

基于深度学习的透射式光学系统初始结构设计

史浩东¹, 何春风^{1,2*}, 王稼禹^{1,2}, 杨帅^{1,2}, 徐森^{1,2}, 孙洪宇^{1,2}, 李英超¹, 付强¹¹长春理工大学吉林省空间光电技术重点实验室, 吉林 长春 130022;²长春理工大学光电工程学院, 吉林 长春 130022

摘要 针对传统透射式光学系统初始结构优化设计效率低、结构选取过度依赖经验等问题,提出了一种基于深度学习的透射式光学系统初始结构自动优化设计方法。通过监督训练学习公开光学镜头库中参考镜头的结构特征数据,构建基于光线追迹的无监督训练模型,提升深度神经网络(DNN)模型的泛化能力。通过训练生成的网络模型输出包含真实玻璃的光学系统的结构参数,从而实现透射式光学系统初始结构的自动优化设计。设计结果表明:利用该网络模型优化设计的光学系统初始结构在全视场、全谱段下的像面点斑半径与参考镜头接近,并且能够根据不同焦距要求分别设计出光学系统初始结构;所设计的 1×10^6 组初始结构的成功率优于96.403%,表明所提网络模型具有良好的泛化能力。

关键词 光学设计;深度学习;自动优化;初始结构;光线追迹

中图分类号 O435.1

文献标志码 A

DOI: 10.3788/AOS221214

1 引言

光学系统设计可以理解为一个参数的优化解算过程,光学系统的光学像差与结构参数之间具有复杂的非线性关系^[1]。传统光学设计通常根据经验或从公开的镜头库中选取与预期结构相似的初始结构,然后基于阻尼最小二乘法^[2-3]、适应法^[4]等局部优化算法和模拟退火法^[5]、遗传算法^[3, 6-7]、逃逸算法^[8]、粒子群算法^[9-10]等全局优化算法对初始结构进行优化。因此,选取一个合适的初始结构对后续的优化效果和效率尤为重要。然而,目前初始结构设计方法通常类似一个试错过程,设计者主要依靠设计经验针对不同设计需求确定最为合适的初始结构,这种方法在一定程度上限制了光学系统的设计效率和后续的可优化性。因此,亟需发展新的光学系统初始结构优化设计方法予以解决。

近年来,人工智能算法得到了快速发展,其在解决非线性问题上相比传统算法具有高效、准确等优势,有望解决光学系统的非线性优化问题,并提升光学系统初始结构的设计效率。因此,基于深度学习的光学系统优化设计方法逐渐成为各国学者的研究热点。2017年,Yang等^[11]提出了一种可以自动获取高性能自由曲面系统的逐点设计方法。之后,Yang等^[12]成功将深度学习算法应用到反射式系统设计中,实现了离轴三反成像系统初始结构的自动化生成。

2018年,Gannon等^[13]利用机器学习方法学习自由曲面的表面形状与设计参数和性能之间的关系,提高了自由曲面照明系统的设计效率。2019年,Côté等^[14]提出了一种基于深度学习生成光学系统初始结构的方法,能够在设计者要求的口径、视场下自动生成透射式光学系统初始结构。2022年,张航等^[15]利用深度学习实现了配光方程逆问题的求解,可获取所需的光学自由曲面面型,实现了进一步将深度学习应用于复杂光学系统的优化设计中。综上所述,目前大多数学者将深度学习算法应用于反射式光学系统的设计中,无需考虑透镜色散等问题。然而,针对透射式光学系统,由于透镜材料种类繁多、组合方式层出不穷,故现有自动优化方法难以应用于大多数光学系统设计中。因此,发展一种适用于透射式光学系统初始结构的深度学习自动优化算法对于提升系统优化效率具有重要意义。

提出了一种基于深度学习的透射式光学系统初始结构优化设计方法。利用监督训练从公开的光学镜头库中学习初始结构特征,构建基于光线追迹的无监督训练模型,将监督训练和无监督训练相结合,在学习镜头结构特征的同时提升设计泛化能力,训练出的网络模型能根据输入的实际设计指标参数自动优化出成像质量满足设计要求的光学系统初始结构。最后,通过设计实例对所提方法进行验证。

收稿日期: 2022-05-30; 修回日期: 2022-06-30; 录用日期: 2022-07-06; 网络首发日期: 2022-07-16

基金项目: 国家自然科学基金(61805027, 61890960, 61805028)

通信作者: hechunfeng68@163.com

2 基本原理

2.1 基于深度学习的透射式光学系统设计过程

基于深度学习的透射式光学系统设计过程分为两部分,即深度学习过程和自动设计过程:深度学习过程使用的是将监督学习和无监督学习结合的半监督学习方法^[16],利用深度神经网络(DNN)学习大量的镜头数据;在自动设计过程中,输入指定的孔径、视场、焦距和厚度范围等归一化的参数后利用已经训练完成的网络设计出光学系统结构。

深度学习过程中选取镜头库的部分镜头作为监督学习的样本,后将其统称为参考镜头,并将孔径、视场和厚度范围等参数处理成为归一化数据,孔径和视场参数与参考镜头的孔径和视场参数组合一致,厚度最小值和厚度范围则在指定范围内随机生成。监督训练的归一化输入参数经过神经网络模型后输出标准化光学结构参数,之后将计算得到的输出的标准化光学结

构参数与参考镜头的结构参数的均方差作为监督损失(L_s)。深度学习过程中无监督学习样本数据从已选取的归一化参考镜头参数中生成,根据参考镜头确定范围孔径、视场、厚度的最大值和厚度的最小值,之后在确定的范围内均匀生成无监督学习样本数据,将归一化参数输入到DNN中训练得到输出的光学结构参数,将输出的光学结构参数作为光线追迹的输入,并以点斑半径大小作为评价标准,计算无监督损失(L_u)。通过损失函数值的不断下降更新网络参数,最终完成网络模型的训练。

自动设计过程是从输入端直接输出光学结构参数的过程,设计者输入归一化的设计参数到训练完成的网络模型中,训练完成的网络快速输出光学结构和光学像质符合设计者要求的光学系统结构参数,进而完成光学系统设计。其中,输出的光学系统结构参数包括透镜的曲率、厚度和玻璃参数。深度学习设计光学系统的学习过程与设计过程如图1所示。

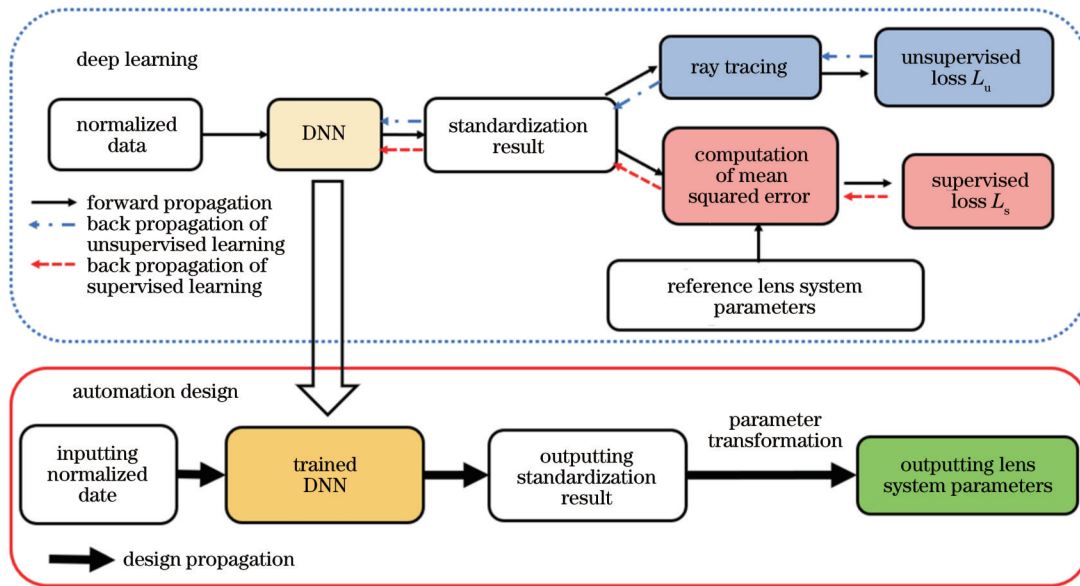


图1 深度学习设计光学系统的学习过程与设计过程

Fig. 1 Learning and design processes of optical system design based on deep learning

2.1.1 深度神经网络

神经网络是深度学习的一个重要部分,经过训练完成的神经网络在输入所需数据后通过网络模型的学习输出结果,实现一个从输入端到输出端的学习过程。然而,实际上神经网络是由一系列全连接层和激活层组成的隐藏层:全连接层的作用是将上一层数据节点的特征提取出来并综合起来^[17-18];激活层的作用是通过函数变换从而增加网络模型的非线性^[19]。单个连接层的层数、全连接层的数量和不同的激活层将决定网络训练结果是否符合要求。

DNN多用于数据线性与非线性关系的学习。因此,选择DNN作为深度学习光学设计的网络模型。网络的结构由多个全连接层和激活层构成,一对全连接层

和激活层构成一层非线性隐藏层。该网络的参数初始化方法使用的是自归一化神经网络中的参数初始化方法^[20]。激活层使用的是SELU激活函数,使用SELU激活函数能保持数据的标准化,避免梯度出现大幅度振荡,有利于损失函数收敛。模型输出的光学系统结构符合实际需求,具体网络架构如图2所示。其中: x 为输入层的参数,分别对应入瞳口径(EPD)、视场(FOV)、焦距(EFL)、光学表面之间的最小厚度($t_{\min,1}, \dots, t_{\min,j}$)、光学表面之间的厚度范围($t_{\text{range},1}, \dots, t_{\text{range},j}$); y 为输出层的参数,分别对应光学表面曲率半径(r_1, \dots, r_{j-1})、中间厚度变量($t_{\text{raw},1}, \dots, t_{\text{raw},j}$)和归一化的玻璃变量($g_{n,1}, g_{v,1}, \dots, g_{n,k}, g_{v,k}$); j 为光学表面数量; k 为玻璃材料数量; ω 为隐藏层的权重参数; σ 为激活函数。

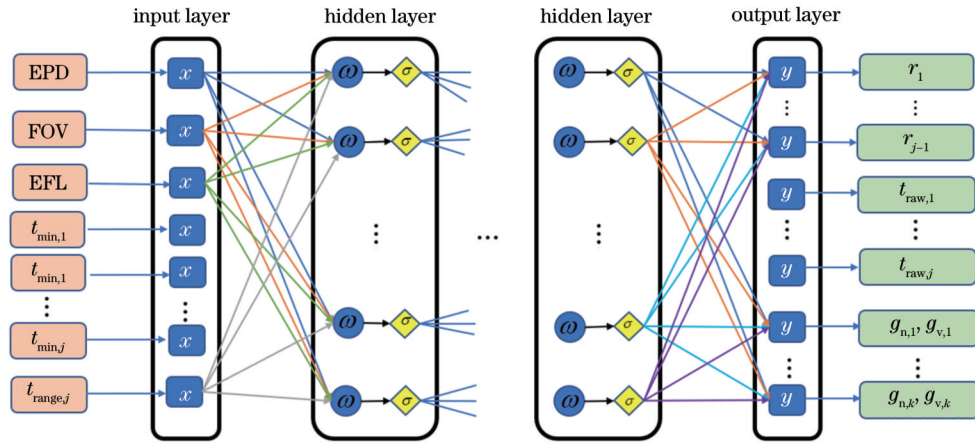


图 2 深度学习网络架构

Fig. 2 Architecture of deep learning network

2.1.2 监督学习过程

监督训练数据是根据参考镜头的特征数据生成的。网络训练所需要的参考镜头输入特征分别为孔径、视场角、焦距、光学表面之间的最小厚度 ($t_{\min,1}, \dots, t_{\min,j}$) 和光学表面之间的厚度范围 ($t_{\text{range},1}, \dots, t_{\text{range},j}$)。在输入数据生成之前,需要对参考镜头进行归一化处理,归一化之后生成的特征化数据将提高模型的精度和模型训练的收敛速度。

本文中监督训练的孔径和视场角遵循参考镜头中孔径和视场角的组合不变原则,网络模型通过学习参考设计孔径与视场角之间的组合关系掌握光学系统结构的设计规律。训练中为控制网络的训练范围,需要确定厚度参数范围。例如,若归一化参考透镜的厚度为 1 mm,则光学表面之间的最小厚度范围可以适度设置为 0.1~0.5 mm,光学表面之间的厚度范围可设定为 0.5~1.0 mm。范围的设定并不是固定的,而是根据实际的训练需求适当设定的,训练数据从所确定的最小厚度范围、光学表面之间的厚度范围中平均生成。

输入生成的特征数据到神经网络模型中,经全连接层和激活层的运算后输出中可能出现负值,而实际光学设计中厚度不能为负值,故需要将中间厚度变量和归一化玻璃变量进行转换。引入 Softplus 函数控制输出的光学系统厚度为正值,Softplus 函数是一种对 ReLU 函数的平滑近似,可以用来控制网络模型的输出始终为正^[21]。Softplus 函数为

$$\text{Softplus}(x) = \ln[1 + \exp(x)], \quad (1)$$

利用该模型训练的输出 t_{raw} 与输入的参数范围的计算

值始终为正值,故最后得到的光学系统的厚度始终为正值。

计算网络模型输出的厚度与设定的最小厚度之间的差值,并代入到 Softplus 函数中,可得

$$t_{\text{Softplus1}} = \ln[1 + \exp(t_{\text{raw}} - t_{\min})], \quad (2)$$

计算网络模型输出的厚度与设定的最小厚度和厚度范围之间的差值,并代入到 Softplus 函数中,可得

$$t_{\text{Softplus2}} = \ln\{1 + \exp[t_{\text{raw}} - (t_{\text{range}} - t_{\min})]\}, \quad (3)$$

最终建立一个输入的光学表面最小厚度、厚度范围和输出的原始中间厚度之间的转换关系为

$$t_i = t_{\min} + t_{\text{Softplus1}} - t_{\text{Softplus2}}. \quad (4)$$

在玻璃变量中, $g_{n,1}$ 代表玻璃的折射率, $g_{v,1}$ 代表玻璃的阿贝数,但是网络模型输出的归一化玻璃变量 $[(g_{n,1}, g_{v,1}), \dots, (g_{n,k}, g_{v,k})]$ 实际上并不能直接映射到某一确定的玻璃材料上。因此,本文根据玻璃库建立了折射率和阿贝数的二维数据库,利用最邻近搜索法定位与输入的玻璃变量 $(g_{n,1}, g_{v,1})$ 邻近的玻璃材料作为真实镜头玻璃材料,借助这种搜索算法能够快速定位网络模型输出的玻璃参数所对应的实际光学玻璃,有效解决了光线追迹过程中不同谱段下点斑半径大小的优化问题。

监督损失函数是度量深度学习效果的标准,利用公开镜头库中的标准镜头作为监督训练的标签,计算训练出的透镜曲率半径、厚度、玻璃材料等变量与参考镜头对应的镜头参数之间的均方差,具体损失函数计算为

$$L_s = \frac{\sum_{i=1}^{j-1} (r_i - r'_i)^2 + \sum_{i=1}^j (t_{\text{raw},i} - t'_{\text{raw},i})^2 + \sum_{i=1}^k (g_{n,i} - g'_{n,i})^2 + \sum_{i=1}^k (g_{v,i} - g'_{v,i})^2}{2 \times (j + k) - 1}, \quad (5)$$

式中: $r'_i, t'_{\text{raw},i}, (g'_{n,i}, g'_{v,i})$ 为参考镜头的曲率半径、厚度和玻璃材料。

通过该监督损失函数的计算,利用反向传播过程对网络模型参数不断进行更新,随着参数的改变,损失

函数在减小,网络模型输出数据与参考透镜各项参数之间的差距在缩小,从而网络模型能够更好地学习到参考镜头的特征。

2.1.3 无监督学习过程

无监督学习过程同样需要输入归一化参考镜头的孔径、视场角、焦距、光学表面之间的最小厚度和光学表面之间的厚度范围等特征数据。与监督学习不同的是,无监督学习综合了所有的参考透镜特征范围,在每个特征的最大值与最小值范围内平均生成训练数据。例如,针对孔径这一输入特征,首先确定所有参考镜头中孔径的最小值与最大值,再在最大值与最小值之间平均生成无监督数据。孔径特征数据与视场特征数据不再遵循特定的组合原则,这将增加网络模型学习镜头特征的时间,网络模型的泛化能力也在对随机组合特征数据进行学习的过程中得到了提升。在相应的最大值和最小值范围内随机输入孔径、视场等参数后,网络模型可设计出符合设计者要求的光学系统结构。

考虑到网络模型学习的通用性,将孔径、输出厚度间隔($t_{\text{raw},1}, \dots, t_{\text{raw},j}$)、曲率半径(r_1, \dots, r_{j-1})和折射率作为已知条件,系统焦距为设计者设定值,从而推导出通用式^[22]。透镜的通用焦距公式为

$$f' = \frac{n_k \times r_j \times r_{j-1}}{(n_k - 1) \times [n_k \times (r_j - r_{j-1}) + (n_k - 1) \times t_j]} \quad (6)$$

式中: n_k 为第 k 块玻璃的折射率。正切计算法的通用公式为

$$\left\{ \begin{array}{l} \tan U'_1 = \tan U_2 = h_1/f'_1 \\ h_2 = h_1 - d_1 \times \tan U'_1 \\ \tan U'_2 = \tan U_3 = \tan U_2 + h_2/f'_2 \\ h_3 = h_2 - d_2 \times \tan U'_2 \\ \vdots \\ h_k = h_{k-1} - d_{k-1} \times \tan U'_{k-1} \\ \tan U'_k = \tan U_k + h_k/f'_k \end{array} \right. \quad (7)$$

式中: U_k 为入射光线与光轴的夹角; h_k 为入射光线的高度; d_k 为主面之间的距离; f'_k 为焦距; U'_k 为出射光线与光轴的夹角。总光焦度 Φ 和各组透镜 φ_k 的光焦度的关系式为

$$\Phi = \frac{1}{f'} = \frac{\tan U'_k}{h_1} = \varphi_1 + \frac{h_2}{h_1} \times \varphi_2 + \frac{h_3}{h_1} \times \varphi_3 + \dots + \frac{h_k}{h_1} \times \varphi_k = \frac{1}{h_1} \sum_1^k (h \times \varphi) \quad (8)$$

在实际深度学习过程中,仅有最后一面透镜的曲率半径为未知量,则通过式(6)可以单独求出除最后一面透镜外所有透镜的焦距。本文中系统的光阑设定在第一面光学表面上,则式(7)中初始的入射光线高度 h_1 与EPD相同,由此逐步推导出下一组透镜主面入射光线高度和下一组透镜主面出射光线与光轴的夹角,光线在多光组主面内的传播路径如图3所示。其中, n_{air} 为空气的折射率, n_1, n_2, n_k 为系统中不同玻璃的折射率, l_1 为无限远的物方截距, $-l$ 为近轴物方截距, l' 为像方截距, l'_F 为系统的后截距。




图3 光线在光组主面内的传播路径

Fig. 3 Path of light ray in main plane of optical array

整个光学系统的光焦度为总焦距的倒数,系统总焦距由设计者设定,再将式(6)计算的每片透镜的焦距和式(7)计算的入射光线高度代入式(8)中反推出系统

最后一面透镜的曲率半径。反推出的通用式为

$$l'_{k-1} = \frac{t_{j-2} r_{j-2}}{n_{k-1} (r_{j-3} - r_{j-2}) + (n_{k-1} - 1) t_{j-2}} \quad (9)$$

$$r_k = \frac{n_k [h_{k-1} r_{j-1} - h_{k-1} t_{j-1} + \tan u'_{k-1} (l'_{k-1} r_{j-1} - l'_{k-1} t_{j-1} - r_{j-1} t_{j-2} + t_{j-2} t_{j-1})]}{r_{j-1} (\varphi_1 h_1 + \dots + \varphi_{k-1} h_{k-1}) - \Phi h_1 r_{j-1} + h_{k-1} n_k + (l'_{k-1} n_k - l'_{k-1} - n_k t_{j-2} + t_{j-2}) \tan u'_{k-1}} + \frac{-h_{k-1} r_{j-1} + 2h_{k-1} t_{j-1} + \tan u'_{k-1} (-l'_{k-1} r_{j-1} + 2l'_{k-1} t_{j-1} + r_{j-1} t_{j-2} - r_{j-1} t_{j-1} - 2t_{j-2} t_{j-1})}{r_{j-1} (\varphi_1 h_1 + \dots + \varphi_{k-1} h_{k-1}) - \Phi h_1 r_{j-1} + h_{k-1} n_k + (l'_{k-1} n_k - l'_{k-1} - n_k t_{j-2} + t_{j-2}) \tan u'_{k-1}} + \frac{-h_{k-1} t_{j-1} + \tan u'_{k-1} (-l'_{k-1} t_{j-1} + t_{j-2} t_{j-1} + r_{j-1} t_{j-2})}{r_{j-1} (\varphi_1 h_1 + \dots + \varphi_{k-1} h_{k-1}) - \Phi h_1 r_{j-1} + h_{k-1} n_k + (l'_{k-1} n_k - l'_{k-1} - n_k t_{j-2} + t_{j-2}) \tan u'_{k-1}}, \quad (10)$$

式中: l'_{k-1} 为倒数第二片透镜的主面位置; u'_{k-1} 为光线传播到最后一片透镜时光线与光轴的夹角。

一方面, 推导的通用式有助于设计者根据实际需求设定焦距, 网络模型设计出的光学系统是在设计者设定焦距下优化过的光学系统初始结构, 故光学像质更符合设计者要求。另一方面, 推导的通用式能够提高本文深度学习网络模型的通用性, 从而使其能够学习复杂的光学系统初始结构。

在无监督学习中需要将输出的曲率、玻璃变量、厚度这些光学结构参数作为输入来进行光线追迹, 旨在为后续的损失函数计算提供相应的数据, 进而实现反向传播更新神经网络参数, 使得网络模型能设计出结构合理、像质符合要求的光学系统初始结构, 故光线追迹的过程非常重要。光线追迹式为

$$\begin{cases} \sin I = \frac{L-r}{r} \sin U \\ \sin I' = \frac{n \sin I}{n'} \\ U' = U + I - I' \\ L' = r + r \frac{\sin I'}{\sin U'} \end{cases}, \quad (11)$$

式中: I 为光线入射角; I' 为光线出射角; U 为入射光线与光轴的夹角; U' 为出射光线与光轴的夹角; L 为物方截距; L' 为像方折射率; r 为光学表面曲率半径; n 为光线透射前介质折射率; n' 为光线透射后介质折射率。

无监督训练过程并不像监督学习一样具有参考样本供网络模型进行训练学习, 而需要设计相应的自定义损失函数去约束训练。为训练出能设计光学系统的网络模型, 在经过前面的光线追迹之后, 需要对输出进行评价度量。使用均方根 (RMS, E_{RMS}) 点斑半径作为评价标准, 当视场角分别为 0、归一化视场的 7/10 和归一化视场时, 通过对每一条光线进行追迹计算出 RMS 点斑半径, 具体计算式为

$$L_u = \frac{1}{N_H} \sum \sqrt{\frac{1}{N_\lambda N_p} \sum (y_{H,\lambda,p} - \bar{y}_H)^2}, \quad (12)$$

式中: N_H 为视场的数量; N_λ 为波长的数量; N_p 为孔径的数量; $y_{H,\lambda,p}$ 为某一视场某一波长某一孔径下的点斑半径大小; \bar{y}_H 某一视场下的点斑半径大小。

综上, 深度学习的过程中仅通过监督学习进行训练学习不足以进行光学设计: 一方面训练学习所需要

的监督样本数量过少, 不足以支撑深度学习的训练; 另一方面仅进行监督训练, 网络模型设计优化生成的光学系统泛化能力弱。此外, 无监督训练学习虽然可以通过光线追迹计算损失函数的方式对训练进行优化, 但是缺少标准参考样本, 故训练结果与预期结果间会出现巨大偏差。本文将引入光线追迹的无监督损失函数与监督损失函数相结合, 在保证训练结果正确性的同时提升了网络模型的泛化能力, 结合式为

$$L_{\text{final}} = L_s + \omega' \times L_u, \quad (13)$$

式中: L_{final} 为最终的损失; ω' 为无监督损失函数的加权因子。

在将监督学习与无监督学习相结合的方法中, 监督学习可保证网络模型能学习到光学孔径、视场、焦距、厚度范围与曲率、厚度、玻璃参数之间的非线性关系, 无监督学习利用本文所推导的曲率求解通用式和光线追迹公式求解无监督损失, 从而保证网络具有一定的泛化能力, 故最终可以生成更多不同孔径、不同视场组合的透射式光学系统初始结构。

3 分析与讨论

3.1 超参数设置

在进行完整的深度学习训练之前, 需要通过实验调整学习率的大小。在未将学习样本分为多个小样本的情况下, 学习率是指每个 epoch 中参数调整的步长, 学习率过小会导致学习速度过于缓慢, 学习率过大会导致训练损失无法收敛到最小值。网络模型每完成一次对全部样本的深度学习称为一个 epoch。将初始学习率设定为 0.001, epoch 设为 20000 次。如图 4 所示,

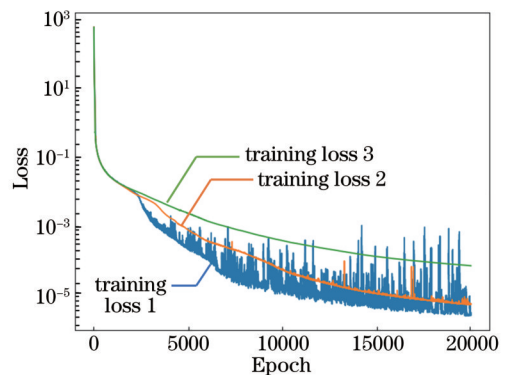


图 4 不同学习率下的训练图

Fig. 4 Training diagram under different learning rates

训练损失 1 曲线为学习率始终为 0.001 时的损失曲线, 训练损失 2 曲线为 epoch 是 1000、学习率动态调整为 0.0001 时的损失曲线, 训练损失 3 曲线为 epoch 是 5000、学习率动态调整为 0.00001 时的损失曲线。可以看出, 随着学习率的不断调整, 深度学习训练损失曲线逐渐稳定, 表明学习率的动态调整有助于训练损失正常收敛。另外, 通过损失曲线的损失大小对比发现, 训练损失 1 曲线比训练损失 3 曲线下落得快, 这是由训练损失 3 曲线学习率降低引起学习速度减缓造成的, 虽然会增加学习时间, 但是能保证深度学习训练过程的稳定和准确性。

在进行深度学习之前, 由于神经网络中参数是随机初始化的, 故输出的曲率半径和厚度都是随机

值, 如图 5(a) 所示。可以看出: 每个面的曲率超过实际需求, 面与面之间相互交叠; 透镜材料选取随机, 光线在系统中不能正常传播, 不能在像面上会聚成像。

通过 2×10^5 次的训练, 神经网络的参数经过了 2×10^5 次更新, 从而训练出合适的深度学习模型。实验采用 NVIDIA RTX3060 显卡和 Intel core i7 处理器所搭建的平台。在输入相关参数之后直接输出合适的系统曲率半径、厚度和玻璃参数, 利用 Python 画出光路图, 如图 5(b) 所示。可以看出, 深度学习之后优化设计出的光学系统结构合理, 透镜材料选取合理, 面与面之间距离合理, 系统在像面上正常会聚成像。

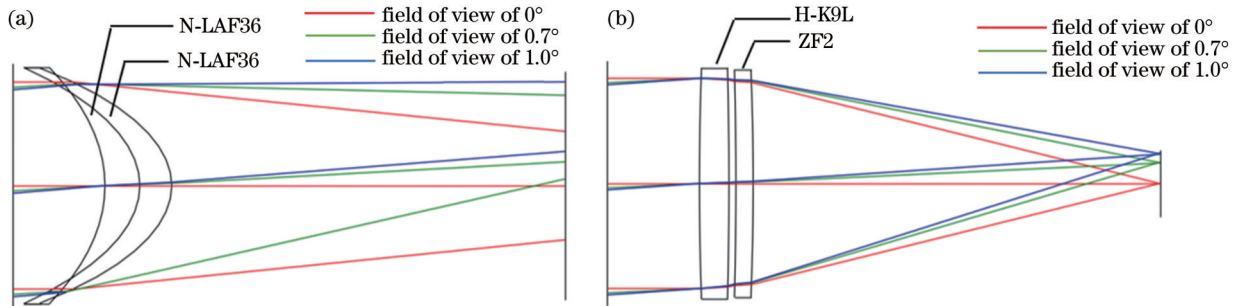


图 5 未经训练生成的光学系统和训练后生成的光学系统。(a) 未经训练生成的光学系统; (b) 训练后生成的光学系统

Fig. 5 Untrained optical system and trained optical system. (a) Untrained optical system; (b) trained optical system

经过深度学习训练过的网络模型能输出相应的玻璃阿贝数和折射率参数, 如图 6 所示。图 6 中为成都光明光电有限责任公司 (CDGM) 生产的玻璃的参数和网络模型设计的 1000 组光学系统中的玻璃参数, 将监督样本和成都光明光电有限责任公司玻璃库作为参考, 对网络模型生成的阿贝数与折射率范围进行限定, 保证输出玻璃参数都在成都光明光电有限责任公司玻璃库内, 并通过最邻近搜索算法搜寻与输出玻璃参数相近的玻璃作为选取的玻璃。

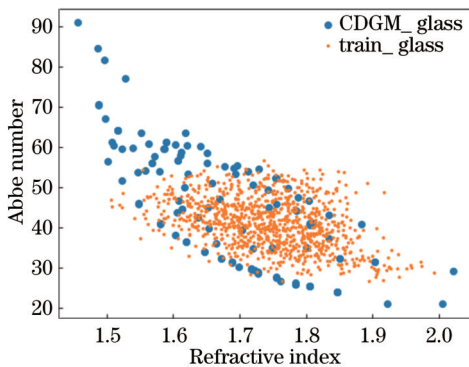


图 6 网络模型输出玻璃与玻璃库对比

Fig. 6 Comparison between output glass obtained by network model and glass library

3.2 仿真验证

ZeBase 镜头库中可供参考的镜头有限, 选取其中

8 组两片透镜的镜头作为监督训练的参考, 并分为 8 组分别进行训练。深度学习训练数据与测试数据分组如图 7 所示, 其中 $F^\#$ 为 F 数, HFOV 为半视场角度数。可以发现: $K=0$ 对应于所有参考镜头的孔径和半视场数据, 用于表示孔径和视场角特定组合的参考镜头; $K=1$ 对应于 7 组训练镜头和 1 组测试镜头, 对训练镜头特定的孔径、视场、焦距、最小厚度和厚度范围等数据进行深度学习, 利用训练完成的网络模型设计优化出光学系统, 并与参考镜头对比其 RMS 点斑半径大小; 其他分组均与 $K=1$ 类似, 以此验证深度学习训练得到的网络模型具有光学系统优化设计能力。

完成训练的深度学习网络模型, 在给定测试所需的孔径、视场、焦距、最小厚度、厚度范围参数后设计出光学系统。为了便于对比, 将镜头焦距设定为 100 mm, 同时将相同孔径、视场的参考镜头焦距均缩放到 100 mm, 具体对比如图 8 和图 9 所示。图中分别对比了深度学习设计的镜头与其相同孔径、视场的参考镜头的光学结构图、点列图、场曲图和畸变图。通过对比可以看出, 深度学习设计的镜头 RMS 点斑半径大小与参考透镜 RMS 点斑半径大小相近, 甚至部分深度学习透镜 RMS 点斑半径小于参考透镜, 表明该网络模型具备设计满足实际成像质量要求的透射式光学系统初始结构的能力。

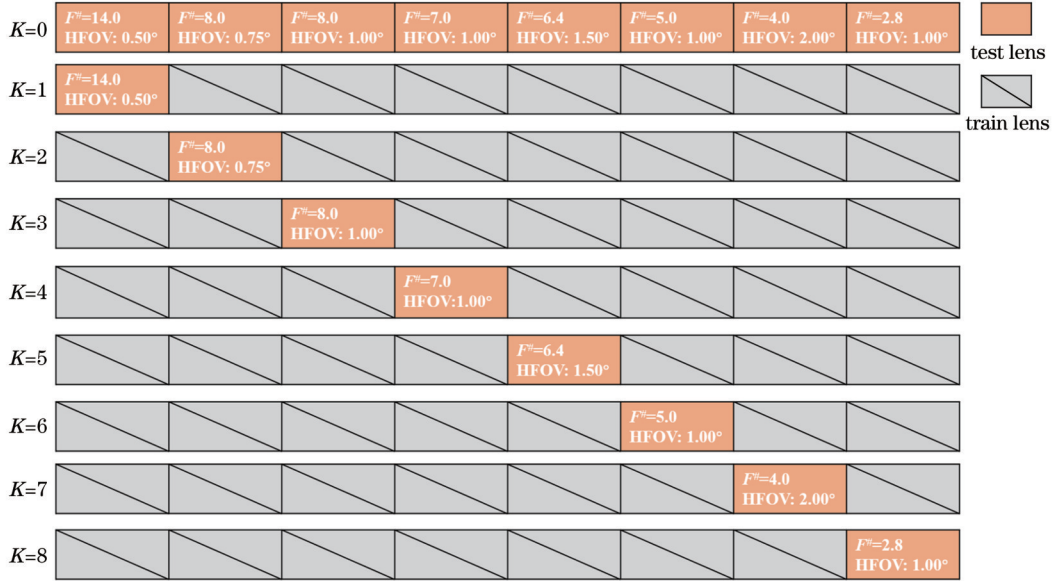


图 7 深度学习训练数据与测试数据分组

Fig. 7 Grouping of deep learning training data and test data

除了验证深度学习网络模型与相同孔径、相同视场的参考光学系统的光学性能外,还需要验证深度学习网络模型在不同焦距下设计光学系统初始结构的泛化能力,如图 10 所示。图 10(a)~(c)分别为焦距为 1、100、1000 mm 的情况下所对应的 RMS 点斑大小。孔径可根据焦距与 F 数计算得到,故用 F 数来表示孔径, F 数在 2.0~14.0 范围内平均生成 1000 组数据。同样,半视场在 $0.5^\circ\sim 2.0^\circ$ 范围内平均生成 1000 组数据,网络模型输出的不同孔径、视场下的光学系统共 1×10^6 组,利用热力图来表示不同孔径、视场下生成的初始结构的点斑半径大小。从图 10(a)~(c)中可以看出,在不同焦距下,网络模型除生成与参考镜头相当的光学系统外,能在不同的孔径、视场下生成相应的光学系统,点斑半径大小随着 F 数的增大而减小,即在相同焦距下,点斑半径大小随着孔径的减小而减小。图 10(d)~(f)分别为焦距为 1、100、1000 mm 下模型生成的光学系统光学像差满足条件的情况。以图 10(d)为例,设定当焦距为 1 mm 的情况下生成的光学系统的 RMS 点斑半径大小小于 0.01 mm 时,所设计的光学系统满足要求,即视为设计成功,通过饼状图可以看出网络设计光学系统的成功率高达 96.403%。当焦距为 100 mm 时,网络设计光学系统的成功率为 98.799%。当焦距为 1000 mm 时,网络设计光学系统成功率为 96.673%。图 10 表明该网络模型具有较好的泛化能力,并且设计的光学系统基本满足要求。

上述实验通过学习率等超参数的调整使得网络训练更加稳定,并通过有限的参考透镜交叉验证了深度学习训练出的网络模型能够设计出与参考透镜性能相

当的光学系统。同时,在合适的孔径和视场范围内,网络可以生成更多的光学系统初始结构,具有一定的泛化能力。

4 结 论

提出了一种利用深度学习进行透射式光学系统初始结构优化设计的方法,结合监督训练和无监督训练对样本进行训练,监督训练帮助 DNN 模型学习光学系统的结构特征,无监督训练将光线追迹和所推导的通用式引入到深度学习框架中,从而可以在设定焦距下优化更多的光学系统。经过 2×10^5 次训练的网络模型能够设计出与参考透镜光学性能相当的光学系统初始结构。经过实验仿真,不同焦距下的网络模型能够在规定的孔径、视场范围内生成 1×10^6 组光学系统初始结构,并且在规定的 RMS 点斑半径下设计的成功率优于 96.403%,说明经过深度学习之后网络模型具有一定的泛化能力。所提的基于深度学习进行透射式光学系统初始结构优化设计的方法,为设计者提供了一种初始结构的选择方式,提高了光学设计的效率,更为光学优化设计提供了一种新的优化方式和优化思路。

在未来,深度学习在光学设计方面有望更加深入,利用深度学习解决非线性关系问题的优势,结合调制传递函数、光学像差、偏振像差等光学系统评价标准,实现从初始结构的设计到特定的光学系统优化设计,甚至利用深度学习在图像处理等方面的发展,可能做到从光学系统设计、光学系统成像、图像处理和分析整个过程的学习优化。

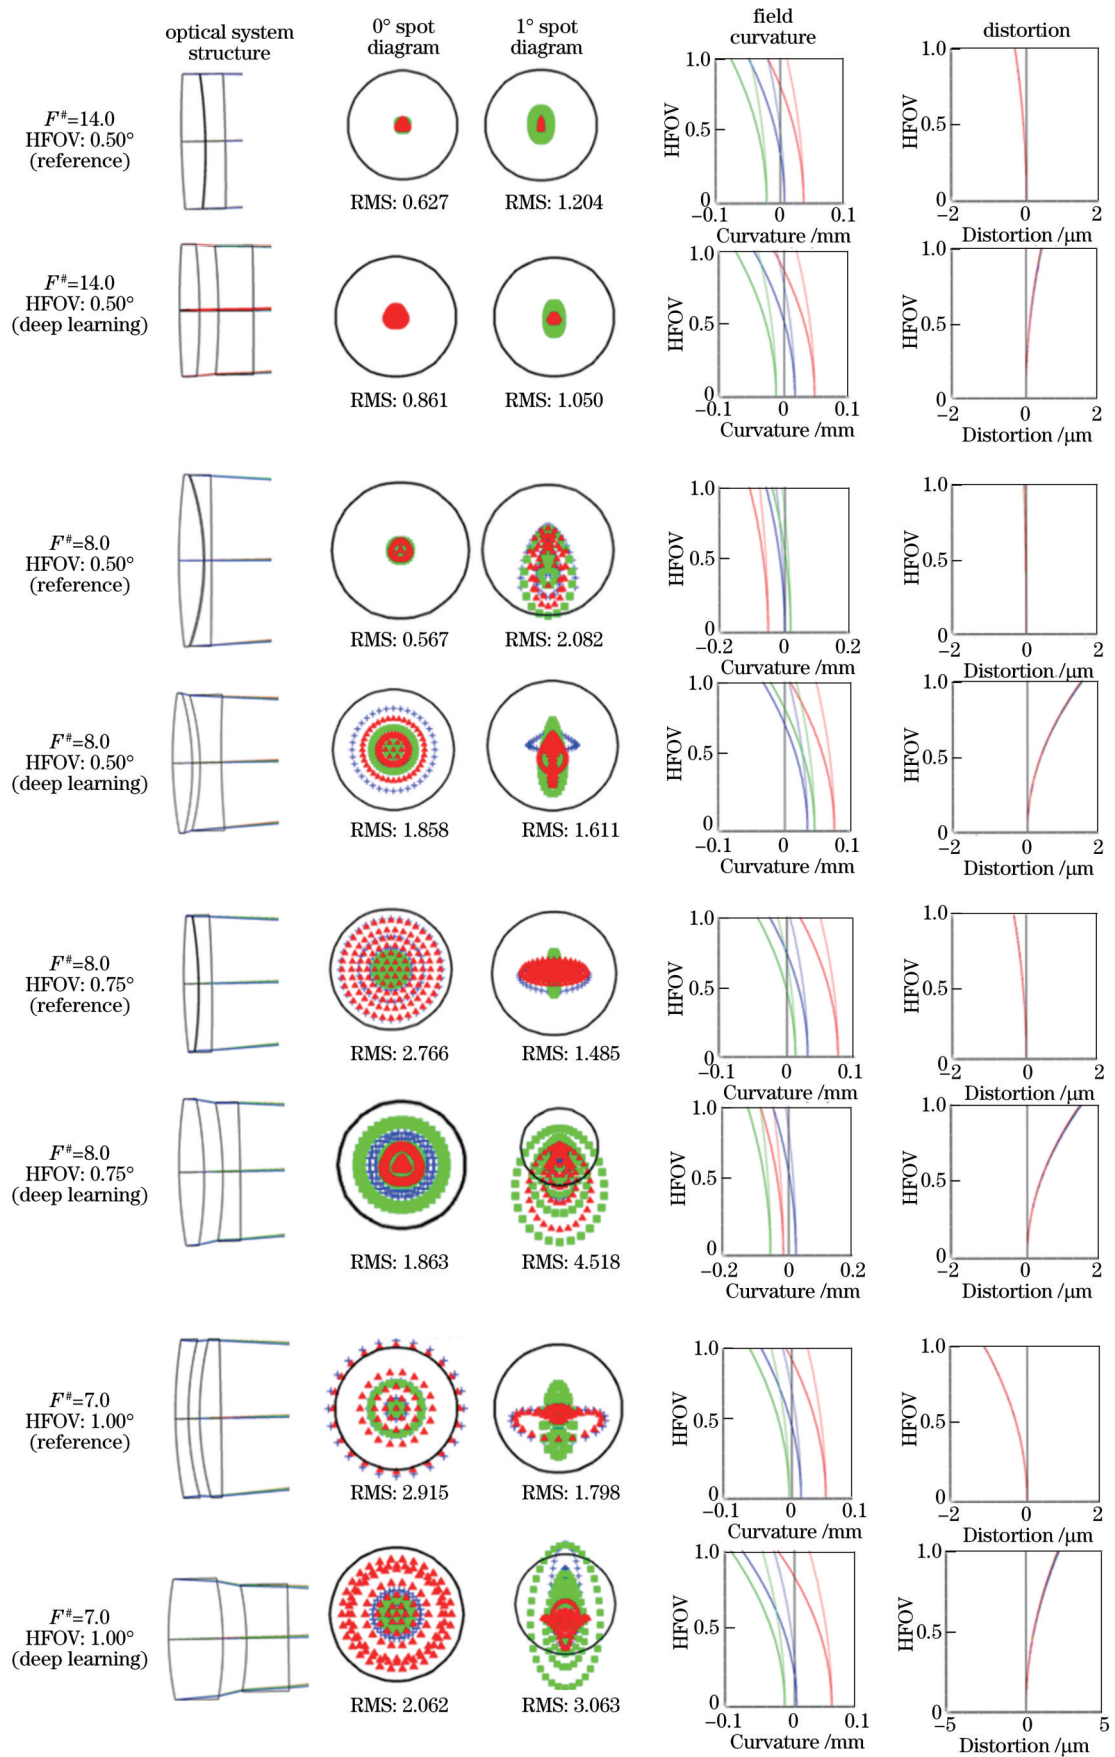


图 8 $F^\#$ 为 14.0、8.0 和 7.0 时不同视场下 4 组深度学习设计的镜头与参考镜头对比结果

Fig. 8 Comparison results of four groups of deep learning designed lenses and reference lenses under different apertures at $F^\#$ of 14.0, 8.0 and 7.0

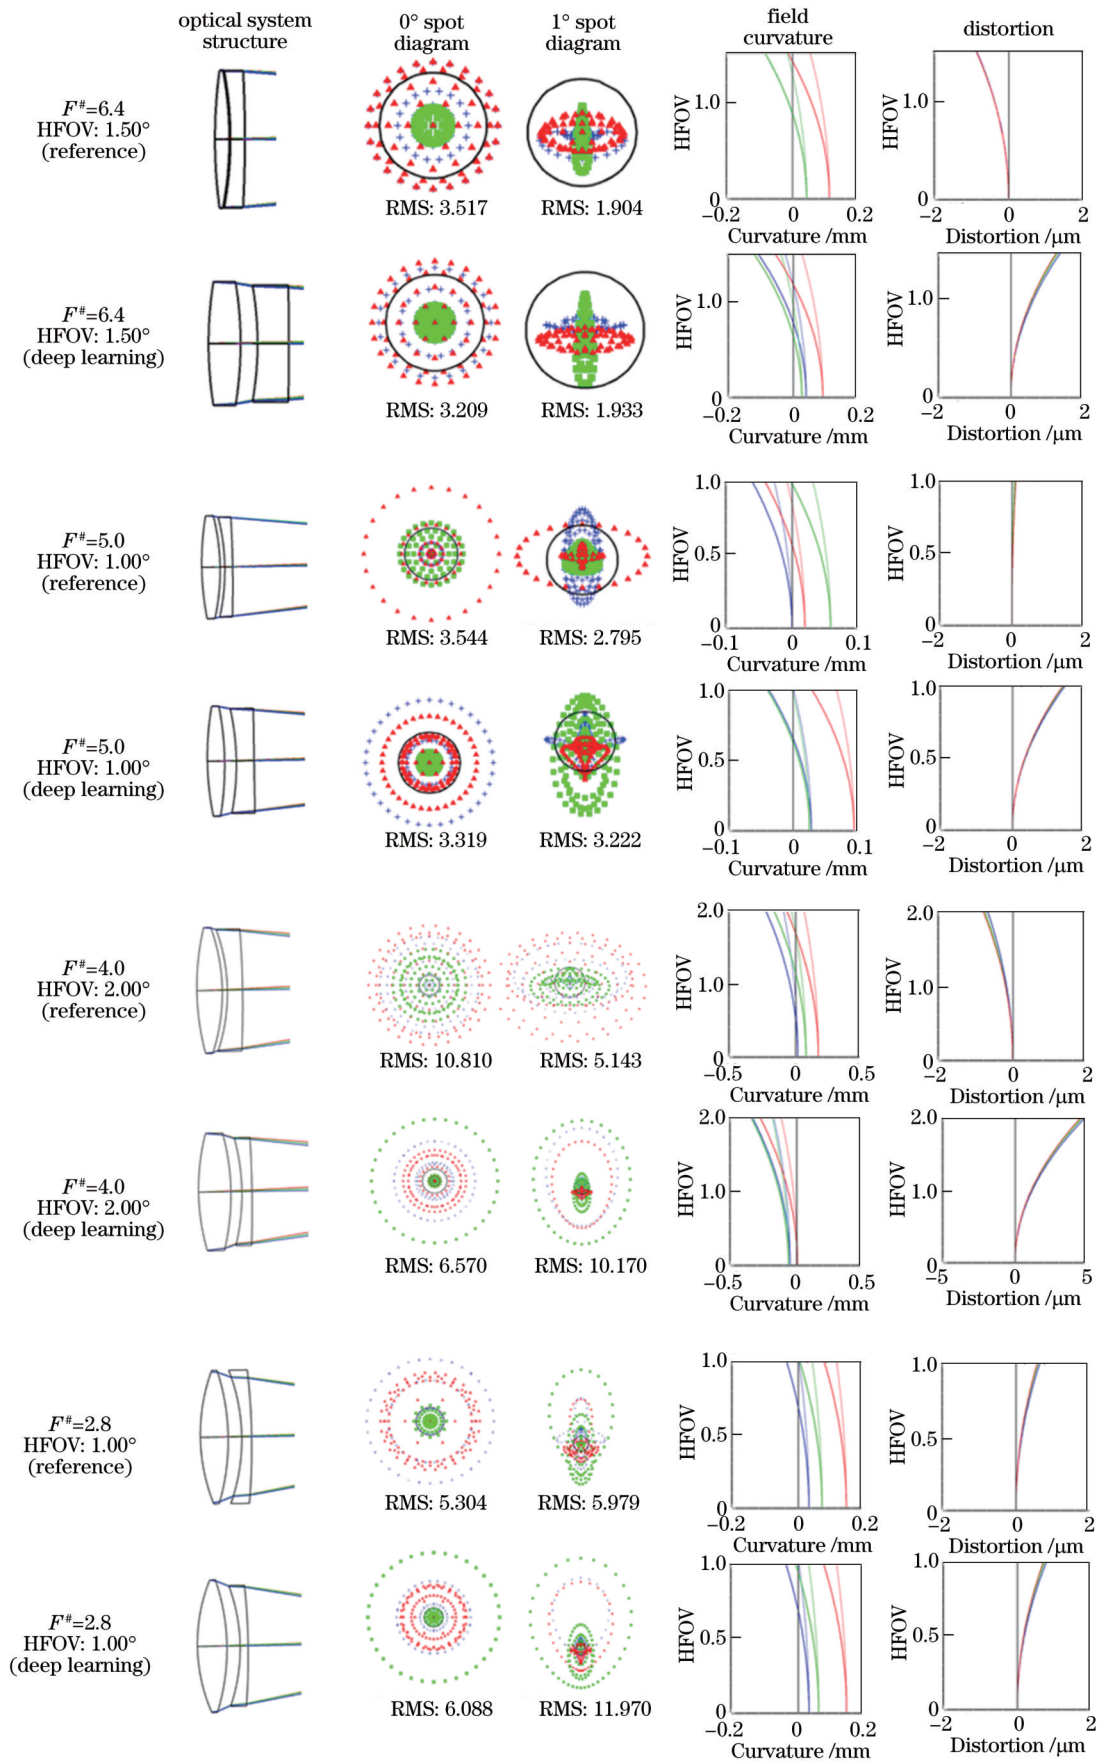


图 9 $F^\#$ 为 6.4、5.0、4.0 和 2.8 时不同视场下 4 组深度学习设计的镜头与参考镜头对比结果

Fig. 9 Comparison results of four groups of deep learning designed lenses and reference lenses under different apertures at $F^\#$ of 6.4, 5.0, 4.0 and 2.8

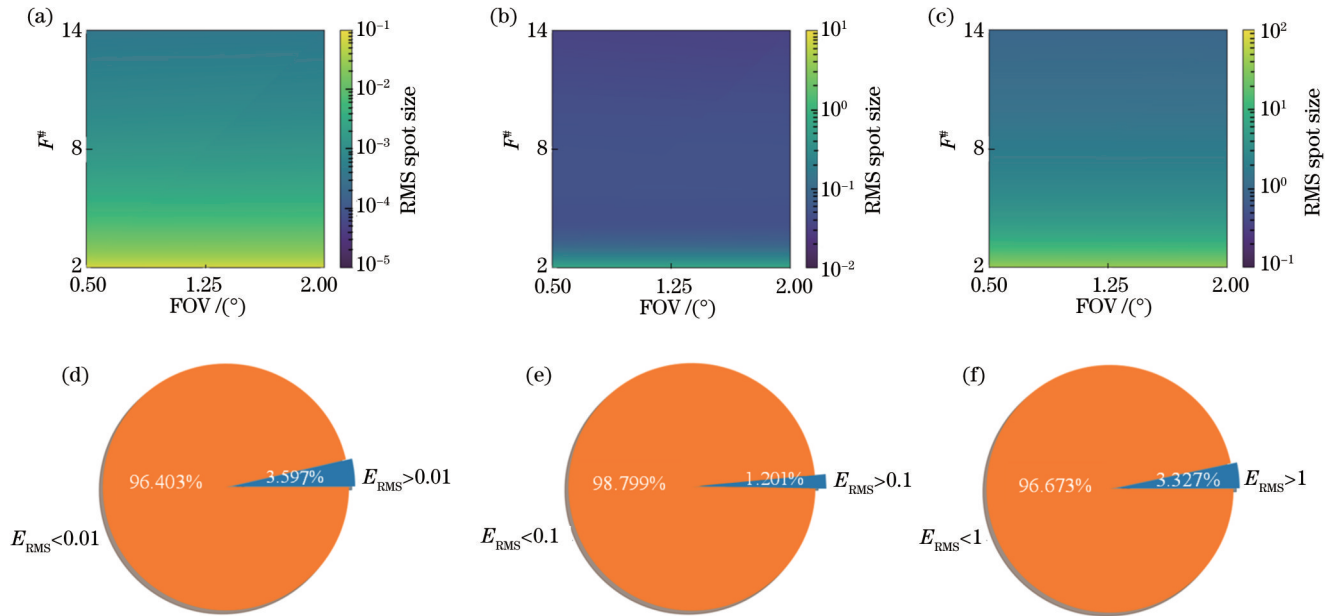


图 10 网络模型泛化能力测试结果。(a)焦距为 1 mm 时的光学系统点斑半径热力图;(b)焦距为 100 mm 时的光学系统点斑半径热力图;(c)焦距为 1000 mm 时的光学系统点斑半径热力图;(d)焦距为 1 mm 时光学系统设计成功的比例;(e)焦距为 100 mm 时光学系统设计成功的比例;(f)焦距为 1000 mm 时光学系统设计成功的比例

Fig. 10 Test results of network model generalization capability. (a) Spot radius thermal diagram of optical system at focal length of 1 mm; (b) spot radius thermal diagram of optical system at focal length of 100 mm; (c) spot radius thermal diagram of optical system at focal length of 1000 mm; (d) success proportion of optical system design at focal length of 1 mm; (e) success proportion of optical system design at focal length of 100 mm; (f) success proportion of optical system design at focal length of 1000 mm

参 考 文 献

- 毛文炜. 现代光学镜头设计方法与实例[M]. 北京: 机械工业出版社, 2013.
Mao W W. Modern optical lens design: methods and examples [M]. Beijing: China Machine Press, 2013.
- Meiron J. Damped least-squares method for automatic lens design[J]. Journal of the Optical Society of America, 1965, 55(9): 1105-1109.
- Sun J F, Li X T. Automatic design of machine vision lens based on improved genetic algorithm and damped least squares[J]. Proceedings of SPIE, 2021, 11895: 118950X.
- Glatzel E, Wilson R. Adaptive automatic correction in optical design[J]. Applied Optics, 1968, 7(2): 265-276.
- Forbes G W, Jones A E. Towards global optimization with adaptive simulated annealing[J]. Proceedings of SPIE, 1991, 1354: 144-153.
- Höschel K, Lakshminarayanan V. Genetic algorithms for lens design: a review[J]. Journal of Optics, 2019, 48(1): 134-144.
- 唐运海, 吴泉英, 陈晓翌, 等. 基于遗传算法的渐进多焦点镜片子午线优化设计[J]. 光学学报, 2014, 34(9): 0922005.
Tang Y H, Wu Q Y, Chen X Y, et al. Optimization design of the meridian line of progressive addition lenses based on genetic algorithm[J]. Acta Optica Sinica, 2014, 34(9): 0922005.
- Issiki M, Ono H, Hiraga K, et al. Lens design: global optimization with escape function[J]. Optical Review, 1995, 2(6): 463-470.
- Menke C. Application of particle swarm optimization to the automatic design of optical systems[J]. Proceedings of SPIE, 2018, 10690: 106901A.
- 李映函, 吕杰, 江琳, 等. 基于混合粒子群算法的光子器件逆向设计[J]. 激光与光电子学进展, 2022, 59(11): 1113001.
Li Y H, Lü J, Jiang L, et al. Reverse design of photonic devices based on a hybrid particle swarm algorithm[J]. Laser & Optoelectronics Progress, 2022, 59(11): 1113001.
- Yang T, Jin G F, Zhu J. Automated design of freeform imaging systems[J]. Light: Science & Applications, 2017, 6(10): e17081.
- Yang T, Cheng D W, Wang Y T. Direct generation of starting points for freeform off-axis three-mirror imaging system design using neural network based deep-learning[J]. Optics Express, 2019, 27(12): 17228-17238.
- Gannon C, Liang R G. Using machine learning to create high-efficiency freeform illumination design tools[EB/OL]. (2018-12-12)[2022-01-05]. <https://arxiv.org/abs/1903.11166>.
- Côté G, Lalonde J F, Thibault S. Extrapolating from lens design databases using deep learning[J]. Optics Express, 2019, 27(20): 28279-28292.
- 张航, 陈嘉文, 胡月姣, 等. 基于深度学习和程能映射的自由配光设计[J]. 光学学报, 2022, 42(10): 1022003.
Zhang H, Chen J W, Hu Y J, et al. Freeform light distribution design based on deep learning and length-energy mapping[J]. Acta Optica Sinica, 2022, 42(10): 1022003.
- Berthelot David. MixMatch: a holistic approach to semi-supervised learning[EB/OL]. (2019-05-06)[2022-01-05]. <https://arxiv.org/abs/1905.02249>.
- Sharma P, Singh A. Era of deep neural networks: a review[C]// 2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT), July 3-5, 2017, Delhi, India. New York: IEEE Press, 2017.
- Chen Y R, Xie Y, Song L H, et al. A survey of accelerator architectures for deep neural networks[J]. Engineering, 2020, 6(3): 264-274.
- Kılıçarslan S, Adem K, Çelik M. An overview of the activation functions used in deep learning algorithms[J]. Journal of New Results in Science, 2021, 10(3): 75-88.

- [20] Klambauer G, Unterthiner T, Mayr A, et al. Self-normalizing neural networks[C]//31st Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, CA, USA. Spain: Curran Associates, Inc., 2017: 971-980.
- [21] Sun K L, Yu J M, Zhang L, et al. A convolutional neural network model based on improved softplus activation function [M]//Abawajy J H, Choo K K R, Islan R, et al. International conference on applications and techniques in cyber intelligence ATCI 2019. Advances in intelligent systems and computing. Cham: Springer, 2019, 1017: 1326-1335.
- [22] 梁铨廷. 物理光学[M]. 4 版. 北京: 电子工业出版社, 2012: 41-42.
- Liang Q T. Physical optics[M]. 4th ed. Beijing: Publishing House of Electronics Industry, 2012: 41-42.

Initial Structure Design for Refractive Optical System Based on Deep Learning

Shi Haodong¹, He Chunfeng^{1,2*}, Wang Jiayu^{1,2}, Yang Shuai^{1,2}, Xu Miao^{1,2}, Sun Hongyu^{1,2},
Li Yingchao¹, Fu Qiang¹

¹*Jilin Provincial Key Laboratory of Space Optoelectronics Technology, Changchun University of Science and Technology, Changchun 130022, Jilin, China;*

²*School of Opto-Electronic Engineering, Changchun University of Science and Technology, Changchun 130022, Jilin, China*

Abstract

Objective The design of an optical system can be understood as a process of seeking optimal solutions of parameters. There is a complex nonlinear relationship between optical aberration and structural parameters of an optical system. Traditional optical design usually selects an initial structure similar to the expected structure on the basis of experience or from a public lens library. Then, the initial structure is optimized by local optimization algorithms such as damped least squares and the adaptive method, and global optimization algorithms such as simulated annealing, the genetic algorithm, the escape algorithm, and the particle swarm optimization algorithm. Therefore, selecting an appropriate initial structure is essential for subsequent optimization effect and efficiency. However, the current initial structure design method is usually similar to a trial-and-error process, and designers mainly rely on design experience to determine the most appropriate initial structure for different design requirements. This method limits the design efficiency and subsequent optimization of the optical system to a certain extent. In this paper, the proposed optimal design method for the initial structure of a refractive optical system based on deep learning provides designers with a way to choose the initial structure and improves the efficiency of optical design.

Methods First, the structural characteristic data of the reference lens in the optical lens library are learned through supervised training. Then, an unsupervised training model based on ray tracing is constructed. The corresponding general formula for solving optical parameters is derived, and the structure of the optical system under a specific focal length is optimized by unsupervised training. After that, unsupervised training is combined with supervised training to ensure the correctness of the training results and improve the generalization ability of the network model. The super parameters of the network model are adjusted, and the rationality of the system structure is compared before and after the training. Finally, the gap between the output of the network model and the reference lens is compared through the cross-validation experiment, and the generalization ability of the deep learning network model for the design of the initial structure of the optical system under different focal lengths is verified.

Results and Discussions Before the training, the size of the super parameter is dynamically adjusted. The comparison of different loss curves in Fig. 4 indicates that the training loss curve 1 drops faster than the training loss curve 3. This is because the learning rate of the training loss curve 3 decreases, which can increase the learning time but ensure the stability and accuracy of the deep learning training process. After deep learning, the optimized optical system is designed. Lens parameters are selected reasonably, and the distance between surfaces is appropriate. The system can perform normal imaging on the image surface (Fig. 5). After cross-validation training (Fig. 8), the comparison shows that the root-mean-square (RMS) spot radius of the lens designed by deep learning is similar to that of the reference lens, and some of the RMS spot radii of the deep learning lenses are even smaller than that of the reference lens. This indicates that the network model can design the initial structure of the refractive optical system that meets the requirements of the actual imaging quality. Finally, the initial structures under different entrance pupil distortions (EPDs) and fields of view (FOVs) are

designed, and the success rate of optimal design is better than 96.403%. This indicates that the network model has a good generalization ability.

Conclusions In this work, a deep learning method for the optimal design of the initial structure of the refractive optical system is proposed, combining supervised training with unsupervised training. Supervised training helps the deep neural network model to learn the structural characteristics of the optical system, and unsupervised training introduces ray tracing and the general formula derived in this paper into the deep learning framework to optimize more optical systems at a set focal length. After 2×10^5 times of training, the network model can design the initial structure of the optical system with the same optical properties as the reference lens. The simulation shows that under different focal lengths, the network model can generate one million groups of initial optical system structures within the specified EPD and FOV, and the design success rate is better than 96.403% under the specified RMS spot radius. This indicates that the network model has a certain generalization ability after deep learning. The proposed optimal design method for the initial structure of the refractive optical system based on deep learning in this paper provides designers with a way to choose the initial structure, improves the efficiency of optical design, and renders a new optimization method and optimization idea for optical optimal design.

Key words optical design; deep learning; automatic optimization; initial structure; ray tracing