

Digitalisierung und Prozessmesstechnik



KI - Nutzung in der Oberflächeninspektion Eine Revolution?

Jens Brandenburger

BFI-Kolloquium, Düsseldorf, 29.04.2026

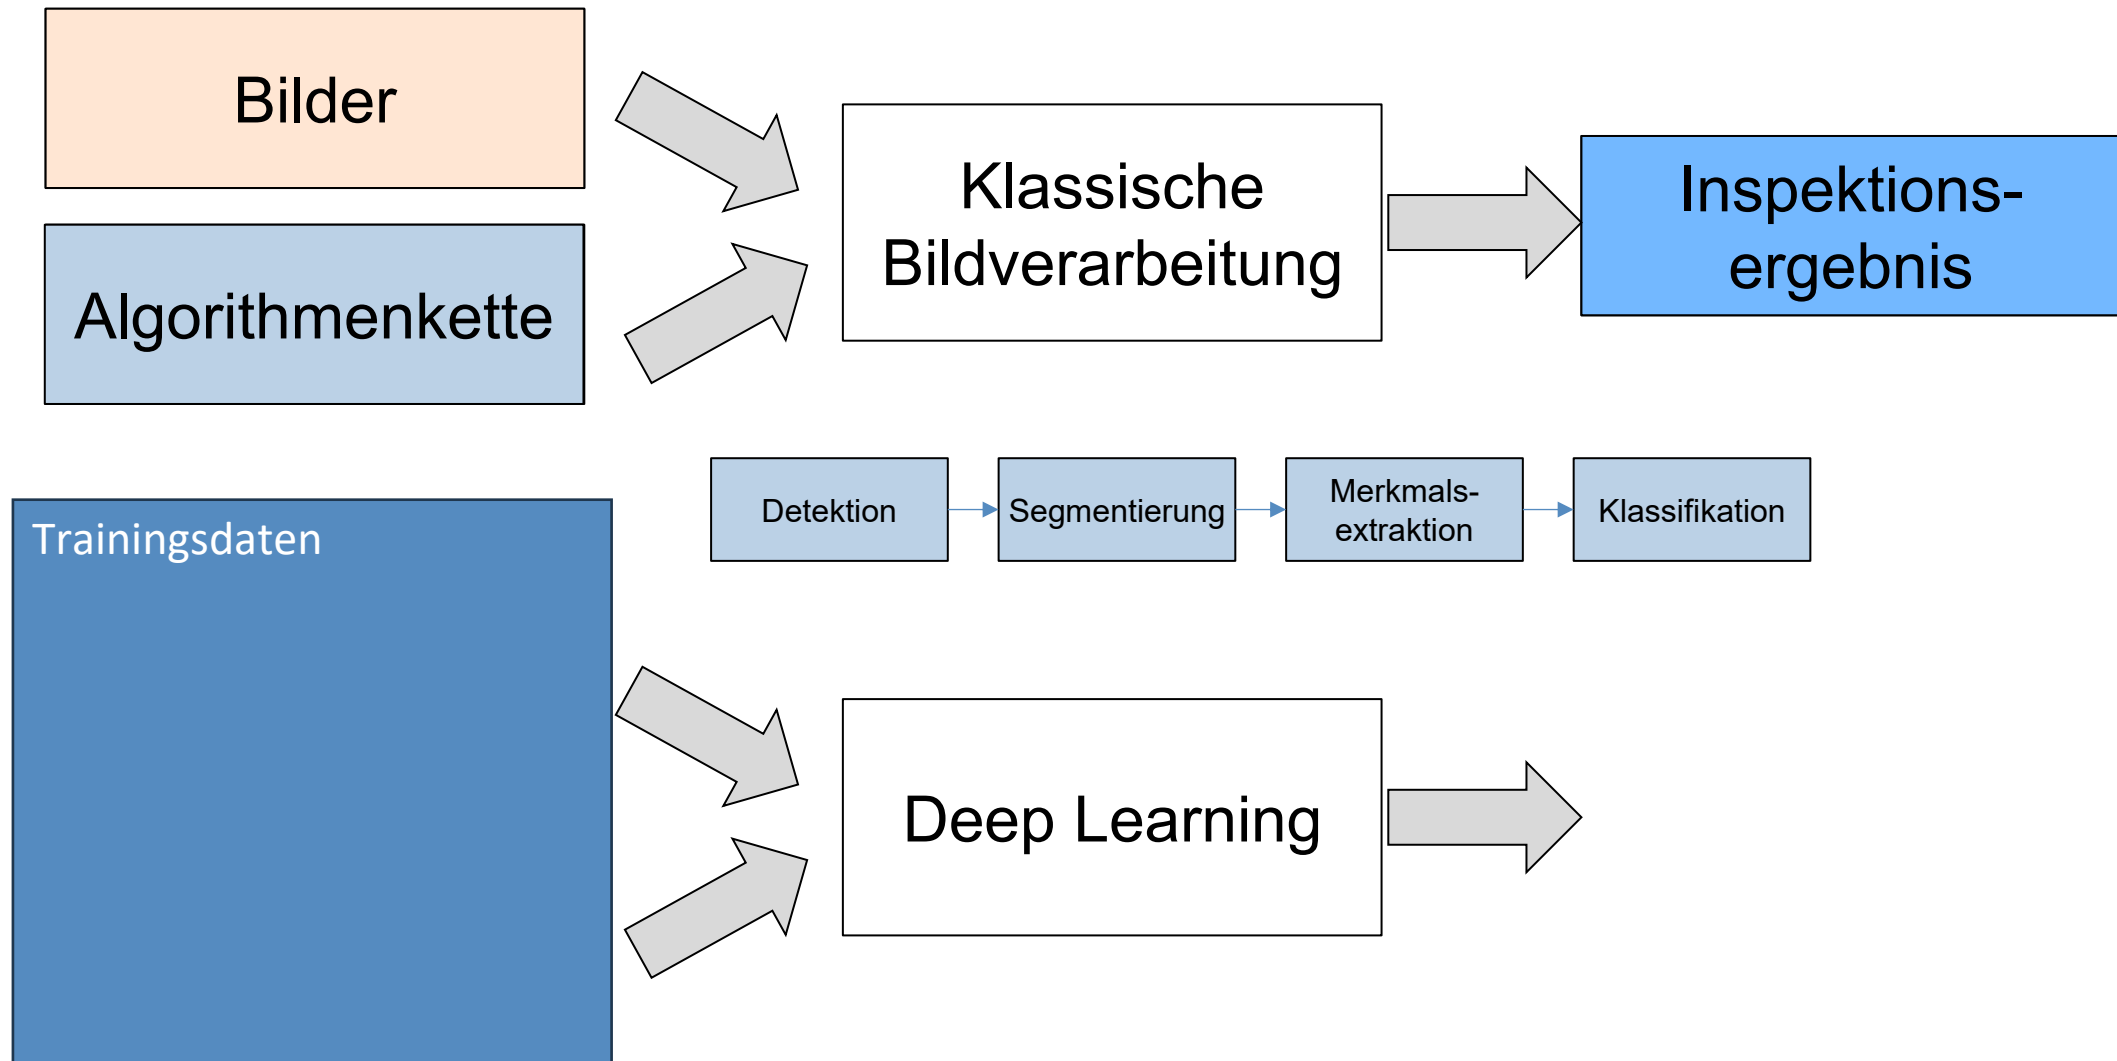
Themenfeld: Digitalisierung und Prozessmesstechniken



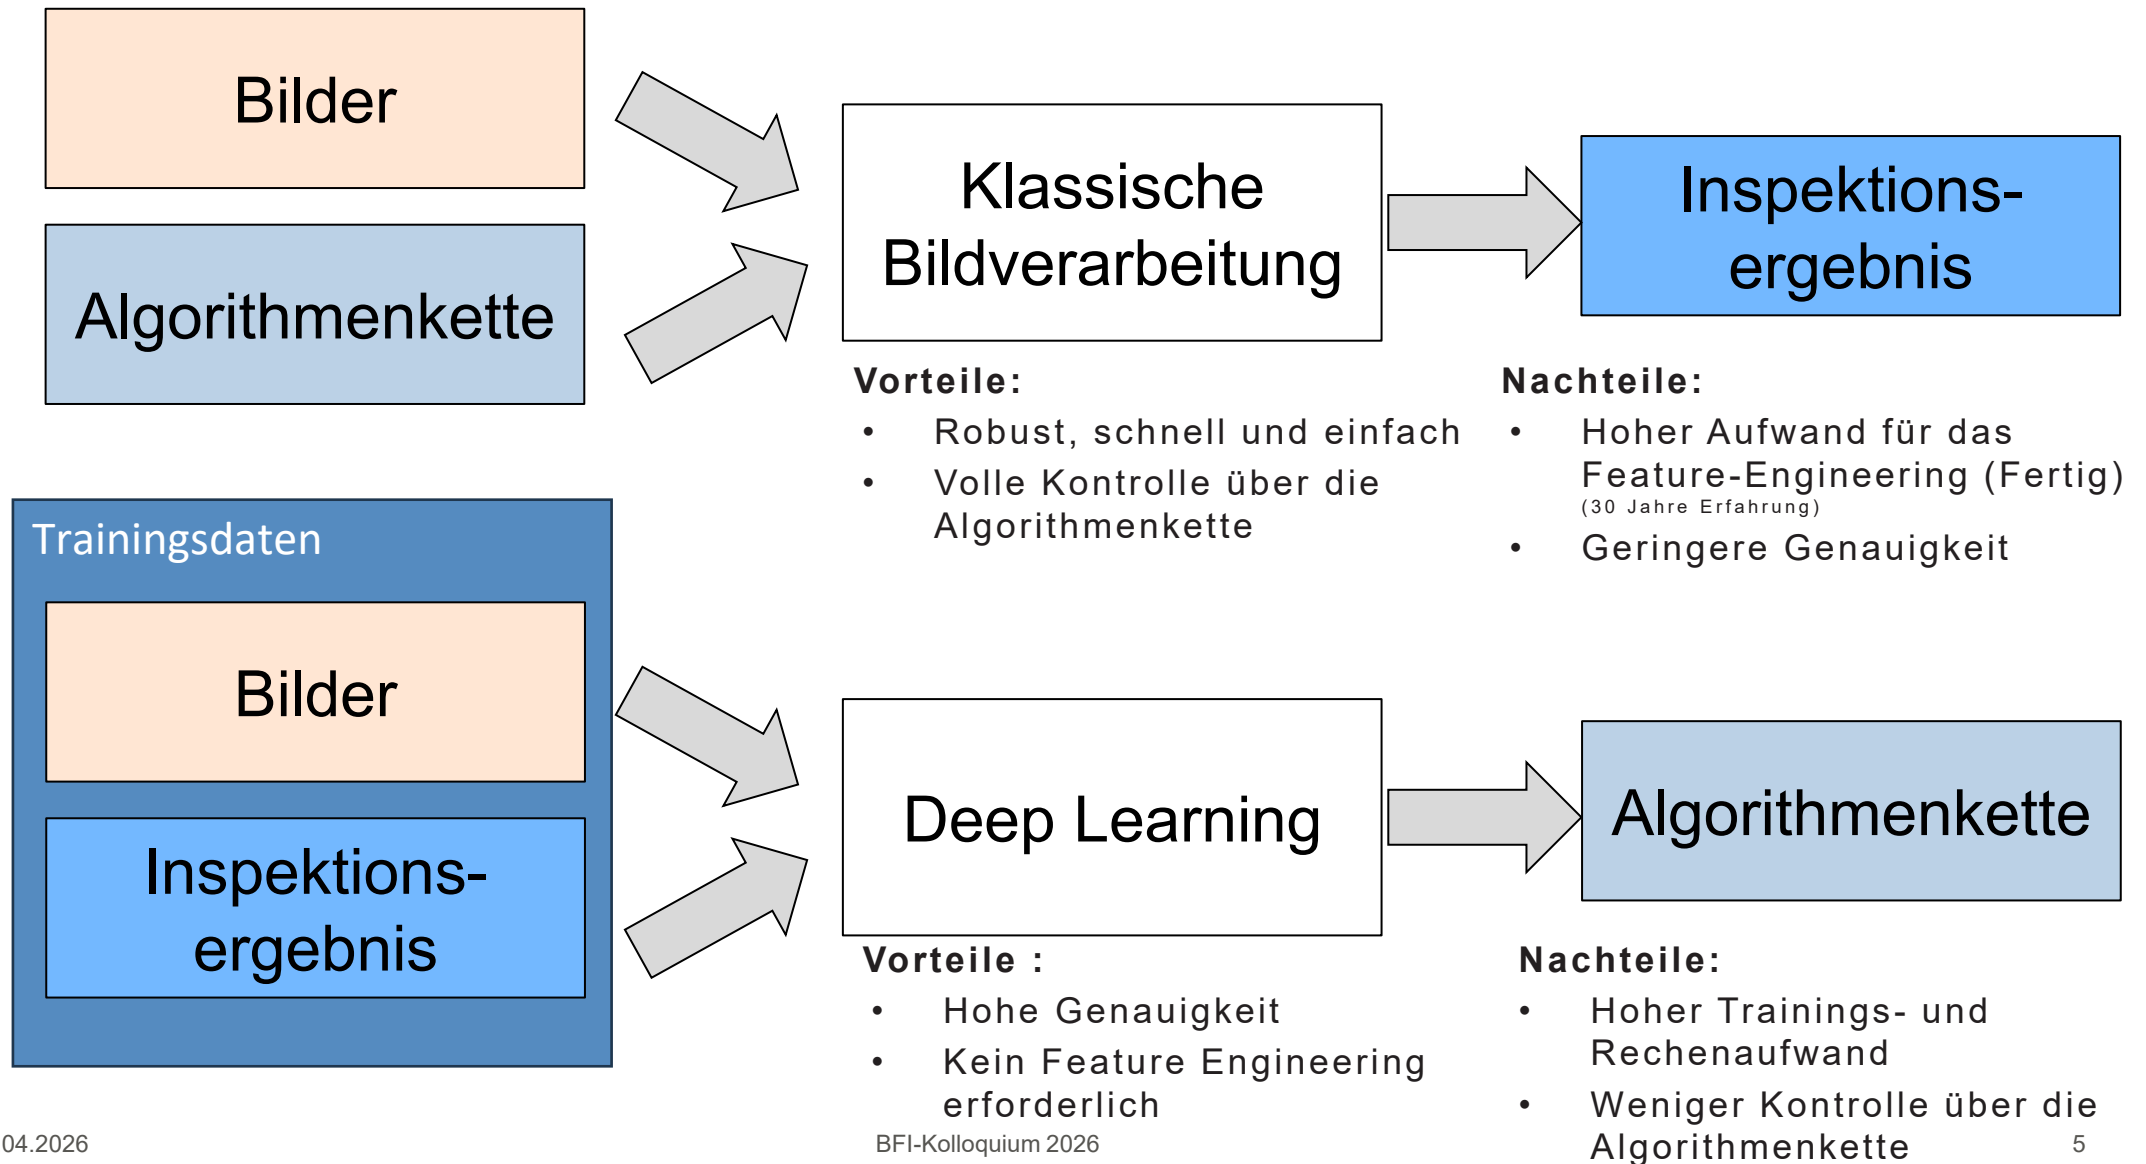
- › 1997: Erstes vollständig software-basiertes Oberflächeninspektionssystem (OIS) für Bandstahl
 - › Klassifikation über Entscheidungsbäume
Quinlan, J.R. (1992). C4.5 Programs for Machine Learning, San Mateo, CA: Morgan Kaufmann
- › 2012: Erste Versuche mit Deep-Learning Modellen für die Oberflächeninspektion auf Stahl
Masci et al, 'Steel defect classification with max-pooling convolutional neural networks'
- › 2015: Deep Learning Modelle übertrafen erstmals die menschliche Genauigkeit bei der Klassifikation auf ImageNet. Kaiming He et al., 'Deep Residual Learning for Image Recognition'
- › 2020: Vision Transformer (ViT): weniger „lokale Filter“, mehr globale Aufmerksamkeit
Alexey Dosovitskiy et al., 'An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale'
- › **Erwartungshaltung damals wie heute: Null-Fehler-Toleranz bei maximaler Geschwindigkeit**



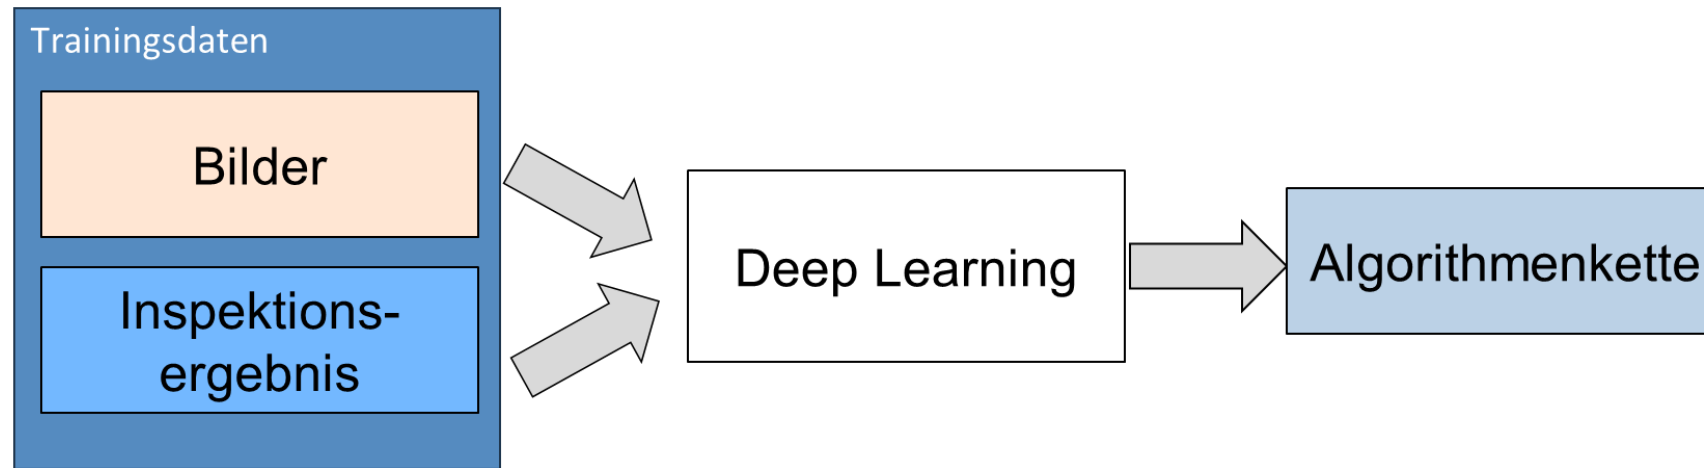
Klassische Bildverarbeitung vs. Deep Learning



Klassische Bildverarbeitung vs. Deep Learning



Datenqualität: „Garbage in, Garbage out“ – Warum gute Bilder entscheidend sind.



- › **Prozesswissen ist zwingend erforderlich, um gute Ergebnisse zu erzielen**
- › **Vollständigkeit der Trainingsdaten ist kritischer Faktor**
 - › Daten außerhalb des abgedeckten Trainingsbereichs
 - › Seltene Fehlerereignisse (Das OIS-Problem ist extrem unausgewogen)
- › **Standards für die Leistungsbewertung von KI-Modelles sind in Entwicklung**
 - › VDI/VDE/VDMA 2632 Blatt 4.2 definiert ein Standardvorgehen für die Berechnung der Precision
 - › Die Berechnung des Recalls benötigt hohen Aufwand zur Bestimmung der False-Negatives

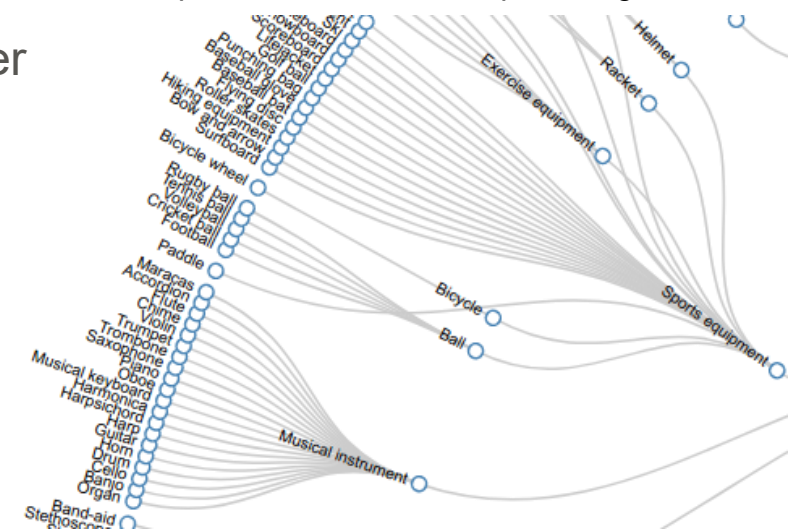
Offene Datenbanken als Motor für KI-Anwendung

Ein **Hauptgrund** für den Erfolg von Deep-Learning-Anwendungen in den letzten Jahren war die Verfügbarkeit riesiger **öffentlicher Bilddatenbanken** mit Millionen von annotierten Bildern, z. B.:

- › ImageNET ~ 1.3m Bilder
- › MS Common Objects in Context (COCO) ~ 330k Bilder
- › Open Images Dataset by Google ~ 9m Bilder

	Train	Validation	Test	# Classes	# Trainable Classes
Images	8,992,648	41,620	125,436	-	-
Machine-Generated Labels	164,809,380	681,049	2,060,717	15,382	9,068
Human-Verified Labels	58,783,034 pos: 21,144,175 neg: 37,638,859	618,184 pos: 390,797 neg: 227,387	2,003,748 pos: 1,319,751 neg: 683,997	20,638	9,668

Beispielklassen aus dem Open Images Dataset



- › Bereitstellung von **realistischem Bildmaterial** mit **realen Problemstellungen** an Dritte (z. B. Bildverarbeitungsunternehmen, Universitäten, Forschungsinstituten):
 - › **Hohe Ähnlichkeit** verschiedener Fehlerklassen
 - › **Hoher Anteil** von Pseudo-Fehlern (z.B. Oberflächenstruktur, Wasser, etc.)
 - › **Niedriger Anteil von schweren**, “kritischen” Fehlern
- › Diese Bilder können dazu verwendet werden, **neue Klassifizierungsansätze und -technologien** an realen Bildern zu testen und im besten Fall **erhebliche Verbesserungen bei der Klassifikation zu erzielen**, wodurch sich die Inspektionsergebnisse vieler bestehender OIS verbessern ließen.
- › Veröffentlichung unter einer offenen Lizenz, wie z.B. Creative Commons Attribution Share-Alike 4.0 License (**CC BY-SA 4.0**)

Die SurfConInspect offene OIS - Bilddatenbank

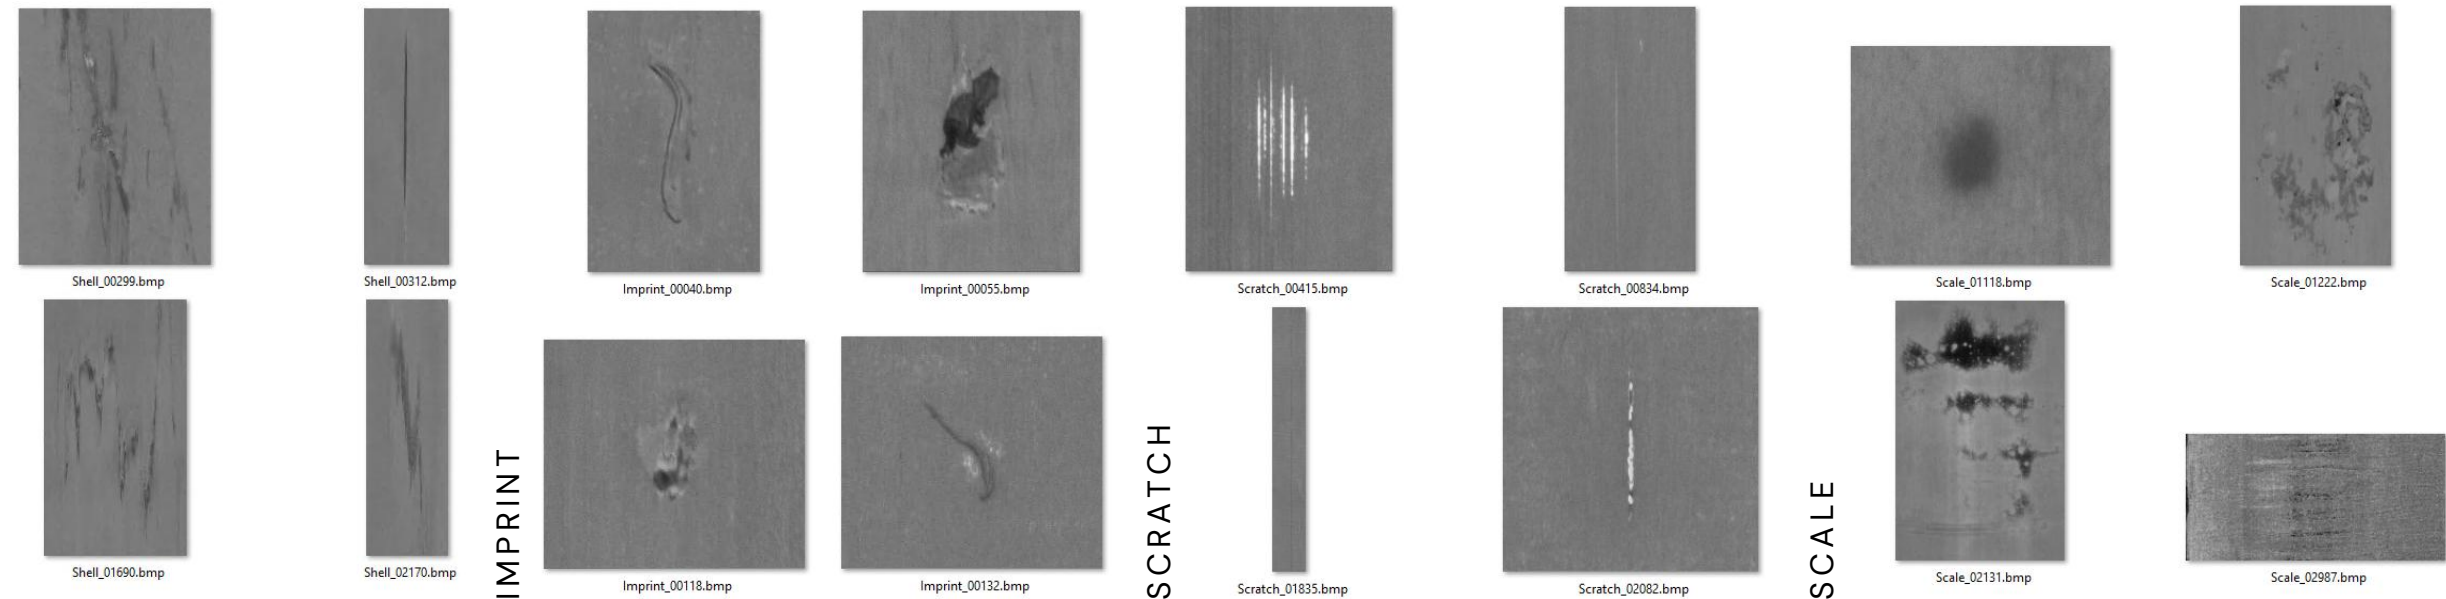
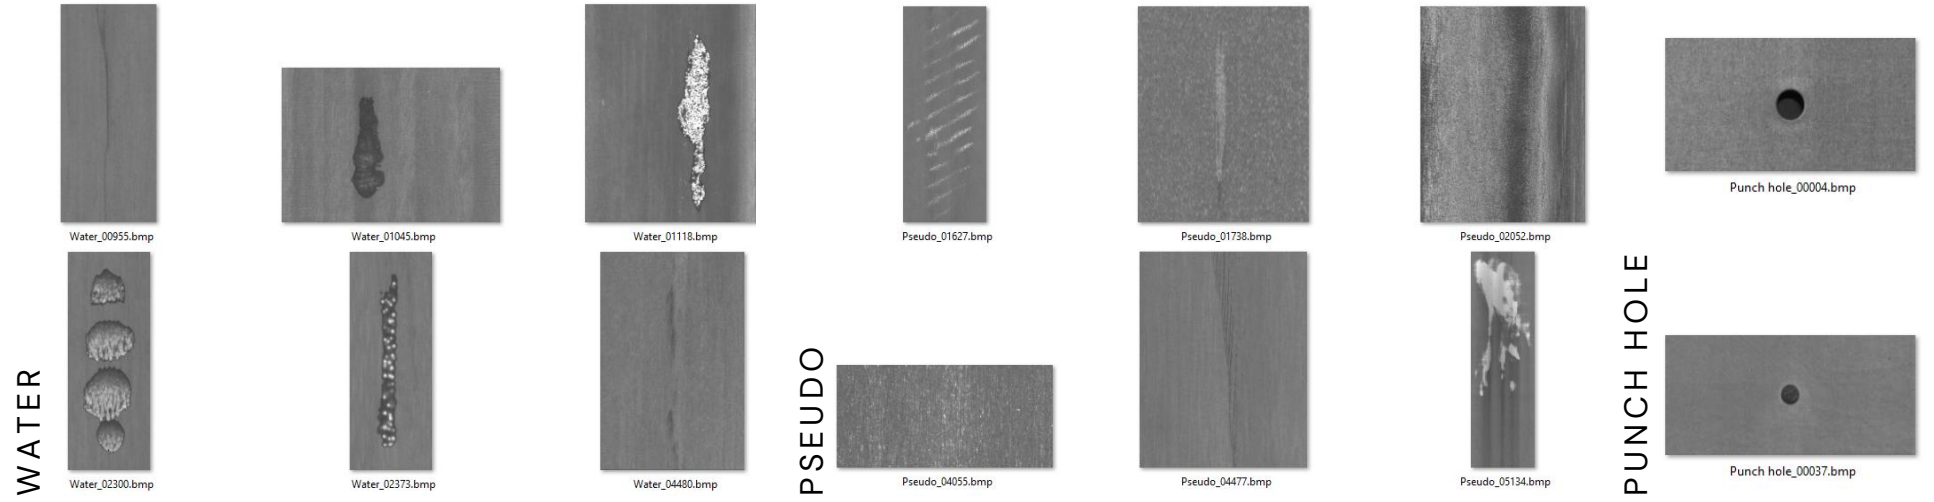
Eine neue Referenz für die Klassifikation von Oberflächenfehlern



Co-funded by the European Union



Klasse	#Bilder
Shell	3402
Imprint	193
Scratch	2347
Scale	8200
Water	6657
Pseudo	9082
Punch hole	124
Total	30.005



29.04.2026

BFI-Kolloquium 2026

<https://ckan.surfconinspect.cetic.be>

- › Paradigmenwechsel Klassische Bildverarbeitung vs. KI / Deep Learning
 - › **Klassische BV**: Robust, schnell und einfach. Volle Kontrolle über die Algorithmenkette.
Aber: Geringere Genauigkeit
 - › **Deep Learning**: Hohe Genauigkeit ohne Feature Engineering
Aber: Höherer Rechenaufwand und weniger vorhersagbar

- › Eine Revolution ?
 - › Tendenz geht zu **hybriden Ansätzen**, welche die Robustheit der klassischen BV mit der Präzision von Deep Learning Modellen verbinden.

 - › KI benötigt große Mengen an **qualitativ hochwertigen, annotierten Trainingsdaten**
 - › **Offene Bilddatenbanken**: Sparen zeitaufwendiges Annotieren
 - › **Synthetische Daten**: KI trainiert mit am Computer generierten Fehlern
 - › **Anomalie-Erkennung**: KI lernt nur „Gut-Teile“ und schlägt bei allem anderen Alarm

Kontakt: Dr.-Ing. Jens Brandenburger

VDEh-Betriebsforschungsinstitut GmbH

Sohnstraße 69 · 40237 Düsseldorf

Telefon +49 98492-229 · Fax +49 211 98492-202

E-Mail jens.brandenburger@bfi.de · www.bfi.de

E-Mail jens.brandenburger@bfi.de · www.bfi.de

Telefon +49 98492-229 · Fax +49 211 98492-202

Sohnstraße 69 · 40237 Düsseldorf

VDEh-Betriebsforschungsinstitut GmbH

Kontakt: Dr.-Ing. Jens Brandenburger

Automatisierung der Produktionsplanung im Walzwerk

Christoph Nölle, Jens Brandenburger, Ahmad Rajabi, Andreas Wolff

BFI-Kolloquium, Düsseldorf, 29.04.2026

Themenfeld: Digitalisierung und Prozessmesstechniken



Projekte zum Thema Produktionsplanung

- › **DynReAct**, RFCS 2019 – 2022
Refinement of production scheduling through dynamic product routing, considering real-time plant monitoring and optimal reaction strategies
- › **DynReActPDP**, RFCS 2023 – 2026
Roll-out refinement of production scheduling through dynamic product routing, considering real-time plant monitoring and optimal reaction strategies.
<https://dynreact.eu>
- › **DeepScheduling**, RFCS 2025 – 2028
Explainable AI and Human-Centric Learning Solution Framework for Industrial Scheduling Optimization.
<https://deepscheduling.eu>

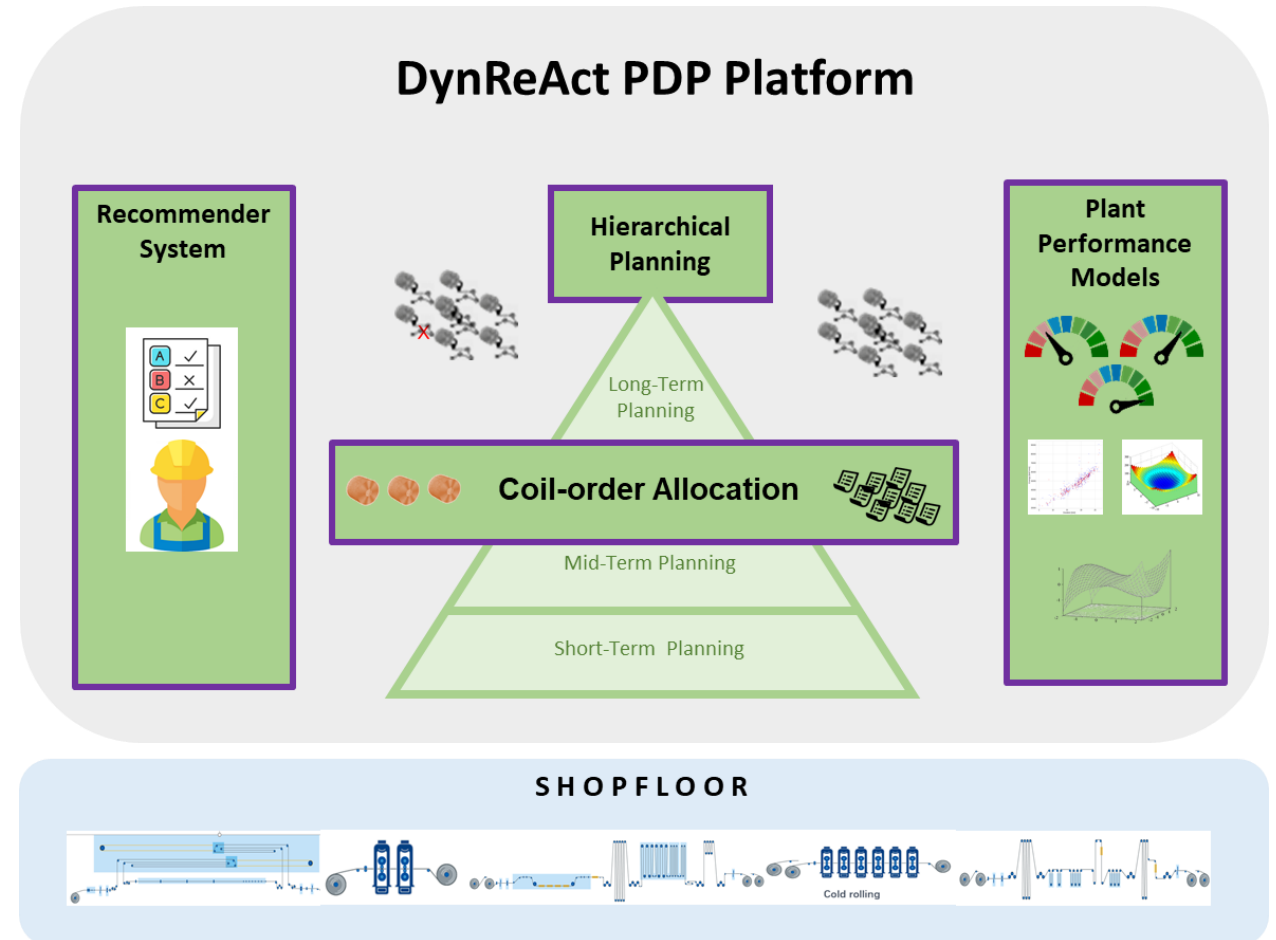


Forschungsthema: Dynamische Produktionsplanung im Kaltwalzwerk

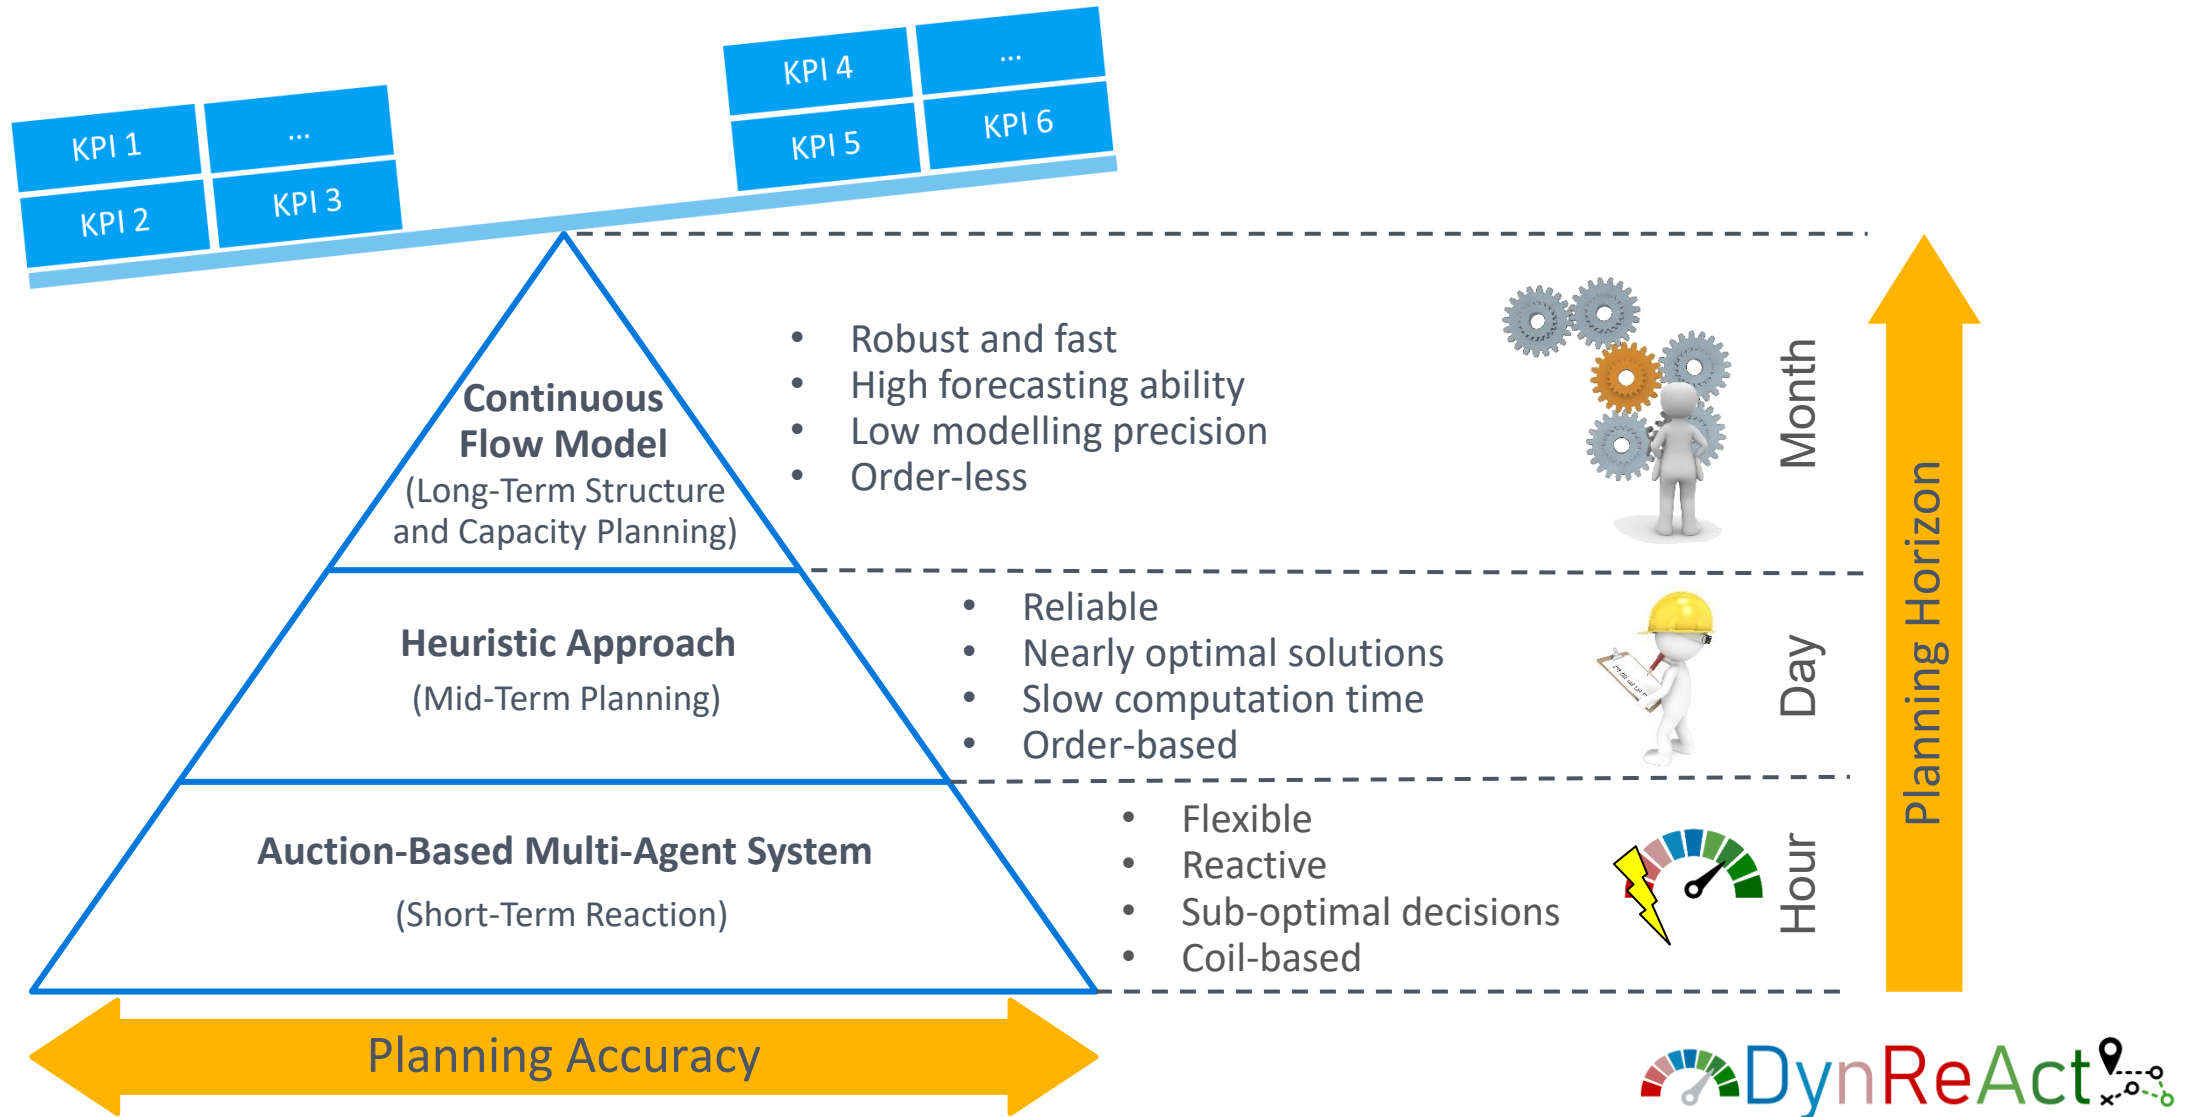
- › Komplexes Produktportfolio, Anlagen- und Auftragsanforderungen
=> hochdimensionales Optimierungsproblem
- › Dynamische Anlagenzustände, mit ungeplanten Stillständen oder vorübergehenden Produktbeschränkungen
- › Disponenten als Wissensträger
- › Vorhandene Software-Anwendungslandschaft

Ergebnisse:

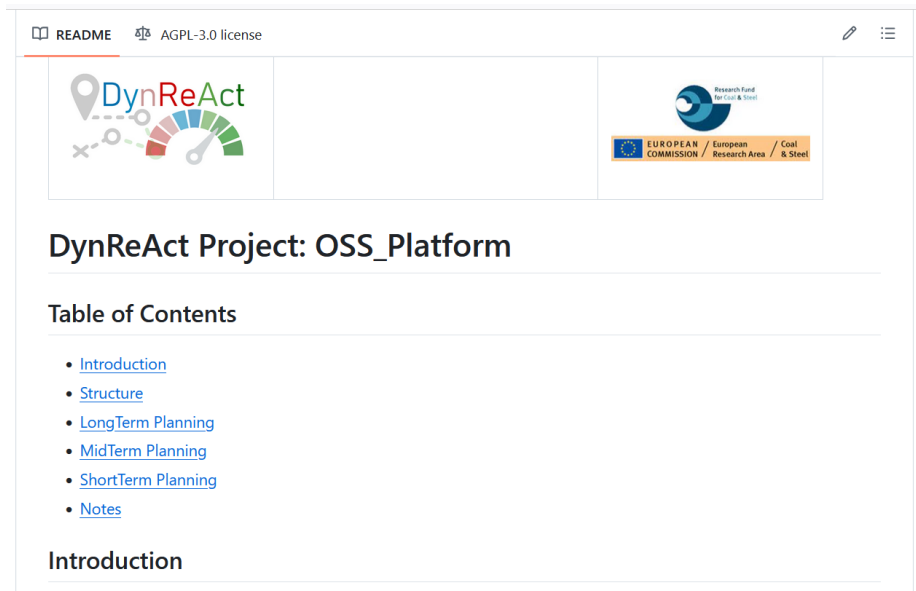
- › Konzept der Planungshierarchie
- › Industrieller Demonstrator
 - › Softwarekomponenten für die verschiedenen Hierarchiestufen und Performance-Modelle
 - › Fokus auf Veredelungsanlagen



DynReAct: Planungshierarchie



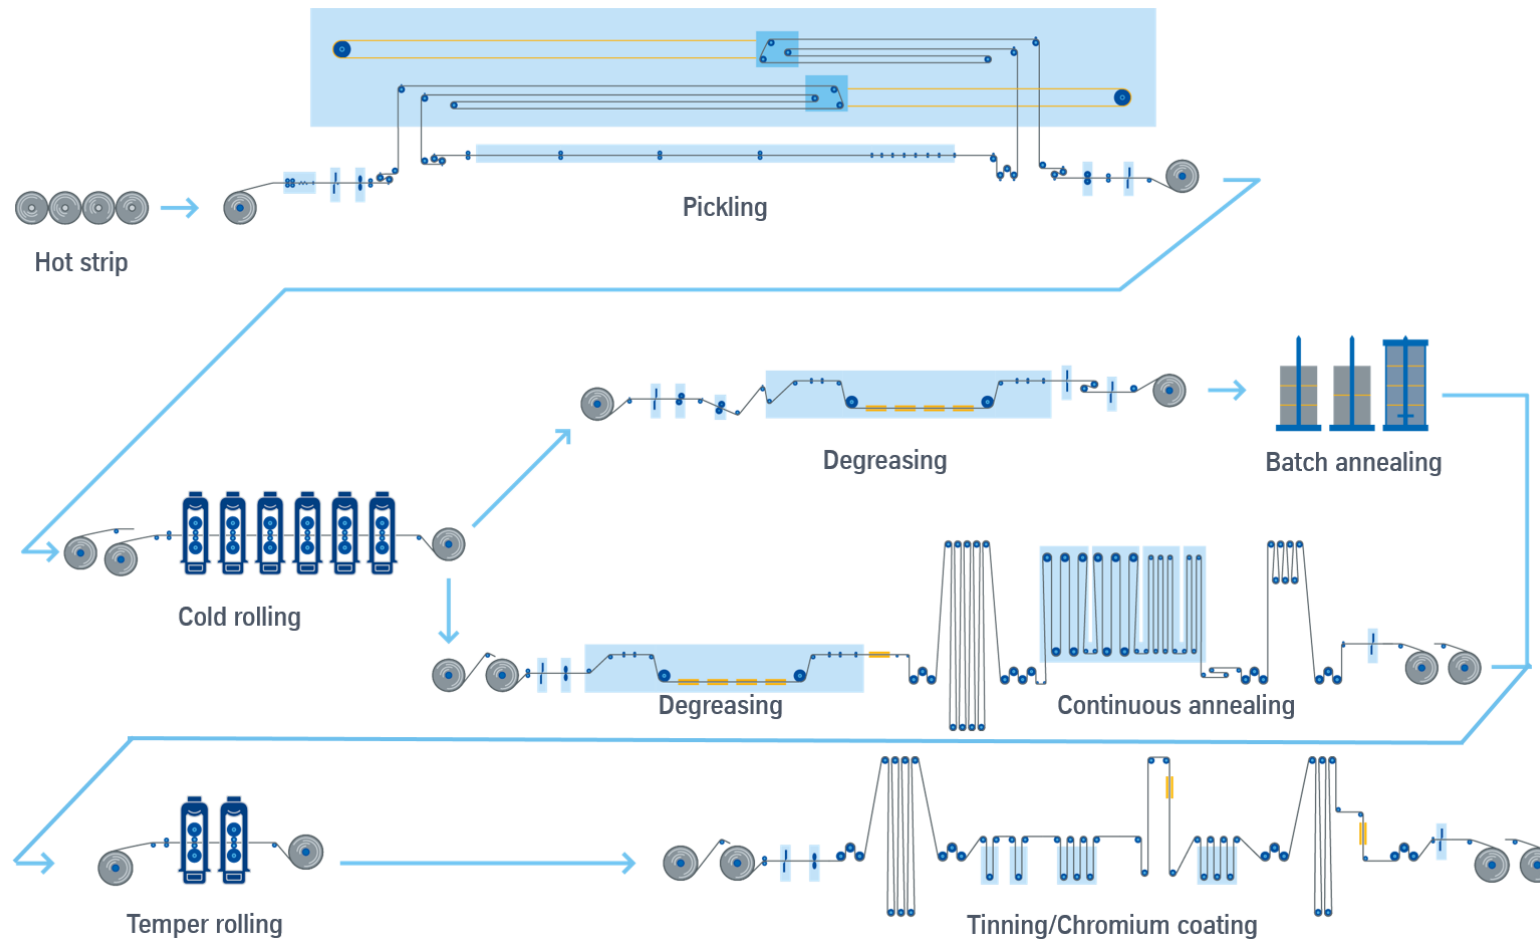
- › Industrielles Ausrollen der DynReAct-Software
 - › Ausweitung auf weitere Prozessstufen (Kaltwalzen, Glühen, Nachwalzen)
 - › Produktive Inbetriebnahme
- › Open-Source Planungsframework
 - › Veröffentlichung des Quellcodes auf https://github.com/DynReAct/OSS_Platform
 - › Übertragbarkeit auf weitere Anwendungsfälle mittels Modularisierung der Software-Komponenten
 - › Feinspezifikation der Interaktion zwischen den Planungsstufen



The screenshot shows the GitHub README for the 'DynReAct Project: OSS_Platform'. At the top, there are icons for 'README' and 'AGPL-3.0 license'. Below this is a header section with the DynReAct logo on the left and logos for 'Research Fund for Coal & Steel' and 'EUROPEAN COMMISSION / European Research Area / Coal & Steel' on the right. The main heading is 'DynReAct Project: OSS_Platform'. Below the heading is a 'Table of Contents' section with a list of links: 'Introduction', 'Structure', 'LongTerm Planning', 'MidTerm Planning', 'ShortTerm Planning', and 'Notes'. The 'Introduction' section is currently selected and expanded.

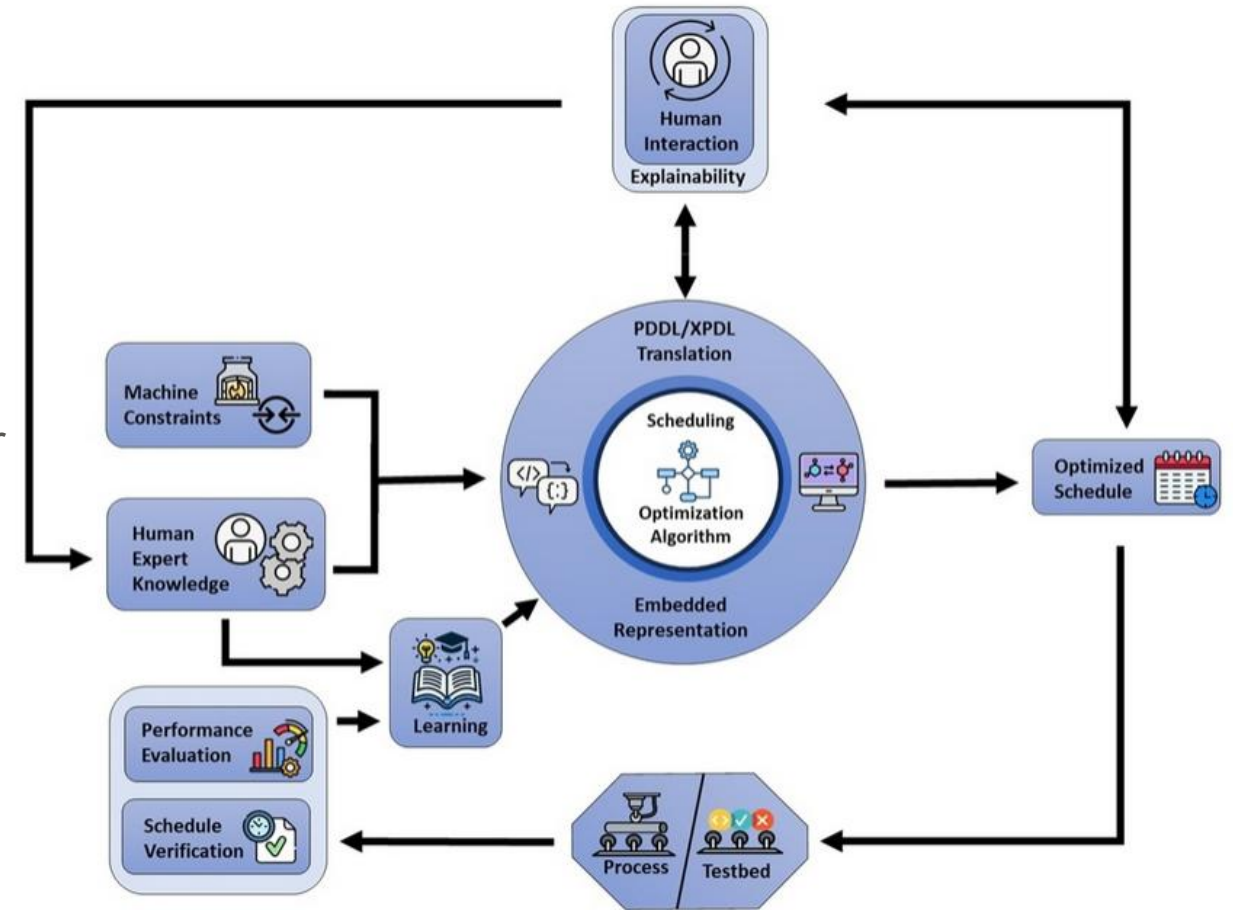


DynReActPDP: Industrieller Demonstrator



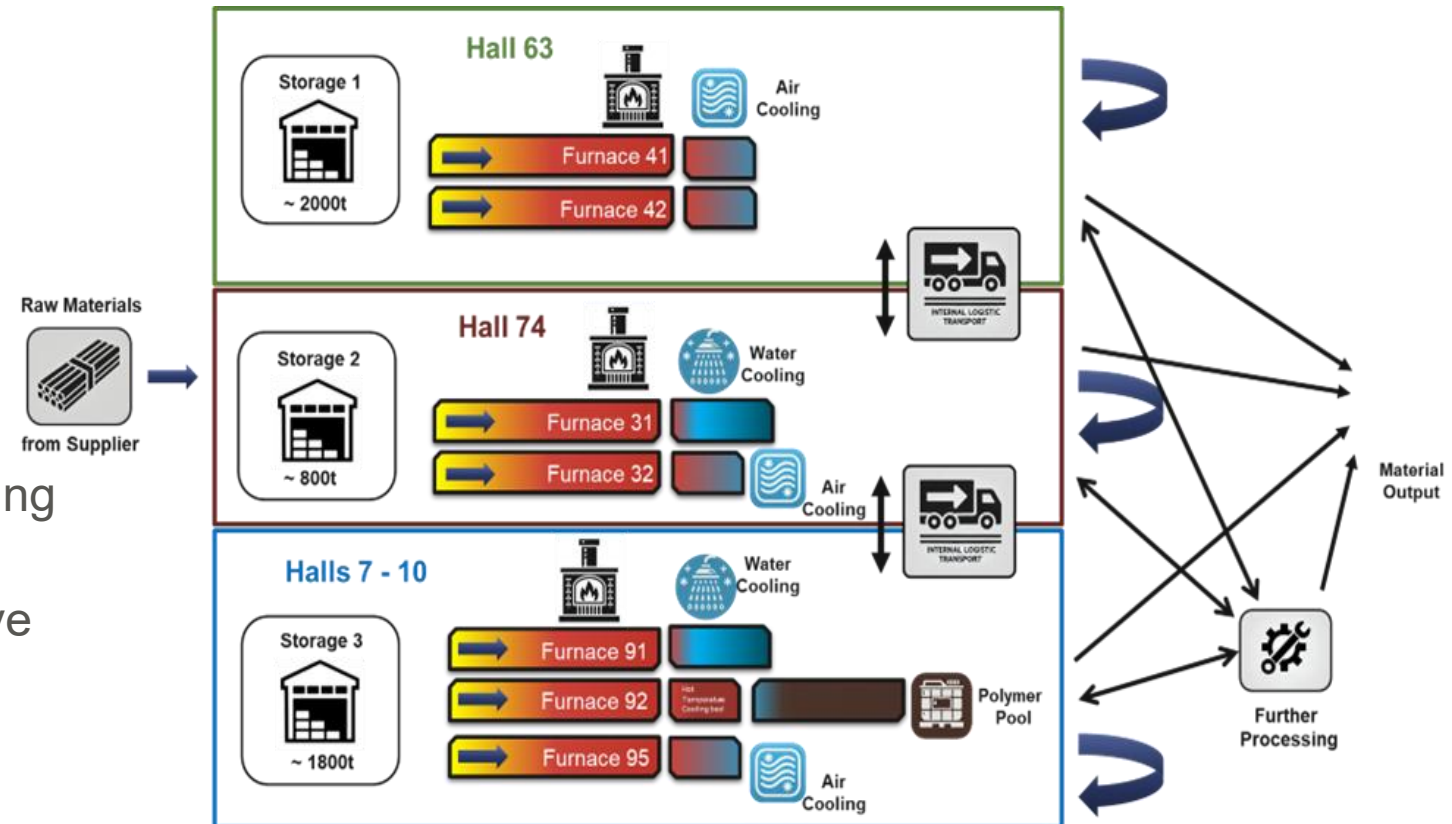
DeepScheduling Projekt

- › Forschungsthema:
 - › Adaptives Scheduling-Framework
 - › Optimierungsassistent
 - › Einsatz erklärbarer KI
- › Methodik: Anwendung von KI-Methoden in der Produktionsplanung => Benchmarking unterschiedlicher Ansätze:
 - › Großes Sprachmodell (LLM)
 - › Agentenbasiert
 - › Decision Diagram Based Optimizer (DDO)



DeepScheduling: Industrieller Demonstrator

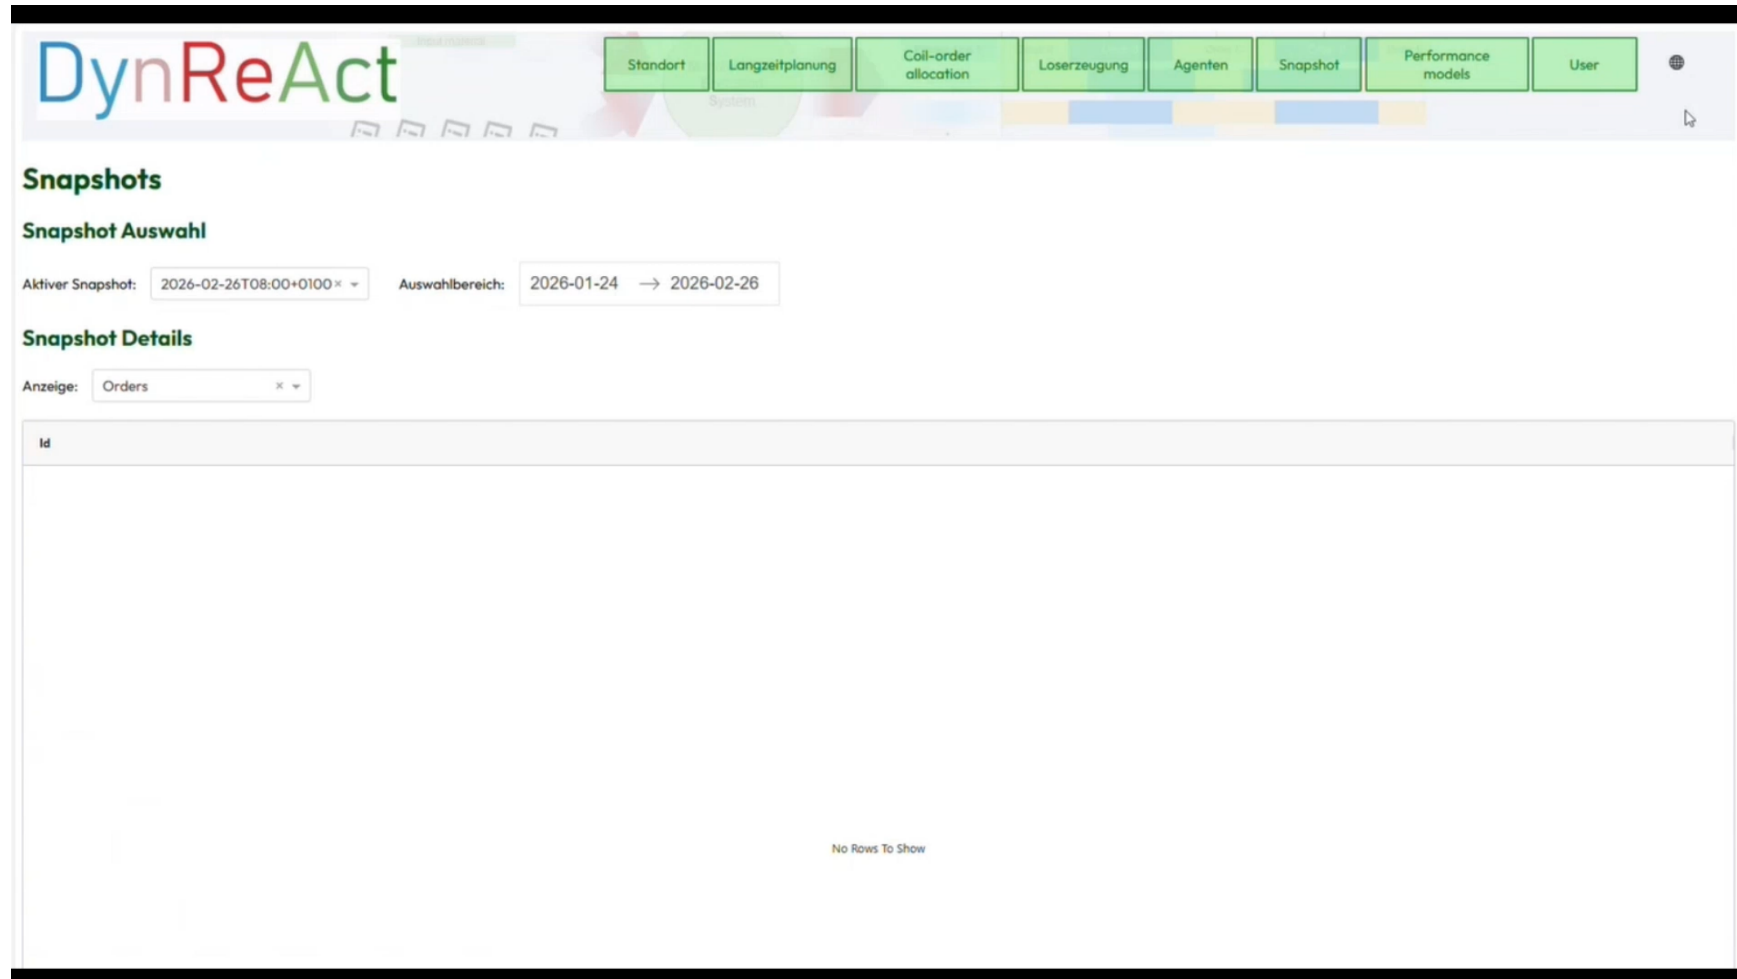
- › Sehr hohe Anforderungen an die Wärmebehandlung (enge Toleranzbereiche, z. B. < 3 K)
- › Komplexe Prozesskette mit vielen Randbedingungen (Produktabmessungen, maximale Temperatur, Gewicht)
- › Derzeit ausschließlich manuelle Planung durch Experten
- › Materialwechsel erfordern unproduktive Zeiten zur Temperaturanpassung



Ausblick: Forschungsthemen im Umfeld Produktionsplanung

- › Nutzen moderner KI-Methoden (LLMs, Agenten, ...) für Scheduling-Probleme (@DeepScheduling)
- › Multimodale Optimierung: gekoppelte Energie-, Prozess- und Kostenoptimierung
- › Übertragbarkeit des DynReAct-Konzepts auf weitere Anwendungsfälle





The screenshot displays the DynReAct web application interface. At the top, there is a navigation bar with the DynReAct logo and several menu items: Standort, Langzeitplanung, Coil-order allocation, Loserzeugung, Agenten, Snapshot, Performance models, and User. Below the navigation bar, the 'Snapshots' section is active. It includes a 'Snapshot Auswahl' section with a dropdown menu for 'Aktiver Snapshot' (set to 2026-02-26T08:00+0100) and a date range selector for 'Auswahlbereich' (2026-01-24 to 2026-02-26). Underneath, the 'Snapshot Details' section has an 'Anzeige' dropdown set to 'Orders'. A table with a single header row 'Id' is shown, but it is currently empty, with the message 'No Rows To Show' centered below it.

Kontakt: Dr. Christoph Nölle

VDEh-Betriebsforschungsinstitut GmbH

Sohnstraße 69 · 40237 Düsseldorf

Telefon +49 98492-653

E-Mail christoph.noelle@bfi.de · www.bfi.de

E-Mail christoph.noelle@bfi.de · www.bfi.de

Telefon +49 98492-653

Sohnstraße 69 · 40237 Düsseldorf

VDEh-Betriebsforschungsinstitut GmbH

Kontakt: Dr. Christoph Nölle

Nachhaltige Prozessführung des EAF-Prozesses basierend auf hybriden Modellen

Bernd Kleimt, Akhilesh Chandgude, Vera Peiss


BFI-Kolloquium, Düsseldorf, 29.04.2026

Themenfeld: Digitalisierung und Prozessmesstechniken



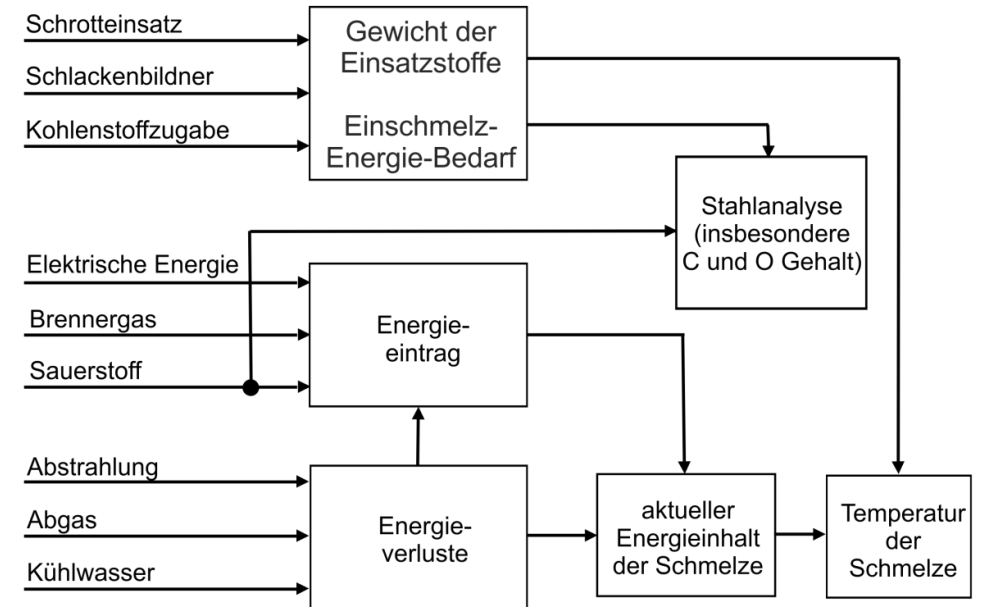
Ausgangssituation

- › Auf dem Weg zur Dekarbonisierung der Stahlherstellung bei gleichzeitiger Stärkung der Kreislaufwirtschaft ist der Elektrolichtbogenofen (EAF) von entscheidender Bedeutung.
 - › Der EAF-Prozess umfasst komplexe Wechselwirkungen zwischen Energieeinträgen und Einsatzstoffen
 - › Hohe gegenseitige Abhängigkeit und Nichtlinearität der metallurgischen Reaktionen erschweren die Optimierung des gesamten Prozesses.
 - › Schwankende Qualität der Einsatzstoffe (z.B. Stahlschrott) und Einsatz nachhaltiger Materialien (z.B. biogene Kohlenstoff-Träger) verstärken diese Herausforderung
- ↪ Dynamische, modellbasierte Prozessführung erforderlich, um den EAF-Prozess effizient und mit möglichst geringem CO₂-Fussabdruck zu betreiben



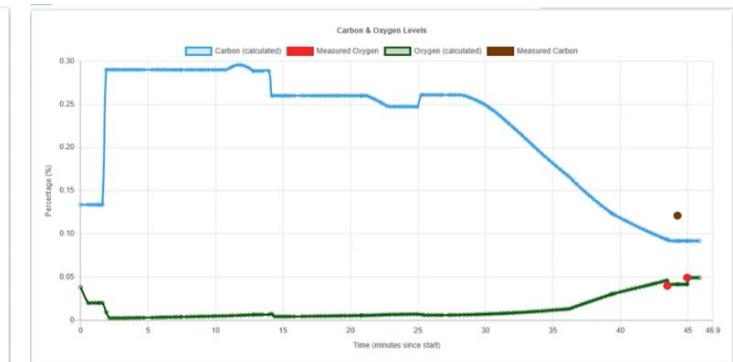
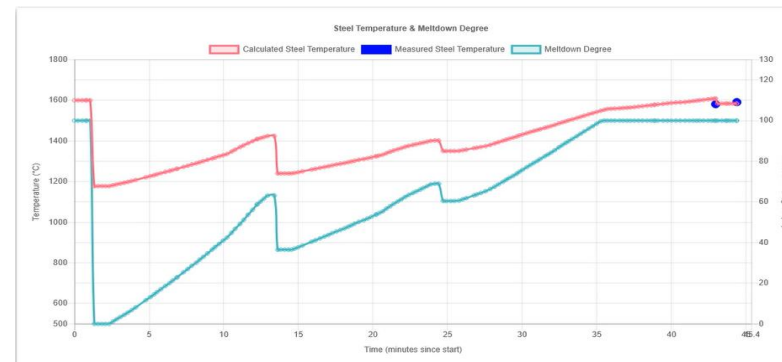
Dynamisches Prozessmodell für den EAF

- › Das BFI hat ein dynamisches EAF-Prozessmodell zur Online-Überwachung des Prozessverhaltens und Bereitstellung von Empfehlungen und Sollwerten für die Prozessführung entwickelt.
- › Das Modell berechnet prozessbegleitend den Verlauf der Schmelzentemperatur, der Gehalte von C, O und P, des Einschmelzgrads der Einsatzstoffe sowie Gewicht und Zusammensetzung von Stahl und Schlacke.
- › Eine Bedienerunterstützung erfolgt bzgl. des optimalen Chargierzeitpunkts der Schrottkörbe und der optimalen Dauer des Brennerbetriebs.
- › Sollwerte für elektrische Energie und Sauerstoffzufuhr werden berechnet, um die Zielwerte für Temperatur und C-Gehalt präzise zu erreichen.



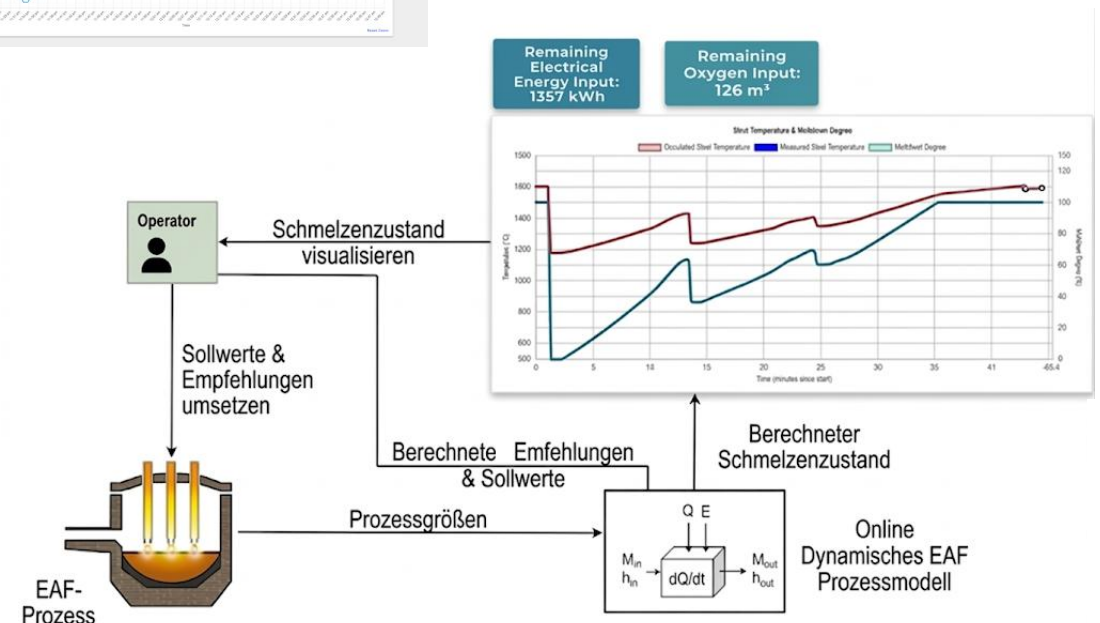
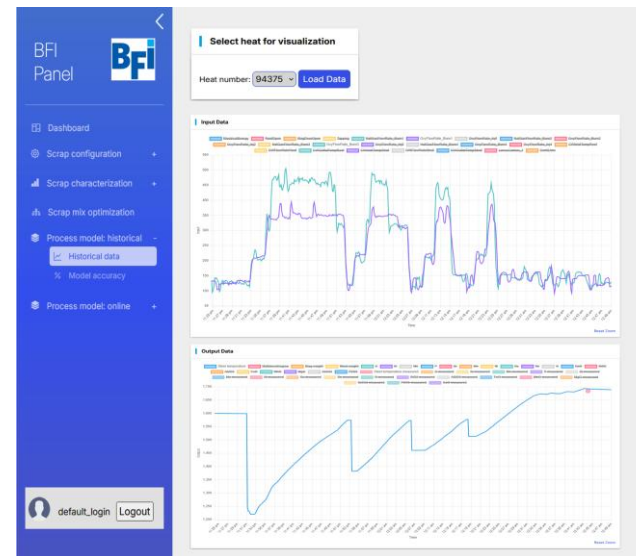
Remaining Electrical Energy Input: 1357 kWh

Remaining Oxygen Input: 126 m³



Softwaretechnische Realisierung des EAF-Prozessmodells

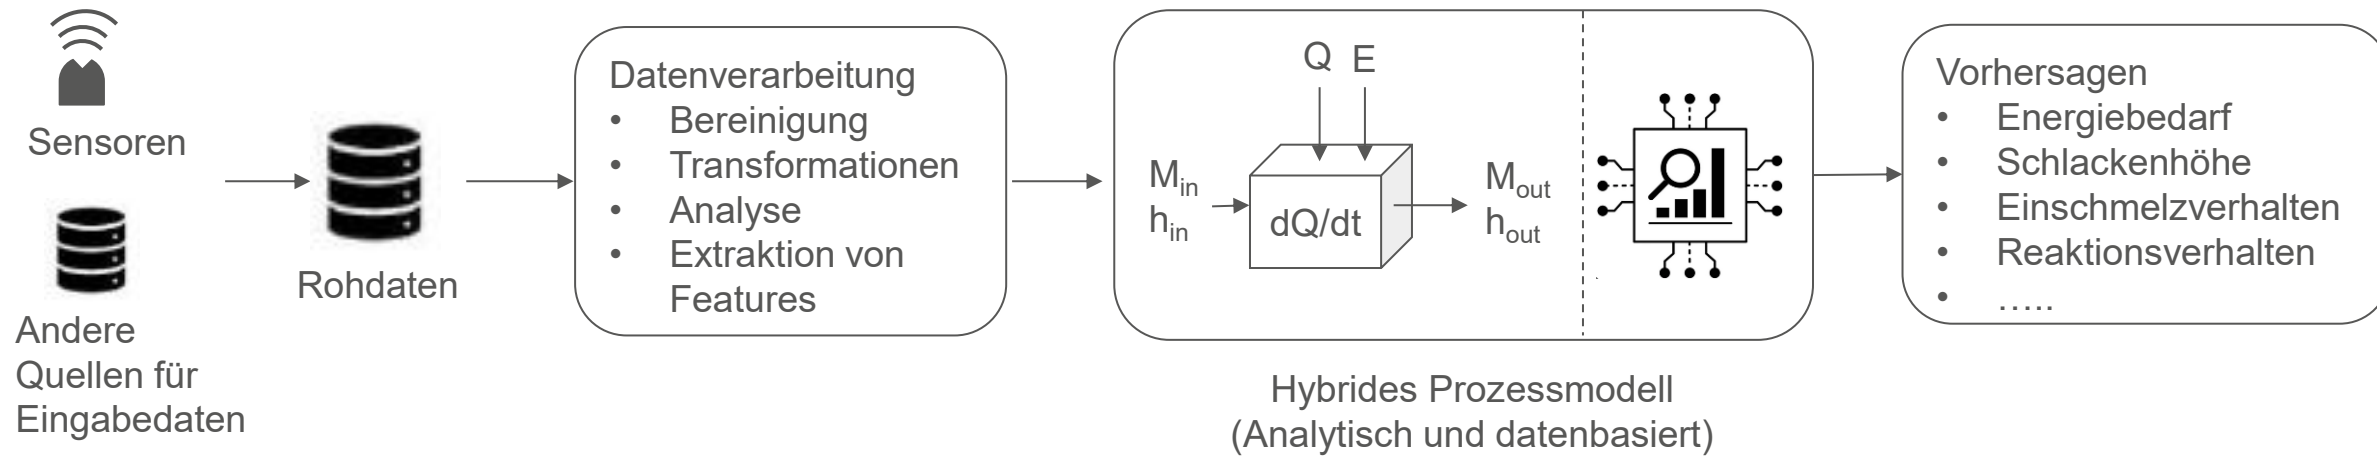
- › Zur off-line Validierung des EAF-Modells und Replikation von historischen Schmelzen wurde eine Web-basierte Oberfläche erstellt
- › Gleichzeitig sind Werkzeuge zur Charakterisierung der Einsatzstoffe und zur Berechnung des optimalen Einsatzstoff-Mixes integriert
- › Für die on-line Implementierung wird das in Python codierte EAF-Modell über eine definierte Schnittstelle mit den Eingangsdaten versorgt
- › Die Visualisierung der Ergebnisse erfolgt über die web-basierte Oberfläche oder anwenderspezifische Dashboards



- › Entwicklung von hybriden Teilmodellen basierend auf physikalisch konsistenten KI-Modellen für Teilprozesse, die sich on-line nicht mit rein physikalischen Modellen beschreiben lassen, z.B.:
 - › Performance des Schlackenschäumens
 - › Einschmelz- und Reaktionsverhalten von nachhaltigen Einsatzstoffen (DRI, HBI, Alternative Kohlenstoffträger)
- › Damit Bereitstellung eines verbesserten Einblicks in das Prozessverhalten in Echtzeit
- › Vorausschauende Unterstützung für die Bediener, um datenbasierte und fundierte Entscheidungen während des Betriebs zu ermöglichen
- › Stabile Echtzeit-Kontrolle von Temperatur und chemischer Zusammensetzung der Schmelze und der Schlackeneigenschaften, für
 - › gleichmäßige und reproduzierbare Rohstahlqualität
 - › reduzierten Energieverbrauch und geringere CO₂-Emissionen
 - › erhöhte Prozesseffizienz



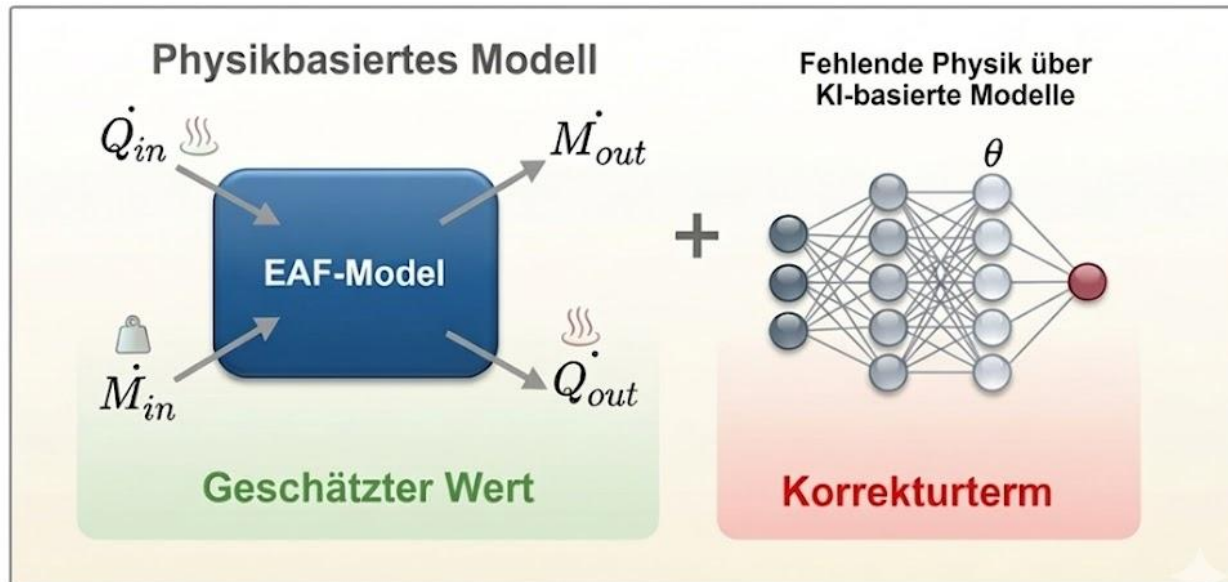

Methodik und Vorgehensweise



- › Durchführung von Versuchen mit verschiedenen Einsatzstoffen (DRI/HBI, Schrott, Bio-Kohlenstoff) zur Analyse von Schmelzverhalten, Reaktionen und Schlackenschäumen
- › Dabei Erfassung relevanter Sensor- und Prozesssignale, ggf. Installation neuer Sensoren
- › Entwicklung, Kalibrierung und Validierung hybrider, physikbasierter KI-Modelle zur Verknüpfung von Einsatzstoffen, Prozessparametern und Schlackenverhalten

Hybrides Prozessmodell – Beispiel Vorhersage der Schaumshlackenhöhe

Schaumshlacken-Vorhersage ($h(t)$)



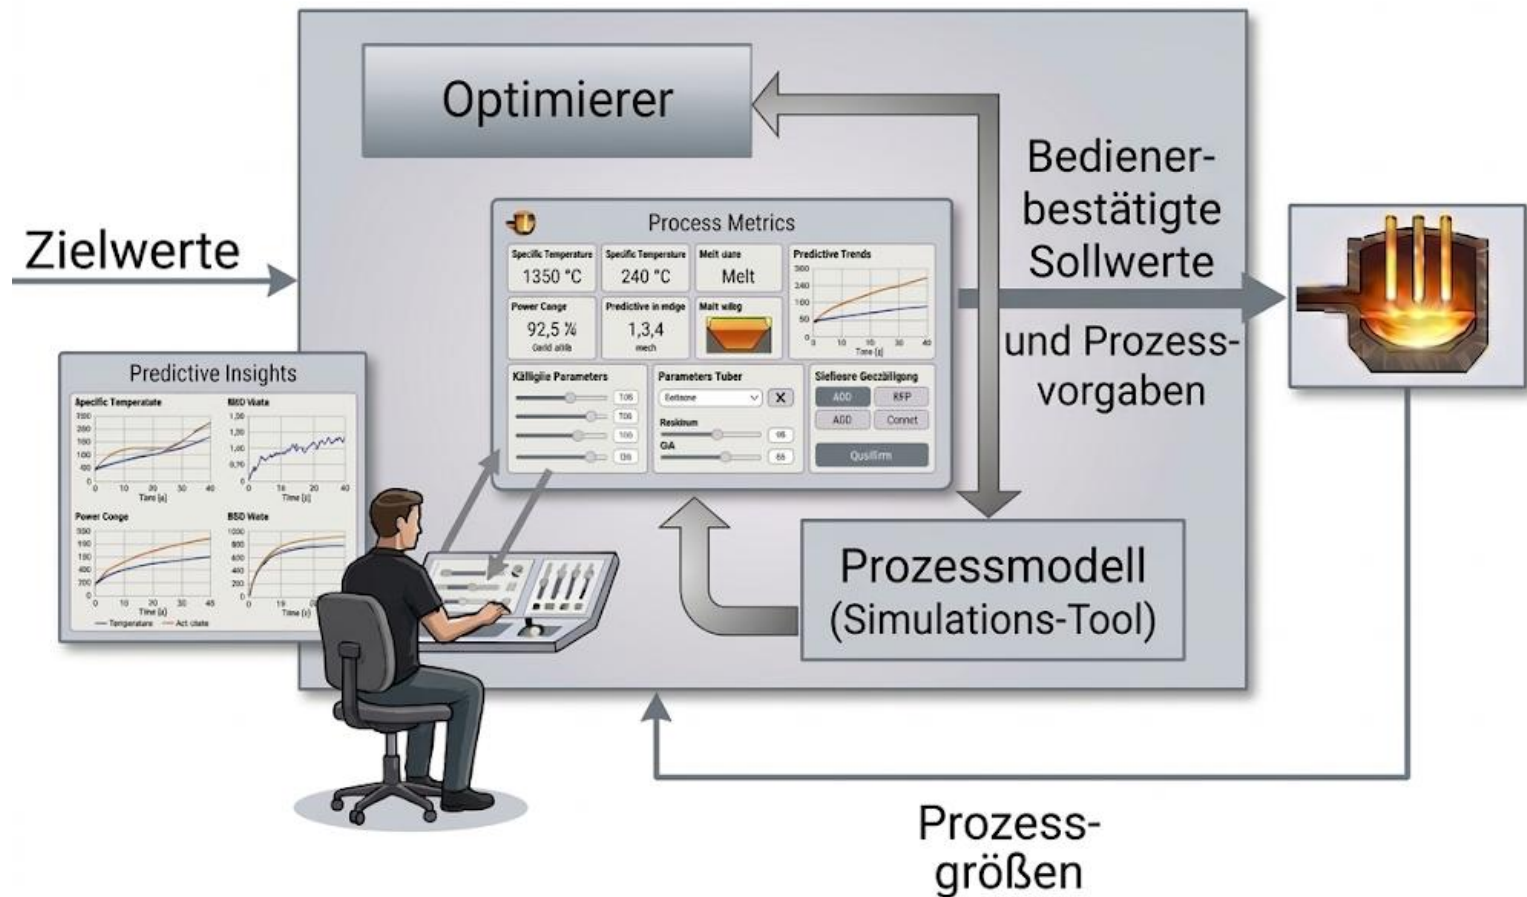
Hybrides Modell

- Das physikbasierte Modell liefert eine grobe Schätzung für die Schlackenhöhe
- Zusätzliche EAF-Sensorsignale werden in einem KI-basierten Modell genutzt, um einen Korrekturterm zu bestimmen
- Das resultierende hybride Modell ist interpretierbar (kein Black-Box-Modell). Die physikalische Modellierung ermöglicht präzise Vorhersagen für nicht messbare Prozessgrößen.
- Dynamisches Modell mit Echtzeit-Vorhersage der Schlackenhöhe für jeden Zeitschritt.

Entscheidungsunterstützung basierend auf modellprädiktiver Regelung

- › Formulierung des Optimierungsproblems mit Zielen (z. B. Minimierung Energieverbrauch und CO₂-Emissionen, Sicherstellung der Stahlqualität) und Einschränkungen (z. B. betriebliche Grenzen).
- › Integration von modellbasierten Vorhersagen in modellprädiktive Regelung zur echtzeitfähigen Entscheidungsfindung
- › Entwicklung von Dashboards zur Anzeige von Empfehlungen und Sollwerten zur Anpassung von Energiezufuhr, Sauerstoffinjektion und anderen kritischen Parametern und des zu erwartenden Prozessverlaufs

Echtzeit-Prozessüberwachung und Entscheidungsunterstützung



Kontakt: Dr.-Ing. Bernd Kleimt

VDEh-Betriebsforschungsinstitut GmbH
Sohnstraße 69 · 40237 Düsseldorf
Telefon +49 98492-385
E-Mail Bernd.Kleimt@bfi.de · www.bfi.de

E-Mail Bernd.Kleimt@bfi.de · www.bfi.de
Telefon +49 98492-385
Sohnstraße 69 · 40237 Düsseldorf
VDEh-Betriebsforschungsinstitut GmbH
Kontakt: Dr.-Ing. Bernd Kleimt

Kontakt: M.Sc. Akhilesh Chandgude

VDEh-Betriebsforschungsinstitut GmbH
Sohnstraße 69 · 40237 Düsseldorf
Telefon +49 98492-898
E-Mail Akhilesh.Chandgude@bfi.de · www.bfi.de

E-Mail Akhilesh.Chandgude@bfi.de · www.bfi.de
Telefon +49 98492-898
Sohnstraße 69 · 40237 Düsseldorf
VDEh-Betriebsforschungsinstitut GmbH
Kontakt: M.Sc. Akhilesh Chandgude

Akustische Multifunktionsmessung zur Optimierung des EAF Betriebs

Martin Brodeck (B&D), Emanuel K. Thienpont (BFI)

BFI-Kolloquium, Düsseldorf, 29.04.2026

Themenfeld: Digitalisierung und Prozessmesstechniken


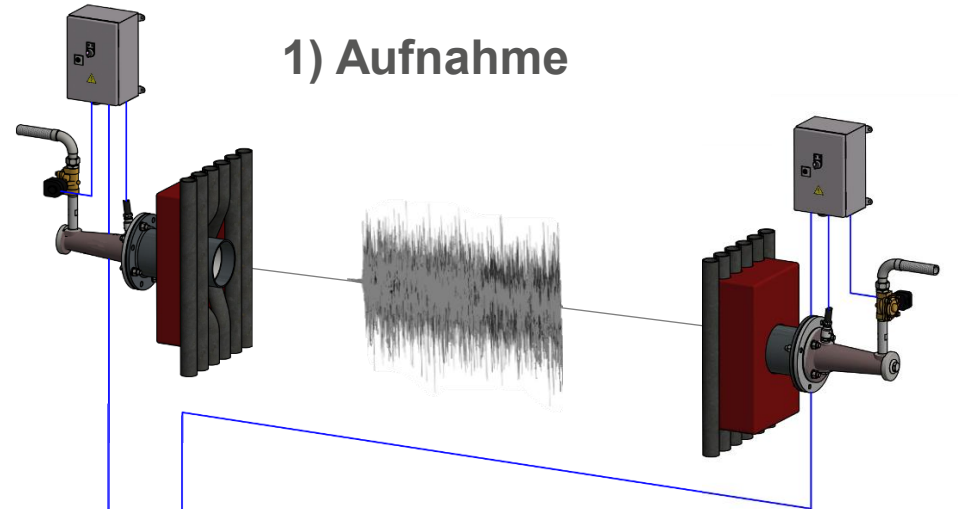
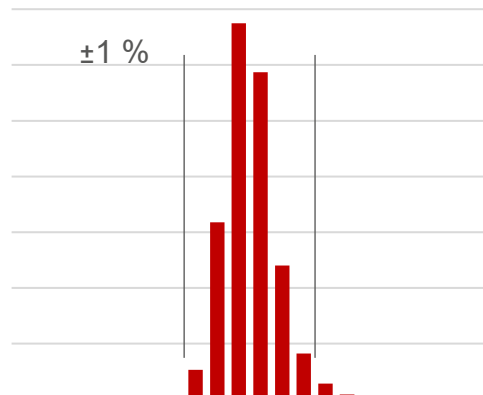


AGAM: Messprinzip

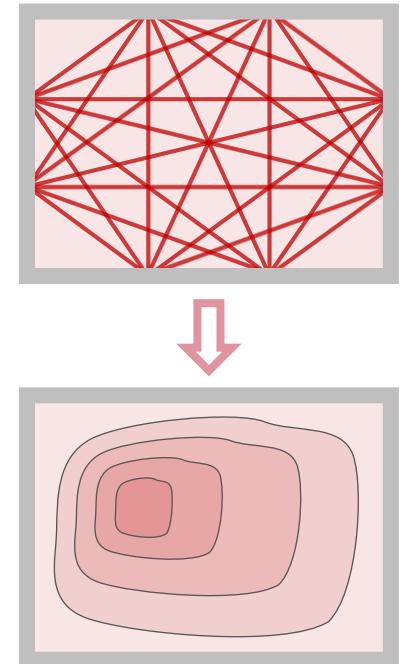
$$c = \sqrt{RT \frac{\kappa}{M}}$$

c Schallgeschwindigkeit
 R Gaskonstante
 T Temperatur
 κ Adiabatischer Index
 M Molare Masse

Änderungen in der Gaszusammensetzung






3) Tomographie



AGAM: Vorteile und Anwendungen

Vorteile der akustischen Temperaturmessung


- Unabhängig von Strahlung
- Schnelle Messung
- Geometrische Präzision & hohe Auflösung
- Kein Drift
(keine Kalibrierung)
- Hohe Lebenserwartung
(keine Wartung)



Installation der AGAM am EAF Abgaskanal bei Höganäs




Installationsposition der AGAM




EAF-Abgaskanal bei Höganäs

AGAM: Akustische Temperatur Messung am EAF-Abgaskanal

Wärme 250490, Feb. 2025



Wärme 260129, Jan. 2026




Vergleich der Temperaturwerte während der Referenz-Wärme

- › AGAM-Temperaturwerte (blaue Linie) weisen konsistente Werte aber größere Dynamik auf als Thermoelement

- › AGAM-Temperaturmessung reagiert schneller auf Temperaturwechsel
- › Messung liefert nach rd. 1 Jahr immer noch plausible Messwerte (wartungsarm, selbstreinigend)


AGAM: Geschwindigkeitsmessung und Wärmestrom Berechnung am EAF-Abgaskanal

Abgas Geschwindigkeit



Durch Laufzeitunterschied in/entgegengesetzt zur Strömung kann die Strömungsgeschwindigkeit berechnet werden


Abgas Wärmestrom (Abschätzung)



Potential der AGAM-Messung:

- › Einfluss Falschluff (Menge) und Wärmestrom als Limit der Wärmerückführung jetzt in Echtzeit darstellbar (Softsensor)

AGAM: Weitere Einsatzmöglichkeiten am EAF, Lärm ~ Schlackenzustand?



„Lärm-Pegel“ im EAF gibt Hinweise auf Schlackenzustand:

- › Unterschiedlichen Ofenphasen lassen sich im Lärm-Pegel abbilden: Raffinations- und Entschlackungsphase heben sich deutlich von den Schmelzphasen ab!
- › Unterschiede von Temperatur und Lärm können Rückschluss auf Schaumslag geben
- › Weitere Messkampagnen benötigt, um Sachverhalt zu verifizieren
 - › Unterschiede im Zustand der Schaumslag verifizieren
 - › Ofenbetreiber können gute Ofenfahrweise, Schlackenzustand „hören“



AGAM: Weitere Einsatzmöglichkeiten & Ausblick

- › Mit AGAM können kontaktlos Temperatur und Geschwindigkeit gemessen werden
- › Abschätzung der Abgaswärmemenge (Abgasverlust) kann in Echtzeit dargestellt werden
 - › Implementierung als Softsensor
- › Weiteres Potential bietet die Auswertung des Lärm-Pegels, der Zusammenhänge mit dem Zustand der Schlacke beinhaltet (weitere Messkampagnen notwendig)
- › AGAM wird bereits in Dampferzeugern für die Detektion von Leckagen eingesetzt
- › Weitere Installationen von AGAM im Stahl- und Eisen-Bereich
 - › Hochofen
 - › Closed Submerged Arc Furnace
 - › Open Submerged Arc Furnace
 - › Brammenofen



Kontakt: Dr. Martin Brodeck
Bonnenberg & Drescher GmbH
Galileo-Allee 8 · 52457 Aldenhoven
Telefon +49 2464 5810
E-Mail info@budi.de · www.budi.de

E-Mail info@budi.de · www.budi.de
Telefon +49 2464 5810
Galileo-Allee 8 · 52457 Aldenhoven
Bonnenberg & Drescher GmbH
Kontakt: Dr. Martin Brodeck

Kontakt: Dipl.-Ing. (FH) Emanuel K. Thienpont
VDEh-Betriebsforschungsinstitut GmbH
Sohnstraße 69 · 40237 Düsseldorf
Telefon +49 98492-387
E-Mail Vorname.Nachname@bfi.de · www.bfi.de

E-Mail Vorname.Nachname@bfi.de · www.bfi.de
Telefon +49 98492-387
Sohnstraße 69 · 40237 Düsseldorf
VDEh-Betriebsforschungsinstitut GmbH
Kontakt: Dipl.-Ing. (FH) Emanuel K. Thienpont



VDEh-Betriebsforschungsinstitut
GmbH



Co-funded by the European Union – GA n. 101092328 (GreenHeatEAF)

