropout 后, 模型网络的准确率均有一定程度的提升, 其中密度为 0.3 时提升最多, 达到 0.87%, 因此 Dropout 密度最终选择为 0.3。

至此模型网络的参数全部确定, 使用全部数据集进行模型训练, 设置 learning\_rate 取值 0.001, batch\_size 取值 50。每训练完一个 epoch 后, 使用测试集进行验证, 得到如图 3 所示的图像。其中横轴代表训练次数, 纵轴 MSE loss 代表预测面形与真实面形所有特征点的均方差。

根据图 3 可以看出, 训练开始时损失值下降很




图 3 策略网络损失下降曲线

Fig. 3 Loss decline curve of strategy network

快。大约到 400 的时候基本稳定，此时的损失值大约为 0.1，说明预测面形与实际面形已经基本一致，可以保存模型参数并停止训练。

### 2.2.2 策略网络

策略网络的输入是当前状态(288×288 矩阵)，输出是初始控制策略(21×1 力向量)，适合采用卷积神经网络来构建，卷积不仅能够在很大程度上提取图像中的细节信息，还可以减少全连接层的参数；卷积层之间使用最大值池化相连，全连接层之间使用 ReLU 作为激活函数。

记决策单元的输出最佳策略  $\mathbf{a}_{opt}$ ，策略网络的实际输出为  $\mathbf{a}_i$ ，于是，可以定义策略网络的损失函数为

$$L(\theta^a) = \|\mathbf{a}_{opt} - \mathbf{a}_i\|, \quad (13)$$

式中： $\theta^a$  为策略网络的参数，通过最小化  $L(\theta^a)$ ，让策略网络尽可能模仿决策单元的输出，从而不断产生更加适合当前状态的优秀初始策略。

为了分别确定卷积与全连接网络的层数，使用阻尼最小二乘法生成 1000 组面形-策略数据作为数据集(如多次校正才满足要求，则累加每次的输出并记为最佳输出)，同样按照 4:1 分成训练集和测试集，根据工程经验，卷积层数量在 1~5 之间，全连接层的数量在 2~4 之间，验证每种组合最终的平均校正率，最终结果如表 3 所示。

表 3 校正率和卷积层数以及全连接层数的关系

Table 3 Relationship between correction rate and convolutional layers and FC layers

FC layer	Convolutional layer				
	1	2	3	4	5
2/%	84.37	84.92	90.81	96.14	97.92
3/%	86.41	88.59	93.01	98.42	98.51
4/%	85.20	88.38	92.97	98.34	98.27

根据表格中的数据可以看出，使用 4 层卷积 3 层全连接时可以取得不错的效果，并且网络参数较

少，因此策略网络选择这种参数组合。最终策略网络的参数设置如图 4 所示。

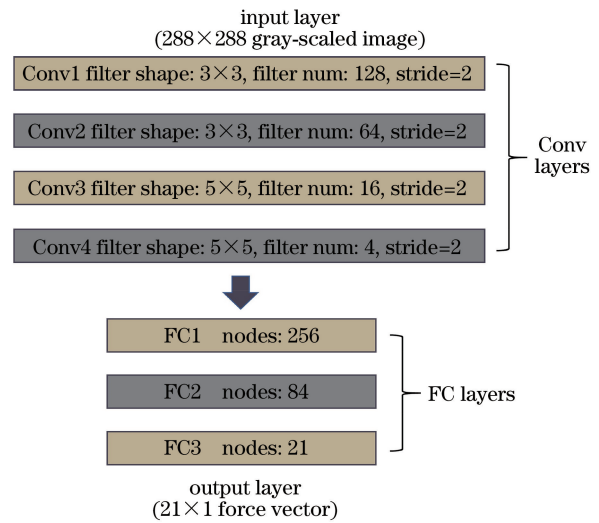


图 4 策略网络结构与参数

Fig. 4 Framework and parameters of strategy network

训练开始前，随机初始化模型网络的参数，将决策单元输出  $\mathbf{a}_{opt}$  作为策略目标，通过最小化  $L(\theta^a)$ ，让策略网络模仿决策单元的输出，从而不断产生更加适合当前状态的优秀初始策略。

### 2.2.3 决策单元

决策单元的作用是：以策略网络输出  $\mathbf{a}_i$  为起点，使用启发式搜索算法实现进一步挖掘与探索，寻找当前状态下的最优控制策略  $\mathbf{a}_{opt}$ 。启发式搜索是利用现有与解决问题有关的信息作为启发式信息，利用这些信息提升查找效率、减少查找次数的一类方法。启发函数定义为

$$f(k) = g(k) + h(k), \quad (14)$$

式中： $f(k)$  为节点  $k$  的综合优先级； $g(k)$  为节点  $k$  距离起点的代价； $h(k)$  为节点  $k$  距离终点的预计代价。当算法要跳转到下一个需要搜索的节点时，总会选择能使  $f(k)$  取最大的方向。

常用的启发式搜索算法有模拟退火算法<sup>[24]</sup>、粒子群算法<sup>[25]</sup>、遗传算法<sup>[26]</sup>和进化策略(ES)算法<sup>[27]</sup>等。其中的 ES 算法由于可以并行运算，因而更加满足本文需求<sup>[28]</sup>。进化策略的思想是模拟大自然中物竞天择、适者生存的理论，定期剔除种群中的离群值个体，只保留优秀个体。此外，优秀个体可以产生更多的后代，再在这些变异个体中实行优胜劣汰，直至找到最优策略。

将 21 个促动器的输出作为染色体，为了减少计算，染色体只保留两位小数。定义促动器输出范围： $-50.00 < f < 50.00$ ，个体的优劣程度用 RMS 值来

评价。为验证该算法,随机生成初始策略  $a_0$ ,观察每一代个体的分布情况,得到如图 5 所示的搜索过程图,最初各个点随机分布,但是随着生成数的增加,生存的个体都逐渐聚集在一起,最终基本重合到一个点,这意味着进化策略算法已经收敛。




图 5 进化策略算法收敛过程

Fig. 5 Convergence process of evolutionary strategy algorithm

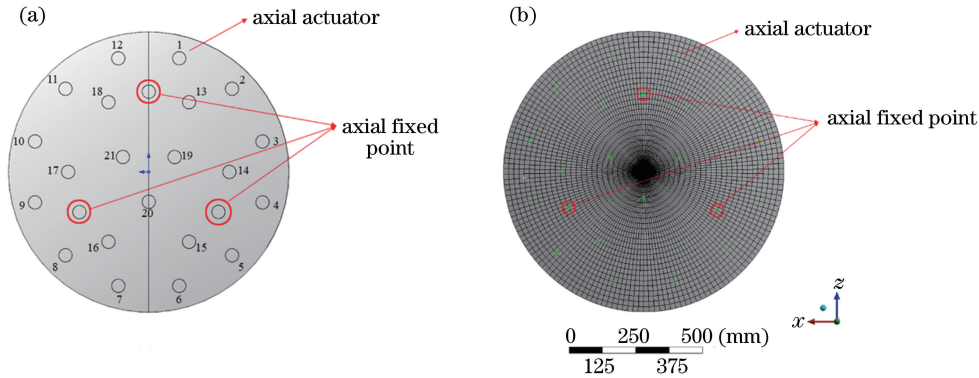


图 6 促动器分布图。(a)标准球面镜的支撑方式;(b) ANSYS 仿真模型

Fig. 6 Actuator distribution map. (a) Support method of standard spherical mirror; (b) ANSYS simulation model

策略网络和决策单元均采用随机初始化,训练开始后,策略网络根据当前状态  $s_t$  输出初始策略  $a_t$ ,决策单元使用进化策略算法,程序定期遍历所有样本,并预测每个样本的 RMS 值,“杀死”那些较差的样本,直至所有样本基本收敛至一处,记为  $a_{opt}$ 。将  $a_{opt}$  的 21 个“基因”作为校正力输入到有限元软件中,获取校正过后镜面的面形数据  $s_{opt}$ ,判断校正后的面形的 RMS 是否小于阈值  $0.05\lambda$  ( $\lambda = 632.8 \text{ nm}$ ),如不满足则重新执行校正过程;满足则标记校准完成,然后随机输出一个作用力打乱已经校准好的面形,再次执行校正算法。将每次控制过程的初始状态  $s_t$ 、策略网络输出  $a_{opt}$ 、调整后状态  $s_{opt}$  加入模型网络的训练集,将初始状态  $s_t$  与决策单元的输出  $a_{opt}$  加入策略网络的训练集,当新数据累计达到 10 时,模型网络与策略网络进行自我更新,提升模型网络与策略网络的精准度。

算法的运行速度与硬件平台有很大关系,表 5

### 3 实验与讨论

#### 3.1 实验验证

本文使用 ANSYS 对主动光学镜面进行仿真实验,表 4 为主镜的一些重要参数。

表 4 主镜的重要参数

Table 4 Main parameters of spherical mirror

Name	Parameter
Diameter /mm	1000
Thickness /mm	80
Radius of curvature /mm	4000
Material	K9 glass
Mass /kg	174.445

主镜由 3 个固定支撑和 21 个可运动的促动器共同支撑,其中 21 个促动器分布如图 6(a)所示。图 6(b)为 ANSYS 有限元仿真中的镜面模型。

为本文算法训练时所采用的硬件平台信息。

表 5 算法训练平台的硬件和软件信息

Table 5 Hardware and software parameters of algorithm training platform

Name	Parameter
CPU	Intel Core i7-4790 CPU @ 3.6 GHz
Memory	16 GB
Graphics card	NVIDIA GeForce GTX980 Ti
System	Windows 7 professional
Environment	Python3.7, PyTorch 1.5.1-GPU

训练过程中除了需要关注面形误差数据外,还应该注意算法的运行时间,因此在算法训练过程中,记录算法完成一次校准的时间,并将其整理为曲线图,如图 7 所示。

图 7 为训练迭代次数与完成一次校准所需要的时间,训练开始的时候由于策略网络处于欠拟合状态,真正起作用的是启发式搜索,而启发式搜索需要很大的运算量,因此算法的运行时间较长,最长时间




图 7 DLCM 算法运行时间

Fig. 7 Running time of DLCM algorithm

大约 140 s。然后,随着算法迭代次数的增加,策略网络输出初始策略的质量也在不断提高,决策单元

需要搜索的范围不断减小,因此算法运行时间不断下降,当算法迭代到 800 次时,运算时间仅为 0.63 s,满足主动光学算法对快速性的要求。

一段时间后,测试模型学习效果,经过一段时间训练后,观察模型一次校正所能达到的成果,其效果如图 8 所示。

图 8 为 DLCM 算法针对不同初始面形,仅用一次校正所能达到的效果,可以看出,DLCM 算法已经很好地学会了光学镜面主动校正的方法,尤其是在初始 RMS 面形误差较小时,可以一次完成校准,当初始 RMS 较大时,一次调整就可以将误差校正到  $0.1\lambda$  附近。

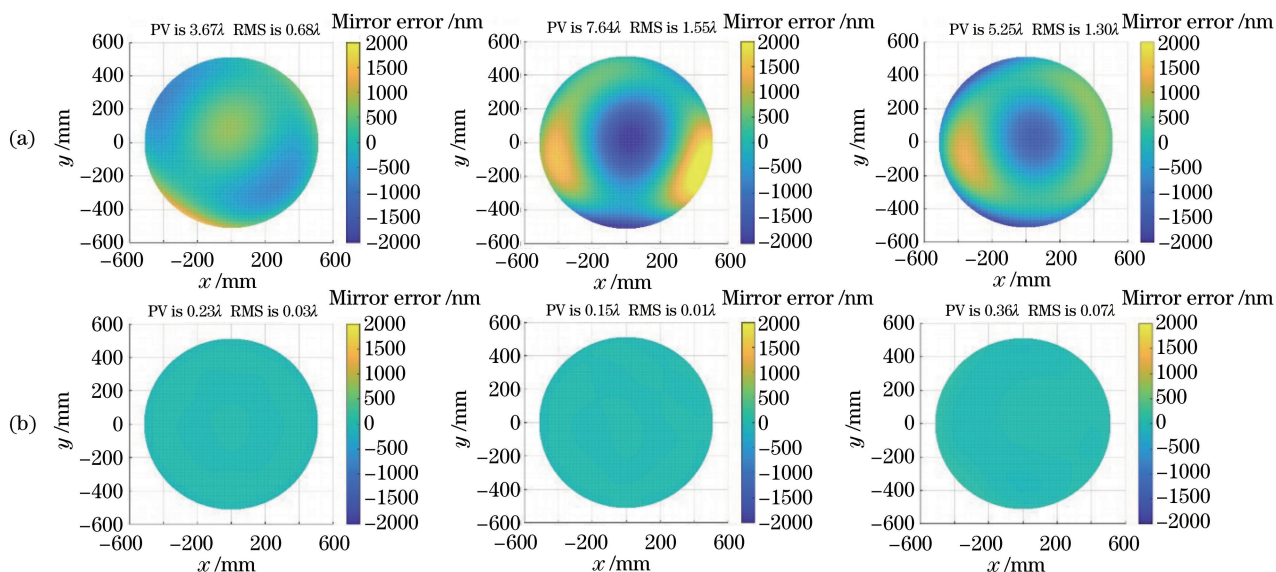


图 8 第一次校正效果比较。(a)校正前;(b)校正结果

Fig. 8 Comparison of effect of first correction. (a) Before correction; (b) corrected results

### 3.2 实验对比与讨论

为了进一步检验本文算法的可靠性,进行如下实验:随机选取四组不同初始面形,分别使用阻尼最小二乘法(DLS)、最小二乘法(LS)和 DLCM 进行镜面主动校正,得到如表 6 所示的对比数据。

表 6 展示了三种算法在相同初始面形下的不同表现,以 RMS 小于  $0.05\lambda$  作为停止校准的阈值。观察实验数据,可以得到以下实验结论:

- 1) 当 RMS 小于  $0.86\lambda$  时,DLCM 算法基本可以一次完成校准任务;
- 2) 当 RMS 较大时,可能需要多次校准;
- 3) 三种算法中表现最好的是 DLCM 算法,表现最差的是 LS 算法;
- 4) LS 算法与 DLS 算法校准效果类似,校准次数差距不大;

由于 DLCM 算法具有很强的记忆功能,如果能

表 6 三种算法校准效果比较

Table 6 Comparison of calibration results of three algorithms

Method	Initial state	Result	Number of times	Single promotion ratio /%
DLS	$0.27\lambda$	$0.02\lambda$	2	46.26
LS	$0.27\lambda$	$0.04\lambda$	2	42.60
DLCM	$0.27\lambda$	$0.01\lambda$	1	96.30
DLS	$0.56\lambda$	$0.03\lambda$	3	27.98
LS	$0.56\lambda$	$0.02\lambda$	4	24.11
DLCM	$0.56\lambda$	$0.02\lambda$	1	96.42
DLS	$0.86\lambda$	$0.02\lambda$	5	19.54
LS	$0.86\lambda$	$0.05\lambda$	6	15.70
DLCM	$0.86\lambda$	$0.03\lambda$	1	96.51
DLS	$1.21\lambda$	$0.05\lambda$	5	19.17
LS	$1.21\lambda$	$0.04\lambda$	7	13.81
DLCM	$1.21\lambda$	$0.02\lambda$	2	49.17

增加训练数据的多样性,进一步加强 DLCM 算法的

泛化能力,那么只需要一次校正就能满足观测需求。

另外,力促动器数量、镜面材料、镜面厚度等都会对最终结果造成一定的影响,通常情况下力促动器的数量越多,校准效果越好,这是因为少量促动器仅能够校正低阶像差,更多数量的力促动器可以校准更高阶像差。同等材料下,镜面越厚,高阶像差越少,但是重量越大,各个支撑点受力也越大,造成力促动器输出范围受限。因此实际系统需要在这几个参数中进行取舍。

## 4 结 论

本文介绍了一种基于深度学习的主动光学校准算法,并通过 ANSYS 有限元仿真对算法进行了验证,结果表明,该算法能够完成镜面校正任务;并且相比于传统的最小二乘法与阻尼最小二乘法,校正速度与校准精度均有较大幅度的提升。本文算法的优势主要表现在以下两个方面。

1)提高了校准精度。深度神经网络的应用使得控制算法无需精确的响应矩阵和物理参数,从源头减少了误差。此外神经网络对于线性和非线性系统均具有强大的适应性,因此在初始误差较大时也能取得不错的控制效果。

2)减少了校准次数。模型网络的加入使算法内部就可以初步评判各种策略的优劣;加速了进化策略算法的运算速度。此外由于深度网络具有一定的记忆性,所以更加适合执行此类重复性工作。

不过,本文算法也存在一些问题,如策略网络收敛较慢,训练开始阶段基本都是启发式搜索在发挥作用,而由于启发式搜索耗时较多,导致训练初期算法需要很长时间才能计算完成。此外,由于本文实验平台为 ANSYS 有限元仿真,减少了很多环境干扰,如果是真实的主动光学实验设备,还应该进一步对算法中各个部分的参数进行优化。

## 参 考 文 献

- [1] Li H Z, Zhang Z D, Wang J L, et al. Active surface-profile correction of 620 mm thin-mirror based on flotation support [J]. *Acta Optica Sinica*, 2013, 33 (5): 0511001.  
李宏壮, 张振铎, 王建立, 等. 基于浮动支撑的 620 mm 薄反射镜面形主动校正 [J]. *光学学报*, 2013, 33(5): 0511001.
- [2] Dai X Y, Tan Y, Ren G, et al. Analysis of image quality detection performance of scanning hartmann technology [J]. *Acta Optica Sinica*, 2020, 40 (7): 0712002.  
戴勋义, 谭毅, 任戈, 等. 扫描哈特曼方法的像质检测性能分析 [J]. *光学学报*, 2020, 40(7): 0712002.
- [3] Noethe L, Franza F, Giordano P, et al. Active optics: from the test set up to the NTT in the observatory [J]. *Proceedings of SPIE*, 1989, 1114: 314-319.
- [4] Martin H M, Davison W B, Derigne S T, et al. Active supports and force optimization for a 3.5-m honeycomb sandwich mirror [J]. *Proceedings of SPIE*, 1994, 2199: 251-262.
- [5] Kimbrell J E. AEOS 3.67 m telescope primary mirror active control system [J]. *Proceedings of SPIE - The International Society for Optical Engineering*, 1998, 3352(4): 506-507.
- [6] Martin H M, Callahan S P, Cuerden B, et al. Active supports and force optimization for the MMT primary mirror [J]. *Proceedings of SPIE*, 1998, 3352: 412-423.
- [7] Horikawa H, Baba N S, Ohtsubo M, et al. Wind-flow measurement over the Subaru Telescope [J]. *Applied Optics*, 2004, 43(15): 3097-3102.
- [8] Schneermann M W, Cui X Q, Enard D, et al. ESO VLT: III. The support system of the primary mirrors [J]. *Proceedings of SPIE*, 1990, 1236: 920-928.
- [9] Martin H M, Cuerden B, Dettmann L R, et al. Active optics and force optimization for the first 8.4-m LBT mirror [J]. *Proceedings of SPIE*, 2004, 5489: 826-837.
- [10] Su D Q, Cui X Q, Wang Y N, et al. Large-sky-area multiobject fiber spectroscopic telescope (LAMOST) and its key technology [J]. *Proceedings of SPIE*, 1998, 3352: 76-90.
- [11] Hardy J W. Active optics: a new technology for the control of light [J]. *Proceedings of the IEEE*, 1978, 66(6): 651-697.
- [12] Wilson R N, Franza F, Noethe L. Active optics. I. A system for optimizing the optical quality and reducing the costs of large telescopes [J]. *Journal of Modern Optics*, 1987, 34(4): 485-509.
- [13] Guo Y M, Ma X Y, Rao C H. Optimal closed-loop bandwidth of tip-tilt correction loop in adaptive optics system [J]. *Acta Physica Sinica*, 2014, 63 (6): 069502.  
郭友明, 马晓燠, 饶长辉. 自适应光学系统倾斜校正回路的最优闭环带宽 [J]. *物理学报*, 2014, 63(6): 069502.
- [14] Cho M K. Active optics performance study of the primary mirror of the gemini telescopes project [C] // *Optical Telescopes of Today & Tomorrow*.



- International Society for Optics and Photonics, 1997.
- [15] Cheon K, Kim J, Hamadache M, et al. On replacing PID controller with deep learning controller for DC motor system[J]. *Journal of Automation and Control Engineering*, 2015, 3(6): 452-456.
- [16] Zuo C, Feng S J, Zhang X Y, et al. Deep learning based computational imaging: status, challenges, and future [J]. *Acta Optica Sinica*, 2020, 40 (1): 0111003.  
左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像: 现状、挑战与未来[J]. *光学学报*, 2020, 40(1): 0111003.
- [17] Su Y D, Qian Y L, Qiu J. Heuristic search in test selection[J]. *China Measurement Technology*, 2005, 31(5): 46-48, 78.  
苏永定, 钱彦岭, 邱静. 基于启发式搜索策略的测试选择问题研究[J]. *中国测试技术*, 2005, 31(5): 46-48, 78.
- [18] Dong L J, Cui Q L, Li P Z, et al. Design and experiment of active compensation system for thermal aberration of lithographic lens [J]. *Acta Optica Sinica*, 2017, 37(3): 0322003.  
东立剑, 崔庆龙, 李朋志, 等. 光刻物镜热像差主动补偿系统设计与实验[J]. *光学学报*, 2017, 37(3): 0322003.
- [19] Su D Q, Cui X Q. Active optics: key technology of a new generation of large telescopes [C] // *Chinese Astronomical Society 97 Symposium on New Techniques for Telescopes and Instruments*, 1997.  
苏定强, 崔向群. 主动光学——新一代大望远镜的关键技术[C]//中国天文学会 97 天文望远镜及仪器新技术学术交流会, 1997.
- [20] Ni Y, Huang Q T, Yu J C. Optimized design of active support of ultra thin mirror [J]. *Opto-Electronic Engineering*, 2008, 35(9): 22-26, 31.  
倪颖, 黄启泰, 余景池. 超轻超薄反射镜主动支撑方案优化设计[J]. *光电工程*, 2008, 35(9): 22-26, 31.
- [21] Li H Z, Wang J L, Lin X D, et al. Active optics experiment system with thin-mirror [J]. *Opto-Electronic Engineering*, 2009, 36(6): 120-125.  
李宏壮, 王建立, 林旭东, 等. 薄反射镜主动光学实验系统[J]. *光电工程*, 2009, 36(6): 120-125.
- [22] Kirkpatrick S, Gelatt C D Jr, Vecchi M P. Optimization by simulated annealing[M]. Singapore: World Scientific, 1986: 339-348.
- [23] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. *Journal of Machine Learning Research*, 2014, 15: 1929-1958.
- [24] Corana A, And C M R M. Corrigenda: "minimizing multimodal functions of continuous variables with the 'simulated annealing' algorithm" [J]. *ACM Transactions on Mathematical Software*, 1989, 15 (3): 287.
- [25] Kennedy J, Eberhart R. Particle swarm optimization [C] // *Proceedings of ICNN' 95 - International Conference on Neural Networks*, November 27 - December 1, 1995, Perth, WA, Australia. New York: IEEE Press, 1995: 1942-1948.
- [26] Goldberg D E. Genetic algorithms in search, optimization, and machine learning [J]. *Choice Reviews Online*, 1989, 27(2): 936.
- [27] Beyer H G. Evolution strategies [J]. *Scholarpedia*, 2007, 2(8): 1965.
- [28] Sa-limans T, Ho J, Chen X, et al. Evolution strategies as a scalable alternative to reinforcement learning [EB/OL]. (2017-09-07). [2020-08-25]. <https://arxiv.org/abs/1703.03864>.