

# Circularity-Oriented Maintenance

KI-gestützte Entscheidungsunterstützung für zirkularitäts-orientierte Instandhaltung

**Gábor Princz <sup>1</sup>, Sareh Aghaei <sup>2</sup>, Iasmina Solovastru <sup>2</sup>, Fazel Ansari <sup>2</sup>,  
Rudolf Plettenberg <sup>3</sup>, Isfried Janetschek <sup>4</sup>**

<sup>1</sup> *FH-Wiener Neustadt, Institut für Industrial Engineering und Management*

<sup>2</sup> *TU-Wien, Forschungsbereich Produktions- und Instandhaltungsmanagement, Fakultät für Maschinenwesen und Betriebswissenschaften*

<sup>3</sup> *Fried. v. Neuman Gesellschaft m.b.H., Austria*

<sup>4</sup> *MESify Solutions GmbH, Austria*


# Einleitung

## Inhalte

- Videobotschaft von Neuman Aluminium
- Einleitung
- Wissensbasierte Instandhaltung
- Zirkularitäts-orientierte Instandhaltung
- Framework
- Fallstudie
- Ergebnisse

# Videobotschaft Neuman Aluminium


Dipl.-Ing. Rudolf Plettenberg



# Einleitung

## Symptomatische statt kausale Fehlerbehebung

- Nachbearbeitungsprozesse werden unabhängig vom Umformverfahren überwiegend zeitbasiert instandgehalten.
- Unvorhergesehene Stillstände erfordern eine rasche, jedoch häufig unvollständige Ursachenanalyse.
- Bei unzureichendem Detailwissen werden auch funktionsfähige Komponenten präventiv ausgetauscht.
- Diese Praxis verlängert die Reparaturzeit und erhöht den Ersatzteilbedarf.
- Erforderlich ist ein Modell, das die tatsächliche Fehlerursache anstelle des Symptoms identifiziert.



Sang, G. M.; Xu, L.; De Vrieze, P. (2021): *A Predictive Maintenance Model for Flexible Manufacturing in the Context of Industry 4.0*. In: *Frontiers in Big Data*, Vol. 4, S. 663466.

Friedrich, J.; Scheifele, S.; Verl, A.; Lechler, A. (2015): *Flexible and Modular Control and Manufacturing System*. In: *Procedia CIRP*, Vol. 33, S. 115–120.

# Einleitung

## Erklärbarkeit als Modellkriterium für ein Recommendation System

- Deep-Learning-Modelle wie LSTM erreichen eine hohe Vorhersagegüte, arbeiten jedoch als Black-Box-Modelle.
- Sie liefern keine nachvollziehbare Begründung für den Zusammenhang zwischen Anlagenzustand und Empfehlung.
- Bayes'sche Netze bilden Ursache-Wirkungs-Beziehungen explizit und nachvollziehbar ab.
- Sie erlauben zudem die Fusion heterogener Datenquellen bei vergleichsweise geringem Datenbedarf.
- Damit erfüllen sie sowohl die Anforderung an Vorhersagegüte als auch an Erklärbarkeit.

| Kriterium           | Deep Learning (z. B. LSTM) | Bayes'sches Netz  |
|---------------------|----------------------------|-------------------|
| Vorhersagegüte      | hoch                       | hoch              |
| Nachvollziehbarkeit | gering (Black Box)         | hoch (kausal)     |
| Datenbedarf         | groß                       | gering bis mittel |
| Datenfusion         | aufwendig                  | direkt möglich    |


Ansari, F.; Glawar, R.; Sihn, W. (2020): *Prescriptive Maintenance of CPPS by Integrating Multimodal Data with Dynamic Bayesian Networks*. Berlin, Heidelberg: Springer, ISBN 978-3-662-59084-3, S. 1–8.

Jiang, Y.; Dai, P.; Fang, P.; Zhong, R. Y.; Zhao, X.; Cao, X. (2022): *A2-LSTM for predictive maintenance of industrial equipment based on machine learning*. In: *Computers & Industrial Engineering*, Vol. 172, S. 108560.

# Wissensbasierte Instandhaltung

## Das PriMa-Modell: Vier Reifegrade der Instandhaltung

- Bei komplexen Anlagen ist Sensordaten allein unzureichend; ergänzendes Erfahrungswissen ist erforderlich.
- Das PriMa-Modell kategorisiert Instandhaltung in vier Reifegrade.
- Empfehlungssysteme übersetzen dieses Wissen in konkrete Handlungsalternativen.
- Die präskriptive Stufe schließt die Lücke zwischen Vorhersage und Handlungsempfehlung.



Ansari, F.; Glawar, R.; Nemeth, T. (2019): *PriMa: a prescriptive maintenance model for cyber-physical production systems*. In: International Journal of Computer Integrated Manufacturing, Vol. 32, S. 482–503

Erkoyuncu, J. A.; Ansari, F.; Iung, B.; Takata, S. (2026): *Digitally enhanced maintenance: path towards continuous value creation and sustainability*. In: CIRP Annals, Vol. 75, S. 943–969

Uta, M.; Felfernig, A.; Le, V.-M.; Tran, T. N. T.; Garber, D.; Lubos, S.; Burgstaller, T. (2024): *Knowledge-based recommender systems: overview and research directions*. In: Frontiers in Big Data, Vol. 7, S. 1304439

# Zirkularitäts-orientierte Instandhaltung

## Das 9R Framework

- **Bestehende Recommendation Systeme vernachlässigen ökologische Auswirkung einer Empfehlung.**
- **Klassische Bewertungskriterien für Instandhaltungsentscheidungen wie Verfügbarkeit und Kosten blenden ökologische Zielgrößen wie den Ressourcenverbrauch aus.**
- **Repair (R4) ist ökobilanziell vorteilhaft, solange die Ausfallrate der Komponente einen definierten Schwellenwert nicht überschreitet**
- **Recycling (R8) ist erst indiziert, wenn Repair und Remanufacture technisch ausscheiden.**
- **Ausnahme: Sicherheitsrelevante Bauteile werden unabhängig von ihrem Zustand ersetzt.**

**R3 • Reuse** – Wiederverwendung, z. B. Sensor aus dem Ersatzteillager

**R4 • Repair** – Reparatur, z. B. nur die Dichtung statt der Spindel

**R6 • Remanufacture** – Aufarbeitung, z. B. ein überholter Servomotor


**R7 • Repurpose** – Umnutzung, z. B. Förderband als Materialpuffer

→ **danach erst** R8 Recycle bzw. linearer Neuteilaustausch

# Framework

## Architektur des Recommendation-Systems

- Ein Bayes'sches Netz verknüpft objektbezogene, auftragsbezogene und historische Daten.
- Der Maschinenzustand wird kontinuierlich aktualisiert und objektübergreifend verglichen.
- Case-Based Reasoning gleicht neue Störfälle mit bereits gelösten Fällen ab.
- Das System leitet daraus eine Rankinglogik ab, die Reparatur und Wiederverwendung priorisiert.
- Die Empfehlung wird textbasiert ausgegeben: Abbildung für den Überblick, Text für die Anweisung



# Fallstudie

## Datengrundlage einer CNC-Rundtaktanlage

- Die Fallstudie basiert auf fünf Datensätze der CNC-Rundtaktanlage.
- Der gemeinsame Beobachtungszeitraum umfasst rund 28 Tage.
- 83,5 % der Alarme stimmen mit dem gemeldeten Störungszustand überein.
- Eine Filterung reduziert das Alarmprotokoll um 85 % bei gleichbleibendem Informationsgehalt.
- Die resultierende Modellgrundlage umfasst rund 40.900 Zeitscheiben.

5

Datensätze aus einer Rundtaktanlage

~28 Tage

gemeinsamer Beobachtungszeitraum

83,5 %

Übereinstimmung Alarm ↔  
Störungszustand

-85 %

Alarmreduktion ohne Informationsverlust

~40.900

Zeitscheiben als Modellgrundlage


# Fallstudie

## Vom Merkmal zum kausalen Netz

- Die 16 Merkmale gliedern sich in vier Klassen (OOBN): Zustand, Alarme, Auftrag, Qualität.
- Nur vier Verknüpfungen führen zwischen den Klassen
- Die anderen Verknüpfungen bleiben innerhalb einer Klasse.
- Zusammengesetzt ergeben die Klassen ein Netz für die gesamte Maschine.
- Dieses Netz bildet die Grundlage für die Vorhersage im nächsten Schritt.

*Abhängigkeit innerhalb der Klasse*


*Schnittstelle zwischen den Klassen*



# Fallstudie

## Vorhersage über Betriebslagen hinweg


- Eine zusätzliche Größe sagt voraus, ob in den nächsten zehn Minuten ein Fehler auftritt.
- Ergänzend erfasst das Modell die aktuelle Betriebslage der Maschine.
- Es lassen sich drei Betriebslage unterscheiden: ruhig, mittel, störungsreich.
- Bei hoher Alarmhäufigkeit und gleichzeitigem Stillstand ergibt sich eine Fehlerwahrscheinlichkeit von 65,33 %.
- Die Berücksichtigung der Betriebslage verbessert die Vorhersagegüte spürbar (ROC-AUC 0,752 → 0,826).



# Ergebnisse

## Ergebnisse und Limitationen

- Ein Bayes'sches Netz verdichtet fünf heterogene Datenquellen zu einem kausalen Modell.
- Wechselnde Betriebslagen erhöhen die Modellgüte auf ROC-AUC 0,826.
- Die Fehlerwahrscheinlichkeit variiert je nach Betriebslage zwischen 6 % und 40 %.
- Limitation: eine Maschine, 28 Tage – Übertragung folgt in künftigen Arbeiten.



# Circularity-Oriented Maintenance

KI-gestützte Entscheidungsunterstützung für zirkularitäts-orientierte Instandhaltung


Gábor Princz, Sareh Aghaei, Iasmina-Roxana Solovastru, Fazel Ansari, Rudolf Plettenberg, Isfried Janetschek

**Kontakt:** [gabor.princz@fhwn.ac.at](mailto:gabor.princz@fhwn.ac.at)

# Framework

## Warum nicht-stationäre Bayes'sche Netze


- Bayes'sche Netze sind azyklische Wahrscheinlichkeitsgraphen; ihre dynamische Form ist zeitindiziert (Shiguihara et al. 2021).
- Interpretierbare Wahrscheinlichkeiten schaffen Transparenz gegenüber Deep-Learning-Modellen, die in der Fertigung noch wenig erforscht sind.
- In einem sich laufend verändernden Umfeld eignen sich nsDBN besonders gut zur transparenten Fusion multivariater Daten.
- Ein nsDBN vereint Diagnose, Prognose und Präskription in einem einzigen probabilistischen Modell.
- Unter wechselnden Bedingungen bildet ein nsDBN die Kette Symptom → Fehler → Ursache → Lösung ab und zeigt deren Wirkung auf RUL, MTBF, MTTR und Ersatzteilkosten.



# Framework

## Struktur und Datenherkunft der Empfehlung


- Jede Empfehlung folgt einer vierstufigen Textschablone: Descriptive, Diagnostic, Predictive, Prescriptive.
- Jede Stufe verknüpft eine spezifische Information mit ihrer Datenherkunft -> objektbezogen, auftragsbezogen oder historisch.
- Descriptive lokalisiert die Anomalie; Diagnostic quantifiziert deren wahrscheinlichste Ursache.
- Predictive schätzt Restnutzungsdauer und Handlungsdringlichkeit; Prescriptive leitet die Maßnahme ab.
- Diese Struktur bestimmt, welche Daten für eine nachvollziehbare Empfehlung erforderlich sind.



# Framework

## Aufbau des vollständigen Netzes im Detail


- Jeder Knoten steht für ein Merkmal der Maschine, z. B. den aktuellen Zustand oder eine Alarmgruppe.
- Ein Pfeil von A nach B bedeutet: B hängt wahrscheinlichkeitsmäßig von A ab.
- Links: Der Maschinenzustand bestimmt, ob ein Fehler vorliegt, und darüber die Alarmgruppen.
- Rechts, unabhängig davon: Ein Auftragswechsel bestimmt Stillstand, Stückzahl und Qualität.
- Alle Wahrscheinlichkeiten wurden aus rund 40.900 Zeitscheiben der Rundtaktanlage gelernt.



# Framework

## Vom aktuellen Zustand zur Vorhersage

- Das Netz aus der Abbildung wird um einen neuen Knoten erweitert: **fault\_h10**.
- **fault\_h10** sagt voraus, ob in den nächsten zehn Minuten ein Fehler auftritt.
- Vier Pfeile führen auf diesen Knoten zu: Fehlerzustand, Alarmlast, Stillstand, Alarmkombination.
- Diese vier Merkmale liefern also die stärksten Hinweise auf einen bevorstehenden Fehler.
- Alle übrigen Pfeile entsprechen weiterhin dem Netz der letzten Abbildung.



# Framework

## Beispielhafte Inferenz im Detail

- Jeder Kasten zeigt die Wahrscheinlichkeitsverteilung eines Merkmals als Balken.
- Orange markiert die beiden bekannten Werte: hohe Alarmlast und aktueller Stillstand.
- Ausgehend davon berechnet das Netz für jeden anderen Knoten die passende Verteilung.
- Die grünen Balken zeigen jeweils den neu berechneten, wahrscheinlichsten Wert.
- Am Ende dieser Kette steht fault\_h10: 65,33 % Fehlerwahrscheinlichkeit.

