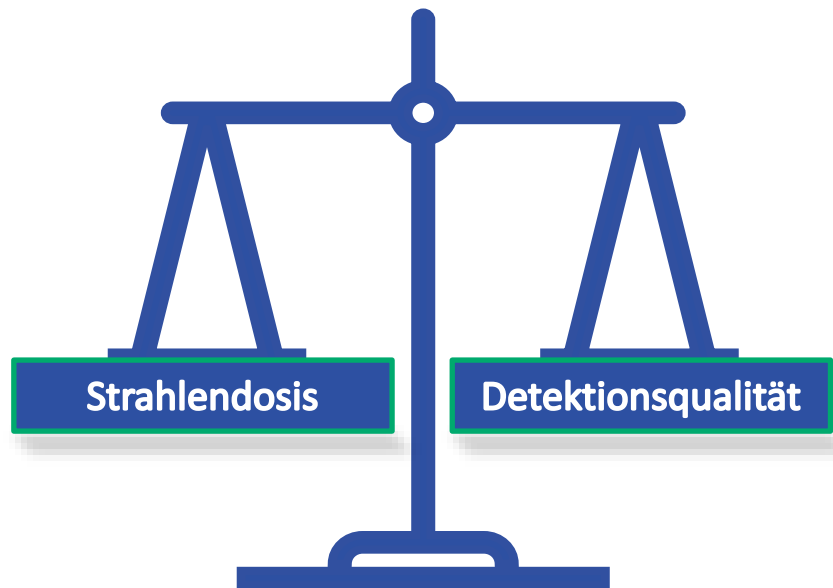


Erklärbarkeit für KI zur Bildqualitätsbewertung in der Mammographie

N. Amanova, J. Martin. C. Elster

BILDQUALITÄTSBEWERTUNG IN MAMMOGRAPHIE



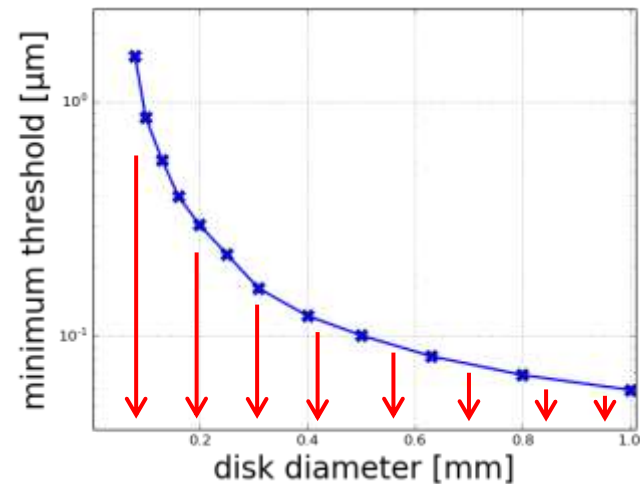
EUROPEAN GUIDELINES

mindestens 16 Aufnahmen



CDMAM phantom [1]


Niedrige CDC - bessere Bildqualität




Kontrast-Detail-Kurven (CDC)



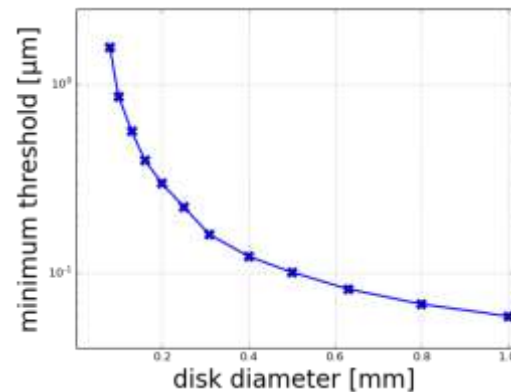
KI IN BILDQUALITÄTBEWERTUNG



CDMAM phantom [1]



neurales Netz
(vereinfacht)



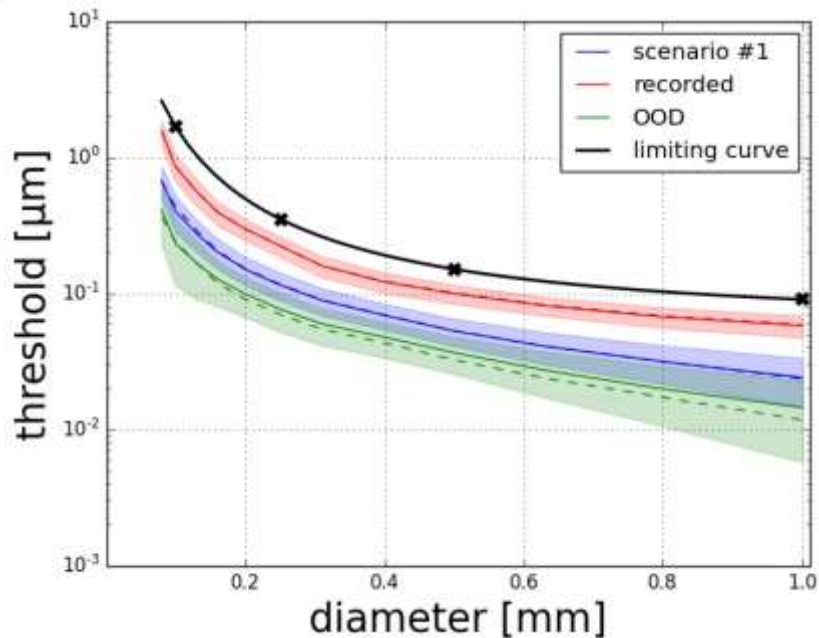
CDC Vorhersage [2]



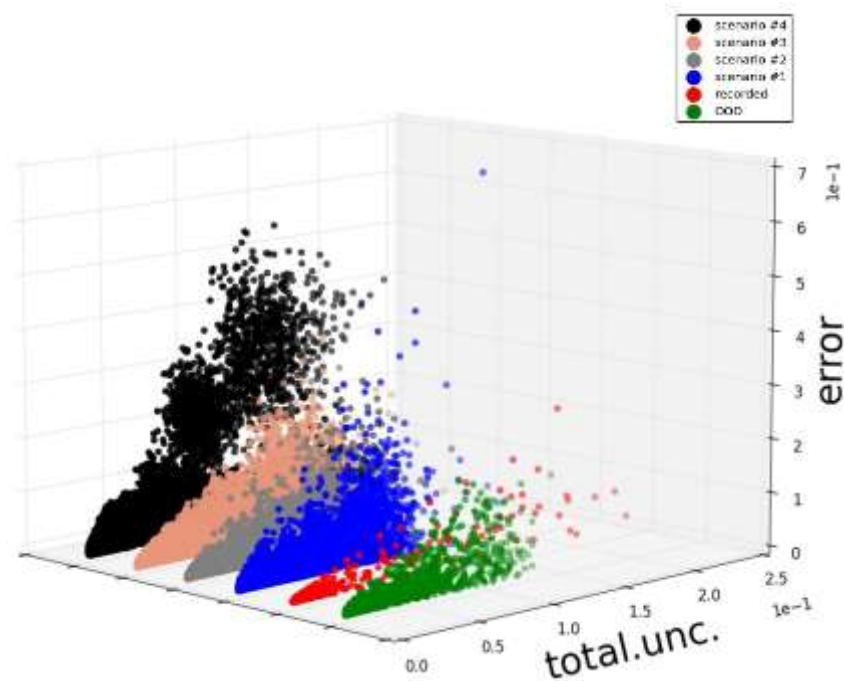
[1] – J. A. Thomas, et.al. Contrast-detail phantom scoring methodology. *Medical physics*

[2] – N. Amanova, J. Martin, C. Elster. (2022). Explainability for deep learning in mammography image quality assessment. *Machine Learning: Science and Technology*, 3(2), 025015

KI IN BILDQUALITÄTSBEWERTUNG - ERGEBNISSE




Ensemble Performance
auf Einzelbildern




Performance auf den
gesamten Testdatensatz




ERKLÄRBARKEIT DER KI IN BILDQUALITÄTSMBEWERTUNG



CDMAM phantom [1]



neurales Netz
(vereinfacht)




CDC Vorhersage [2]



[1] – J. A. Thomas, et.al. Contrast-detail phantom scoring methodology. Medical physics

[2] – N. Amanova, J. Martin, C. Elster. (2022). Explainability for deep learning in mammography image quality assessment. Machine Learning: Science and Technology, 3(2), 025015

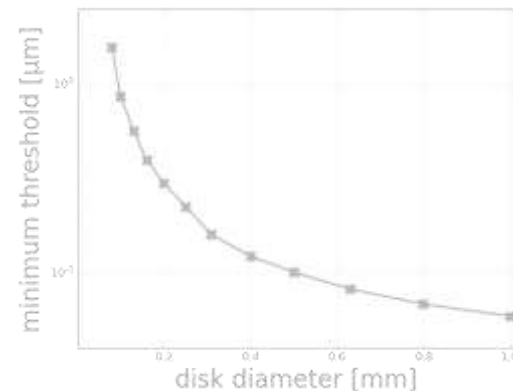
ERKLÄRBARKEIT DER KI IN BILDQUALITÄTSMBEWERTUNG



CDMAM phantom [1]

- Sensitivity Analysis [3]
 - Occlusion Sensitivity [4]
 - Layer-wise Relevance Propagation (LRP) [5]
- ➔ keine zufriedenstellenden Ergebnisse

neurales Netz
(vereinfacht)



CDC Vorhersage [2]



[1] – J. A. Thomas, et.al. Contrast-detail phantom scoring methodology. Medical physics

[2] – N. Amanova, J. Martin, C. Elster. (2022). Explainability for deep learning in mammography image quality assessment. Machine Learning: Science and Technology, 3(2), 025015

[3] – Zeiler MD and Fergus R 2014 Visualizing and understanding convolutional networks European Conf. on Computer Vision (Springer) pp 818–33

[4] – Montavon G, Samek W and Müller. (2018). Methods for interpreting and understanding deep neural networks Digit. Signal Process. 73 1–15

[5] – Bach S, et.al. (2015). On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation PLoS One 10 e0130140

NEUE ERKLÄRBARKEITSMETHODE FÜR KI

OMIG - oriented, modified integrated gradients

Berechnung der Relevanzen:

$$R(x) = \frac{\partial (\text{midpoint of CDC})}{\partial x} \quad (1)$$

Modifikation von x anhand der Relevanzen $R(x)$ um x' zu finden:

$$x_{l+1} = x_l - \varepsilon \cdot R(x_l) \quad (2)$$

OMIG sind die Differenz zwischen dem **End-** und dem **Anfangs**punkt des Pfades:

$$\Delta x = x' - x \quad (3)$$





REELLE AUFNAHME





OMIG HEATMAP





SIMULIERTE AUFNAHME



OMIG HEATMAP - REELLE AUFNAHME




OMIG HEATMAP - SIMULIERTE AUFNAHME



ZUSAMMENFASSUNG UND AUSBLICK

- **Machine Learning: Science and Technology**
N. Amanova, J. Martin, C. Elster, Explainability for deep learning in mammography image quality assessment
 - ✓ CDC Vorhersagen mit einer **einzelnen** Aufnahme
 - ✓ **Unsicherheitsberechnung**
 - ✓ **OMIG Erklärbarkeitsmethode**
 - ✓ **Upsampling** Methode
- OMIG auf **Klassifikationsaufgaben**
 - ✓ Wahrscheinlichkeiten der vorhergesagten Klassen
- **Weitere** CDMAM Phantom Aufnahmen



Beispiele von OMIG heatmaps auf CelebA Datensatz [1]





[Veröffentlichung herunterladen](#)



[Lernen Sie uns kennen](#)

Physikalisch-Technische Bundesanstalt, Berlin

Narbota Amanova

030 3481 7978

narbota.amanova@ptb.de



2022-10-11



Physikalisch-Technische Bundesanstalt
Braunschweig und Berlin
Nationales Metrologieinstitut