

Reinforcement Learning für die automatisierte Auslegung drei- bis fünflinsiger Systeme unter Berücksichtigung Seidelscher Aberrationen

Cailing Fu*, Dominik Onyszkiewicz*, Jochen Stollenwerk* **, Carlo Holly* **

*RWTH Aachen University – Lehrstuhl für Technologie Optischer Systeme TOS, Aachen

**Fraunhofer-Institut für Lasertechnik ILT, Aachen

<mailto:cailing.fu@tos.rwth-aachen.de>

Das Design optischer Systeme ist in der Praxis nach wie vor ein zeitaufwendiger iterativer Prozess. Dieser Beitrag untersucht die Verwendung von bestärkendem Lernen (Reinforcement Learning), um einen "Agenten" das Optikdesign eigenständig und ohne Trainingsdaten erlernen zu lassen. Dem Agenten stehen dafür Aktionen zur Manipulation des Systems sowie die Seidelschen Aberrationen zur Bewertung der Abbildungsqualität des optischen Systems zur Verfügung. Nach einer initialen Anlernphase ist der Agent in der Lage, binnen weniger Sekunden optische Systeme innerhalb des erlernten Anwendungsbereichs auszulegen.

1 Einführung und Stand der Technik

Für das automatisierte Optikdesign etablieren sich neue Methoden, mit dem Ziel, den Designzyklus zu vereinfachen sowie neuartige, bisher unbekannte Lösungen zu generieren. Dafür werden beispielsweise evolutionäre Algorithmen [1],[2] sowie Erweiterungen für lokale Suchalgorithmen [3],[4] genutzt. Darüber hinaus wird die Auslegung von Systemen, die ausschließlich mit Kataloglinsen realisiert werden sollen, untersucht [5],[6]. Mit der fortschreitenden Entwicklung der künstlichen Intelligenz wird seit wenigen Jahren auch an Methoden des maschinellen Lernens zur Auslegung optischer Systeme geforscht [7]–[9].

Dieser Artikel befasst sich mit Reinforcement Learning zur Auslegung von optischen Systemen mit drei bis fünf Linsen.

2 Reinforcement Learning für das Optikdesign

Reinforcement Learning ist eine Klasse von maschinellen Lernalgorithmen, in welcher ein Agent die Auswirkung seiner Aktionen in einer Umgebung erlernt. Die Auswirkung der Aktionen werden mittels einer Bewertungsfunktion beurteilt und belohnt oder bestraft. Die Interaktion zwischen Agenten und Umgebung ist in **Abb. 1** dargestellt. Das Ziel des Agenten ist es, die kumulierte Belohnung über alle Aktionen innerhalb einer Episode (im Fall des Optikdesigns – eine Optikauslegung) zu maximieren.




Abb. 1 Interaktion zwischen Agenten und Umgebung. Eine Iteration definiert einen Zeitschritt

Zur Untersuchung von Reinforcement Learning für die automatisierte Auslegung von Linsensystemen werden verschiedene Systeme mit Anforderungen an die numerische Apertur (NA) und Abstände zur Bildebene (BFL) betrachtet. Als Ausgangssystem werden dabei Aneinanderreichungen von planparallelen Platten genutzt. Das Zielsystem soll die Seidelschen Aberrationen dritter Ordnung unter monochromatischem Lichteinfall und 20° Halbfeldwinkel minimieren. Die zur Evaluierung betrachteten Systeme sind in **Tab 1** Überblick über die verschiedenen untersuchten Anforderungen, aufgelistet, wobei die Anforderungen an System A leichter zu erfüllen sind als die von B.

System	BFL	NA
A	100 mm	0.025
B	80 mm	0.04
Variabel	80 mm - 120 mm	0.02 - 0.04

Tab 1 Überblick über die verschiedenen untersuchten Anforderungen.

3 Training des Agenten

Das Training des Agenten kann entweder für ein fest vorgegebenes System oder für eine Bandbreite an variablen Systemen erfolgen. Außerdem ist es möglich, einen bereits trainierten Agenten auf spezifische Anforderungen weiter zu trainieren. In **Abb. 2** ist die Belohnung eines Agenten für 10 Millionen Zeitschritte auf das System B dargestellt. Durch eine höhere Linsenanzahl von 4 oder 5 Linsen kann im Vergleich zu einem 3 Linsler eine höhere Belohnung erreicht werden. Die Verwendung von 4 oder 5 Linsen ergeben in diesem Vergleich eine nahezu identische Belohnung. In **Abb. 3** wurde der Agent zuerst für 10 Millionen Zeitschritte auf einen variablen Anforderungsbereich trainiert (Pre-Training) und dann weiter für 5 Millionen Zeitschritte auf A oder B

trainiert. Im Vergleich zu **Abb. 2** erreicht der Agent mit Pre-Training nun höhere Belohnungen, insbesondere bei dem System mit 4 oder 5 Linsen. Auch hier ist zu erkennen, dass mehrere Linsen für eine höhere Belohnung sorgen.




Abb. 2 Training für das System B für eine verschiedene Anzahl von Linsen.

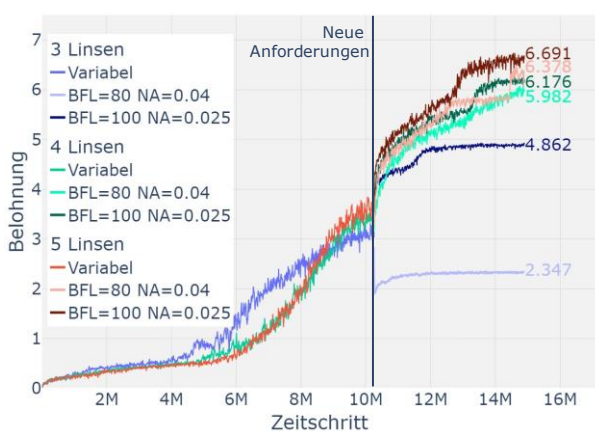


Abb. 3 Training von ~10M Schritten auf variable Systemanforderungen. Darauffolgendes zielspezifisches Training von 5M Schritten für die Anforderungen A und B.

4 Auslegung von Systemen durch den Agenten

Bei der Verwendung des trainierten Agenten mit Pre-Training ergeben sich die in **Abb. 4** abgebildeten Systeme. Während das System A bereits als dreilinsiges System geringe Seidelsche Aberrationswerten aufweist, kann der Agent bei Systemen des Types B geringere Aberrationswerte erzielen, indem eine höhere Linsenanzahl verwendet wird. Eine Auslegung erfolgt durch den Agenten innerhalb von weniger als 2 Sekunden.

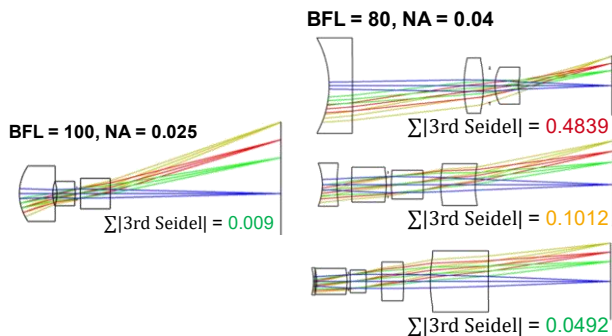


Abb. 4 Beispielsysteme, welche von Agenten mit Pre-Training ausgelegt wurden.

5 Zusammenfassung und Ausblick

Unterschiedliche Arten von optischen Systemen können mit Hilfe eines Reinforcement Learning Agenten ausgelegt werden. Die Anzahl der verwendeten Linsen spielt dabei eine entscheidende Rolle. Je mehr Linsen verwendet werden, desto genauer können die Anforderungen erfüllt werden. In der Optikfertigung werden jedoch meist geringere Linsenanzahlen bevorzugt. Bei der Lernphase ist es vorteilhaft, mithilfe von Pre-Training auf verschiedene Arten von Zielsystemen zu trainieren, sodass der Agenten den Optimierungsraum ausführlich erkunden kann. Ein darauffolgendes anforderungsspezifisches Training ermöglicht eine höhere Belohnung im Vergleich zum Training ohne Pre-Training.

6 Danksagung

Dieses Projekt wurde gefördert durch die Deutsche Forschungsgemeinschaft (DFG) im Rahmen der Exzellenzstrategie des Bundes und der Länder – EXC-2023 Internet of Production – 390621612.

Literatur

- [1] B. F. Carneiro de Albuquerque, F. Luis de Sousa, and A. S. Montes, "Multi-objective approach for the automatic design of optical systems," *Optics Express* **24**, pp. 6619–6643 (2016).
- [2] C. C. Olson, "Automated design of optical architectures using novel encoding methods and a multi-objective optimization framework," in *Novel Optical Systems, Methods, and Applications XXII*, Vol. 11105 (SPIE, 2019).
- [3] D. C. Dilworth, "Novel global optimization algorithms: binary construction and the saddle-point method," in *Current Developments in Lens Design and Optical Engineering XIII*, Vol. 84860 (SPIE, 2012).
- [4] M. van Turnhout, P. van Grol, F. Bociort, and H. P. Urbach, "Obtaining new local minima in lens design by constructing saddle points," *Optics Express* **23**, pp. 6679–6691 (2015).
- [5] G. König, C. Fu, J. Stollenwerk, C. Holly, and P. Loosen, "Automated lens design for optical systems consisting of stock lenses," *Optics Express* **29**, pp. 39027–39041 (2021).
- [6] M. D. Young, "Global design of an off-the-shelf objective lens with no a priori design and macro-enabled optimization," in *Optical Engineering*, Vol. 61(10) (SPIE, 2022).
- [7] G. Côté, J.-F. Lalonde, and S. Thibault, "Deep learning-enabled framework for automatic lens design starting point generation," *Optics Express* **29**, pp. 3841–3854 (2021).
- [8] G. Côté, Y. Zhang, C. Menke, J.-F. Lalonde, and S. Thibault, "Inferring the solution space of microscope objective lenses using deep learning," *Optics Express* **30**, pp. 6531–6545 (2022).
- [9] C. Fu, J. Stollenwerk, and C. Holly, "Reinforcement learning for guiding optimization processes in optical design," in *Applications of Machine Learning 2022*, Vol. 12227 (SPIE, 2022).