

# Abstract

Many eye diseases cause damage to the visual field leading to an irreversible loss of peripheral and central vision. These changes in the visual field can be found and quantified with the method of visual field testing. However, visual field testing is considered to be error-prone and tedious since the result of the examination is largely depending on the patient's behavior during testing. Another and less error-prone examination for the diagnosis of diseases in ophthalmology is the fundus photography.

This work examines if visual field damages can be predicted on fundus photography with machine learning methods. Furthermore the experiments in this work will include results from optical coherence tomography examinations. For this purpose three machine learning models were trained in order to predict, quantify and locate visual field damages.

The data basis in this work was provided by the Clinic of Ophthalmology from the University Hospital of Münster (UKM) and contains datasets of fundus photography, perimetry and optical coherence tomography.

In order to predict and quantify the visual field damage on fundus photography a CNN model was trained and evaluated on a dataset containing 6126 pairs of fundus photography and perimetry of 2265 subjects. Another dataset containing 1372 pairs of perimetry and optical coherence tomography was used to train and evaluate a regression model to predict and locate visual field sensitivity.

The experiments in this work could not prove a clinical relevance of detecting and quantifying visual field damages just on the basis of fundus photography. The evaluation of the CNN to quantify visual field damages reached an overall accuracy of 56 percent on the test dataset. Through the combination of examination data of the optical coherence tomography the overall model accuracy in quantifying visual field damages could be improved to 86 percent. In predicting and locating visual field damages on examination data of the optical coherence tomography the regression model reached on average a  $R^2$  of 0.56 with a  $MAE$  of 4.41 dB.

**Key words** – Machine Learning; Convolutional Neural Network; Gradient Boosting; Ophthalmology; Peripheral Vision; Feature Engineering.

# Zusammenfassung

Viele Augenerkrankungen führen zu Gesichtsfeldveränderungen, die meistens mit einem irreversiblen Verlust des peripheren und zentralen Sehvermögens einhergehen. Dabei werden einzelne Ausschnitte des Blickfeldes schwächer oder gar nicht mehr wahrgenommen. Mit der Gesichtsfeldmessung werden solche Veränderungen im Gesichtsfeld festgestellt und quantifiziert. Die Gesichtsfeldmessung ist allerdings sowohl zeitaufwändig als auch fehleranfällig, da sie von der Mitarbeit des Patienten abhängt. Eine weitere weniger aufwendige und häufig verwendete Diagnosemethode für Erkrankungen ist die Fundusfotografie.

In dieser Arbeit wird untersucht, inwieweit Gesichtsfelddefekte anhand von Fundusfotos und Ergebnissen aus optischen Kohärenztomographien durch Machine Learning Methoden vorhergesagt werden können. Hierfür wurden drei Machine Learning Modelle trainiert, mit denen die Erkennung, Quantifizierung und Verortung von Gesichtsfelddefekten untersucht wurde.

Als Datengrundlage dienten Fundusfotos, Untersuchungsergebnisse aus der Perimetrie sowie der optischen Kohärenztomographie, die durch die Klinik für Augenheilkunde am Universitätsklinikum Münster (UKM) bereitgestellt wurden. Aus diesen Datenquellen wurde für das Training eines CNN, zur Erkennung und Quantifizierung der Gesichtsfelddefekte, ein Datensatz mit 6126 Paare von Fundusfotografien und Gesichtsfeldmessung von 2265 Patienten erstellt. Mit einem weiteren Datensatz aus 1372 Paare von Gesichtsfeldmessungen und der optischen Kohärenztomographie, wurde ein XGBoost Modell für die orts aufgelöste Vorhersage von Defekten trainiert.

Durch die Experimente in dieser Arbeit konnte nicht bestätigt werden, dass sich Fundusfotografien alleine zur Erkennung und Quantifizierung von Gesichtsfelddefekten eignen. Das CNN, das zur Quantifizierung von Gesichtsfelddefekten trainiert wurde, erreicht eine Accuracy von 56 Prozent auf den Testdaten. Durch die Verknüpfung von Ergebnissen aus den optischen Kohärenztomographien konnte die Modellgüte mit Methoden des Gradient Boosting verbessert werden. Hier erreicht das Modell zur Quantifizierung von Gesichtsfelddefekten eine Accuracy von 86 Prozent.

Für die orts aufgelöste Vorhersage von Gesichtsfelddefekten erreichte das XGBoost Regressionsmodell ein  $R^2$  von 0.56 bei einem  $MAE$  von 4.41 dB.

**Stichworte** – Machine Learning; Convolutional Neural Network; Gradient Boosting; Augenmedizin; Peripheres Sehen; Feature Engineering.