



Maschinelles Lernen

Anwendungen im Mittelstand –
von Betrugserkennung bis
Instandhaltung

Prof. Dr. Michael Bücker
Professor für Data Science





Prof. Dr. Michael Buecker

Professor für Data Science, Mathematik und Wirtschaftsinformatik

Fachhochschule Münster

www.buecker.ms



IPD Institut für
Prozessmanagement und
Digitale Transformation



FH MÜNSTER
University of Applied Sciences

McKinsey
& Company



technische universität
dortmund

- Seit 12/2019: Vorstand Institut für Prozessmanagement und Digitale Transformation (IPD) der FH Münster
- Seit 03/2018: Professor für Data Science, Mathematik und Wirtschaftsinformatik an der FH Münster
- 05/2011 – 02/2018: Expert und Engagement Manager für Marketing und Data Science bei McKinsey & Company, Inc.
- 04/2011: Promotion in Statistik an der TU Dortmund
- 06/2008: Diplom in Statistik an der TU Dortmund

Das IPD

12 engagierte Professoren mit Ihren Doktoranden und Mitarbeitern



IPD Institut für
Prozessmanagement und
Digitale Transformation



fh-muenster.de/ipd

Partner der regionalen mittelständischen Wirtschaft in praxisnahen Fragen zu Prozessmanagement und Digitaler Transformation

Forschung

Praxisnahe Forschung,
Konferenzen, Publikationen

Transfer

Transferprojekte,
Beratung

Weiterbildung

Weiterbildungsprogramme,
Ringvorlesung, Projektstudium



Agenda

Inhalte für heute

1

Was ist Maschinelles Lernen?

2

Anwendungsfälle für den Mittelstand

3

Der Weg zum daten-getriebenen Unternehmen



Agenda

Inhalte für heute

1

Was ist Maschinelles Lernen?

2

Anwendungsfälle für den Mittelstand

3

Der Weg zum daten-getriebenen Unternehmen




Lernende Computer: Machine Learning

Lernen aus Erfahrung

What we want is
a machine that
can learn from
experience.

Alan Turing



Lernende Computer: Machine Learning


Abgrenzung zu traditionellen Computerprozeduren

Traditionelles Computerprogramm

Definiere explizite Regeln, die der Computer befolgt und abarbeitet

```

if email contains "V!agra"
  then mark is-spam;
if email contains ...
  then mark is-spam;
  
```




Erkläre mit Instruktionen

Machine Learning Programm

Computerprogramm, das anhand von Beispielen Regeln erlernt

```

try to classify some emails;
change self to reduce errors;
repeat;
  
```




Erkläre mit Beispielen

Funktionsweise lernender Algorithmen


Entscheidungsbäume zur Klassifikation von Obst

Jetzt: Wir wollen einem Computer beibringen, Äpfel von Orangen anhand der Breite und Höhe zu unterscheiden



Funktionsweise lernender Algorithmen

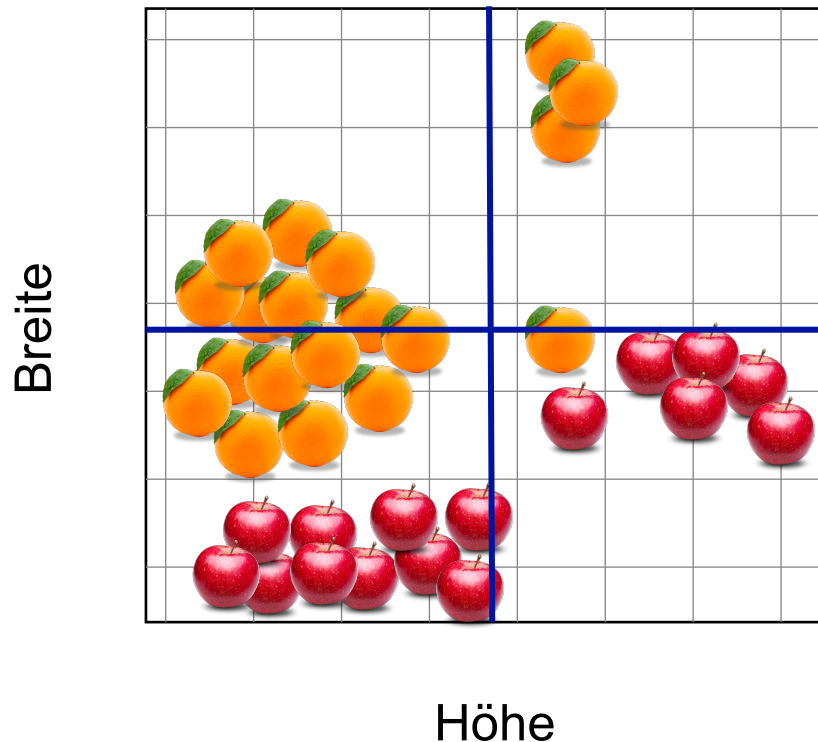
Entscheidungsbäume zur Klassifikation von Obst



- Wir sammeln **Beispiele**: eine Stichprobe von Orangen und Äpfeln
- Wir erfassen die **relevanten Daten**: Höhe und Breite jeder Frucht
- Wir kennen die **Zuordnung** der Früchte (Apfel, Orange)
- Wir nutzen die Beispiele um mit Hilfe eines Algorithmus **Regeln zu lernen**, mit denen sich die Früchte automatisch unterscheiden lassen
- Der Algorithmus wird so trainiert, dass möglichst **wenige Fehlzusordnungen** auftreten

Funktionsweise lernender Algorithmen

Entscheidungsbäume zur Klassifikation von Obst

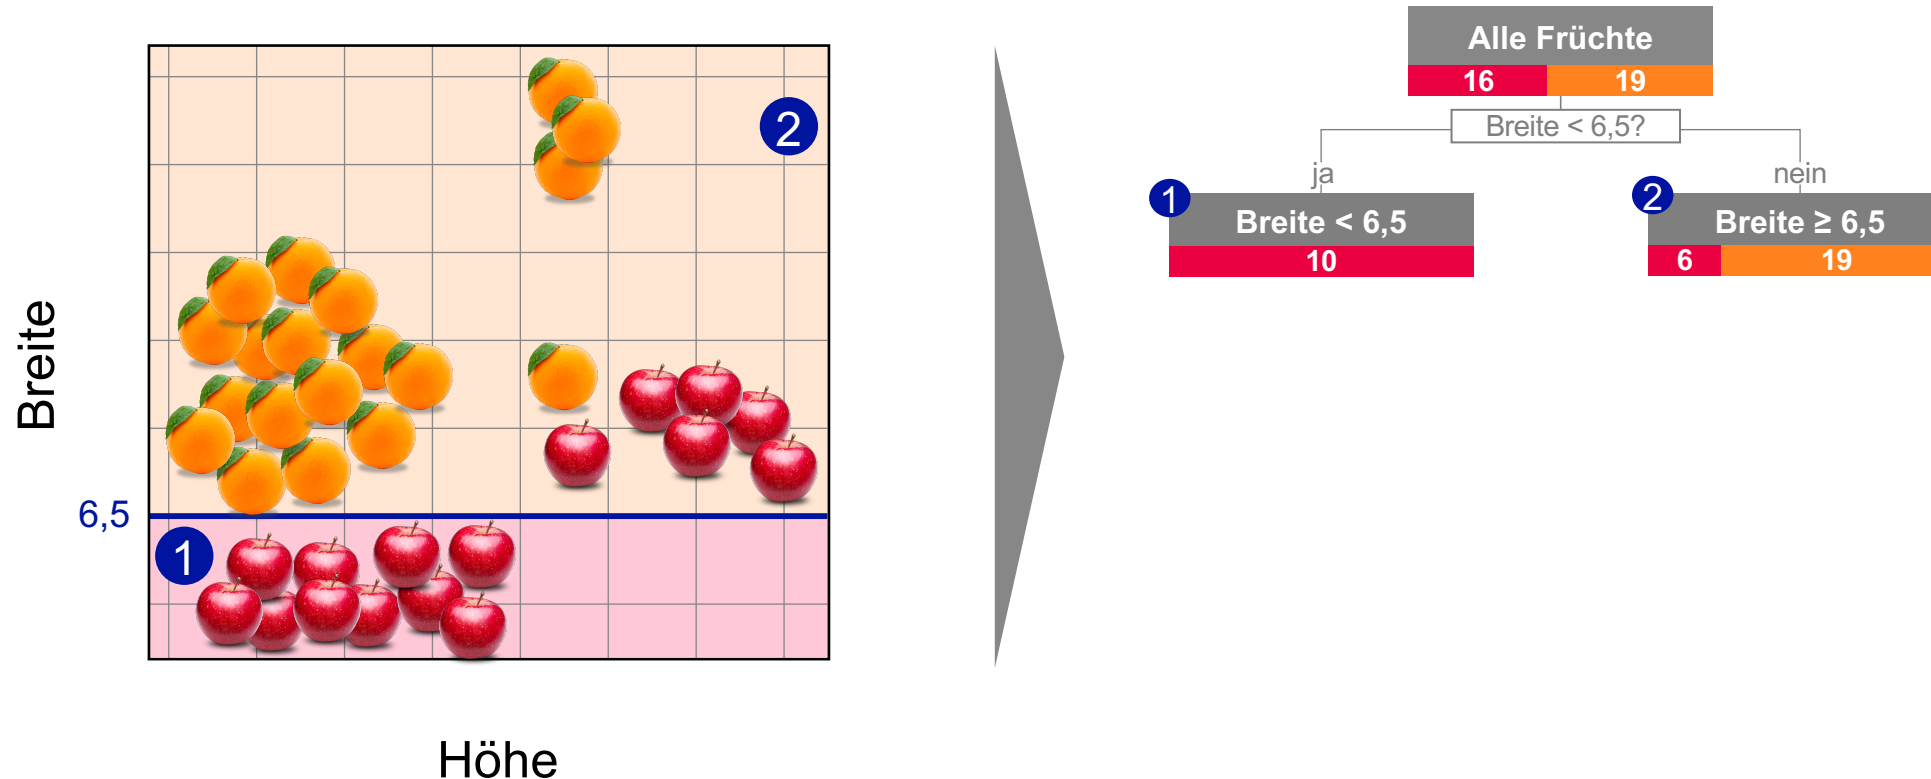


- Der Algorithmus prüft nun entlang jeder Dimension, wie sich **Äpfel und Orangen möglichst gut unterscheiden lassen**
- Eine gute Trennung gelingt,
 - wenn die aufgetrennten Gruppen **möglichst sortenrein** sind
 - wenn die aufgetrennten Gruppen **möglichst groß** sind
- Die beste Trennung wird als erste **Regel** festgehalten

Funktionsweise lernender Algorithmen

Entscheidungsbäume zur Klassifikation von Obst

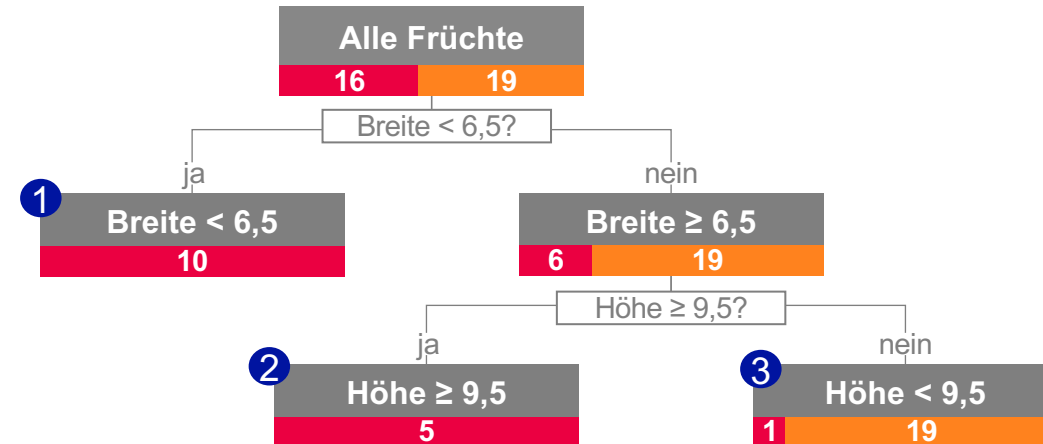

Ein Entscheidungsbaum lernt eine Folge von Entscheidung zur Vermeidung von Fehleinordnungen



Funktionsweise lernender Algorithmen

Entscheidungsbäume zur Klassifikation von Obst

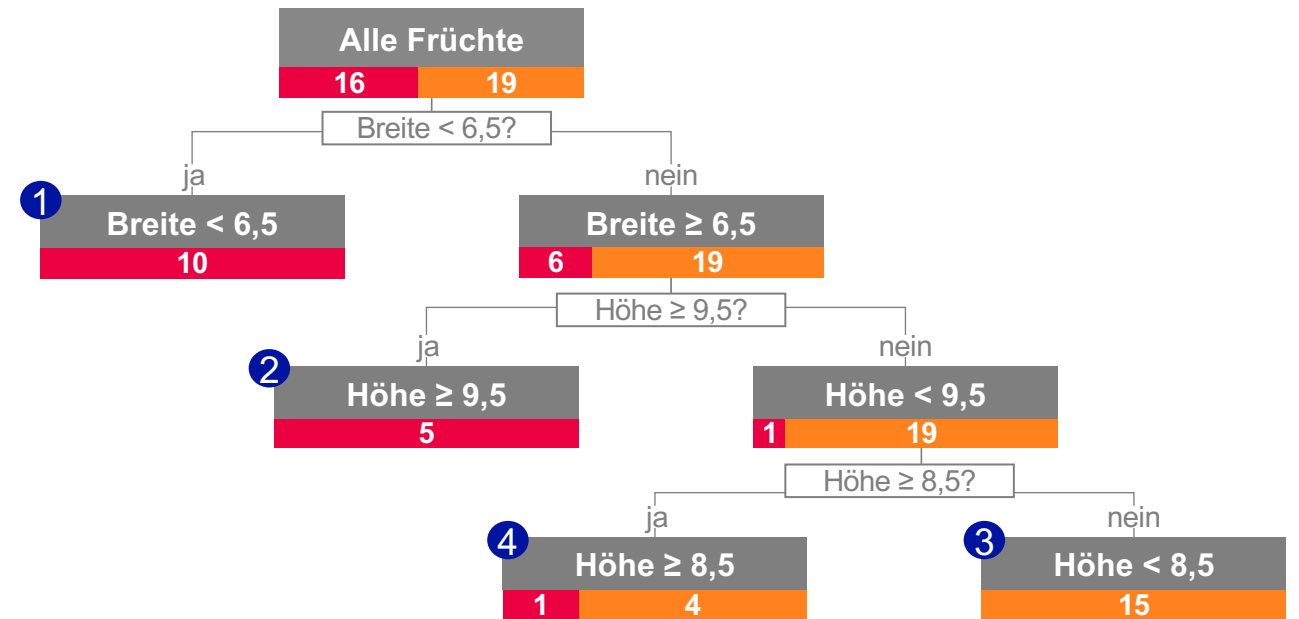

Ein Entscheidungsbaum lernt eine Folge von Entscheidung zur Vermeidung von Fehleinordnungen



Funktionsweise lernender Algorithmen

Entscheidungsbäume zur Klassifikation von Obst

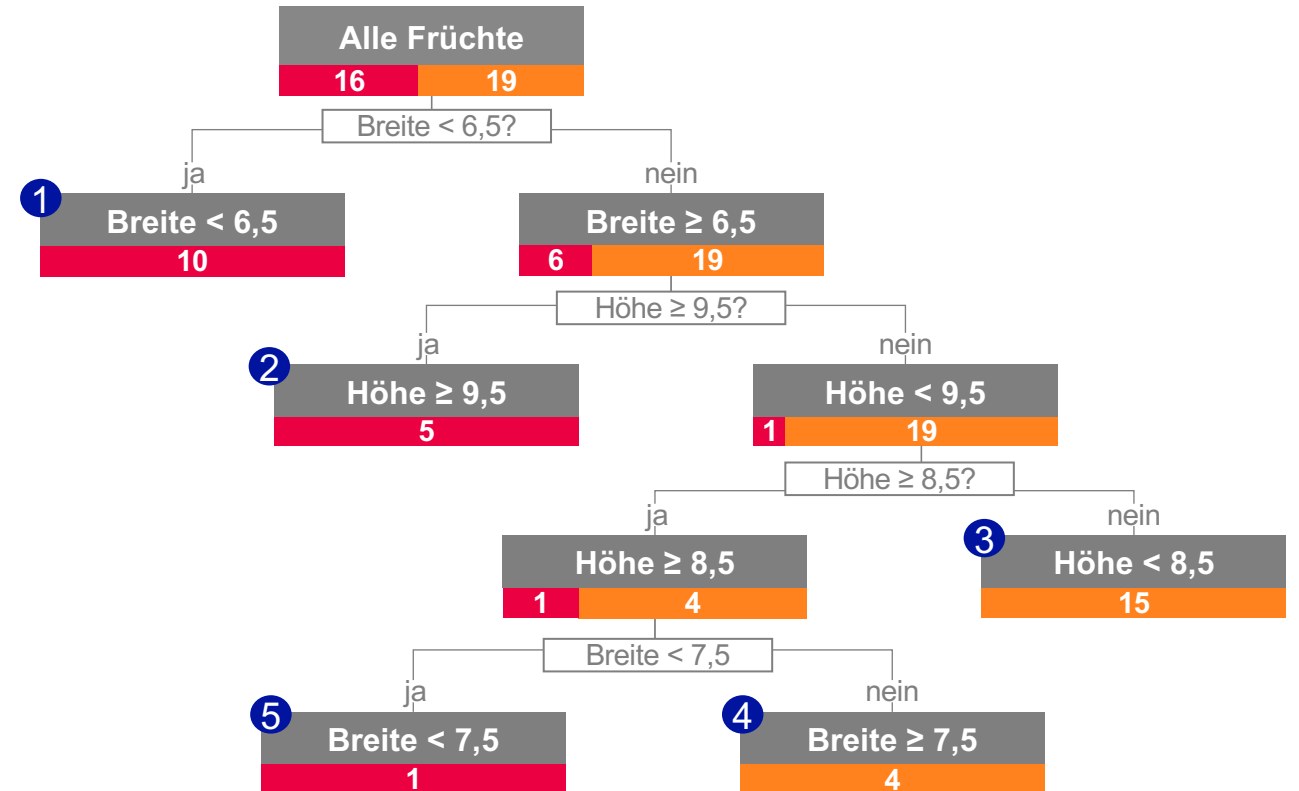

Ein Entscheidungsbaum lernt eine Folge von Entscheidung zur Vermeidung von Fehleinordnungen



Funktionsweise lernender Algorithmen

Entscheidungsbäume zur Klassifikation von Obst


Ein Entscheidungsbaum lernt eine Folge von Entscheidung zur Vermeidung von Fehleinordnungen



Funktionsweise lernender Algorithmen

Entscheidungsbäume zur Klassifikation von Obst

Ein Entscheidungsbaum lernt eine Folge von Entscheidung zur Vermeidung von Fehleinordnungen



Agenda

Inhalte für heute

1 Was ist Maschinelles Lernen?

2 Anwendungsfälle für den Mittelstand

3 Der Weg zum daten-getriebenen Unternehmen



Anwendungen von Datenanalyse

Fallbeispiele

Without Big Data
you are blind and
deaf in the
middle of a
freeway.

Geoffrey Moore



Agenda

Inhalte für heute

1

Was ist Maschinelles Lernen?

2

Anwendungsfälle für den Mittelstand

3

Der Weg zum daten-getriebenen Unternehmen



Agenda

Inhalte für heute

1 Was ist Maschinelles Lernen?

2 Anwendungsfälle für den Mittelstand

2.1 Betrugserkennung

2.2 Predictive Maintenance

2.3 Data-as-an-Asset

3 Der Weg zum daten-getriebenen Unternehmen



Agenda

Inhalte für heute

1 Was ist Maschinelles Lernen?

2 Anwendungsfälle für den Mittelstand

2.1 Betrugserkennung

2.2 Predictive Maintenance

2.3 Data-as-an-Asset

3 Der Weg zum daten-getriebenen Unternehmen



Betrugserkennung

Identifikation „fauler Äpfel“ also Betrüger im Online Shop

Jetzt: Anstatt Äpfel und Orangen möchten wir nun zahlende Kunden (Äpfel) von nicht-zahlenden Kunden (faule Äpfel) differenzieren



Vorgehensweise zur Betrugserkennung

Merkmale „fauler Äpfel“



Was macht „faule Äpfel“ aus?



Erfassung relevanter Daten

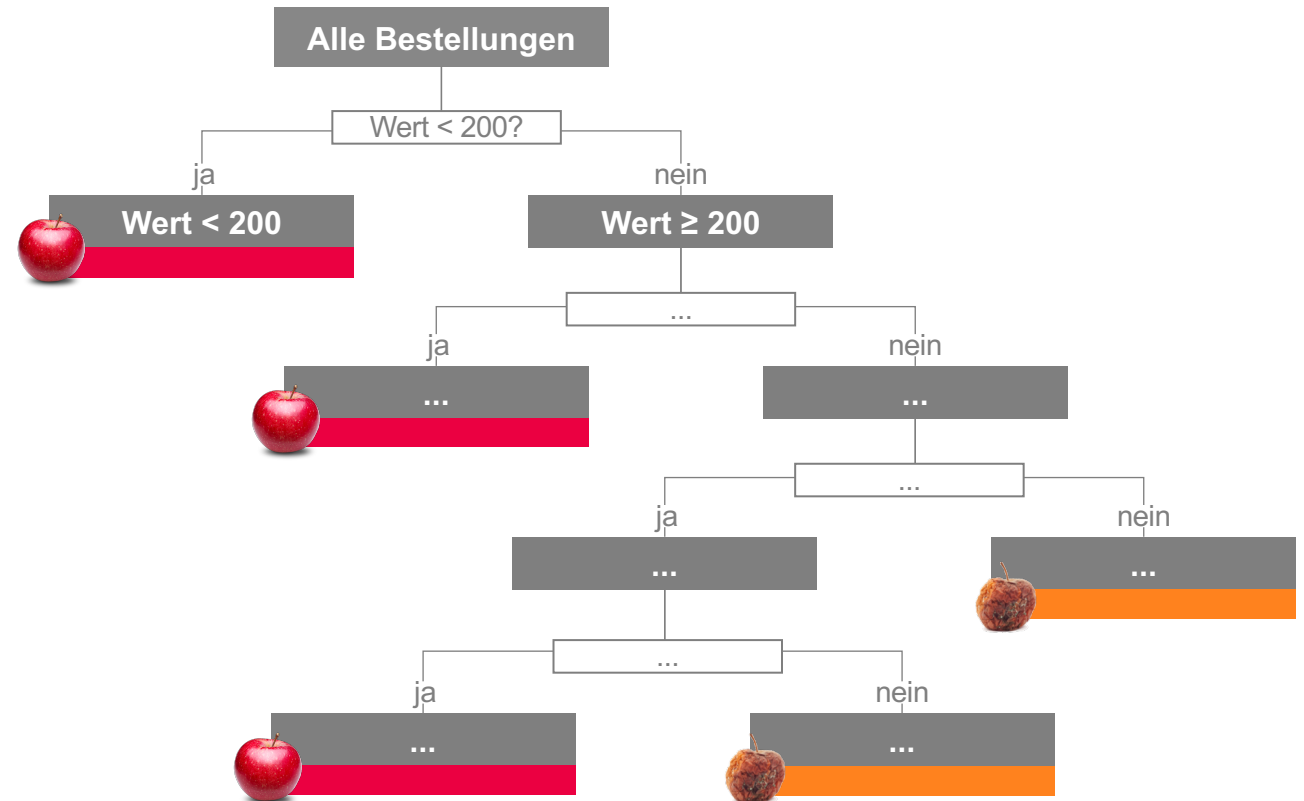
Merkmale „fauler Äpfel“



- Bestellt der Kunde zum ersten Mal?
- Ist die Bestellung ein teures Produkt?
- Ist der Artikel bereits bei anderen Betrugsversuchen aufgefallen (z. B.: Notebooks, Smartphones etc.)?
- Ist Rechnungsanschrift gleich Lieferanschrift?
- Ist die angegebene Adresse real?
- Passen Name und E-Mail zusammen?
- Um welche Uhrzeit wurde die Bestellung getätigt?
- Wie lange dauerte der Einkauf?

Vorgehensweise zur Betrugserkennung

Merkmale „fauler Äpfel“



Was tun mit faulen Äpfeln?

Implementierung der Lösung



Agenda

Inhalte für heute

1 Was ist Maschinelles Lernen?

2 Anwendungsfälle für den Mittelstand

2.1 Betrugserkennung

2.2 Predictive Maintenance

2.3 Data-as-an-Asset

3 Der Weg zum daten-getriebenen Unternehmen



Was ist Predictive Maintenance?

Prädiktive Instandhaltung



1 Sensoren sammeln Maschinendaten wie Druck, Durchlauf, Temperatur, Helligkeit, Vibration, Lärm



3 Der Algorithmus erkennt frühzeitig einen zukünftigen Ausfall und schlägt Alarm

2

Mit Hilfe von Maschinellem Lernen werden Modelle bestimmt, die Störungen vorhersagen können



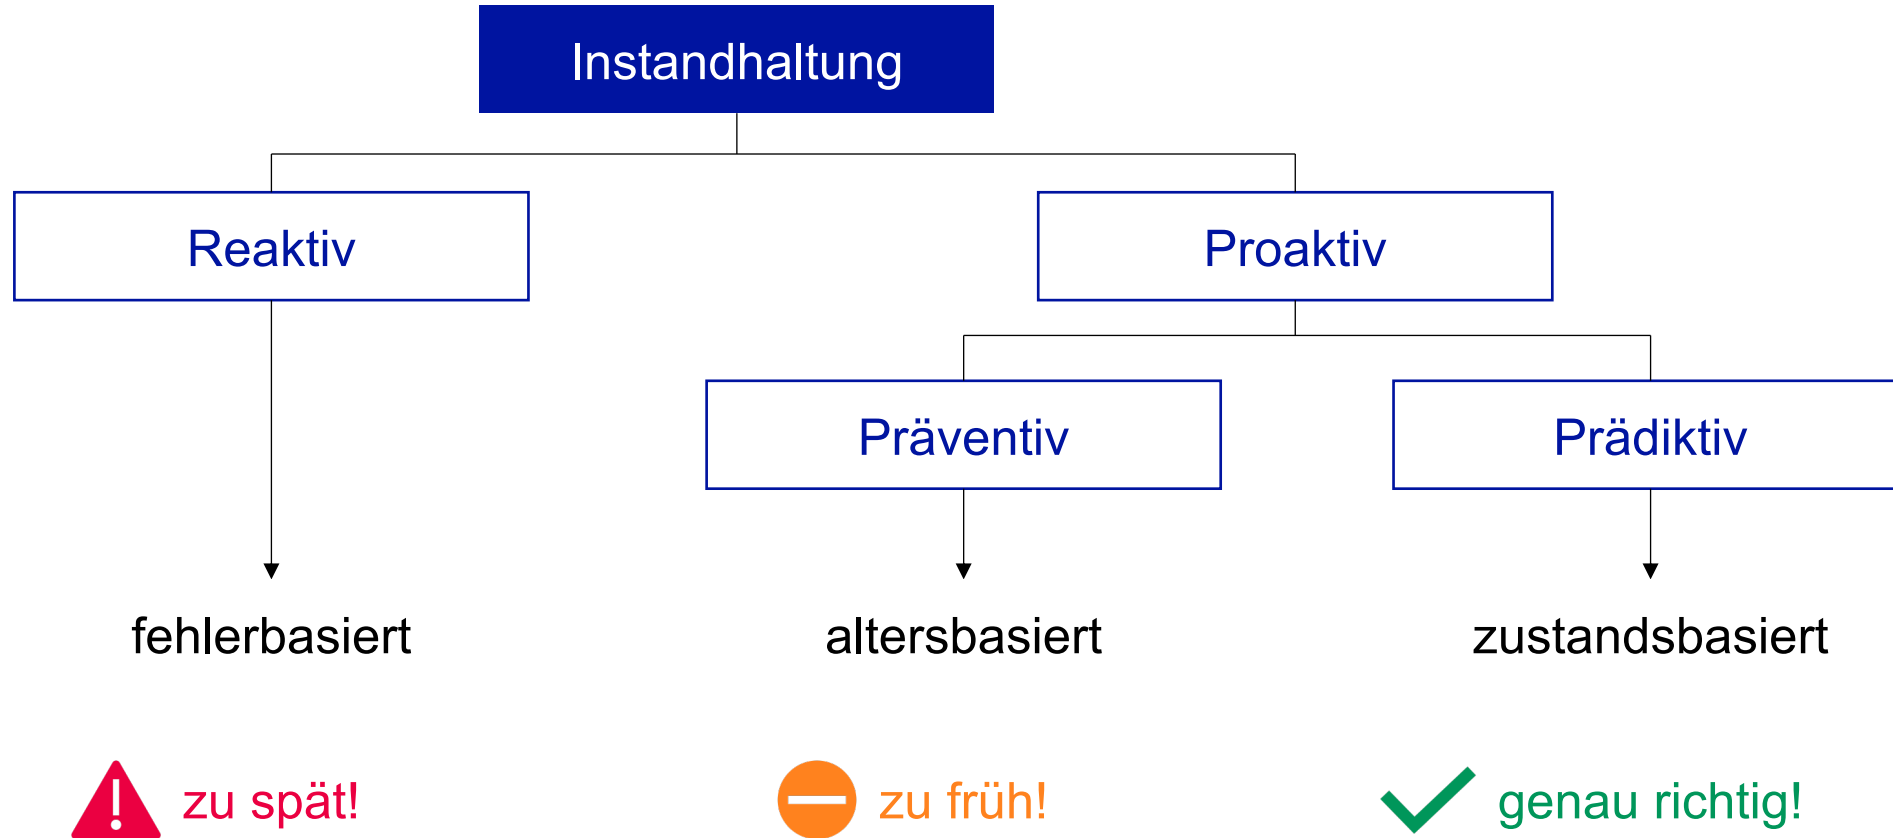
4

Die Instandhaltungsarbeiten können geplant werden; es kommt zu keinem Ausfall




Was ist Predictive Maintenance?

Abgrenzung zu reaktiver und präventiver Instandhaltung



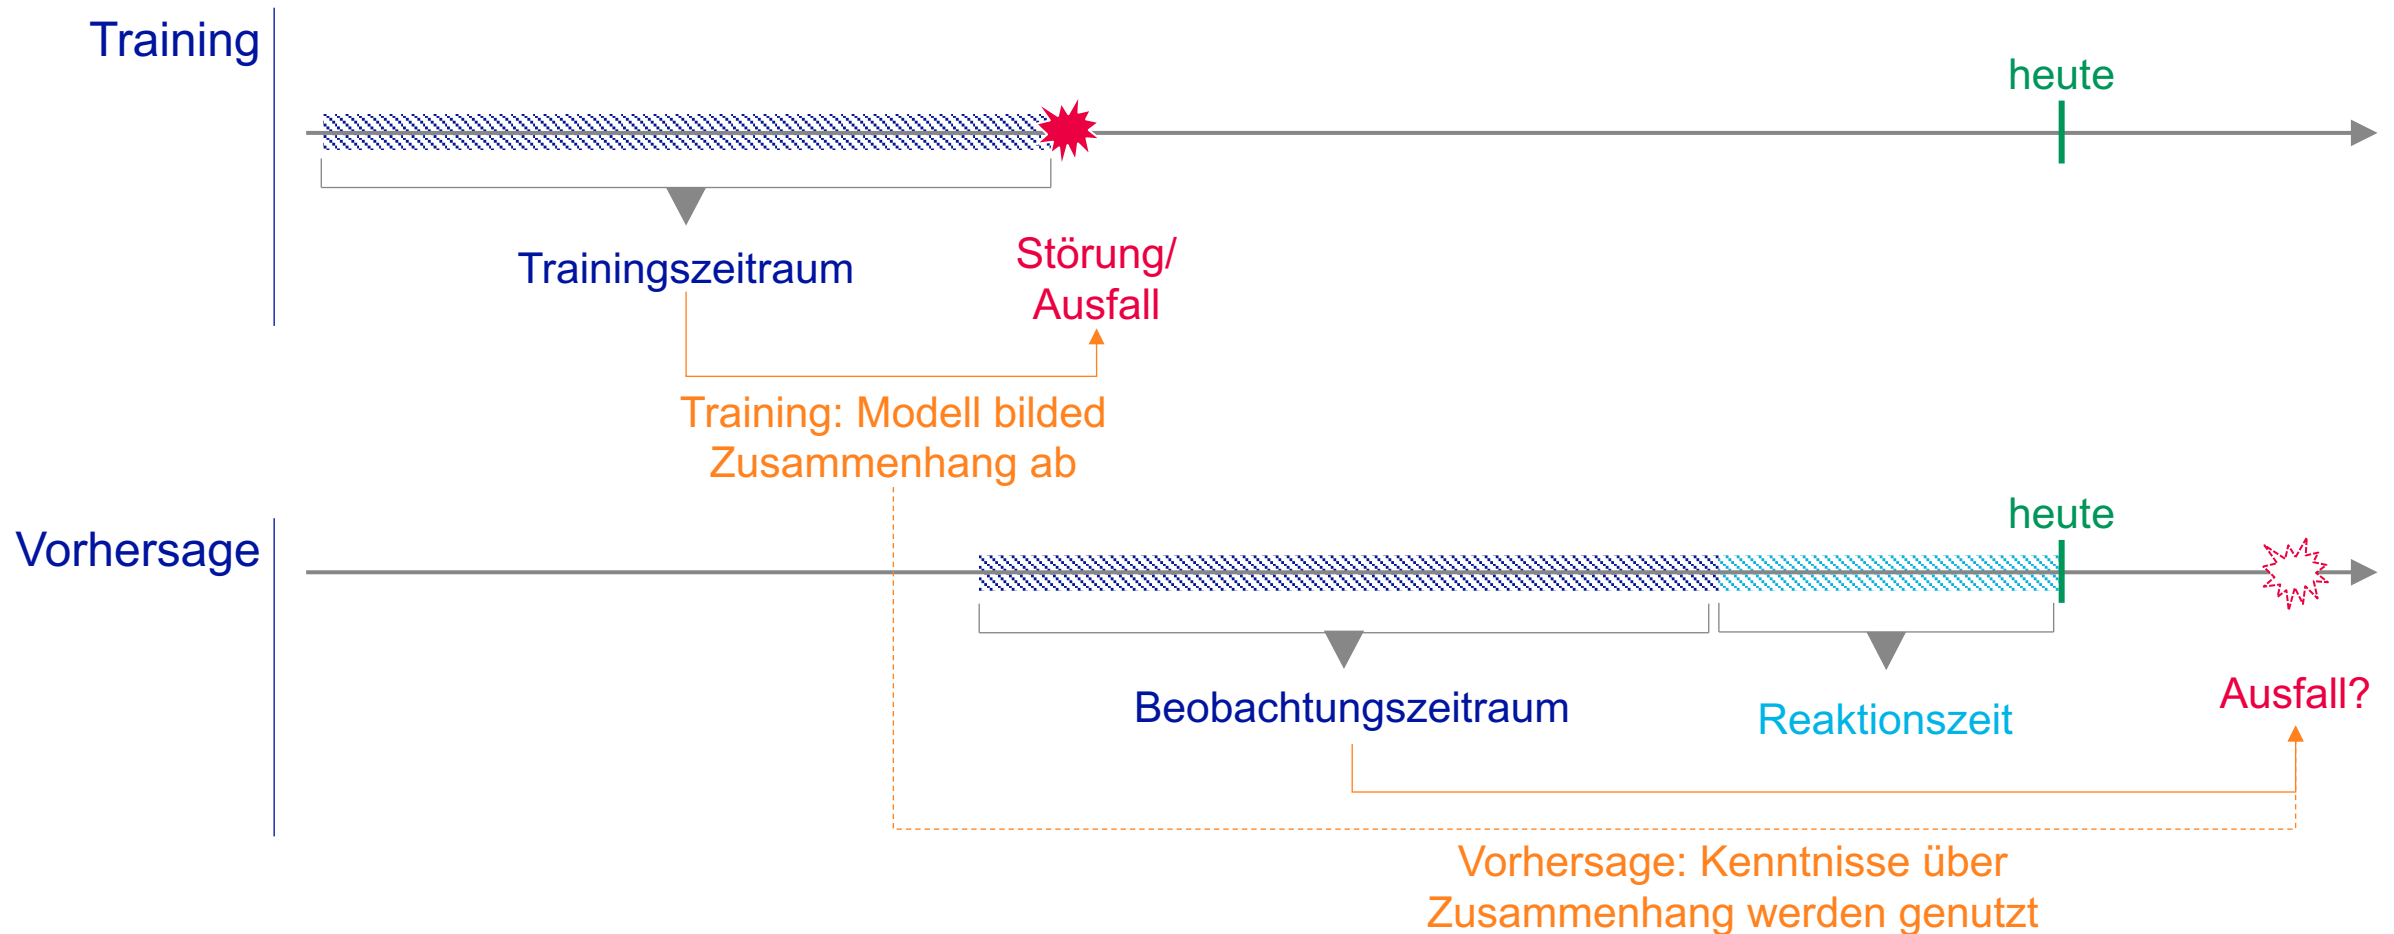
Funktionsweise: Vorhersagemodelle

Training und Vorhersage



Funktionsweise: Vorhersagemodelle

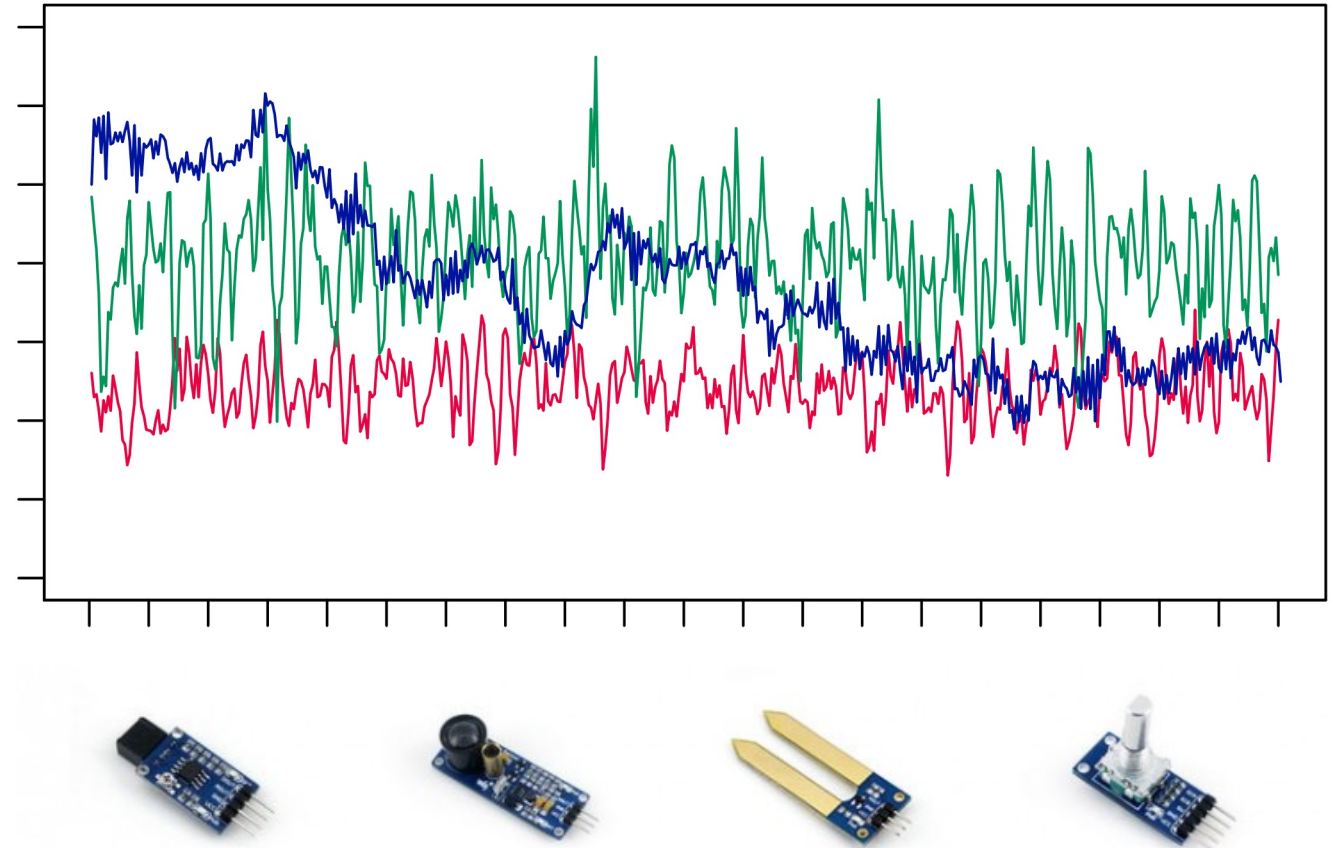
Training und Vorhersage



Datengrundlage: Sensordaten

Arten von Sensoren, Struktur der Daten

- Es gibt viele **verschiedene Arten von Sensoren**, die in den Maschinen Informationen erfassen können: Temperatur, Feuchtigkeit, Druck, Vibration, ...
- Alle haben gemeinsam, dass sie die **Information (fast) kontinuierlich** erfassen (Frequenz kann in der Regel festgelegt werden)
- **Datenqualität ist in der Regel gut**, da Daten automatisch (ohne menschliches Zutun) erfasst werden



Datengrundlage: Störungen, Ausfälle

Besonderheiten

Die Datengrundlage für das vorherzusagende Ereignis (Störung) häufig problematisch, denn:

- Störungen werden in der Regel **händisch erfasst**, dadurch sehr ungenau (z.B. exakter Zeitpunkt)
- Störungen werden **nur erfasst, wenn sie tatsächlich auftreten**, d.h. vor dem typischen Wartungszyklus
- Die **Störungsursache** ist häufig **nicht eindeutig identifizierbar**

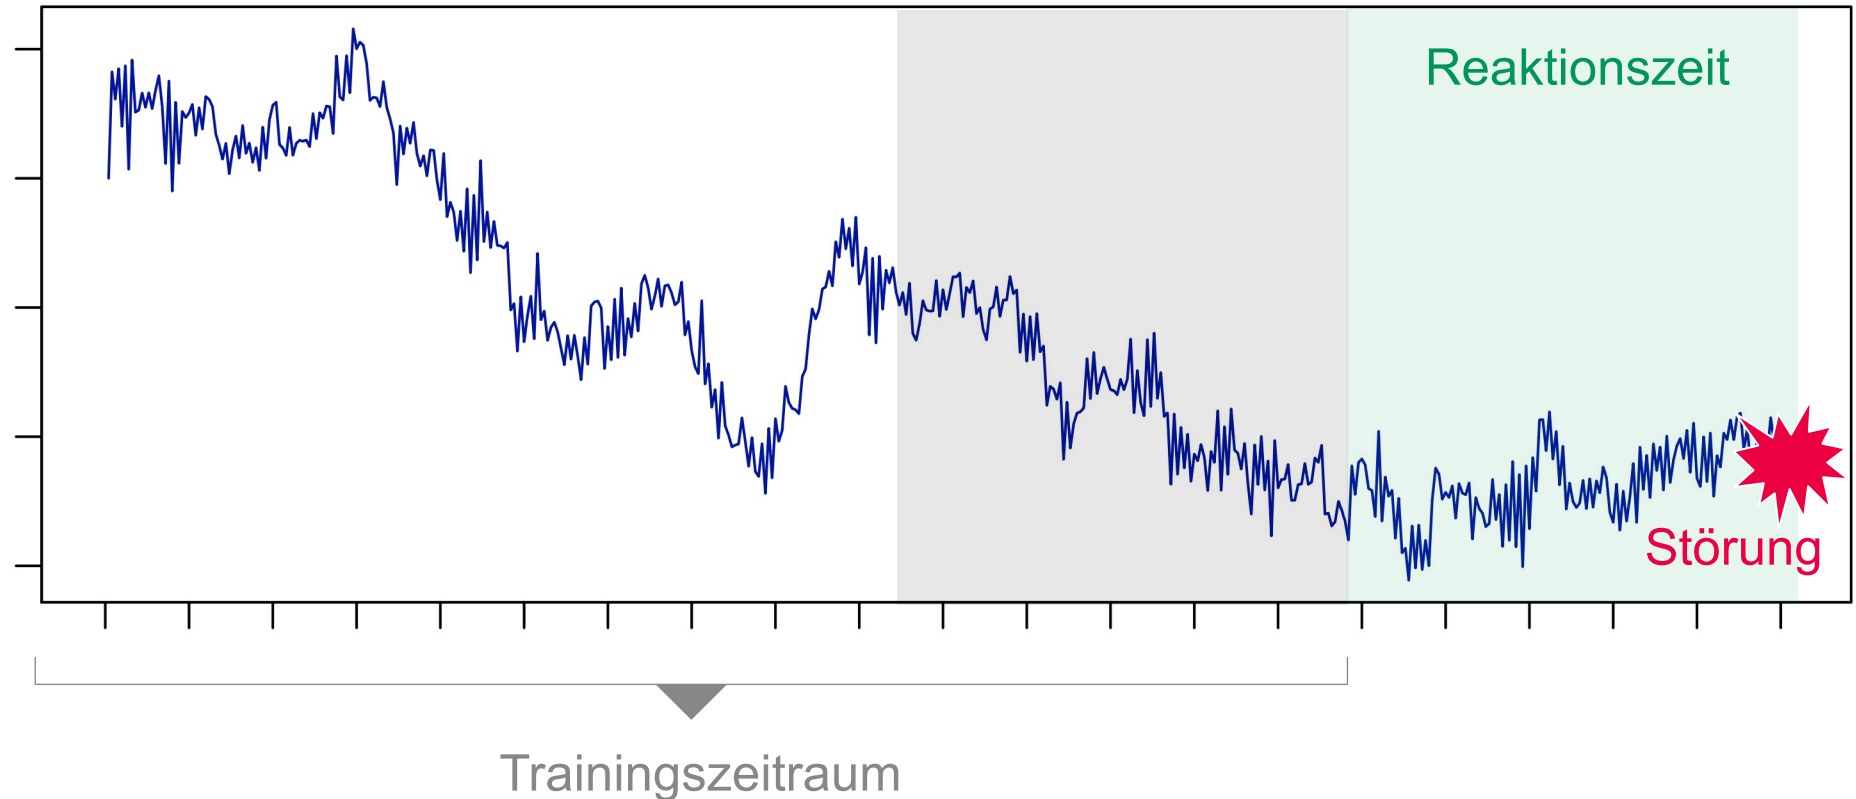


Verwendung von Sensordaten

Extraktion der nützlichen Informationen

Für jeden Sensor werden für variierende Zeitfenster bestimmte Verhaltensmuster untersucht:

- Durchschnittswert
- Extremwerte
- Volatilität
- Trend/Steigung
- Amplitude
- ...

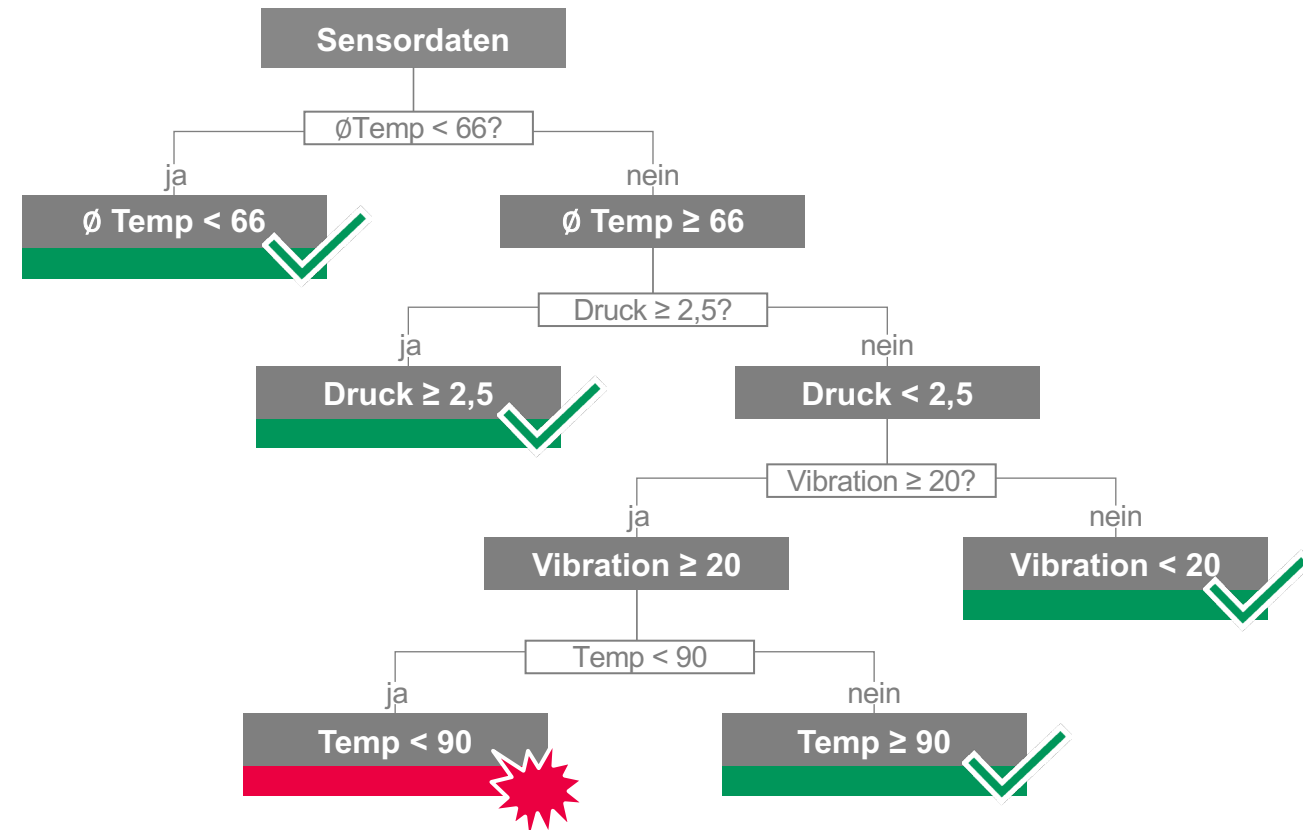


... außerdem betrachtet man Zusammenhänge zwischen verschiedenen Sensoren!

Funktionsweise von Vorhersagemodellen

Beispiel Entscheidungsbaum

- Die aus den Sensordaten erzeugten Informationen werden genutzt, um über einen Algorithmus **Regeln zu generieren**, die Auskunft darüber geben, unter welchen Voraussetzungen mit einem Ausfall zu rechnen ist
- Diese Regeln können sehr **komplex** werden
- Es werden sehr **viele unterschiedliche Regeln** erzeugt
- Alle Regeln gemeinsam ergeben ein **Modell zur Vorhersage von Störungen**



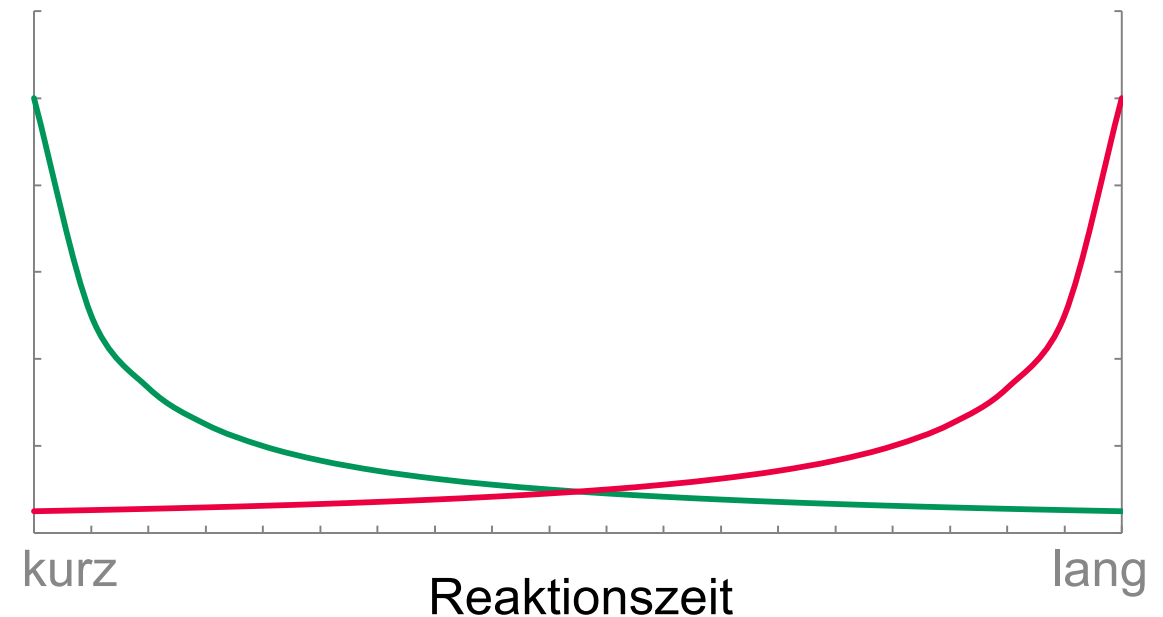
Vorhersagehorizont und -genauigkeit

Möglicher Zielkonflikt

- Im Idealfall möchten wir eine **möglichst lange Reaktionszeit** für die Reparatur bei gleichzeitig hoher Vorhersagegenauigkeit erreichen
- In der Regel lassen sich nicht Aspekte optimieren: **je länger die Reaktionszeit, um so geringer die Vorhersagegenauigkeit**
- Daher muss im Einzelfall genau abgewogen werden

Vorhersage-
genauigkeit

Kosten-
ersparnis



Ökonomische Überlegungen

Wann lohnt sich Predictive Maintenance?

Überlegungen für eine Kosten-Nutzen Abwägung:



Kosten der „Downtime“

Kosten eines Ausfalls sind extrem hoch, so dass sich ein rechtzeitiger (und möglicherweise verfrühter) Austausch lohnt



Kosten der Reparatur

Kosten einer Reparatur sind nicht so hoch, so dass es möglicherweise profitabler ist, bis zum tatsächlichen Ausfall abzuwarten

Ausblick

Weitere Themenfelder im Bereich IoT Analytics

Energie-
effizienz



Änderung von Produktionsprozessen zur **Minimierung des Energieverbrauchs** bei gleichbleibender Qualität und Geschwindigkeit

Prozess-
optimierung



Anpassung von Prozessabläufen zur **Maximierung der Kapazität bzw. Minimierung der Produktionsdauer** bei gleichbleibender Qualität

Yield
Optimization



Einstellung von Produktionsprozessen zur **Maximierung des Ertrags** bzw. der **Reinheit oder Qualität** der Endprodukte

Agenda

Inhalte für heute

1 Was ist Maschinelles Lernen?

2 Anwendungsfälle für den Mittelstand

2.1 Betrugserkennung

2.2 Predictive Maintenance

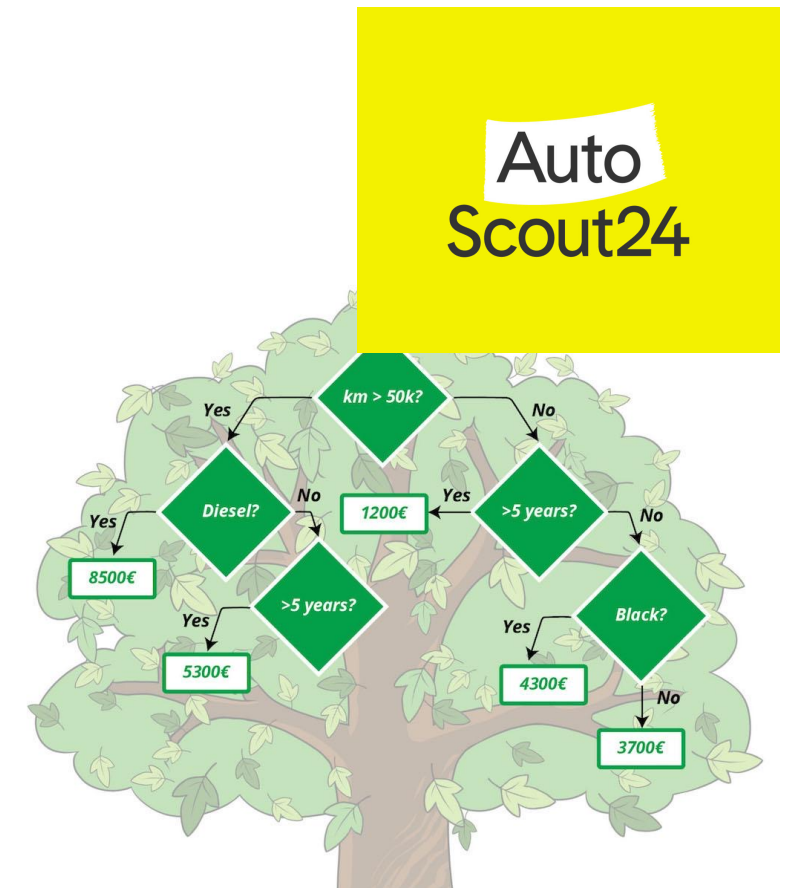
2.3 Data-as-an-Asset

3 Der Weg zum daten-getriebenen Unternehmen



Daten als Rohstoff oder Produkt

Identifikation potentieller Interessenten



Agenda

Inhalte für heute

1 Was ist Maschinelles Lernen?

2 Anwendungsfälle für den Mittelstand

3 Der Weg zum daten-getriebenen Unternehmen



Daten-getriebene Unternehmen

Strategische Ausrichtung

In God we trust.
All others
must bring data.

William Edwards Deming



Datenstrategie

Entwicklung zum daten-getriebenen Unternehmen

Ziel: Entwicklung des Unternehmens hin zu daten-getriebenen Geschäftsmodellen und -prozessen, um Wettbewerbsvorteile zu erlangen oder einzuholen.



1. Schritt: Überblick über die Datenlandschaft des Unternehmens und potentieller externer Datenquellen; Bewertung der Datenqualität



2. Schritt: Ermittlung konkreter profitabler Anwendungsfälle sowie entsprechender Konzepte zur unmittelbaren Umsetzung



3. Schritt: Festlegung der Agenda zur schrittweisen Steigerung des digitalen und analytischen Reifegrads des Unternehmens



Ich freue mich auf Ihre Fragen und eine gute Diskussion!

Prof. Dr. Michael Bücker

Professor für Data Science

Corrensstraße 25
D-48149 Münster

fon +49 (0)251.83 65-615
fax +49 (0)251.83 65-502

michael.buecker@fh-muenster.de
www.fh-muenster.de

