

ABSTRACT

Magnetic Particle Imaging (MPI) is an emerging medical imaging modality which aims to reconstruct a particle concentration from measured voltage. In order to acquire scan data, the nonlinear response of superparamagnetic iron oxide nanoparticles (SPIO) to external magnetic fields is exploited. The modality is tracer based and inherits advantageous properties like high sensitivity, temporal and spatial resolution while working without radioactive materials or X-Rays. For that reason, many applications in the medical field could benefit from MPI.

In this work, the measurement-based approach using a lengthy calibration process in order to acquire the system response at each voxel position is applied. Consequently, the relation between concentration distribution and measured voltage can be described as a system of linear equations. Since the problem is ill-posed, regularization techniques are used to reconstruct the concentration distribution. The goal of this thesis is to implement and compare one standard and two different Machine Learning-based regularization techniques to approach the inverse problem and reconstruct MPI data from a preclinical scanner.

In order to reconstruct the data, three regularization techniques are applied: Besides L^2 -Tikhonov Regularization, Machine Learning-based methods Deep Image Prior (DIP) and Plug and Play Prior (PnP) are implemented in Python. To denoise reconstructed volumes within the PnP framework, a pretrained denoiser Convolutional Neural Network (CNN) is used. Preprocessing of the data is described and implemented in Matlab. The results of reconstructed concentration distributions by the implemented different regularization techniques are evaluated by the standard image quality measures SSIM and PSNR.

The results differ by the scanned phantom and preprocessing applied to the data. Regarding SSIM, L^2 -Tikhonov Regularization reconstructs in most cases the best results using preprocessed data of a phantom consisting of thin tubes. It is shown that Learning-based techniques lead to a better image quality of a phantom with a large area: Edges are preserved while the noise level is low. This applies to both the visual impression and image quality measures. The tuning of hyperparameters is non-trivial and crucial for the image quality. Both Learning-based methods require early stopping of the training process. The best visual result of a phantom with a large amount of low frequent parts is achieved in the first iteration of the PnP.

Keywords: Magnetic Particle Imaging, Machine Learning, Medical Imaging, Algorithms, Regularization, Data Science

ZUSAMMENFASSUNG

Magnetic Particle Imaging (MPI) ist eine neuartige medizinische Bildgebungsmodalität, bei der die Konzentration paramagnetischer Partikel anhand gemessener Spannung rekonstruiert wird. Dabei wird die nichtlineare Antwort superparamagnetischer Eisenoxid Nanopartikel (SPIO) auf externe Magnetfelder für die Signalerhebung von MPI ausgenutzt. Die Modalität ist tracerbasiert und bietet vorteilhafte Eigenschaften wie hohe Sensitivität und hohe zeitliche sowie örtliche Auflösung. Dabei verzichtet MPI auf radioaktive oder Röntgenstrahlung. Daher könnten viele Anwendungen in der Medizin von MPI profitieren.

Der messbasierte Ansatz für MPI wird in dieser Arbeit verfolgt. Dabei wird während eines zeitintensiven Kalibrationsprozesses die Systemantwort eines Scanners bei jeder Voxelposition erfasst. Folgend wird der Zusammenhang zwischen Konzentrationsverteilung und gemessener Spannung als lineares Gleichungssystem beschrieben. Dieses Problem ist schlecht gestellt, weswegen Regularisierungstechniken zur Rekonstruktion eingesetzt werden. Ziel dieser Thesis sind Implementierung und der Vergleich verschiedener Machine Learning-basierten Regularisierungstechniken und einem Standardregularisierungsverfahren um das inverse Problem anzugehen und MPI Daten eines präklinischen Scanners zu rekonstruieren.

Neben einer L^2 -Tikhonov Regularisierung werden Machine Learning-basierte Methoden Deep Image Prior (DIP) und Plug and Play Prior (PnP) implementiert. Um die rekonstruierten Volumina mit PnP zu entauschen, wurde ein vortrainiertes entauschendes künstliches neuronales Faltnetz (CNN) verwendet. Die Datenvorverarbeitung wird beschrieben und in Matlab implementiert. Die Bildqualität der Resultate wird anhand Standardbildqualitätsmaße SSIM und PSNR quantifiziert.

Die Ergebnisse unterscheiden sich anhand der gescannten Phantome und Datenvorverarbeitung. Gemessen an SSIM führt die L^2 -Tikhonov Regularisierung von Daten eines Phantoms bestehend aus dünnen Stäben meistens zu den besten Ergebnissen. Es wird gezeigt, dass die implementierten lernbasierten Techniken zu besserer Bildqualität eines Phantoms mit großen Flächen führt. Dabei werden Kanten bei niedrigem Rauschlevel erhalten, was sowohl der visuelle Eindruck, als auch Bildqualitätsmaße zeigen. Hyperparameter-tuning ist nicht trivial und entscheidend für die resultierende Bildqualität. Frühzeitiges Abbrechen ist bei beiden lernbasierten, iterativen Techniken notwendig. Das beste visuelle Ergebnis des flächigen Phantoms wurde in der ersten Iteration von PnP erreicht.

Keywords: Magnetic Particle Imaging, Maschinelles Lernen, Medizinische Bildgebung, Algorithmen, Regularisierung, Data Science