

## ABSTRACT

---

Fluorescent microscopy is an established tool in life sciences, enabling the visualization of biological structures and processes. This imaging technique works by illuminating the specimen and thus exciting fluorophores located within the specimen with light of specific wavelengths, causing them to emit light that can be detected and used to generate detailed images. However, it requires balancing key imaging parameters, including speed, spatial resolution, light exposure, and imaging depth. Major challenges in fluorescence microscopy are photobleaching and phototoxicity, which necessitate minimizing photon exposure by reducing the duration or intensity of light. This, in turn, degrades image quality, highlighting the importance of computational methods for improving image reconstruction.

This thesis investigates the use of pre-trained Gaussian denoising networks for fluorescence microscopy image reconstruction. Originally trained on large natural image datasets, these networks are fine-tuned on fluorescence microscopy images to evaluate their suitability for this specialized task. Given the limited size of microscopy datasets, this process can be framed as few-shot learning. The work highlights appropriate denoising networks based on diverse architectures and selects suitable fluorescence microscopy datasets for training and evaluation.

The findings demonstrate that pre-trained Gaussian denoisers can effectively reconstruct fluorescence microscopy images, achieving performance comparable to or exceeding state-of-the-art methods. Additionally, this thesis identifies key hyperparameters that significantly influence the fine-tuning process, providing insights to maximize network performance. The approach is straightforward to implement and can be readily adapted for new denoiser networks as they emerge, leveraging the ongoing advancements in this active field of research. Furthermore, by utilizing pre-trained networks, the technique reduces the computational costs and time associated with training, since the pre-training is already performed in different previous studies. These contributions aim to advance the field of computational imaging and provide a basis for future developments that could contribute to practical improvements in fluorescence microscopy techniques.

*Keywords:* Fluorescence Microscopy; Image Reconstruction; Deep Learning; Fine-Tuning; Convolutional Neural Networks.

## ZUSAMMENFASSUNG

---

Fluoreszenzmikroskopie ist ein etabliertes Werkzeug in den Lebenswissenschaften und ermöglicht die Visualisierung biologischer Strukturen und Prozesse. Diese Bildgebungstechnik basiert auf der Anregung von Fluorophoren im Präparat durch Licht bestimmter Wellenlängen. Die Fluorophore emittieren dabei Licht, das detektiert und zur Erstellung detaillierter Bilder genutzt werden kann. Dabei müssen jedoch wichtige Parameter wie Geschwindigkeit, räumliche Auflösung, Lichtintensität und Eindringtiefe sorgfältig ausbalanciert werden. Zu den zentralen Herausforderungen der Fluoreszenzmikroskopie gehören Photobleichen und Phototoxizität, die eine Minimierung der Photonendosis durch Verringerung der Belichtungsdauer oder Lichtintensität erforderlich machen. Dies beeinträchtigt die Bildqualität und verdeutlicht die Bedeutung rechnergestützter Methoden zur Verbesserung der Bildrekonstruktion.

In dieser Masterarbeit wird der Einsatz vortrainierter Gaußscher Denoising-Netzwerke für die Rekonstruktion von Fluoreszenzmikroskopie-Bildern untersucht. Ursprünglich auf großen Datensätzen natürlicher Bilder trainiert, wird durch Fine-Tuning auf Fluoreszenzmikroskopie-Bildern ihre Eignung für diese spezialisierte Aufgabe untersucht. Aufgrund der begrenzten Größe der benutzten Mikroskopiedatensätze kann dieser Ansatz als Few-Shot-Learning betrachtet werden. Geeignete Denoising-Netzwerke mit unterschiedlichen Architekturen werden vorgestellt, und passende Datensätze aus der Fluoreszenzmikroskopie werden für Training und Evaluierung ausgewählt.

Es wird gezeigt, dass vortrainierte Gaußsche Denoising-Netzwerke Fluoreszenzmikroskopie-Bilder effektiv rekonstruieren können und dabei eine Leistung erzielen, die mit dem aktuellen Stand der Technik vergleichbar ist oder diesen übertrifft. Zudem werden wichtige Hyperparameter identifiziert, die den Feinabstimmungsprozess wesentlich beeinflussen, und es werden wertvolle Erkenntnisse zur Optimierung der Netzwerkleistung gewonnen. Der Ansatz lässt sich einfach umsetzen und an neue Denoising-Netzwerke anpassen, die aus den kontinuierlichen Fortschritten in diesem aktiven Forschungsfeld hervorgehen. Durch den Einsatz vortrainierter Netzwerke werden außerdem die mit dem Training verbundenen Rechenkosten und Zeitaufwände reduziert, da das Vortraining bereits in anderen Studien durchgeführt wurde.