



Universität der Bundeswehr München
Institut für Technische
Produktentwicklung



Künstliche Intelligenz im Produktportfolio- und Variantenmanagement

Machine Learning zur Handhabung der Portfoliokomplexität am Beispiel der MAN Truck & Bus SE

Jan Mehlstäubl - Universität der Bundeswehr München
Dr.-Ing. Felix Braun - MAN Truck & Bus SE



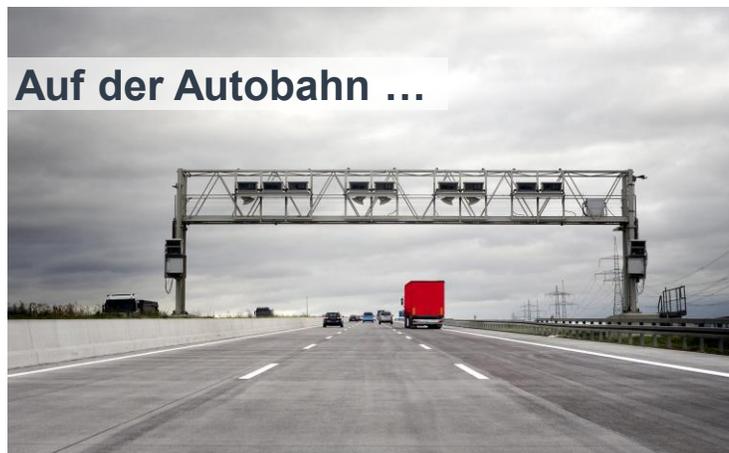
Bayerische
Forschungsstiftung

Wenn man normalerweise an einen Lkw denkt, ...



...hat man eine klare Vorstellung.

... jedoch ist der Nutzfahrzeugmarkt durch eine große Varianz geprägt!

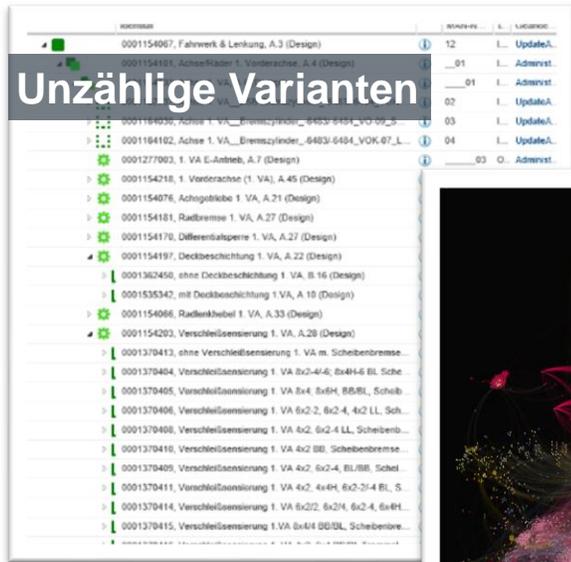


Dieses umfangreiche Portfolio mit zahlreichen Regeln und Objekten erfordert mehr als nur eine manuelle Analyse

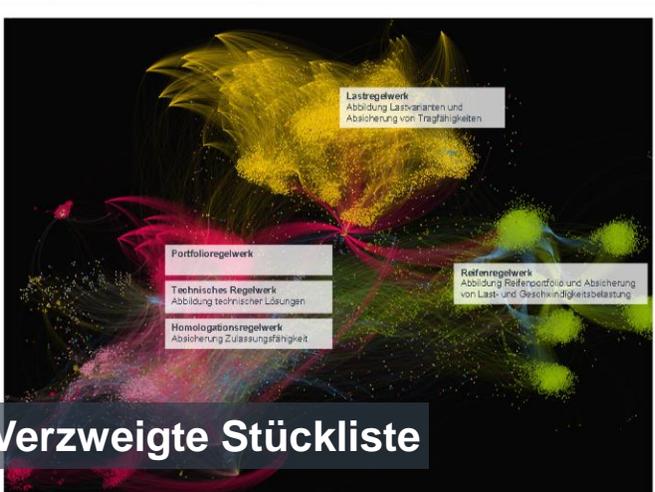
Ein komplexes Produktportfolio mit zahlreichen unterschiedlichen Varianten ist erforderlich

Entwicklung und Wartung stark abhängig von manuellen und erfahrungsbasierten Prozessen

Unzählige Varianten



Verzweigte Stückliste



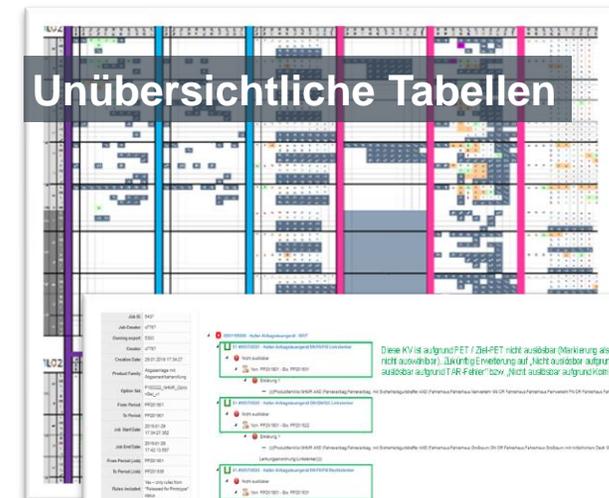
Lastregelwerk
Abbildung Lastvarianten und Absicherung von Tragfähigkeiten

Referenzregelwerk
Abbildung Referenzportfolio und Absicherung von Last- und Geschwindigkeitsbelastung

Technisches Regelwerk
Abbildung technischer Lösungen

Homologationsregelwerk
Absicherung Zulassungsfähigkeit

Unübersichtliche Tabellen



Vielschichtige Fehlerprotokolle



Diese KV ist aufgrund PET / Ziel-PET nicht ausbar (Markierung als Fehler, da aufgrund KV-Übergkeit nicht ausbar), zurück Ersetzung auf „Nicht ausbar aufgrund KV-Übergkeit“ bzw. „Nicht ausbar aufgrund TAR-Fehler“ bzw. „Nicht ausbar aufgrund Komplexität“ getagt.

Diese Lücke entsteht durch einen späteren PET der KV-0001 und 0003 (PET: XXXXXX), d.h. dieser Ausdruck müsste jeweils im Profil für den ...

In diesem Zeitraum gibt es gar keine auswählbare KV innerhalb der K, dh. entweder kam nie ein Fahrzeug gebaut werden oder die Komponente ist nicht Teil des Fahrzeuges.

Bei einem so komplexen Produktportfolio müssen wir modernste IT-Lösungen einsetzen, um alle Varianten zu beherrschen!

Zielsetzung des Forschungsprojekts

Systematische Anwendung von Machine Learning zur Unterstützung von Aktivitäten und Entscheidungen im Produktportfolio- und Variantenmanagement in der Nutzfahrzeugindustrie



Meilenstein 1

Verständnis für den Einsatz von KI im Kontext von Produktportfolio- und Variantenmanagement



Meilenstein 2

Umsetzung und Evaluation ausgewählter Anwendungsfälle

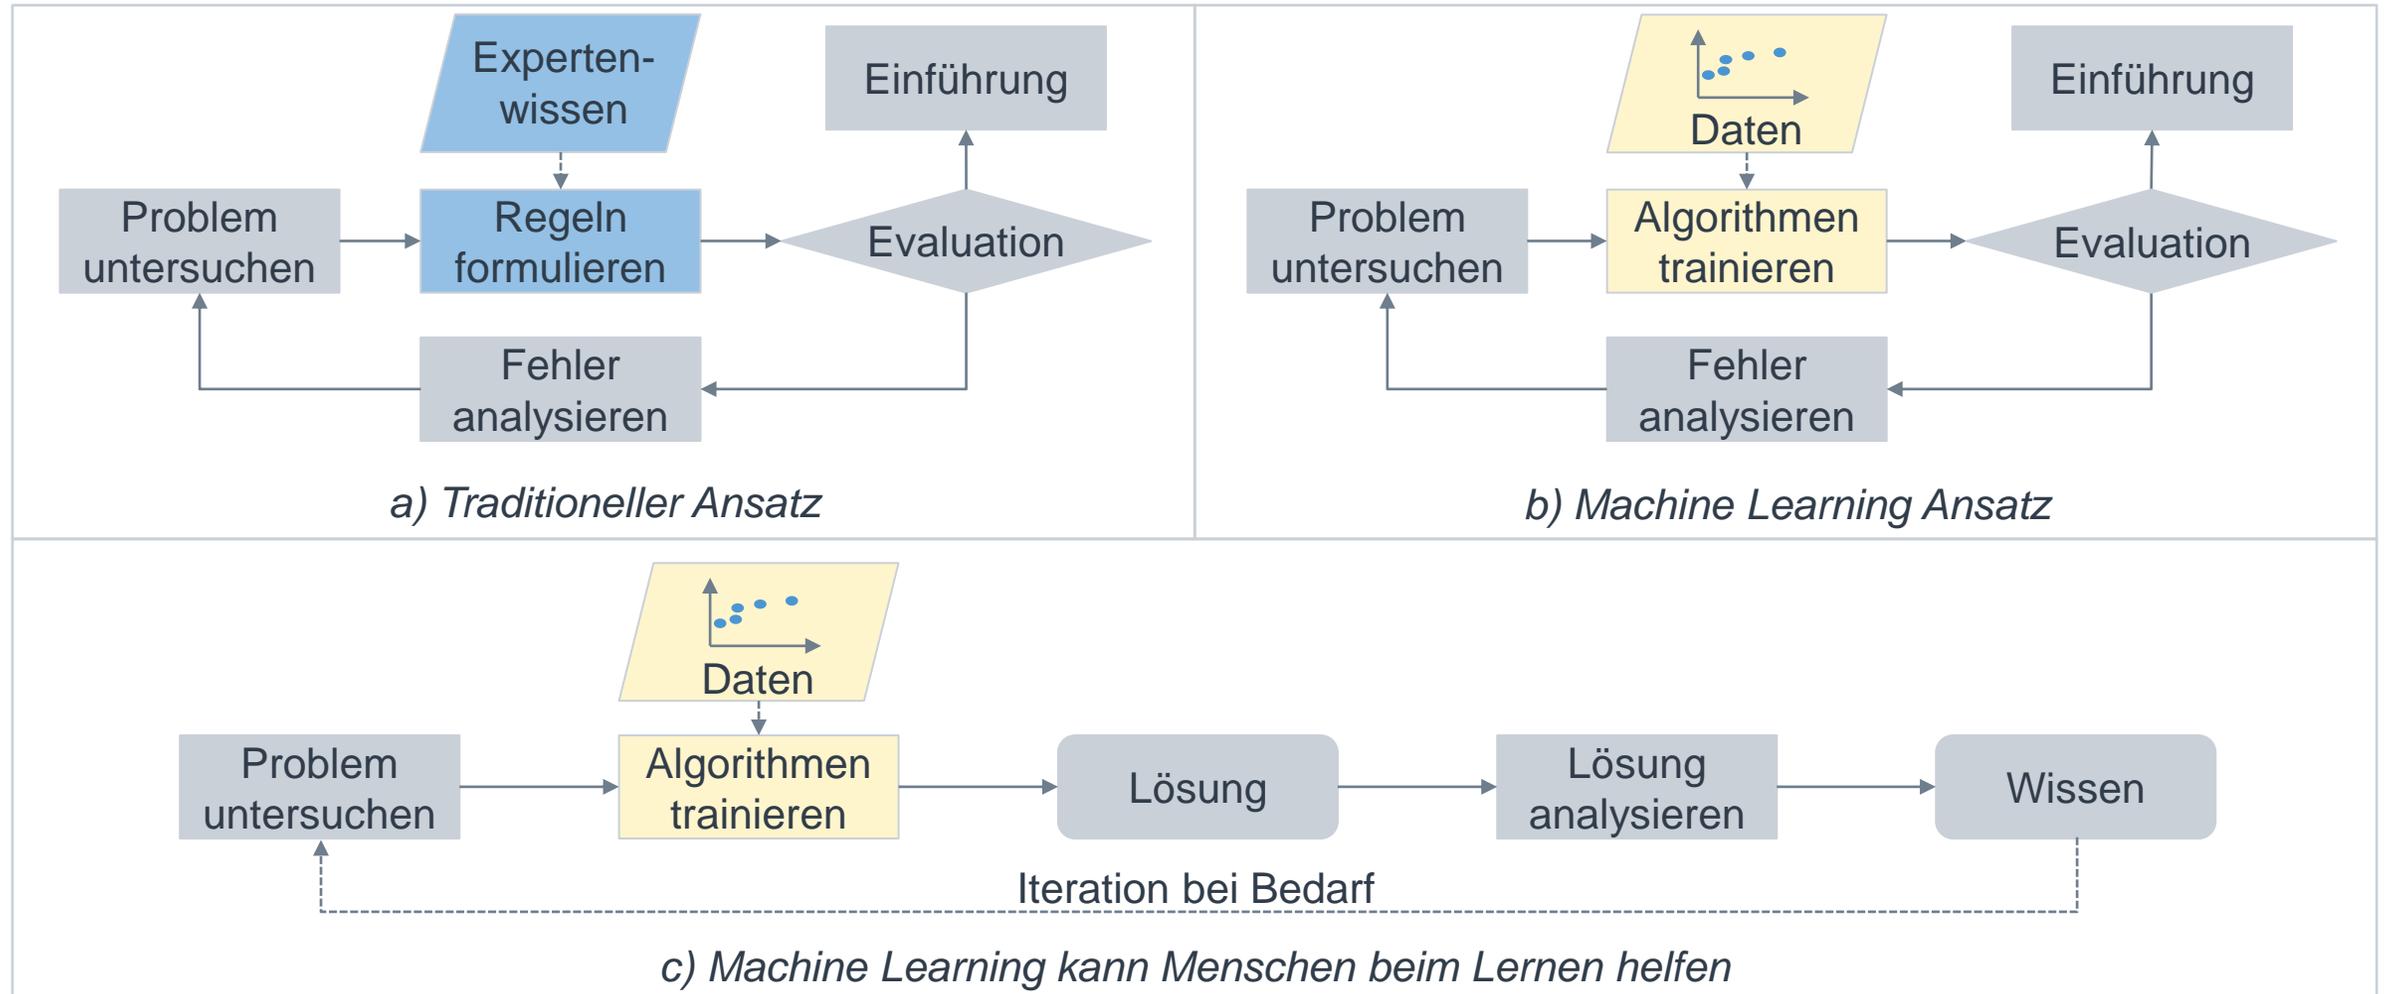


Meilenstein 3

Zusammenfassung der Ergebnisse in einem Framework für den systematischen Einsatz von Machine Learning

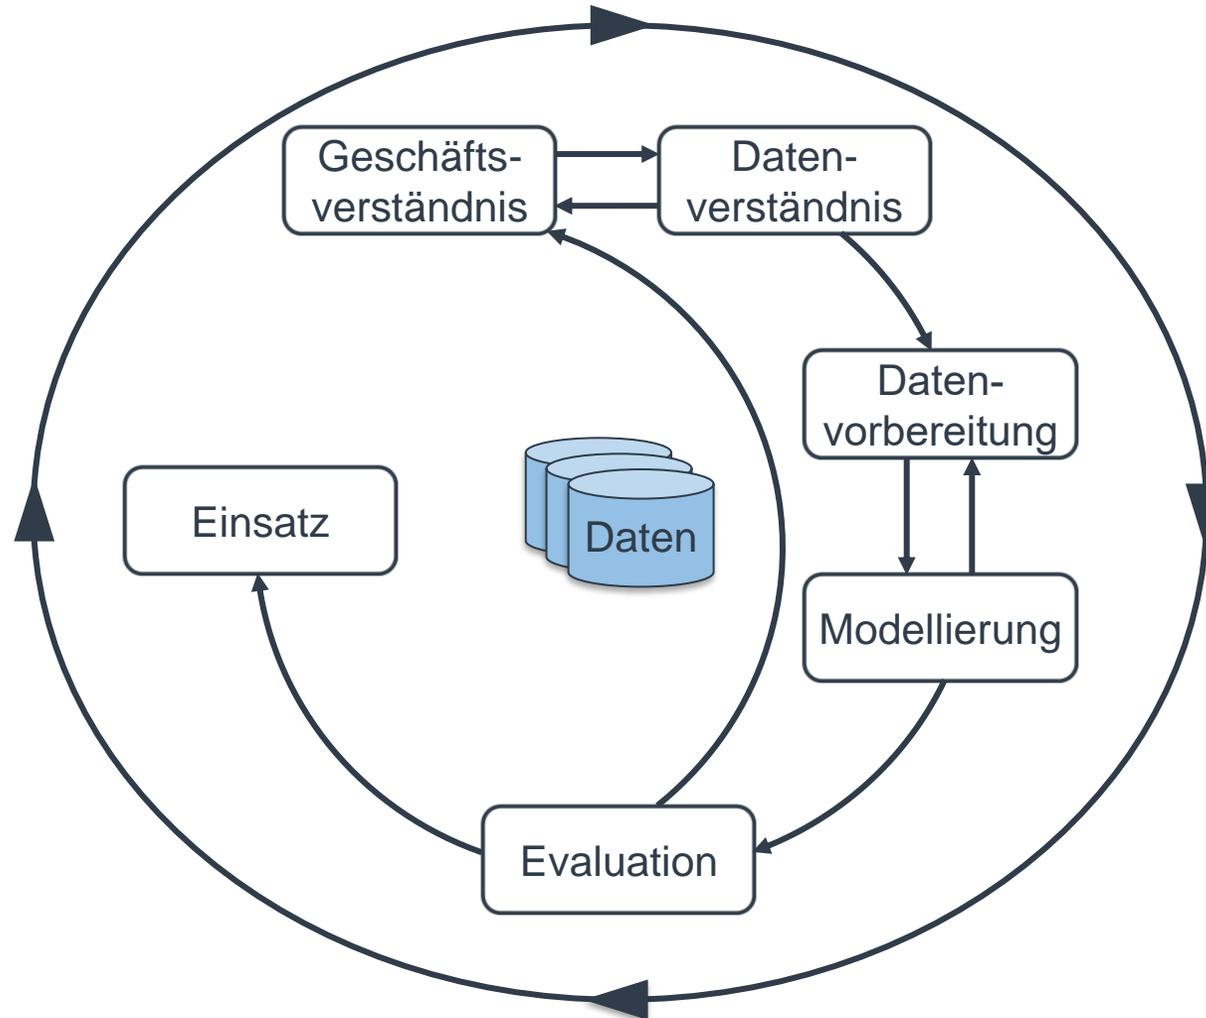


Potenziale von Machine Learning



Reference: Géron, A. (2017). Hands-on machine learning with Scikit-Learn and TensorFlow

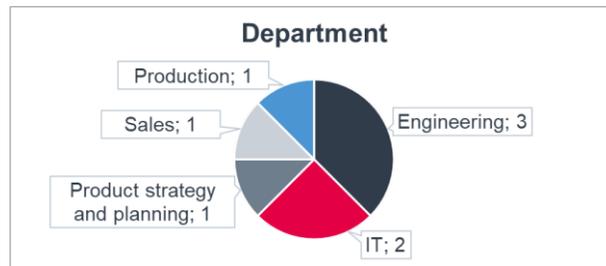
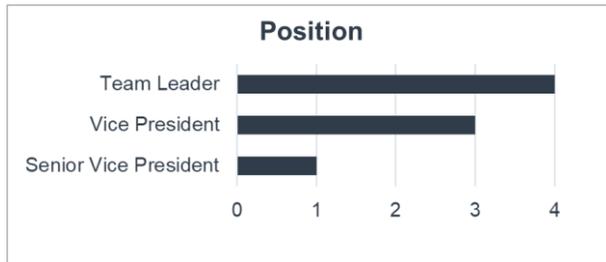
Datenanalyseprozess für den systematischen Einführung von Machine Learning



Reference: Wirth, R., & Hipp, J. (2000). CRISP-DM :
Towards a Standard Process Model for Data Mining

Interviewstudie zur Entwicklung eines Geschäftsverständnisses

Aufbau der Interviewstudie



Schlüsselekenntnisse aus den Interviews bei MAN Truck & Bus SE

- Wenig Erfahrung mit ML, aber hohe Erwartungen
- Erste Pilotprojekte wurden gestartet, haben sich aber noch nicht konsolidiert
- Die Herausforderungen können in die Kategorien Wissen, Unternehmenskultur und -strategie sowie Daten eingeteilt werden
- Wertvolle Anwendungsfälle für ML wurden sowohl im Produktportfolio als auch im Variantenmanagement identifiziert

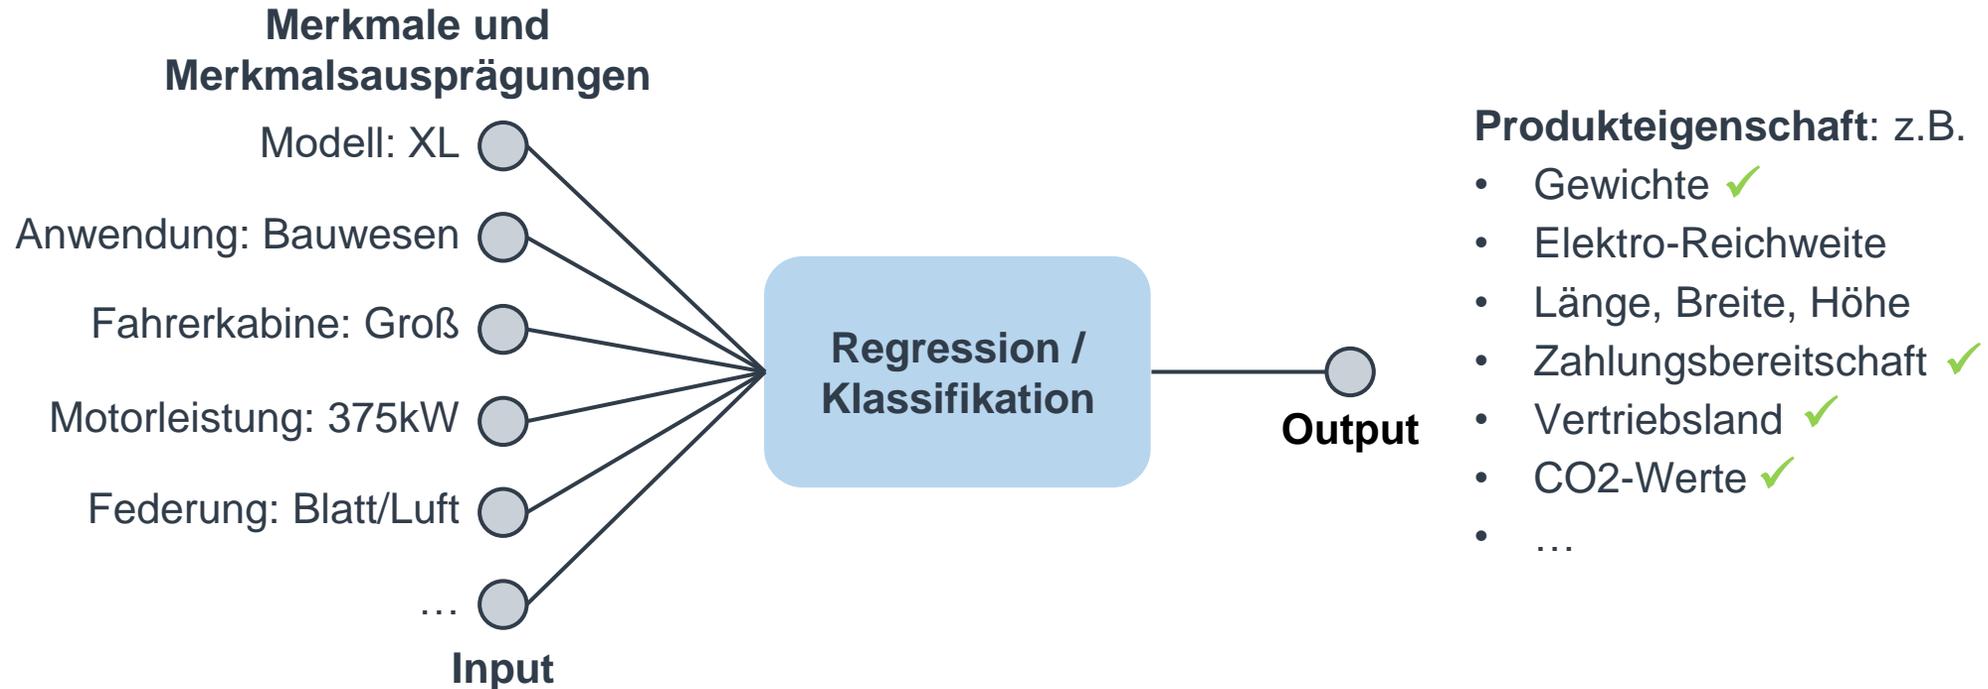
No.	Description	Assessment				Average
		Value (1=very low; 5=very high)	Effort (1=very high; 5=very low)	Degree of innovation (1=very low; 5=very high)	Data availability (1=very low; 5=very high)	
1	Product Attribute Prediction	4	3	4	4	3,75
2	Portfolio Decision Proposals	5	3	5	2	3,75
3	Identify similar components and modules	5	3	3	4	3,75
4	Simulate the effects of Portfolio Changes	5	3	4	1	3,25
5	Determine Part Selection Rules	4	2	4	3	3,25
6	Clustering of similar configurations	4	3	2	4	3,25
...

Reference: Mehlstäubl, J., Braun, F., & Paetzold, K. (2021). Artificial Intelligence in Product Portfolio and Variety Management in Commercial Vehicle Industry – An Overview about Expectations, Challenges and Use Cases

Datenverständnis im Produktportfolio- und Variantenmanagement



Prognose von Produkteigenschaften: Grundarchitektur

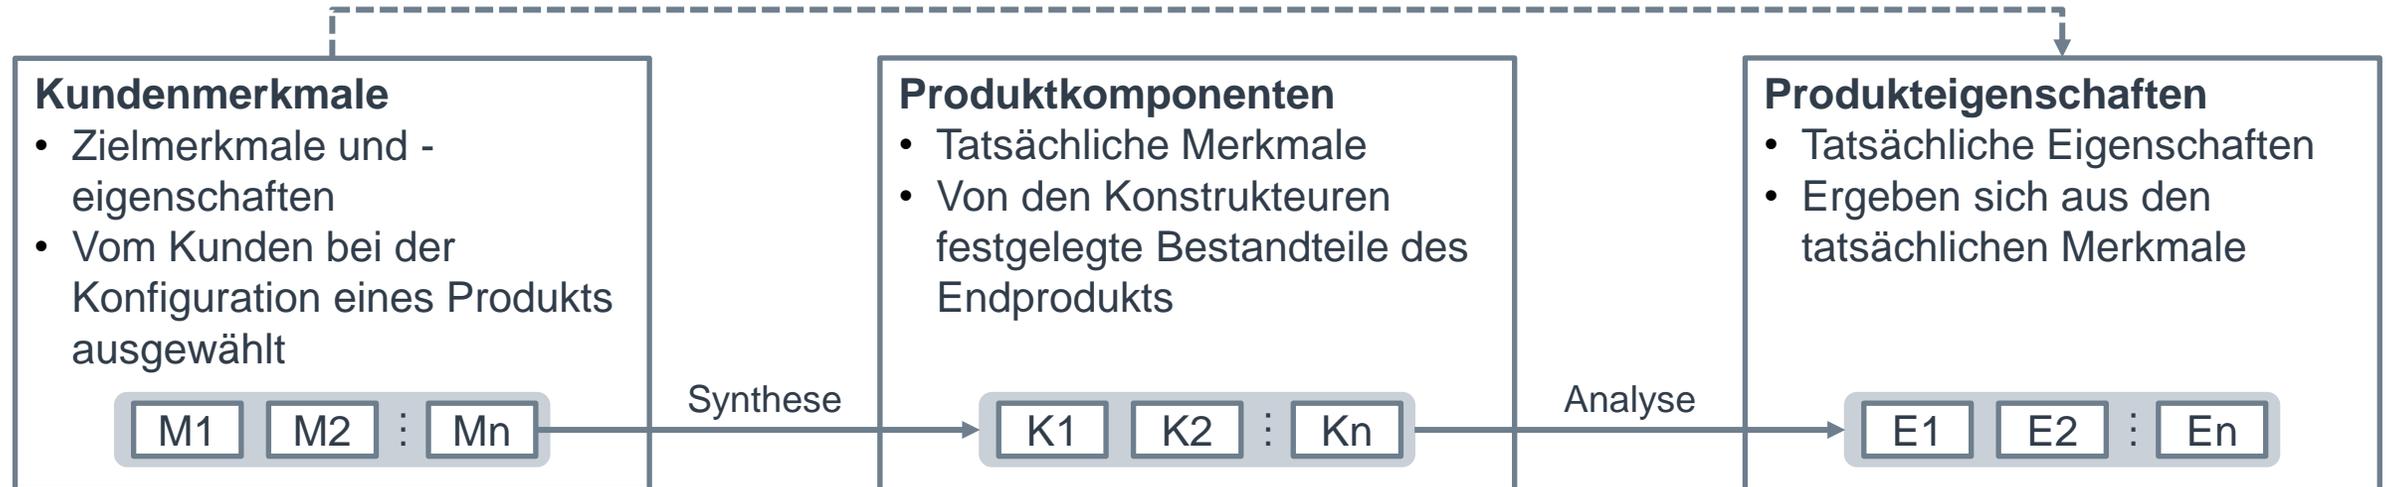


Reference: Mehlstäubl, J., Braun, F., Denk, M., Kraul, R., & Paetzold, K. (2022). Using Machine Learning for Product Portfolio Management: A Methodical Approach to Predict Values of Product Attributes for Multi-Variant Product Portfolios

Prognose von Produkteigenschaften: Nutzen

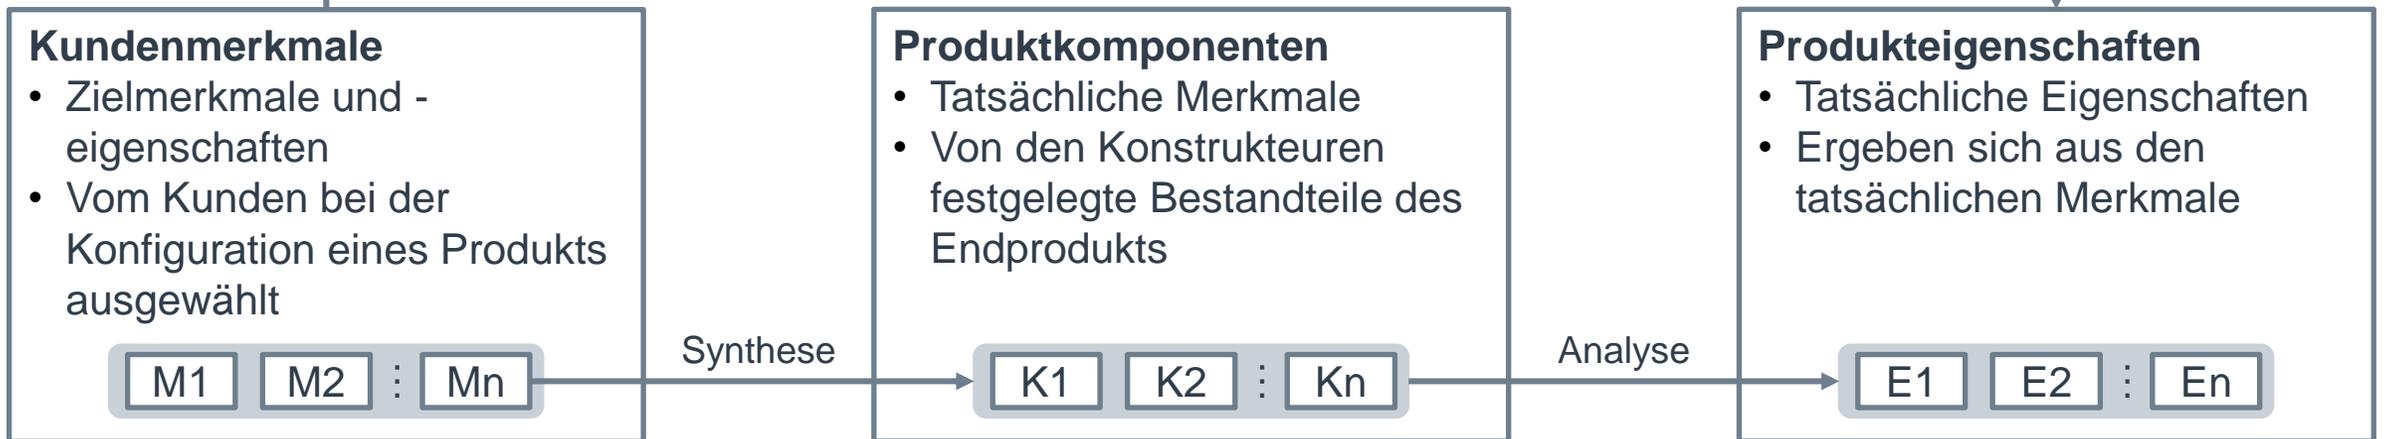


- Expertenwissen
- Zeitaufwendig
- Ungenau

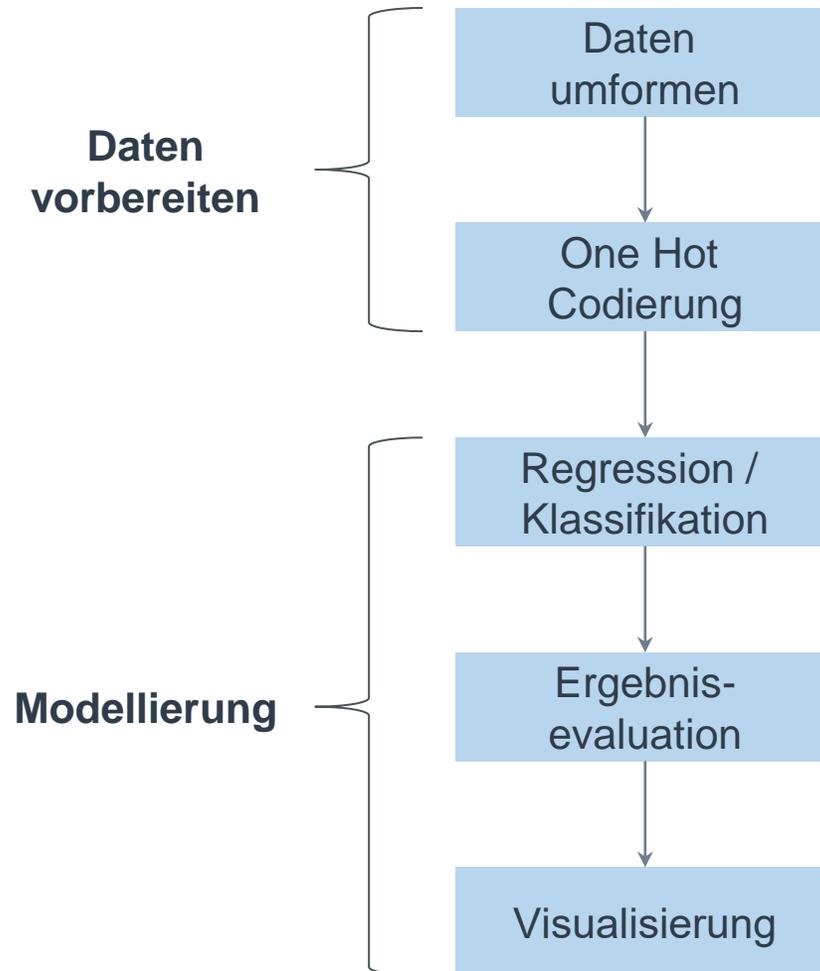


Prognose von Produkteigenschaften: Nutzen

Vorhersage der Machine Learning Modelle



Prognose von Produkteigenschaften: Vorgehen

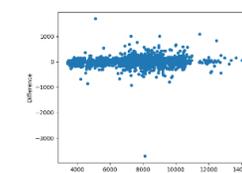
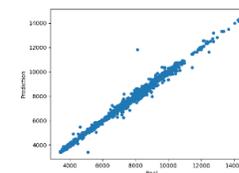


ID	Customer Features				Product Attribute	
	Model	Application	Cab	Suspension	Engine	Weight
1	TGX	Construction	GN	Leaf/Air	375 kW	10 000 kg
2	TGS	Construction	NN	Leaf/Leaf	294 kW	6 000 kg
3	TGM	Construction	CC	Leaf/Air	213 kW	8 000 kg
4	TGM	Beverages	CC	Air/Air	235 kW	7 500 kg
5	TGL	Distribution	CC	Leaf/Air	140 kW	8 500 kg

ID	TGS	TGM	TGL	TGX	Construction	Beverages	Distribution	GN	NN	CC	...	Weight
1	0	0	0	1	1	0	0	1	0	0	...	10 000 kg
2	1	0	0	0	1	0	0	0	1	0	...	6 000 kg
3	0	1	0	0	1	0	0	0	0	1	...	8 000 kg
4	0	1	0	0	0	1	0	0	0	1	...	7 500 kg
5	0	1	0	0	0	0	1	0	0	0	...	8 500 kg

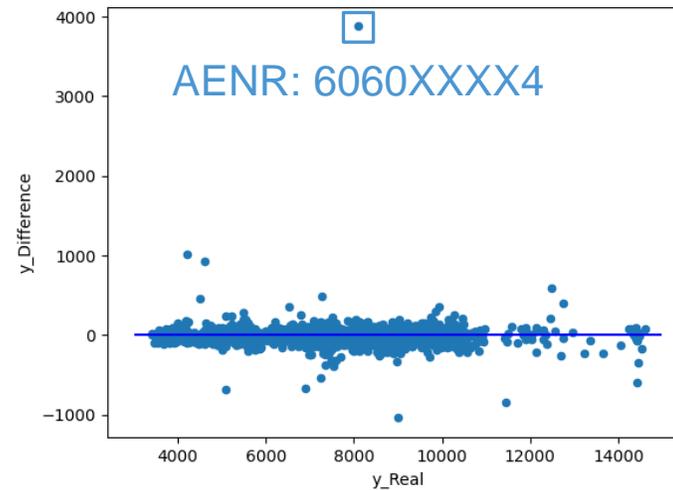
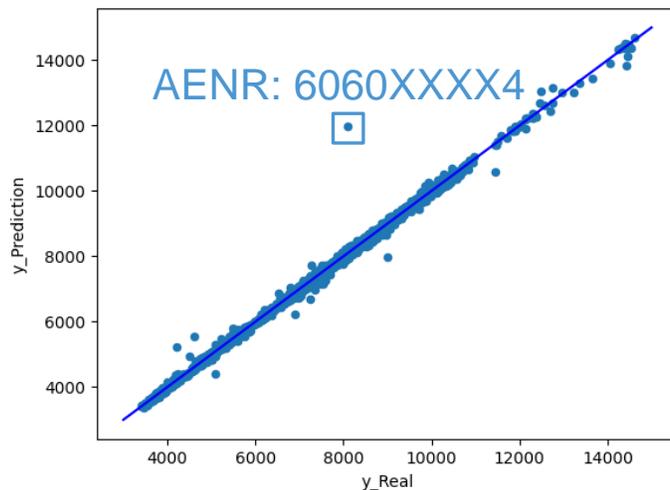
- Linear Regression
- Support Vector Machine
- K-nearest Neighbors
- Decision Tree Regression
- Random Forest
- Neural Network

- MSE (mean squared error)
- MAE (mean absolute error)
- MAPE (mean absolute percentage error)
- R2 (r-squared)



Prognose von Produkteigenschaften: Ergebnisse Fahrzeuggewichten

Datenpunkte: ~ 35.000	Linear Regression	Support Vector Machine	K-nearest Neighbors	Decision Tree	Random Forest	Neural Network
MAE	$4,35 \times 10^{10}$	745	81	59	53	43
MAPE	$5,49 \times 10^{10} \%$	11,74 %	1,1 %	0,72 %	0,81 %	0,6 %
R2	$2,55 \times 10^{-5}$	0,405	0,989	0,993	0,995	0,996
Trainingszeit	283 s	4776 s	0,362 s	34 s	96 s	200 s



- **AENR 6060XXXX4:** 96E, 8x8, 44t
 - y_Real: 8105 kg
 - y_Prediction: 11971,3 kg
- Identische Konfiguration wie 6060XXXX5 (11995 kg)

Prognose von Produkteigenschaften: Evaluation



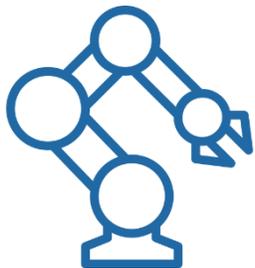
Verständnis

- Grundlagen
- Anwendbarkeit
- Umsetzung



Genauigkeit

- Genauere Eigenschaftsvorhersage
- Regelbasiert: 97 %
 - ML: 99,4 %.
- Reduzierung des Fehlers um 80%



Automatisierung

- Regelbasiert: Manuelle Definition von Regeln
- ML: Automatisierte Ermittlung von Regeln aus Daten



Beschleunigung

- Schnellere Eigenschaftsvorhersage
- Regelbasiert: 1-2 s
 - ML: 0,08 s
- Prozess 96% schneller

Prognose von Produkteigenschaften: Einsatz



Prognose von Produkteigenschaft



Produkteigenschaft	Gewicht		<input checked="" type="radio"/> Konfigurationsdatei	<input type="radio"/> Konfigurationsnummer
Machine Learning Modell	Random Forest		Datei	6072XXXX8.json

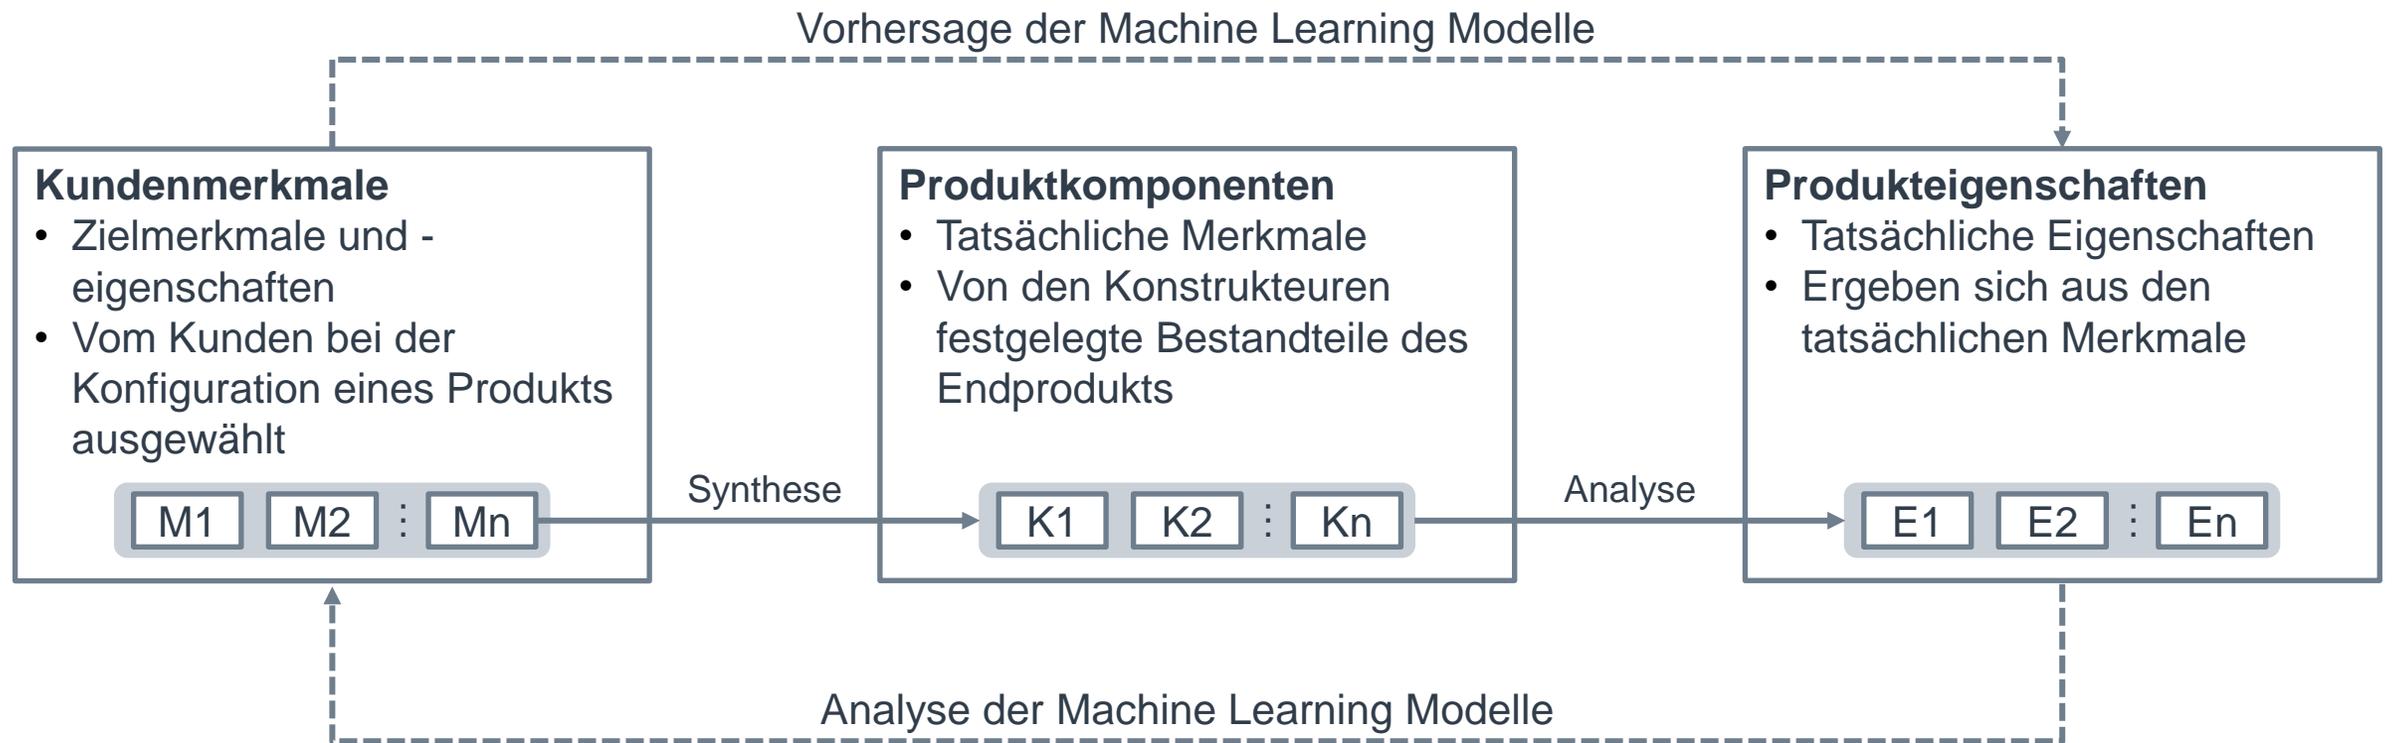
Ergebnis

12 834 kg

Ergebnisse anzeigen

Ergebnisse exportieren

Prognose von Produkteigenschaften: Nutzen



Analyse der Modelle: Feature Importance am Beispiel der Zahlungsbereitschaft

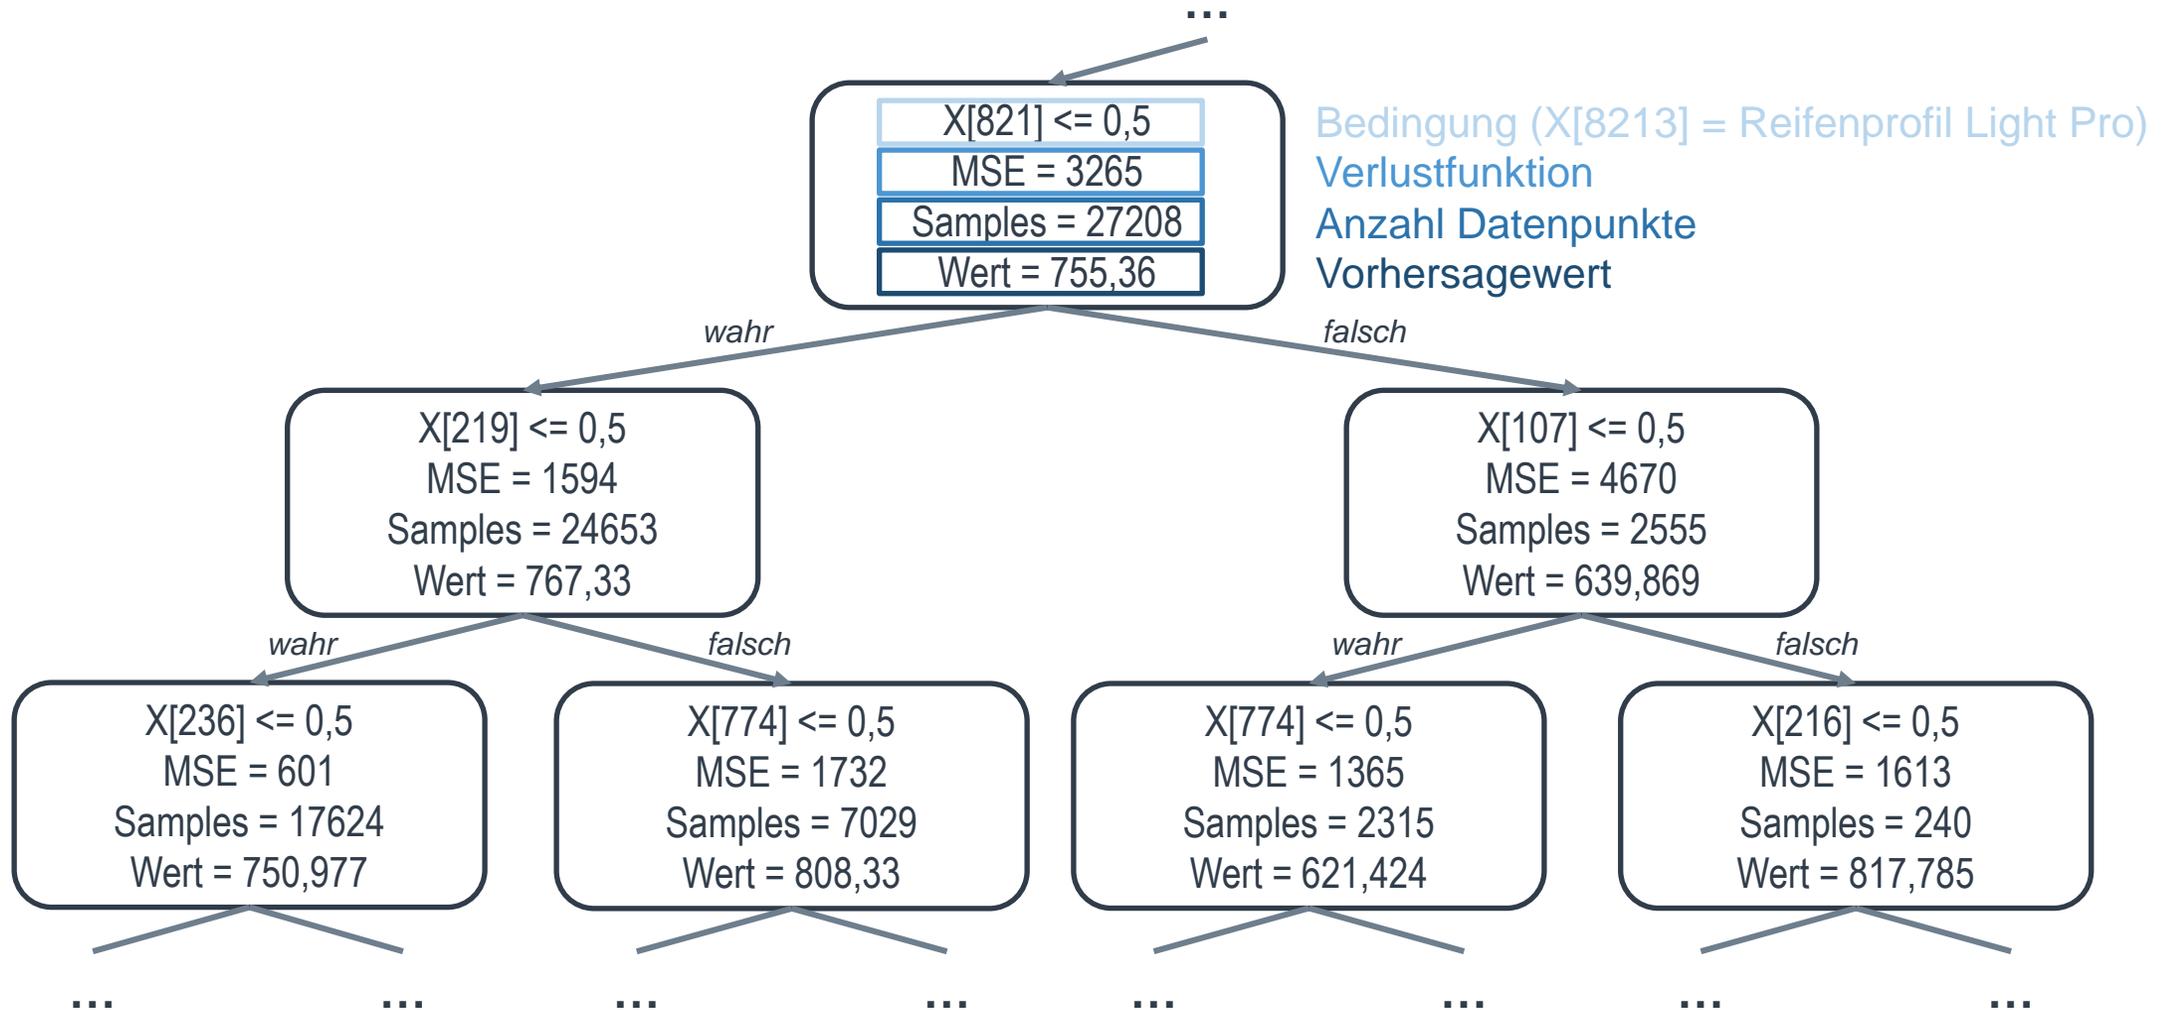
Feature Importance: Einfluss der Merkmale eines Machine Learning Modells auf den Zielwert

Nr.	Merkmale	Feature Importance
1	0KU8 - LACK_Hilfsmerkmal	0,243
2	0KD8 - Vorbereitung Kamera	0,125
3	0K25 - Nennleistung Motor	0,057
4	0KJN - Drucklufthorn	0,053
5	0KHI - Fahrzeugtyp	0,040
6	0K2F - Warnmeldung Kühlwasserstand	0,030
...
881	0KQK - Anhänger-Bremsanschlüsse an Fahrzeugfront	0
882	0K35 - Radabdeckung an 2. HA	0
883	0K60 - Verlängerung Unterfahrschutz hinten	0
883	0K10 - Fernbedienung der Fahrkupplung	0
885	0K9C - Hydraulikanschlüsse an Fahrzeugfront	0

Großer Einfluss auf die Zahlungsbereitschaft
→ Großen Kundennutzen?

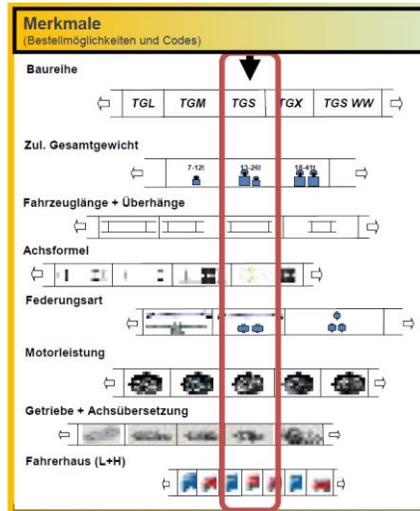
Kein Einfluss auf Zahlungsbereitschaft
→ Keinen Kundennutzen?

Analyse der Modelle: Entscheidungsbaum am Beispiel der CO2 Werte



Analyse der Modelle: Simulation am Beispiel der CO2-Werte

1. Fahrzeug Konfigurieren



2. Freiheitsgrade definieren

- Dachspoiler
 - Mit Dachspoiler
 - Ohne Dachspoiler

- Sideflaps
 - Sideflaps, klappbar rechts und links
 - Sideflaps, klappbar rechts und feststehend links
 - Sideflaps, klappbar links und feststehend rechts
 - Ohne Sideflaps

3. Mögliche Konfigurationen bestimmen

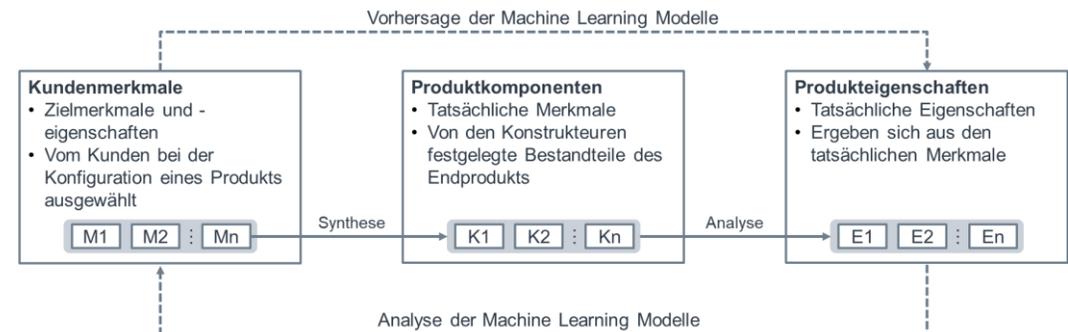
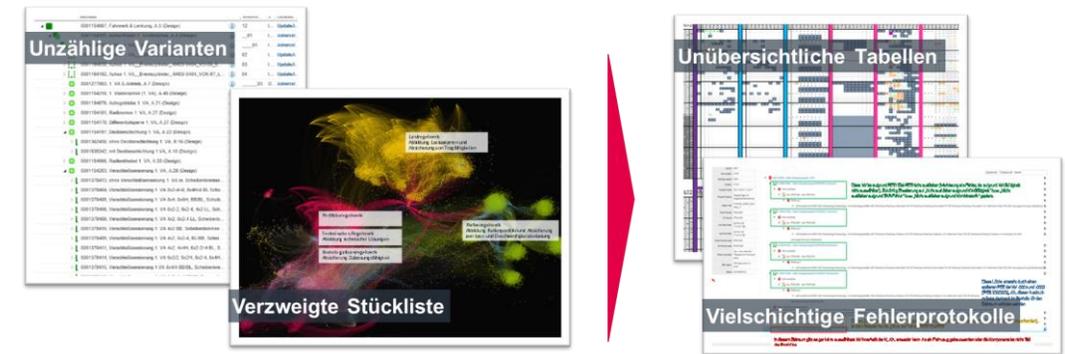
	Dachspoiler	Sideflaps
1	Mit Dachspoiler	Sideflaps, klappbar links und feststehend rechts
2	Mit Dachspoiler	Sideflaps, klappbar rechts und links

4. Produkteigenschaften vorhersagen

	CO2-Wert
1	737.936 $\frac{\text{g CO}_2}{\text{kg}}$
2	738.175 $\frac{\text{g CO}_2}{\text{kg}}$

Zusammenfassung

- Manuelle und erfahrungsbasierte Prozesse können Portfoliokomplexität nicht handhaben
- Machine Learning Verfahren erkennen Muster in großen Datensätzen und ermöglichen Vorhersagen über neue Ereignisse
- Konkrete Anwendung an einem Anwendungsfall zur Prognose von Produkteigenschaften
- Analyse der Modelle ermöglicht Rückschlüsse auf einzelne Kundenmerkmale





Universität der Bundeswehr München
Institut für Technische
Produktentwicklung



Künstliche Intelligenz im Produktportfolio- und Variantenmanagement

Machine Learning zur Handhabung der Portfoliokomplexität am Beispiel der MAN Truck & Bus SE

Jan Mehlstäubl - Universität der Bundeswehr München
Dr.-Ing. Felix Braun - MAN Truck & Bus SE



Bayerische
Forschungsstiftung