

Schnelle Überprüfung miniaturisierter optischer Transceiver mithilfe Neuronaler Netze

Yingbin Xu¹⁾, Rainer Tutsch²⁾, Kai Schmieder¹⁾, Tobias Schneider¹⁾, Rene Kirrbach¹⁾

1) Fraunhofer Institut für Photonische Mikrosysteme, Dresden, Deutschland

2) Institut für Produktionsmesstechnik, TU Braunschweig, Braunschweig, Deutschland

Kontakt: yingbin.xu@ipms.fraunhofer.de

Kurzfassung

Optische Transceiver können hinsichtlich ihrer Funktion detailliert untersucht und charakterisiert werden. Dafür werden i. d. R. spezielle Messaufbauten benötigt und die Messungen selbst sind zeitaufwändig. In diesem Beitrag wird eine schnelle Detektionsmethode auf Basis von Convolutional Neural Networks (CNNs) zur Bewertung der Übertragungsqualität optischer Transceiver vorgestellt. Erste Ergebnisse an verschiedenen Transceiver-Typen zeigen, dass diese Methode die Positionierung der Linse relativ zur Laserdiode mit mikrometeregenauer Präzision vorhersagen kann. Damit lässt sich die Prüfzeit pro Bauteil von etwa 15 Minuten für eine vollständige Bewertung auf konventionellem Wege auf rund 1 Minute senken. Gleichzeitig wird mit dieser neuen, KI-gestützten Prüfung eine bestehende Lücke im Repertoire schneller Testmethoden geschlossen.

1 Einführung

Die im Beitrag erwähnten Transceiver bestehen aus einem Sender für eine erste optische Datenübertragungsstrecke und einem Empfänger für einen zweiten optischen Link. Zum Senden der Daten werden beispielsweise Laserdioden und Fotodioden zum Empfang der optischen Signale eingesetzt. Die Strahlformung geschieht durch Linsen, die auf den jeweiligen Einsatzfall angepasst sind. Selbst geringe Positionierungsungenauigkeiten der optischen Komponenten können den Querschnitt des emittierten Strahls erheblich verändern und die Systemleistung beeinträchtigen und zu einem sprunghaften Anstieg der Datenübertragungsfehler führen. Herkömmliche optische Messverfahren mit Linearartischen liefern präzise Ergebnisse; ihre langen Messzyklen machen sie jedoch für die großflächige Online-Inspektion in Produktionslinien ungeeignet. Convolutional Neural Networks (CNNs) haben in den vergangenen Jahren verbreiteten Eingang in Bilderkennung und industrieller Inspektion gefunden.

Dieser Beitrag beschäftigt sich mit einer automatisierten Inspektionslösung für den industriellen Einsatz. Mithilfe von Strahlbildern wird die relative Lageabweichung der Linse zum Substrat in Echtzeit bestimmt. Das gefundene Verfahren arbeitet berührungslos. Im vorliegenden Beitrag wird ein industriell einsetzbarer End-to-End-Workflow beschrieben. Positionierabweichungen bei optischen Transceivern können auf Basis von Kamerabildern und CNNs regressiv vorhergesagt werden. Als Datenbasis dienen optische Simulationen sowie experimentell aufgezeichnete Strahlprofile. Auf Modellseite kommt ein Regressionsrahmenwerk zur Anwendung, das eine multi-skalige Merkmalsextraktion mit geometrischen Vorinformationen kombiniert.

2 Methodik

2.1 Datenbasis

Das Training neuronaler Netze erfordert eine große Anzahl von Strahlprofilbildern als Trainingsdaten. Für das Generieren dieser Daten wird die Simulations-Software: „ZEMAX OpticStudio“ eingesetzt. Das Koordinatensystem wird so gelegt, dass der Ursprung mit der Position der Laserdiode im Transceiver-Modell übereinstimmt.

Für die Simulation des optischen Systems wird das so genannte Raytracing [01] genutzt. **Bild 1** zeigt beispielhaft eine solche Simulation. Für eine angenommene Lageabweichung zwischen 0 und max. 100 μm in x, y und z wurden circa 30.000 Strahlprofilbilder erzeugt. Drei davon sind exemplarisch in **Bild 2** gezeigt.




Bild 1 Ansicht einer Raytracing-Simulation mit Austrittsfenster (links) und Detektorfläche (rechts)

Der simulierte Strahl durchläuft eine definierte Detektorebene. Diese entspricht der Kamera im Experiment.




Bild 2 Mit ZEMAX simulierte Strahlprofile (Beispiel)

2.2 Bildvorverarbeitung

2.2.1 Filtern

Die Intensität der Strahlprofile I ist bei den untersuchten optischen Transceivern im Zentrum am höchsten und nimmt typischerweise nach außen hin ab. Zur Rauschunterdrückung und Verbesserung der Konturen wurde der in Gleichung (1) angeführte Gauß-Filter eingesetzt:

$$I_{fil}(x) = \frac{1}{W(x)} \sum_{\zeta \in N(x)} G_{\sigma_s}(\|\zeta - x\|) G_{\sigma_r}(|I(\zeta) - I(x)|) I(\zeta) \quad (1)[02]$$

Dieser verwendet einerseits einen räumlichen Gauß'schen Filterkern $G_{\sigma_s}(\|\zeta - x\|)$, dessen Wirkung vom Abstand des Pixels zum Zielpixel x abhängt und andererseits einen weiteren Gauß'schen-Filterkern $G_{\sigma_r}(|I(\zeta) - I(x)|)$, der die Differenz der Pixel-Intensitäten gewichtet. $W(x)$ gibt die Normierung an. ζ steht für das Nachbarpixel.

Auf diese Weise bleiben die Kanten erhalten, während zufälliges Rauschen reduziert wird.

2.2.2 Bild-Binarisierung

Im nächsten Schritt muss eine Schwellwert-Segmentierung gemäß Gleichung (2) erfolgen. Ein mit einem geeigneten Schwellenwert T erzeugtes Binärbild kann den Strahlquerschnitt deutlich vom Hintergrund unterscheiden:

$$I_{binary}(x, y) = \begin{cases} 1, & I(x, y) \geq T \\ 0, & I(x, y) < T \end{cases} \quad (2)$$

Das resultierende Binärbild idealer Transceiver zeigt einen annähernd kreisförmigen Bereich. Im Gegensatz zu den simulierten Bildern weisen reale Profile häufig eine ungleichmäßige Intensitätsverteilung auf. Dies kann zu Konturbrüchen oder unscharfen Kanten führen. Um diese Problematik zu beheben, wird ein iteratives Schwellwert-Verfahren auf Basis der Bild-Binarisierung eingesetzt [06].

$$Q = \frac{A}{U} \quad (3)$$

$$C = \frac{1}{Q} \quad (4)$$

In den o. g. Gleichungen steht Q für Qualität, A für die Fläche, U für den Umfang und C für die Kosten. Gleichung (3) ist zu entnehmen, dass ein Profil mit einem hohem Qualitätswert ein größeres Flächen-Umfangs-Verhältnis aufweist und damit näher an einer Kreisform liegt. Je höher die Qualität des Strahlprofils, desto geringer erscheinen die Kosten. So der Schwellwert T in Gl. (2) wird so gewählt, dass die Kosten C minimal sind. **Bild 3** zeigt das Effekt-Diagramm und die Profilqualität bei gewählten Schwellwerten T von 15, 40 und 60.




Bild 3 Abhängigkeit der Qualität des Strahlprofils von der Wahl des Schwellwertes T - 15 (oben rechts), 40 (unten links) und 60 (unten rechts)

Die vorgenommene Implementierung verwendet einen iterativen Schwellwert-Algorithmus, um den Schwellwert-Bereich anzupassen. Dabei werden alle zur Auswahl stehenden Schwellwerte hinsichtlich der erzielbaren Profil-Qualität getestet [07].

2.2.3 Kanten-Erkennung

Bei der Kanten-Erkennung wird der so genannte Canny-Algorithmus [03] angewendet, um die Konturen weiter zu optimieren. Bei diesem Algorithmus handelt es sich um ein Standardverfahren der digitalen Bildverarbeitung von Graustufenbildern. Die Berechnung der Intensitätsänderung im Bild erfolgt mittels Sobel-Operatoren, die die Gradienten in x - und y -Richtung bestimmen. In den Gleichungen (5) und (6) steht G für den Gradienten, S für der Sobel-Operator und EB für das Eingangsbild.

$$G_x = S_x * EB = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * EB \quad (5)$$

$$G_y = S_y * EB = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * EB \quad (6)$$

Anschließend wird der Bereich mit den markantesten Änderungen ermittelt, der die Kante des Strahlprofils darstellt. Im verwendeten Programm-Code sind zwei Schwellwertparameter enthalten, um die Intensität der Strahlkante zu bestimmen zu können. Wenn der Betrag des Gradienten größer als der obere Schwellwert ist, wird dies als Kante betrachtet. Liegt sie niedriger als der untere Schwellwert, wird keine Kante erkannt [04].

2.2.4 Bild-Dilatation

Bei der Kanten-Erkennung kann es zu Unterbrechungen oder Fehlstellen (beispielsweise in Form von Löchern) im Profil kommen. Um diese zu schließen und um die Strahlkontur insgesamt homogener darzustellen zu können, wird Methode der Dilation eingesetzt.

Die Dilatation kann als die so genannte Minkowski-Summe des Strukturelements SE_B auf dem Zielgebiet $_A$ betrachtet werden, d. h. als Vereinigung aller Translationen von SE_B mit SE_A ($SE_A \oplus SE_B$). Dadurch wird die Grenze von SE_A nach außen hin verschoben. Auch kleinere Fehlstellen (Löcher) können so gefüllt werden.

Bild 4 zeigt das ursprüngliche Binarisierungs-Ergebnis eines simulierten Strahlprofils. Im Strahlprofil auf der linken Seite sind noch Lücken erkennbar. Für die mittlere Abbildung wurde ein kreuzförmiges 9×9 -Strukturelement zur Ausdehnung verwendet, wobei bevorzugt die horizontale und vertikale Richtung erweitert werden. Die kleinen Lücken werden dadurch im Wesentlichen gefüllt. Die diagonalen Linien des Profils weisen jedoch noch Kanten auf. Die rechte Abbildung verwendet ein kreisförmiges Strukturelement gleicher Größe zur Ausdehnung. Die isotrope Ausdehnung glättet die Kanten und schließt gleichzeitig die verbleibenden Lücken vollständig, wodurch der Füllereffekt deutlicher wird.




Bild 4 Verdeutlichung des genutzten Dilatationsprinzips: Lücken nach Binarisierung (links), Anwendung eines kreuzförmigen Strukturelementes (Mitte) und eines kreisförmigen Strukturelementes (rechts)




Bild 5 Verdeutlichung der Bildverarbeitungsschritte: gefiltertes Bild (links oben), binäres Bild (rechts oben), Bild mit Kantenerkennung (rechts unten) und dilatiertes Bild (links unten)

In der Bildverarbeitung muss oftmals eine Erosion nach der Dilatation durchgeführt werden, um eine Vergrößerung des Zielbereichs zu verhindern. Dieser Weg wurde hier nicht besprochen, da der Schwerpunkt in diesem Beitrag

auf dem Erkennen des Strahlprofils und der Merkmals-Extraktion liegt. Für die Strahlprofilerkennung ist es besser, das dilatierte Bild direkt zu verwenden. [05]

In der gefilterten Darstellung von **Bild 5** ist zu erkennen, dass die Helligkeit der Kontur im Originalbild von unten nach oben allmählich abnimmt. Dadurch verringert sich der Pixelgradient, und am oberen Rand werden die Grenzen unscharf, sodass keine klare Kantenlinie mehr erkennbar ist. Diesem Effekt wird bei der Kanten-Erkennung Rechnung getragen, und im Dilatationsprozess wird der Kontrastverlauf gezielt verstärkt, indem helle Pixelbereiche weiter ausgedehnt und dunkle Randzonen betont werden, um den Übergang zwischen intensiven und abgeschwächten Strahlungsbereichen präziser herauszuarbeiten.

2.3 Merkmalsextraktion

Nach erfolgter Bild-Vorverarbeitung werden im nächsten Schritt Strahlprofil-Merkmale für das Training von Regressions- und neuronalen Netzwerkmodellen ermittelt. Aus dem Strahl-Profil extrahiert man dazu die Merkmale, die zur Charakterisierung von Form, Position und Intensitätsverteilung genutzt werden können. **Bild 6** zeigt die Merkmals-Gewinnung.

2.3.1 Hough-Kreis-Erkennung

Da die eingesetzten Transceiver einen kreisförmigen bzw. elliptischen Strahlquerschnitt aufweisen, kann die so genannte Hough-Transformation eingesetzt werden. Diese basiert auf der Kreisgleichung: [08].

$$(x - a)^2 + (y - b)^2 = r^2 \quad (7)$$

Dabei sind a, b die Koordinaten des Kreismittel-Punkts und r der Radius. In der Praxis werden die Randpunkte des Strahls zunächst mit dem Canny-Algorithmus identifiziert. Für jeden Randpunkt werden mögliche Mittelpunkte berechnet, die im Parameter-Raum Kreisbögen bilden. Der Schnittpunkt der überlagerten Bögen entspricht dem tatsächlichen Mittelpunkt.




Bild 6 Merkmalsextraktion anhand der Kontur (oben rechts) sowie durch Hough-Kreise (unten rechts)

Um Fehlinterpretationen bei der Vorhersage zu minimieren, werden die drei wahrscheinlichsten Kreise ausgegeben, sodass die realen Profile möglichst genau approximiert werden können [09]

2.3.2 Kontur-Mittelpunkt und Flächen-Berechnung

Nach der Bestimmung des Strahlprofils müssen der Konturmittelpunkt und die Fläche erfasst werden. Der Konturmittelpunkt drückt im gegebenen Anwendungsfall die relative Position der Linse zur Laserdiode aus. Die Fläche repräsentiert den Strahlquerschnitt. Die Quantifizierung dieser Merkmale erfolgt anhand des Konturmittelpunkts und der Profilfläche. Die dazugehörige Berechnungsformel lautet wie folgt [10]:

$$M_{pq} = \sum x^p y^q I(x, y) \quad (8)$$

$$x_c = \frac{M_{10}}{M_{00}}, y_c = \frac{M_{01}}{M_{00}} \quad (9)$$

In dieser Gleichung steht M_{pq} für Bildmoment, p ist die Ordnung des Moments in x -Richtung, q die Ordnung in y -Richtung und die Indizes: c für Konturmittelpunkt. Da die kreisförmige Kontur aus einem gefilterten Binärbild entsteht, kann ihr Helligkeitswert I nur die Werte 0 oder 1 annehmen. Daher entspricht der Mittelpunkt der Kontur ihrem Schwerpunkt. In diesem Fall entspricht M_{00} der Summe der Intensitäten und (x_c, y_c) dem geometrischen Schwerpunkt der Kontur, der die relative Lage der Linse zur Laserdiode direkt beschreibt.

3 Innovative Convolutional-Neural-Network

Ungleichmäßige Intensitätsverteilung sowie die teilweise geringen Kanten-Details im Strahlprofilbild erfordern die Verwendung mehrerer Faltungskernel-Größen damit beide Kriterien im Strahlprofilbild simultan verarbeitet werden können. Aus diesem Grund wird die Verwendung eines innovativen CNN-Modells mit 3-Zweigen vorgeschlagen. Für Zweig 1 kommt ein (3×3-Kernel) zum Herausfinden lokaler Intensitätsmaxima zur Anwendung. Mit diesem erfolgt die Vorhersage der x -Koordinate.

Für Zweig 2 ist ein (5×5-Kernel) vorgesehen. Dieser dient der Erfassung der Strahlprofil-Form sowie der Vorhersage der y -Koordinate.

Schließlich wird ein (7×7-Kernel) für die Verzweigung 3 eingesetzt. Dieser ist darauf ausgerichtet, die globale Intensitäts-Verteilung zu analysieren und die zusätzlichen Informationen für x und y zusammenzuführen.

3.1.1 Korrelations-Verbesserung

Zur Verbesserung der Korrelation wird nach der Vorverarbeitung zunächst eine 1×1-Faltung auf das Eingabebild angewendet, deren Ergebnis mittels Sigmoid-Funktion in den Bereich [0,1] transformiert wird und als Gewicht dient. Die gewichteten Merkmale entstehen durch elementweise Multiplikation.

3.1.2 Ausgabeschichten

Bei beiden Zweigen 1 und 2 handelt es sich um vollverbundene Schichten, die die x - bzw. y -Koordinate ausgeben. Schließlich wird F_3 mit den Merkmalen aus den Zweigen 1 und 2 fusioniert. Dabei konzentriert sich Zweig 1 auf lokale Details (x), Zweig 2 auf die Konturform (y), während Zweig 3 globale Zusatzinformationen liefert.

3.1.3 Verlustfunktion

Um die Unabhängigkeit der Zweige sicherzustellen, werden separate Verlustfunktionen definiert. Zusätzlich wird ein intensitätsgewichteter Gradienten-Verlust verwendet, um die genaue Lokalisierung der x - und y -Grenzen zu unterstützen. Dieser berechnet die Abweichung zwischen dem vorhergesagten Gradienten und dem wahren Gradienten. Damit kann dem Modell mitgeteilt werden, wo Anpassungen vorgenommen werden müssen. Die Umsetzung erfolgte in Anlehnung an die in [03] vorgestellte Methode. Der normalisierte Pixelintensitätswert verstärkt den Einfluss der helleren Bereiche im Strahlprofil. Um eine Überverstärkung zu vermeiden, wird der Maximalwert mit der min-Funktion auf einen Wert zwischen 1 und 2 begrenzt.

3.1.4 CNN kombiniert mit Hough-Transformation

Zur weiteren Verbesserung der Robustheit werden die Ergebnisse der Hough-Kreis-Erkennung aus der Merkmalsextraktion als zusätzliche Eingabe integriert. Der erkannte Konturmittelpunkt (x_c, y_c) wird vor der verbundenen Schicht mit den CNN-Merkmalen verknüpft. Dadurch wird das Modell in die Lage versetzt, geometrische Vorab-Informationen mit den gelernten Bildmerkmalen zu kombinieren und die Vorhersagegenauigkeit für die x - und y -Koordinaten zu steigern.

3.2 Modellarchitektur

Das CNN-Modell gemäß **Bild 7** enthält drei parallele Faltungszweige, eine Korrelationsverbesserung und eine Hough-Merkmalfusion. Die Eingabeebene umfasst den PNG-Bildeingang und einen Hough-Merkmalereingang. Das PNG-Bild wird mithilfe einer dreistufigen Architektur verarbeitet.

Aufgabe der ersten Faltungsschicht ist das Extrahieren lokaler Merkmale mithilfe verschiedener Faltungskerne. Die Batch-Normalisierungsschicht soll die Merkmalsverteilung vereinheitlichen und den Trainingsprozess beschleunigen. Mit Hilfe der Max-Pooling-Schicht wird u. a. die Translationsinvarianz verbessert.

Die zweite Faltungsschicht dient der Erfassung lokaler Formen und Konturen. Anliegen der Korrelations-Verbesserung ist die Verstärkung wesentlicher Bild-Merkmale und die Unterdrückung nebensächlicher Informationen. Die nachfolgende Schicht führt ein 2×2-Pooling zur weiteren Komprimierung durch und reduziert das Bild anschließend zu einem eindimensionalen Vektor $F1$ bis $F3$.




Bild 7 Gewählte Struktur des 3-zweigigen CNNs

Die reduzierten Merkmale $F1$, $F2$ und $F3$ der drei Zweige werden über die Verkettungs-Ebene mit dem Hough-Eingang fusioniert, um einen umfassenden Merkmalsvektor zu erhalten. In diesen werden mehrskalige Bildmerkmale und geometrische Vorhersagen integriert. Die fusionierten Merkmale werden schließlich von zwei parallelen Ausgabeköpfen verarbeitet, um die x bzw. y -Koordinaten vorherzusagen.

4 Test und Validierung

4.1 Ergebnisse der Vorhersage

Bild 8 veranschaulicht den Zusammenhang zwischen dem vom Modell vorhergesagten und dem Zielwert für Δx . Die gestrichelte Linie repräsentiert den idealen Vorhersagewert. Die Verteilung der Datenpunkte um diese Linie zeigt die gute Anpassung des Modells an den Zielwert. Eine nahezu identische Aussage trifft auch auf die prognostizierten Werte für Δy zu.

Eine beispielhafte Darstellung für konkrete Versatzwerte eines Transceiver-Samples ist in **Bild 9** gezeigt. Aus der GUI lässt sich im ausgewählten Fall auf eine Lageabweichung Abweichung von $6 \mu\text{m}$ in x und $8 \mu\text{m}$ in y -Richtung schließen.

Die durchgeführten Experimente zeigen, dass das entwickelte CNN-Modell die Vorhersage der ΔX - und ΔY -Koordinaten mit hoher Genauigkeit und Robustheit leisten kann. Die kompakte Verteilung der Datenpunkte entlang der idealen Linie bestätigt die effektive Anpassung des Modells an die simulierten Montage-Abweichungen.

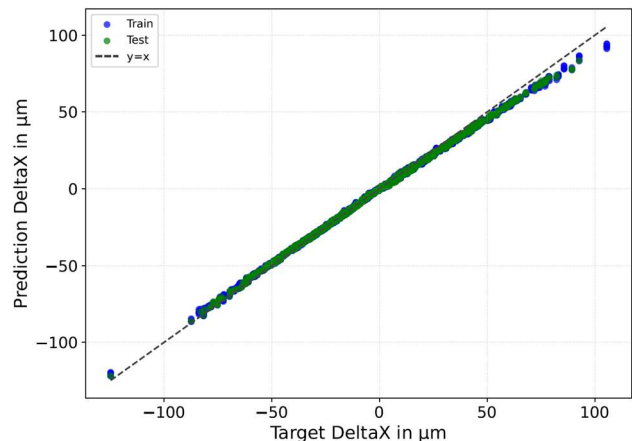


Bild 8 Sollantwort für die Δx -Komponente (CNN mit 3 Verzweigungen)

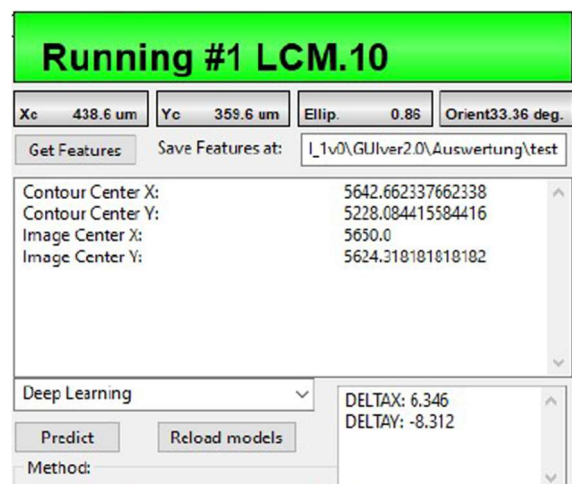


Bild 9 Beispiel für die ermittelten Versatzwerte eines Transceivers

4.2 Diskussion

Die Ergebnisse zeigen, dass die Kombination aus mehrskaliger Faltung, Korrelations-Verbesserung und Hough-Merkmal-Fusion die Vorhersageleistung des Modells signifikant steigert und im Vergleich zu traditionellen Methoden die Robustheit und die Anpassungsfähigkeit des Testverfahrens an unterschiedliche Strahlprofil-Formen erhöht. Die Einbeziehung geometrischer Vorinformationen spielt eine entscheidende Rolle bei der Lokalisierung der Koordinaten.

Nichtsdestotrotz weist auch das hier vorgestellte Modell Einschränkungen auf. Beispielsweise hängt seine Leistungsfähigkeit stark von der Qualität der simulierten Daten ab.

5 Fazit und Ausblick

Dieser Beitrag schlägt eine innovative CNN-Architektur vor, die durch die Fusion von Bild-Merkmalen mit geometrischen Informationen nach Hough eine hochpräzise Vorhersage von Punktkoordinaten ermöglicht. Zukünftige Arbeiten konzentrieren sich auf die folgenden zwei Bereiche:

- Die Entwicklung einer automatisierten Pipeline zur signifikanten Vergrößerung des Trainingsdatensatzes ermöglicht die Generierung zahlreicher, leicht variiert Trainingsbeispiele aus wenigen realen Bildern.
- Methoden zur Übertragung simulativ trainierter Modelle auf reale Daten und zur Anpassung an deren spezifische Eigenschaften werden untersucht (z. B. Transferlernen und Domänenanpassung). Dadurch wird der Übergang von der Simulation zur Realität beschleunigt und die schnelle Modellierung unterschiedlicher Transceiver-Typen unterstützt.

6 Literatur

- [01] J. R. Mahan, *The Monte Carlo Ray-Trace Method in Radiation Heat Transfer and Applied Optics*, ASME/Wiley, 2019, pp. 1–28.
- [02] Carlo Tomasi und Roberto Manduchi. “Bilateral filtering for gray and color images” . In: Sixth international conference on computer vision (IEE Cat.No.98CH36271). IEEE. 1998,S. 839 – 846 S.2
- [03] John Canny. “A computational approach to edge detection” . In: IEEE Transactions on pattern analysis and machine intelligence 6 (1986), S. 679 – 698 S.6-8
- [04] I. Sobel and G. Feldman, “A 3×3 isotropic gradient operator for image processing,” Stanford Artificial Intelligence Project, 1968
- [05] R. C. Gonzalez und R. E. Woods. *Digital Image Processing*. 3. Aufl. Upper Saddle River, NJ: Prentice Hall, 2008 S.343-360
- [06] Sonka, M., Hlavac, V., & Boyle, R. (2014). *Image Processing, Analysis, and Machine Vision* (4th ed.). Cengage Learning S.248
- [07] Jähne, B. (2005). *Digital Image Processing* (6th ed.). Springer S.427
- [08] Hough, P. V. C. (1962). “Method and means for recognizing complex patterns.” S.1
- [09] L. Bachmann, Entwicklung eines Software Tools zur computergestützten Auswertung von Transceiver Profilen auf Basis Neuronaler Netze für die Prozessqualifizierung, Diplomarbeit, Institut für Halbleiter- und Mikrosystemtechnik, Technische Universität Dresden, Apr. 26, 2021. S.46
- [10] R. C. Gonzalez und R. E. Woods. *Digital Image Processing*. 3. Aufl. Upper Saddle River, NJ: Prentice Hall, 2008 S.688