

STEFAN BOSSE^{1*}

JENS PRAGER, DIRK GOHLKE³


DIRK LEHMHUS²

¹ Institute of Computer Science
Researchgroup Practical Computer Science
University of Koblenz

³ Bundesanstalt für Materialforschung und Prüfung

² Fraunhofer IFAM, Bremen





Class	Dens.	Size
A	0.01	0.02
D	0.1	0.5
C	1	2

POROSITY CHARACTERIZATION OF HIGH-PRESSURE DIE-CAST PLATES BY A FUSION OF ULTRASONIC AND X-RAY MEASURING METHODS AND EXPLAINABLE DATA-DRIVEN MODELING

Stefan Bosse, Jens Prager, Dirk Gohlke, Dirk Lehnhus

INHALTE

01

Aluminium Druckguss

Aluminum High-Pressure Die Casting
Porendefekte und Legierungen

02

Röntgendiagnostik

Radiography, Micro Focus, CT
Bildverarbeitung
Simulation und ML

03

Puls-Echo US Diagnostik

HF Puls-Echo Dual Transducer
Frequenzspektrum als Eigenschaft

04

Transmission US Diagnostik

HF Puls Transmission
Zeitsignal als Eigenschaft

05

Immersion US Diagnostik

Fokussierter HF Puls-Echo Scan
Poren und weitere Defekte

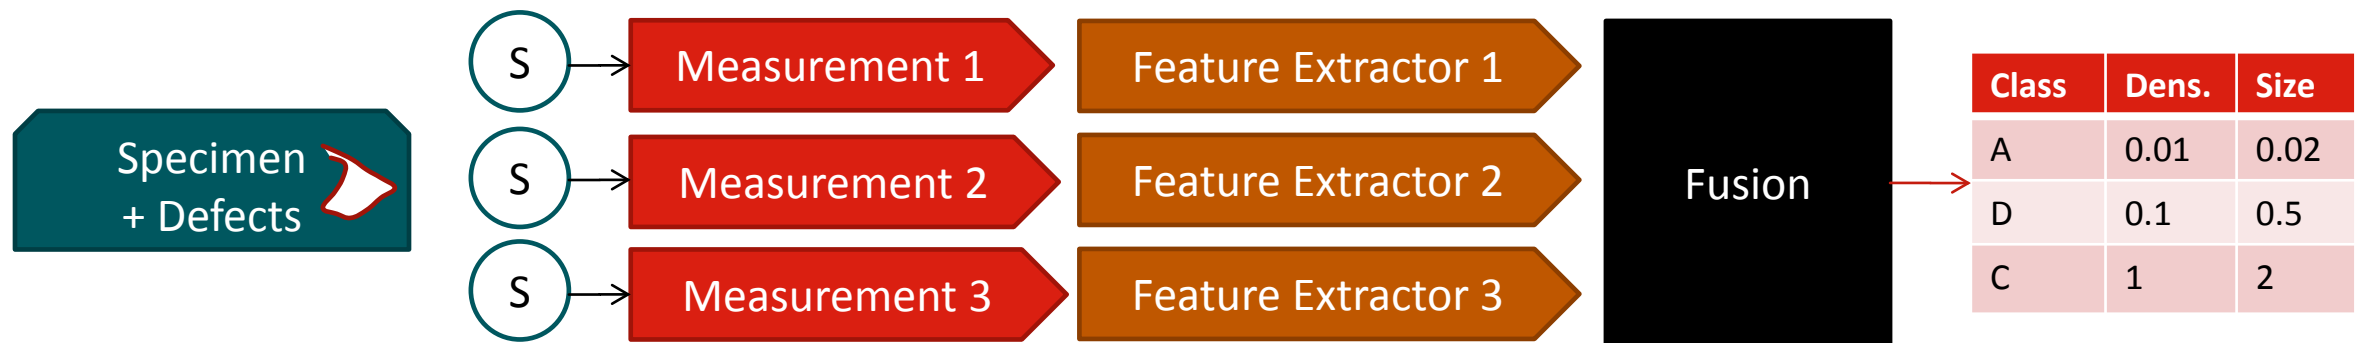
06

Legierungs- und Porenanalyse

Datengetriebene Prädiktion
Erkenntnis aus ML Modellen
Lessons learned

ÜBERBLICK

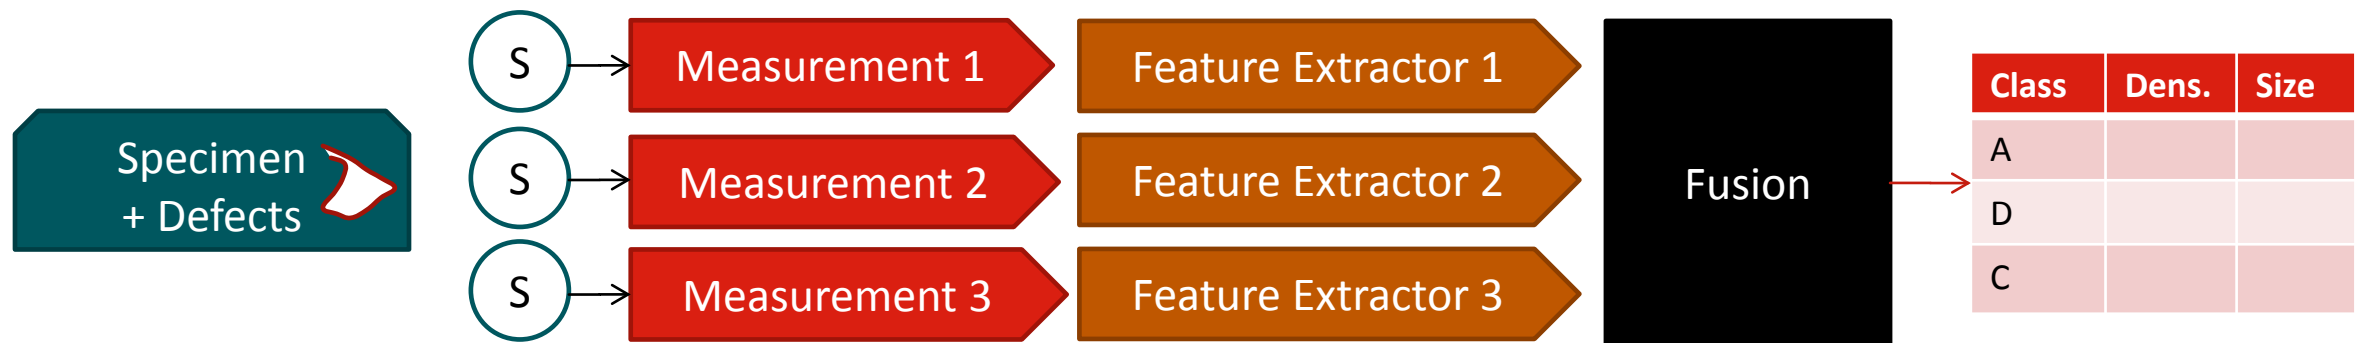
- In dieser Studie werden verschiedene Messtechniken untersucht, die zur Identifizierung und Charakterisierung von Defekten, insbesondere Poren, in dünnwandigen Hochdruck-Druckguss-Aluminiumproben (HPDC) mit unterschiedlichen Legierungszusammensetzungen eingesetzt werden.
- Hier Konzentration auf **zerstörungsfreie Prüfmethoden** wie **Röntgenradioskopie** und verschiedene **Ultraschallprüfansätze**.
- Die Merkmalsextraktion wird sowohl mit analytischen (modellgetriebenen) als auch mit datengetriebenen Methoden (ML) durchgeführt; schließlich Fusion der extrahierten Merkmale...



Defect Characterization

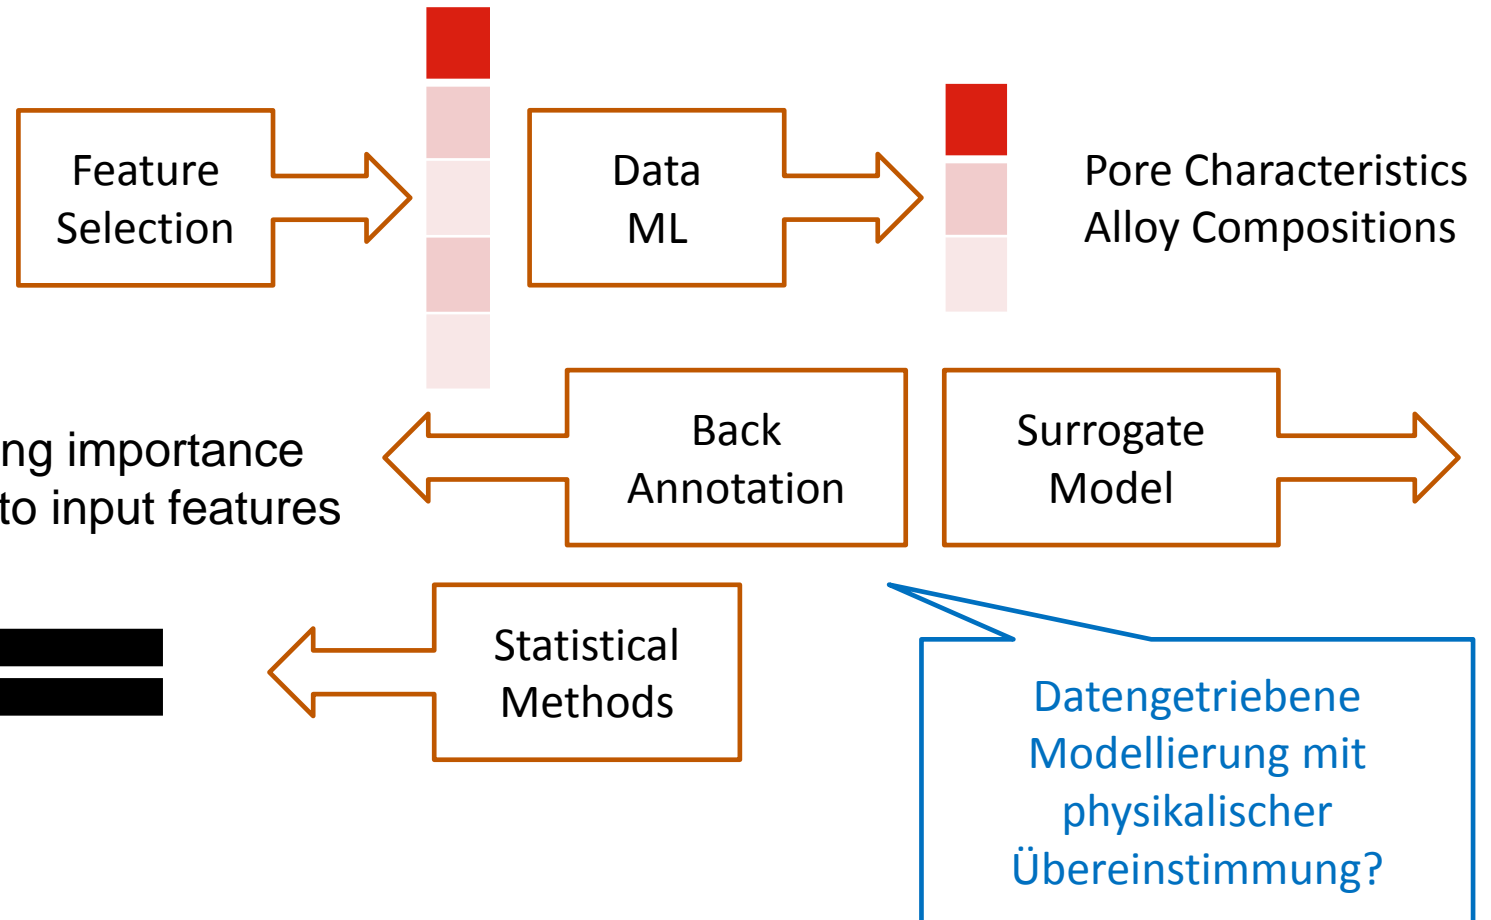
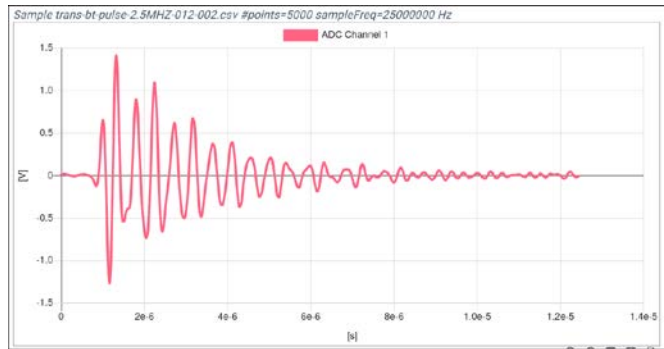
WORUM GEHT ES? WAS IST DAS ZIEL?

1. Multivariate und Multimodale Charakterisierung von Alu Druckguß Proben
2. Einsatz von datengetriebenen Modellen zur Bestimmung der Bauteil- und Materialeigenschaften - aber erklär-, generalisier- und nachvollziehbar!
3. **Ersatz von teuren und aufwändigen Prüf- und Messverfahren (Röntgen, Tomografie, Scan Verfahren) mit preisgünstigen Verfahren (Pulsecho UT mit gängigen Prüfköpfen für Dickenmessung)**




Defect Characterization

LEGIERUNGS- UND POREN DEFEKT DIAGNOSTIK




MATERIALIEN: ALU. DRUCKGUSS PLATTEN


- Aluminium-Druckguss von (kleinen) Platten mit unterschiedlichen Legierungszusammensetzungen: Primär, Sekundär-89, Sekundär-58
- Form der Prüflinge: 1. Rechteckig 2. T-Bone (für Zugversuche)
- Größe der Prüflinge ca. 140x40/28 mm, Dicke 3 mm
- Typische Defekte: Poren unterschiedlicher Größe, Form, Dichte, teilweise höhlenartige Strukturen, Verteilung über Platte ist inhomogen und folgt dem Materialfluss
- Anzahl der Proben mit Legierungsverteilungen:
Vollständiger Satz: 150, Teilmenge 1: 50, Teilmenge 2 : 12



VERFAHREN: HIGH-PRESSURE DIE CASTING



(a)



(b)

[Fraunhofer IFAM]

HPDC-Matrize für die Musterherstellung: (a) bewegliche Seite und (b) feste Seite. Hohlraum, aus dem die in der vorliegenden Studie verwendeten Proben stammen, ist rot hervorgehoben .

PROBENSATZ

Number and use of samples	AlSi10MnMg100 wt.-% primary	AlSi10MnMg58 wt.-% secondary	AlSi10MnMg89 wt.-% secondary
Total number of samples	198	100	130
Visual classification based on X-ray radioscopy (IFAM)	198	100	130
ADR of porosity based on X-ray radioscopy with a micro-focus X-ray tube (University of Koblenz)	18	14	18
Pulse-echo HF US (University of Koblenz)	18	14	18
Tensile testing (Fraunhofer IWS) ¹	15 (4A/3B/3C)	15 (4A/3B/4C)	11 (3A/4B/4C)

Übersicht über die Anzahl der gegossenen Proben und die Anzahl der für die verschiedenen *Untersuchungen* verwendeten Proben [Fraunhofer IFAM, Bremen]

LEGIERUNGEN

Alloy	Element content level [wt.-%]														
	Si	Fe	Cu	Mn	Mg	Cr	Zn	Ti	Sr	Ni	Pb	Sn	Sb	Ca	P
Silafont-36®specification*	9.5-11.5	<0.15	<0.03	0.5-0.8	0.1-0.5	-	<0.07	0.04-0.15	0.010-0.025	-	-	-	-	-	<0.001
Silafont-36®100 wt.-% primary**	10.28	0.082	0.002	0.513	0.146	0.001	0.001	0.008	0.002	-	-	-	-	-	-
AlSi10MnMg58 wt.-% secondary**	10.18	0.13	0.02	0.61	0.27	0	0.01	0.06	0.0171	0.009	0.002	0.0006	0.002	-	-
SILVAL 10®Specification*	9.5-11	<0.35	<0.05	0.35-0.6	0.25-0.35	<0.03	<0.1	0.05-0.15	0.015-0.025	<0.05	<0.05	<0.05	<0.002	<0.002	<0.002
SILVAL 10®89 wt.-% secondary**	9.95	0.338	0.023	0.471	0.279	0.011	0.026	0.075	0.0275	0.007	0.005	0.001	0	0.0009	0.001


Zusammensetzung der in den Experimenten verglichenen Legierungen: Lieferantenspezifikationen und Analysen der tatsächlich in den Experimenten verwendeten Chargen, wie sie von den Lieferanten bereitgestellt wurden [Fraunhofer IFAM, Bremen].

MESSVERFAHREN

(P)rimär, (S)ekundär, (T)ertiär

Röntgentechnik (RT)

- A. Röntgenuntersuchung (Einzelprojektion), μ -Fokus Radioskopie (S)
- B. Röntgenuntersuchung (Mehrprojektion), μ -Fokus, Computed Tomography (T)
- C. Röntgensimulation (T)




Ultraschalltechnik (UT)

- D. HF US Impulsecho (P)
- E. HF US Impulsecho Tauchtechnikprüfung (S)
- F. HF US Transmission (P)

Sonstiges

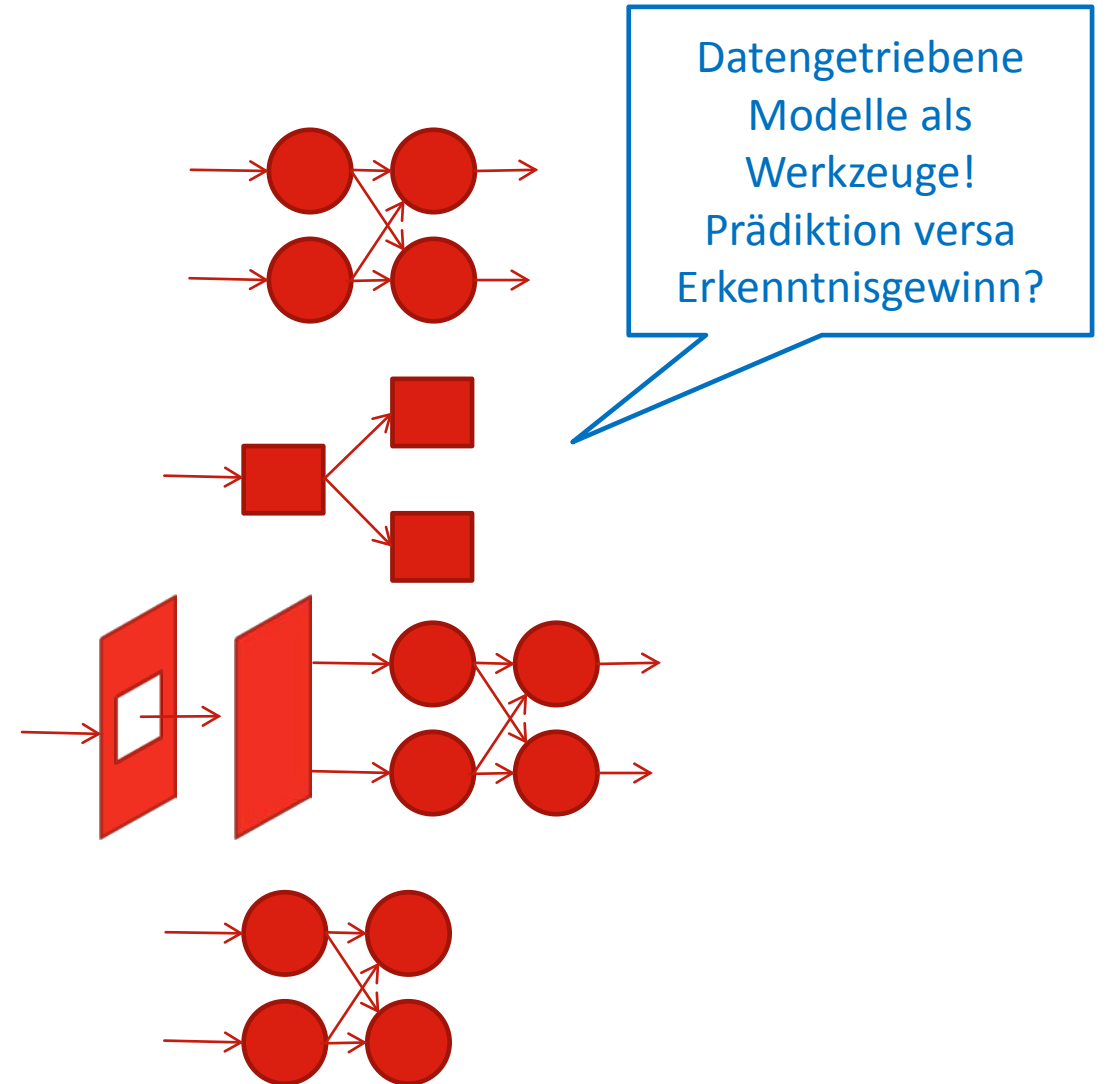
- G. Zugversuche (T)

Multimodale
Messverfahren

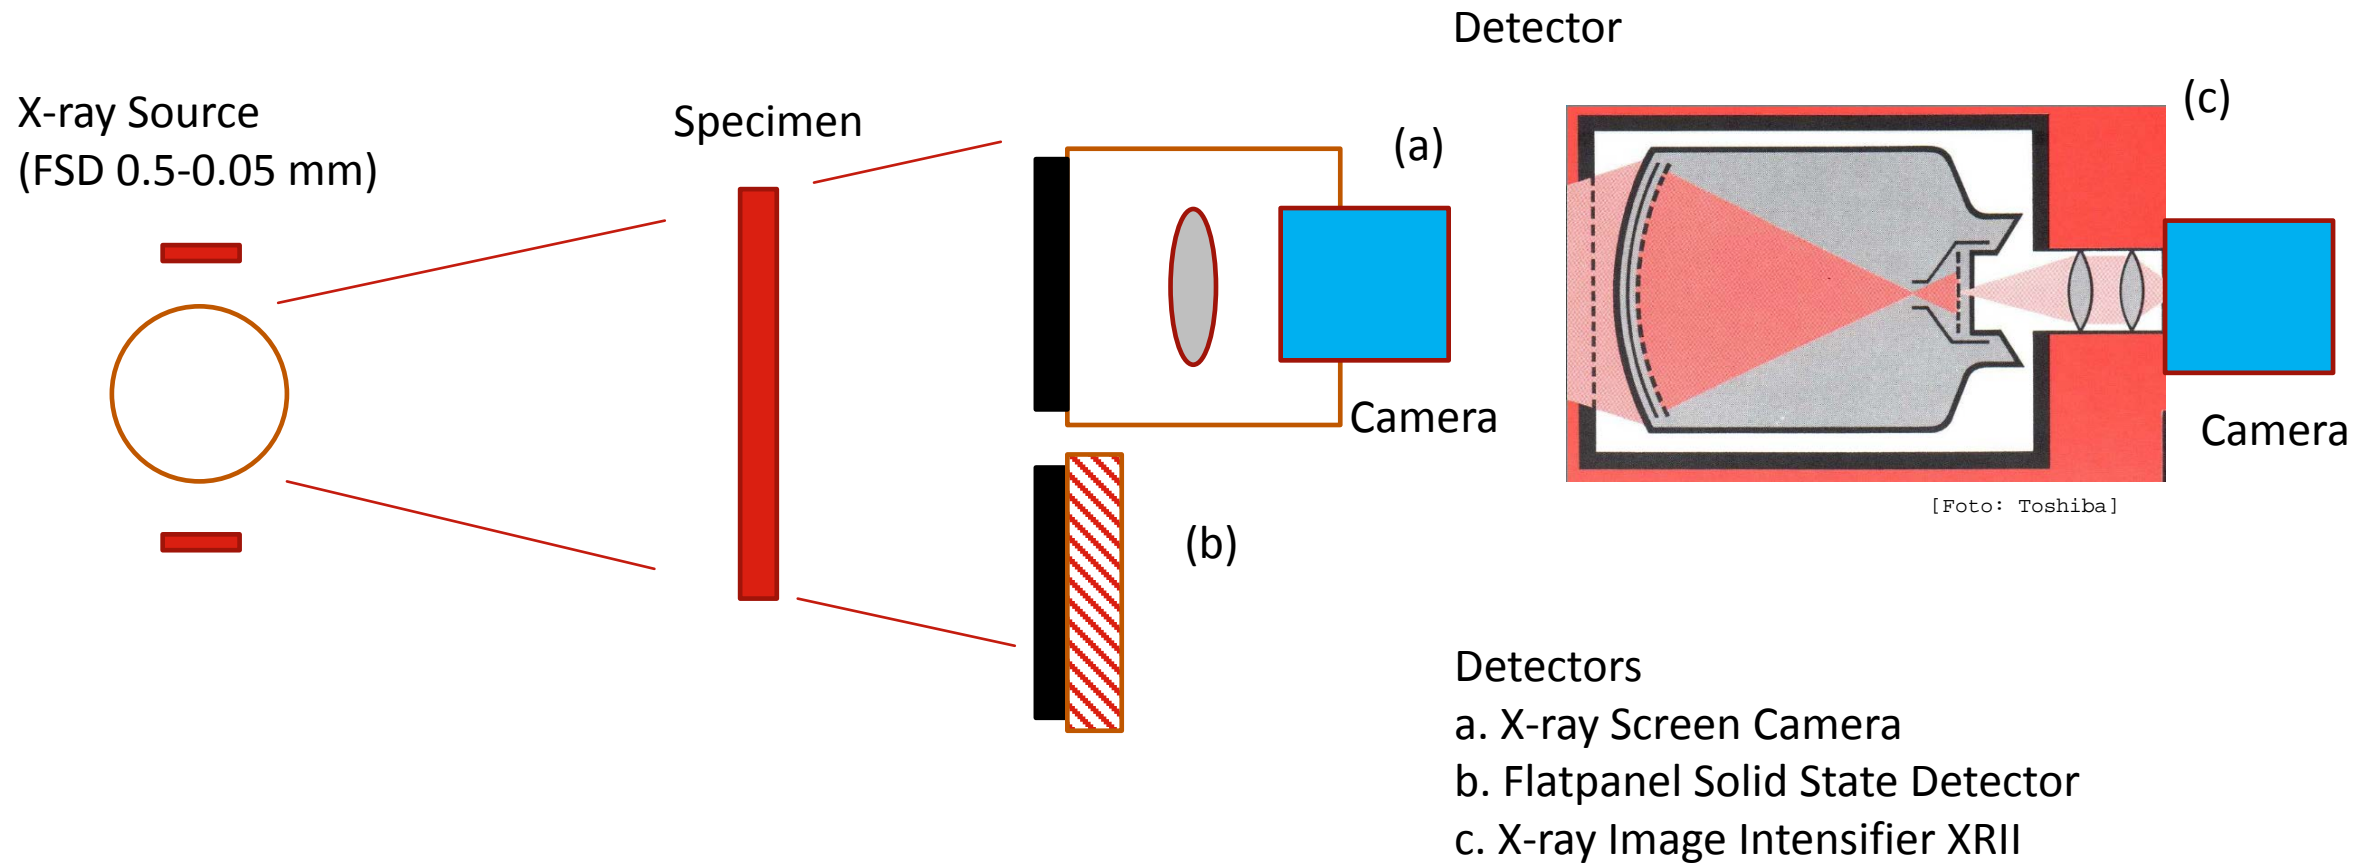


MODELLE


- KNN: Künstliches Neuronales Netzwerl, gerichteter nichtlinearer Funktionsgraph, überwachtes Training (UT)
- EB: C50 Entscheidungsbaum, überwachtes Training, algorithmische Maßnahmen gegen Überanpassung (UT)
- CNN: Kombination aus mathematischen Matrixfaltungen mit KNN, überwachtes Training (RT)
- SOM: KNN ohne Ausgang (Self-organizing Map), automatisierte und nicht überwachte Datengruppering/Clustering (UT)



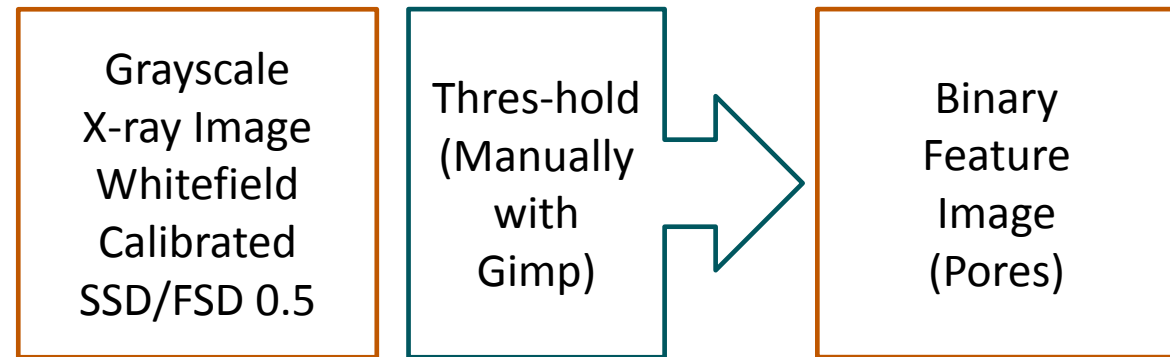
RÖNTGENDIAGNOSTIK: RADIOSKOPIE



RÖNTGENDIAGNOSTIK: RADIOSKOPIE



*Beispielhafte Darstellung von binarisierten Röntgenbildern, die die vier Qualitätsklassen A, B, C und D (Ausschuss) repräsentieren, die bei der **visuellen Inspektion** unterschieden werden*

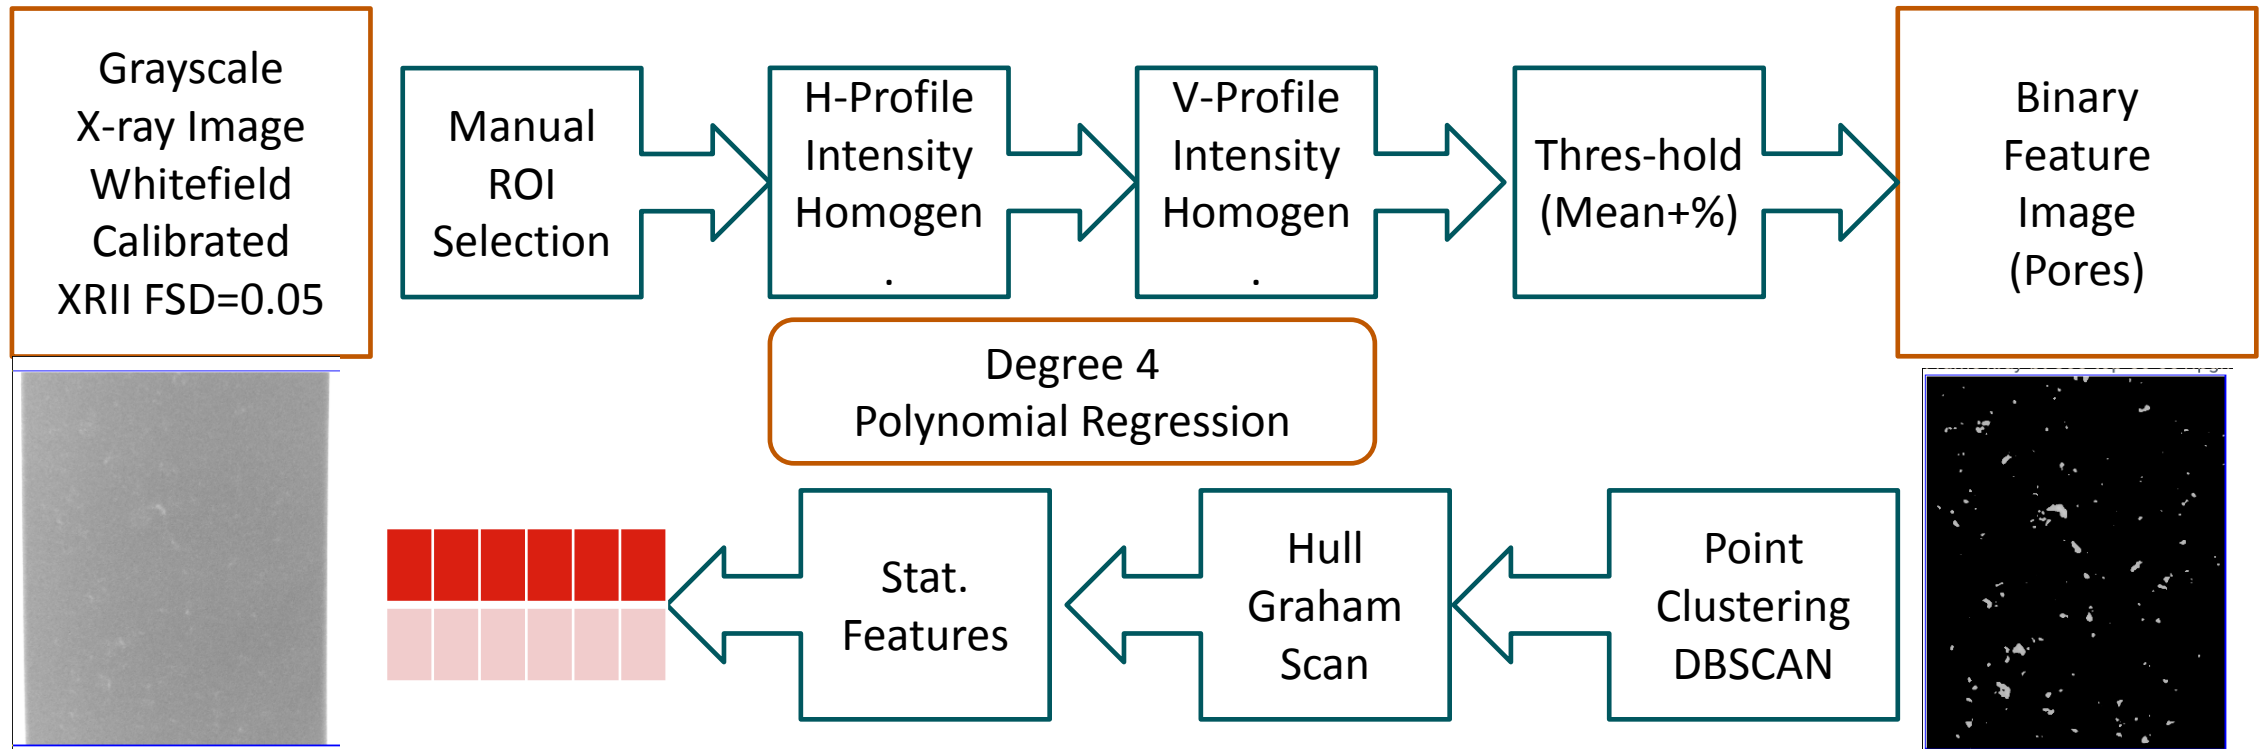


Der naive Ansatz mit visueller Klassifikation der Proben!

RÖNTGENDIAGNOSTIK: RADIOSKOPIE

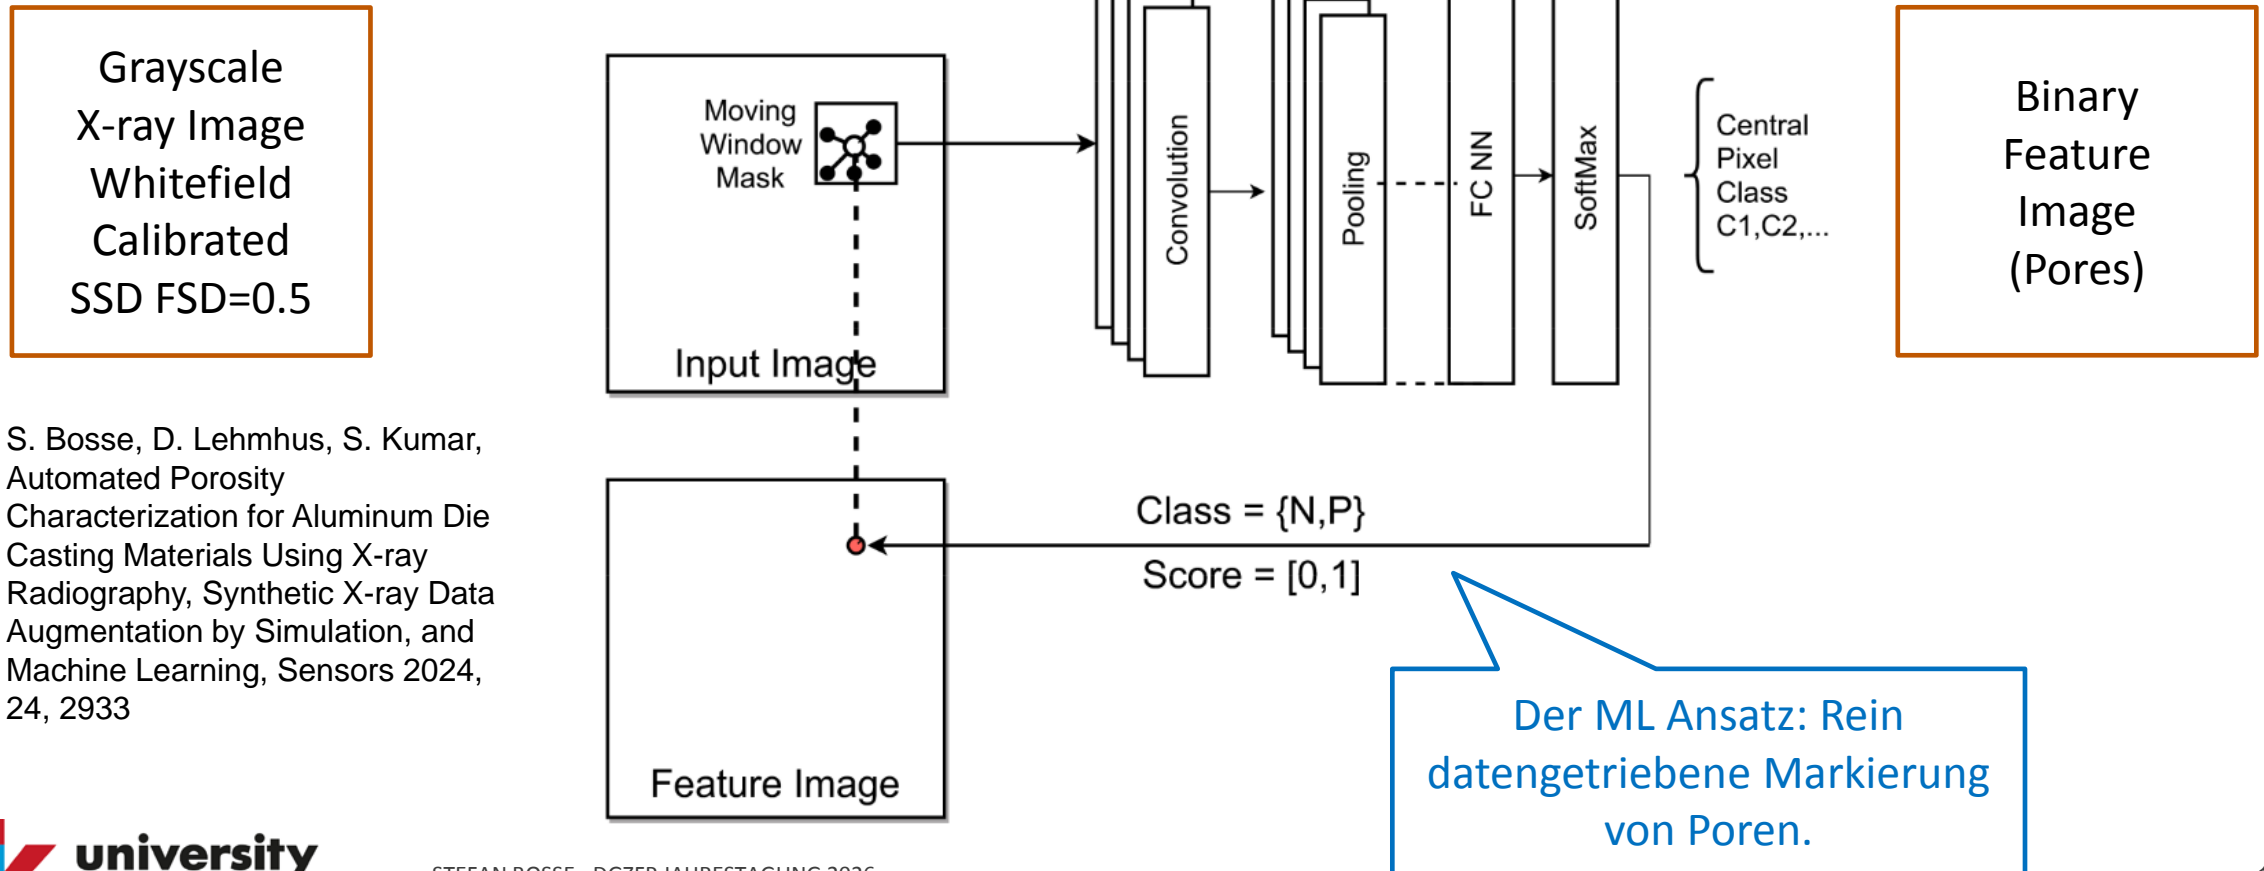
Der verbesserte Ansatz mit klass. Bildverarbeitungs-
algorithmen!

Modellgetriebene Bildverarbeitung und Merkmalsextraktion



RÖNTGENDIAGNOSTIK: RADIOSKOPIE

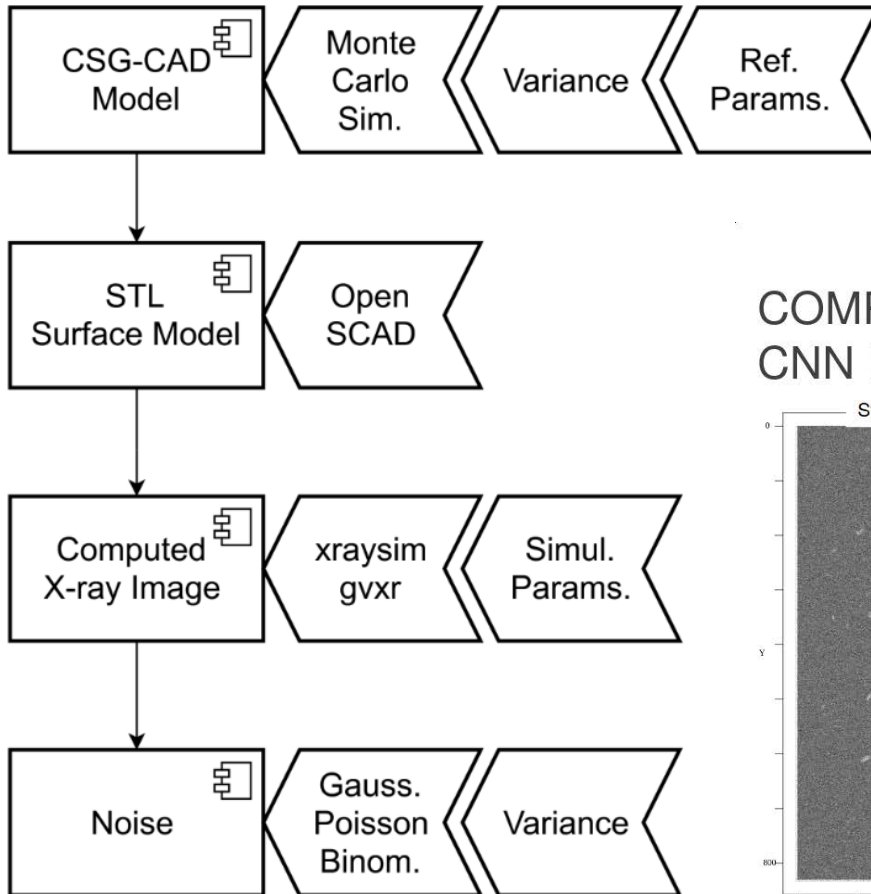
ML-getriebene verbesserte (?) Bildverarbeitung und Merkmalsextraktion



S. Bosse, D. Lehmhus, S. Kumar,
Automated Porosity
Characterization for Aluminum Die
Casting Materials Using X-ray
Radiography, Synthetic X-ray Data
Augmentation by Simulation, and
Machine Learning, Sensors 2024,
24, 2933

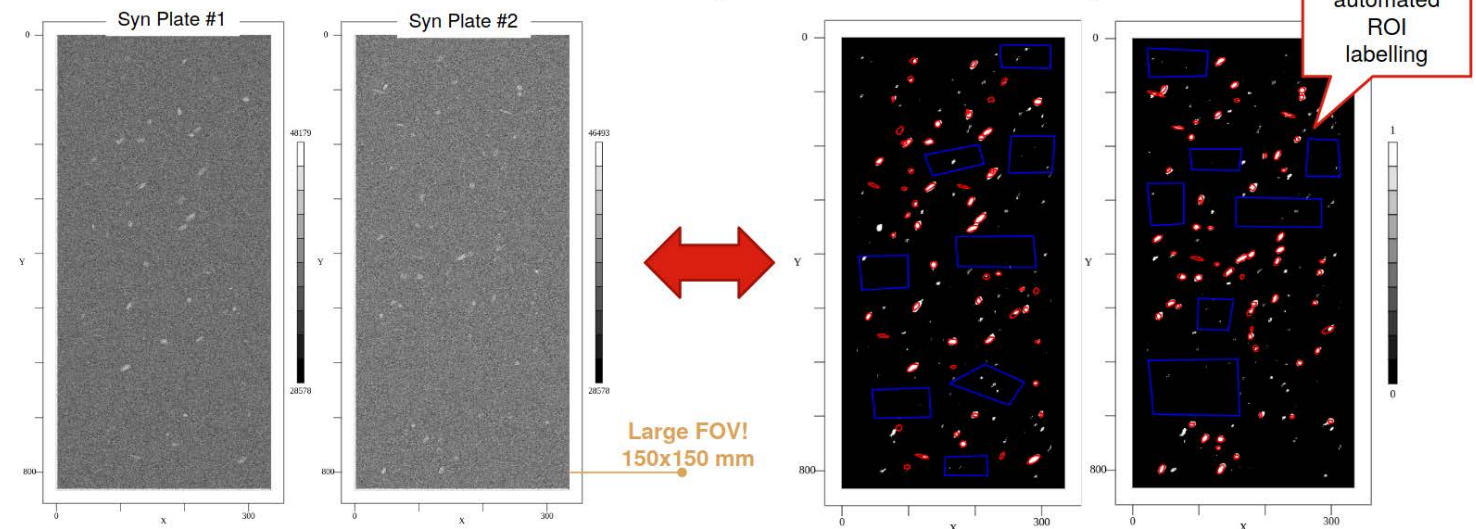
RÖNTGEN SIMULATION: RADIOSKOPIE

Der ML Ansatz muss trainiert werden. Hier mit synthetischen Daten aus Simulation



Stefan Bosse, Dirk Lehmus, Detection of hidden Damages in Fibre Laminates using low-quality Transmission X-ray Imaging, X-ray Data Augmentation by Simulation, and Machine Learning, FEMS EUROMAT 2023, the 17 European Congress and Exhibition on Advanced Materials and Processes, on 03 - 07 September 2023 in Frankfurt am Main (Germany). 2023

COMPARISON SIMULATED RADIOGRAPHY AND CNN PORE FEATURE MARKING (GROUND TRUTH)



X-RAY CT

Basisdaten: Geometrische
Charakterisierung der Poren.

Gerät:

- Micro Focus CT, U Siegen, Zeiss Xradia

Datenverarbeitung:

- Point cloud clustering (DBSCAN), Convex Hull of clustered points of a pore



Modellbasiert ist besser als ML!


X-RAY RADIOSCOPY

Gerät:

- Micro Focus Radioscopy, U Koblenz, Oxford Instruments Cu X-ray source 40 μm FSD, Toshiba XR11, 50 kV, 100-500 μA

Datenverarbeitung:

- Intensitäts Homogenisierung mit H/V Profilen
- Merkmalsmarkierung in Bildern
 - A. Threshold Binarization (cthr/otsu)
 - B. CNN Pixel Classifier
- Punktclustering (DBSCAN)
- Statistische Aggregate (Größe, Dichte)



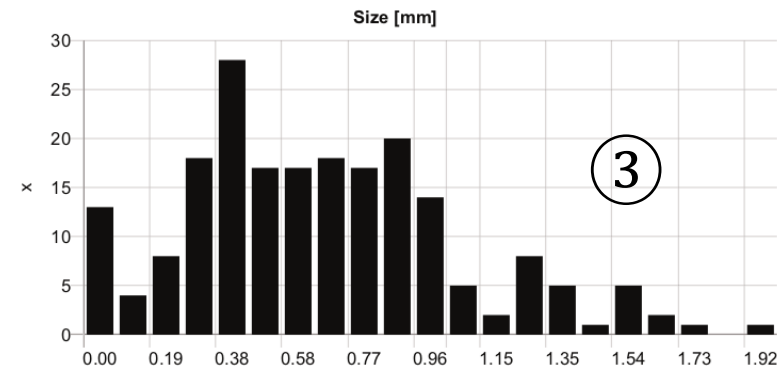


PORENSTATISTIK

Attribute:

1. Mittlere Anzahl von Poren/Sample (npores)
2. Mittlere Porendichte (coverage)
3. Mittlere Porendichte

Ergebnisse:

- Viele Poren sind klein (< 0.5 mm), einige sind groß (> 1 mm)
- Porendichte ist gering.



SELF ORGANIZING MAP (SOM) CLUSTERING

Autoklassifikation der Proben!

Attribute:


- Mittlere Anzahl von Poren / Sample (npores)
- Mittlere Porendichte (coverage)

Netzwerk

- 2x2 Knoten

Ergebnisse:




- Starke Attribute (gute Separation)
- C:18, B:22, A(A1+A2):10
- Nur 50% Übereinstimmung mit visuellen Klassen!



Node=Group
Assignment

[Kohonen, Neural Networks (3) 2013]


SOM Clustering



US DIAGNOSTICS: POROSITY MEASUREMENT


- Idee: Die Dämpfung von US-Wellen hängt von Frequenz und Porosität ab (Materialinhomogenität)
- Erfordert Breitband-US-Wandler - NA
- Ungefähr: Konventionelle Dickenmesswandler

Adler, Laszlo, and Shaio-Wen Wang. "Ultrasonic measurement of porosity in casts and welds." NASA. Lewis Research Center Analytical Ultrasonics in Materials Research and Testing (1986).



Der theoretische Ansatz

UT DIAGNOSTIK: IMPULS-ECHO (OBERFLÄCHE)



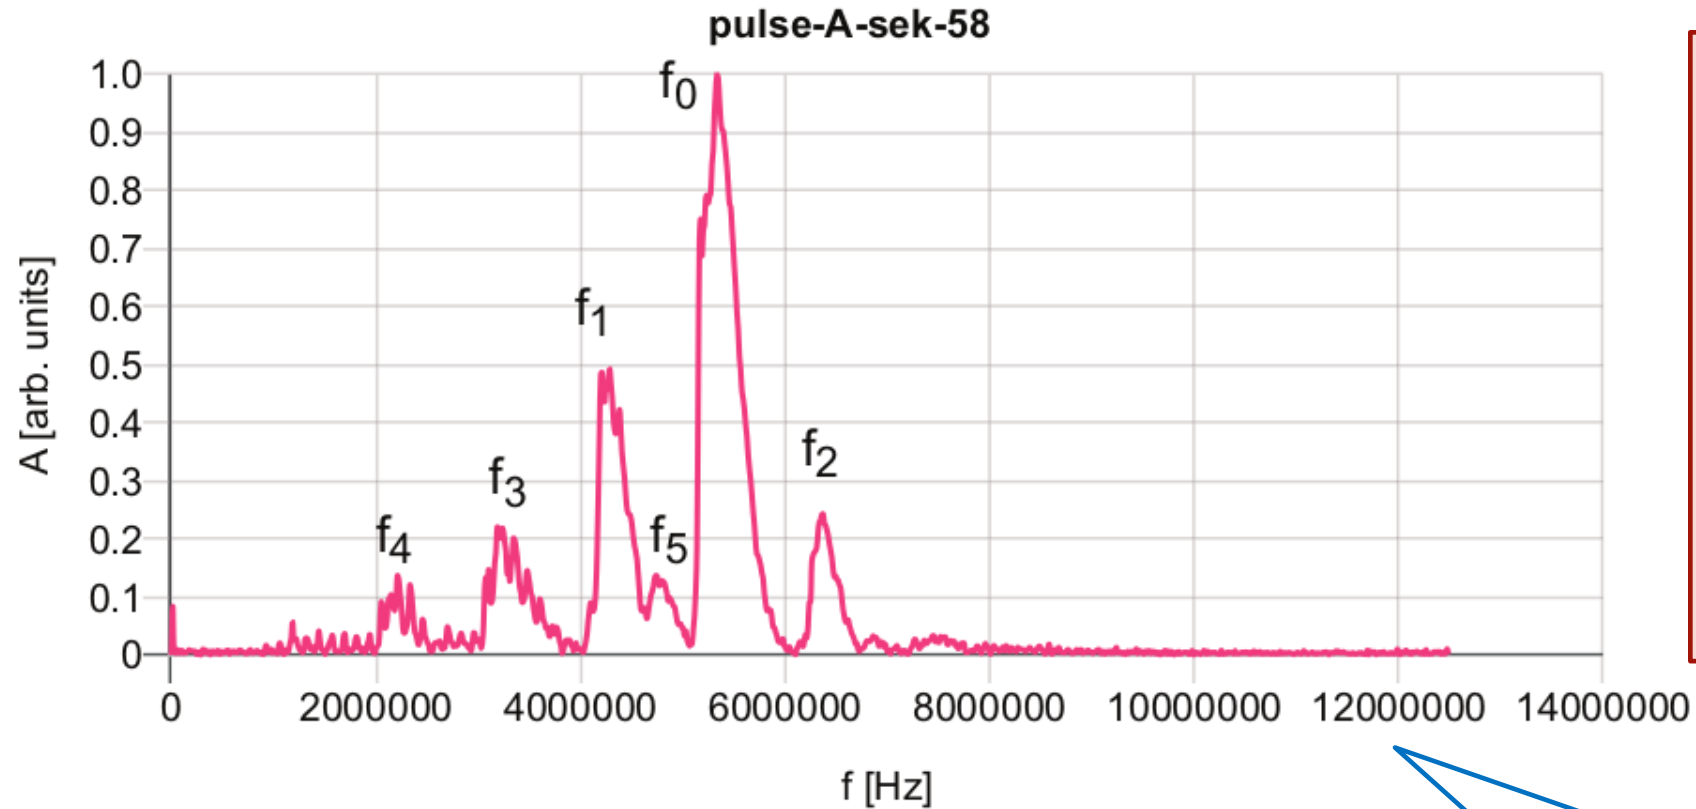
Typischer Messaufbau für hochfrequente Impuls-Echo-Messung

UT DIAGNOSTIK: IMPULS-ECHO

$s(t)$

FFT

Peak Fit



Prim. Frequency Ratios:

- $r_1 = f_0/f_1$
- $r_2 = f_0/f_2$

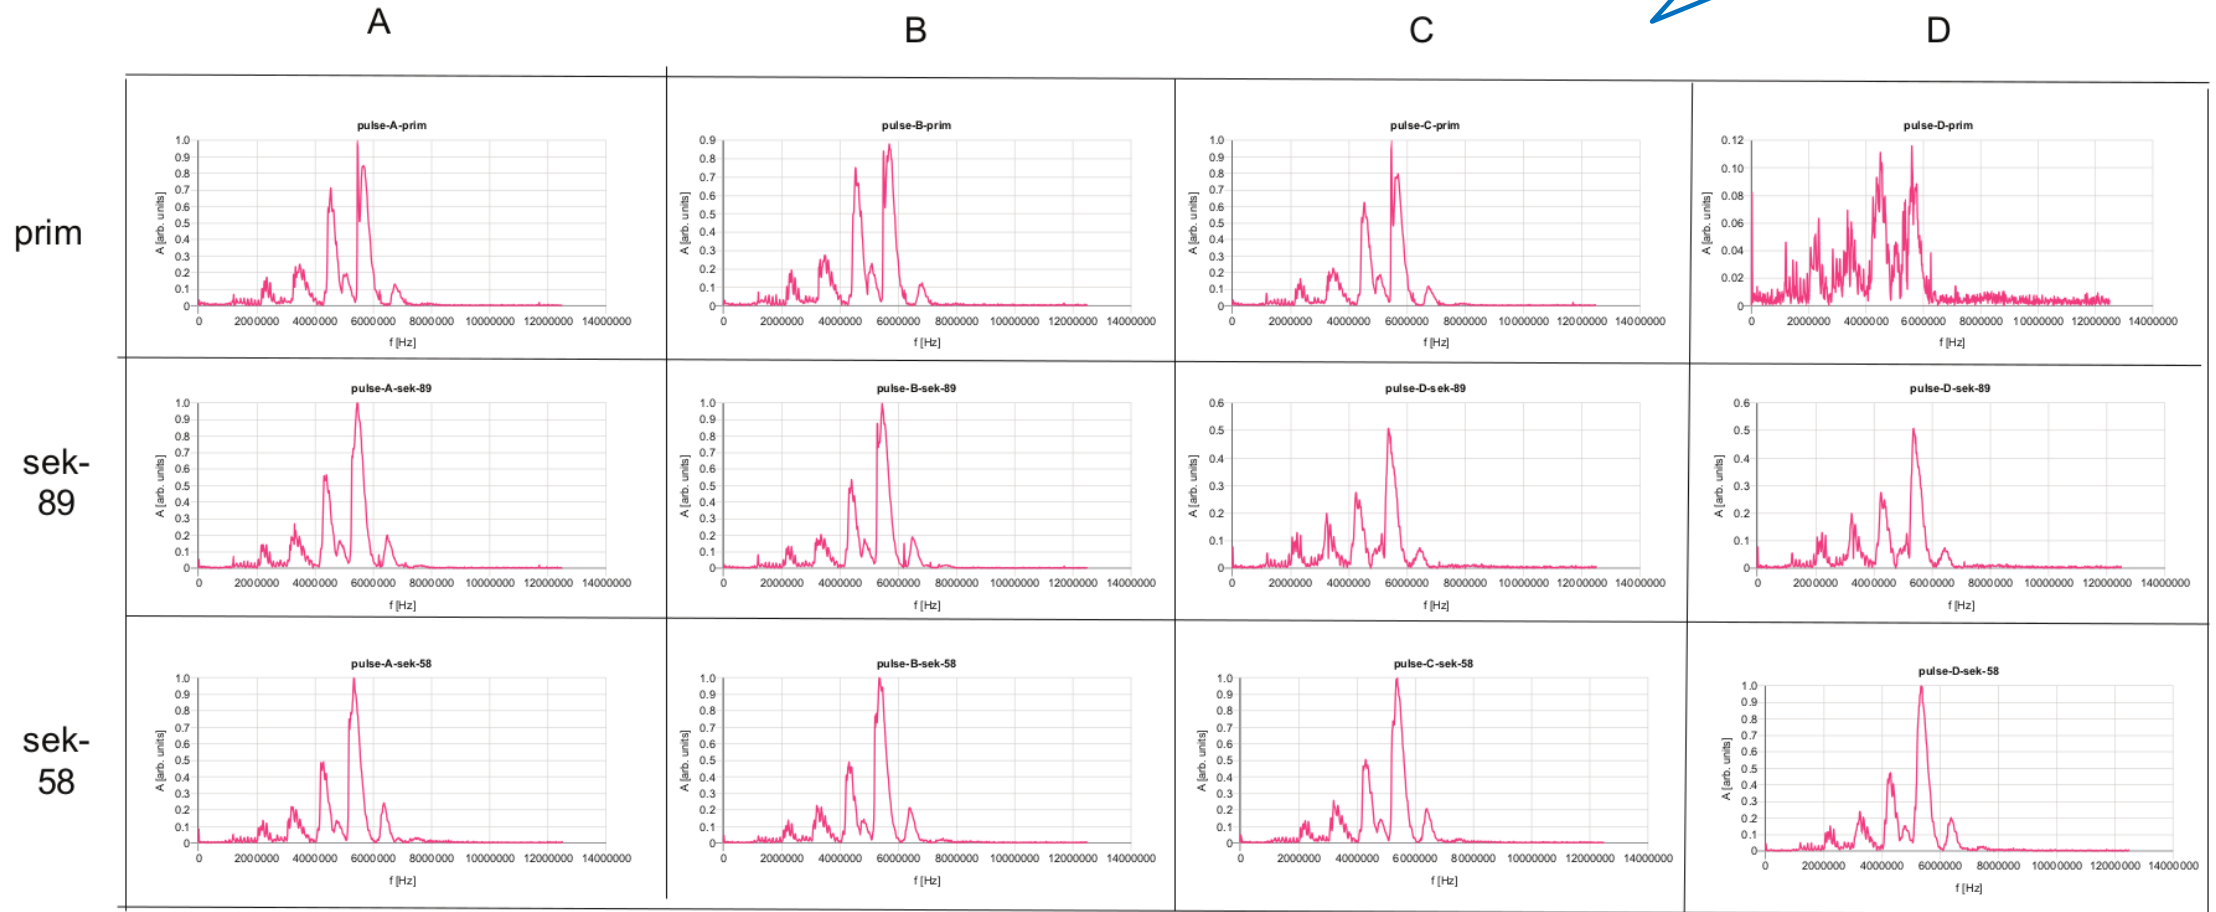
Sec. Frequency Ratios:

- $r_3 = f_0/f_3$
- $r_4 = f_0/f_4$
- $r_5 = f_0/f_5$

Resonantes Frequenzspektrum


UT DIAGNOSTIK: IMPULS-ECHO: SPEKTREN

Unterschiede erkennbar?
Legierung: Ja, Porosität: Nein



Akkumulative Frequenzspektren Legierung/Porositätsklasse

UT DIAGNOSTIK: LEGIERUNGSKLASSIFIKATION




Frequenzverhältnisse (Signalspitzen freq. 5,3/4,3 MHz und freq. 5,3/6,3 MHz, Gauss Peak Anpassung) für verschiedene Legierungsklassen

UT DIAGNOSTIK: LEGIERUNGSKLASSIFIKATION

Sinnvoller ML Einsatz?
Ja!


- Starke Frequenzspektren-Trennung für verschiedene Legierungen: Primär, Sekundär-89, Sekundär-58
- Ein einfacher Entscheidungsbaum (mit drei Knoten) unter Verwendung von Frequenzverhältnissen reicht für die automatisierte Klassifizierung aus
- Dieses Ergebnis war jedoch nicht zu erwarten: Die Legierungsvariation ist gering, was nicht die Ursache für die frequenzabhängige Ultraschallwellendämpfung sein kann.
- **Ein sekundärer Effekt muss die Ursache sein. Oxiddoppelfilme oder Mikrostruktur?**





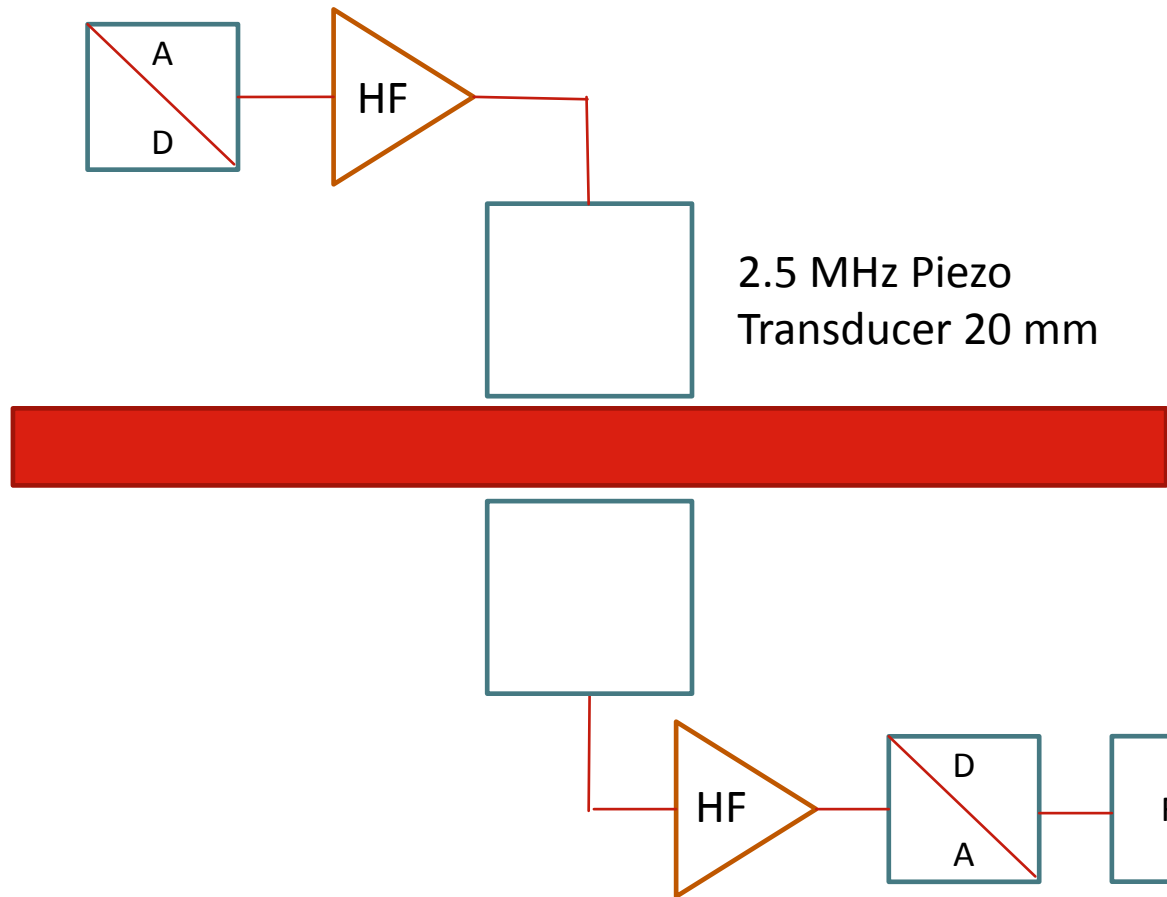
UT DIAGNOSTIK: POROSITÄTSKLASSIFIKATION

Sinnvoller ML Einsatz?
Nein!



- Schwache Trennung mit Frequenzspektren für verschiedene Porositätsklassen A, B, C, D
- Komplexer Entscheidungsbaum (> **20 Knoten**) unter Verwendung von Frequenzverhältnissen reicht für die automatisierte Klassifizierung nicht aus
- Aber: Wir haben zwei Porositätsklassifizierungen!
 - Visuell von Mensch zu Mensch
 - Basierend auf unüberwachtem SOM-Clustering
- Die Entscheidungsbäume und Klassifikationsqualität unterscheiden sich!
 - Visuell: 30 Knoten, 25% Fehler
 - SOM-Clustering: 20 Knoten, 15% Fehler



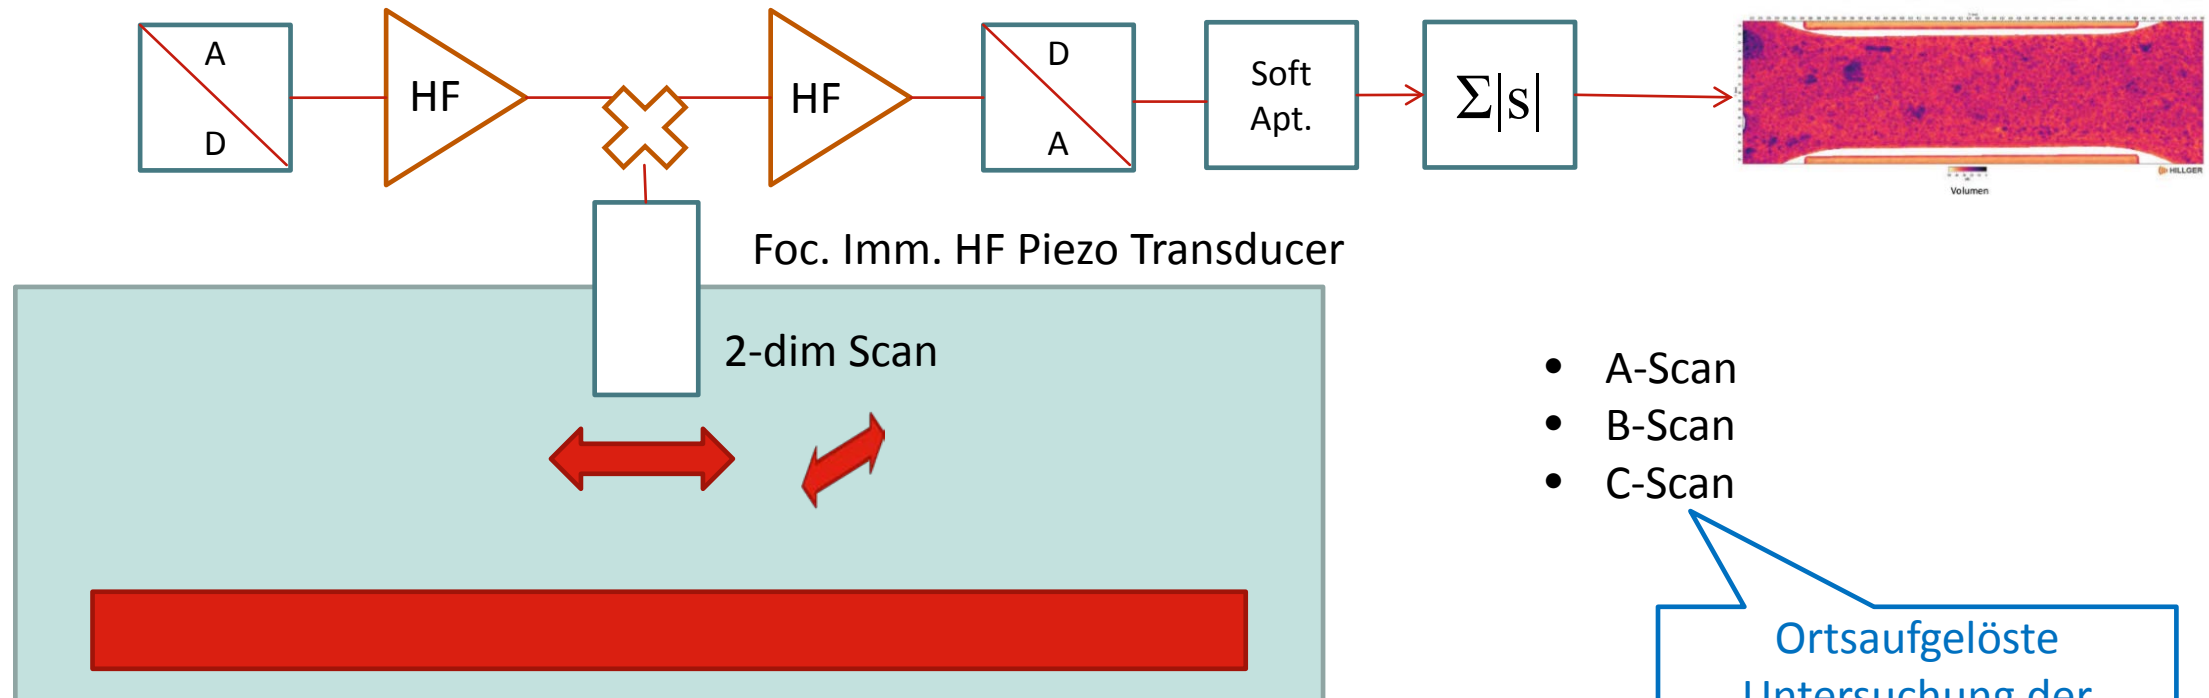
UT DIAGNOSTIK: TRANSMISSION (OBER-UNTERSEITE)



Frequenz Spektrum (a) Pitch (b) Catch Signal



UT DIAGNOSTIK: HF IMPULS-ECHO TAUCHTECHNIKPRÜFUNG

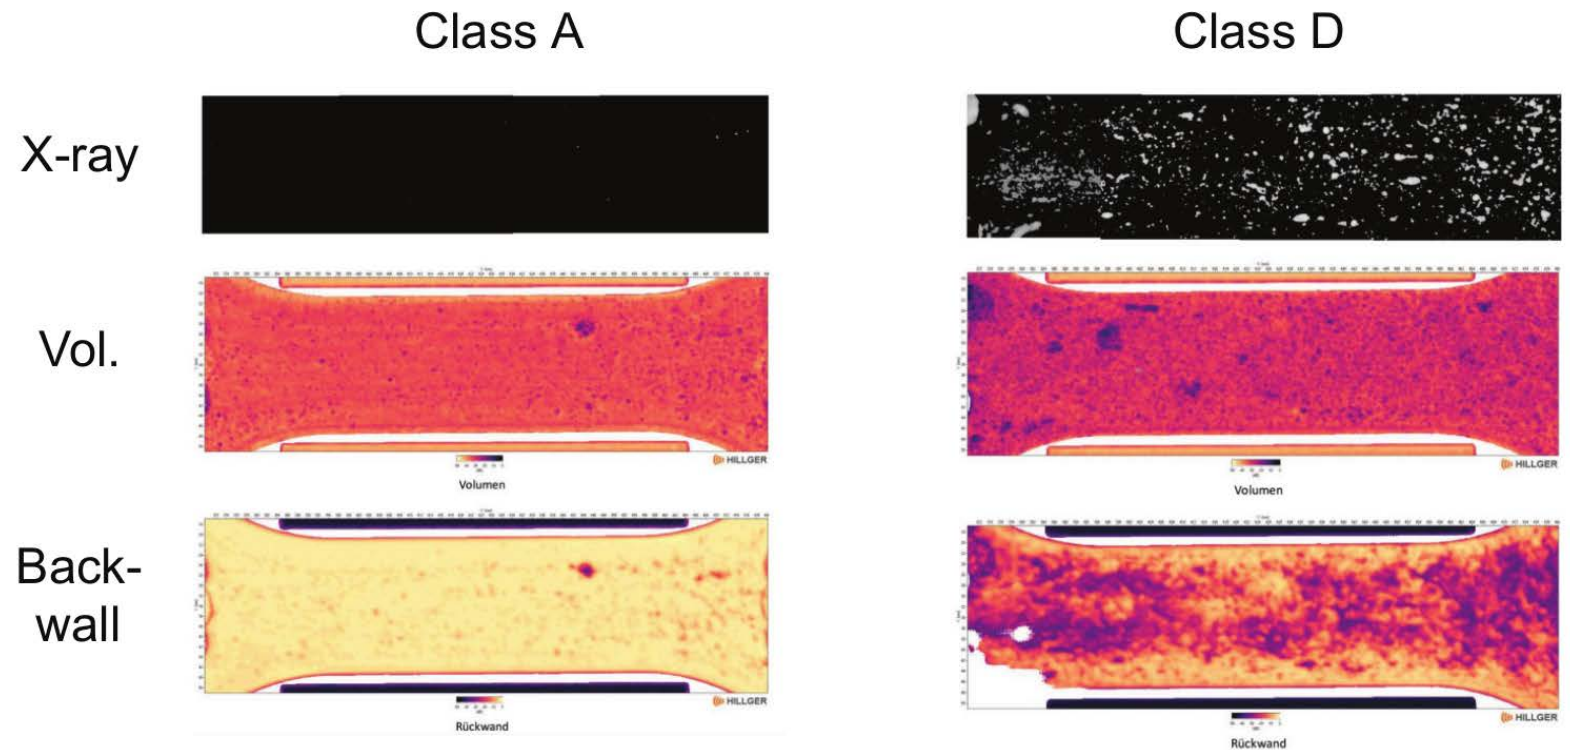


- A-Scan
- B-Scan
- C-Scan

Ortsaufgelöste
Untersuchung der
Wechselwirkung
HF-US mit Poren.

UT DIAGNOSTIK: HF TAUCHTECHNIKPRÜFUNG

- Schwache Korrelation zwischen Röntgenmarkierung und gescannten Rückwand- und Volumenimmersionsbildern!
- **Poren sind hier keine primäre oder alleinige Wechselwirkung!**






Räumlich aufgelöste C-Bilder (Oberfläche, Raster 0.1 mm)

UT DIAGNOSTIK: HF TAUCHTECHNIKPRÜFUNG

Class D

- Aber: Einige größere Porendefekte sind identifizierbar
- Steigende Anzahl von Fehlstellen (A => D)
- Und Immer stärker werdendes Rauschen, was zu einer RW-Absenkung führt.



Sinnvoller ML Einsatz?
Ja und Nein!

ZUSAMMENFASSUNG

Röntgendiagnostik

- Radioskopie liefert zur Oberfläche integrale Projektion von Poren
- Herausforderung ist der geringe Kontrast und Rauschen
- Porenanalyse mit klassischer Bildverarbeitung zeigt inhomogene Verteilung von Poren und Porengrößen, Qualität ist besser als ML!
- CT lieferte exemplarische 3-dim Porengeometrien (Höhlen)

Ultraschaldiagnostik

- Hochfrequenz Impuls-Echo Ultraschallmessungen liefern in einem lokalen Volumen integrale Interaktion mit Poren
- Frequenzspektrum kann verwendet werden um Porosität zu bestimmen - hier weniger!
- Frequenzspektrum liefert Rückschlüsse über Legierungszusammensetzung - aber physikalisch nicht erklärbar

Maschinelles Lernen

- Klassische Bildverarbeitungs-algorithmen bei guter Bildvorverarbeitung bessere Ergebnisse als CNN-ML Modelle
- Problem: Kein Ground-Truth! Automatisierte SOM Klassifikation besser als visuelle!
- KNN sind trügerische Datenmodelle, EB geben Auskunft über Generalisierbarkeit, EB mit SOM Labeling → bessere Ergebnisse

THANK YOU

Stefan Bosse

sbosse@uni-koblenz.de

www.edu-9.de

