



KI-Projekte erfolgreich umsetzen

Eine Checkliste für den Mittelstand

Inhalt

1	Vorwort und Vorgehensweise	4
1.1	Ziele und Grenzen der Checkliste sowie Fokus der Betrachtung	4
1.2	Aufbau der Checkliste	5
1.3	Flowchart Checkliste zur Mess- und Datenplanung	6
2	Vorbereitung und Projektplanung (A)	8
3	Mess- und Datenplanung (B)	11
3.1	Prozesswissen aufbauen und nutzen	12
3.2	Normen und Standards nutzen	13
3.3	Messunsicherheiten	14
3.4	Aufbau der Daten	14
3.5	Datenablage	16
3.6	Manuelle Datenquellen einbinden	17
4	Datenaufnahme (C)	19
4.1	Erste Testmessung und Überprüfung der Datenqualität	19
4.2	Langzeitdatenaufnahme	21
5	Datenprüfung und Datenbereinigung (D)	22
6	Datenauswertung und Modellbildung (E)	24
6.1	Datenvisualisierung und Datenverständnis	24
6.2	Auswahl von maschinellen Lernalgorithmen	25
6.3	Modellbildung	29
6.4	Modellanwendung	30
7	Projektabschluss (F)	31
8	Fazit	32
9	Abkürzungsverzeichnis, Glossar und Literaturverzeichnis	34
9.1	Abkürzungsverzeichnis	34
9.2	Glossar	36
9.3	Literaturverzeichnis	37



Bild: NINENII – stock.adobe.com

1. Vorwort

Um das volle Potential der Algorithmen in datengetriebenen KI-Projekten der Industrie, speziell im Mittelstand, voll auszuschöpfen, spielt die zugrundeliegende Qualität der Daten eine maßgebende Rolle.

Die vorliegende Checkliste basiert auf der „Checkliste – Mess- und Datenplanung für das maschinelle Lernen in der Montage“ von Schnur et al., welche kostenlos und Open Source auf dem Online-Repository Zenodo unter folgendem Link verfügbar ist: <https://zenodo.org/record/6943476> [1]. Um den Fokus von dem Anwendungsfall Montage auf die Anwendung in kleine und mittlere Unternehmen (KMU) anzupassen, wurde die Checkliste in vielen Punkten abgeändert und ergänzt. Sie soll industrielle Anwender bei der Aufnahme qualitativ hochwertiger Daten unterstützen, um so den Aufwand beim Analysieren zu minimieren und die Aussagekraft der Ergebnisse zu steigern.

Ein besonderer Dank gilt Herrn Prof. Dr. Andreas Schütze, Herrn Tizian Schneider und Frau Verena Milde für ihre Unterstützung beim Erstellen dieser Checkliste.

1.1 Ziele und Grenzen der Checkliste sowie Fokus der Betrachtung

Diese Checkliste dient als Unterstützung bei der Planung eines Projektes zur Nutzung von maschinellem Lernen (ML) an bereits vorhandenen Anlagen, Prozessen und Betriebsmitteln. Im Fokus stehen daher nicht die Neugestaltung/-anschaffung von Prozessen, Anlagen und Prototypen. Dennoch kann die Checkliste auch eine Orientierung für diese Anwendungsfälle sein. Sie verfolgt den Ansatz, durch die Einbringung von Fachwissen möglichst gezielt valide zeitkontinuierliche Daten aufzuzeichnen und übersichtlich bereitzustellen. Weiterhin wird bei der Modellbildung unterstützt. Aufgrund der hohen Vielfalt verfügbarer maschineller Lernmethoden wird die Datenanalyse im Rahmen dieses Dokumentes nur auf einem grundlegenden Niveau behandelt.

1.2 Aufbau der Checkliste

Zu Beginn eines jeden Kapitels führt ein kurzer Absatz in das Themengebiet ein. Anschließend folgen die Checkpunkte zum Abhaken. Grundsätzlich werden zwei Arten von Checkpunkten unterschieden: Muss- und Best-Practice-Checkpunkte.

Die Muss-Checkpunkte sind diejenigen, die zur erfolgreichen Bearbeitung der nachfolgenden Kapitel unbedingt umgesetzt werden müssen.

Muss-Checkpunkt

Best-Practice-Checkpunkte sind solche, die zur grundsätzlichen Bearbeitung der Abschnitte nicht unbedingt erforderlich sind, aber sich als sehr hilfreich in der weiterführenden Optimierung erwiesen haben.

Best-Practice-Checkpunkt

Weiterhin enthält die Checkliste nützliche Tipps (Handlungsempfehlungen) und Hinweise (Dinge, die zu beachten sind), die Ihnen bei der Bearbeitung helfen.

Tipp:
Handlungsempfehlungen

Hinweis:



Bild: Prostock-studio – stock.adobe.com

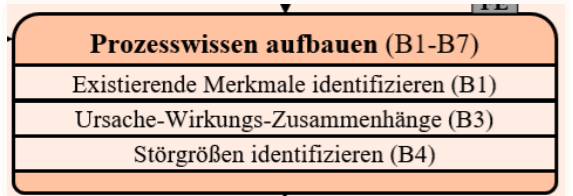
1.3 Flowchart Checkliste zur Mess- und Datenplanung

Nachfolgend finden Sie einen Flowchart, der Sie beim Durchlaufen der Checkliste unterstützen soll. Folgende Punkte helfen Ihnen den Flowchart besser interpretieren zu können:


- Der Flowchart ist nach den jeweiligen Kapiteln der Checkliste unterteilt und farblich gekennzeichnet, wie z. B.:



- Hinter jedem Schritt finden Sie in Klammern die zugehörigen Checkpunkte in der Checkliste. Bei manchen Schritten werden wichtige Checkpunkte explizit erwähnt, wie z. B.:



- Bei manchen Punkten kann der Rat bzw. die Erfahrung von zusätzlichen Personen hilfreich sein. Im Ablaufplan wird dies durch folgende Symbole gekennzeichnet:



- Rekursive Pfeile werden gestrichelt dargestellt:



- Iterative Prozesse sind als solche gekennzeichnet:


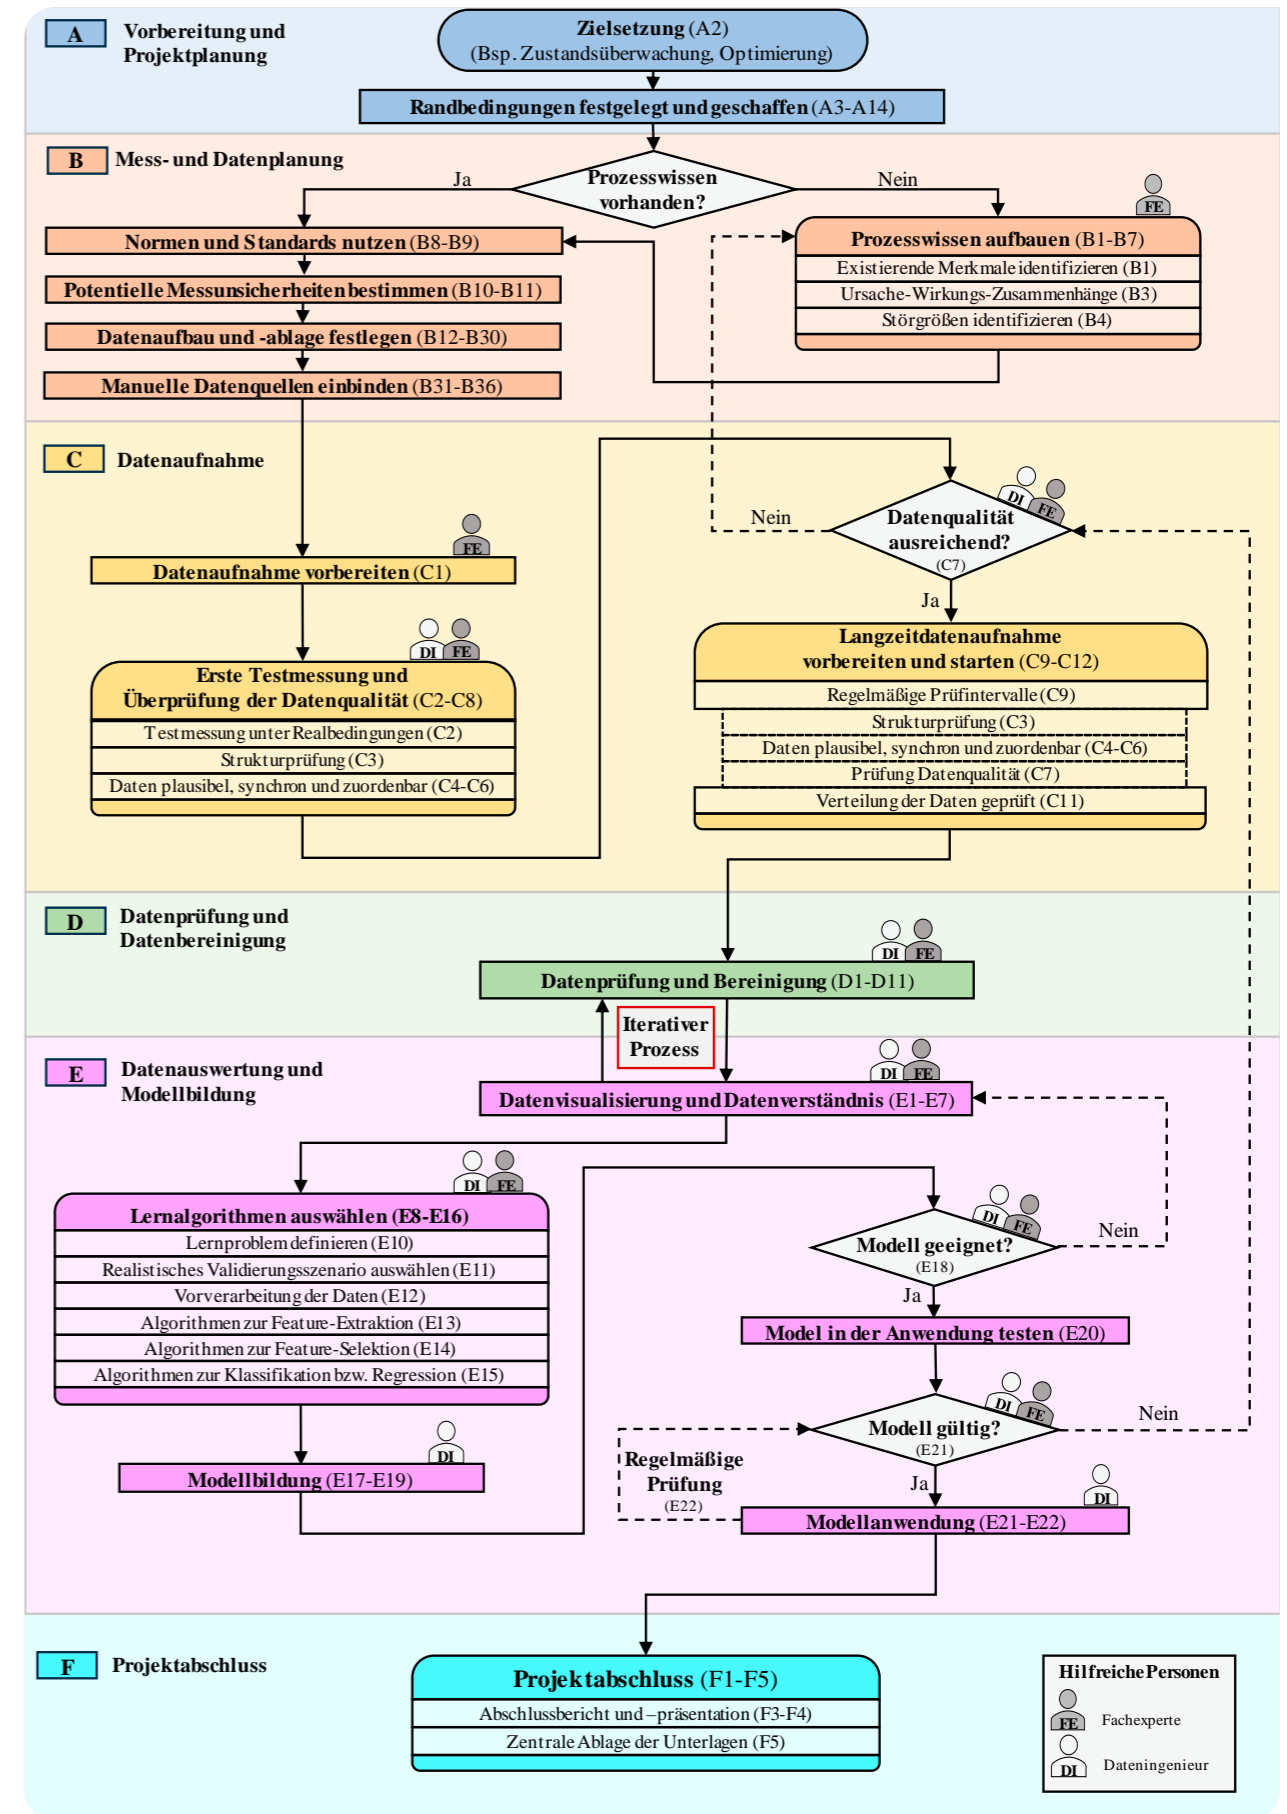





Bild: Micah C/peopleimages.com – stock.adobe.com

2. Vorbereitung und Projektplanung (A)

Bereits bei der Vorbereitung gibt es mehrere Aspekte zu beachten, um eine gute Ausgangsbasis für Ihr Projekt zu schaffen. Obwohl folgende Punkte trivial erscheinen, zeigt die Erfahrung, dass sie in der Praxis häufig vernachlässigt werden. Auch wenn in der Regel bereits eine Vielzahl an Daten in Ihrem Unternehmen existieren,

ist eine gute Vorbereitung essenziell, um Ihr Projekt erfolgreich voranzubringen. Im Rahmen dieser Checkliste werden nur für die Datenqualität kritische Punkte des Projektmanagements genannt. Weitere wichtige Punkte, wie z. B. die Budgetplanung oder eine Risikoanalyse, sollten Sie aber dennoch berücksichtigen.

A1. Checkliste gelesen und verstanden

Bevor Sie mit der Bearbeitung starten, sollten Sie die Checkliste komplett gelesen und die einzelnen Arbeitsschritte verstanden haben.

A2. Ziele und Art des Projektes festgelegt

Überlegen Sie sich genau, bestenfalls in einem abteilungsübergreifenden Meeting mit Facharbeitern oder externen Experten, was die Ziele Ihres Projektes sind. Wollen Sie den Zustand von Produkten, Prozessen oder Anlagen überwachen? Wollen Sie gezielt Daten an nur einer Anlage erfassen oder möchten Sie Daten stations- bzw. anlagenübergreifend aufzeichnen? Oder wollen Sie kritische Prozesse mithilfe von maschinellem Lernen optimieren?

Hinweis:

Beachten Sie, dass maschinelles Lernen auf einer statistischen Analyse aufbaut und daher nur Lösungen liefern kann, wenn die gesuchte Information in den aufgezeichneten Daten enthalten ist.

A3. Fördermöglichkeiten geprüft

Prüfen Sie Fördermöglichkeiten für Ihr Unternehmen. Speziell für KMU gibt es häufiger Ausschreibungen, die Sie in Ihrem Projekt unterstützen können. Eine erste Anlaufstelle kann bspw. Ihr lokales Mittelstand-Digital Zentrum sein.

A4. Facharbeiter / Experten identifiziert

Versuchen Sie, die jeweiligen Facharbeiter bzw. Experten für Ihre Produkte, Prozesse und Anlagen zu identifizieren und von Ihrem Vorhaben zu überzeugen. Expertenwissen ist sehr wertvoll für die Planung, Auswertung und Interpretation Ihrer Daten.

Hinweis:

Oftmals lässt sich (spezifisches) Wissen nur bei einzelnen Personen im Unternehmen finden und wird dadurch schwer zugänglich, was die Datenauswertung und -analyse enorm behindern kann.

Sollten Sie keine Mitarbeiter mit Erfahrung in der Messunsicherheitsbestimmung haben, erwägen Sie die Beauftragung eines externen Dienstleisters oder die Weiterbildung der Mitarbeiter.

Prüfen Sie auch, ob in ihrem Unternehmen bereits Personal mit Erfahrung in der Bestimmung der Messunsicherheit (Kapitel 3.3) vorhanden ist. Sollte dies nicht der Fall sein, erwägen Sie die Schulung/Weiterbildung von Mitarbeitern mit erweitertem mathematischem Verständnis oder die Auslagerung der Aufgabe.

A5. Externe Experten hinzuziehen

Sollten Sie weiteres Fachwissen, z. B. im Bereich maschinelles Lernen benötigen, können Sie auch auf externe Unterstützer zurückgreifen.

Tipp:

Auch hier kann Sie ggf. Ihr lokales Mittelstand-Digitalzentrum unterstützen.

<https://www.mittelstand-digital.de/MD/Navigation/DE/Praxis/Kompetenzzentren/kompetenzzentren.html>

A6. Archiv auf ähnliche Projekte geprüft

Bevor Sie Ihre Planung starten, prüfen Sie, ob bereits ähnliche Projekte in Ihrem Unternehmen (oder in Ihrer Branche) durchgeführt wurden. Falls ja, sehen Sie sich die verfügbare Projektdokumentation an und versuchen Sie, das Gelernte aus den bereits durchgeführten Projekten in dieses Projekt einfließen zu lassen.

A7. Übersicht mit möglichen Produkten, Prozessen oder Anlagen erstellt

Erstellen Sie eine Übersicht mit den Produkten, Prozessen oder Anlagen, die für Ihre Analyse in Frage kommen.

A8. Aufwand realistisch abgeschätzt

Der größte Aufwand, Daten mit maschinellem Lernen zu analysieren, liegt mit ca. 80% in der Aufbereitung der Daten und lediglich zu 20% in der eigentlichen Analyse. Gerade die wichtige Kommunikation mit den Facharbeitern oder Experten, die oftmals nur sporadisch verfügbar für Ihr Projekt sind, können den Zeitplan verzögern.

A9. Betrachtungsfokus definiert

Versuchen Sie, Ihren Betrachtungsfokus möglichst klein zu halten. Bündeln Sie Ihre Ressourcen und verlieren Sie sich nicht in der Auswertung von Daten von zu komplexen Produkten, Prozessen oder Anlagen. Starten Sie lieber klein, bspw. mit einem einzelnen (kritischen) Prozess und erweitern Ihre Analyse zu einem späteren Zeitpunkt. Bei der Auswahl des Betrachtungsfokus können Sie die ausgewählten Facharbeiter/Experten (A4) unterstützen.

A10. Zeitplan erstellt

Bis wann wollen Sie das Projekt abschließen? Erstellen Sie sich Meilensteine, die Sie erreichen wollen (und können vgl. A8).

A11. Arbeitspakete aufgeteilt

Leiten Sie einzelne Arbeitspakete ab und teilen Sie diese nach Möglichkeit unter Ihren Mitarbeitern auf, oder vergeben Sie diese an externe Unternehmen.

A12. Koordination und Verantwortlichkeiten geklärt

Es ist wichtig, dass eine Person die Verantwortung übernimmt, das Projekt koordiniert und vorantreibt sowie auf die Einhaltung des Zeitplans achtet.

A13. Mitarbeiter aufgeklärt und Commitment eingeholt

Häufig ist dieser Punkt besonders wichtig, da sich Interessen unterscheiden. Wenn Mitarbeiter kein Verständnis für Ihr Projekt haben, wird dieses höchstwahrscheinlich scheitern. Stellen Sie daher den Mitarbeitern die Projektziele und die sich konkreten Vorteile (z. B. für die spezifischen Arbeitsplätze), welche sich durch das Projekt ergeben bspw. in einem Workshop vor. Dies kann die Akzeptanz unter Mitarbeitern fördern. Versuchen Sie über die Projektlaufzeit regelmäßig den Fortschritt des Projektes für die Mitarbeiter transparent darzustellen. Hilfreich ist auch „Projekt-Gegner“ zu identifizieren, zu integrieren und deren Bereitschaft zur Unterstützung des Projektes sicherzustellen. Zusätzliche Informationen und Ansätze finden sich in dem Buch *Change-Management - Mitarbeiter mobilisieren. Vision, Kommunikation, Beteiligung, Qualifizierung von Stolzenberg et al.* [2].

A14. Lastenheft erstellt

Erstellen Sie ein Lastenheft, auch Anforderungskatalog genannt, mit allen konkreten Anforderungen, die es im Rahmen des Projektes zu erfüllen gilt.



Bild: sornthanashatr – stock.adobe.com

3. Mess- und Datenplanung (B)

Nachdem die ersten Vorbereitungen abgeschlossen wurden, kann die eigentliche Mess- und Datenplanung beginnen. Zunächst ist es wichtig, grundlegendes Wissen über Produkte, Prozesse und Anlagen zu erfassen bzw. aufzubauen und dabei bereits existierende Normen und Standards zu identifizieren. Ihre Daten werden in der Regel nicht nur innerhalb einer Abteilung genutzt, daher ist eine einheitliche und für alle Parteien verständliche Datenstruktur mit allen notwendigen Metadaten essenziell.

Hinweis:

Die Mess- und Datenplanung ist ein iterativer Prozess und darf (bzw. muss, wenn erforderlich) angepasst werden.

Tipp:

Achten Sie zu jeder Zeit in Ihrem Projekt auf die Wiederauffindbarkeit von Wissen/Informationen! Nutzen Sie dazu in Ihrem Unternehmen vorhandene Strukturen und Vorgehensweisen zur Datenablage und Dokumentation. Falls Sie eine eigene Struktur aufbauen müssen, orientieren Sie sich an den FAIR-Data Prinzipien, siehe <https://www.fairsharing.org/>. FAIR steht für Findable (auffindbar), Accessible (zugänglich), Interoperable (interoperabel) und Reuseable (wiederverwendbar).

Beachten Sie, dass „FAIR“ Daten nicht gleichzusetzen sind mit „offenen“ Daten (open data), da sich die Auffindbarkeit bzw. Zugänglichkeit auch exklusiv auf Ihr Unternehmen bzw. einzelne Abteilungen beziehen kann.

3.1 Prozesswissen aufbauen und nutzen

B1. Bereits existierende Merkmale identifiziert

Welche Merkmale werden bereits in Ihrer Anlage bzw. Ihrem Prozess aufgezeichnet und für wen (welche Abteilung) sind diese relevant? Z. B.: Welche Merkmale sind für die Montage-, Qualitäts- bzw. Konstruktionsabteilung interessant?

B2. Qualitätsanforderungen recherchiert

Sprechen Sie mit Ihrer Qualitätssicherung und/oder Ihren Kunden und dokumentieren Sie wichtige Mess-/Prüfgrößen.

B3. Ursache-Wirkungs-Diagramm erstellt

Erstellen Sie ein Ursache-Wirkungs-Diagramm, auch Ishikawa-Diagramm genannt. Dieses hilft Ihnen, Ursachen- bzw. Einflussfaktoren, welche ihre Daten (und somit auch ihre Zielgröße) beeinflussen, zu identifizieren. Eine leicht verständliche Erklärung des Ursache-Wirkungs-Diagramm finden Sie in [3].

B4. Störgrößen identifiziert und deren Einfluss bestimmt

Um ein robustes maschinelles Lernmodell zu erhalten, ist die Bestimmung von Störgrößen und die Berücksichtigung ihres Wertebereichs bzw. ihres Einflusses enorm wichtig, da die Lernmodelle in der Regel nicht extrapolieren können. Störgrößen können bspw. Temperatur, Luftfeuchte, Herstellertoleranzen und auch Mitarbeiter (Handarbeitsplätze) sein. Bei der Bestimmung der Störgrößen kann Sie das Ursache-Wirkungs-Diagramm und gegebenenfalls der Prozessexperte unterstützen.

Hinweis:

Bei der Aufzeichnung von Daten sollten die relevantesten von Ihnen identifizierten Stör- bzw. Einflussgrößen enthalten sein. Falls möglich können Sie auch bewusst diese Störgrößen in Vorversuchen herbeiführen.

Tipp:

Wenn Sie sich für die Nutzung zusätzlicher Sensorik entscheiden und sich nicht sicher sind, welche Sensoren Sie benötigen, probieren Sie zunächst genauere bzw. hochwertigere Sensoren aus. Viele Sensorik-Hersteller unterstützen Sie auch bei der Auswahl von Sensoren und stellen Ihnen diese für Testmessungen zur Verfügung. Alternativ bieten manche Unternehmen auch Sensorik zum Mieten an.

B5. Einfluss von Störgrößen minimiert

Entsprechend dem Punkt „Einfluss von Störgrößen bestimmt“ ist es sinnvoll, den Einfluss von Störgrößen zu minimieren. Prüfen Sie, inwieweit dies in Ihrem Projekt möglich ist. Beispielsweise hilft die Beschränkung auf eine einzelne (Produkt-)Variante, um Einflüsse der Baugröße zu eliminieren.

B6. Nutzung zusätzlicher Sensorik erwogen

Wenn Sie bspw. aufgrund Ihres Ursache-Wirkungs-Diagramms oder einer Empfehlung Ihrer Prozessexperten interessante bzw. relevante Messgrößen oder Kennwerte identifizieren konnten, erwägen Sie die Anbringung

zusätzlicher Sensorik, um diese zu erfassen. Zusätzliche Sensoren müssen nicht zwangsweise physisch sein, es können auch virtuelle Sensoren genutzt werden, die ihre Werte aus physikalischen Messgrößen berechnen.

B7. Sensorübersicht erstellt

Erstellen Sie eine Übersicht über die eingesetzte Sensorik mit allen relevanten Informationen. Sie können sich an den folgenden Punkten orientieren:

- Sensorbezeichnung
- Sensorart
- IP-Adresse
- Hersteller
- Messgröße
- Einheit
- Messbereich
- Abtastrate/Auslesemethode
- Bandbreite
- Auflösung
- Messunsicherheit
- Ausgangssignal (Analog/Digital, Kommunikation, Spannung)

Eine Vorlage für eine solche Übersicht der Sensorik finden Sie auf der letzten Seite dieses Dokumentes als Anhang.

3.2 Normen und Standards nutzen

B8. Interne Standards recherchiert

Viele Unternehmen haben bereits eigene Standards und Richtlinien zur Datenaufzeichnung entwickelt. Diese sollten Sie zunächst prüfen und bei Eignung nutzen.

B9. Externe Standards und Normen recherchiert

Prüfen Sie, ob bereits etablierte Standards oder Normen zur Datenaufzeichnung in ihrer Branche bzw. in der Industrie allgemein existieren.

Hinweis:

Sofern es für Ihren Bereich bereits Normen oder Standards gibt, wird dringend empfohlen, diese auch zu nutzen bzw. auf ihnen aufzubauen. Hier sind bspw. die Internationale Organisation für Normung (ISO), das Europäische Komitee für Normung (CEN bzw. CENELEC) und national das Deutsche Institut für Normung (DIN) zu beachten.

Für die Automobilbranche z. B. bietet u.a. die Association of Standardization of Automation and Measuring Systems, kurz ASAM, Standards in diversen Disziplinen wie Messsystemen, Data Management, Simulation und vielen weiteren an.

3.3 Messunsicherheiten

B10. Quellen von Messunsicherheiten bestimmt

Überlegen Sie, bspw. mithilfe des Ursache-Wirkungs-Diagramms (B3), wo in Ihrer Messkette Messunsicherheiten auftreten können. Messunsicherheiten sind nicht nur durch den Sensor selbst bedingt, sondern auch durch Umgebungseinflüsse wie Temperaturschwankungen oder Feuchte.

B11. Unsicherheiten der Messmittel bestimmt

Entweder Sie verfügen über kalibrierte Sensoren und finden die entsprechenden Unsicherheiten im Kalibrierzertifikat, oder Sie führen eine grobe Abschätzung der Messunsicherheiten mithilfe des Sensordatenblattes des Herstellers durch.

Tipp:

Die Physikalisch-Technische Bundesanstalt in Braunschweig forscht aktiv an dem Thema Messunsicherheiten. Dort findet sich auch eine Einführung in das Thema Messunsicherheiten, sowie Beispiele [7], [8].

Die in E13 erwähnte ML-Toolbox (<https://github.com/ZeMA-gmbH/LMT-UA-ML-Toolbox>) verfügt über eine Version mit Unsicherheitsberechnungen inkl. Unsicherheitsfortpflanzung für Klassifikations- als auch Regressionsaufgaben.

Hinweis:

Die Bestimmung von Messunsicherheiten ist wichtig, aber oftmals nicht trivial.

Um die Qualität und Zuverlässigkeit der Messdaten und des maschinellen Lernmodells zu bewerten und gewährleisten ist die Berücksichtigung von Messunsicherheiten essenziell. Ohne Angabe der Messunsicherheit sind Messergebnisse unvollständig. Daher sind diese für die Vertrauenswürdigkeit der Lernmodelle bei hohen Qualitätsansprüchen unbedingt erforderlich. Denn insbesondere bei preiswerter Sensorik (im Sinne der Messgenauigkeit) kann die Messunsicherheit entsprechend hoch sein.

Für die Bestimmung der Messunsicherheit ist oftmals Expertenwissen oder die Kalibrierung von Sensorik notwendig und eine schnelle Auswertung nicht ohne weiteres möglich. Eine weit verbreitete und international anerkannte Vorgehensweise zur Bestimmung der Messunsicherheiten ist im Guide to the expression of Uncertainty in Measurement (GUM) und seiner beiden Supplemente (GUM-S1 und GUM-S2) zu finden [4]–[6]. Ggf. existiert in Ihrem Unternehmen ein Prüfmittelbeauftragter, den Sie zu Rate ziehen können.

3.4 Aufbau der Daten

B12. Datenformat ausgewählt

Halten Sie Rücksprache mit Ihren (ggf. externen) Prozess- und Datenanalyseexperten und wählen Sie einheitlich ein passendes Dateiformat aus. Idealerweise sollte das Dateiformat nicht proprietär und bereits etabliert sein, sowie möglichst einfach um Metadaten ergänzt werden können.

B13. Datenstruktur ausgewählt

Überlegen Sie, wie Sie Ihre Daten sinnvoll strukturieren. Hier sind weder unzählige kleine Dateien noch eine große Datei mit allen Daten empfehlenswert. Berücksichtigen Sie ggf. die Kompatibilität der Datenstruktur mit bereits existierenden/verwendeten Datenbanken.

B14. Eindeutige Benennung der Daten gewählt

Durch eine eindeutige Benennung Ihrer Daten steigern Sie die Handhabbarkeit Ihrer Daten ungemein.

B15. Beschreibende Benennung der Daten gewählt

Durch eine beschreibende Benennung (bspw. Datum_Uhrzeit_Produkt_Station_Sensor) Ihrer Daten steigern Sie die Handhabbarkeit Ihrer Daten ebenfalls. Der mögliche Detailgrad für eine beschreibende Benennung hängt stark von der Komplexität Ihrer Anlage und Ihres Vorhabens ab, denn zu lange Dateinamen können ebenfalls zu Problemen in der Analyse führen.

B16. Eindeutige Beziehung der Daten zu den Produkten, Prozessen oder Anlagen hergestellt

Um später eine übergreifende Auswertung zu ermöglichen, ist eine eindeutige Zuordnung der Daten zu den jeweiligen Produkten, Prozessen oder Anlagen, z. B. über eine eindeutige Identifikationsnummer (ID), unbedingt notwendig.

B17. Aufzuzeichnende Metadaten ausgewählt

Wählen Sie alle für Sie relevanten Metadaten, bestenfalls in Abstimmung mit anderen beteiligten Abteilungen aus. Relevante Metadaten können bspw. Informationen und Parameter von Produkten, Prozessen oder Anlagen sein. Empfehlenswert ist die Berücksichtigung der Maschinenlesbarkeit und die Verwendung von Standards bei der Benennung.

B18. Verständliche Beschreibung der Metadaten gewählt

Jede Messung muss eindeutig, vollständig und verständlich beschrieben sein. Mithilfe der Metadaten bzw. einer Dokumentation sollte ein Projektfremder grundsätzlich in der Lage sein, die W-Fragen (Wer?, Was?, Wie?, Wo?, Wann?, Warum?) zu beantworten.

B19. Automatische Annotation der Metadaten sichergestellt

Händisches bzw. nachträgliches Annotieren stellt, speziell bei hohen Stückzahlen oder komplexen Prozessen, ein potenzielles Risiko für fehlerhafte Metadaten dar.

Tipp:

Durch einen einheitlichen Aufbau und ein geeignetes Datenformat werden die Daten zugänglicher und können leichter verarbeitet werden. Aus verschiedenen Erfahrungen haben sich einige „Best Practices“ für Datenformate entwickelt. So eignet sich zum Beispiel für größere Datenmengen ein binäres Format wie HDF5 [9] oder ähnlichen (TDMS für NI LabVIEW [10]) aufgrund ihrer einfachen Strukturierung und Verwendung. Bei kleineren Datenmengen bieten sich dagegen Formate an, welche offen (nicht proprietär) und für Menschen besser lesbar sind. Dazu zählt beispielsweise das CSV-Format [11], welches vor allem bei manuell (bspw. in MS Excel) erfassten Daten sinnvoll ist. Das JSON-Format [12] eignet sich hingegen als mensch- und maschinenlesbares Austauschformat für automatisierte Systeme (bspw. Datenbanken).

B20. Format von Zeitstempeln festgelegt und dokumentiert

- Welches Format?
- Datum und Uhrzeit gemeinsam oder getrennt angeben?
- z. B. Datum (TT.MM.JJJJ); Uhrzeit (hh:mm:ss)
- Eindeutige Uhrzeitreferenz (UTC, Lokalzeit, andere?)

 B21. Bezugssysteme geklärt und dokumentiert

Stimmen Sie Nullpunkte, Referenzen und Koordinatensysteme Ihrer Prozesse bzw. Maschinen gemeinsam ab und dokumentieren Sie diese in den Metadaten. Bspw. ist der Nullpunkt einer Temperaturskala nach Celsius, Fahrenheit und Kelvin verschieden und die Auswirkung eines unklaren Bezugssystems damit entsprechend hoch. Gleiches gilt bspw. auch für Längenmaße wie Kilometer und Meilen.

 B22. Kennzeichen von Referenzfahrten und Testmessungen

Sollten die von Ihnen aufzuzeichnenden Daten auch Referenzfahrten, Testmessungen, Referenzmuster oder ähnliche vom Normalbetrieb abweichende Messungen enthalten, kennzeichnen Sie diese, bestenfalls automatisch, eindeutig als solche oder speichern Sie diese separat ab.

 B23. Speicherung von Grenzwerten

Speichern Sie die Grenzwerte von einzelnen Prozessen und ggf. Anlagen, Prozessen und Betriebsmitteln ebenfalls in den Metadaten.

 B24. Klare Definition von Messwerten und Kennzahlen bereitgestellt

Gerade bei Kennzahlen können oftmals unterschiedliche Formeln zur Berechnung herangezogen werden. Definieren und dokumentieren Sie daher die verwendeten Formeln, um diese später nachvollziehen zu können.

 B25. Nicht-Digitales Wissen bzw. Daten digitalisiert und gesichert

Oftmals finden sich hilfreiche Informationen in nicht-digitalem Wissen und Daten, z. B. Schichtbüchern oder handschriftlichen Dokumenten. Sichern Sie diese Informationen durch Digitalisierung, im einfachsten Fall durch ein Foto oder einen Scan, und speichern Sie diese mit Ihren Daten.

3.5 Datenablage

 B26. Vorhandene Datenerfassungssysteme eingebunden

Versuchen Sie, alle (relevanten) erfassten Daten vorhandener Datenerfassungssysteme, bestenfalls automatisiert und zentral in Ihrer Datenablage einzubinden.

 B27. Speicherbedarf abgeschätzt

Schätzen Sie den benötigten Speicherbedarf ab und planen Sie eine zusätzliche Sicherheitspuffer ein. Beachten Sie hier auch, dass unterschiedliche Datenformate (B12) einen unterschiedlichen Speicherbedarf haben.

 B28. Geeignete Plattform für Datenablage gewählt

Wählen Sie, ggf. unter Berücksichtigung von Firmenrichtlinien und dem voraussichtlichen Speicherplatzbedarf, eine geeignete Plattform zur Datenablage. Beispiele wären: Festplatte, Server oder Cloud. Beachten Sie bei sensiblen Daten die jeweils gültigen Sicherheitsstandards (insbesondere bei Servern außerhalb der EU).

 B29. Zugriffsrechte definiert

Definieren Sie wer (z. B. welche Abteilung, Mitarbeiter etc.) Zugriff auf Ihre abgelegten Daten erhält.

 B30. Datensicherung ausgewählt

Um den Verlust von Daten zu verhindern, sollten Sie Ihre Daten mit einer geeigneten Strategie speichern (bspw. der 3-2-1-Back-up Regel [13] in Kombination mit RAID-Systemen).

Hinweis:

Erfahrungsgemäß sind die Schnittstellen vom Sensor zum Server nicht so schnell implementiert wie gewünscht/gedacht. Typische Beispiele wären u.a. das Durchlaufen interner Freigabeprozesse, VPN-Verbindungen oder Firewalls. Planen Sie hier ggf. zusätzliche Zeit ein.

3.6 Manuelle Datenquellen einbinden

 B31. Menschlichen Einfluss reduziert

Reduzieren Sie den menschlichen Einfluss auf die Daten so weit wie möglich, z. B. durch:

- Einheitliche Benamung anhand eines Glossars
- Dropdownlisten
- Fehlerkategorien
- Standard-Fehlercodes

Tipp:

Die Nutzung von Standards und Dropdownlisten erleichtern die Maschinenlesbarkeit manuell erfasster Daten.

B32. Digitale Schichtbücher eingeführt

Die Einführung von digitalen Schichtbüchern erhöht die Zugänglichkeit der darin enthaltenen Informationen enorm [14]. Gerade bei Unstimmigkeiten in den Daten kann das Schichtbuch wertvolle Informationen geben.

Hinweis:

Manuell erfasste Daten enthalten oft relevante Information für die Interpretation von Ereignissen in Daten und sind daher wichtig für die Analyse bzw. das Verständnis der Daten.

B33. Durchgängige Speicherung von Zustandsänderungen sichergestellt

Alle Arten von Eingriffen, Änderungen und Anpassungen an Produkten, Prozessen und Anlagen müssen dokumentiert werden.

B34. Kommentarfeld bei Bedarf implementiert

Gerade bei unvorhersehbaren Komplikationen kann ein Feld für zusätzlichen Fließtext, obwohl dieser nicht unmittelbar maschinenlesbar ist, für die Fehlerbeschreibung sinnvoll sein.

B35. Bilder als zusätzliche Datenquelle eingebunden

Auch Bilder, gerade bei mechanischen Defekten, können für Ihre Analysen hilfreich sein.

B36. Zuordnung manuell erfasster Daten zu automatisiert erfassten Daten ermöglicht

Ermöglichen Sie die Zuordnung von manuellen Daten zu automatisierten Daten, bspw. über Zeitstempel, eindeutige ID o.ä. Beachten Sie, dass Metadaten auch hier eine wichtige Rolle spielen.



Bild: chaylek – stock.adobe.com

4. Datenaufnahme (C)

Nachdem die Mess- und Datenplanung erfolgt ist, können erste Daten aufgenommen werden. Eine scharfe Trennung zwischen Mess- und Datenplanung und

Datenaufnahme ist nicht möglich, da Sie im Normalfall, nachdem Sie erste Daten aufgezeichnet haben, weitere Anpassungen vornehmen müssen.

C1. Notwendige Vorbereitungen zur Datenaufnahme getroffen

Stellen Sie sicher, dass alle notwendigen Vorbereitungen der vorherigen Kapitel umgesetzt wurden und die Hard- und Software bereit zur Datenaufnahme ist.

4.1 Erste Testmessung und Überprüfung der Datenqualität

C2. Testmessung durchgeführt

Führen Sie eine erste Testmessung unter Realbedingungen durch. Die Messung sollte nicht zu umfangreich sein, aber dennoch von allen Sensoren mehrere Messungen enthalten.

C3. Datenstruktur überprüft

Überprüfen Sie, ob die Daten in der gewünschten Struktur (Messwerte und Metadaten) gespeichert wurden. Leiten Sie einen ersten Teil der aufgezeichneten Daten an die Experten bzw. Datenanalysten weiter und stellen Sie sicher, dass die Datenstruktur verständlich, vollständig und praktikabel ist.

Tipp:

Anfangs, bzw. später in regelmäßigen Abständen, ist das Aufzeichnen von zeitkontinuierlichen Daten („Kurvendaten“) sinnvoll. Bsp.: Nach einer Anzahl X an Messungen werden für die Anzahl Y an Messungen zeitkontinuierliche Daten aufgezeichnet. So können Sie zu einem späteren Zeitpunkt auch auf diese zurückgreifen, falls sie andere Analysemethoden testen möchten.

C4. Ordnungsgemäße Funktion der Sensoren überprüft

Überprüfen Sie, bestenfalls mit den Experten, ob die Sensoren ordnungsgemäß funktionieren und plausible Werte liefern. Dazu können Sie sich bspw. die entsprechenden Datenpunkte plotten und den Messverlauf überprüfen. Zeichnen Sensoren keine oder unerwartet konstante Messwerte (wie bspw. 0) auf, kann dies auf einen Fehler bei der Datenerfassung bzw. -speicherung hinweisen. Überprüfen Sie auch, ob Sie Quantisierungsstufen in Ihren Messsignalen erkennen können und ersetzen Sie ggf. den Sensor durch einen Sensor mit höherer Auflösung oder besserem Analog-Digital-Umsetzer (ADC).

 C5. Synchronität der Datenerfassungssysteme sichergestellt

Überprüfen Sie, ob Ihre Datenerfassungssysteme ausreichend synchron zueinander laufen. Hierzu ist es notwendig die maximal zulässige zeitliche Abweichung Ihrer Prozesse und Anlagen zu kennen. Dieser Schritt ist insbesondere für die zeitliche Zuordnung der Daten über Prozesse und Anlagen hinweg wichtig. Beispielsweise kann es sein, dass die Uhrzeit auf Anlage 1 um 3 Minuten von der Uhrzeit auf Anlage 2 abweicht. Wenn Sie nun versuchen die Daten über den Zeitstempel zusammenzufügen, kann es (je nach gefertigten Produkten pro Minute) passieren, dass die Daten von unterschiedlichen Produkten durch den zeitlichen Versatz einander zugeordnet werden. Beachten Sie auch einen möglichen zeitlichen Versatz durch Puffer zwischen Prozessen bzw. Anlagen.

 C6. Zuordnung der Daten zu Prozessen, Produkten und Anlagen sichergestellt

Stellen Sie sicher, dass Ihre Daten eindeutig den entsprechenden Produkten, Prozessen und Anlagen zugeordnet werden können (bspw. über die eindeutige ID). Nur dann sind übergreifende Analysen möglich.

 C7. Datenqualität beurteilt

Versuchen Sie, die Qualität Ihrer Daten zu beurteilen und diese ggf. zu steigern, z. B. anhand der 15 IQ-Dimensionen [15]:

- Zugänglichkeit
- Angemessener Umfang
- Glaubwürdigkeit
- Vollständigkeit
- Übersichtlichkeit
- Einheitliche Darstellung
- Bearbeitbarkeit
- Fehlerfreiheit
- Eindeutige Auslegbarkeit
- Objektivität
- Relevanz
- Hohes Ansehen
- Aktualität
- Verständlichkeit
- Wertschöpfung

 C8. Automatische Überprüfung der Datenqualität integriert

Integrieren Sie eine automatische Überprüfung, z. B. in Form einer Datenpipeline, der für Sie relevanten Datenqualitätskriterien.

4.2 Langzeitdatenaufnahme

 C9. Prüfintervalle festgelegt

Legen Sie regelmäßige Intervalle zur Überprüfung der Datenqualität (C2-C7) fest. Anfangs sollte dies häufiger erfolgen, um bei Fehlfunktion frühzeitig eingreifen zu können.

 C10. Langzeitdatenaufnahme gestartet

Starten Sie die Langzeitaufnahme der Daten. Führen Sie gemäß Checkpunkt C9 regelmäßige Prüfintervalle durch, um bei Fehlfunktionen zeitnah reagieren zu können.

 C11. Verteilung der Daten geprüft

Prüfen Sie die Verteilung Ihrer Daten, bspw. mit Hypothesentests. Eine gängige Verteilung in der Industrie ist, u.a., die Normalverteilung, welche sich z. B. durch den Anderson-Darling-Test prüfen lässt [16].

 C12. Erste Datenanalyse durchgeführt

Führen Sie eine erste Datenanalyse (vgl. Kapitel Datenauswertung und Modellbildung) durch, um frühzeitig relevante Sensoren bzw. Merkmale zu identifizieren und deren Verhalten zu interpretieren. Gegebenenfalls merken Sie, dass Sensoren ungünstig ausgewählt oder platziert wurden.



Bild: Ticha – stock.adobe.com

5. Datenprüfung und Datenbereinigung (D)

Selbst bei einer optimalen Planung und bestmöglicher Durchführung Ihrer Messungen werden Fehler passieren. Daher müssen Sie die Daten nach der Aufnahme prüfen und bereinigen. Diese Fehler müssen nicht zwangsweise menschlicher Natur sein, sondern können auch von Ihren Datenerfassungssystemen kommen. Dies ist gerade bei solch iterativen Ansätzen ein normaler Vorgang und sollte Sie nicht verunsichern.

D1. Datenstruktur erneut überprüft

Überprüfen Sie, ob die aufgezeichneten Daten in der gewünschten Struktur vorliegen und korrigieren Sie Abweichungen.

D2. Fehlende Informationen ergänzt

Ergänzen Sie ggf. fehlende Informationen wie z. B. Zielgrößen oder Metadaten.

D3. Datensätze kombiniert

Sollten Sie mehrere einzelne Datensätze, bspw. von mehreren Datenerfassungssystemen, haben, können Sie diese über die eindeutige ID oder den Zeitstempel kombinieren, woraus sich ggf. zusätzliche Erkenntnisse über Produkte, Prozesse und Anlagen ableiten lassen.

D4. Blinde Flecken identifiziert und verifiziert

Bereiche, in denen Daten nicht aufgenommen werden (können), werden als blinde Flecken bezeichnet. Die Lücken in den Daten, die durch blinde Flecken entstehen, sollten durch Erfahrungswissen und physikalische Zusammenhänge Ihrer Experten geschlossen und bestenfalls verifiziert werden. Oftmals sind blinde Flecken nicht leicht zu identifizieren und nur im Rückblick erkennbar.

D5. Daten von fehlerhaften Messungen bereinigt

Entfernen Sie Messungen aus Ihrem Datensatz, bei denen der Messwert (ungeplant) immer den gleichen Wert oder Null angenommen hat.

D6. Referenzen und Nullpunkte angepasst

Sollten Sie unterschiedliche Referenzen oder Nullpunkte für Messdaten oder Zeitstempel verwenden, überführen Sie diese ineinander, um ein gleiches Bezugssystem zu gewährleisten.

D7. Referenzfahrten und Testmessungen separiert

Sollten die von Ihnen aufgezeichneten Daten auch Referenzfahrten, Testmessungen oder ähnliche, vom Normalbetrieb abweichende Messungen enthalten, sortieren Sie diese aus. Dabei sollten Sie diese nicht einfach löschen, da ggf. Informationen über den Zustand Ihrer Produkte, Prozesse und Anlagen über die Zeit gewonnen werden können.

D8. Ausreißer aus Auswertung entfernt

Als Ausreißer werden Messwerte bezeichnet, die erkennbar und begründbar von den restlichen Messwerten und deren Varianz abweichen [17]. Entfernen Sie Ausreißer aus Ihrer Auswertung, sofern diese physikalisch nicht plausibel sind oder die Verteilung Ihrer Daten signifikant beeinflussen.

D9. Einheiten geprüft und vereinheitlicht

Unvollständige, fehlende oder falsche Einheiten stellen ein großes Risiko in der Datenanalyse dar. Im Beispiel der Längenmessung macht es einen großen Unterschied, ob Sie bspw. in Metern oder Inches messen. Überführen Sie alle Messwerte einer Messgröße in die gewählte Standardeinheit. Prüfen Sie daher, ob ihre Einheiten gemäß ihrer Planung aufgezeichnet wurden und passen Sie dies ggf. an.

D10. Datendrift ausgeglichen

Überprüfen Sie, ob Ihre Daten driften (sich über die Zeit verschieben) und gleichen Sie diesen Drift ggf. aus, sofern dieser nicht die gewünschte Information ist.

D11. Bereinigung dokumentiert

Dokumentieren Sie die durchgeführten Schritte, ggf. mit zusätzlichen Bemerkungen.



Bild: Kiattisak – stock.adobe.com

6. Datenauswertung und Modellbildung (E)

Bei der Datenauswertung kann und sollte das maschinelle Lernen nicht als allmächtig betrachtet werden. Vielmehr sollte es als Kompass gesehen werden, der den Datenbetrachter auf den richtigen Weg zur Interpretation der Daten führt. Bevor Sie mit der Erstellung eines maschinellen Lernmodells beginnen, sollten Sie zunächst ein grundlegendes Datenverständnis über Ihre Daten aufbauen.

6.1 Datenvisualisierung und Datenverständnis

E1. Geeignete Zeitskala für die Visualisierung ausgewählt

Nutzen Sie eine geeignete Zeitskala für die Visualisierung Ihrer Daten. Bspw. verändert sich die Umgebungstemperatur nur in seltenen Fällen innerhalb von wenigen Minuten schlagartig, Drifts können über den Tag oder über die Woche hinweg entstehen. Geeignete Betrachtungszeiträume könnten daher z. B. schichtweise, tageweise oder wochenweise sein.

E2. Signalverläufe im Zeitreihendiagramm geplottet

Schauen Sie sich die Signalverläufe Ihrer Messungen beispielhaft an. Fokussieren Sie sich hier nicht ausschließlich auf ein Signal, sondern plotten Sie auch mehrere Messungen (desselben oder verschiedener Sensoren) in ein Diagramm. Versuchen Sie so, ein Gefühl für Ihre Daten und die zugehörigen Produkte, Prozesse und Anlagen zu bekommen.

E3. Quasi-statische Signale geplottet

Auch das quasi-statische Signal kann Ihnen Informationen über Ihren Prozess liefern, bspw. können Sie dadurch Drifteffekte leichter identifizieren. Als quasi-statisches Signal wird im Rahmen dieses Beitrages ein Signal bezeichnet, welches durch die Aneinanderreihung eines ausgewählten Datenpunktes über mehrere Messreihen entsteht. Ein anschauliches Beispiel wäre die Betrachtung eines Temperaturverlaufs zu einer bestimmten Uhrzeit über mehrere Tage hinweg.

E4. Histogramme geplottet

Histogramme bieten ebenfalls wertvolle Einblicke in Ihre Daten. Oftmals lassen sich durch das Darstellen des Histogramms leichter Ausreißer identifizieren. Auch bspw. spezifische Änderungen an Produkten, Prozessen und Anlagen ggf. im Histogramm erkannt werden.

E5. Boxplot-Diagramm geplottet

Durch die übersichtliche Darstellung mehrerer Lage- und Streumaße von Daten bspw. eines Prozesses, Produktes oder Anlage in einer einzelnen Box lassen sich diese einfach miteinander vergleichen [18].

E6. Hauptkomponentenanalyse durchgeführt

Eine Hauptkomponentenanalyse (PCA: Principal Component Analysis) in Kombination mit aussagekräftigen Zielgrößen kann dazu genutzt werden, die größten Einflüsse auf die Daten zu ermitteln. Durch das Einfärben nach Zielgröße (oder auch Störgrößen wie z. B. Umgebungstemperatur, Schichten oder Chargen) lassen sich ggf. Cluster erkennen. Eine leicht zugängliche Erklärung finden Sie in [19].

E7. Fehlerbilder untersucht und interpretiert

Untersuchen und interpretieren Sie nicht nur Fehlerbilder in einzelnen Anlagen oder Stationen, sondern auch deren Auswirkung im Gesamtsystem.

Hinweis:

- Nur Gleiches mit Gleichem vergleichen.
- Bei einem Vergleich mit zwei oder mehr Diagrammen: Achsen korrekt beschriften, gleich skalieren und gleiche Einheiten nutzen.

6.2 Auswahl von maschinellen Lernalgorithmen

E8. Stand der Technik überprüft

Recherchieren Sie, durch Web- oder Literatursuche oder die Teilnahme an Fortbildungen bzw. ggf. Fachkonferenzen, den aktuellen Stand der Technik. Eventuell wurden bereits ähnliche Szenarien überprüft und passende Algorithmen vorgestellt, an denen Sie sich orientieren können.

E9. Verfügbare Rechenleistung überprüft

Ein nicht zu unterschätzendes Kriterium bei der Auswahl von maschinellen Lernalgorithmen und speziell bei deren Parameteroptimierung ist die notwendige Rechenleistung und der notwendige Speicherbedarf. Je geringer Ihre verfügbare Rechenleistung ist, desto länger dauert auch Ihre Berechnung und desto länger ist Ihr System blockiert, wenn Sie nicht auf ressourcensparende Algorithmen ausweichen. Ggf. können Sie auch das Training der Algorithmen auf Clouddienste o.ä. auslagern. Halten Sie hier ggf. Rücksprache mit Ihren Fachexperten.

Hinweis:

Je nach ausgewähltem Algorithmus und Umfang der Daten kann das Training eines maschinellen Lernmodells inkl. Validierung schnell von mehreren Stunden über mehrere Tage hin zu mehreren Wochen erfordern. Dies sollten Sie unbedingt berücksichtigen und zunächst einfache Modelle bzw. Algorithmen erproben.

E10. Lernproblem definiert

Prinzipiell wird im industriellen Kontext zwischen drei Lernproblem unterschieden:

- Klassifikationsproblemen, bspw. beschädigt/unbeschädigt, Schaden A/B/C oder iO/niO
- Regressionsproblemen, bspw. Lebensdauer (0-100%)
- Anomalie-Erkennung, der Erkennung neuer Zustände hervorgerufen durch geänderte Randbedingungen oder Störgrößen

Je nach ausgewähltem Lernproblem kommen unterschiedliche Algorithmen in Frage.

Tipp:

Sollten Sie keine oder nur wenig Erfahrung mit maschinellem Lernen haben, erwägen Sie die Auslagerung der Datenanalyse. Dies muss nicht zwangsweise an ein Unternehmen sein. Über Forschungsprojekte (als aktiver oder assoziierter Partner) oder Direktaufträge können Sie sich auch an Forschungsinstitute oder Hochschulen wenden. Dort finden sich oftmals motivierte Forschende mit Fachexpertise, deren Zugang zu „Daten aus der echten Welt“ allerdings oftmals sehr beschränkt ist. Auf diese Weise können sowohl Industrie als auch Forschung profitieren.

E11. Passendes und realistisches Validierungsszenario ausgewählt

Der vielleicht wichtigste und oftmals am meisten unterschätzte Punkt im maschinellen Lernen ist die Auswahl eines passenden Validierungsszenarios. Ein maschinelles Lernmodell zu erzeugen, welches Ihnen mit einer Genauigkeit von 100% Ihre Daten klassifiziert (Klassifikationsproblem) oder die gewünschte Zielgröße vorhersagt (Regressionsproblem), ist prinzipiell einfach. Allerdings ist dieses Modell höchstwahrscheinlich unzuverlässig und leidet unter Überanpassung (Overfitting), d.h. es lernt im einfachsten Fall die Testdatenmuster auswendig. Durch das bewusste Einteilen Ihrer Daten in Trainings-, Validierungs- und Testdaten können Sie überprüfen, wie gut Ihr Modell bei den „unbekannten“ Daten performt. Die (gruppenbasierte) Kreuzvalidierung ist ein etabliertes Verfahren zur Vermeidung von Overfitting. Zeichnen Sie auch Ihre Daten mit möglichst vielen realistischen „Störgrößen“ (bspw. Umgebungsparameter, Hersteller-

Tipp:

Einen guten Einstieg in die Validierung maschineller Lernalgorithmen bieten Maleki et al. in ihrem Review-Paper „Machine Learning Algorithm Validation – From Essentials to Advanced Applications and Implications for Regulatory Certification and Deployment“ [20].

toleranzen) auf und beschreiben Sie diese in den Messungen. Nun können Sie durch bewusstes Herauslassen einzelner Störgrößen die Robustheit gegenüber dieser Störgröße testen. Bspw. können Sie Ihre Charge A trainieren und validieren und auf Charge B testen. Achten Sie darauf, mit einem (oder mehreren) realistischen Validierungsszenarien die tatsächliche Übertragbarkeit Ihres Algorithmus zu testen.

E12. Datenvorverarbeitung ausgewählt

Prüfen Sie, ob Ihre Daten durch die Auswahl geeigneter Methoden der Datenvorverarbeitung aussagekräftiger werden, wie z. B. eine Normalisierung oder die Anwendung von Filtern.

E13. Algorithmen zur Merkmalsextraktion ausgewählt

Werden ganze Zeitreihen aufgezeichnet, sind die einzelnen Messpunkte einer Messung oftmals nur von geringer Aussagekraft. Daher gilt es, aus diesen relevante Merkmale zu extrahieren. Dies können z. B. Mittelwerte und Steigungen über festgelegte Intervalle (linearer Fit), Frequenzen aus dem Frequenzspektrum oder statistische Größen (Standardabweichung, Kurtosis) sein. Durch die Merkmalsextraktion wird die Dimensionalität der Daten i.d.R. erheblich reduziert (Datenreduktion), was einerseits die Berechnung geeigneter Modelle vereinfacht, andererseits die Tendenz zum Overfitting reduziert. Werden direkt Merkmale aufgezeichnet (z.B. Maximalwerte oder Mittelwerte), ist eine Merkmalsextraktion nicht erforderlich.

E14. Algorithmen zur Merkmalsselektion ausgewählt

Gerade bei komplexen Prozessen, Produkten und Anlagen mit einer hohen Anzahl an hochfrequent abgetasteten Sensoren kann eine sehr hohe Anzahl an Merkmalen resultieren. Um Ressourcen (Rechenleistung und Zeit) zu schonen und der Überanpassung vorzubeugen, kann die Anzahl an Merkmalen durch Selektion der relevantesten reduziert werden. Dies kann auch durch simple Algorithmen wie z. B. eine Korrelationsana-

Tipp

- Im Internet finden sich auch Toolboxes, die Sie für Ihr Projekt nutzen können. Wie bspw. die kostenlose ML-Toolbox DAV₃E (Data Analysis and Verification/Visualization/Validation Environment) mit grafischer Benutzeroberfläche [21]. Dabei erlaubt die Toolbox die Kombination von ausgewählten Algorithmen der Merkmalsextraktion, Merkmalsselektion und Klassifikation bzw. Regression. DAV₃E kann unter <https://github.com/lmtUds/dav3e-beta>, sowie in einer umfangreicheren, skript-basierten Version inklusive Beispiel unter <https://github.com/ZEMA-gmbH/LMT-ML-Toolbox> heruntergeladen werden.
- Bevorzugen Sie Algorithmen, bei denen die Bestimmung der Messunsicherheit bereits vorhanden ist, wie z. B.: <https://github.com/ZEMA-gmbH/LMT-UA-ML-Toolbox>.

Hinweis:

- Bei der hohen Anzahl an existierenden maschinellen Lernalgorithmen gibt es keinen, der sich per se universell anwenden lässt und für alle Lernprobleme gleichermaßen gut geeignet ist.
- Priorisieren Sie plausible Algorithmen, insbesondere bei der Merkmalsextraktion und Merkmalsselektion.
- Beachten Sie die Verfügbarkeit der Lernalgorithmen. Können Sie auf bestehende Algorithmen zurückgreifen, oder müssen Sie bspw. einen Algorithmus in einer komplett neuen (Programmier-)Umgebung implementieren. Dies kann ein großer Faktor in Ihrer zeitlichen Planung ausmachen.
- Seien Sie sich bewusst, dass Sie einen iterativen Prozess mit einer wechselnden Kombination unterschiedlicher Algorithmen durchlaufen werden.

lyse oder auch komplexeren Algorithmen (oder einer Kombination aus beiden) erfolgen.

E15. Algorithmen zur Klassifikation bzw. Regression ausgewählt

Wählen Sie, Ihrem Lernproblem entsprechend, Algorithmen zur Klassifikation bzw. Regression aus. Verwenden Sie zunächst einfache Ansätze, z. B. für die Klassifizierung eine Lineare Diskriminanzanalyse (LDA) in Kombination mit einem k Nächste-Nachbar-Klassifikator, für die Regression eine Partial Least Squares Regression (PLSR). Diese Ansätze haben nicht nur geringere Ansprüche an die Rechenleistung, sondern sind zudem gut visualisierbar, sodass man einen schnellen Eindruck der Modellgüte erhält. Höhere Verfahren wie Künstliche Neuronale Netze sind dagegen häufig Black Box Methoden mit kaum interpretierbaren Ergebnissen. Eine Übersicht über die gängigsten Algorithmen finden Sie in [22].

E16. Zusätzliche Anomalie-Erkennung angewendet

Aufgrund der oftmals hohen Komplexität des Zusammenspiels von Prozessen, Produkten und Anlagen, können nicht alle Fehlerszenarien in der Modellbildung abgedeckt werden. Daher kann sich die Implementierung einer zusätzlichen Anomalie-Erkennung lohnen. Diese erkennt, wenn sich die Verteilung Ihrer Daten über einen vorher definierten Grad ändert und gibt eine Meldung heraus. Sollte diese Verschiebung aufgrund einer Störung auftreten, können die entsprechenden Messungen annotiert und in ein maschinelles Lernmodell eingespeist werden.

Hinweis:

Künstliche Neuronale Netze und maschinelles Lernen sind in der Öffentlichkeit fest verbunden und werden gerne miteinander assoziiert. Sollten Sie erwägen, im industriellen Kontext auf Neuronale Netze zurückzugreifen, seien Sie sich den folgenden Punkten bewusst:

■ Neuronale Netze sind eine Black Box

Sie können sich nicht sicher sein, ob das neuronale Netz nicht aus den falschen Gründen das richtige Ergebnis liefert (Überanpassung, Korrelation und Kausalität).

■ Hohe Datenmenge erforderlich

Um zuverlässige Ergebnisse zu erzielen, ist eine hohe Menge an Daten erforderlich, welche alle möglichen Störeinflüsse beinhaltet (vergleiche Training in Bilderkennung mit typischerweise >14.000.000 annotierten Trainingsbildern). Dies ist im Mittelstand oftmals nicht gegeben.

■ Die Auswahl eines geeigneten Typs bzw. einer geeigneten Architektur ist nicht trivial

Es existieren eine Vielzahl verschiedener Typen neuronaler Netze, bei denen Sie in der jeweiligen Architektur praktisch nicht eingeschränkt sind.

■ Hohe Rechenleistung bzw. dezidierte Hardware erforderlich

Zwar lassen sich Neuronale Netze sehr gut parallelisieren, allerdings ist hierzu oftmals dezidierte Hardware (Server, Cloudcomputing) erforderlich.

Eine Einführung in Neuronale Netze finden Sie in [23].

6.3 Modellbildung

E17. Performanz der maschinellen Lernalgorithmen vergleichen

Vergleichen Sie die Performanz der von Ihnen ausgewählten Algorithmen in den verschiedenen Validierungsszenarien; bei der Klassifikation dient dazu primär der Prozentsatz der korrekt klassifizierten Validierungs- oder Testdaten, bei der Regression der mittlere quadratische Fehler (RMSE) wiederum für Validierungs- bzw. Testdaten.

E18. Passende Lernalgorithmen ausgewählt

Wählen Sie passende Algorithmen anhand der Performanz aus. Die Algorithmen müssen hierbei nicht für alle Sensoren gleich sein und können sich auch von Sensor zu Sensor unterscheiden. Ist die Performanz der ausgewählten Algorithmen nicht ausreichend (vgl. A14), können Sie tieferes Verständnis für die Daten aufbauen und weitere Algorithmen auswählen.

E19. Unsicherheiten der Algorithmen bestimmt

Sollte bei den gewählten maschinellen Lernalgorithmen die Messunsicherheitsbestimmung nicht enthalten sein, so muss die Messunsicherheit bspw. nach den Regeln des Guide to the expression of Uncertainty in Measurement (GUM) und seiner Supplemente hergeleitet werden.

E20. Modell zur Anwendung aufgespielt

Nachdem Ihr Modell trainiert wurde, können Sie dieses am vorgesehenen Anwendungsort (dies muss nicht auf der Anlage sein, sondern kann auch auf einem Server oder der Cloud erfolgen) zur Anwendung aufspielen.

E21. Modell kontrolliert

Kontrollieren Sie anhand zusätzlicher Daten im Normalbetrieb nach einem sinnvollen Zeitraum, ob Ihr maschinelles Lernmodell weiterhin die gewünschten und vor allem plausible Ergebnisse liefert. Sollte dies nicht der Fall sein, müssen Sie u.U. mehr Daten aufzeichnen, die den Quereinfluss der Störgröße (welche zum Fehler geführt hat) enthalten, oder Ihr ML-Modell überarbeiten.

6.4 Modellanwendung

- E22. Regelmäßige Gültigkeitsprüfung des Modells eingeplant**
 Sie sollten regelmäßig kontrollieren, ob Ihr Modell immer noch sinnvolle und plausible Daten liefert.
- E23. Regelmäßiges Nachtrainieren des Modells eingeplant**
 Sie sollten Ihr Modell in regelmäßigen Abständen neu trainieren. Auf diese Weise können Sie neuere Daten ebenfalls mit in Ihr Modell einbeziehen, Drifteffekte ausgleichen und bestenfalls die Robustheit Ihres Modells steigern.
- E24. Hardware- und Software-Änderungen dokumentiert**
 Dokumentieren Sie jegliche Änderungen am Zustand Ihrer Prozesse, Produkte und Anlagen. Erwägen Sie eine Versionskontrolle (bspw. über Git-Lab) Ihrer Software und des maschinellen Lernmodells, um auch im Nachgang frühere Modelle einsehen zu können. Seien Sie sich bewusst, dass bei einer signifikanten Änderung der Hardware das ML-Modell ggf. grundlegend neu trainiert werden muss, da die Datenmuster vor und nach dem Umbau nicht mehr zwangsweise übereinstimmen müssen.



Bild: Dontree – stock.adobe.com

7. Projektabschluss

Im Gegensatz zur Anwendung und regelmäßigen Optimierung Ihres maschinellen Lernmodells muss Ihr initiales Projekt zu einem gewissen Zeitpunkt abgeschlossen werden. Damit zukünftige maschinelle Lernprojekte aus Ihren gesammelten Erfahrungen dieses Projektes profitieren können, ist es wichtig, Ihre Vorgehensweise und Erkenntnisse sowie alle Unterlagen übersichtlich und vollständig zu dokumentieren und bereitzustellen.

- F1. Analyseergebnisse mit dem ursprünglichen Ziel der Analyse abgeglichen**
 Gleichen Sie Ihr ursprüngliches Ziel mit den tatsächlichen Analyseergebnissen ab und dokumentieren Sie die Abweichungen.
- F2. Lessons Learned formuliert**
 In jedem Projekt passieren zwangsweise Fehler oder Dinge, die hätten besser gelöst werden können. Damit nicht nur Sie aus dem Projekt für zukünftige Projekte lernen, sollten Sie Ihre gelernten Lektionen (Lessons Learned) formulieren.
- F3. Abschlusspräsentation erstellt**
 Erstellen Sie eine kurze Abschlusspräsentation, in der Sie klar Ihre Ziele, Vorgehensweise, die Erfolge und Grenzen Ihres Projektes benennen. Dies ermöglicht Ihren Kollegen schnell und anschaulich, Ihr Projekt zu erfassen und darauf aufzubauen.
- F4. Abschlussbericht verfasst**
 Verfassen Sie einen Abschlussbericht; dieser sollte so umfassend wie nötig, gleichzeitig, aber so kurz wie möglich sein.
- F5. Alle Unterlagen zentral abgelegt**
 Überprüfen Sie noch einmal, ob alle notwendigen Unterlagen, Dokumente, Programme und ggf. Daten zentral und leicht auffindbar abgelegt wurden.



Bild: Geber86 – stock.adobe.com

8. Fazit

Nach Studium dieser Checkliste ergibt sich schnell eine erste Erkenntnis: Datenplanung und -auswertung sind zeitaufwendig. Das liegt unter anderem auch daran, dass beides nie zu einem perfekten Ergebnis führt. Es sind Iterationen und stetige Neubearbeitungen notwendig, die dazu führen, dass eine kontinuierliche Verbesserung aufrechterhalten wird. Daraus folgt offensichtlich auch, dass diese Checkliste keinen einmalig zu bearbeitenden Leitfaden darstellt, sondern dazu dient, die Mess- und Datenplanung stetig zu verbessern.

Hierzu können und sollen auch eigenes Wissen und Erfahrungen aus Projekten in die Bearbeitung mit einfließen, denn die Checkliste stellt keine allein stehende Musterlösung, sondern viel mehr eine Hilfestellung dar.

Übersicht der Sensorik

Ersteller: _____
 Projekt: _____
 Datum: _____

	Sensor 1	Sensor 2	Sensor 3	Sensor 4	Sensor 5	Sensor 6	Sensor 7
Allgemein							
Sensorbezeichnung							
IP-Adresse							
Hersteller							
Messgröße und Einheit							
Messposition							
Erwartete Effekte							
Anzahl Sensoren							
Sensortyp							
Messprinzip							
Auslesemethode							
Abtastrate							
Bandbreite							
Auflösung							
Messbereich							
Messinstrument							
Kanäle							
Ausgangssignal							
Sensordaten							

Verantwortlicher

Ersteller



Bild: Jade Maas/peopleimages.com – stock.adobe.com

9. Abkürzungsverzeichnis, Glossar und Literaturverzeichnis

9.1 Abkürzungsverzeichnis

ADC	Analog-Digital-Umwandler (englisch: Analog-Digital-Converter)
ASAM	Association of Standardization of Automation and Measuring Systems
bspw.	beispielsweise
bzw.	beziehungsweise
ca.	circa
CEN	European Committee for Standardization
CENELEC	European Committee for Electrotechnical Standardization
CSV	Comma-separated values
DIN	Deutsches Institut für Normung
ggf.	gegebenenfalls
HDF5	Hierarchical Data Format Version 5
i.d.R.	In der Regel
ID	Identifikationsnummer
IP	Internetprotokoll
ISO	Internationale Organisation für Normung
JSON	JavaScript Object Notation
KI	Künstliche Intelligenz

KMU	Kleine und mittlere Unternehmen
LDA	Lineare Diskriminanzanalyse
ML	Maschinelles Lernen
NI	National Instruments
o.ä.	oder ähnliches
PCA	Hauptkomponentenanalyse (englisch: Principal Component Analysis)
PLSR	Partial Least Squares Regression
TDMS	Technical Data Management Streaming
u.a.	unter anderem
UTC	Coordinated Universal Time
vgl.	vergleiche
z. B.	zum Beispiel

9.2 Glossar

Anomalie-Erkennung	Erkennung von Unregelmäßigkeiten. (Englisch: Novelty Detection).
Back-up	Sicherung von Daten auf einem weiteren Medium, um dem Verlust von Daten vorzubeugen.
Best-Practice	Bereits etabliertes Vorgehen/Methode/Prozess.
Black Box	In der Systemtheorie bezeichnet eine Black Box ein System, dessen innere Struktur bzw. Funktionsweise unbekannt ist. Der Betrachter sieht lediglich was in die Black Box rein geht (Input) und was aus ihr herauskommt (Output).
Drift	Langsame Änderung der Mess- bzw. Ausgangsgröße über die Zeit.
Dropdownlisten	Ausklappbare Liste mit vordefinierten Elementen.
GitLab	Webanwendung zur Versionsverwaltung für Softwareprojekte.
LabVIEW	Grafisches Programmiersystem von National Instruments.
Lessons Learned	Gelernte Lektionen.
Merkmal	Extrahierte Größen wie bspw. Sensormesswerte, statistische Werte (z. B. Mittelwerte), Kennzahlen oder ähnlichen.
Neuronale Netze	Algorithmen, die dem menschlichen Gehirn nachempfunden sind (künstliche Neuronen).
Plot, plotten	Graphische Darstellung.
Quasi-statisches Signal	Signal, welches durch die Aneinanderreihung eines ausgewählten Datenpunktes über mehrere Messreihen hinweg entsteht.
RAID-System	Redundante Anordnung unabhängiger Festplatten zur Sicherung von Daten.
Überanpassung	Überanpassung eines Modells an einen Datensatz (englisch: Overfitting).
Validierung	Prüfung des Modells, ob es reproduzierbar und zuverlässig seinen praktischen Einsatzzweck erfüllt.

9.3 Literaturverzeichnis

- [1] C. Schnur, S. Klein, und A. Blum, „Checkliste – Mess- und Datenplanung für das maschinelle Lernen in der Montage“, Aug. 2022, doi: 10.5281/ZENODO.6943476.
- [2] K. Stolzenberg und K. Heberle, Change Management: Veränderungsprozesse erfolgreich gestalten - Mitarbeiter mobilisieren. Vision, Kommunikation, Beteiligung, Qualifizierung, Berlin, Heidelberg: Springer Berlin Heidelberg, 2021. doi: 10.1007/978-3-662-61895-0.
- [3] A. Windolph, „Das Ishikawa-Diagramm am Beispiel erklärt“, Projekte leicht gemacht, 19. Februar 2015, [Online], Verfügbar unter: <https://projekte-leicht-gemacht.de/blog/business-wissen/ishikawa-diagramm/> (zugegriffen 26. Juli 2023).
- [4] BIPM u. a., JCGM 100: Evaluation of measurement data – Guide to the expression of uncertainty in measurement, 2008, [Online], Verfügbar unter: https://www.bipm.org/documents/20126/2071204/JCGM_100_2008_E.pdf/cb0ef43f-baa5-11cf-3f85-4dcd86f77bd6 (zugegriffen 23. Oktober 2023).
- [5] Joint Committee for Guides in Metrology, Evaluation of Measurement Data – Supplement 1 to the Guide to the Expression of Uncertainty in Measurement – Propagation of Distributions using a Monte Carlo Method, ISO 2008, [Online], Verfügbar unter: https://www.bipm.org/utis/common/documents/jcgm/JCGM_101_2008_E.pdf (zugegriffen 23. Oktober 2023).
- [6] Joint Committee for Guides in Metrology, Evaluation of Measurement Data – Supplement 2 to the Guide to the Expression of Uncertainty in Measurement – Extension to Any Number of Output Quantities, ISO, 2011, [Online], Verfügbar unter: https://www.bipm.org/documents/20126/2071204/JCGM_102_2011_E.pdf (zugegriffen 23. Oktober 2023).
- [7] S. Mieke, „Berechnung der Messunsicherheit nach GUM - Kurzfassung in 20 min“, April 2014, [Online], Verfügbar unter: https://www.ptb.de/cms/fileadmin/internet/fachabteilungen/abteilung_8/8.4_mathematische_modellierung/277_PTB_SEMINAR/VORTRAEGE/11_Mieke_-_Berechnung_der_Messunsicherheit_nach_GUM_-_Kurzfassung_in_20.pdf (zugegriffen 23. Oktober 2023).
- [8] S. Mieke, „Kurze Einführung in die Berechnung der Messunsicherheit nach GUM“, [Online], Verfügbar unter: <https://docplayer.org/73036604-Kurze-einfuehrung-in-die-berechnung-der-messunsicherheit-nach-gum-stephan-mieke-physikalisch-technische-bundesanstalt-institut-berlin-8.html> (zugegriffen 23. Oktober 2023).
- [9] The HDF Group, „Hierarchical Data Format, version 5“, The HDF Group - ensuring long-term access and usability of HDF data and supporting users of HDF technologies, [Online], Verfügbar unter: <https://www.hdfgroup.org/> (zugegriffen 23. Oktober 2023).
- [10] National Instruments, „Das NI-TDMS-Dateiformat“, [Online], Verfügbar unter: <https://www.ni.com/de-de/support/documentation/supplemental/06/the-ni-tdms-file-format.html> (zugegriffen 23. Oktober 2023).
- [11] Y. Shafranovich, „Common Format and MIME Type for Comma-Separated Values (CSV) Files“, RFC Editor, RFC4180, Okt. 2005, doi: 10.17487/rfc4180.
- [12] F. Pezoa, J. L. Reutter, F. Suarez, M. Ugarte, und D. Vrgoč, „Foundations of JSON schema“, in Proceedings of the 25th International Conference on World Wide Web, International World Wide Web Conferences Steering Committee, 2016, S. 263–273.
- [13] N. Rabinov, „What’s the Diff: 3-2-1 vs. 3-2-1-1-0 vs. 4-3-2“, Backblaze Blog | Cloud Storage & Cloud Backup, 21. Juli 2021, [Online], Verfügbar unter: <https://www.backblaze.com/blog/whats-the-diff-3-2-1-vs-3-2-1-1-0-vs-4-3-2/> (zugegriffen 23. Oktober 2023).

- [14] Embedded data GmbH, „Schichtübergabe in der Produktion: Das (digitale) Schichtbuch und seine Entwicklung“, [Online], Verfügbar unter: <https://blog.embedded-data.de/blog/entwicklung-digitales-schichtbuch> (zugegriffen 23. Oktober 2023).
- [15] J. P. Rohweder, G. Kasten, D. Malzahn, A. Piro, und J. Schmid, „Informationsqualität – Definitionen, Dimensionen und Begriffe“, in Daten- und Informationsqualität, K. Hildebrand, M. Gebauer, H. Hinrichs, und M. Mielke, Hrsg., Wiesbaden: Vieweg+Teubner, 2011, S. 25–45. doi: 10.1007/978-3-8348-9953-8_2.
- [16] L. Papula, Vektoranalysis, Wahrscheinlichkeitsrechnung, Mathematische Statistik, Fehler- und Ausgleichsrechnung, 7. überarbeitete und Erweiterte Auflage, Band 3, Wiesbaden: Springer Vieweg, 2016. doi: 10.1007/978-3-658-11924-9.
- [17] W. A. Hemmerich, „StatistikGuru: Ausreißer“, Mai 2016, [Online], Verfügbar unter: <https://statistikguru.de/lexikon/ausreisser.html> (zugegriffen 23. Oktober 2023).
- [18] S. Matzka, Crashkurs KI im Unternehmen: alles, was Sie über Data Science wissen müssen, 1. Auflage. Freiburg München Stuttgart: Haufe Group, 2021.
- [19] „Principal Component Analysis - einfach erklärt! | Data Basecamp“, 9. Februar 2022, [Online], Verfügbar unter: <https://databasecamp.de/statistik/principal-component-analysis> (zugegriffen 23. Oktober 2023).
- [20] F. Maleki, N. Muthukrishnan, K. Ovens, C. Reinhold, und R. Forghani, „Machine Learning Algorithm Validation“, Neuroimaging Clinics of North America, Bd. 30, Nr. 4, S. 433–445, Nov. 2020, doi: 10.1016/j.nic.2020.08.004.
- [21] M. Bastuck, T. Baur, und A. Schütze, „DAV₃E – a MATLAB toolbox for multivariate sensor data evaluation“, J. Sens. Syst., Bd. 7, Nr. 2, S. 489–506, Sep. 2018, doi: 10.5194/jsss-7-489-2018.
- [22] S. Papp u. a., Handbuch Data Science: mit AI, Datenanalyse und Machine Learning Wert aus Daten generieren, 2. Auflage. München: Hanser, 2022.
- [23] „A Practitioner’s Guide to Machine Learning“, [Online], Verfügbar unter: https://franziskahorn.de/mlbuch_auszug_all.html#_einleitung (zugegriffen 23. Oktober 2023).

Hinweis:

Die aufgeführte Literatur dient als Hilfestellung, um Lesern einen niederschweligen Einstieg in die entsprechenden Themengebiete zu ermöglichen, d.h. Lesbarkeit und Zugänglichkeit hatten Priorität vor wissenschaftlichem Tiefgang.

Hinweis:

Zur besseren Lesbarkeit wird das generische Maskulinum verwendet. Die verwendeten Personenbezeichnungen beziehen sich – sofern nicht anders kenntlich gemacht – auf alle Geschlechter.



Was ist Mittelstand-Digital?

Das Mittelstand-Digital Netzwerk bietet mit den Mittelstand-Digital Zentren und der Initiative IT-Sicherheit in der Wirtschaft umfassende Unterstützung bei der Digitalisierung. Kleine und mittlere Unternehmen profitieren von konkreten Praxisbeispielen und passgenauen, anbieterneutralen Angeboten zur Qualifikation und IT-Sicherheit.

Das Bundesministerium für Wirtschaft und Klimaschutz ermöglicht die kostenfreie Nutzung der Angebote von Mittelstand-Digital.

Weitere Informationen finden Sie unter:
www.mittelstand-digital.de

Impressum:

Herausgeber:
Mittelstand-Digital Zentrum Saarbrücken
Eschberger Weg 46, Gewerbepark, Gebäude 9
D - 66121 Saarbrücken

info@digitalzentrum-saarbruecken.de
www.digitalzentrum-saarbruecken.de

Redaktion:
Christopher Schnur, Daniela Schmidt,
Daniel Becker, Anne Blum, Prof. Dr. Andreas
Schütze, Tizian Schneider

Gestaltung und Produktion:
Isabelle Kirsch, Marius Becker, Verena Milde

Bildnachweis:
Mittelstand-Digital Zentrum Saarbrücken,
Adobe Stock

Stand:
Version 1.0 (Januar 2024)
doi: 10.5281/zenodo.10069539