

Prophet Analytics

WHITEPAPER

Machine Learning in der Produktion - Warum die digitale Revolution anders aussieht, als gedacht.

Author: DR.-ING. STEFAN PROROK

Date: 18.08.2023

Der Einsatz von Machine Learning und künstlicher Intelligenz in der industriellen Produktion nimmt einen großen Raum in der Fachpresse ein. Aber die Lage ist paradox: Obwohl überall von Machine Learning zu lesen ist, haben sich die großen Erwartungen an Effizienzgewinne bis jetzt kaum bewahrheitet. In diesem White Paper wird gezeigt, dass Machine Learning häufig für ungünstige Anwendungsfälle eingesetzt wird. Es wird ein einfaches Kriterium vorgestellt, welches Entscheidern hilft zu beurteilen wann Machine Learning das richtige Werkzeug ist. Das Kriterium wird anhand von Beispielen veranschaulicht. Handlungsempfehlungen am Ende des Texts helfen bei der strategischen Ausrichtung und den breiteren Einsatz von Machine Learning in der Industrie.

Machine Learning in der Industrie stellt eines der großen Themen der digitalen Transformation unseres Wirtschaftssystems dar. Doch obwohl es viele Anwendungsgebiete gibt, in denen Machine Learning einen echten Mehrwert geschaffen hat (siehe z.B. [1, 2]), bleibt die Revolution in der breiten Fläche aus. Viele Firmen arbeiten heute noch so, wie vor 20 Jahren. Die Wert-

schöpfenden Prozesse haben sich wenig verändert. Es wird noch immer geschweißt, geklebt, gespritzt und gefräst. Das Interesse an Machine Learning und künstlicher Intelligenz für Anwendungen in der Produktion ist ungebrochen. Gleichzeitig gibt es Ernüchterung darüber, dass die erhofften Produktivitätssprünge bis jetzt ausgeblieben sind.

Datenanalysten stehen oft vor der Herausforderung unzureichend strukturierten Daten[3]. Dies ist jedoch nur ein Aspekt des Problems. Daten zu erheben kostet Geld und bindet Ressourcen. Es ist ein Spannungsfeld in dem sich die das Qualitätswesen seit jeher bewegt. Mehr und genauere Prüfungen verhindern die Auslieferung schlechter Produkte und erleichtern die Fehlersuche. Diese zusätzliche Sicherheit wird jedoch mit Prüf- und Personalkosten erkaufte. Das Argument von Geschäftsleitung und Controlling lautet daher folgerichtig: Wir haben bereits sehr viele Daten, aber wir nutzen sie nicht optimal. Beide Argumente haben ihre Berechtigung, aber um zu erkennen wo die schlafenden Potentiale für Machine Learning liegen, muss das Problem aus einer breiteren Perspektive betrachtet werden.

Zunächst stellt sich die Frage welche Erwartungen mit Machine Learning als Technologie verbunden sind. Nicht zuletzt von den Datenanaly-

sten selbst wurde häufig die Hoffnung geschürt, dass die Lösung eines jeden Problems sich in den Daten finden lässt. Es ist richtig, dass sich die Methoden von Machine Learning besonders gut für die Analyse großer Datenmengen eignen. Das hat jedoch zunächst einmal nichts mit den Problemen zu tun, mit denen die moderne industrielle Fertigung konfrontiert ist. Tatsächlich steht in der Industrie bereits ein ganzes Arsenal an Problemlösungstechniken bereit, die sich über Jahrzehnte bewährt haben (z.B. SixSigma/DMAIC, PDCA oder Shainin/Red X). Viele dieser Techniken nutzen in hohem Umfang Daten. Die Hoffnung an Machine Learning besteht häufig darin, dass mit neuen Methoden diejenigen Probleme gelöst werden, bei denen klassische Problemlösung an die Grenzen stößt. Und genau hier liegt der Irrtum.

Ein historischer Vergleich soll den Trugschluss verdeutlichen. Die Einführung der Elektrizität wird oft auch als zweite industrielle Revolution bezeichnet. Heute ist moderne Industrie ohne Elektrizität gar nicht vorstellbar. Aber was ist so revolutionär an elektrischer Energie? Eine der wichtigsten Aspekte, die er Elektrizität letztendlich zum breiten Durchbruch verhelfen, war nicht die Tatsache, dass es keine Alternativen gab. Gas, Öl und Kohle waren günstige und lange etablierte Energieträger. Der Grund war vielmehr, dass es mit Elektrizität möglich war Energie über lange Strecken zu transportieren. Energieerzeugung und Verbrauch konnten so erstmals räumlich getrennt werden[4]. Alle anderen bis dahin gebräuchlichen Energiequellen, nutzten Verbrennung bei der das Licht oder die Wärme vor Ort verwendet werden musste. Neben der Belästigung durch Rauch und Gestank stellte die Vielzahl an Feuern und brennbarem Material ein permanentes Risiko für Brände dar. Energietransport stellte somit ein Alleinstellungsmerkmal der elektrischen Energie dar. Machine Learning hat aber kein Alleinstellungsmerkmal für Problemlösung und schon gar nicht für schwierige Problem.

Tatsächlich gibt es eine Klasse von Problemen, die sich ausgezeichnet für Machine Learning eignen und ein vergleichbares Alleinstellungsmerkmal, wie die Elektrizität besitzt. Eine grafische Darstellung verdeutlicht um welche Probleme es sich dabei handelt. Abbildung 1 zeigt zwei Arten von Problemstellungen. Zunächst wird

der für Machine Learning ungünstige Fall I gezeigt. Hierbei tritt ein Defekt oder eine Störung an einem Produkt oder einer Maschine auf, der mittels eines Modells vorhergesagt werden soll. Beispiele hierfür sind Kundenreklamationen oder Maschinendefekte, die zu ungeplanten Stillstandszeiten und Reparaturen führen. Die Ausfälle sollen mit Hilfe von Daten vorhergesagt werden um eine Auswirkung beim Kunden oder einen Maschinenstillstand zu vermeiden. Solche Anwendungsfälle scheinen aufgrund der hohen Fehlerkosten zunächst finanziell attraktiv (Gewährleistungskosten, Kosten für Ersatzteile und Effizienzverluste). Vorbeugende Instandhaltung ist ein typisches Schlagwort in diesem Zusammenhang und viele Forschungsarbeiten haben sich mit diesem Problemfeld beschäftigt[2].

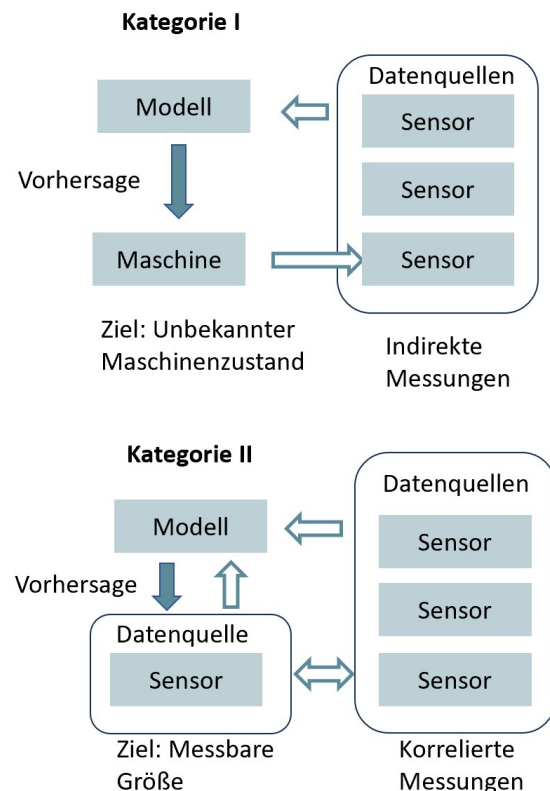


Abbildung 1: Typ I-Problem (o.) mit Modell eines unbekanntem Zustands, Typ II-Problem (u.) mit Modell zur Vorhersage einer messbaren Größe.

Bei näherer Betrachtung stellt sich heraus, dass Kategorie I-Probleme meist technisch anspruchsvoll sind. Charakteristisch für Kategorie I-Probleme ist, dass wir an dem inneren Zustand einer Maschine oder eines Produkts interessiert sind. Dieser innere Zustand

ist bei Kategorie I-Problemen jedoch nicht direkt messbar. Es sind lediglich indirekte Messungen verfügbar. Bei vorbeugender Instandhaltung für Windturbinen wird beispielsweise häufig auf Vibrations- und Schallmessungen zurückgegriffen um den Verschleißzustand im Inneren eines Getriebes zu beurteilen[5]. Das Schließen von einer Vibrations- und Schallmessung auf den Verschleiß des Getriebes ist ein anspruchsvolles Problem. Es setzt jahrelange Erfahrung und ein tiefes Verständnis von Getrieben voraus. Machine Learning kann helfen um diese Erfahrung in ein Vorhersagemodell zu überführen. Allerdings sind solche Modelle in der Regel sehr spezifisch für eine Art Maschine und der Aufwand beginnt von Neuem, wenn eine neue Generation von Maschinen auf den Markt kommt. Kategorie I-Probleme setzen somit eine hohe Fachkompetenz für den Anwendungsfall voraus. Da sie auf einen speziellen Anwendungsfall zugeschnitten sind, sind sie schlecht skalierbar und wenig wirtschaftlich.

Kategorie II-Probleme sind grundsätzlich anders. In diesem Fall ist das Ziel der Vorhersage bekannt und direkt messbar. Ein einfaches Beispiel für ein Kategorie II-Problem ist die Überwachung von Sensoren und Prüfgeräten. Für Messungen an sicherheitskritischen Komponenten schreibt der VDA Band 5 eine kontinuierliche Überwachung vor[6]. Der Umsetzungsvorschlag im VDA Band 5 besteht darin eine Stabilitätsregelkarte zu führen, bei der ein oder mehrere Meisterteile täglich geprüft werden und die Werte in eine Regelkarte eingetragen werden (siehe [7] für eine ausführliche Diskussion). Dieses Verfahren hat zwei Schwächen: Es ist ein händisches Verfahren, welches zusätzlichen Arbeitsaufwand mit sich bringt. Außerdem ist die Überwachung nicht kontinuierlich, wie gefordert, sondern nur täglich. Intermittierende Fehler, die nicht permanent anliegen, werden so nicht zuverlässig erkannt.

Das Problem der Maschinenüberwachung kann in vielen Fällen durch ein einfaches Machine Learning Modell gelöst werden. Angenommen in der Fertigungslinie stehen zwei Prüfgeräte. Dies ist häufig der Fall, wenn ein Produkt für unterschiedliche Temperaturbereiche getestet werden muss. Auch Stichprobenprüfungen, wie Run-In oder Burn-in Prüfungen können verwendet werden. In solchen Fällen tauchen in der Re-

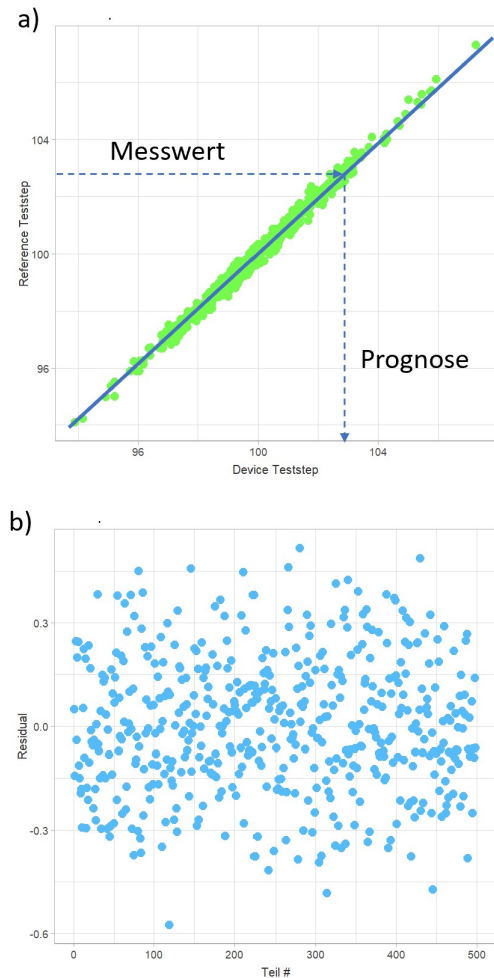


Abbildung 2: zeigt das Streudiagramm von zwei korrelierten Messwerten (o). Die untere Abbildung zeigt die zugehörige Abweichung zwischen Messwert und Prognose.

gel Korrelationen zwischen den Prüfgeräten auf. So ist die Stromaufnahme eines Prüflings bei Hochtemperatur in der Regel mit der Stromaufnahme bei Raum- oder Tieftemperatur korreliert. Abbildung 2a zeigt so eine Korrelation. Die Daten werden in ein Regressionsmodell überführt. Wenn der Messwert bei Tieftemperatur bekannt ist, dann kann eine Prognose für den Messwert bei Raumtemperatur angegeben werden. Die Abweichung zwischen Prognose und tatsächlich gemessenem Wert kann in eine Regelkarte überführt werden. Abbildung 2b zeigt den so ermittelten Fehler der Prognose. Dieser Prognosefehler besitzt, ebenso wie eine Regelkarte, einen Zufallsstreuungsbereich. Der Unterschied zur klassischen Regelkarte ist, dass die Stabilität nun für jeden Prüfling verfolgt werden kann und eine kontinuierliche Überwachung

möglich wird. Es ist auch kein Zusatzaufwand mehr nötig um Meisterteile einzulegen oder Daten zu pflegen. Die Überwachung des Prüfgeräts ist nahezu aufwandsneutral.

Abbildung 3 zeigt den Zufallsstrebereich von zwei Standardabweichungen als blau unterlegten Bereich. Das Bild zeigt schematisch mehrere Ausreißer in rot. Bei diesen Ausreißern weichen Prognose und Messwert stark von einander ab. Diese Abweichung kann mit Hilfe einfacher Ausreißertests detektiert werden und es können entsprechende Abstellmaßnahmen eingeleitet werden. Durch Zusammenfassung mehrerer Messungen kann auch die Lage der Prüfgeräte zueinander überwacht werden.

Die Machine Learning Modelle für Kategorie II-Probleme sind im Vergleich zu Kategorie I deutlich einfacher und verlangen kaum spezielle Fachkenntnisse. Der Grund dafür ist, dass die innere Funktion des Prüfstandes keine Rolle spielt. Es wird lediglich vorausgesetzt, dass ein bekannter Zusammenhang (Korrelation) in den Daten besteht. Jede Abweichung von diesem bekannten Zusammenhang kann mit einfachen statistischen Methoden erkannt werden. Der Ansatz fügt sich nahtlos in bestehende Methoden der statistischen Prozesskontrolle. Die Einfachheit der Modelle hat zur Folge, dass einmal geschriebene Software sich besser auf neue Produkte oder Anlagen übertragen lässt, als dies bei einem Kategorie I-Problem der Fall ist. Die dadurch verbesserte Skalierbarkeit verbessert auch die Wirtschaftlichkeitsrechnung.

Die Übertragbarkeit auf andere Anlagen und Produkte ist der große Vorteil von Machine Learning gegenüber klassischen Problemlösemethoden. Hier greift auch die Analogie aus dem historischen Vergleich mit der Elektrizität: Elektrizität ermöglicht Energietransport gleichzeitig brennbares Material zu transportieren. Analog können Kategorie-II Probleme mit Machine Learning gelöst werden ohne dass tiefes Fachwissen vorhanden sein muss. Der Ersteller des Kategorie II-Modells muss nicht genau wissen, wie ein Produkt oder Prüfstand funktioniert, weil der Prüfstand alle relevanten Daten bereitstellt. Das Alleinstellungsmerkmal von Machine Learning besteht damit in der Übertragbarkeit einer technischen Lösung und diese Übertragbarkeit zeigt sich am deutlichsten bei Problemen der Kategorie II.




Abbildung 3: zeigt einen Werteverlauf mit intermittierenden Fehlern in rot.

Die bisherige Argumentation zeigt, dass die Frage, ob Machine Learning erfolgreich und wirtschaftlich eingesetzt werden kann, nicht vom Umfang der Daten abhängt. Auch aus vergleichsweise kleinen Datensätzen können brauchbare Modelle erzeugt werden. Wichtiger ist die Frage, was das Ziel der Vorhersage des Machine Learning Modells sein soll: Ein unbekannter innerer Zustand (Kategorie I) oder eine bekannte Datenquelle, die direkt messbar ist (Kategorie II). Hohe Skalierbarkeit, einfache Modelle und damit verbunden geringes Risiko in der Umsetzung machen Probleme der Kategorie II zu lohnenden Zielen.

Der Unterschied zwischen Kategorie I und Kategorie II-Problemen soll anhand eines weiteren Beispiels dargestellt werden. Gegeben ist eine Sichtkontrolle an mechanischen Bauteilen. Diese Sichtkontrolle hat einen Durchschlupf, der zu mehreren Reklamationen geführt hat. Die Sichtkontrolle soll verbessert werden. Zunächst wird das Problem als Kategorie I-Problem behandelt. Es werden Einflussfaktoren bestimmt. Beleuchtungsstärke, Auswertungen von Fehleranteilen nach Werker (soweit der Datenschutz dies zulässt) durchgeführt. Die Daten werden nach Schichten (früh, spät und Nacht) erhoben und verschiedene Arbeitsanweisungen ausprobiert. Das Ziel solcher Aktivitäten ist es herauszufinden, welche Einflussfaktoren dazu führen, dass beim Werker Fehlentscheidungen entstehen. Der Werker selbst bleibt dabei eine Blackbox und sein/ihr innerer Zustand (aufmerksam

oder abgelenkt) ist nicht von außen erkennbar. Der Ansatz einen Datenanalysten zu beauftragen ein Machine Learning Modell für diese Anwendung zu erstellen, ist zum Scheitern verurteilt.

Es ist jedoch möglich das gleiche Problem als Kategorie II-Problem zu behandeln. Dazu wird zu jedem Bauteil ein oder mehrere Fotos angefertigt. Solche Fotostationen lassen sich oft mit wenig Aufwand in Anlagen integrieren. Es entsteht ein Datensatz, der jedem Werkerentscheid (Gut oder Schlecht) ein Bild zuordnet. Sowohl das Ziel (Werkerentscheid) als auch die Datenquelle (Bild) sind bekannt. Unter diesen Umständen kann über Machine Learning ein Modell erzeugt werden, welches den Entscheid des Werkers vorhersagt. Gelegentliche Fehlentscheidungen des Werkers sind dabei nicht problematisch. Wie bei der automatischen Anlagenüberwachung ist ein gewisses Maß an Abweichung zwischen Modell und Werker immer zu erwarten. Das so entstandene Modell kann je nach Güte auf mehrere Weisen eingesetzt werden:

- Bei sehr guten Modellen: Reduzierung der menschlichen Prüfung auf eine Stichprobe
- Bei guten Modellen: Teile, die die Maschine als n.i.O. klassifiziert werden dem Werker zugeführt
- Bei weniger guten Modellen: Erkennung von Übermüdung beim Werker, wenn die Anzahl der Abweichungen zu groß wird.

Wichtig ist an dieser Stelle, dass durch diesen Ansatz kein Modell des Werkers erzeugt wird. Es wird vielmehr davon ausgegangen, dass der Werker in der Regel richtig entscheidet. Was überwacht wird, ist die Abweichung zwischen Werkerentscheid und Modellprognose. Beides ist messbar, weshalb das Problem in die Kategorie II fällt. Moderne AOI-Systeme (automatische optische Inspektion) nutzen genau diesen Ansatz. Wenn die Abweichung zwischen Modell und Werker zu groß wird, können geschulte Spezialisten entweder Feinabstimmungen am Modell vornehmen oder gezielt Werker nachschulen. Das Beispiel soll zeigen, dass es manche Probleme je nach genauer Fragestellung in die Kategorie I oder II fallen können. Die Einteilung in die zwei Kategorien kann daher auch helfen Problemstellungen so zu formulieren, dass sie einfach lösbar werden. Einige Faustregeln helfen dabei, dass möglichst viele Probleme in der Kate-

gorie II landen und somit einfach lösbar werden:

- Stellen Sie sicher, dass alle Daten, die Sie erheben maschinenlesbar sind (festes Format, keine händisch ausgefüllten Zettel, oder Excel Tabellen, nur vorgefertigte Formblätter).
- Wenn Sie Zeiten erfassen, verwenden Sie automatische Zeitstempel. Am besten aus einer Quelle (z.B. zentral über ein Traceability System).
- Ordnen Sie alle Messungen einer Seriennummer zu, die Sie entlang des Fertigungsprozesses verfolgen können.
- Bauen Sie gezielt Redundanz in Ihren Fertigungsprozess ein. Kombinieren Sie beispielsweise 100% Prüfungen mit Stichproben.

Gerade der letzte Punkt wird vielen Firmen schwer fallen, da hier scheinbar erhöhte Kosten entstehen. Aber das Gegenteil ist der Fall. Die Redundanz der Daten schafft erst die Voraussetzung dafür statistisch nachweisen zu können, welche Prüfungen wirklich notwendig sind. Redundanzen können auch bewusst eingesetzt werden um Prüfmittel zu überwachen, zu kalibrieren oder Werkerprüfungen zu verbessern.

Zusammenfassung

Die hier vorgeschlagene Unterteilung zwischen Problemen der Kategorie I und Kategorie II soll eine Richtschnur dafür sein, welche Probleme sich gut für Machine Learning eignen. Es wurde an Beispielen Dargestellt, dass sich Machine Learning eher für Probleme der Kategorie II eignet. Der Einsatz von Machine Learning bietet dabei die Möglichkeit gut laufende Prüfungen zu automatisieren und Prüfumfänge zu reduzieren sowie Ausreißer und Abweichungen von erwarteten Ergebnissen sicher zu erkennen. Anwendungsbeispiele hierfür sind Kalibrierung, Überwachung von Sensoren und Prüfständen sowie die Reduzierung von Sichtkontrollen. Machine Learning ist klassischen Problemlösungstechniken überlegen, wenn es um Problemstellungen geht, die auf verschiedene Produkte oder Anlagen übertragbar sind. In der Praxis wird Machine Learning jedoch häufig für schwierige Probleme der Kategorie I eingesetzt, weil bewährte Methoden wie PDCA nicht zum Ziel geführt haben. Dies führt zu überhöhten Erwartungen, die häufig enttäuscht werden. Die vorgeschlagene Un-

terteilung nach Kategorie I und II soll sowohl Daten Analysten als auch Entscheidern die Möglichkeit geben die richtigen Prioritäten zu setzen und Risiken von Projekten besser einschätzen zu können. Entscheider können durch strategische Maßnahmen dazu beitragen, dass Probleme mit höherer Wahrscheinlichkeit in der Kategorie I landen. Einige Faustregeln hierzu wurden am Ende des Textes genannt.

Über den Autor

Dr.-Ing. Stefan Prorok ist promovierter Diplomingenieur der Elektrotechnik. Er war acht Jahre lang in verschiedenen Führungspositionen in der Automobilindustrie tätig. Er ist Autor mehrerer Patente für industrielles maschinelles Lernen sowie eines Buches über Statistiken in der industriellen Produktion. Darüber hinaus ist er als Trainer für die Deutsche Gesellschaft für Qualität (DGQ) tätig. Seit 2023 bietet er mit seinem Unternehmen Ingenieurbüro Prorok und Partner Beratungs- und Softwarelösungen an (für mehr Informationen siehe [link](#)).



Literatur

- [1] Marina Paolanti, Luca Romeo, Andrea Felicetti, Adriano Mancini, Emanuele Frontoni, and Jelena Loncarski. Machine Learning Approach for Predictive Maintenance in Industry 4.0. In *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA)*, pages 1–6. IEEE, 2018.
- [2] Thyago P Carvalho, Fabrízio AAMN Soares, Roberto Vita, Roberto da P Francisco, João P Basto, and Symone GS Alcalá. A Systematic Literature Review of Machine Learning Methods Applied to Predictive Maintenance. *Computers & Industrial Engineering*, 137:106024, 2019.
- [3] Bridging the Gap Between Data Science and Manufacturing. <https://sightmachine.com/blog/bridging-gap-data-science-manufacturing/>. Accessed: 2023-08-09.
- [4] Daniel French. *When They Hid the Fire: A History of Electricity and Invisible Energy in America*. University of Pittsburgh Press, 2017.
- [5] Ziyang Xu, Jing Wei, Shijie Zhang, Zhirou Liu, Xiangqian Chen, Qiang Yan, and Jianpeng Guo. A State-of-the-art Review of the Vibration and Noise of Wind Turbine Drive-trains. *Sustainable Energy Technologies and Assessments*, 48:101629, 2021.
- [6] VDA. *Mess- und Prüfprozesse: Eignung, Planung und Management*. Verband der Automobilindustrie, 2021.
- [7] Von Kanonen und Spatzen - Warum der neue VDA Band 5 gleichzeitig radikal und doch nichts Neues ist. https://prophet-analytics.de/whitepapers/VDA5_2021.pdf. Accessed: 2023-08-09.