



Künstliche Intelligenz in der Logistik

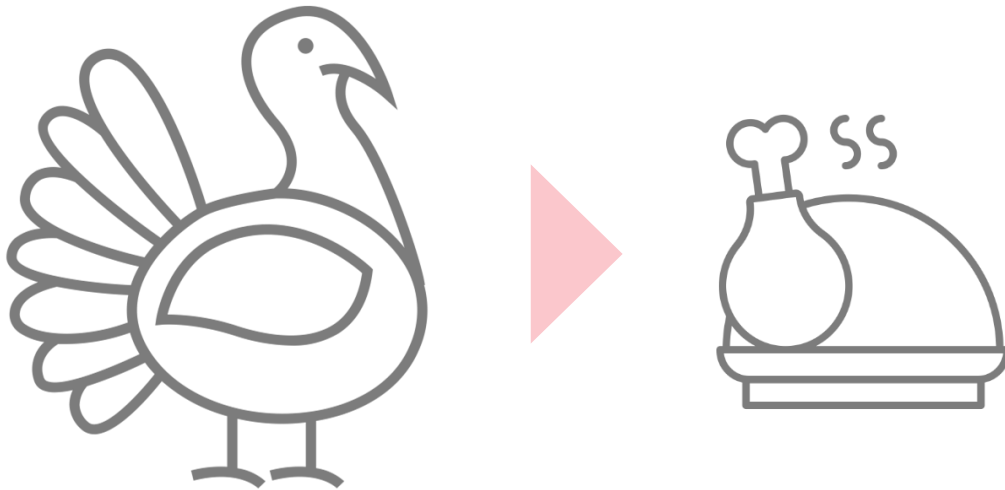
Können Störungen in Transportnetzwerken sicher erkannt und besser bewältigt werden?



Manuel Weinke


Deutscher Logistik-Kongress
24.10.2019

Truthahn-Illusion



Truthahn ist aufgrund fehlender Informationen nicht in der Lage, den Bruch des Trends (regelmäßiges Füttern) an Thanksgiving zu erkennen

Machine Learning

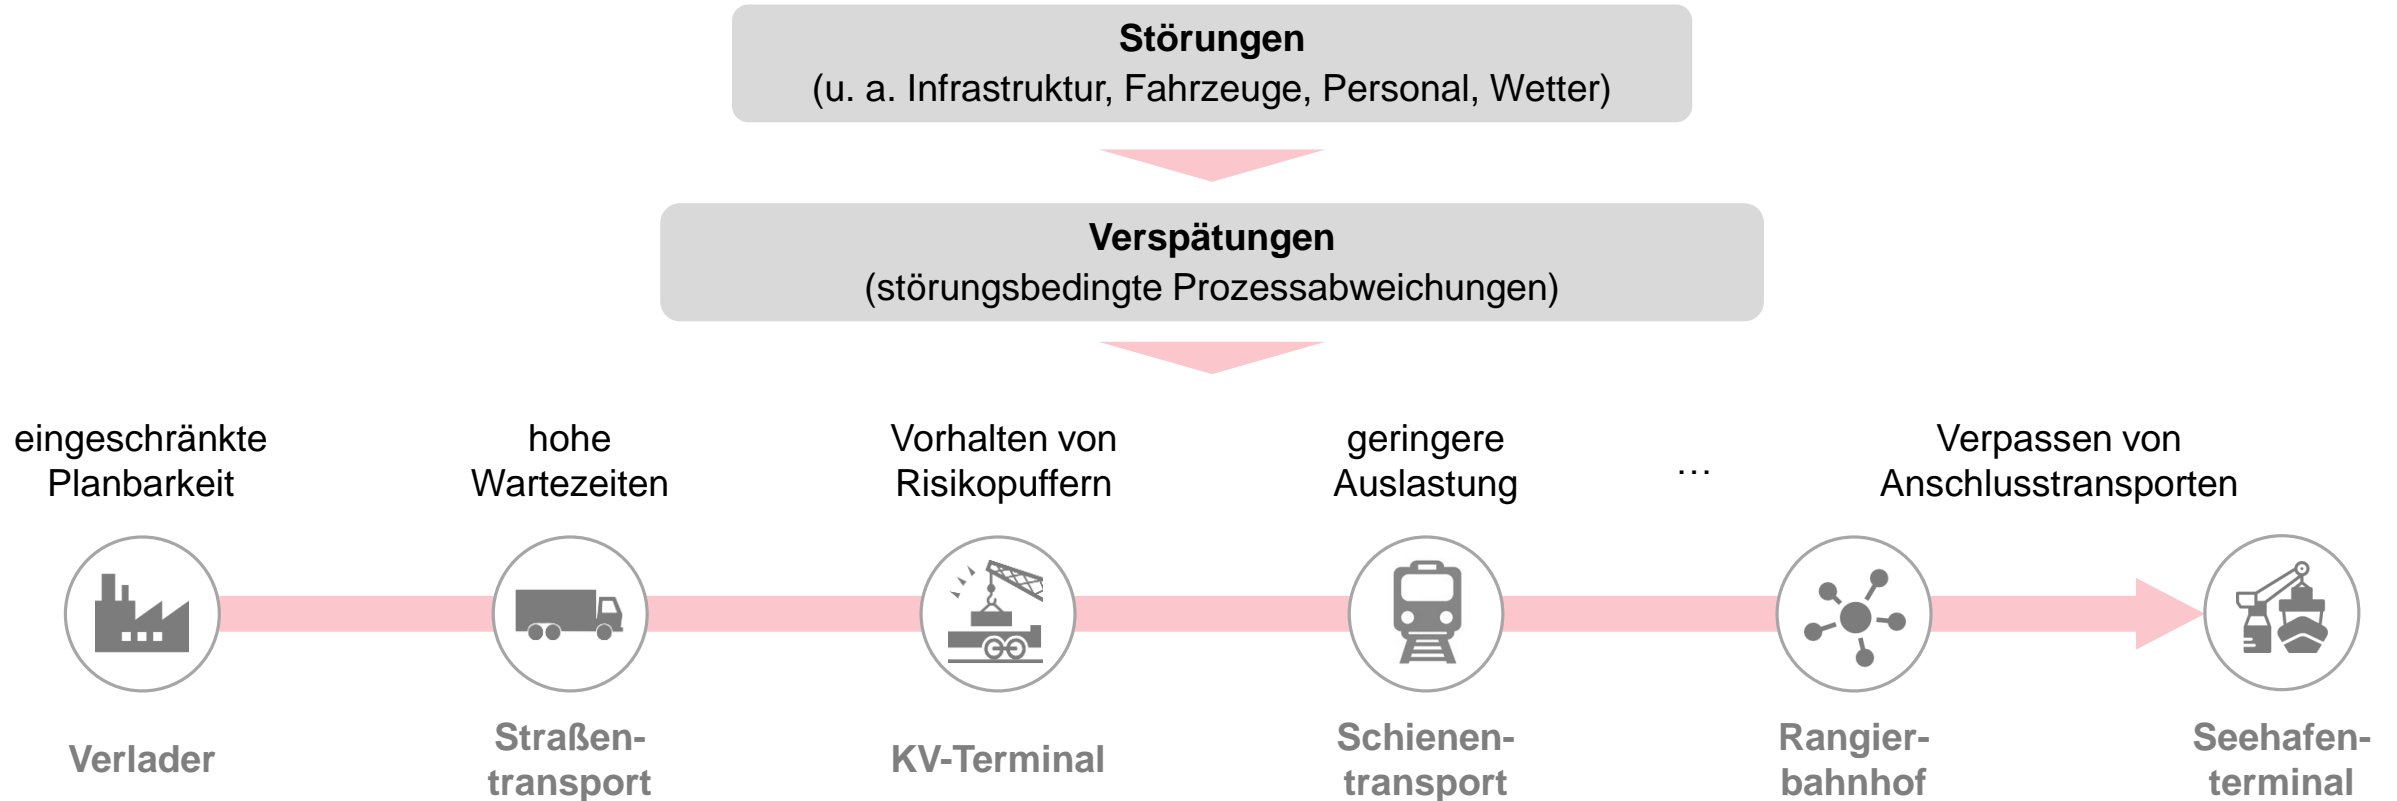


Ermöglicht die Identifizierung komplexer (menschlich schwer erfassbarer) Wirkungszusammenhänge für den Blick in die Zukunft – unter Nutzung von historischen Daten

Potenziale? Grenzen?

Anwendungsfeld: Door-to-Port der maritimen Transportkette

Vielzahl von Störungen mit Einfluss auf die Prozesszeiten



Handlungsspielraum auf Basis von Echtzeitinformationen ist begrenzt

Proaktive Erkennung von Störungen und Einleitung von geeigneten Steuerungsmaßnahmen notwendig

Projekt SMECS: Smart Event Forecast for Seaports

Erhöhung der Zuverlässigkeit von Transportnetzwerken durch KI-Assistenz



TU Berlin
FG Logistik
(Leitung)



DB Cargo



Kühne
Logistics
University

Entwicklung eines Entscheidungsunterstützungssystems, welches durch die **proaktive Erkennung von Verspätungen mittels KI** ein zielgerichtetes und effizientes **Störungsmanagement** für die **maritime Transportkette** ermöglicht.



Bundesministerium
für Verkehr und
digitale Infrastruktur



IHATEC
Innovative
Hafentechnologien

Daten aus 15
IT-Systemen

Lernfähiger
Algorithmus

Interaktive
Web-App

Prozess-
daten



Infrastruktur- und
Ressourcendaten



externe
Daten



historische Daten für 4 Jahre, u. a. 50.000 Schienen- und 120.000 Straßentransporte mit 8,6 Mio. Events



Prognose der
Prozesszeiten (ETA)

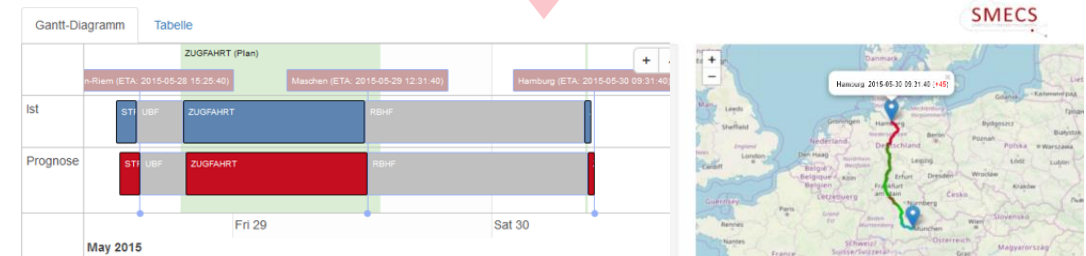


Detektion von
Konfliktfällen



Maßnahmen-
generierung

7 prozessspezifische Prognosesysteme mit
Ø 300 Teilmodellen je Transportauftrag

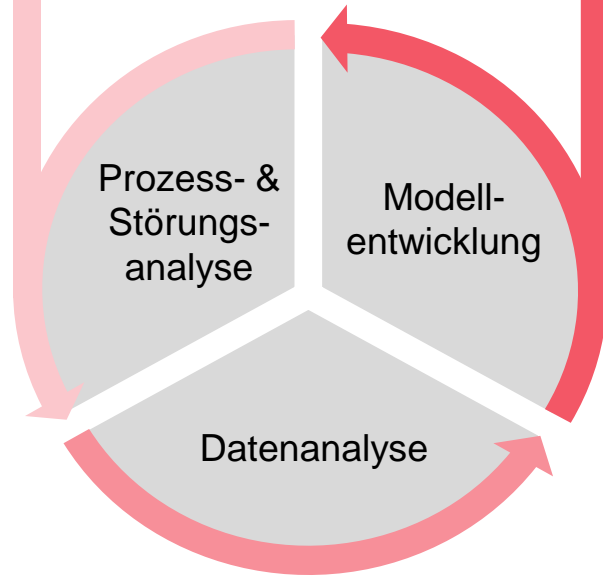


Lösungsansatz: Mehrstufiges, iteratives Verfahren

Abbildung realer Störungsszenarien durch datenbasierte Prognosemodelle



- Aufnahme von physischen und informatorischen **Prozessen**
- Experten- und datenbasierte Identifizierung relevanter **Störungen** und **Einflussfaktoren**, die zu Prozessabweichungen führen
- Analyse der **Ursachen** und **kausalen Zusammenhänge**



- Identifizierung geeigneter **Datenarten** und **-quellen**, die Störungen und Einflussfaktoren abbilden
- Beschaffung und Analyse der Daten

- Unterteilung des Prognoseziels in separate **Teilprobleme**
- Entwicklung problemspezifischer **Prognosemodelle**
- Einsatz verschiedener **ML-Verfahren**

Prozess			
Teilproblem	...	Prognose Abfahrtszeit	Prognose Fahrzeit
Prognoseart	...	Regression	
Granularität	...	je Betriebsstellenabschnitt ein Modell	
ML-Verfahren	...	insb. Random Forest und Gradient Boosting	

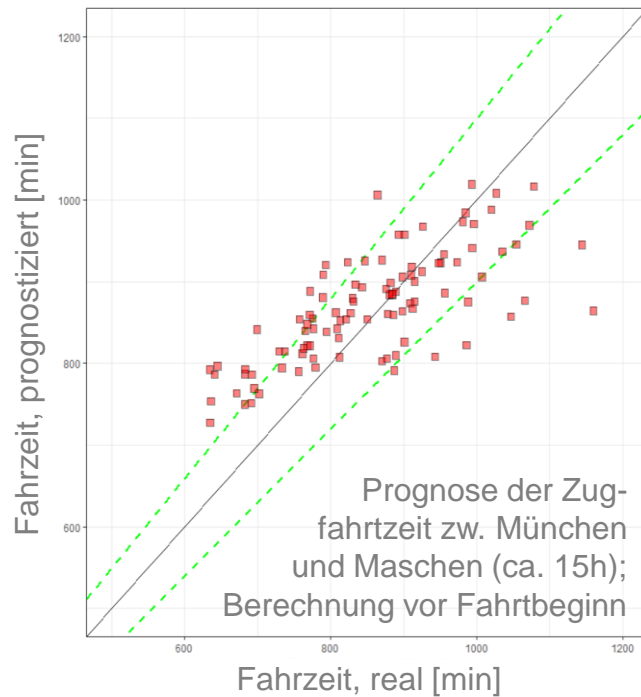
Erkenntnis: Beispiel des Schienentransports

KI-Ansatz führt zu vielversprechenden Prognoseergebnissen

Ausgangssituation

„Prognose“ durch Betrachtung der \emptyset -Fahrzeit je Relation

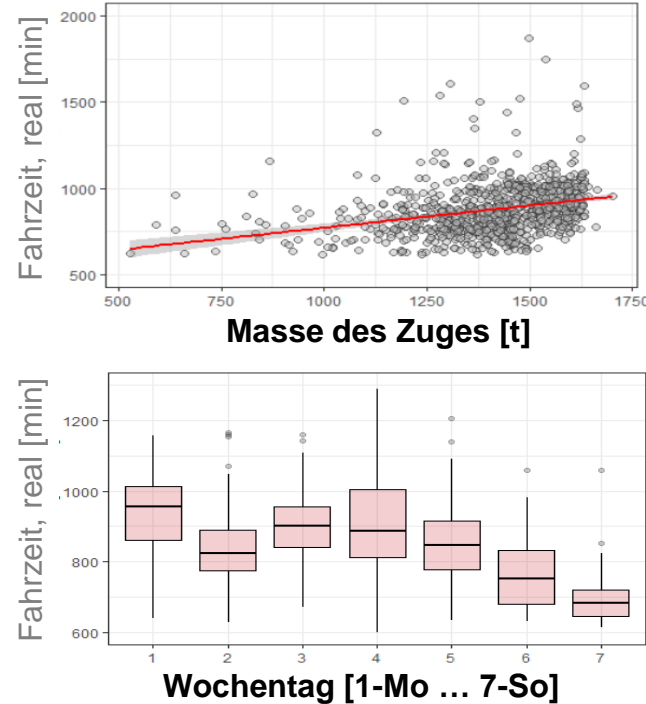
Prognosequalität*: **68%**



Einflussfaktoren

Identifizierung von relevanten Einflussfaktoren der Fahrzeit


Auswahl (ca. 50 Faktoren)



Prognoseergebnis

Prognose durch Berücksichtigung relevanter Einflussfaktoren

Prognosequalität*: **86%**



VIELEN DANK!



Dipl.-Ing. Manuel Weinke

Technische Universität Berlin
Fachgebiet Logistik, Prof. Dr.-Ing. Frank Straube

Wissenschaftlicher Mitarbeiter
Projekt SMECS

weinke@logistik.tu-berlin.de