

Vergleich neuronaler Netzarchitekturen zur Vorhersage elektrisch deformierter Polymertropfen

Lucas Fischer, Annika Dehm, Mike Dohmen, Andreas Heinrich

Aalen School of Applied Photonics, Hochschule Aalen

mailto: lucas.fischer@studmail.htw-aalen.de

Diese Arbeit untersucht die Vorhersage elektrisch deformierter UV-Polymertropfen mittels Deep Learning. Ein 1D U-Net und ein 1D Transformer rekonstruieren Tropfenkonturen auf Basis experimenteller Prozessparameter. Die Ergebnisse verdeutlichen unterschiedliche Modellierungseigenschaften beider Architekturen und deren Eignung für elektrohydrodynamische Deformationsprozesse.

1 Einleitung

Die additive Fertigung mikrooptischer Bauteile nutzt zunehmend die kontrollierte Formgebung flüssiger UV-Polymertropfen mittels elektrischer Felder. Die resultierende Tropfengeometrie hängt dabei von Spannung, Elektrodenkonfiguration und Materialeigenschaften ab, wodurch klassische Modellierungsansätze an ihre Grenzen stoßen [1].

Datengetriebene Methoden, insbesondere Deep Learning, bieten hierfür eine alternative Modellierungsstrategie, da komplexe nichtlineare Zusammenhänge direkt aus experimentellen Daten approximiert werden können [2].

In dieser Arbeit wird die Vorhersage elektrisch deformierter Polymertropfen als Regressionsproblem formuliert. Dazu werden ein 1D U-Net und ein 1D Transformer untersucht, um faltungs- und aufmerksamkeitbasierte Rekonstruktionsansätze zu untersuchen.

2 Datengrundlage und Problemformulierung

Die Datengrundlage basiert auf einem experimentellen Aufbau zur elektrischen Deformation von UV-Polymertropfen. Der Tropfen wird auf einer Elektrodenstruktur positioniert und durch Variation von Spannung und Anodenposition deformiert (Abb. 1). Die resultierende Formänderung entsteht infolge elektrohydrodynamischer Kräfte [3].




Abb. 1 Aufnahme eines UV-Polymertropfens mit extrahierter Tropfenkontur (grün) sowie definierten Kontaktpunkten (rot) zur parametrisierten Konturerfassung.

Die Tropfenkontur wird aus Schattenbilddaufnahmen extrahiert und über eine feste Anzahl diskreter Stützstellen parametrisiert (Abb. 1). Die Kontaktpunkte definieren dabei die räumliche Begrenzung der Tropfenkontur. Für jeden Versuch liegen die Ausgangskontur, die deformierte Zielkontur sowie die zugehörigen Prozessparameter vor. Daraus ergibt sich eine sequenzielle Regressionsaufgabe zur Beschreibung der geometrischen Konturänderung. Modelliert wird die Differenz

$$\Delta y = y_{\text{after}} - y_{\text{before}} \quad (1)$$

zwischen Ausgangs- und Zielkontur. Die neuronalen Netzwerke lernen somit direkt die Konturänderung in Abhängigkeit der experimentellen Randbedingungen.

3 Vergleichene Modellarchitekturen

Zur Modellierung der Tropfenkonturen werden ein 1D U-Net sowie ein 1D Transformer in anwendungsspezifischer Architektur untersucht. Beide Modelle verarbeiten identische Eingangssequenzen und sagen die Konturänderung Δy an jeder Stützstelle voraus, basieren jedoch auf unterschiedlichen Modellierungsprinzipien.

Residual U-Net++: Das faltungsbasierte Encoder-Decoder-Netzwerk nutzt mehrskalige Faltungsblöcke sowie Skip-Connections zur hierarchischen Rekonstruktion lokaler Konturstrukturen [4, 5]. Residuale Verbindungen unterstützen dabei die stabile Gradientenpropagation während des Trainings [6].

Transformer: Der 1D Transformer verarbeitet positionskodierte Sequenzen mittels Self-Attention-Blöcken [7], um globale Abhängigkeiten entlang der gesamten Tropfenkontur zu modellieren. Hierdurch kann die Rekonstruktion eines Kontaktpunktes Informationen aus der gesamten Tropfenkontur berücksichtigen.

Die Gegenüberstellung beider Ansätze ermöglicht die Analyse faltungs- und aufmerksamkeitsbasierter Modellierungsstrategien im Kontext elektrohydrodynamischer Deformationsprozesse.

4 Trainings- und Evaluationsstrategie

Zur Gewährleistung eines konsistenten Modellvergleichs wurde eine einheitliche Trainings- und Evaluationsstrategie verwendet.




Abb. 2 Übersicht der Trainings- und Evaluationsstrategie.

Als primäre Fehlermetrik dient der Root Mean Square Error (RMSE) zwischen vorhergesagter und experimenteller Konturänderung. Ergänzend erfolgt eine positionsabhängige Analyse der Fehlerverteilungen entlang der Tropfenkontur.

5 Ergebnisse und Diskussion

Beide Modelle approximieren die deformierten Tropfenkonturen mit sehr hoher Genauigkeit, was durch niedrige RMSE-Werte bestätigt wird. Der 1D Transformer erreicht mit $2.16 \mu m$ einen leicht geringeren Gesamtfehler als das Residual U-Net++ mit $2.24 \mu m$.

Die Fehlerverteilungen entlang der Tropfenkontur offenbaren Unterschiede in den Modellierungseigenschaften beider Architekturen (Abb. 3). Während das Residual U-Net++ insbesondere benachbarte Kontursegmente robust erfasst, ermöglicht der Transformer eine stärkere Berücksichtigung konturübergreifender Zusammenhänge. Die beobachteten Unterschiede stehen im Zusammenhang mit den physikalischen Eigenschaften elektrohydrodynamischer Tropfendeformationen, welche sowohl lokale Krümmungs- und Oberflächeneffekte als auch globale Feldkopplungen aufweisen.

In den aggregierten Fehlerverteilungen zeigt das U-Net++ homogenere Fehlerstrukturen, während der Transformer insgesamt schmalere Fehlerverteilungen aufweist.




Abb. 3 Aggregierte positionsabhängige Fehlerverteilungen der rekonstruierten Tropfenkonturen für das Residual U-Net++ und den 1D Transformer auf dem Testdatensatz.

6 Zusammenfassung und Ausblick

Beide Netzwerkarchitekturen ermöglichen eine präzise datengetriebene Modellierung elektrisch deformierter Polymertropfen. Während faltungs-basierte Ansätze robuste lokale Rekonstruktionen liefern, bieten Transformer-Modelle Potenzial zur verbesserten Erfassung globaler geometrischer Zusammenhänge. Zukünftige Arbeiten können hybride sowie physikalisch informierte Ansätze untersuchen, um lokale Präzision und globale Konsistenz zu kombinieren.

References

- [1] P. Schreiber et al., "Freeform microlens arrays by electric-field-driven deformation of UV-curable polymers," *Applied Optics*, vol. 54, no. 23, pp. 7366–7372, 2015. doi: 10.1364/AO.54.007366
- [2] I. Goodfellow et al., "Deep Learning," MIT Press, 2016.
- [3] G. Taylor, "Disintegration of Water Drops in an Electric Field," *Proceedings of the Royal Society A*, vol. 280, no. 1382, pp. 383–397, 1964.
- [4] O. Ronneberger et al., "U-Net: Convolutional Networks for Biomedical Image Segmentation," *MICCAI*, 2015.
- [5] Z. Zhou et al., "UNet++: A Nested U-Net Architecture for Medical Image Segmentation," *Deep Learning in Medical Image Analysis*, 2018.
- [6] K. He et al., "Deep Residual Learning for Image Recognition," *CVPR*, 2016.
- [7] A. Vaswani et al., "Attention Is All You Need," *Advances in Neural Information Processing Systems (NeurIPS)*, 2017.