

Kalibrierung von Lichtmodulatoren mit physikalisch interpretierbaren neuronalen Netzen

Andreas Brenner*, Markus Zimmermann*, Tobias Haist*, Stephan Reichelt*

*Institut für Technische Optik, Universität Stuttgart

mailto:andreas.brenner@ito.uni-stuttgart.de

Für die Kalibrierung eines phasenschiebenden räumlichen Lichtmodulators (SLM) wurde ein physikalisch interpretierbares neuronales Netz entwickelt, das die realen Bedingungen des optischen Aufbaus möglichst genau modelliert. Die Gewichte werden durch eine Camera-in-the-Loop-Kalibrierung an den realen Aufbau angepasst. Die Methode lässt eine Interpretation der Gewichte des neuronalen Netzes zu und zeigt eine hohe Stabilität gegenüber Veränderungen im optischen Aufbau.

1 Motivation

Um komplexe Wellenfelder präzise und dynamisch zu beeinflussen, kommen phasenschiebende räumliche Lichtmodulatoren (engl. Spatial Light Modulators, SLMs) zum Einsatz. Ihre Anwendungsgebiete reichen von der Lasermaterialbearbeitung über holografische Pinzetten bis hin zu holografischen Displays und AR/VR-Technologien.

Da klassische Berechnungsmethoden für computer-generierte Hologramme (CGHs) wie der Stochastic Gradient Descent (SGD) die realen Randbedingungen des optischen Aufbaus in der Regel nicht berücksichtigen, ist die Wiedergabequalität im Vergleich zur Simulation deutlich reduziert. Um die Qualität zu steigern, ist eine Kalibrierung erforderlich, die auf einem möglichst präzisen Modell des optischen Aufbaus basiert. In unserem Fall wird dieses Modell durch ein physikalisch interpretierbares neuronales Netz realisiert, das die physikalischen Zusammenhänge im optischen System berücksichtigt. Dabei werden unter anderem inhomogene Beleuchtung, die nichtlineare Kennlinie des SLMs und optische Aberrationen modelliert. Das Modell wird verwendet, um eine Camera-in-the-Loop (CITL)-Kalibrierung durchzuführen, wie sie von Peng et al. für Near-Eye-Displays vorgeschlagen wurde [1].




Abb. 1 Schematische Skizze des Versuchsaufbaus. Die Hologrammgeometrie entspricht einem Fourier-Hologramm.

2 Aufbau des neuronalen Netzes

Der verwendete Versuchsaufbau entspricht einem Fourier-Hologramm (siehe Abbildung 1). Eine Punktlichtquelle wird dabei ins Fernfeld abgebildet. Auf dem reflektiven SLM wird ein Phasenhologramm eingeschrieben. Ein Kamerasensor zeichnet die Intensitätsverteilung im Fernfeld auf.

Im einfachsten Fall lässt sich dieser optische Aufbau, also die Propagation ins Fernfeld, durch eine Fourier-Transformation beschreiben. Die Pixelgrößen in der Simulation werden durch Zero-Padding an die Realität angepasst. Dieses vereinfachte Modell reicht jedoch nicht aus, um die physikalischen Bedingungen des Versuchsaufbaus korrekt abzubilden. Daher wird es durch verschiedene Schichten (engl.: layer) eines neuronalen Netzes erweitert, von denen jede einen spezifischen Einfluss beschreibt.

Mit einem Phase-to-Voltage-Layer wird die nicht-lineare Kennlinie des SLMs modelliert, also der Zusammenhang zwischen eingeschriebenem Grauwert und tatsächlicher Phasenänderung. Hierfür wird ein Polynom 10. Grades verwendet:

$$p_{10}(x) = \sum_{i=0}^{10} a_i(x - b)^i$$

Das Pixelübersprechen (engl. Fringing Field Effekt) am SLM wird durch einen Convolutional 2D Layer modelliert, also einer Faltung der Inputphase mit einem 3x3 Faltungskern.

Optische Aberrationen im Aufbau, etwa verursacht durch Linsen oder Polarisatoren, werden mithilfe eines Zernike-Layers modelliert. Die Gleichung

$$W(\rho, \theta) = \sum_{i=1}^N a_i Z_i(\rho, \theta)$$

beschreibt die Abweichung $W(\rho, \theta)$ von einer idealen Wellenfront, wobei die einzelnen Zernike-Polynome $Z_i(\rho, \theta)$ mit einem Gewichtungsfaktor a_i multipliziert werden.

Die Beleuchtungswellenfront am SLM wird durch eine Gaußverteilung beschrieben. Um eine inhomogene Beleuchtung zu modellieren, wird die Gesamtverteilung als Summe von drei Gaußverteilungen dargestellt, wobei je ein Gewichtungsfaktor, die Breite und der Schwerpunkt trainierbare Parameter sind.

Ein zweiter Strang des neuronalen Netzes modelliert das am SLM ungebogene Licht, welches in die nullte Beugungsordnung fällt. Dieses wird im Vergleich zum Motiv mit einem Scale-Layer gewichtet. Die Propagation ins Fernfeld entspricht einer Fourier-Transformation.

Ein Sinc^2 -Layer modelliert den Intensitätsabfall im Fernfeld ausgehend von der nullten Beugungsordnung, welcher durch die rechteckige Pixelstruktur des SLMs verursacht wird. Die Sättigung des Kamerasensors wird im Modell durch Clipping repräsentiert.

3 Kalibrierungsmethode

In der Camera-in-the-Loop-Kalibrierung wird zunächst ein klassisch berechnetes Phasenhologramm am Laboraufbau angezeigt. Das physikalisch interpretierbare neuronale Netz wird mit der Kameraaufnahme trainiert und die Gewichte durch Backpropagation aktualisiert. Mit diesem trainierten Modell wird ein neues Phasenhologramm berechnet. Durch eine iterative Wiederholung dieser beiden Schritte nähert sich das Modell immer näher den realen Bedingungen am optischen Aufbau an.

4 Ergebnisse

In Abbildung 2 sind die Ergebnisse einer CITL-Kalibrierung dargestellt. Links ist dabei die Fernfeldaufnahme eines klassisch berechneten Motivs dargestellt. In der mittleren bzw. rechten Spalte ist die Fernfeldaufnahme nach 25 bzw. 200 Iterationen der CITL-Kalibrierung dargestellt. Die Strukturen des Motivs werden im Laufe der Kalibrierung sehr viel schärfer und die Kanten sind deutlicher zu erkennen. Außerdem reduziert sich das Streulicht, somit fällt mehr Intensität ins gewünschte Motiv. Der Einfluss der Kalibrierung auf die nullte Beugungsordnung ist eher gering.



Abb. 2 Verlauf der Kalibrierung: Kameraaufnahmen nach dem SGD (links), nach 25 (Mitte) bzw. 200 (rechts) Iterationen der CITL-Kalibrierung.

Ein Vergleich zwischen Kamerabild und simuliertem Bild ist in Abbildung 3 dargestellt. Das in der Detailansicht gezeigte Specklemuster des Kamerabildes entspricht sehr genau dem vom physikalisch interpretierbaren neuronalen Netz berechneten Specklemuster, was auf eine sehr hohe Genauigkeit des angenommenen Modells schließen lässt.




Abb. 3 Vergleich der Specklestrukturen in Kamerabild und Simulation nach einer CITL-Kalibrierung.

Ein großer Vorteil der Verwendung eines physikalisch interpretierbaren neuronalen Netzes gegenüber klassischen Deep-Learning-Ansätzen besteht darin, dass sich die physikalischen Randbedingungen des Versuchsaufbaus aus den Gewichten ableiten lassen.

Um den Einfluss einer gezielten Defokussierung des Kamerasensors auf die Kalibrierung zu untersuchen, wurde der Kamerasensor gezielt aus der Fokusebene bewegt und der Defokus-Koeffizient der Zernike-Polynome ausgewertet. Dabei zeigt sich ein linearer Zusammenhang zwischen der Verschiebung des Kamerasensors und der kalibrierten Defokussierung.

5 Zusammenfassung und Ausblick

Ein Modell des SLMs und des optischen Aufbaus wurde in Form eines physikalisch interpretierbaren neuronalen Netzes implementiert und eine Camera-in-the-Loop-Kalibrierung durchgeführt.

Zukünftig sollen eine genauere Modellierung der nullten Beugungsordnung, orts aufgelöste SLM-Kennlinien sowie feldabhängige Aberrationen berücksichtigt werden. Zudem ist eine Erweiterung auf gekrümmte Flächen und die Kombination mit Specklereduzierungsmethoden möglich.

Literatur

[1] Y. Peng, S. Choi, N. Padmanaban, and G. Wetzstein, "Neural holography with camera-in-the-loop training," *ACM Trans. Graph.* **39**(6) (2020).