

Predictive Maintenance im Informationssystem der Instandhaltung

Dr. Kühnast-Benedikt

Leoben, 07.10.2020

© WBW; KÜ

07-10-2020

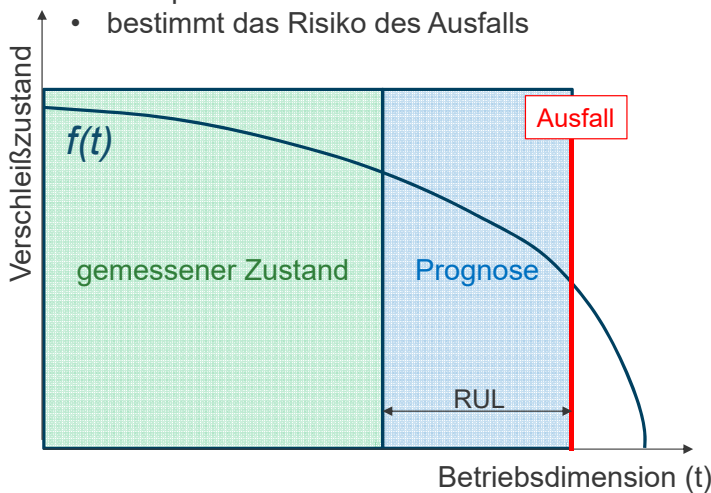
1

Predictive Maintenance

Definition

Predictive Maintenance:

- verfolgt den Verschleißzustand
- extrapoliert die Verschleißfunktion
- bestimmt das Risiko des Ausfalls

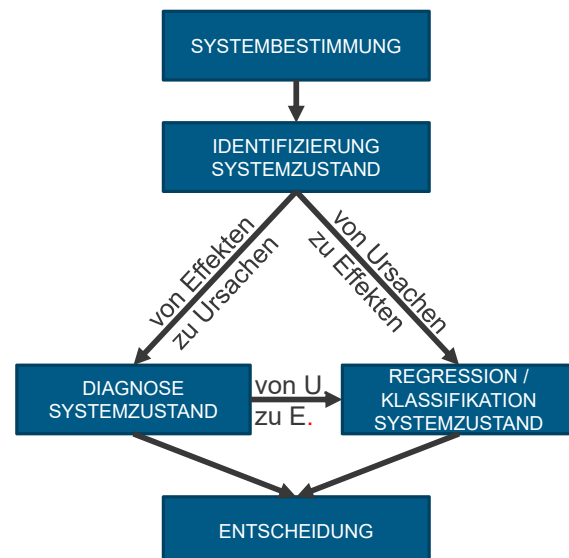


© WBW; KÜ

RUL...Remaining Useful Life

07-10-2020

Methodik:



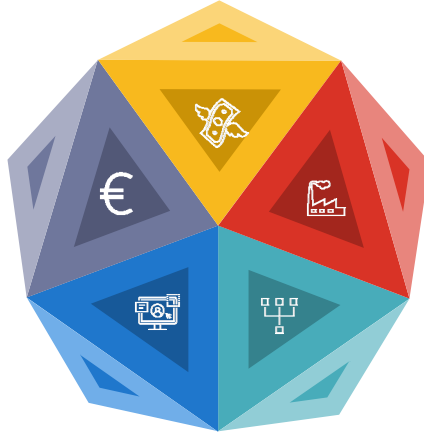
In Anlehnung an Gouriveau (2016)

2

Predictive Maintenance (PdM) als mehrdimensionales Konstrukt

01 Erwartungshaltung

Unzählige Studien bescheinigen PdM sehr große Benefits



05 Wertschöpfung

Die Messung, Bewertung und Validierung des zu leistenden Wertschöpfungsbeitrags wird in der Praxis kaum verfolgt

04 Implementierung

Die Implementierung ins Live-System erfolgt oftmals ineffektiv

02 Systemkomplexität

Das zu modellierende System ist äußerst komplex

03 Lösungskomplexität

Die anwendbaren Verfahren weisen ebenso eine hohe Komplexität auf

Erwartungshaltung an Predictive Maintenance

Studien rechnen PdM große Potenziale zu

01

Erwartungshaltung




Lebensdauer



Kostenreduktion


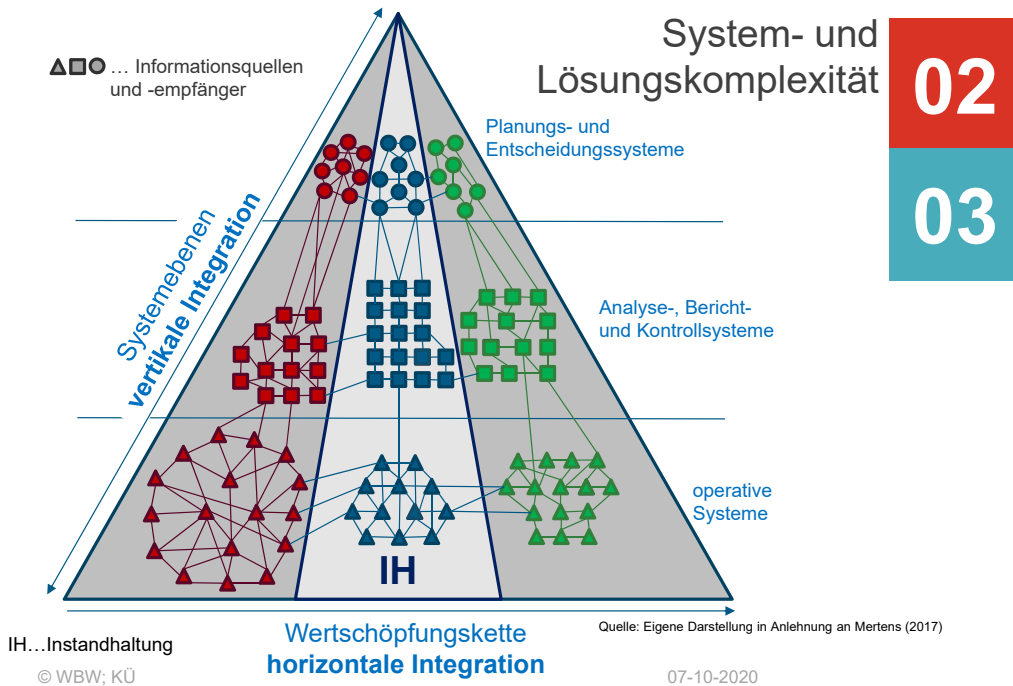


Stillstände



McKinsey&Company; Operations July 2017; V. Dilda, M. Hippe, L. Mori, O. Noterdaeme, C. Schmitz, J. V. Niel; Manufacturing: Analytics unleashes productivity and profitability
 PwC; M. Haarman, P. Klerk, P. Decaigny, M. Mulders, C. Vassiliadis, H. Sijtsema, I. Gallo; Predictive Maintenance 4.0; September 2018
 McKinsey&Company; Global Institute June 2015; The internet of things: Mapping the value beyond the hype
 Deloitte; O. P. Schleichert, B. Bringmann, H. Kremer, S. Zablotskiy, D. Köpfer; Predictive Maintenance – Taking pro-active measures based on advanced data analytics to predict and avoid machine failure; Issue 7/2017
 Deloitte; Development LLC; Asset Monitoring & Predictive Maintenance; May 2017

Das Gesamtsystem ist hochkomplex




Die Implementierung von Data-Mining-Resultaten ist nicht straightforward



04

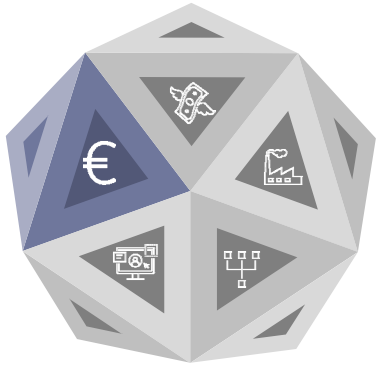
Implementierung

Prognose	Wahres Ergebnis		Precision	Pseudofehlerrate
	nicht in Ordnung 3.018 (4,42%)	in Ordnung 65.302 (95,58%)		
nicht in Ordnung 1.656 (2,42%)	1.021	635 Pseudofehler	61,65%	38,35%
in Ordnung 66.664 (97,58%)	1.997 Schlupf	64.667	False Omission Rate 3,00%	Negative Predictive Value 97,00%
	Sensitivity / Recall 33,83%	False Positive Rate 0,97%	Accuracy 96,15%	
	Schlupfrate 66,17%	Specificity 99,03%		



Mazarov et al (2020)

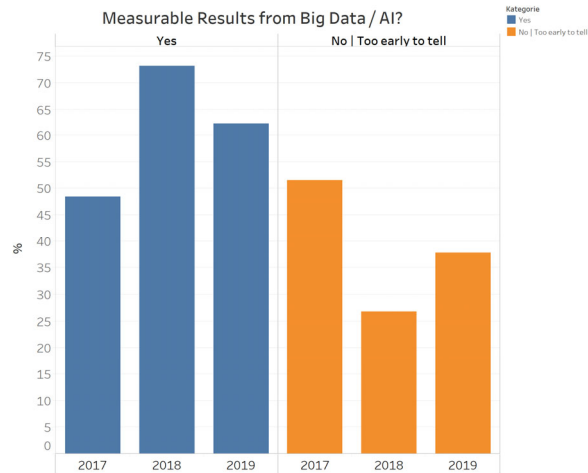
Viele Projekte scheitern



05

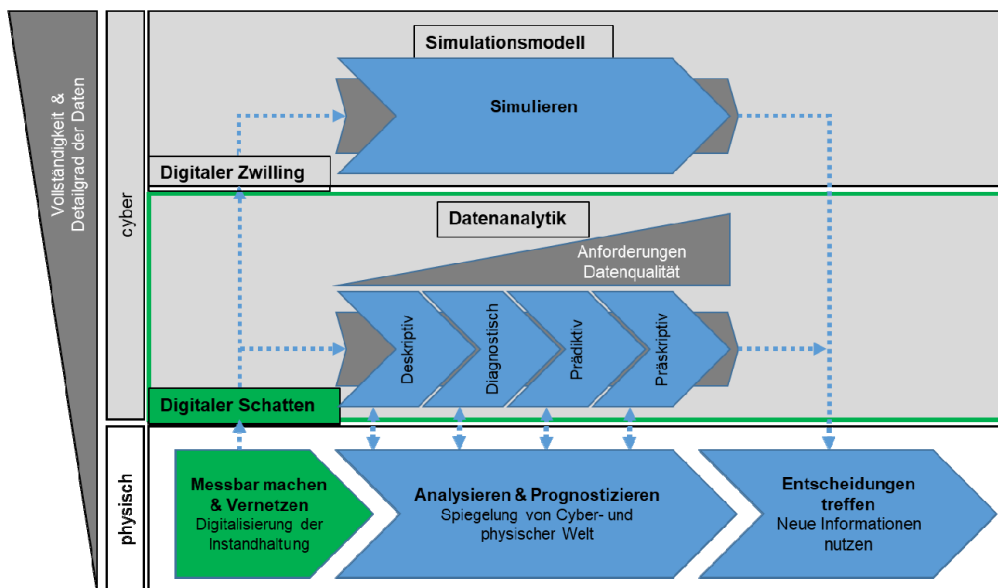
Wertschöpfung

~85% Big Data Projekte scheitern (Gartner 2017)



New Vantage Partners: Big Data and AI Executive Survey 2019 (2019), Boston (<https://newvantage.com/wp-content/uploads/2018/12/Big-Data-Executive-Survey-2019-Findings.pdf>)

Digitaler Schatten und Zwilling

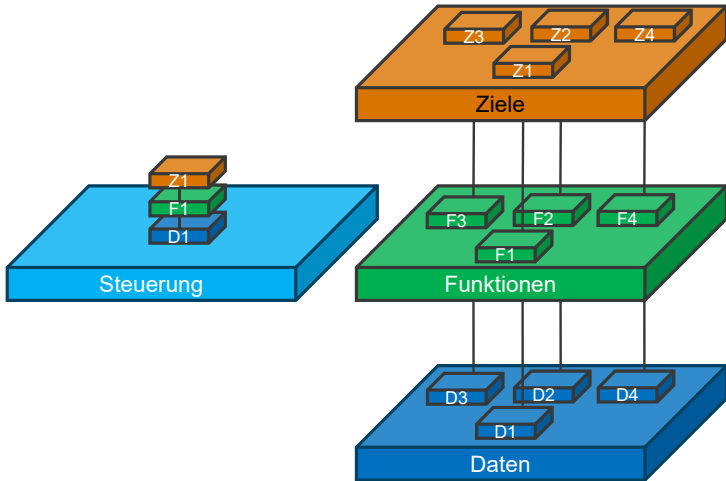


Eigene Darstellung in Anlehnung an Bauernhansl, T. et al. (2017)

Referenzmodell

Sichtweisen und originäre Ergebnisse

Referenzmodell



Eigene Darstellung

07-10-2020

© WBW; KÜ

Inhalt

50 Ziele

40 Funktionen

127 Attribute

originärer Beitrag

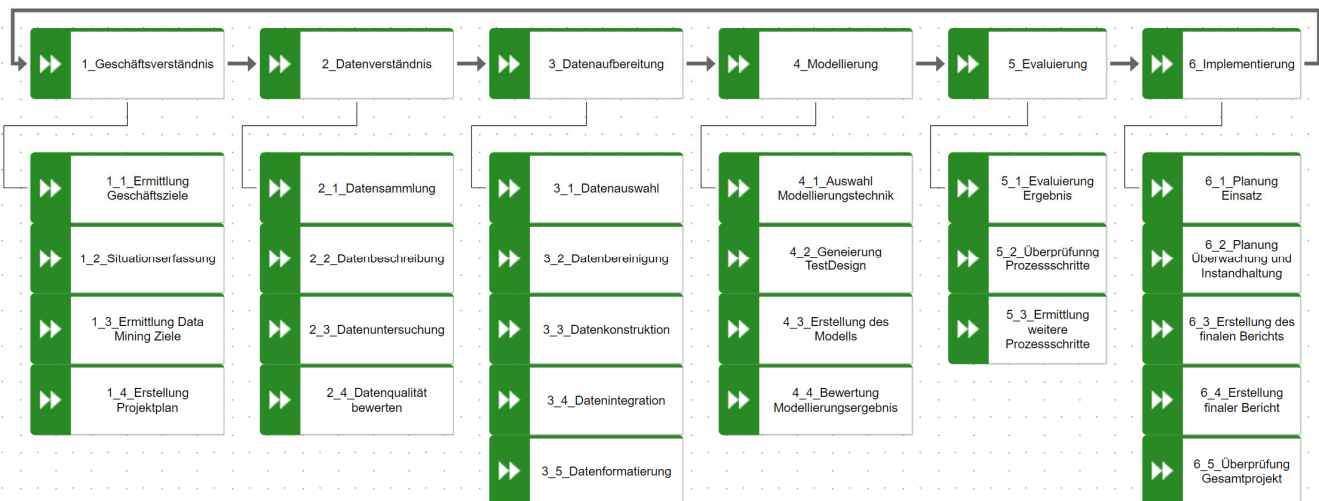
generisches Zielmodell

generisches Funktionsmodell
von Strategie - Durchführung

generisches Datenmodell
Inhalt & Beziehungen
Verbindung zu Funktionen
Verbindung zu Zielen

9

Implementierung des CRISP-DM in das Informationssystem



Eigene Darstellung

07-10-2020

© WBW; KÜ

10

Phase 1: Business Understanding

Aufgaben und Ziele der Phase:

- Ziele und Anforderungen aus einer betriebswirtschaftlichen Perspektive
- Situationserfassung
- Definition des Data Mining Problems
- Projektplan

Bewährt:

- Use-Case Definition

Use-Case

- Prozessindustrie
- Engpassanlage (24/7)
- Verschleißanfälliger Produktionsprozess
- Hochautomatisiert (wichtig für Datenlage & -qualität)
- Keine direkten Inspektionen möglich

Phase 2: Data Understanding


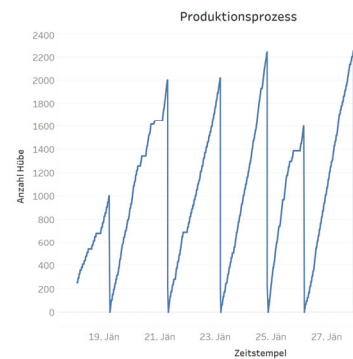
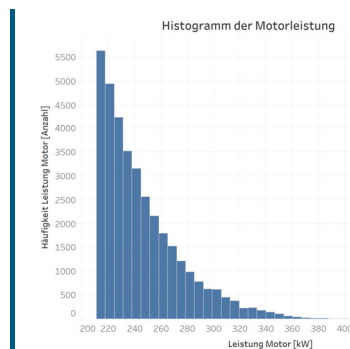
Aufgaben und Ziele der Phase:

- Datenakquise
- Datenbeschreibung
- Datenexploration
 - Visualisierungen
 - Korrelationen (small data)

Bewährt:

- Datenqualitätsassessment

Use-Case



Reifegrad	1	2	3	4
Kategorie	„Stahlwerk 1970“	Entstehendes Bewusstsein für Daten	Industrie 4.0-Ansätze	Bereit für Industrie 4.0
Erfassung			3,8	
Speicherung & Übertragung				4,4
Datenformate			3,5	4,1
Datencodierung				4,6
Datenumfang			4,0	
Zeitliche Konsistenz			4,0	

Durchschnitt: 4,0

Quelle: Bernerstätter und Kühnast (2019)

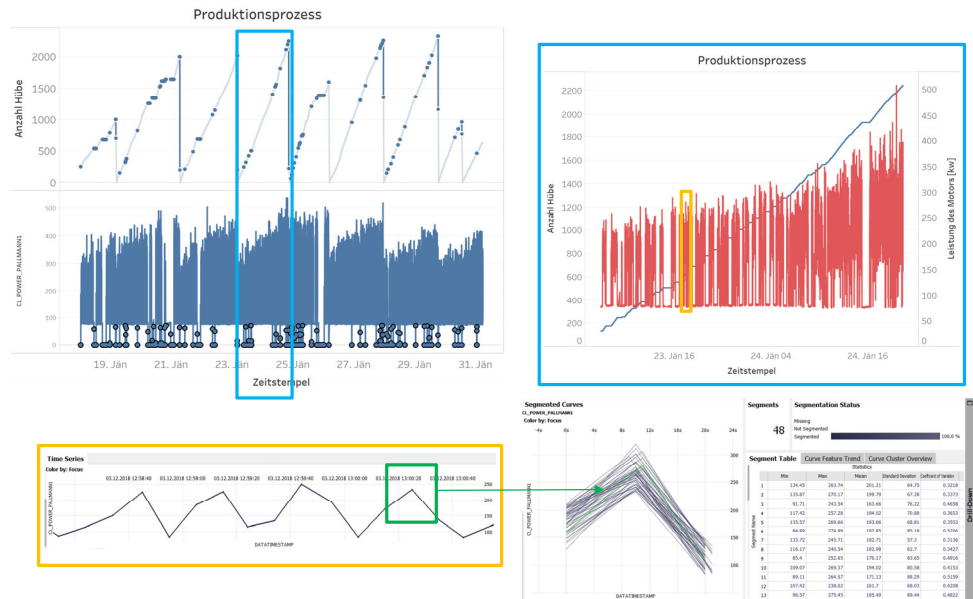
Phase 3: Data Preparation

Aufgaben und Ziele der Phase:

- Datenauswahl
- Datenbereinigung
- Datenkonstruktion
- Datenintegration
- Datenformatierung

Bewährt: Investition in Visualisierungsprogramme (siehe Anhang)

Use-Case



Phase 4: Data Modeling

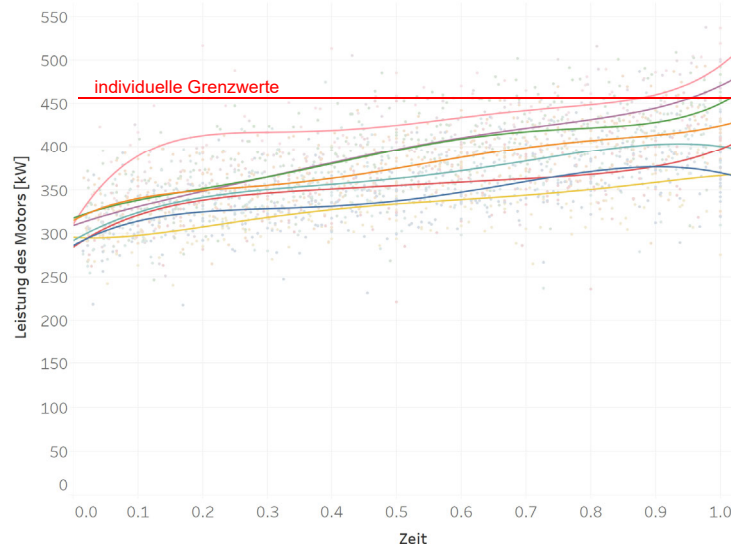
Aufgaben und Ziele der Phase:

- Auswahl der geeigneten Modellierungstechnik
- Testdesign gestalten
- Modell bauen
- Modellierung

Bewährt: so einfach wie möglich, so komplex wie nötig

Use Case

Multiple Regression



Phase 5 & 6: Evaluation & Deployment

Aufgaben und Ziele der Phase Evaluation:

- **Resultate bewerten**
 - Genauigkeit ausreichend?
- **Methodik reviewen**
- **Nächste Schritte definieren**

Bewährt: Genauigkeit ist nicht alles, folgende Vorteile werden oft übersehen:

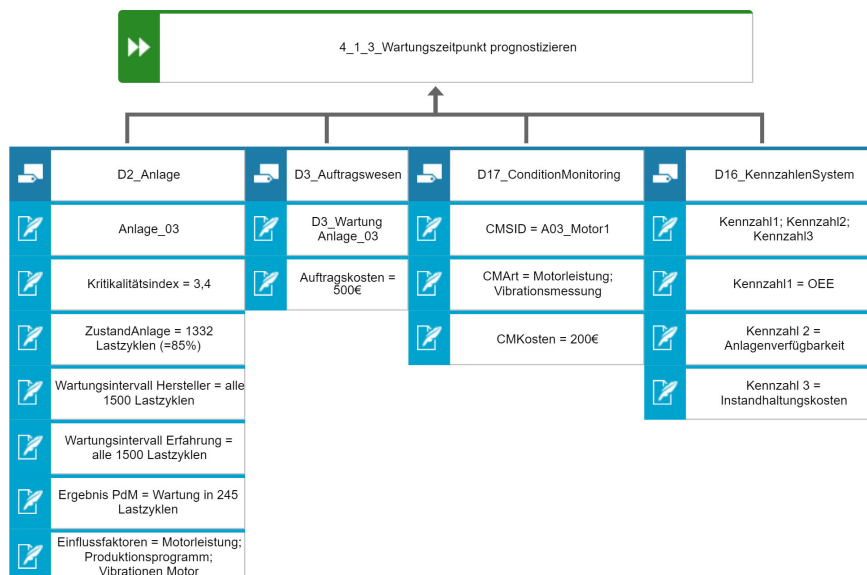
- **Prozessverständnis wird geschärft**
- **Einflussparameter ermittelt**
- **Datenqualität erhöht**

Aufgaben und Ziele der Phase Deployment:

- **Plan umsetzen**
- **Plan kontrollen**
- **Abschlussreport**
- **IH - Management**

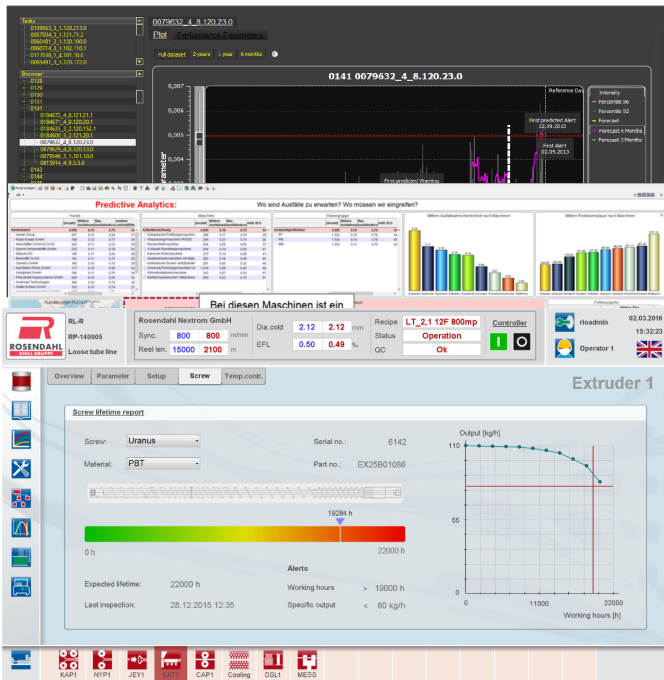
Bewährt: Zwischenreports zu DQA & Ergebnissen – an alle Stakeholder!

Ergebnis von Predictive Maintenance



Eigene Darstellung

Darstellung der Ergebnisse in der Software



<p>Ausfallwahrscheinlichkeit</p> <p>80%</p> <p>in den nächsten 2 Stunden</p>	<p>Einflussfaktoren</p> <p>A42_Motor_Power 0.8</p> <p>A42_Motor_Vibr 0.6</p> <p>A622_Temp 0.3</p>
<p>Kritischer Zustand</p> <p>in</p> <p>97 Min.</p> <p>erreicht</p>	<p>05.10.2020 17:33</p> <p>Anomalie</p> <p>erkannt</p> <p>Anomaliescore = 4172</p>

Zusammenfassung

- Predictive Maintenance besitzt großes Potenzial als Vorzeigeprojekt einen wichtigen Schritt in Richtung der digitalisierten Instandhaltung zu machen
- Wichtigste Punkte:
 - Systematische Vorgehensweise (CRISP-DM)
 - Abteilungsübergreifende Teams (Data-Scientists, Analytiker, Processing., IT, Produktion, IH, ...)
 - Ausführung muss ohne Doktor der Informatik möglich sein
 - Implementierung der Erkenntnisse und Nutzen der Ergebnisse in den entsprechenden Regelkreisen des Instandhaltungsmanagements
 - Wertschöpfung sicht- und messbar machen

Eingesetzte Software

▪ Matlab



▪ Tableau



▪ SPSS Modeler



▪ Visplore



▪ Microsoft Excel



Bewährt: Visualisierungen

