Gefördert durch:

Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

TrendAuto
2030plus

Hands-on KI

Verstehen. Programmieren. Anwenden.

Quelle: geralt auf pixabay.com

Handlungsfeld: Technologie

Entwicklungssystematik und kollaboratives Arbeiten

02.09.2025

Technology
Arts Sciences
TH Köln
CAD CAM CENTER COLOGNE

Agenda

09:00 Uhr – 09:30 Uhr	**Intro**	I. Begrüßung, Vorstellung der Teilnehmer und Zielsetzung des Workshops II. Impuls „Von den Daten zum KI-System“
09:30 Uhr – 10:10 Uhr	**Praxis**	I. Problemdefinition - Klassifikation II. Programmiersprint - Einführung in die Datenanalyse & -vorbereitung III. Reflektion
10:20 Uhr – 11:00 Uhr	**Praxis**	I. Programmiersprint - Einführung in die Modellerstellung & Optimierung II. Reflektion
11:20 Uhr – 12:00 Uhr	**Praxis**	I. Problemdefinition – Regression II. Programmiersprint - eigenständige Datenanalyse & -vorbereitung III. Reflektion
12:10 Uhr – 12:50 Uhr	**Praxis**	I. Programmiersprint - eigenständige Modellerstellung & Optimierung II. Reflektion
12:50 Uhr – 13:00 Uhr	**Outro**	I. Zusammenfassung, Feedback und Abschluss

Ihre Vorstellung(en)

- *Ihr Name*
- *zugehöriges Unternehmen + Funktion*
- *Mit welchen Gedanken und welcher Stimmung bin ich heute Morgen in den Workshop gegangen?*
- *Meine Erwartungen an den Workshop*
- …

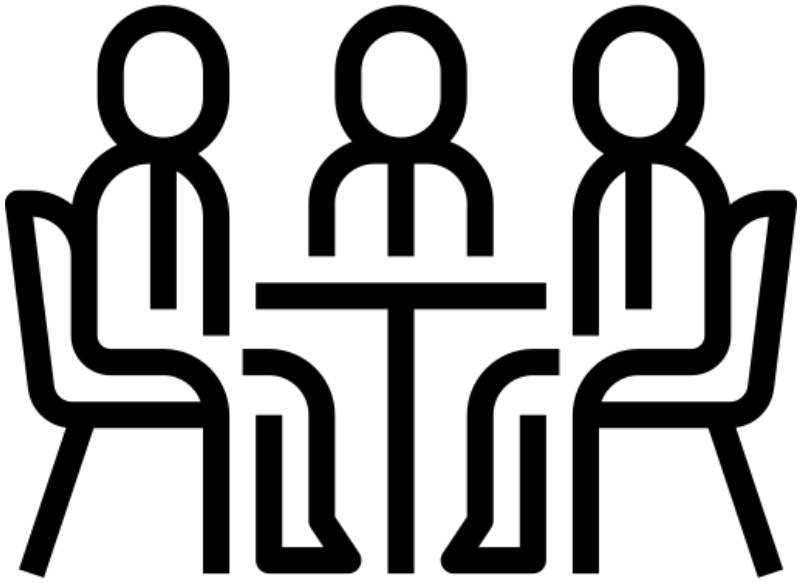

Innerhalb des Arbeitskreises können sich die Akteure kennenlernen und vernetzen. Durch das gemeinsame Bearbeiten der Themenstellungen entstehen neue Einblicke in die unterschiedlichen Arbeits- und Denkweisen.

Zielsetzung des Workshops

Kernpunkte des heutigen Termins

- Beleuchtung ausgewählter KI-Herausforderung und der daraus resultierenden Perspektive
- Strukturierte Darstellung des Ablaufs für den Prozess hin von den Daten zum eigentlichen KI-System
- Best Practices: Vergleich zwischen akademischer und industrieller Perspektive sowie Verallgemeinerung der Vorgehensweise

Dieser Workshop verbindet Unternehmensherausforderungen mit dem Prozess des Aufbaus von KI-Systemen und vereint akademische sowie industrielle Best Practices.

Impuls
Von den Daten zum KI-System

Quelle: geralt auf pixabay.com

Lösungsansatz: Künstliche Intelligenz & Maschinelles Lernen

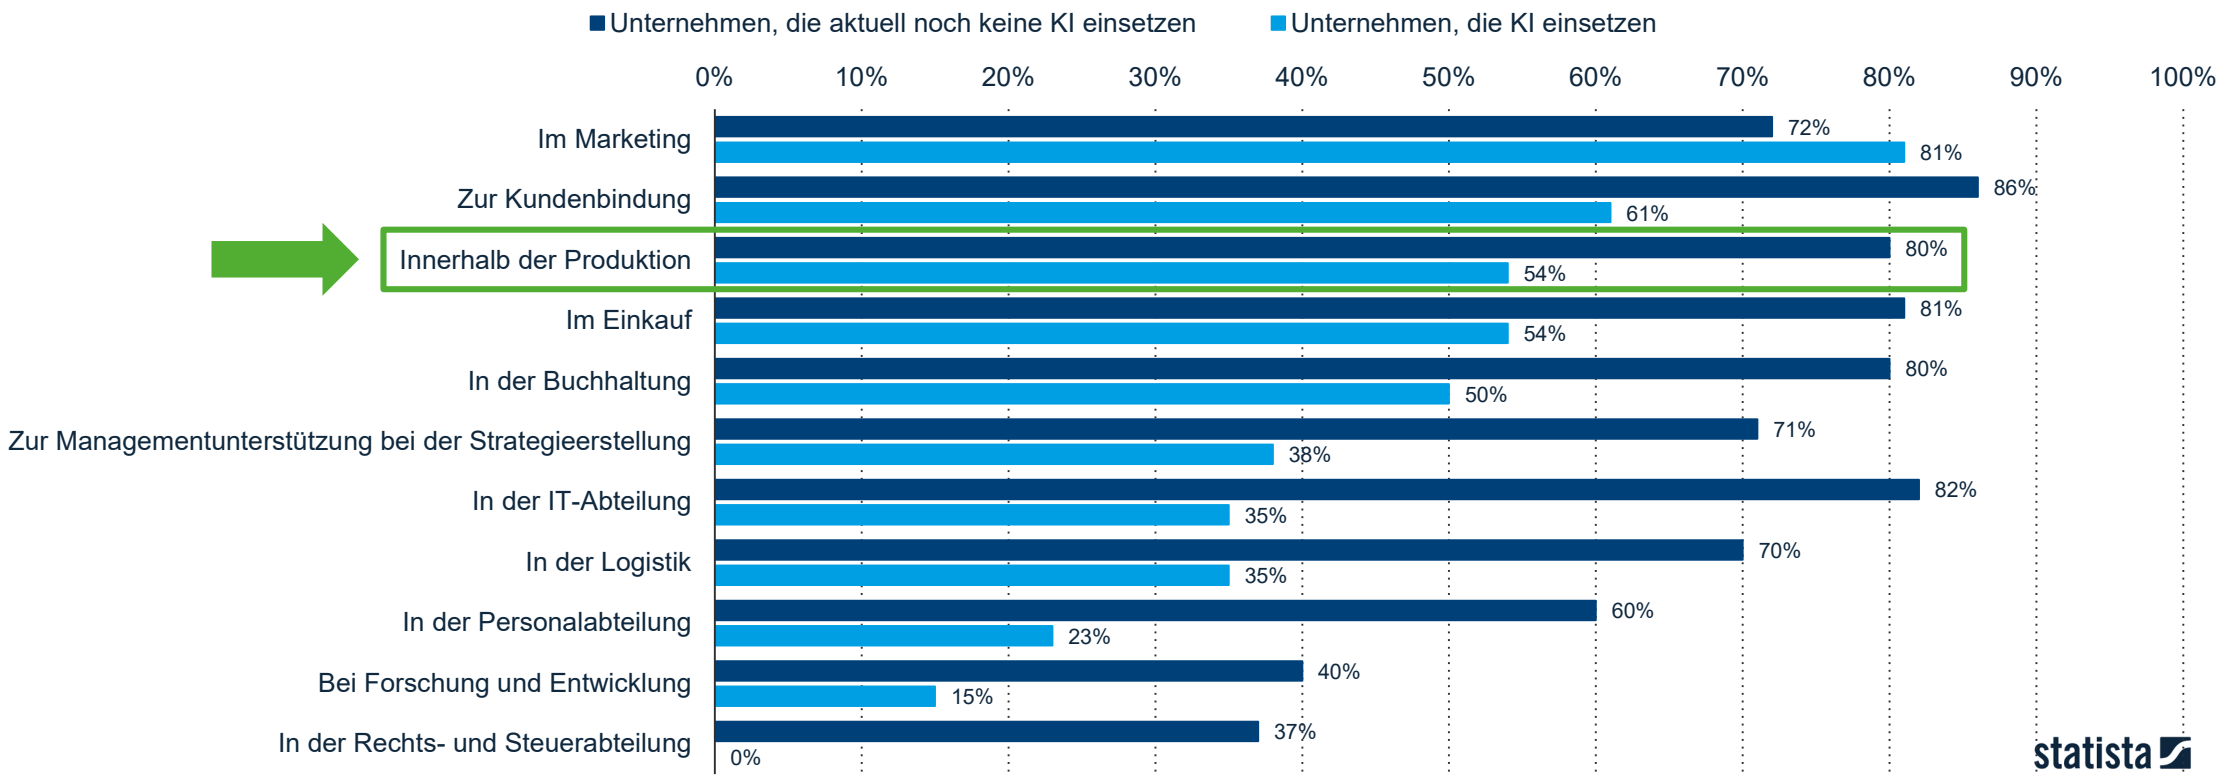

Hinweis: Deutschland; 13.06.2022 bis 24.07.2022; 593 Befragte; Unternehmen, die KI nutzen (n=54); Unternehmen, die noch keine KI nutzen (n=539)

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

Künstliche Intelligenz:
Künstlich geschaffenes System (*Modell*), das die ähnlich intellektuellen Tätigkeiten wie ein Mensch ausführen kann oder diesen dabei übertrifft. [**1**]

Modell:
Mathematische Struktur, die einen Zusammenhang zwischen einer Eingabe und einer Ausgabe (näherungsweise) herstellt

Maschinelles Lernen:
Computerprogramme lernen aus *Erfahrungen* in Bezug auf eine *Aufgabe*, wenn seine *gemessene Leistung* bei der *Aufgabe* mit steigender *Erfahrung* anwächst. [**2**]

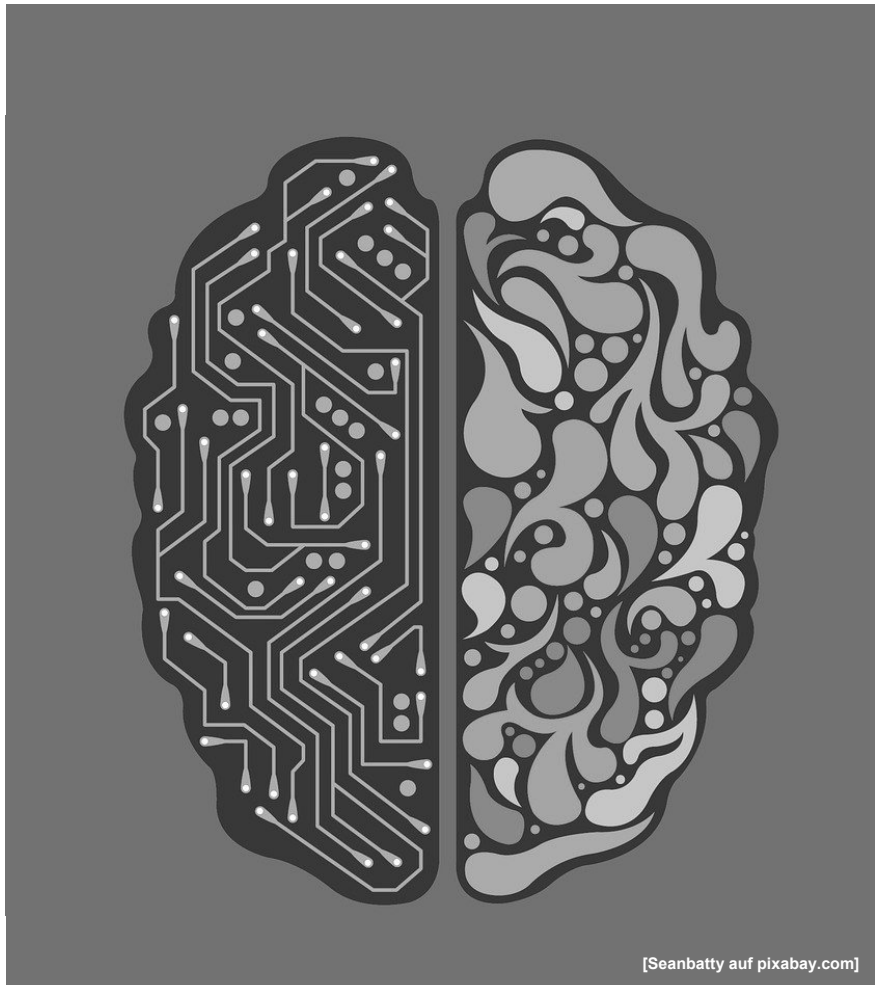

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

Herangehensweise bei Maschinellen Lernen:
Datengetriebene Generierung von Modellen unter Nutzung von Statistik und Optimierungsrechnung

Lernalgorithmus / Trainingsalgorithmus:
Algorithmus, der die Modellparameter so anpasst, dass das Modellverhalten sich verbessert (*Optimierung*)

Zielsetzung:
Modelle mit *Generalisierungsfähigkeit* schaffen
(Verallgemeinerung / Ergebnisfindung in fremden Daten)
→ komplexe Aufgabe vereinfachen / lösbar machen **[3]**

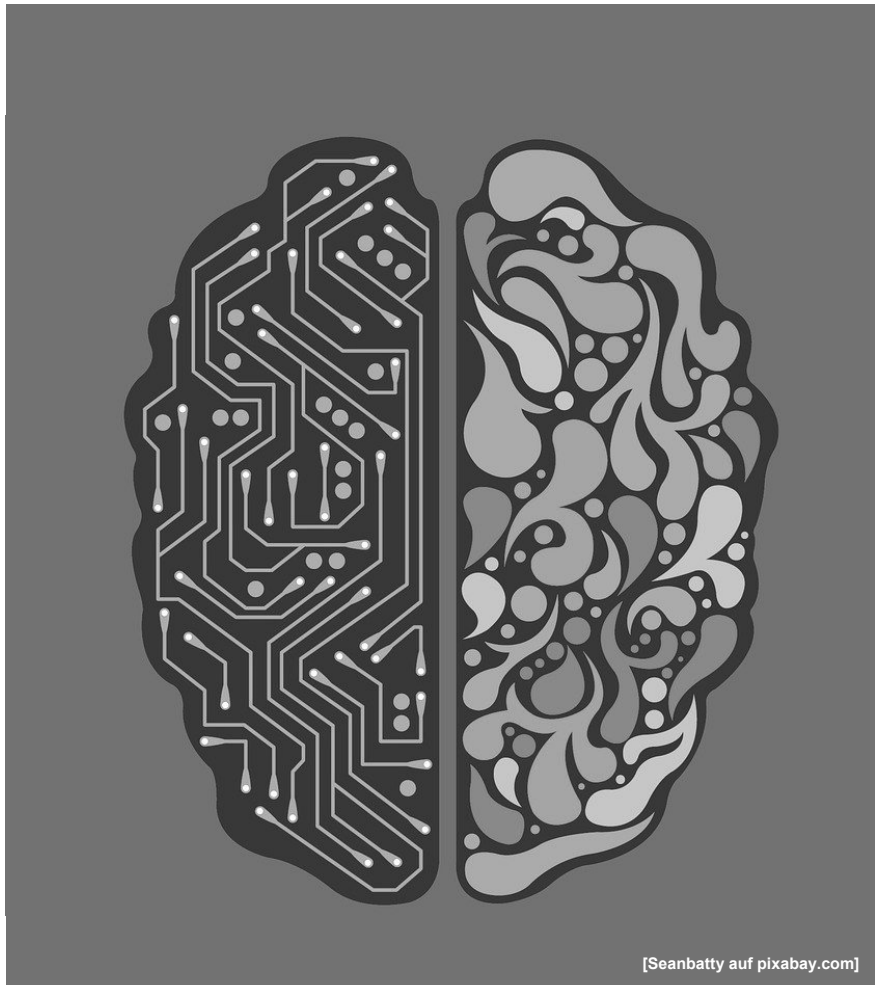

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

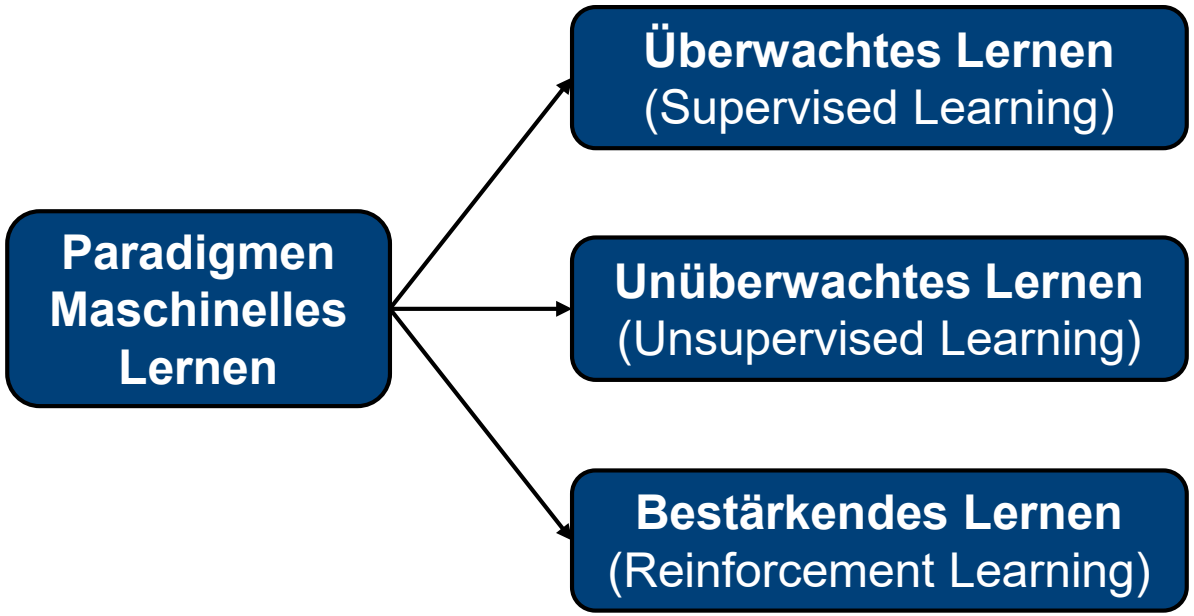

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

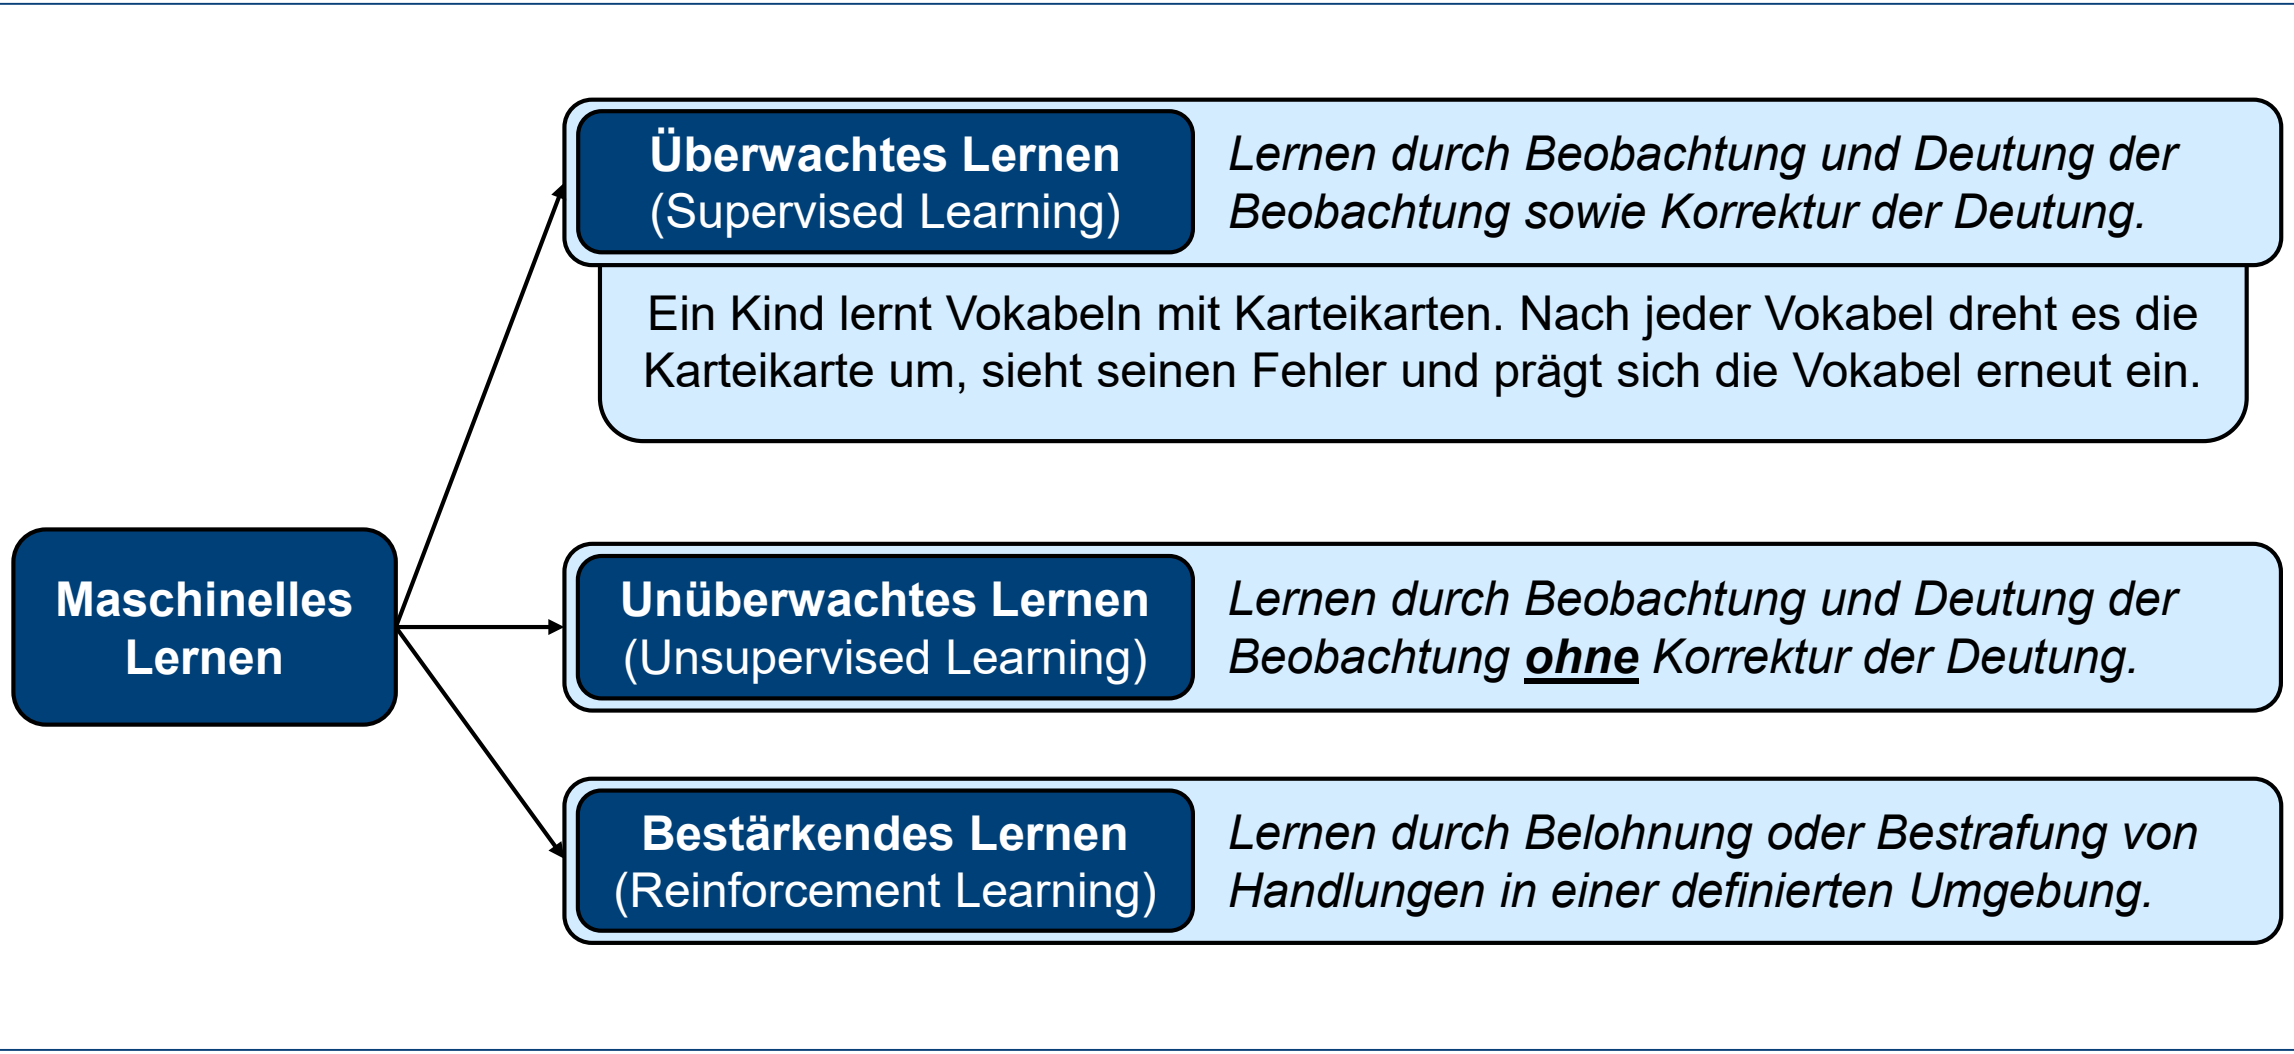

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

- **Ausgangssituation**
  - „gelabelter“ Datensatz
    → Paare aus Input-Daten und zugehörigen Output-Daten
  - Aufteilung in Trainings- und Testdaten
  - Erzeugung dieses Datensatzes ist umfangreiche Aufgabe

[1, 3]

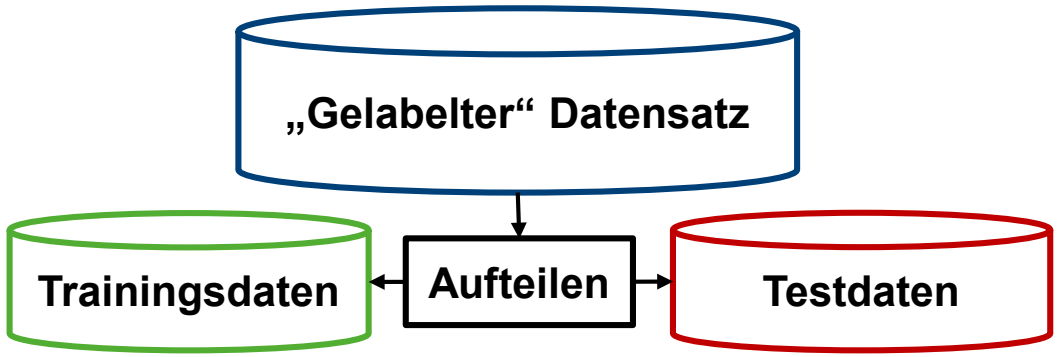

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

- **Lernprozess** („**Training**“)
  → Optimierung des Modells

1. Input-Daten werden Modell vorgegeben
2. Modell ermittelt **Ist-Output**
3. **Modellfehler** = Ist-Output - Soll-Output
4. Anpassung der Modellparameter abhängig von rückgeführtem Modellfehlers durch Lernalgorithmus
5. Vorgang für alle Datenpaare wiederholen bis die Abweichung ausreichend gering

[1, 3]

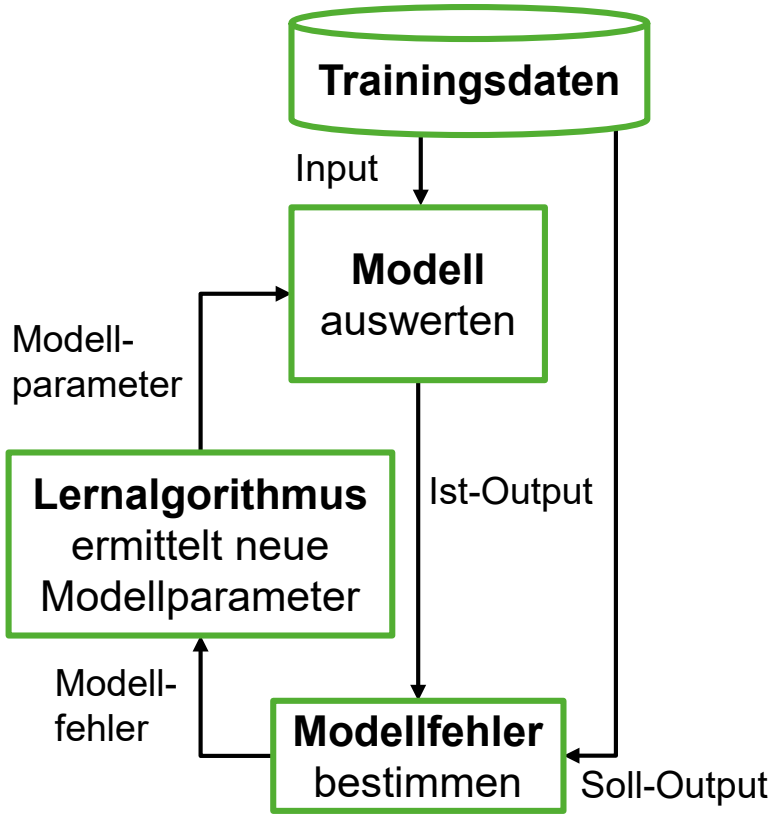

Grundlagen: Künstliche Intelligenz durch überwachtes Lernen

- **Testprozess**
  → Iterative Evaluation des trainierten Modells

  1. Input-Daten werden Modell vorgegeben
  2. Modell ermittelt **Ist-Output**
  3. **Modellfehler** = Ist-Output - Soll-Output
  4. Beurteilung der Generalisierungsfähigkeit
     → **Wie gut funktioniert das Modell auf ihm unbekannten Daten?**

[1, 3]

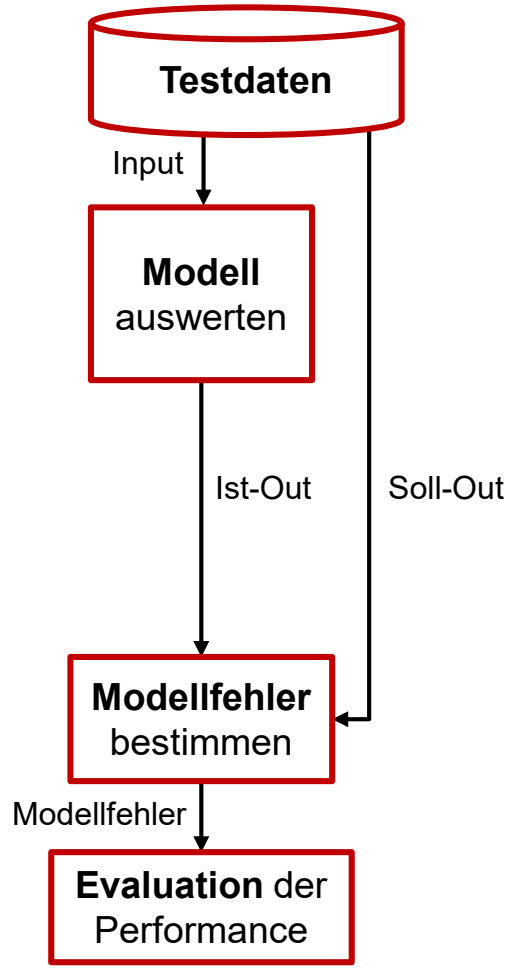

Lösungsweg: Entwicklungssystematik für Künstliche Intelligenz

1. **Problem Definition**:
   - Ziel & Anforderungen klar definieren
2. **Data Acquisition**:
   - Daten sammeln
3. **Data Analysis & Preparation**:
   - Daten analysieren, bereinigen & aufbereiten
4. **ML-Model Selection & Training**:
   - Geeignetes Modell auswählen und Mit aufbereiteten Daten trainieren
5. **ML-Model Analysis & Fine-Tuning**:
   - Modell evaluieren & optimieren, Genauigkeit verbessern
6. **ML-Model Application & Maintenance**:
   - Modell im Einsatz überwachen und nach Bedarf anpassen

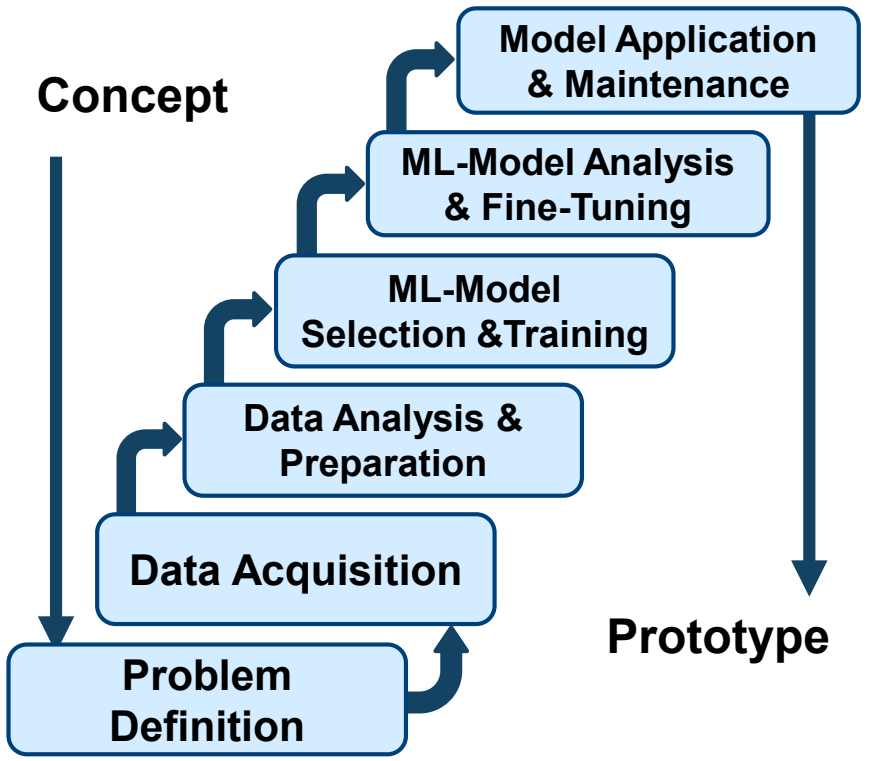

Als Entwicklungssystematik hat sich ein stufenartiger Prozess bewährt, der von der Problemfindung bis zur praktischen Anwendung reicht.

Lösungsweg: Entwicklungssystematik für Künstliche Intelligenz

Mehr dazu in unserem KI-Leitfaden unter *trendauto2030plus.de*

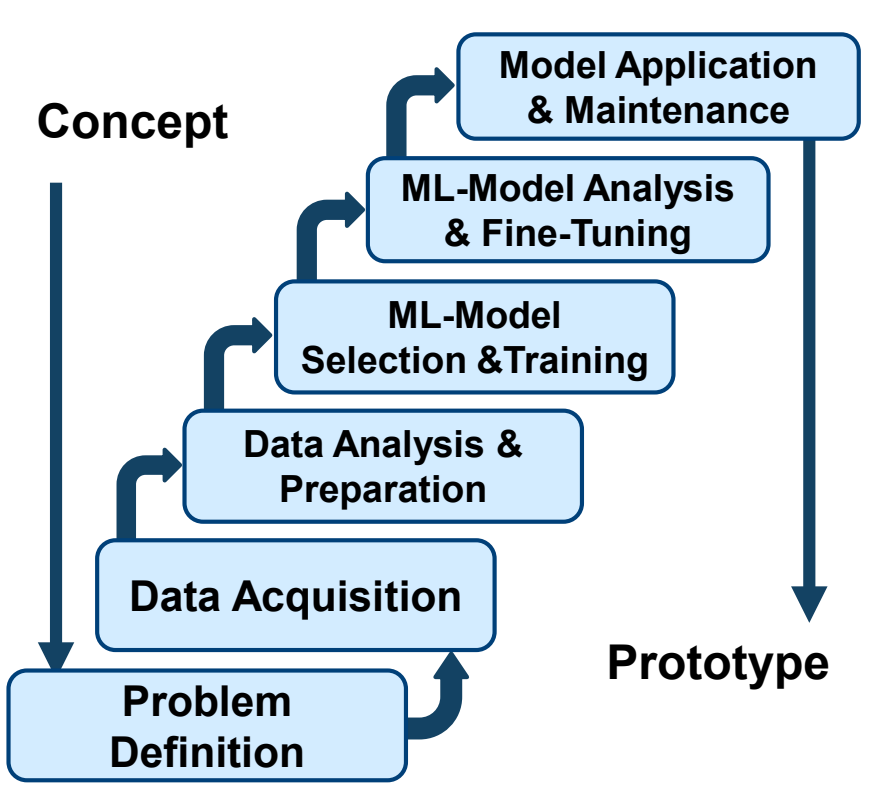

Als Entwicklungssystematik hat sich ein stufenartiger Prozess bewährt, der von der Problemfindung bis zur praktischen Anwendung reicht.

Klassifikation

Vorhersage fester Klassen

Quelle: geralt auf pixabay.com

Problem Definition

- Prozess analysieren
- Datenlage sichten
  - ***Excel-Datei mit Ein- & Ausgangsparametern***
- Problem beschreiben
  - ***Bauteile in Klassen unterteilen***

➢ **Klassifikationsaufgabe**

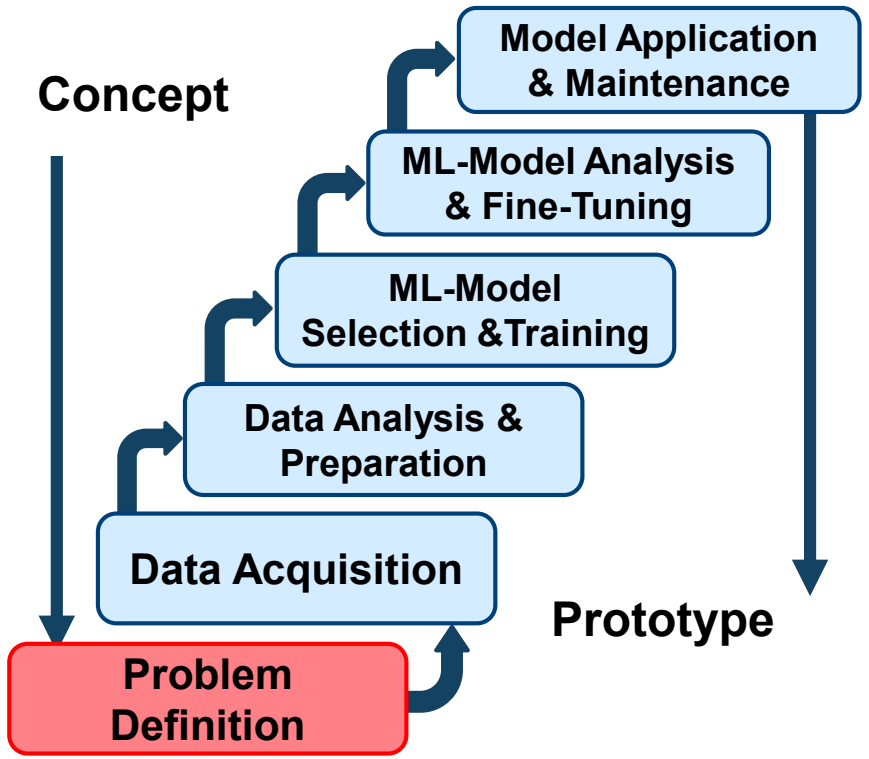

Aus der Datenlage, der Prozessbeschreibung und der Problemdefinition ergeben sich Grundcharakteristiken des zu entwickelnden KI-Modells.

Problem Definition

- Datensatz in Excel
  - Bauteile in **defekt** oder **nicht defekt** einteilen
- Eingangsparameter wie:
  - Produktionskosten
  - Produktionsmenge
  - Qualitätsgüte
  - Produktivität der Mitarbeiter
  - Energieverbrauch
  - Materialkosten
  - …
- Ausgangsparameter (Zielwert):
  - Defektstatus

- Nicht alle Parameter haben den gleichen Einfluss auf das Ergebnis!
  - durch Datenanalyse Nachvollziehbarkeit von Korrelationen
  - Parameter mit **hoher** Korrelation **müssen** berücksichtigt werden
  - Parameter mit **niedriger** Korrelation **können** entfernt werden

Datenakquise

Schritte der Datenakquise

- Datenquellen identifizieren
  - ***Excel-Datei***
- Datensammlungsstrategie festlegen
- Qualität und Repräsentativität der Daten sicherstellen
- Datenaufnahme durchführen
- Datensammlung überprüfen

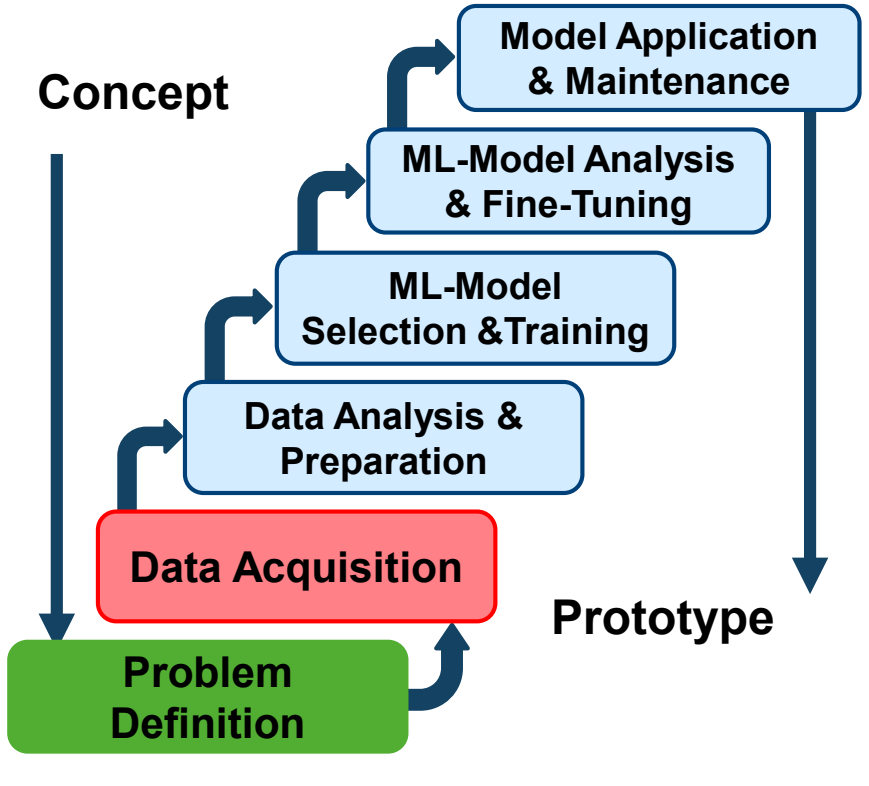

KI-Systeme benötigen Daten, um zu lernen. Die Sammlung von qualitativ hochwertigen, relevanten und vielfältigen Daten ist entscheidend für die Entwicklung einer effektiven KI.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
1	ProductionVolume [1/day]	ProductionCost [$]	SupplierQuality [%]	DeliveryDelay [days]	DefectRate [1]	QualityScore [%]	MaintenanceHours [hours]	DowntimePercentage [%]	InventoryTurnover [1]	StockoutRate [%]	WorkerProductivity [%]	SafetyIncidents [1]	EnergyConsumption [kWh]	EnergyEfficiency [1]	AdditiveProcessTime [hours]	AdditiveMaterialCost [$]	DefectStatus [1]
2	202	13175,40378	86,64853384	1	3,121492267	63,46349433	9	0,052342867	8,630515535	0,081321681	85,04237928	0	2419,616785	0,468946624	5,55163899	236,439301	1
3	535	19770,04609	86,31066361	4	0,819530511	83,69781763	20	4,90832825	9,296598088	0,03848647	99,65744298	7	3915,566713	0,119484558	9,080753557	353,9576312	1
4	960	19060,821	82,13247238	0	4,514504071	90,35055003	1	2,464922789	5,097485701	0,002887365	92,81926429	2	3392,385362	0,496391526	6,562827271	396,1894021	1
5	370	5647,606037	87,33596641	5	0,63852396	67,62869012	8	4,692475792	3,577615991	0,055330971	96,88701346	8	4652,400275	0,183125088	8,09749565	164,1358699	1
6	206	7472,222236	81,98989338	3	3,867783603	82,72833363	9	2,746726169	6,851709481	0,068047139	88,31555364	7	1581,630332	0,263506944	6,406154013	365,7089636	1
7	171	6975,931602	95,33191889	1	3,914573642	92,56843594	19	3,027324301	7,930009366	0,074069495	87,07911774	7	1238,994421	0,118020523	7,279442019	171,7118039	1
8	800	15889,69865	99,32548595	3	4,788999884	90,72991111	10	3,55956128	3,046888531	0,040192495	91,0631579	8	3138,43115	0,333912881	4,891668839	188,7277374	1
9	120	17266,77995	99,40148913	4	0,743604838	92,11968071	13	1,604878668	8,380972117	0,009701963	88,70556885	3	1004,108554	0,293422106	9,333834717	312,5268961	1
10	714	8202,670495	97,30142199	5	3,185855874	95,17293699	2	3,494919803	3,66874656	0,058432643	94,2989611	4	4150,875773	0,366682814	5,517451184	215,6809208	1
11	221	12587,79039	92,01584299	2	2,425282568	97,50728409	0	2,633959549	5,933418343	0,032954789	85,3163618	6	3023,891555	0,317071251	5,965972023	364,6381765	0
12	566	17610,54542	94,01731394	3	1,987848297	76,22084621	6	3,362399748	8,851859599	0,094688748	88,99182062	1	2952,262304	0,259271114	5,724689529	482,3106497	0
13	314	15992,02317	85,70411605	0	0,906433521	82,7507641	3	4,179166305	3,547396088	0,050271211	97,90265495	6	2449,983915	0,395102679	3,845701181	159,5568805	0
14	430	13133,55808	92,6154084	1	3,031943539	91,62638104	6	0,921145651	3,935077184	0,047226605	95,12215801	2	2499,895345	0,110008451	3,08114592	328,2043329	1
15	558	13855,21536	89,11299099	0	2,655683266	87,88559256	15	3,067754552	2,502169252	0,030920953	83,3614033	5	2724,534713	0,316411608	1,664514677	469,3196731	1
16	187	12625,4082	89,6403468	3	0,970495062	99,82080913	9	0,260556643	3,172912894	0,033878651	97,73729659	5	1064,129378	0,145550482	7,463574838	170,6115907	0
17	472	9463,22677	95,15553121	5	3,256202782	60,54710604	14	0,510575445	3,172206558	0,051275478	91,78033181	5	1334,183149	0,274403333	3,603477369	246,7403614	1
18	199	13475,32989	85,63836711	2	3,820789041	74,20532861	15	3,372971179	3,627420017	0,03066648	93,58574367	9	3020,19208	0,416450127	4,502781669	149,446734	1
19	971	15333,27953	86,36079223	2	3,952752355	71,24111705	5	0,354688259	4,289603177	0,089230488	85,88513132	1	1600,489061	0,156984299	9,279353465	356,8150873	1
20	763	18099,84374	98,49283582	0	4,574179347	70,49263401	3	2,976788899	8,519866916	0,043901793	88,83088527	8	4115,050433	0,47432414	6,098026145	367,6571711	1
21	230	14544,37031	81,1244859	4	2,342618338	68,9011913	3	1,100062993	9,326110913	0,029202208	96,13624958	7	2097,940696	0,455401877	1,873702575	365,6729278	1
22	761	16416,82306	89,71268597	4	4,788827459	88,36495363	23	1,520424143	5,250244874	0,015539483	86,61352438	6	1391,598549	0,265962028	8,196507215	316,8508193	1
23	408	7401,074524	98,25601601	5	4,394432323	63,39037893	22	0,648182511	3,025671616	0,067235073	83,30123231	8	1940,839704	0,102389936	3,305175392	398,5043471	1
24	869	11923,36212	92,20726016	2	1,83425707	89,66435336	3	1,243337431	3,790479401	0,002578694	87,56609826	3	2428,392921	0,415897931	5,974352584	114,3509186	1
25	443	5139,974297	90,92814148	0	1,216773668	87,73703368	21	4,106458924	7,889647815	0,044999579	81,38437335	1	1141,266434	0,452358321	5,589833274	483,005395	1
26	591	8700,182968	84,99488358	0	2,459252283	70,0321653	21	3,194392028	7,419404154	0,055012182	94,35712917	3	1566,702098	0,169895237	3,142709581	188,8384832	1
27	513	15896,92573	86,86550978	0	2,308544186	70,11335133	16	4,748798974	9,737658413	0,033978461	82,95491818	9	2295,387018	0,466476884	2,041939313	148,6247875	1
28	905	19877,14927	97,04096832	3	3,090736874	85,15442341	12	0,243724277	2,115909445	0,074981775	85,70251814	2	2241,921895	0,465638911	2,901354458	476,4544172	1
29	485	6487,671494	91,18436264	5	3,125238045	90,48684422	1	3,962059986	8,006070082	0,06756605	97,62162011	1	4201,546786	0,28851634	1,876040196	432,1747665	1
30	291	11022,41474	90,29484388	4	3,87494143	95,05942452	19	3,495385916	6,046348804	0,097139899	90,80995316	1	4373,021901	0,419213924	3,480652171	405,9481677	1
31	376	17001,06453	81,99159427	4	2,794504767	94,08558255	5	1,304461526	9,221543823	0,05087668	86,42676881	7	1773,674397	0,277979191	9,975677597	141,8982836	0
32	260	8060,534519	80,32056313	3	0,971701884	98,59531977	21	3,645833514	6,609333393	0,053781236	90,9533378	4	1495,759536	0,325618506	4,618830387	423,0116855	1
33	559	13326,27424	99,27370377	1	4,36231101	83,25539581	0	3,58274275	5,573341796	0,024583932	84,36555319	5	3536,649937	0,227935604	8,774995522	343,6094092	1
34	413	15996,06944	87,53972335	3	1,893940624	96,34622245	7	2,296726015	7,326804876	0,038548389	80,50346259	7	4218,494223	0,163787738	5,942599229	392,7634444	0
35	121	14239,78175	92,06426124	5	4,870838571	92,34053093	17	3,443198094	8,668187537	0,002686059	92,07464958	6	4854,892389	0,398614634	6,999247714	491,2281119	1
36	352	7820,371019	81,59430146	0	1,030370489	95,78670497	20	2,222904515	4,259988401	0,068927479	94,28251866	6	1027,185139	0,100557138	2,407131728	177,7764708	1
37	847	10330,76853	93,66228571	3	4,812130275	60,46506405	3	1,67772798	2,860216135	0,03116228	97,59563531	6	2654,712454	0,331821076	3,473252807	301,7527843	1
38	956	16756,87677	98,65133417	0	0,909553131	98,63611967	4	2,332454802	5,464144947	0,054036701	95,43766722	6	3935,951336	0,445874411	5,593990807	401,3407786	1
39	660	13313,39771	91,51330506	5	1,539662621	78,94120651	4	4,475647407	3,716158982	0,02549924	98,53355401	7	4314,237195	0,188510915	8,930290908	273,4625403	0
40	574	5078,444203	82,52230645	5	0,709609739	91,92731958	14	1,922918964	5,436329403	0,06210362	99,71906951	0	1249,143795	0,233159783	1,385992323	121,8612332	1
41	158	16414,8614	91,63443055	2	3,67300916	65,08816477	9	2,018440887	9,928385382	0,044758249	94,89870895	2	3722,458078	0,334994341	5,562279636	144,5755596	1
42	610	5529,670324	95,32694426	0	4,326344315	75,83764383	7	3,042016138	6,59297675	0,048186065	97,35846602	0	2155,75487	0,198748099	1,459109913	340,836789	1
43	781	16186,00674	88,12833073	4	2,453319868	70,85842652	6	3,764997377	7,548801783	0,094260714	93,47463006	7	1298,387837	0,438994743	5,111404088	214,0016586	1
44	575	8037,208402	97,59675496	3	4,678349338	71,66635082	11	3,673104302	7,42342738	0,070616032	83,41875582	1	2956,410327	0,246641267	6,659813434	155,1362589	1
45	799	19371,1022	92,97365907	5	3,156345823	64,9302248	10	0,098993651	8,56560669	0,026189974	83,63404853	6	1632,613373	0,332645488	7,702508723	235,956799	1
46	882	10519,11127	97,98497837	0	3,33503211	92,2305533	12	3,437076665	9,553028792	0,050392182	82,20518913	5	3948,030072	0,190448459	2,246788047	180,3923728	1
47	289	9903,974245	92,47010622	1	4,304386408	60,36969258	14	2,25277024	7,270544786	0,046667282	98,8594944	0	3965,047199	0,116554535	2,499177551	109,5757866	1
48	786	7233,320755	82,62575944	2	1,835600923	72,50021828	16	2,620449838	5,808757158	0,079505261	93,45503396	5	4368,27106	0,169480106	5,230584295	160,7255954	1
49	662	9584,063232	86,19383422	1	2,094195746	66,97642173	21	2,808316685	4,542647571	0,083335511	95,79819501	8	2510,274741	0,118479575	9,982328122	453,2311844	1
50	975	18149,76143	84,03589897	5	4,576783636	83,56155762	21	3,658598086	4,882194401	0,028344282	86,62314674	2	1053,239189	0,28744156	4,204421521	104,814913	1
51	666	19945,01506	98,17652995	1	4,554335732	70,1700961	17	4,156664918	4,675844865	0,082115145	89,2084342	6	2038,943753	0,334654956	4,847746846	409,5401214	1
52	343	10524,64296	95,20800135	1	4,894172493	70,35993818	7	3,231304723	4,59572393	0,017950141	80,79559064	3	2871,246798	0,117870083	4,892020685	401,3844423	1
53	931	11729,15946	93,52796738	2	4,558272424	79,53352576	5	2,819536104	7,557000035	0,076277055	97,78014801	0	5776,045118	0,136192889	1,726307392	325,6950753	1
54	604	15831,06407	86,01932639	2	1,073174162	86,10756157	10	1,868846274	6,70167224	0,024878454	97,06006859	6	2528,162343	0,294210011	7,967549308	183,3791063	0
55	230	18292,93671	83,68089544	2	4,206759288	64,85218818	8	0,689391096	3,615960359	0,029793116	95,6962267	0	3144,193584	0,419671973	3,27791372	451,2236897	1
56	584	13895,66501	95,12902176	2	2,344273151	67,0204581	4	4,792888408	9,757008153	0,085246784	81,16604135	3	3097,05435	0,351203672	7,333003512	290,0302275	1
57	918	10872,88547	89,48315892	1	4,958606102	69,88698978	6	2,309211462	5,421804123	0,042007487	83,48499471	8	1659,929397	0,141884088	5,27580891	169,2824916	1
58	746	11189,32761	84,51579104	4	2,625264339	98,94992856	21	2,831061222	6,528691209	0,099056582	86,68341316	4	3492,198	0,45501691	6,50601768	271,609037	1
59	120	15434,2722	92,33243956	4	2,992262371	75,8861	14	3,755365697	7,620807734	0,015194303	85,26125351	6	2757,006913	0,466980094	1,485744728	177,9668911	1
60	940	5048,273954	80,80667704	2	2,883987119	83,95960363	20	0,342052425	6,909419013	0,046334904	96,76919677	6	4231,674807	0,229982731	9,00969116	250,4031365	1
61	266	14293,84006	86,52340508	3	1,947816634	69,66171251	21	4,275055045	4,488414153	0,073245033	83,89671516	2	3762,444833	0,346407117	3,194710925	298,6751084	1
62	373	10332,39516	89,37113989	0	0,8375994	79,61838101	3	3,985128717	8,381652588	0,000536706	90,64248931	7	1445,876745	0,29693086	7,030858488	243,9603559	0
63	487	16912,95997	82,95916668	5	4,530430537	62,96476698	18	3,87214291	2,881229117	0,015185528	91,42762196	0	2955,03364	0,476809507	8,182172009	362,8177096	1
64	700	6394,859597	99,69308955	3	4,112041156	61,38968584	12	0,109913534	6,551966678	0,002035675	88,50023694	3	3809,977434	0,303499413	5,860348456	474,3671216	1
65	415	13823,034	84,18194729	5	1,127870513	78,74934107	0	2,632594257	4,186537784	0,099287787	84,81375863	9	1348,046903	0,483986325	4,036006199	239,2597391	0
66	113	12214,59335	82,6070626	3	3,995457221	75,9463715	0	0,271341854	6,926098941	0,076062466	99,20588582	3	4169,98813	0,17973702	9,80113037	242,2958055	1
67	341	14634,88289	84,07069748	3	3,316309997	65,47521279	21	2,754362894	3,743947849	0,03735591	88,26798485	1	1888,018059	0,238214703	3,505957419	395,3209882	1
68	876	5972,803917	95,38122266	4	2,341147046	87,50405716	13	3,592241631	8,177597242	0,015628493	94,54619991	5	3012,339182	0,412538096	9,537961034	312,2363726	1
69	445	13699,75681	88,51011319	0	1,643095171	99,71613964	8	0,609251251	3,82029065	0,009038324	83,68092975	0	4762,24515	0,413444294	2,406017203	271,5357758	0
70	664	13422,26882	91,3083188	3	4,368779526	75,82587285	23	3,474415527	9,12313708	0,05319072	96,45622337	2	3285,336939	0,39287331	4,502999184	425,5232754	1
71	997	13409,90142	80,42018314	2	3,650847167	84,98234544	11	2,24766423	8,892439237	0,097589132	84,31783646	8	2696,217807	0,443844586	2,246460257	456,4144269	1
72	439	14052,315	80,68862617	5	2,964829593	98,51903769	17	4,057764653	4,899147616	0,067461094	93,50613247	9	1027,17971	0,381018469	1,020164258	336,2346424	1
73	191	15147,01906	88,916511	4	3,249058603	93,2613989	8	2,667944697	5,086562311	0,036513887	90,12993003	5	1533,654491	0,354434058	3,342326864	174,0413091	1

Datenanalyse & -vorbereitung

Fragestellungen, die es zu beantworten gilt:

- Wie liegen die Daten vor (Dateiformat, Datentyp, …)?
- Wie viele Daten sind vorhanden?
- Müssen die Daten bereinigt werden? Sind sie vollständig?
- Sind die Daten für die KI lesbar?
- Welche Vorbereitungsmaßnahmen sind notwendig?

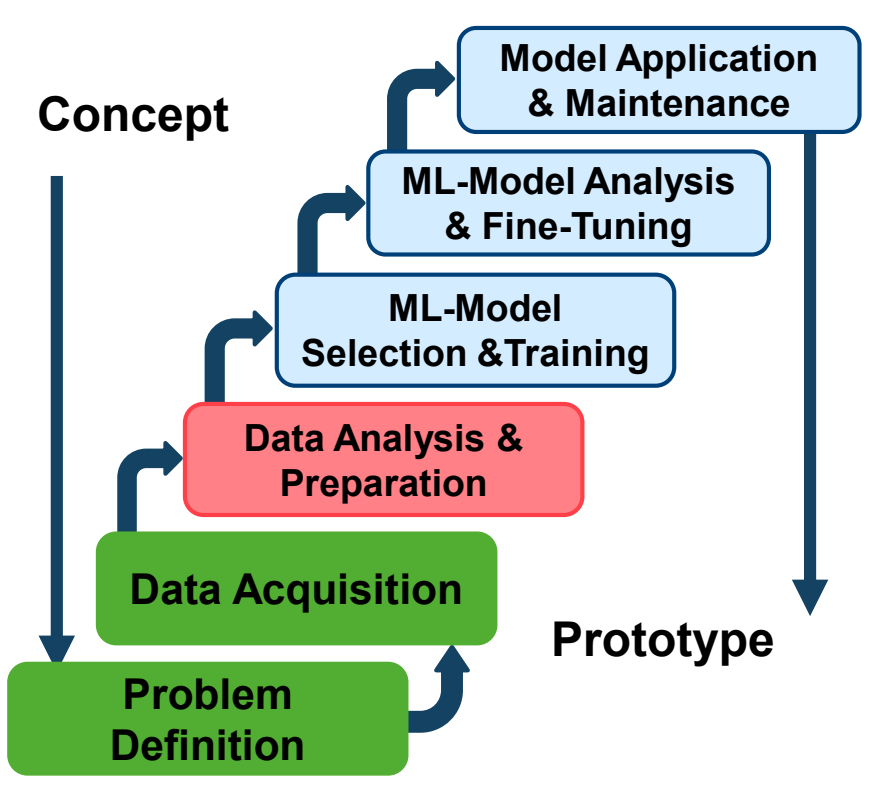

Die gesammelten Daten müssen analysiert, bereinigt und vorverarbeitet werden, um z.B. Ungenauigkeiten, Fehler und Irrelevanzen zu entfernen sowie ein tieferes Systemverständnis zu erlangen.

Programmiersprint 1

Einführung in Datenanalyse & -vorbereitung

Quelle: geralt auf pixabay.com

Modellauswahl und Training

Fragestellungen, die es zu beantworten gilt:

- Welcher Ansatz?
  - ***Überwachtes Lernen***
- Welches Modell in Abhängigkeit der Art
  - ➢ des Problems
    - ➢ ***Klassifikation***
  - ➢ der Daten (z.B. numerisch, Text, Bilder)?
    - ➢ ***numerisch***
- Welche Einstellungsmöglichkeiten (Hyperparameter)?

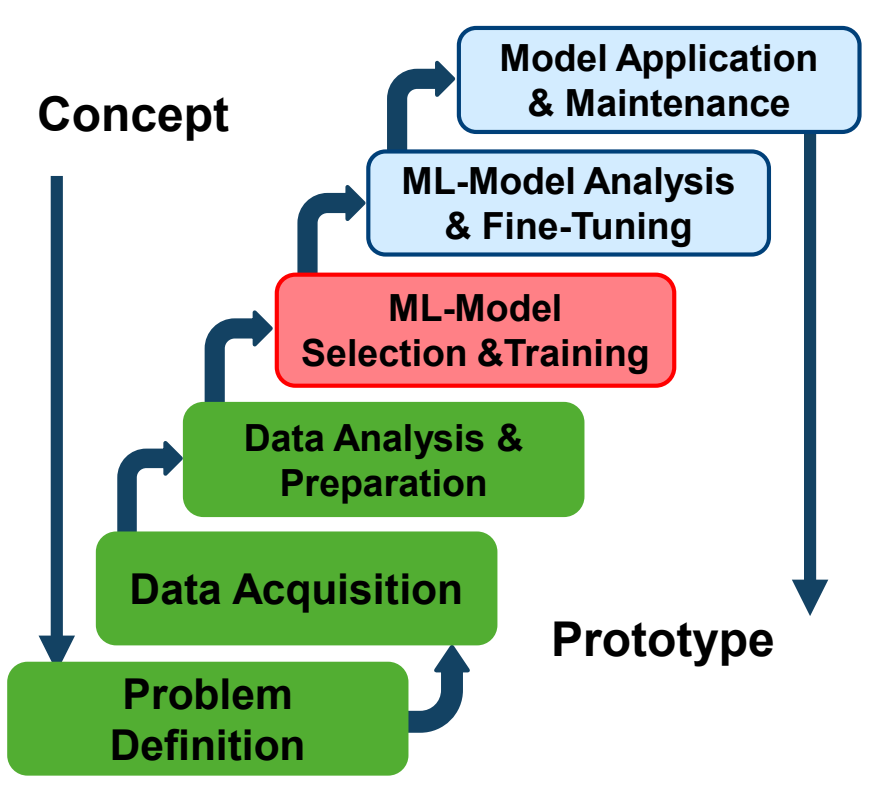

Basierend auf den Zielen und der Art der verfügbaren Daten werden die Architektur des Modells sowie die Hyperparameter gewählt.

Modelle zur Klassifikation

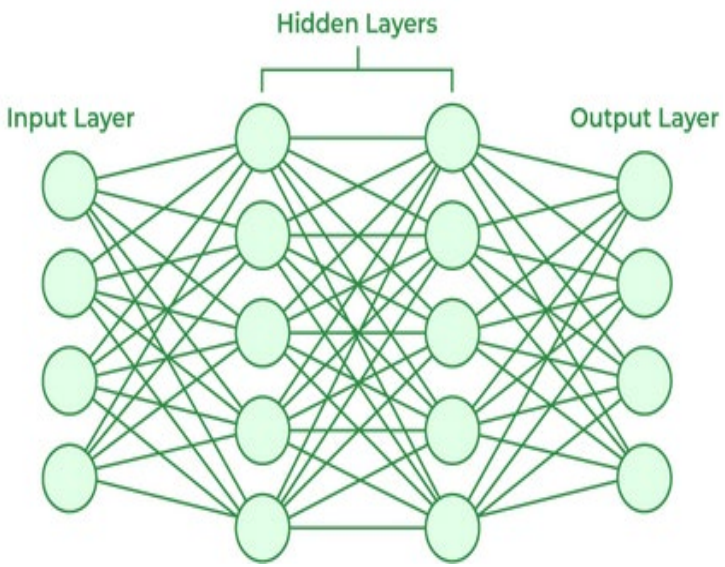

Neuronales Netz

- Modell aus mehreren Schichten
- Erkennt komplexe Muster durch gewichtete Verbindung zw. Eingabe, versteckten Schichten und Ausgabe

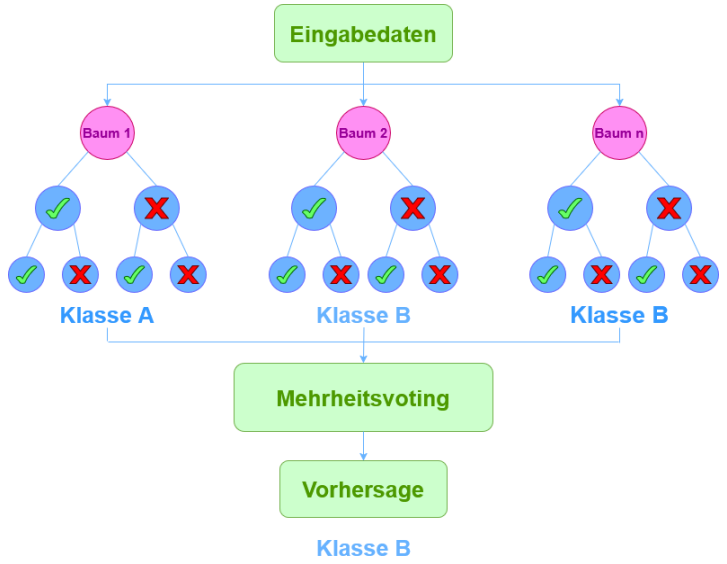

Random Forest Classifier

- Entscheidungsbäume
- Jeder Baum bekommt parallel Daten & trifft daraufhin Entscheidung
- Gesamtergebnis über Mehrheitsabstimmung

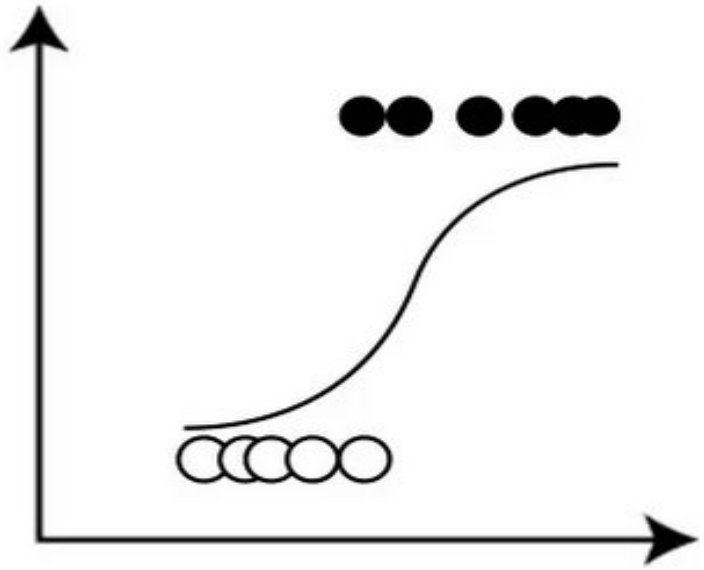

Logistische Regression

- Einfaches Klassifikationsmodell
- Basierend auf Wahrscheinlichkeits-verteilung (Sigmoid-Kurve)

Modelle zur Klassifikation

Neuronales Netz

- Gut geeignet für komplexe Muster
  - Erkennt Nichtlinearität & Muster in Daten
  - Beispiel: Sprache oder Bilderkennung
- Hohe Anpassungsfähigkeit
  - Lernen aus Beispielen
  - Sehr viele Optimierungs-methoden (Architektur, Lernrate, Regularisierung)
- Großer Einsatzbereich
  - Vielfältige Anwendung
  - Gute Architektur → solide Ergebnisse

Random Forest Classifier

- Robust
  - Durch Menge an Entscheidungsbäumen
  - Stabile, generalisierbare Vorhersagen
  - Wenig anfällig für Ausreißer
- Keine Skalierung notwendig
  - Verarbeitung „roher“ Daten
  - Ersparnis an Code & Rechenzeit

Logistische Regression

- Schnell, einfach, effektiv
  - Trotz einfacher Struktur oft sehr gute Ergebnisse
  - Besonders geeignet bei linearen Problemen
  - Geringe Trainingszeit
  - Schnelle Vorhersagen
- Benchmark-Modell für Vergleiche
  - Schnelle Vergleichbarkeit mit Modellen

Modellevaluation und Fine-Tuning

Fragestellungen, die es zu beantworten gilt:

- Welche Metriken zur Evaluation verwenden?
  - ➢ Absoluter Fehler, quadratischer Fehler, prozentualer Fehler, …
- Welche Möglichkeiten des Fein-Tunings existieren?
- Andere Modelltypen (Algorithmen) in Erwägung ziehen?

➢ **Training mit Trainingsdatensatz, Evaluation mit unabhängigen Testdatensatz!**

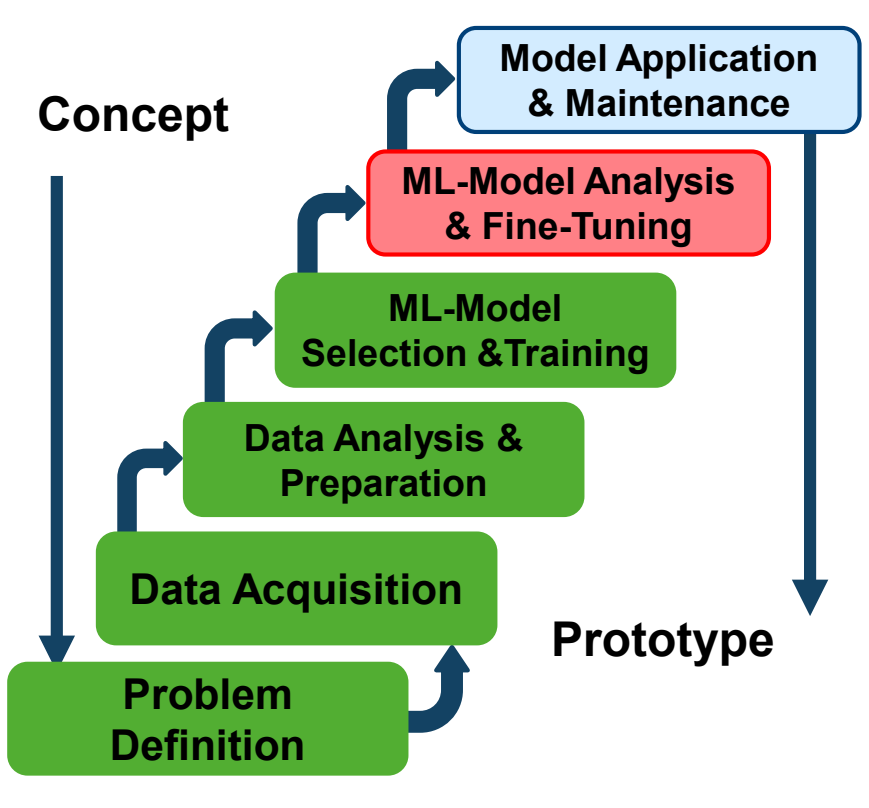

Nachdem das Modell trainiert wurde, muss es evaluiert werden, um seine Leistung zu überprüfen. Hierbei werden verschiedene Metriken verwendet, um die Genauigkeit, Relevanz und andere Aspekte zu bewerten.

Modelleinsatz und Wartung

Fragestellungen, die es zu beantworten gilt:

- Wo muss das Modell integriert werden?
- Welche Schnittstellen existieren zu anderen Systemen?
  - ***Vorhersagen in Excel-Datei integrieren***
- Echtzeit-Fähigkeit notwendig?
- kontinuierliches Monitoring der KI
- Feedbackmöglichkeiten umsetzen
- regelmäßige Aktualisierung des Modells durchführen
- weiteres Sammeln von Daten

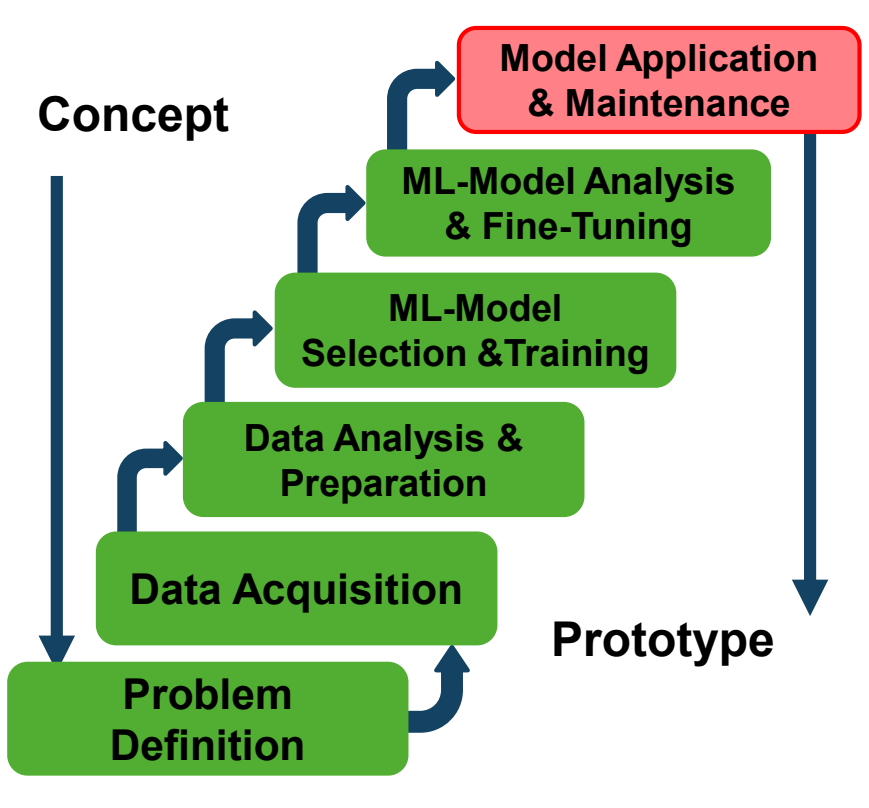

Sammeln Sie Feedback von Nutzern und anderen Stakeholdern, um das KI-System fortlaufend zu verbessern und zu erweitern.

PAUSE

Quelle: geralt auf pixabay.com

Programmiersprint 2

Einführung in Modellerstellung & Optimierung

Quelle: geralt auf pixabay.com

Reflektion

Ergebnisse & Erkenntnisse

Quelle: geralt auf pixabay.com

Ergebnisse der Modelle

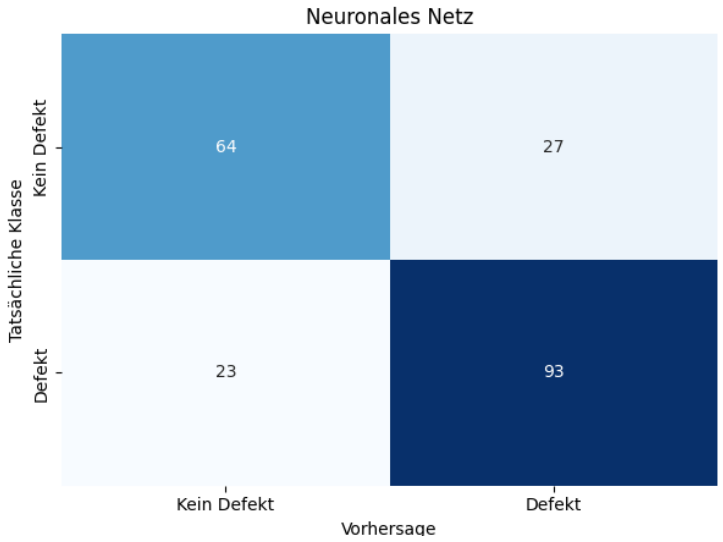

Neuronales Netz

- 157 von 207 korrekt vorhergesagt (~75%)
  - ➢ Mangelhafte Generalisierung
  - ➢ Weitere Optimierungen notwendig

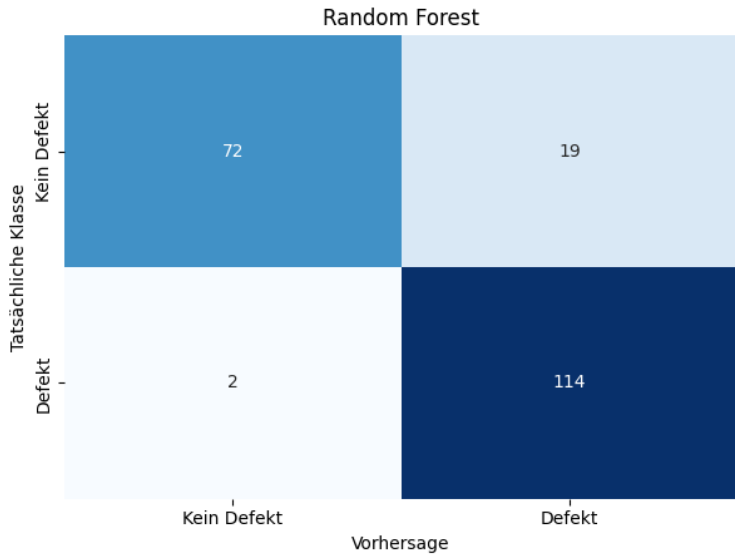

Random Forest Classifier

- 186 von 207 korrekt vorhergesagt (~90%)
  - ➢ Gute Generalisierung
  - ➢ Wenig Anpassungen notwendig

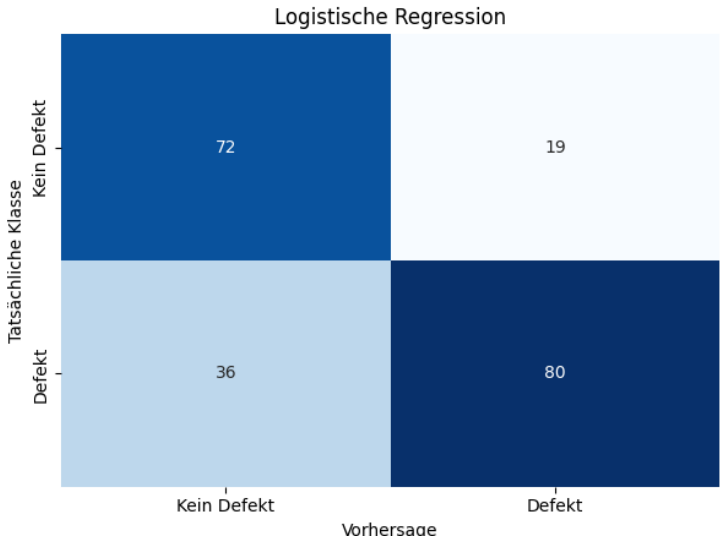

Logistische Regression

- 152 von 207 korrekt vorhergesagt (~75%)
  - ➢ Befriedigende Generalisierung
  - ➢ Weitere Anpassungen notwendig

PAUSE

Quelle: geralt auf pixabay.com

Regression

Vorhersage numerischer Werte

Quelle: geralt auf pixabay.com

Problem Definition

- Prozess analysieren
- Datenlage sichten
  - ***Excel-Datei mit Ein- & Ausgangsparametern***
- Problem beschreiben
  - ***Festigkeiten der Betonmischungen voraussagen***

➢ **Regressionsaufgabe**

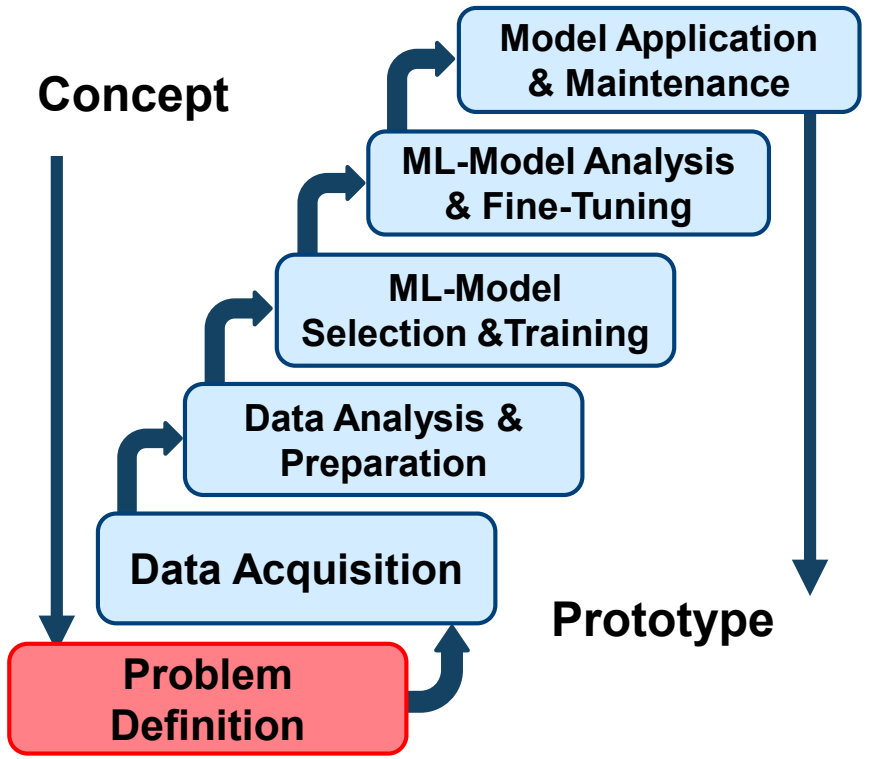

Aus der Datenlage, der Prozessbeschreibung und der Problemdefinition ergeben sich Grundcharakteristiken des zu entwickelnden KI-Modells.

Problem Definition

- Datensatz in Excel
  - **Festigkeit** von Beton mit verschiedenen Zusammensetzungen voraussagen
- Eingangsparameter wie:
  - Anteil Zement
  - Anteil Wasser
  - Anteil Schlacke
  - Anteil Asche
  - Anteil Fließmittel
  - Alter des Betons
  - …
- Ausgangsparameter (Zielwert):
  - Druckfestigkeit des Betons

- Nicht alle Parameter haben den gleichen Einfluss auf das Ergebnis!
  - durch Datenanalyse Nachvollziehbarkeit von Korrelationen
  - Parameter mit **hoher** Korrelation **müssen** berücksichtigt werden
  - Parameter mit **niedriger** Korrelation **können** entfernt werden

Datenakquise

Schritte der Datenakquise

- Datenquellen identifizieren
  - ***Excel-Datei***
- Datensammlungsstrategie festlegen
- Qualität und Repräsentativität der Daten sicherstellen
  - ***Synthetisch generierte Daten***
- Datenaufnahme durchführen
- Datensammlung überprüfen

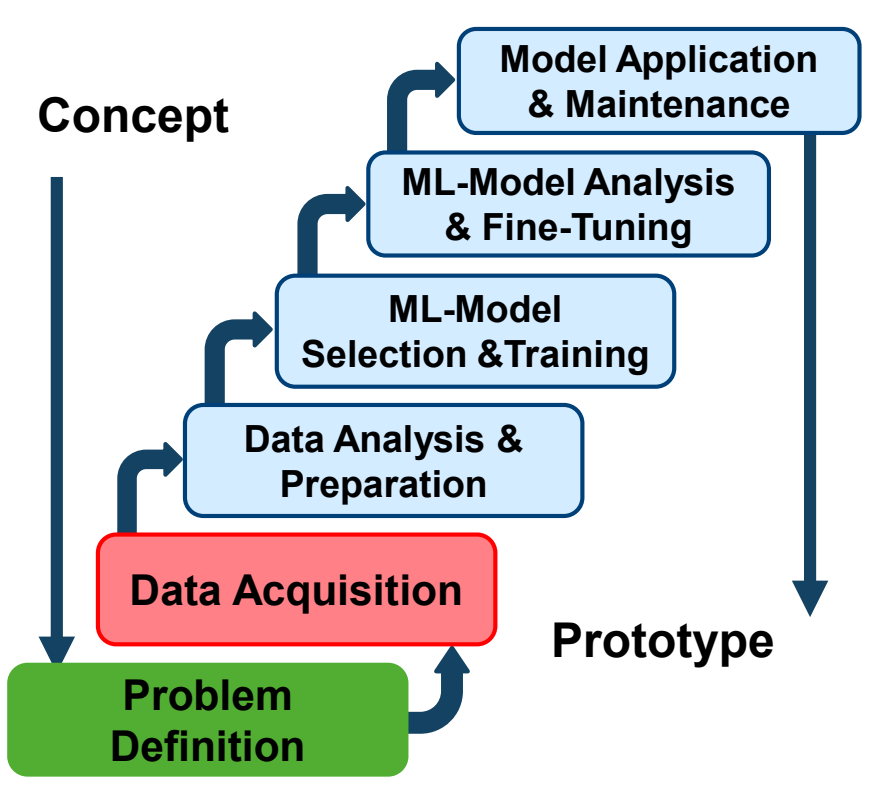

KI-Systeme benötigen Daten, um zu lernen. Die Sammlung von qualitativ hochwertigen, relevanten und vielfältigen Daten ist entscheidend für die Entwicklung einer effektiven KI.

	A	B	C	D	E	F	G	H	I
1	Cement [kg/m3]	Slag [kg/m3]	FlyAsh [kg/m3]	Water [kg/m3]	Superplasticizer [kg/m3]	CoarseAggregate [kg/m3]	FineAggregate [kg/m3]	Age [days]	CompressiveStrength [MPa]
2	540	0	0	162	2,5	1040	676	28	79,99
3	540	0	0	162	2,5	1055	676	28	61,89
4	332,5	142,5	0	228	0	932	594	270	40,27
5	332,5	142,5	0	228	0	932	594	365	41,05
6	198,6	132,4	0	192	0	978,4	825,5	360	44,3
7	266	114	0	228	0	932	670	90	47,03
8	380	95	0	228	0	932	594	365	43,7
9	380	95	0	228	0	932	594	28	36,45
10	266	114	0	228	0	932	670	28	45,85
11	475	0	0	228	0	932	594	28	39,29
12	198,6	132,4	0	192	0	978,4	825,5	90	38,07
13	198,6	132,4	0	192	0	978,4	825,5	28	28,02
14	427,5	47,5	0	228	0	932	594	270	43,01
15	190	190	0	228	0	932	670	90	42,33
16	304	76	0	228	0	932	670	28	47,81
17	380	0	0	228	0	932	670	90	52,91
18	139,6	209,4	0	192	0	1047	806,9	90	39,36
19	342	38	0	228	0	932	670	365	56,14
20	380	95	0	228	0	932	594	90	40,56
21	475	0	0	228	0	932	594	180	42,62
22	427,5	47,5	0	228	0	932	594	180	41,84
23	139,6	209,4	0	192	0	1047	806,9	28	28,24
24	139,6	209,4	0	192	0	1047	806,9	3	8,06
25	139,6	209,4	0	192	0	1047	806,9	180	44,21
26	380	0	0	228	0	932	670	365	52,52
27	380	0	0	228	0	932	670	270	53,3
28	380	95	0	228	0	932	594	270	41,15
29	342	38	0	228	0	932	670	180	52,12
30	427,5	47,5	0	228	0	932	594	28	37,43
31	475	0	0	228	0	932	594	7	38,6
32	304	76	0	228	0	932	670	365	55,26
33	266	114	0	228	0	932	670	365	52,91

Datenanalyse & -vorbereitung

Fragestellungen, die es zu beantworten gilt:

- Wie liegen die Daten vor (Dateiformat, Datentyp, …)?
- Wie viele Daten sind vorhanden?
- Müssen die Daten bereinigt werden? Sind sie vollständig?
- Sind die Daten für die KI lesbar?
- Welche Vorbereitungsmaßnahmen sind notwendig?

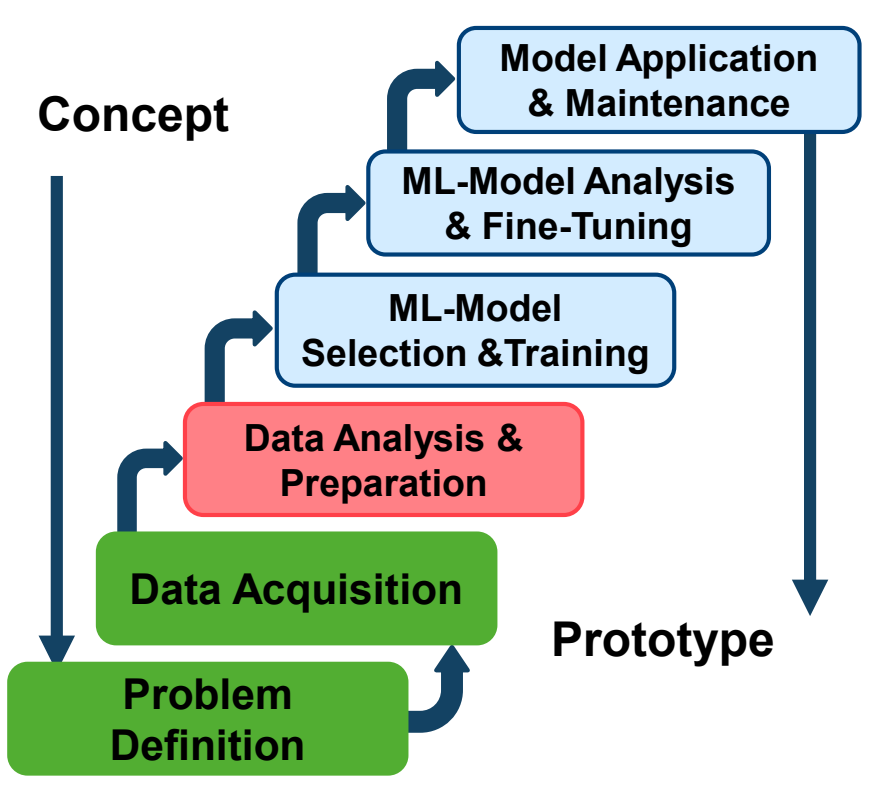

Die gesammelten Daten müssen analysiert, bereinigt und vorverarbeitet werden, um z.B. Ungenauigkeiten, Fehler und Irrelevanzen zu entfernen sowie ein tieferes Systemverständnis zu erlangen.

Programmiersprint 3

eigenständige Datenanalyse & -vorbereitung

Quelle: geralt auf pixabay.com

Modellauswahl und Training

Fragestellungen, die es zu beantworten gilt:

- Welcher Ansatz?
  - ***Überwachtes Lernen***
- Welches Modell in Abhängigkeit der Art
  - ➢ des Problems
    - ➢ ***Regression***
  - ➢ der Daten (z.B. numerisch, Text, Bilder)?
    - ➢ ***numerisch***
- Welche Einstellungsmöglichkeiten (Hyperparameter)?

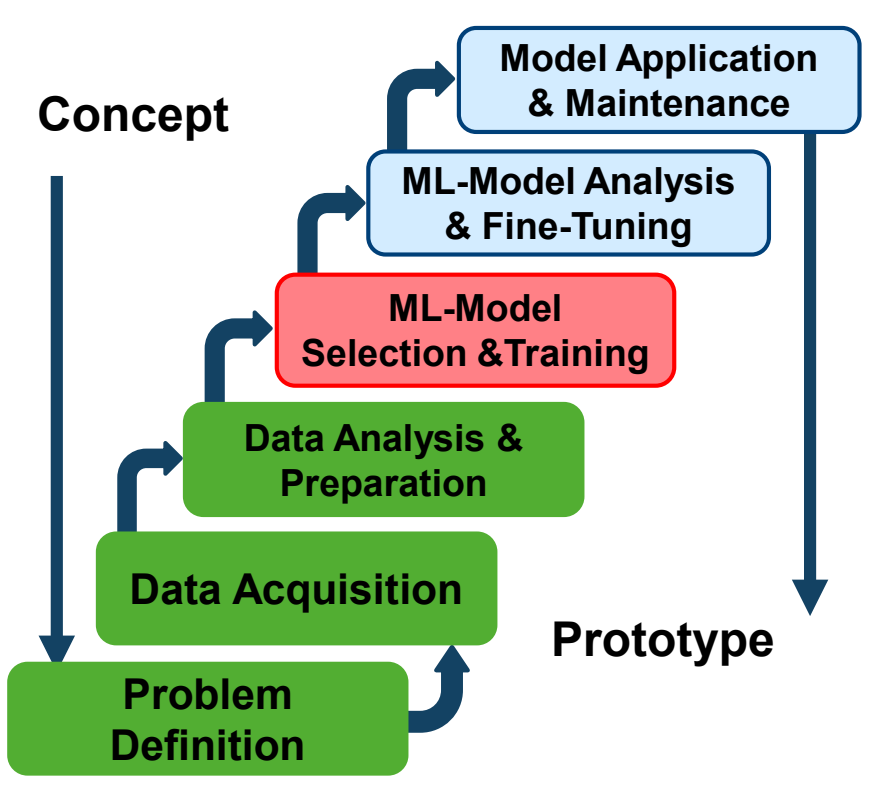

Basierend auf den Zielen und der Art der verfügbaren Daten werden die Architektur des Modells sowie die Hyperparameter gewählt.

Modelle zur Regression

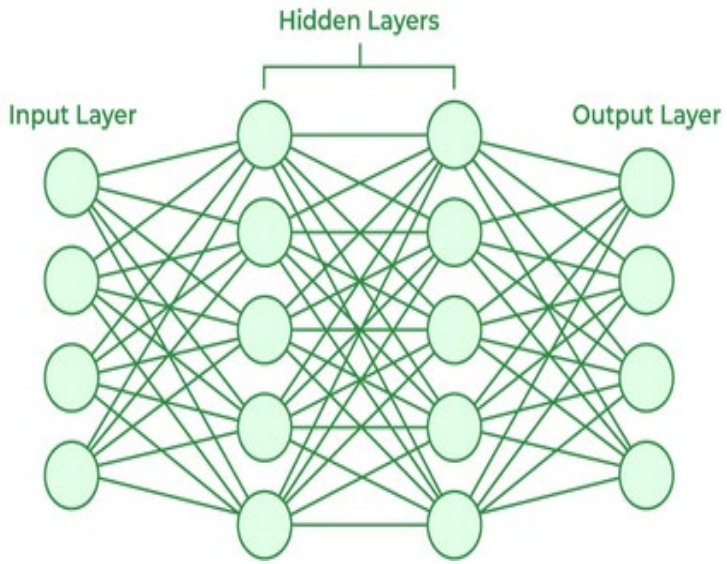

Neuronales Netz

- Modell aus mehreren Schichten
- Erkennt komplexe Muster durch gewichtete Verbindung zw. Eingabe, versteckten Schichten und Ausgabe

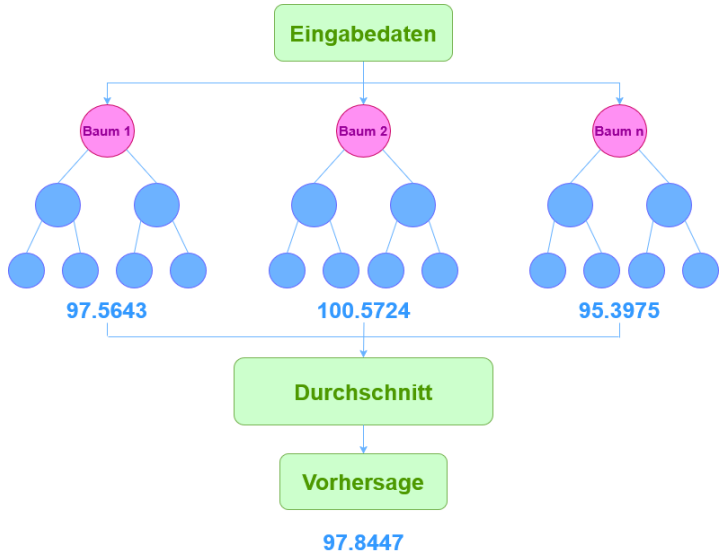

Random Forest Regressor

- Entscheidungsbäumen
- Jeder Baum bekommt parallel einen Teil der Daten & trifft daraufhin Entscheidung
- Gesamtergebnis über Mittelwert

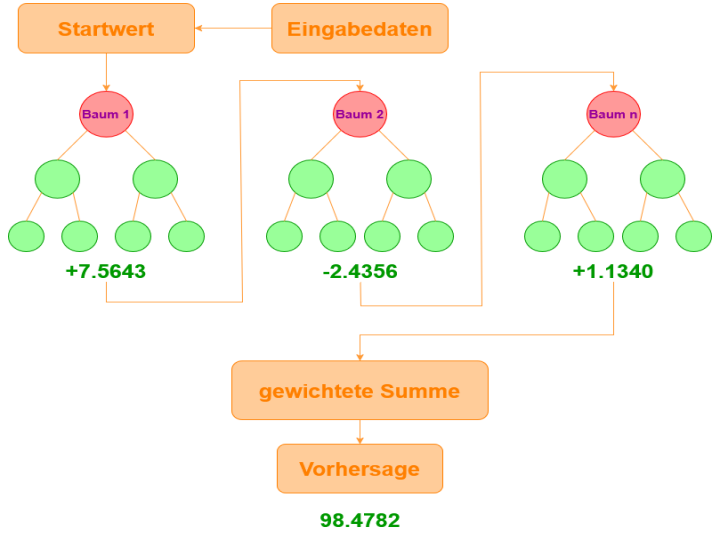

XGBoost

- Basiert ebenfalls auf Entscheidungsbäumen
- Jeder Baum bekommt nacheinander alle Daten & lernt auf Basis vorheriger Bäume

Modelle zur Regression

Neuronales Netz

- Gut geeignet für komplexe Muster
  - Erkennt Nichtlinearität & Muster in Daten
  - Beispiel: Sprache oder Bilderkennung
- Hohe Anpassungsfähigkeit
  - Lernen aus Beispielen
  - Sehr viele Optimierungs-methoden (Architektur, Lernrate, Regularisierung)
- Großer Einsatzbereich
  - Vielfältige Anwendung
  - Gute Architektur → solide Ergebnisse

Random Forest Regressor

- Robust
  - Durch Menge an Entscheidungsbäumen wird Varianz verringert
  - Führt zu stabilen, generalisierbaren Vorhersagen
  - Wenig anfällig für Ausreißer
- Keine Skalierung notwendig
  - Verarbeitung „roher“ Daten
  - Ersparnis an Code & Rechenzeit

XGBoost

- Sehr präzise
  - Nutzt sequentielles Lernen
  - Sehr gute Performance bei Wettbewerben & in der Praxis
- Umgang mit fehlenden Werten
  - Fehlende Daten müssen nicht manuell imputiert werden
  - Modell bleibt robust, auch wenn reale Daten fehlen oder unvollständig sind

Modellevaluation und Fine-Tuning

Fragestellungen, die es zu beantworten gilt:

- Welche Metriken zur Evaluation verwenden?
  - ➢ Absoluter Fehler, quadratischer Fehler, prozentualer Fehler, …
- Welche Möglichkeiten des Fein-Tunings existieren?
- Andere Modelltypen (Algorithmen) in Erwägung ziehen?

➢ **Training mit Trainingsdatensatz, Evaluation mit unabhängigen Testdatensatz!**

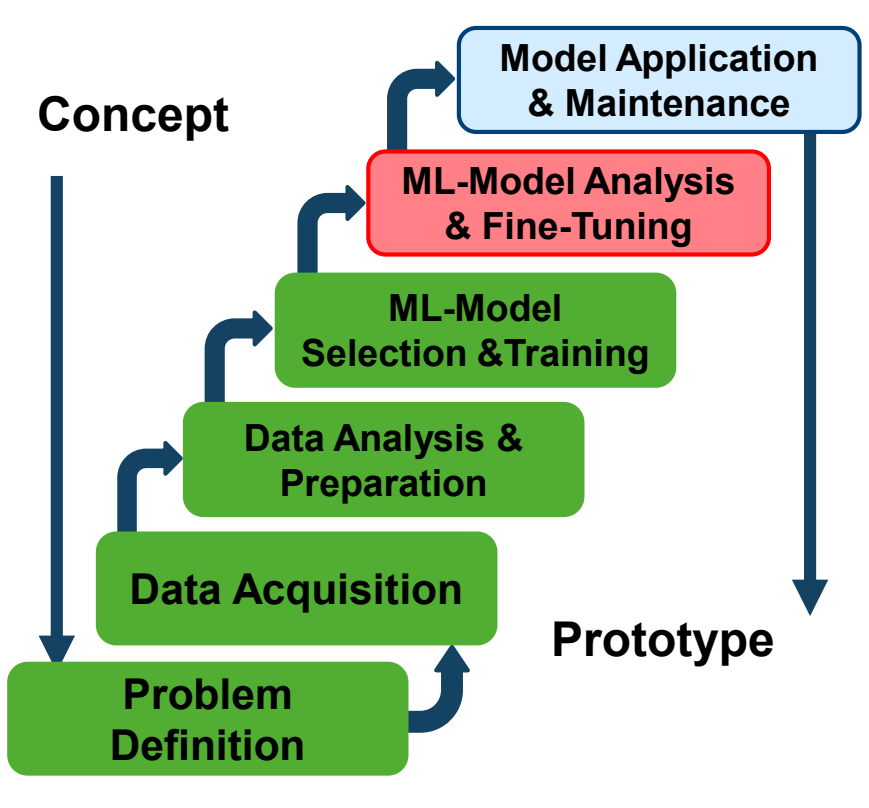

Nachdem das Modell trainiert wurde, muss es evaluiert werden, um seine Leistung zu überprüfen. Hierbei werden verschiedene Metriken verwendet, um die Genauigkeit, Relevanz und andere Aspekte zu bewerten.

Modelleinsatz und Wartung

Fragestellungen, die es zu beantworten gilt:

- Wo muss das Modell integriert werden?
- Welche Schnittstellen existieren zu anderen Systemen?
  - ***Vorhersagen in Excel-Datei integrieren***
- Echtzeit-Fähigkeit notwendig?
- kontinuierliches Monitoring der KI
- Feedbackmöglichkeiten umsetzen
- regelmäßige Aktualisierung des Modells durchführen
- weiteres Sammeln von Daten

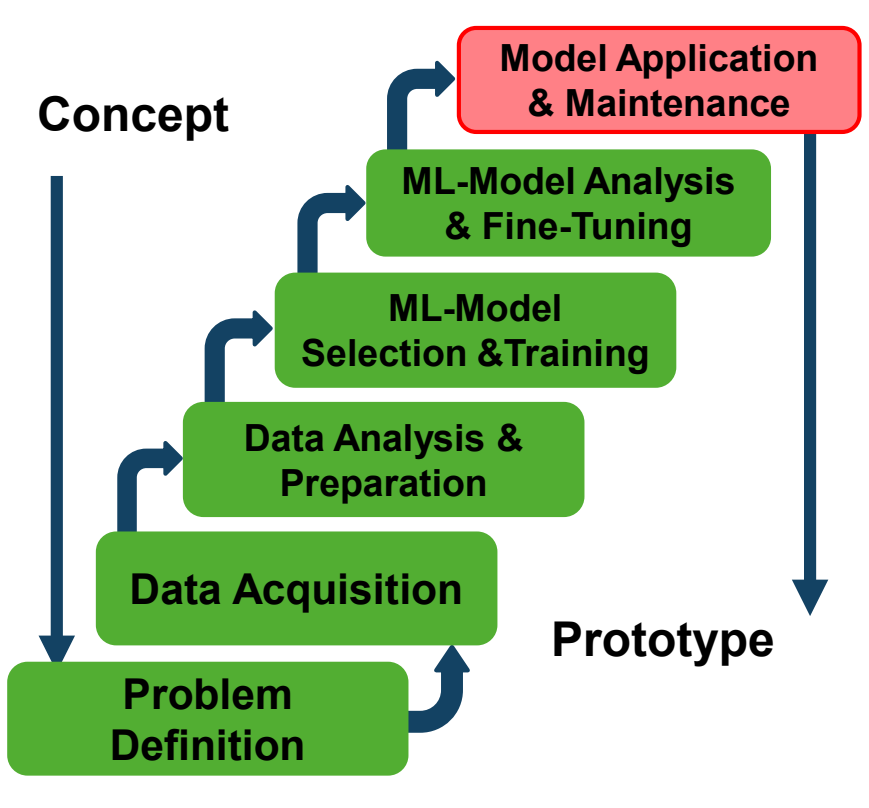

Sammeln Sie Feedback von Nutzern und anderen Stakeholdern, um das KI-System fortlaufend zu verbessern und zu erweitern.

PAUSE

Quelle: geralt auf pixabay.com

Programmiersprint 4

eigenständige Modellerstellung & Optimierung

Quelle: geralt auf pixabay.com

Reflektion

Ergebnisse & Erkenntnisse

Quelle: geralt auf pixabay.com

Ergebnisse der Modelle

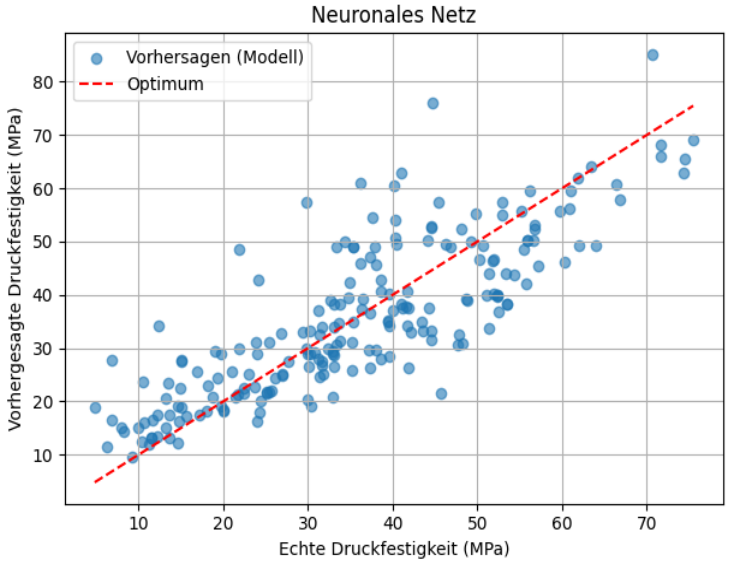

Neuronales Netz

- Große Streuung
  - ➢ Keine gute Generalisierung
  - ➢ Weitere Anpassungen notwendig

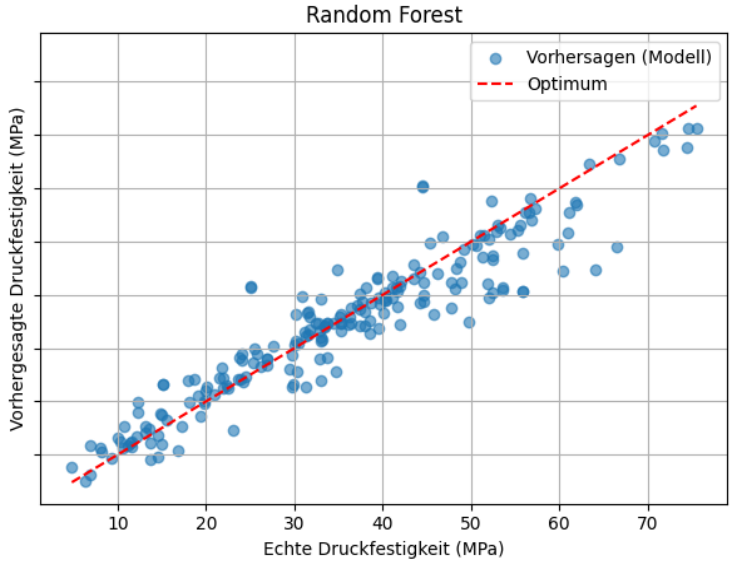

Random Forest Regressor

- Gute Verteilung um Optimum
  - ➢ Bereits gute Generalisierung
  - ➢ Wenig Anpassungen notwendig

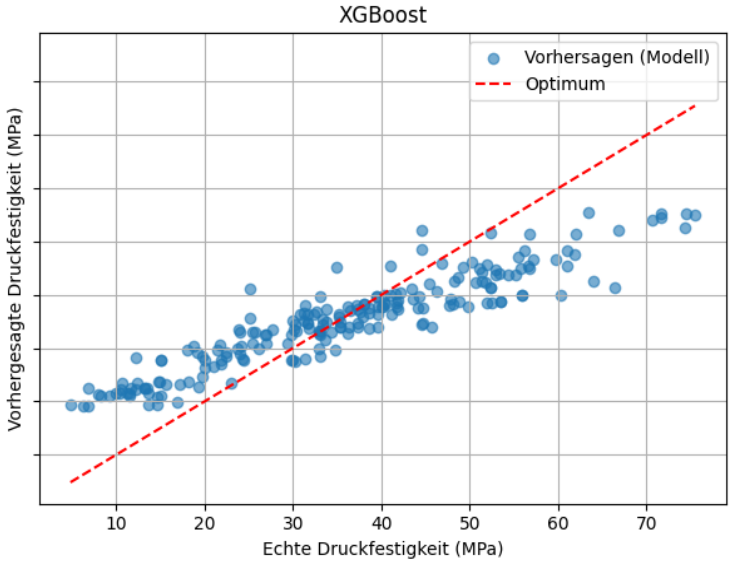

XGBoost

- Schlechte Verteilung bei Randwerten
  - ➢ Keine gute Generalisierung
  - ➢ Weitere Anpassungen notwendig

Clustering

Gruppierung ähnlicher Daten

Quelle: geralt auf pixabay.com

Problem Definition

- Prozess analysieren
- Datenlage sichten
  - ***Excel-Datei ohne Ausgangsparameter***
  - ***Alle Daten werden als Eingang herangezogen***
- Problem beschreiben
  - ***Ähnliche Merkmale ohne feste Vorgaben gruppieren***

➢ **Clustering-Aufgabe**

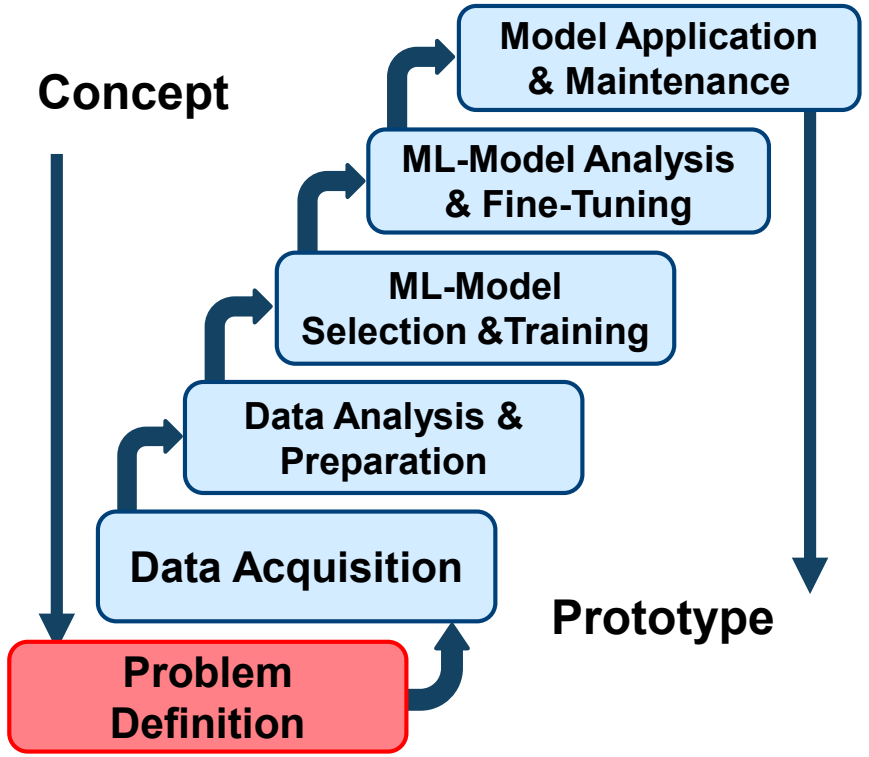

Aus der Datenlage, der Prozessbeschreibung und der Problemdefinition ergeben sich Grundcharakteristiken des zu entwickelnden KI-Modells.

Problem Definition

- Datensatz in Excel
- Nur Eingangsparameter
- Kein Zielwert wie bei überwachtem Lernen
- Autos mit verschiedenen Merkmalen wie:
  - Anzahl Zylinder
  - Verbrauch (Stadt, Autobahn, kombiniert)
  - Klasse (Kompakt, SUV, Truck)
  - Antrieb (FWD, RWD, AWD, 4WD)
  - Getriebe (Automatik, Schalter, Anzahl Gänge)
  - Hubraum
  - …

- Datensatz wurde in numerische & kategorische Werte unterteilt
- Modell 1 (k-Prototypes) nutzt kategorische & numerische Variablen
- Modell 2 (k-Means) nutzt nur numerische Variablen
- Ziel:
  - Darstellung der einzelnen Gruppen (Cluster)
    - ➢ Sind die Gruppen dicht?
    - ➢ Wie verteilen sich die Gruppen?
  - Vergleich zwischen k-Prototypes & k-Means
    - ➢ Lohnen sich zusätzliche kategorische Variablen?

Datenakquise

Schritte der Datenakquise

- Datenquellen identifizieren
  - ***Excel-Datei***
- Datensammlungsstrategie festlegen
- Qualität und Repräsentativität der Daten sicherstellen
- Datenaufnahme durchführen
- Datensammlung überprüfen

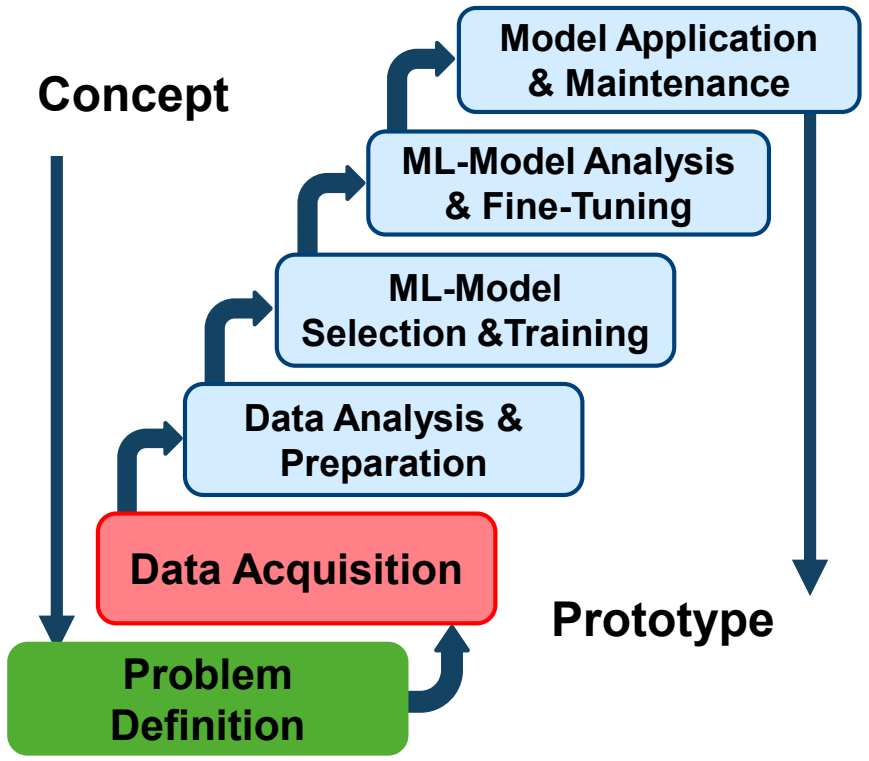

KI-Systeme benötigen Daten, um zu lernen. Die Sammlung von qualitativ hochwertigen, relevanten und vielfältigen Daten ist entscheidend für die Entwicklung einer effektiven KI.

class	drive	transmission	engine_index	engine_cylinders	engine_displacement	fuel_type	city_mpg_ft1	highway_mpg_ft1
Special Purpose Vehicle 2WD	2-Wheel Drive	Automatic 3-Speed	1830	4	2,5	Regular	18	17
Special Purpose Vehicle 2WD	2-Wheel Drive	Automatic 3-Speed	1880	4	2,5	Regular	18	17
Special Purpose Vehicle 2WD	2-Wheel Drive	Automatic 3-Speed	1831	6	4,2	Regular	13	13
Special Purpose Vehicle 2WD	2-Wheel Drive	Automatic 3-Speed	1881	6	4,2	Regular	13	13
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Automatic 3-Speed	1524	6	4,2	Regular	15	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Automatic 3-Speed	1574	6	4,2	Regular	15	19
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1405	4	2,5	Regular	19	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1504	6	4,2	Regular	16	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1455	4	2,5	Regular	19	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1554	6	4,2	Regular	15	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 5-Speed	1420	4	2,5	Regular	19	23
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 5-Speed	1514	6	4,2	Regular	16	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 5-Speed	1564	6	4,2	Regular	16	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Automatic 3-Speed	1430	4	2,5	Regular	17	21
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Automatic 3-Speed	1524	6	4,2	Regular	16	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Automatic 3-Speed	1480	4	2,5	Regular	17	21
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Automatic 3-Speed	1574	6	4,2	Regular	15	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1405	4	2,5	Regular	19	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1504	6	4,2	Regular	16	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1455	4	2,5	Regular	19	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 4-Speed	1554	6	4,2	Regular	15	20
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 5-Speed	1420	4	2,5	Regular	19	23
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 5-Speed	1514	6	4,2	Regular	16	22
Special Purpose Vehicle 4WD	4-Wheel or All-Wheel Drive	Manual 5-Speed	1564	6	4,2	Regular	16	22
Large Cars	2-Wheel Drive	Automatic 4-Speed	4440	6	4,1	Regular	14	19
Large Cars	2-Wheel Drive	Automatic 4-Speed	4333	8	5	Regular	14	20
Large Cars	2-Wheel Drive	Automatic 4-Speed	4351	8	5,7	Diesel	18	26
Large Cars	Rear-Wheel Drive	Automatic 4-Speed	4601	8	4,1	Regular	14	19
Large Cars	Rear-Wheel Drive	Automatic 4-Speed	4351	8	5,7	Diesel	18	26
Large Cars	Rear-Wheel Drive	Automatic 4-Speed	4606	8	4,1	Regular	14	19
Large Cars	Rear-Wheel Drive	Automatic 4-Speed	4320	6	4,3	Diesel	21	31
Standard Pickup Trucks 2WD	2-Wheel Drive	Automatic 3-Speed	4850	6	4,1	Regular	14	17
Standard Pickup Trucks 2WD	2-Wheel Drive	Automatic 3-Speed	4862	8	5	Regular	13	16
Standard Pickup Trucks 2WD	2-Wheel Drive	Automatic 4-Speed	4853	6	4,1	Regular	15	19
Standard Pickup Trucks 2WD	2-Wheel Drive	Automatic 4-Speed	4862	8	5	Regular	14	18
Standard Pickup Trucks 2WD	2-Wheel Drive	Automatic 4-Speed	4880	8	6,2	Diesel	17	22

Datenanalyse & -vorbereitung

Fragestellungen, die es zu beantworten gilt:

- Wie liegen die Daten vor (Dateiformat, Datentyp, …)?
- Wie viele Daten sind vorhanden?
- Müssen die Daten bereinigt werden? Sind sie vollständig?
- Sind die Daten für die KI lesbar?
- Welche Vorbereitungsmaßnahmen sind notwendig?

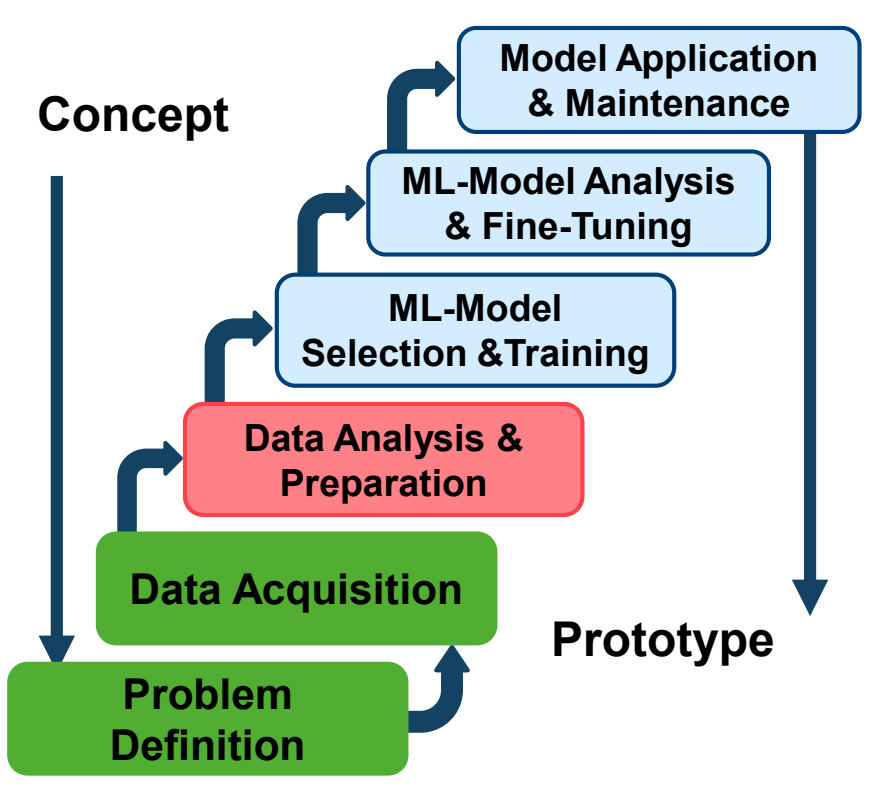

Die gesammelten Daten müssen analysiert, bereinigt und vorverarbeitet werden, um z.B. Ungenauigkeiten, Fehler und Irrelevanzen zu entfernen sowie ein tieferes Systemverständnis zu erlangen.

Modellauswahl und Training

Fragestellungen, die es zu beantworten gilt:

- Welcher Ansatz?
  - ***Unüberwachtes Lernen***
- Welches Modell in Abhängigkeit der Art
  - ➢ des Problems
    - ➢ ***Clustering***
  - ➢ der Daten (z.B. numerisch, Text, Bilder)?
    - ➢ ***Numerisch & kategorisch***
- Welche Einstellungsmöglichkeiten (Hyperparameter)?

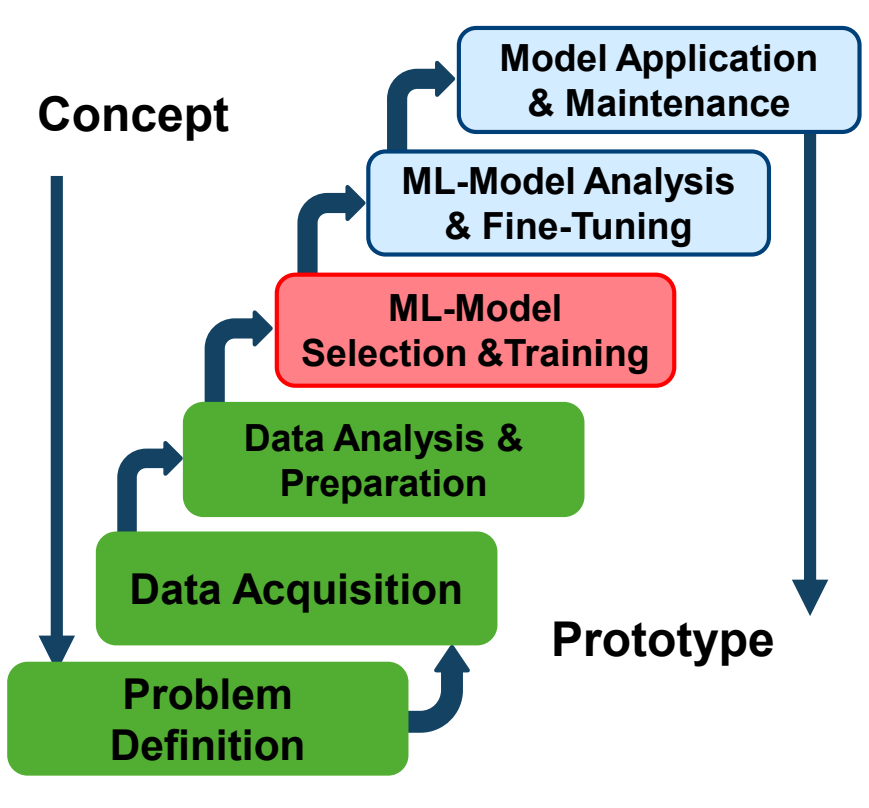

Basierend auf den Zielen und der Art der verfügbaren Daten werden die Architektur des Modells sowie die Hyperparameter gewählt.

Modelle zum Clustering

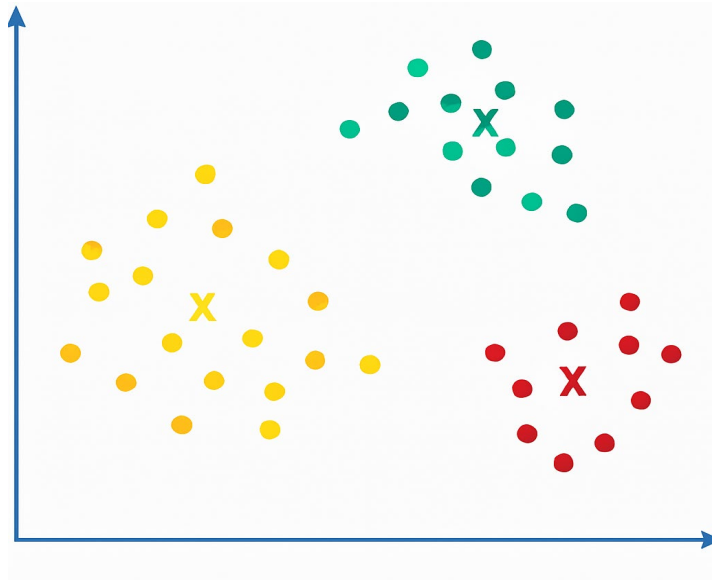

5)

k-Means

- Teilt numerische Daten in *k* Cluster
- Anzahl der Cluster *k* muss vorgegeben werden
- basierend auf minimalen euklidischen Abständen
- Werden nächstem Clusterzentrum zugeordnet (x)

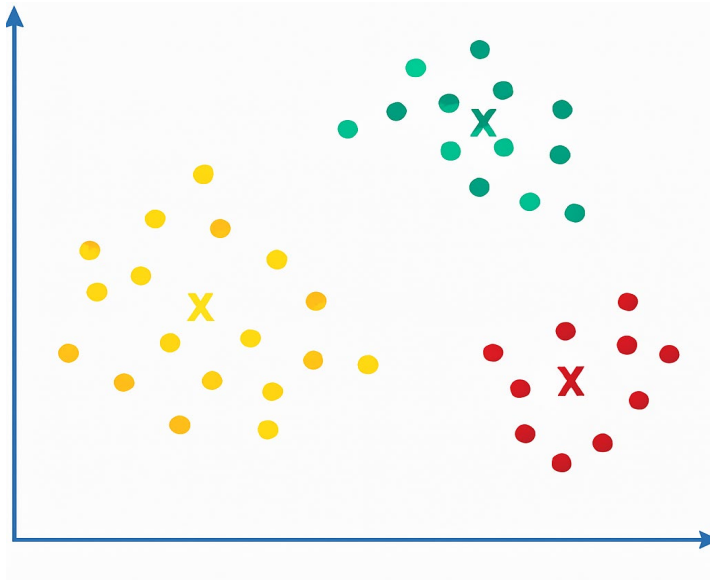

5)

k-Prototypes

- Erweiterung von k-Means für gemischte Daten
- Teilt numerische + kategorische Daten in *k* Cluster
- Kategorische Daten müssen in numerische Werte umgewandelt werden

5) DATAtab. *k-Means Clusteranalyse.* https://datatab.de/tutorial/k-means-clusteranalyse (abgerufen: 25.06.2025)

Warum verwenden wir diese Modelle?

k-Means

- Effizient bei großen Datensätzen
  - Skaliert gut bei vielen Datenpunkten
- Gute Funktionalität bei num. Daten
  - Gruppiert Daten anhand von Mittelwerten
- Einfacher Aufbau
  - Leichte Interpretierbarkeit
  - Oft in Praxis & Forschung verwendet

k-Prototypes

- Für gemischte Datentypen
  - Kombination aus k-Means (numerisch) & k-Modes (kategorisch)
  - Nutzt kombinierte Distanz (Summe)
- Einfache Erweiterung von k-Means
  - Modell muss nicht vollständig neu erstellt werden
- Praktikabilität
  - Ideal für „reale“ Datensätze mit Merkmalen wie:
    - Einkommen (Zahl)
    - Beruf (Kategorie)
    - Alter (Zahl)
    - Region (Kategorie)

Modellevaluation und Fine-Tuning

Fragestellungen, die es zu beantworten gilt:

- Welche Metriken zur Evaluation verwenden?
  - ➢ Bei unüberwachtem Lernen erfolgt die Bewertung über subjektive Interpretation
- Welche Möglichkeiten des Fein-Tunings existieren?
- Andere Modelltypen (Algorithmen) in Erwägung ziehen?

➢ **Training mit Trainingsdatensatz, Evaluation mit unabhängigen Testdatensatz!**

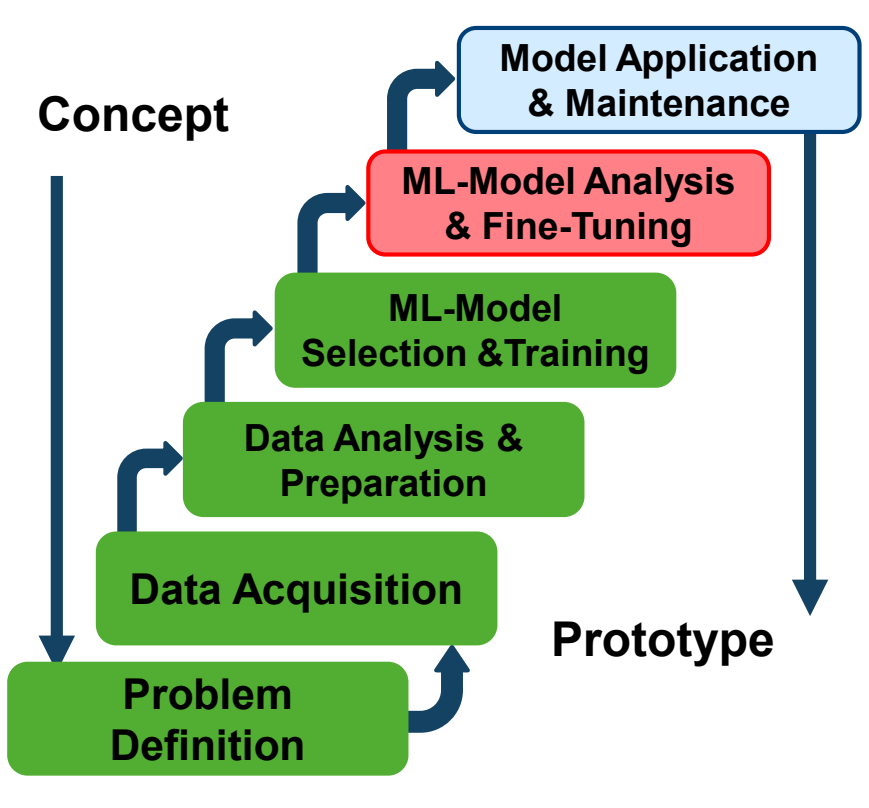

Nachdem das Modell trainiert wurde, muss es evaluiert werden, um seine Leistung zu überprüfen. Hierbei werden verschiedene Metriken verwendet, um die Genauigkeit, Relevanz und andere Aspekte zu bewerten.

Modelleinsatz und Wartung

Fragestellungen, die es zu beantworten gilt:

- Wo muss das Modell integriert werden?
- Welche Schnittstellen existieren zu anderen Systemen?
- Echtzeit-Fähigkeit notwendig?
- kontinuierliches Monitoring der KI
- Feedbackmöglichkeiten umsetzen
- regelmäßige Aktualisierung des Modells durchführen
- weiteres Sammeln von Daten

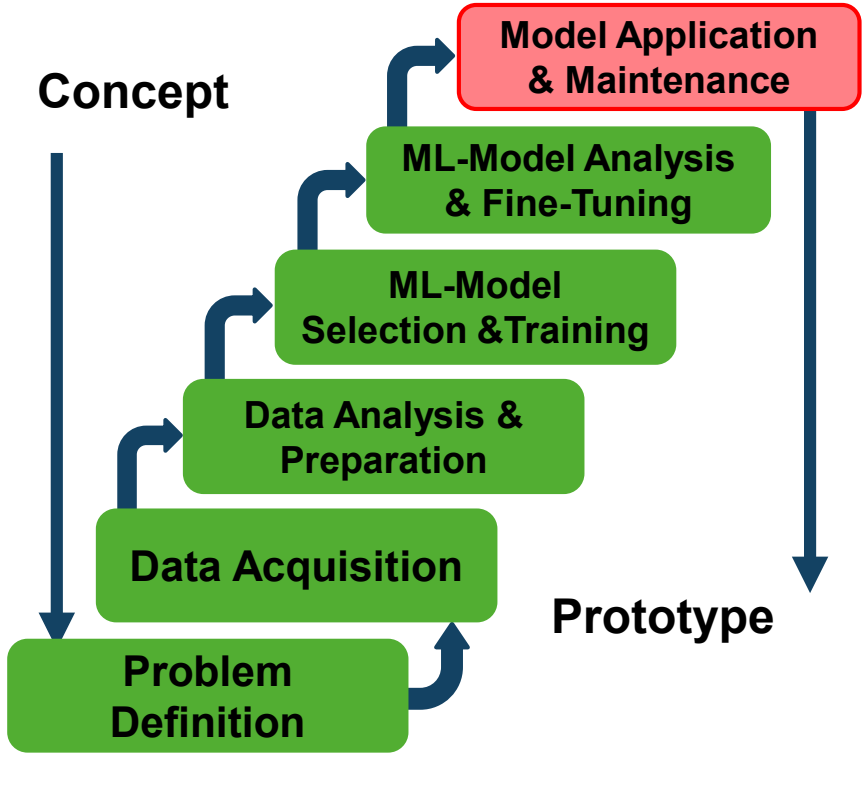

Sammeln Sie Feedback von Nutzern und anderen Stakeholdern, um das KI-System fortlaufend zu verbessern und zu erweitern.

Reflektion

Ergebnisse & Erkenntnisse

Quelle: geralt auf pixabay.com

Was sind die Ergebnisse?

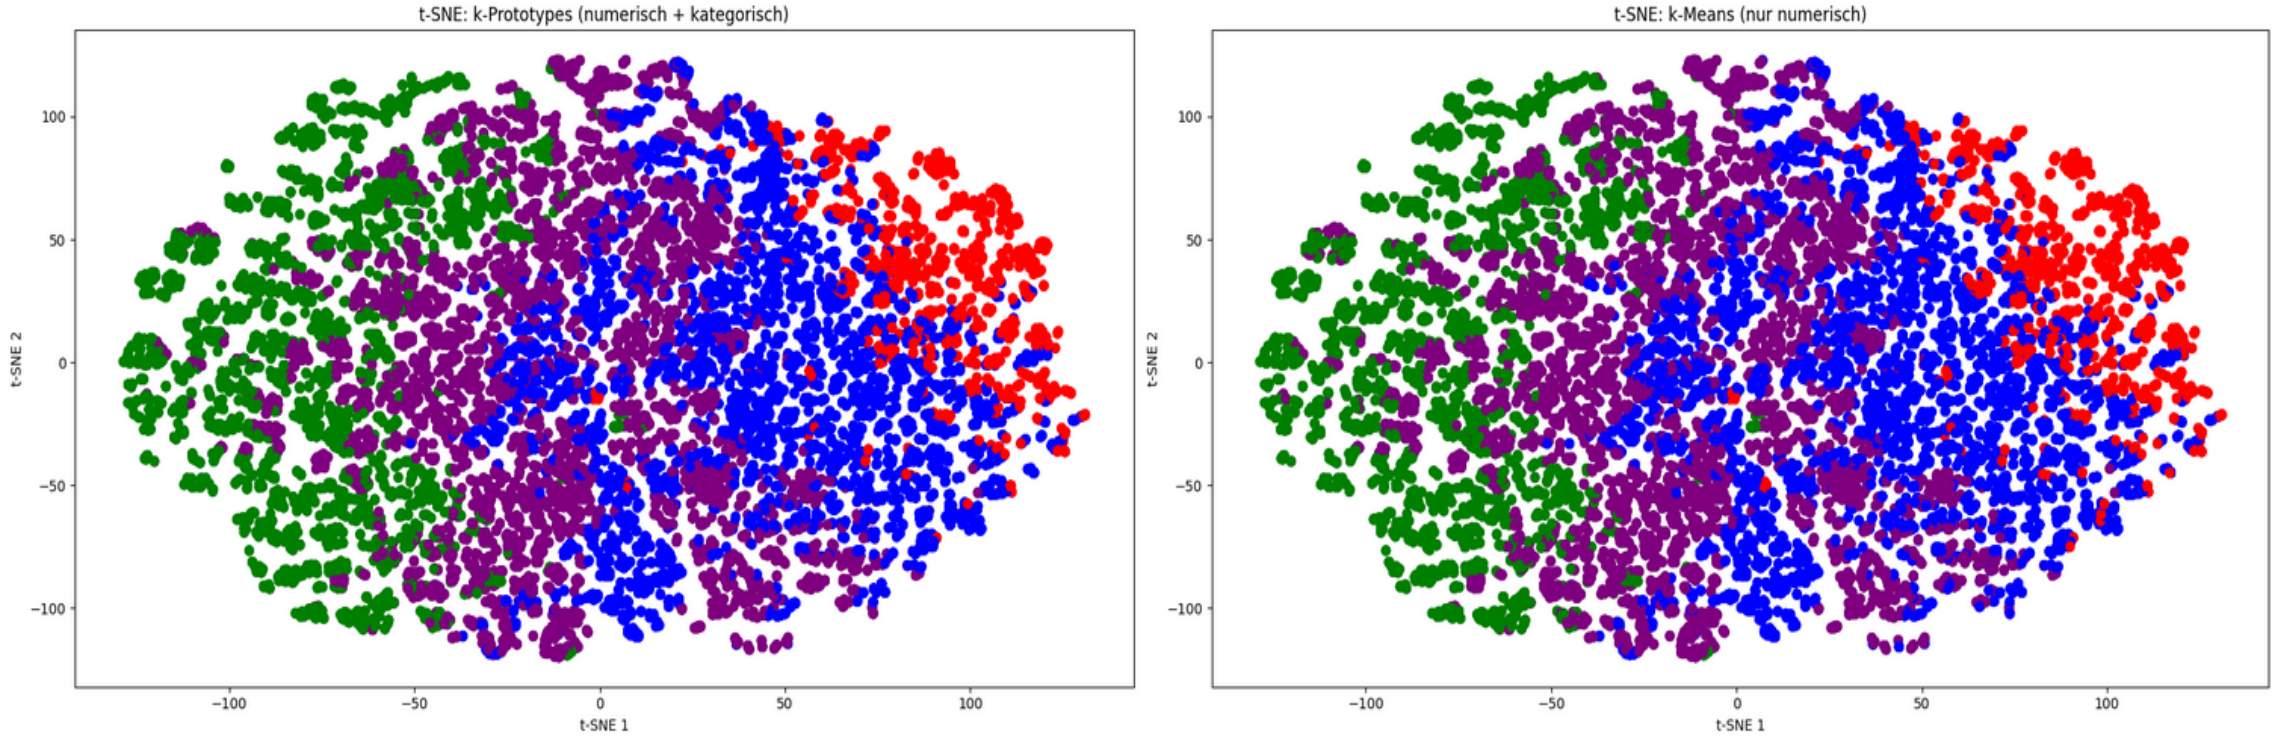

Beide Diagramme sind von Form & Aufteilung sehr identisch

- ➢ Kategorische Variablen haben keinen bedeutenden Einfluss auf die Gruppierung

Zusammenfassung, Feedback und Abschluss

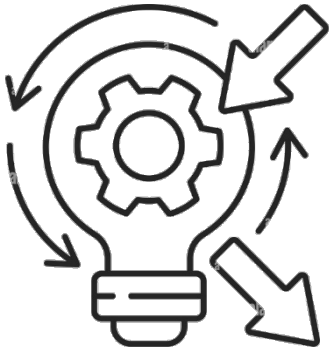

Quelle: geralt auf pixabay.com

Reflektion

Feedback für die zukünftige Ausrichtung des Arbeitskreises

- *Welche neuen Erfahrungen und Erkenntnisse haben Sie heute gewonnen?*
- *Hat das Konzept die Inhalte gut vermittelt?*
- *War die Menge an Informationen gut aufnehmbar?*
- *Gibt es Verbesserungsvorschläge?*
- *Welche neuen Themenideen haben Sie durch den heutigen Termin?*
- *Gibt es noch offene Fragen oder Gedanken zum Thema?*
- *Möchten Sie diese Thematik noch weiter vertiefen?*
- *Haben Sie ergänzende Themenvorschläge, die noch behandelt werden sollen?*
- *… ?*

Um die Inhalte möglichst gut zu vermitteln, sind wir auf Ihr Feedback angewiesen. Helfen Sie uns dabei den Lernprozess maximal ideal zu gestalten und lassen Sie ihre Ideen miteinfließen.

Vielen Dank für Ihre Teilnahme.

Wir freuen uns auf ein baldiges Wiedersehen.

Gefördert durch:
Bundesministerium für Wirtschaft und Klimaschutz
aufgrund eines Beschlusses des Deutschen Bundestages

TrendAuto 2030plus

Technology Arts Sciences TH Köln
CAD CAM CENTER COLOGNE

Literatur

[1] Fröchte. Maschinelles Lernen – Grundlagen und Algorithmen. München. 2021.

[2] T. Mitchell. Machine Learning. New York City. 1997.

[3] Gerón. Praxiseinstieg Machine Learning. Heidelberg. 2020.

[4] Wirth et Al. Maschinelles Lernen – CRISP-DM: Towards a Standard Process Model for Data Mining. Ulm. 2000.

[5] DATAtab. K-Means Clusteranalyse. Online. Abgerufen am: 25.06.2025

Ihre Ansprechpartner

Dr. Marcus Irmer

CAD CAM Center Cologne (4C)
Technische Hochschule Köln
Betzdorfer Straße 2
Mobil: +49 (0) 1573 4466530
Mail: marcus.irmer@th-koeln.de

Prof. Dr. Margot Ruschitzka

CAD CAM Center Cologne (4C)
Technische Hochschule Köln
Betzdorfer Straße 2
Mail: margot.ruschitzka@th-koeln.de

Gibt es ergänzende

Fragen?