

Lisa Friederes

KI & Design

Die Zusammenarbeit von KI und Mensch
zur Förderung der Kreativität

Zusammenfassung

Künstliche Intelligenz gilt heute als zentraler Treiber der Digitalisierung und stellt nicht nur die Gesellschaft und Wirtschaft auf den Kopf, sondern auch die Kreativbranche. In der Folge entwickeln sich die Rollen der Designer*innen ständig weiter und eine kollaborative Beziehung zwischen Mensch und Maschine scheint immer notwendiger zu werden. Steht die Kreativwirtschaft gewissermaßen vor einer kreativen Revolution? Beginnt eine neue Ära, in der Technologien den Menschen nicht bloß technisch unterstützen, sondern mit ihnen vielmehr eine Zusammenarbeit eingehen. Und was geschieht mit der Kreativität? Geht sie verloren, wird sie gesteigert, wird sie vielleicht blockiert oder entfaltet sie sich sogar noch mehr durch das Zusammenwirken von menschlichen und maschinellen Kräften? Funktionieren beide überhaupt zusammen?

Die vorliegende Arbeit widmet sich der Fragestellung, ob und inwieweit KI selbstständigen Designer*innen dabei helfen kann, kreativer zu sein. Sie setzt sich damit auseinander, wie das maximale Potential der Kreativität durch eine Mensch-Maschine-Kollaboration ausgeschöpft werden, wie solch eine Zusammenarbeit aussehen und welche Bedeutung dieser beigemessen werden kann. Mittels der Kreativitätstechnik Brainstorming und unter Zugrundelegung und genauer Analyse von vier Experteninterviews soll dieses Ziel erreicht werden. Aus den daraus entstandenen Erkenntnissen wird abschließend ein Konzept vorgeschlagen, wie KI den Menschen bei der Logogestaltung mit datenbasiertem Output unterstützen könnte. Konkret besteht dieser Vorschlag darin, dass nach der Eingabe von objektiven und subjektiven Attributen einer Firma, die KI einen Output generiert, der besagt, mit welcher Wahrscheinlichkeit das zukünftige Logo hell oder dunkel, die Schrift mit oder ohne Serifen ist, oder ob es sich eher um eine Wort-Bild-Marke oder um eine Wortmarke handelt.

Danke an Menschen

An dieser Stelle möchte ich all jenen danken, die mich während der Arbeit an der vorliegenden Masterthesis begleitet haben. Besonderer Dank gilt meiner Familie, Freunden und Mitstudierenden, durch deren Anregungen meine Arbeit kontinuierlich verbessert wurde und die eine große moralische Unterstützung in der Zeit der Erstellung der Arbeit waren. Darüber hinaus möchte ich mich bei meinen Betreuern und den befragten Experten bedanken, die durch ihre fachliche Unterstützung viel zur Vollendung meiner Arbeit beigetragen haben. Mein Dank gilt weiterhin Waltraud Schauer und Anette Kappes, die mir bei der Endredaktion des Skriptes behilflich waren. Am meisten danken möchte ich meinem Freund Jemp Keup, der mir zum einen durch seine wissenschaftlichen Kompetenzen und seinen Programmierfähigkeiten eine große Hilfe und Stütze war und mir zum anderen mit seinen eher schlechten Witzen, seiner fürsorglichen und verständnisvollen Art die Zeit versüßte.

Danke an KI

Ich bedanke mich recht herzlich bei Google Scholar und beim Karlsruher Virtueller Katalog für die äußerst zielführenden und gewinnbringenden Resultate. Mein Dank gilt zudem auch den Machine-Learning-Algorithmen von Spotify und Netflix, deren persönliche Empfehlungen mir ermöglichten, dass ich abends gut abschalten konnte.

Inhaltsverzeichnis

1 Einleitung	001		6 Experteninterviews	054
1.1 Motivation und Ziel der Arbeit	002			
1.2 Aufbau der Arbeit	004			
2 Künstliche Intelligenz	006		7 Ausarbeitung eines Konzeptes	058
2.1 Historischer Überblick	007		7.1 Beweggründe	058
2.2 Schwache vs. Starke KI	009		7.2 Konzeptvorstellung	059
2.3 Formen von KI	010		7.3 Potentieller Aufbau der Software	060
2.3.1 Maschinelles Lernen	010		7.4 Vereinfachte Umsetzung	062
2.3.2 Überwachtes Lernen	012		7.4.1 Software und Hardware	062
2.3.3 Unüberwachtes Lernen	012		7.4.2 Datenerhebung	062
2.3.4 Verstärktes Lernen	012		7.4.3 Preprocessing	064
2.3.5 Künstliche Neuronale Netze	013		7.4.4 Training & Validierung	067
2.4 Stufenmodell der Automation des Entscheidens	015		7.4.5 Vorhersage (Prediction)	070
2.5 Bereitschaft der Gesellschaft für KI	018		7.5 Bewertung des Konzeptes	071
2.6 VUCA vs. BANI	020			
3 Designprozess	024		8 Diskussion und Ausblick	072
3.1 Kreativität	024		8.1 Menschliche und maschinelle Kreativität	072
3.2 Beschreibung des Designprozesses	026		8.2 Wicked problems und das Treffen von Entscheidungen	073
3.3 Kreativitätstechniken	031		8.3 Mensch-Maschine-Kollaboration	074
4 KI im Designprozess	034		8.4 Ausblick	075
4.1 Künstliche Kreativität	034		Register	078
4.2 Aktuelle Beispiele für Künstliche Kreativität	035		Literaturverzeichnis	078
4.2.1 Mobius Vision	035		Internetverzeichnis	085
4.2.2 The Next Rembrandt	036		Interviewverzeichnis	089
4.2.3 KI-Muse	037		Eidesstattliche Erklärung	090
4.2.4 Avocado Chair	037			
4.2.5 A.I. Chair	038			
4.3 Generatives Design	039			
4.4 Ideenfindung mit KI	042			
5 Brainstorming als Anwendungsfall	044			
5.1 Bedeutung des Brainstormings	044			
5.1.1 Definition des herkömmlichen Brainstormings	044			
5.1.2 Varianten des Brainstormings	045			
5.2 Grenzen des Brainstormings in Gruppen	047			
5.3 Erweiterungen des Brainstormings und Chancen der KI	048			

Abkürzungsverzeichnis

CV	Computer Vision
DL	Deep Learning
DT	Design Thinking
EBS	Elektronisches Brainstorming
GAN	Generative Adversarial Networks
GD	Generative Design
HITL	Human-in-the-loop
KI	Künstliche Intelligenz
KK	Künstliche Kreativität
KNN	Künstliche Neuronale Netze
KPI	Key Performance Indicator
MI	Multiple Intelligences
ML	Maschinelles Lernen
MLP	Multi-Layer Perception Classifier
NGT	Nominal Group Technique
NLP	Natural Language Processing
TAM	Technology Acceptance Model

Abbildungsverzeichnis

Abb. 1: Entwicklungsphasen der KI, S. 8. Quelle: In Anlehnung an Bitkom, 2017, S. 29.
Abb. 2: Traditionelle Programme vs. Maschinelles Lernen, S. 11. Quelle: In Anlehnung an De-Yu (2021, 13. Mai). What is the difference between Traditional Programming and Machine Learning? Medium. Abgerufen am 2. Januar 2022, von https://medium.com/mlearning-ai/what-is-the-difference-between-traditional-programming-and-machine-learning-f6128ed4f595
Abb. 3: ThisPersonDoesNotExist, S. 14. Quelle: ThisPersonDoesNotExist. Abgerufen am 16. Dezember 2021, von https://thispersondoesnotexist.com/
Abb. 4: Kognitive Stärken des Menschen vs. Kognitive Stärken der Maschine, S. 15. Quelle: In Anlehnung an Bitkom, 2017, S. 61.
Abb. 5: Fünf-Stufen-Modell der Automation des Entscheidens, S. 16. Quelle: In Anlehnung an Buxmann et al., 2018, S. 368.
Abb. 6: Technology Acceptance Model, S. 19. Quelle: In Anlehnung an Kreutzer (2021, 1. Dezember). Auf welche Akzeptanz stößt der KI-Einsatz in Deutschland? Abgerufen am 9. Dezember 2021, von https://www.bitkom-akademie.de/news/auf-welche-akzeptanz-stoesst-der-ki-einsatz-deutschland

Abb. 7: VUCA vs. BANI, S. 22.

Quelle: In Anlehnung an Grabmeier (18. Juni 2020). BANI vs. VUCA. Abgerufen am 30. Dezember 2021, von <https://stephangrabmeier.de/bani-vs-vuca/>

Abb. 8: BANI-Komponente und Reaktionen, S. 23.

Quelle: In Anlehnung an Grabmeier (18. Juni 2020). BANI vs. VUCA. Abgerufen am 30. Dezember 2021, von <https://stephangrabmeier.de/bani-vs-vuca/>

Abb. 9: Der kreative Sprung, S. 25.

Quelle: In Anlehnung an Edward de Bono Foundation (o. D.). Lateral Thinking. Abgerufen am 9. Dezember 2021, von <http://www.edwarddebonofoundation.com/Creative-Thinking-Techniques/Lateral-Thinking.html>

Abb. 10: Anfangszustand und Zielzustand, S. 26.

Quelle: In Anlehnung an Brown, 2011, S. 10.

Abb. 11: Eröffnung, Erkundung und Abschluss, S. 27.

Quelle: In Anlehnung an Brown, 2011, S. 13.

Abb. 12: Gruppierung der Kreativitätstechniken, S. 32.

Quelle: In Anlehnung an Geschka & Lantelme, 2005, S. 296.

Abb. 13: The Next Rembrandt, S. 36.

Quelle: Microsoft (2016, 13. April). The Next Rembrandt. Abgerufen am 9. Dezember 2021, von <https://news.microsoft.com/europe/features/next-rembrandt/>

Abb. 14: Avocado Chair, S. 37.

Quelle: OpenAi (2021, 5. Januar). DALL-E: Creating Images from Text. Abgerufen am 9. Dezember 2021, von <https://openai.com/blog/dall-e/>

Abb. 15: A.I. Chair, S. 38.

Quelle: Pechmann A. (2020, 19. April). Philippe Starck – Von der Entstehung des A.I. Chair. Abgerufen am 10. Dezember 2021, von <https://designbote.com/philippe-starck-von-der-entstehung-des-a-i-chair/>

Abb. 16: Concept IAA, S. 40.

Quelle : Designtagebuch (2018, 16. Juli). Generatives Design – Co-Kreation dank künstlicher Intelligenz. Abgerufen am 9. Dezember 2021, von <https://www.designtagebuch.de/generatives-design-co-kreation-dank-kuenstlicher-intelligenz/>

Abb. 17: MIT Media Lab Logo, S. 41.

Quelle: Logolounge (2011, 10. März). One Logo, 40000 permutations. Abgerufen am 9. Dezember 2021, von <https://www.logolounge.com/articles/one-logo-40000-permutations>

Abb. 18: KI im Design Thinking Prozess, S. 43.

Quelle: In Anlehnung an Cautela et al., 2019, S. 125.

Abb. 19: brAInstorm, S. 51.

Quelle: In Anlehnung an Robra-Bissantz et al., 2017, S. 3.

Abb. 20: Ranking der Unternehmen mit der besten Nachhaltigkeitsberichterstattung nach ihrem CSR-Reporting im Jahr 2018, S. 63.

Quelle: Institut für ökologische Wirtschaftsforschung GmbH & future e.V. (Statista) (2019, September). Ranking der Unternehmen mit der besten Nachhaltigkeitsberichterstattung nach ihrem CSR-Reporting im Jahr 2018. Abgerufen am 9. Dezember 2021, von <https://de.statista.com/statistik/daten/studie/1094914/umfrage/ranking-der-unternehmen-mit-der-groessten-nachhaltigkeit-nach-dem-csr-reporting-ranking/>

Abb. 21: Ungleiche Verteilung der Rohdaten, S. 65.

Quelle: Eigene Darstellung.

Abb. 22: Vor und nach dem Preprocessing, S. 66.

Quelle: Eigene Darstellung.

Abb. 23: Ergebnisse der Modelle, S. 68.

Quelle: Eigene Darstellung.

Abb. 24: Pipeline für MLPClassifier, S. 69.

Quelle: Eigene Darstellung.

Abb. 25: Prediction, S. 70.

Quelle: Eigene Darstellung.

Abb. 26: Attribute des zukünftigen Logos, S. 70.

Quelle: Eigene Darstellung.

1 Einleitung

Unsere Gesellschaft befindet sich in einem Zeitalter, in dem künstliche Intelligenz (KI), maschinelles Lernen (ML), Deep Learning (DL), Big Data und viele andere Technologien ständig an Relevanz zunehmen (vgl. Carvalhais & Cerejo, 2019). KI ist das „Buzzword“ von heute. Als zentraler Treiber der Digitalisierung stellt künstliche Intelligenz nicht nur die Gesellschaft und Wirtschaft auf den Kopf, sondern auch nahezu alle anderen Bereiche (vgl. Hecker & Paaß, 2020).

Unzählige traditionelle Unternehmen fühlen sich durch die rasante Entwicklung der Digitalisierung bedroht, da sie mit disruptiven Innovationen anderer Firmen in Konkurrenz stehen. Aufgrund der meist eher kleineren Unternehmensgröße gelingt es ihnen nur beschränkt, sich anzupassen und unter den neuen Innovationskräften mitzuhalten. Andererseits kann dieser Aufbruch aber auch als Chance gesehen werden, um existierende Geschäftsmodelle umzudenken, zu transformieren oder sogar komplett neue zu entwickeln (vgl. Buxmann et al., 2018).

Auch im Design macht sich dieser Prozess bemerkbar. Dies führt unweigerlich zu der Frage nach dem Impact auf den Faktor Kreativität, da dieser dem gleichen rasanten Wandel unterworfen ist. Diese Entwicklung stößt dabei keineswegs bloß auf Zustimmung, denn wie so oft in der Vergangenheit, können Veränderungen Ängste bei den Betroffenen auslösen, was wiederum zu Ablehnung führen kann. Man erinnere sich etwa an die Zeit, als die Fotografie noch in den Kinderschuh steckte; so störten sich erstmals viele an dieser neuen Technik, da es doch eigentlich die Künstler*innen waren, die realistische Bilder schufen. Heutzutage hingegen ist eine Welt ohne Fotos kaum noch vorstellbar (vgl. Katzlerberger, 2021).

Der KI-Hype hat also die Bildung von zwei Fronten ausgelöst. Einige begreifen dem ständigen Fortschritt von KI mit Euphorie und sehen eine Superintelligenz in ihm. Bei anderen hingegen löst KI Bedenken und Unsicherheit aus. Zurecht? (vgl. Schuldt, o. D.)

Dem entgegen steht die Ansicht von Wittpahl (2019, S. 266), der besagt „wo etwas Neues entsteht, [...] etwas Altes weichen“ müsse, dass also „Kreativität und Innovation geradezu per Definition mit Verdrängung verbunden sind“. Die Rollen der Designer*innen entwickeln sich ständig weiter, wobei die zu berücksichtigenden Berührungspunkte immer mehr an Komplexität gewinnen (vgl. Carvalhais & Cerejo, 2019). Wie wird sich nun die Funktion der Designer*innen mit der ständigen Weiterentwicklung von KI verändern? Steht die Kreativwirtschaft sozusagen vor einer kreativen Revolution? Eine neue Ära, in der Technologien den Menschen nicht bloß technisch unterstützen, sondern mit ihnen vielmehr eine Zusammenarbeit eingehen? Wird die KI dem Menschen als Inspirationsquelle dienen? (vgl. Katzlerberger, 2021) Und wie steht es dabei um die Kreativität? Geht sie verloren, wird sie gesteigert, wird sie vielleicht blockiert oder entfaltet sie sich sogar noch mehr durch das Zusammenwirken von menschlichen und maschinellen Kräften? Funktionieren beide überhaupt zusammen?

1.1 Motivation und Ziel der Arbeit

Mit der Digitalisierung hat sich der Alltag der Designer*innen bereits stark verändert. Mithilfe des Internets und einem großen Angebot an qualitativer Software kann heute viel schneller und effizienter gearbeitet werden als jemals zuvor. KI treibt diesen digitalen Wandel durch selbstlernende Systeme noch stärker an und verändert gar die Beziehung zwischen Mensch und Maschine (vgl. Schuldt, o. D.). Der Einsatz von Maschinen gibt den Menschen stets die Hoffnung, dass diese Systeme sie von unangenehmer und anstrengender Arbeit entlasten.

Diese Ansicht wird zusätzlich durch die Tatsache verstärkt, dass die KI in einigen Bereichen einfach viel schneller und präziser arbeitet und folglich die besseren Ergebnisse liefert, die dem Menschen so nicht möglich wären. Dies hätte eventuell den Vorteil, dass Menschen für kreative und sinnstiftende Tätigkeiten freigestellt werden könnten. Im Widerspruch dazu, könnte die Folge aber auch sein, dass Menschen auf diese Weise von Maschinen verdrängt werden. Die ständige Weiterentwicklung der Technologien bestätigt zum einen diese Hoffnungen, lässt zum anderen aber auch Ängste entstehen, dass KI in der Lage ist, komplexe Arbeiten auszuführen, ohne zwangsweise auf die menschliche Überwachung angewiesen zu sein (vgl. Misselhorn, 2019).

Überdies werfen diese Diskussionen die Frage nach der Rolle des Menschen auf, wenn die KI auch in Bereiche wie die Kreativität vordringt, die eigentlich seit jeher nur dem Menschen zugeordnet waren. Ist KI dazu fähig, allein Ideen zu generieren? Oder braucht sie letztendlich doch die Unterstützung eines Menschen? Können Kreative ggf. von der KI profitieren, um die eigene Kreativität zu fördern? Es stellt sich damit die Frage, inwiefern sich die Arbeit der Kreativen mit der voranschreitenden Entwicklung dieser Technik verändert?

Das Ziel der vorliegenden Arbeit ist, herauszufinden, ob und inwieweit KI selbstständigen Designer*innen dabei helfen kann, kreativer zu sein. Sie setzt sich damit auseinander, wie das maximale Potential der Kreativität durch eine Mensch-Maschine-Kollaboration ausgeschöpft werden, wie solch eine Zusammenarbeit aussehen und welche Bedeutung dieser beigemessen werden kann. Diese Fragestellungen werden mittels der Umsetzung eines eigenen Konzepts am Ende der Arbeit untermauert und thematisiert.

1.2 Aufbau der Arbeit

Der erste Teil widmet sich der Erläuterung beziehungsweise Definition einiger relevanter Begrifflichkeiten rund um das Gebiet der KI und des Designprozesses. Um dem Umfang dieser Arbeit gerecht werden zu können, wird der mathematische Teil der KI weggelassen und der Designbegriff auf eine exemplarische Modellierung des Designprozesses beschränkt.

Weiterhin werden verschiedene Varianten des Brainstormings, einer zentralen Kreativitätstechnik, die in vielen Designprozessen am Anfang eingesetzt wird, anhand bestehender Literatur analysiert, um herauszufinden, ob und inwiefern KI und Designer*innen kollaborieren und gemeinsam Ideen generieren können. Um bestehende Wissensstände zu vertiefen und neue Ansätze zu schaffen, werden anschließend vier qualitative Experteninterviews durchgeführt, unter anderem mit Kevin German, Norbert Schmitz, Wolfgang Henseler und Steffen Reichert.

Die Ergebnisse und Ansichten aus den Gesprächen werden zusammengefasst, um daraus ein neues Konzept auszuarbeiten. Die Arbeit wird mit einer Diskussion über die neu gewonnenen Erkenntnisse und einem daran anknüpfenden Ausblick abgeschlossen.

2 Künstliche Intelligenz

Unter dem Begriff der Künstlichen Intelligenz (eng. „Artificial Intelligence“ (AI)) versteht man Maschinen, die sich verhalten, als würden sie über eine Art menschliche Intelligenz verfügen (vgl. McCarthy et al., 2006). Obschon das Thema KI die Menschen seit Jahrzehnten beschäftigt, gibt es bis heute noch keine einheitliche Definition. Um ein besseres Verständnis zu bekommen, wird zuerst der Wortteil „Intelligenz“ genauer analysiert. Intelligenz beschreibt dabei meistens eine „allgemeine Fähigkeit zum Denken oder Problemlösen in Situationen, die für das Individuum neuartig“ sind (Perleth, 2008, S. 15). Der Begriff lässt sich z.B. nach Howard Gardners Multiple-Intelligenzen (MI) Theorie in sieben Formen unterteilen:

1. Visuell-räumliche Intelligenz: Fähigkeit, sich visuell-räumliche Darstellungen vorzustellen und umzuwandeln (z.B. Architekt*innen und Ingenieur*innen)
2. Körperlich-kinästhetische Intelligenz: körperliche Fähigkeit (z.B. Sporttreibende und Tänzer*innen)
3. Musikalische Intelligenz: musikalische Kompetenz (z.B. Komponierende und Interpret*innen)
4. Sozial-interpersonale Intelligenz: Fähigkeit, welche für eine erfolgreiche Interaktion mit anderen Menschen erforderlich ist (z.B. in der Politik Tätige)
5. Sozial-intrapersonale Intelligenz: Zugang zu den eigenen Gefühlen und Wünschen (Selbsterkenntnis)
6. Sprachliche Intelligenz: sprachliche Kompetenz (z.B. Literaturschaffende und Referierende)
7. Logisch-mathematische Intelligenz: Kompetenz, hohes Maß an Problemlösungsfähigkeit (z.B. Forschende) (vgl. Rost, 2008)

Etwas später erweiterte Gardner die sieben Formen des MI durch zwei weitere: die naturalistische und die existentielle Intelligenz. Bei der naturalistischen handelt es sich um die Fähigkeit, Naturphänomene voneinander zu unterscheiden und zu kategorisieren. Überdies gehört das Erkennen von Naturgesetzen zu dieser Form von Intelligenz, was wiederum wichtig für Berufe, die z.B. in der Forst- und Landwirtschaft tätig sind, ist.

Die existentielle Intelligenz bezieht sich auf die Übereinstimmung mit dem Kosmos. In der Zwischenzeit sind auch noch weitere Formen, wie die spirituelle und moralische Intelligenz, angedacht worden. Diese wurden aber letztlich nicht als eigenständige Intelligenzformen in die MI-Theorie integriert (vgl. Rost, 2008).

Um intelligentes Verhalten zu definieren, ohne dass auf jedes einzelne Kriterium der Intelligenz eingegangen werden muss, wird in der KI oft der Mensch als Maßstab genommen. Dabei geht es nicht darum, ein kognitives Problem zu lösen, sondern darum auf welche Art und Weise ein Mensch dies individuell tut (vgl. Misselhorn, 2018).


2.1 Historischer Überblick

Um sich ein genaueres Bild über das Thema KI zu machen, wird im Folgenden ein historischer Überblick vorgenommen. Dabei wird nicht auf historische Theorien über künstliche Menschen (wie z.B. Homunkulus) eingegangen, die erstmals im Spätmittelalter auftauchten. Dieser Teil beschränkt sich auf den technischen Aspekt der künstlichen Intelligenz.

Als in den 50er-Jahren die ersten programmierbaren Computer entwickelt wurden, machten sich Forschende Gedanken dazu, wie man diesen Maschinen intelligentes Verhalten beibringen könnte (vgl. Hecker & Paaß, 2020). Im Zuge dessen entwickelte der britische Logiker Alan Turing den Turing-Test (von ihm selbst genannt: Imitation Game) als Gedankenexperiment, das die philosophische Frage „Kann eine Maschine denken?“

beantworten sollte. Ein Computer besteht diesen Test, wenn eine menschliche befragte Person, nachdem sie einige schriftliche Fragen gestellt hat, nicht erkennen kann, ob die schriftlichen Antworten von einem Menschen oder einem Computer stammen (vgl. Norvig & Russel, 2021).

Es handelt sich hierbei zwar erst noch um einen theoretischen Ansatz, der aber bereits den Wegbereiter für moderne KI darstellt. Als eigentliche Geburtsstunde der KI als akademisches Fachgebiet gilt jedoch die Dartmouth Conference 1956, in der das erste Mal der Begriff „Artificial Intelligence“ fiel (vgl. McCarthy et al., 2006). Seither ist die Entwicklung der KI sehr wechselhaft und von Höhen (KI-Hypes) und Tiefen (KI-Winter) gekennzeichnet. Diese Entwicklungsphasen sind in Abbildung 1 mit ihren technologischen Neuerungen in vier Phasen dargestellt und finden Anwendung in der Industrie sowie im Privaten (vgl. Bitkom e.V., 2017).



Die erste und zweite Phase bestanden grob darin, sehr viel Wissen direkt in die Maschine einzuprogrammieren. Ein Beispiel hierfür ist der Taschenrechner, der zwar intelligentes Verhalten mit seiner Rechen-Fähigkeit aufweist, gleichzeitig aber auch darauf beschränkt ist. Erst mit der dritten Phase löste Maschinelles Lernen über Massendaten den Durchbruch aus. Mittels automatischem Einsortieren in Gruppen (Clustern) gelingt es, Empfehlungen vom System generiert zu bekommen. Die vierte Phase, ungefähr ab dem Jahr 2010, zeichnet sich dadurch aus, dass KI-Systeme versuchen, Lernverfahren mit wissensbasierten Methoden zu kombinieren (vgl. Bitkom, 2017).

2.2 Schwache vs. Starke KI

Der Philosoph John Searle führte im Jahre 1980 die Unterscheidung zwischen einer schwachen und einer starken KI (eng. „Weak Artificial Intelligence“/ „Narrow Artificial Intelligence“ und „Strong Artificial Intelligence“) ein (vgl. Norvig & Russel, 2021).

Dabei bezeichnet eine schwache KI die Entwicklung von gezielten Algorithmen für bestimmte, abgegrenzte Problemstellungen. Diese Technologie ist heute technisch machbar und ist in vielen Softwarelösungen bereits integraler Bestandteil. Eine starke KI hingegen beschreibt „alle Ansätze, die versuchen, den Menschen bzw. die Vorgänge im Gehirn abzubilden und zu imitieren“. Oftmals werden die hierfür beiden nötigen Eigenschaften Bewusstsein und Empathie genannt. Die Lernfähigkeit stellt bei beiden Formen eine fundamentale Anforderung dar (Buxmann & Schmidt, 2021, S.7).

Bis heute existiert jedoch noch keine nachgewiesene Form der starken KI. Dafür müsste sie folgende Fähigkeiten besitzen:

- Logisches Denken
- Treffen von Entscheidungen bei Unsicherheit
- Planen
- Lernen
- Kommunikation in natürlicher Sprache (Schütze & Schlieter, 2019, S. 1091)

Demzufolge kann festgehalten werden, dass heutzutage KI-Lösungen immer der schwachen KI zugeschrieben sind (vgl. Buxmann & Schmidt, 2021). In der vorliegenden Arbeit wird bei der Verwendung des Begriffes KI ebenfalls ausschließlich die Rede von schwacher KI sein.

2.3 Formen von KI

Zur Vornahme einer Begriffseingrenzung der KI, liegt der Fokus im weiteren Verlauf der Arbeit nur auf dem Teilbereich Maschinelles Lernen (ML).

Die wichtigsten Handlungsmittel einer Intelligenz sind Denken und Lernen. Spezifisch bei den folgenden Formen, spielt das „Lernen“ eine essenzielle Rolle. Lernen wird definiert durch die Erzeugung neuer Funktionen zwischen den wahrgenommenen Kenntnissen über die Umwelt und bestimmten Handlungen. Beim Denken wird bereits bestehendes Wissen verknüpft, neues Wissen selbstständig generiert, jedoch ohne, dass die Umwelt befragt werden muss. Wenn Denken oft als deduktives Verfahren verstanden wird, handelt es sich beim Lernen um eine induktive Vorgehensweise. D.h. man erzeugt neues Wissen durch das Nachdenken (Deduktion) und generiert neuartiges Wissen durch die Reize der Umgebung (Induktion). Beim Deep Learning handelt es sich um ein solches induktives Lernen (vgl. Otte, 2021).

2.3.1 Maschinelles Lernen

ML verkörpert ein Teilgebiet der KI und gehört seit Jahrzehnten durch den rasanten technologischen Fortschritt zu den etabliertesten Forschungsgebieten (vgl. Buxmann et al., 2018). Die heutigen Errungenschaften in der KI werden zum Großteil dem ML zugeschrieben. Der Begriff beschreibt dabei eine Reihe von Methoden, die automatisch Muster in Datensätzen erkennen, um daraufbasierend zukünftige Vorhersagen zu treffen (vgl. Murphy, 2012). ML verleiht den Computern somit die Fähigkeit zu lernen, ohne explizit dafür programmiert zu werden (vgl. Samuel, 1959).




Abbildung 2: Traditionelle Programme vs. Maschinelles Lernen.

Abbildung 2 zeigt den Unterschied zwischen traditionellen Programmen und ML. Bei letzterem besteht die Eingabe für die Maschine aus Eingabe-Daten und den dazu passenden Vorhersagen (Output), woraus ein Programm (in diesem Kontext auch Modell bezeichnet) entwickelt wird, welches sowohl für bereits bekannte Eingabe-Daten, als auch für noch nicht gesehene Eingaben möglichst gute Vorhersagen treffen kann. Hierzu versucht die Maschine mittels festgelegter Algorithmen Strukturen und Muster in Daten zu erkennen und sie mit Vorhersagen in Verbindung zu setzen. Bei traditionellen Programmen hingegen ist der Input für die Maschine aus Daten und Programm zusammengesetzt, woraus der Output generiert wird. Das Programm beinhaltet dabei eine feste Abfolge, meist händisch von einem*iner Autor*in zusammengestellter Anweisungen, welche von der Maschine zu befolgen sind, um den Output berechnen zu können. Daher kann festgehalten werden, dass sich das maschinelle Lernen auf die Entwicklung allgemeiner Algorithmen zum Erlernen von Modellen aus Daten konzentriert, anstatt sich auf spezifische Anwendungsprobleme zu basieren (vgl. De-Yu, 2021).

Ein bekanntes Anwendungsfeld, das ML unterschwellig in unseren Alltag integriert, sind die sozialen Medien. Hier scannen ML-Algorithmen Benutzerprofile, identifizieren Verhaltensmuster und generieren auf diese Weise Interessen-basierte Anzeigen, Vorschläge von Freund*innen und Empfehlungen (vgl. Safar, 2020).

ML lässt sich in drei Kategorien unterteilen:

1. Überwachtes Lernen (eng. „Supervised Learning“)
2. Unüberwachtes Lernen (eng. „Unsupervised Learning“)
3. Verstärktes Lernen (eng. „Reinforcement Learning“) (Buxmann & Schmidt, 2021, S. 10)

2.3.2 Überwachtes Lernen

Beim Überwachten Lernen „enthalten die dem Algorithmus gelieferten Trainingsdaten die gewünschten Lösungen, genannt Labels“. Es handelt sich hierbei also um eine Klassifikation, mit welcher das System selbstständig versucht weiter zu lernen. Ein gutes Beispiel hierfür ist der Spamfilter: „Sie werden mit vielen Beispiel-E-Mails und deren Kategorie (Spam oder Ham) trainiert und müssen lernen, neue E-Mails zu klassifizieren“ (Géron, 2018, S. 8).

2.3.3 Unüberwachtes Lernen

Im Gegensatz dazu sind die Trainingsdaten beim Unüberwachten Lernen nicht gelabelt. Der Algorithmus versucht hierbei aus den Daten heraus Strukturen und Muster zu erkennen. Zu den wichtigsten Unüberwachten Lernalgorithmen gehören: Clustering, Visualisierung und Dimensionsreduktion sowie Lernen mit Assoziationsregeln (vgl. Géron, 2018). Unüberwachtes Lernen wird oft als Vorverarbeitung der Daten für Systeme des überwachten Lernens verwendet.

2.3.4 Verstärktes Lernen

Bei der dritten Kategorie des ML, dem Verstärkten Lernen, lernt das System kontinuierlich anhand von eigenen Erfahrungen und vom Erhalt einer Belohnung für richtige Ergebnisse. Wittpahl (2019,) vergleicht das Programm hierbei mit einem dressierten Tier, welches in einer Spielsituation für

den Sieg belohnt wird. Es soll also anhand der eigenen Erfahrungen und dessen Schlussfolgerungen versuchen, diese Belohnung zu maximieren, indem es das Vorgehen immer wieder optimiert.

Das bekannteste Beispiel, bei dem verstärktes Lernen eingesetzt wurde, ist AlphaGo Zero, die Weiterentwicklung von AlphaGo. Hierbei erlernte die KI das Spiel Go während einer Zeitspanne von drei Tagen, ohne es davor gekannt zu haben, und ist nun durchaus in der Lage, die weltbesten menschlichen Spieler*innen zu schlagen (vgl. Wittpahl, 2019). Dies beruht wiederum auf dem Erhalt von Feedback, woraus das System seinen Erfolg oder seine Erfolglosigkeit ableiten kann. Demnach wird das System nur nach einem erfolgreichen Durchlauf des Spieles belohnt (vgl. Wuttke, o. D.).

2.3.5 Künstliche Neuronale Netze

Der aktuelle KI-Hype ist auf das Deep Learning (DL) mit künstlichen neuronalen Netzen (KNN) (eng. „Artificial neural Network“ (ANN)) zurückzuführen. Diese Methode findet bei überwachtes, unüberwachtes als auch bei verstärktes Lernen Anwendung. DL bezieht sich dabei auf künstliche neuronale Netze, welche mehrere Schichten (eng. „Layer“) aufweisen. Jede Schicht lernt ein Konzept aus den Daten, auf dem die nachfolgenden Schichten dann wiederum aufbauen. Je höher die Anzahl der Ebenen, desto komplexer fallen diese Konzepte aus (vgl. Kelley et al., 2015).

Mit anderen Worten verkörpert DL das Lernen mit Algorithmen, welche im Grunde Netzstrukturen und Nervenzellen imitieren (vgl. Wittpahl, 2019). Hierbei handelt es sich um eine Klasse von Algorithmen, deren Funktionsweise das menschliche Gehirn nachzuahmen versucht. Es wird in der Industrie in vielen unterschiedlichen Feldern im Einsatz zum Lösen praktischer Aufgaben verwendet – ob bei Computer Vision (Bilder), bei Spracherkennung (engl. „Natural Language Processing (NLP)“) (Text) oder bei der automatischen Spracherkennung (Audio) (vgl. Trask, 2020).

Wichtig zu erwähnen ist, dass wenn im Bereich der KI von neuronalen Netzen die Rede ist, es sich nicht um eine genaue Darstellung der biologischen Verhältnisse handelt, sondern nur um eine abstrakte Modellierung.

Eine Erweiterung von KNN stellen Generative Adversarial Networks (GANs) dar. Diese Methode besteht primär darin, dass zwei Netzwerke gegeneinander antreten. Das Ursprungsnetz (der Generator), das eigentlich lernen soll, wird mit einem anderen Netz in Form eines Gegners konfrontiert. Dieses Gegnernetz (Diskriminator) ist so programmiert, dass es den Generator mit irreführenden Ergebnissen befeuert. Auf diese Weise wird das lernende Netz permanent mit neuen Daten konfrontiert, die versuchen, es an seine Grenzen zu bringen. Das Resultat eines solchen Kampfes ist zum einen, dass der Generator am Ende richtig gut wird, und selbst die Fähigkeit besitzt, mit schwierigen Eingabewerten zurecht zu kommen (vgl. Wittpahl, 2019). Zum anderen soll dabei auch ein guter Diskriminator entstehen – ein sogenanntes Nullsummenspiel. Ein bekanntes Beispiel der GAN-Methode zeigt die Webseite thispersondoesnotexist.com (Abbildung 3).



Abbildung 3: *ThisPersonDoesNotExist*.

Hier werden GANs (StyleGAN) eingesetzt, um fotorealistische Bilder von Personen zu generieren, die es in Realität gar nicht gibt.

Schlussfolgernd kann festgehalten werden, dass menschliches und maschinelles Lernen einige Parallelen aufzeigen. Immerhin benutzen auch Menschen erlebte Erfahrungswerte, um zu lernen und komplexe Herausforderungen zu meistern: „Durch unser Vorwissen sind wir in der Lage, Dinge vorauszuahnen, zu planen, sowie bereits bekannte Strategien bei neuen Aufgaben anzuwenden“ (Weitz, 2018).

2.4 Stufenmodell der Automation des Entscheidens

Neben der Einteilung von KI in Algorithmen, kann KI auch basierend auf der Grundlage der Zusammenarbeit zwischen Mensch und Maschine eingeordnet werden. In den 50er Jahren stellte man sich bereits die Frage, inwiefern die ständige Weiterentwicklung der Technologien die Beziehung zwischen Menschen und Maschine verändern würde. Aus den Fragen entstand das Stufenmodell der Automation (eng. „Level of Automation“). Um dieses Stufenmodell zu verstehen, werden im Folgenden zunächst die kognitiven Stärken von Mensch und Maschine dargestellt (vgl. Bitkom, 2017):

Kognitive Stärken des Menschen	Kognitive Stärken der Maschine
↳ Unerwartete Stimuli wahrnehmen ↳ Neue Lösungen zu Problemen entwickeln ↳ Mit abstrakten Problemen umgehen ↳ Sich verändern können ↳ Beobachtungen generalisieren ↳ Aus Erfahrung lernen ↳ Schwierige Entscheidungen bei unvollständiger Datenlage	↳ Wiederholbare Aufgaben akkurat ausführen ↳ Große Mengen von Daten speichern ↳ Gespeicherte Daten zuverlässig wiederfinden ↳ Mehrere Aufgaben parallel ausführen ↳ Große Rechenleistung ↳ Einfache Berechnungen schnell durchführen ↳ Routine-Entscheidungen schnell treffen

Abbildung 4: *Kognitive Stärken des Menschen vs. Kognitive Stärken der Maschine*.

Obwohl Maschinen immer besser in der Simulation von menschlichen Denkprozessen werden, verkörpert das Entscheiden eine rein menschliche Fähigkeit, die auf Erfahrungen und Intuition beruht. Um diese menschlichen Fähigkeiten mittels einer KI umzusetzen, gibt es aktuell weder plausible

theoretische Modelle noch technische Implementierungsansätze. Hier ist die Rede von einem Kontinuum des Entscheidens, in der sich die Mensch-Maschine-Kollaboration derzeit befindet und von dem beide Parteien profitieren (vgl. Bitkom, 2017).




Abbildung 5: Fünf-Stufen-Modell der Automation des Entscheidens.

Das Fünf-Stufen-Modell der Automation des Entscheidens (Abbildung 5) zeigt, wie sich solch eine Mensch-Maschine-Kollaboration während der fünf Stufen verändern kann. Sie unterteilt sich folgendermaßen:

➔ Stufe 0: Mensch entscheidet.

Hierbei handelt es sich um ein manuelles System ohne Software. Um ein zuvor festgelegtes Ziel zu erreichen, erfüllt der Mensch alle anfallenden Aufgaben und trifft auch alle Entscheidungen selbst ohne die Hilfe der Maschine (vgl. Buxmann et al., 2018).

➔ Stufe 1: Assistiertes Entscheiden.

Im Gegensatz zu Stufe 0, unterstützt das System hier den Menschen bei der Ausführung verschiedener definierter Aufgaben. Immer noch treffen die Nutzende die Entscheidungen und behalten somit die Kontrolle (vgl. Buxmann et al., 2018).

➔ Stufe 2: Teilweises Entscheiden.

Auf der zweiten Stufe verstärkt sich die Unterstützung des Systems, indem dieses definierte Aufgaben fast ganz übernimmt. Der Mensch behält abermals die Rolle des Entscheidungsträgers. Man spricht hier von „Human-in-the-loop“ (HITL). Solche Systeme sind in kritischen Situationen auf einen menschlichen Supervisor angewiesen (vgl. Buxmann et al., 2018).

➔ Stufe 3: Geprüftes Entscheiden.

Systeme auf der dritten Stufe erledigen alle Aspekte der Aufgaben. Die Funktion des Menschen entwickelt sich vom Entscheidungsträger zum Überwacher dieser intelligenten Systeme, wobei er bei Bedarf oder gar im Notfall einschreiten kann und/oder muss (vgl. Buxmann et al., 2018).

➔ Stufe 4: Delegiertes Entscheiden.

Das Einschreiten bei Notfällen oder Bedarf auf Stufe 3 wird mit steigender Automatisierung immer weniger. Hier ist das Eingreifen des Menschen nicht mehr zwingend erforderlich (vgl. Buxmann et al., 2018).

➔ Stufe 5: Autonomes Entscheiden.

Auf der letzten Stufe des Fünf-Stufen-Modells der Automatisierung des Entscheidens agieren Systeme komplett autonom – ohne menschliche Unterstützung. Diese Systeme sind in der Lage, eigenständig ihre Umgebung zu analysieren und basierend darauf, eigene Entscheidungen zu treffen. Dazu kommt, dass sie die Fähigkeit besitzen, „selbstheilende Funktionen aus[zul]führen, um das vorgegebene Ziel zu erreichen sowie die zur Ausführung einer Aufgabe erforderlichen Fähigkeiten mittels Maschinellem Lernen selbstständig zu erwerben und zu optimieren“ (Buxmann et al., 2018, S. 369).

Dieses Fünf-Stufen-Modell der Automation des Entscheidens deutet darauf hin, dass die Effizienz mit Hilfe von Automation stark steigt, jedoch momentan nur in gewohnten bzw. geplanten Prozessen ganz allein funktioniert.

In Notfällen braucht es aktuell dann doch noch ein gewisses Maß an gesundem Menschenverstand (vgl. Bitkom, 2017).

Hier spricht man auch vom Stichwort Singularität, womit der Zeitpunkt gemeint ist, „ab dem Maschinen in der Lage sind, mit Hilfe künstlicher Intelligenz Maschinen zu schaffen, die weit intelligenter sind als der Mensch“ (Misselhorn, 2018, S. 205). Eine solche Art von Maschine könnte also selbst Maschinen bauen, die noch intelligenter sind als sie selbst (vgl. Misselhorn, 2018). Ob es in Zukunft zu solch einer Entwicklung von einer komplett autonomen KI kommen wird, wird immer wieder in der breiten Öffentlichkeit diskutiert. Aktuelle Versuche in diese Richtung sind bis dato kläglich gescheitert, jedoch warnte Stephen Hawkins bereits auf dem Web Summit 2017 vor einer starken KI: „Erfolgreiches Schaffen einer effektiven künstlichen Intelligenz könnte das größte Ereignis in der Geschichte unserer Zivilisation sein. Oder das Schlimmste. Wir wissen es nur nicht. Wir können also nicht wissen, ob uns die künstliche Intelligenz unendlich helfen wird, ob sie uns ignoriert und beiseite schiebt oder ob sie uns möglicherweise zerstört“ (Gerstl, 2017).

2.5 Bereitschaft der Gesellschaft für KI

Die Diskussion um zukünftige autonome KI-Systeme wirft u.a. auch die Frage auf, ob die Technologie überhaupt auf Akzeptanz in der Gesellschaft trifft oder zukünftig treffen wird.

Ein Modell, welches zur Evaluierung von Technologie-Akzeptanz dient, ist das Technologieakzeptanzmodell (TAM) (eng. „Technology Acceptance Model“). Auf diese Weise kann festgestellt werden, warum Menschen eine neuartige Technologie benutzen und/oder warum nicht (vgl. Kreutzer, 2021).




Abbildung 6: Technology Acceptance Model.

Das Ziel von TAM liegt darin, eine allgemeine Erklärung für die Einflussfaktoren von Technologie-Akzeptanz zu geben. Ein wesentlicher Zweck von TAM ist das Erschaffen einer Grundlage für die Untersuchung der Auswirkungen externer Faktoren auf interne Überzeugungen, Einstellungen und Absichten (vgl. Bagozzi et al., 1989).

Kreutzer (2021) wandte das Modell auf die Technologie KI in einem durchschnittlichen Unternehmen an. Im Folgenden werden Resultate von drei Komponenten genauer aufgeführt, u.a. die Erfahrung, welche eher gering ausfällt, was Akzeptanz-bremsend ist. Zudem erkennen viele die Relevanz von KI noch nicht, sei es für die eigene Branche, das eigene Unternehmen oder die eigene Beschäftigungsfähigkeit. Bei der Kategorie „Qualität des Outputs“ wird ersichtlich, dass die mediale Konzentration auf KI-Versagen eine negative Auswirkung auf die KI-Akzeptanz hat.

Klarere und deutlichere Ergebnisse zeigt jedoch die Trendstudie „Artificial Intelligence“ der Internationalen Hochschule IU. Hier wurden mehr als 500 Mitarbeitende und Führungskräfte aus unterschiedlich großen Unternehmen im Oktober 2020 zum Thema KI befragt. Die Studie zeigt, dass vor allem die Führungsetage, mit 71% der Befragten, sich bereits konkret mit KI beschäftigt. Aber auch Mitarbeitende sehen, mit 75% der Befragten,

eine Chance in KI und hoffen, dass mit Hilfe von KI ihre Arbeit effizienter gestaltet werden kann. Doch letztlich geben nur 14% der Befragten an, KI aktuell zu nutzen (vgl. IUBH Internationale Hochschule, 2021).

Diese Ergebnisse zeigen, dass es zwar zum einen schon eine gewisse Bereitschaft für die KI gibt. Zum anderen fehlt es letztendlich aber an Aufklärungsarbeit, um die Wissenslücken der Gesellschaft zu schließen und gleichzeitig zu zeigen, welches Potential KI-Ansätze bergen – sei es in Unternehmen oder in der Gesellschaft (vgl. Kreutzer, 2021). Daraus lässt sich folglich ableiten, dass das Thema sehr umstritten ist. Auf der einen Seite zeigt die Gesellschaft schon eine gewisse Bereitschaft für KI. Die Menschen haben Hoffnung, dass dadurch effizientere Arbeitsprozesse realisierbar sind. Andererseits empfinden Menschen Respekt und Angst aufgrund von Wissenslücken und weil unklar ist, wie sich die KI zukünftig entwickeln wird. Ein bekanntes Modell, das diese aufkommende Unsicherheit aufgrund von einer sich ständig verändernden Welt verdeutlicht, ist das VUCA-Konzept.

2.6 VUCA vs. BANI

Das in den späten 1980er Jahren entstandene VUCA-Konzept, das die Welt als „V:olatile (volatil), U:ncertain (unsicher), C:omplex (komplex) und A:mbiguous (mehrdeutig)“ beschreibt, liegt vielen selbstorganisierten Denk- und Handlungslogiken zu Grunde (Grabmeier, 2020). Das Akronym, welches ursprünglich von Militär- und Unternehmensplaner*innen verwendet wurde, steht für eine spezielle Kategorie von Planungsaufgaben. Dabei handelt es sich um die komplexesten Umstände für Planung und Strategie, wobei auch perfekt ausgearbeitete Konzepte immer wieder erneut angepasst werden müssen (vgl. Patten, 2019).

Für die immer mehr von Chaos geprägte Welt jedoch reicht das VUCA-Modell nicht mehr aus. Einen neuen Rahmen für innovative Denkmodelle bietet daher BANI aus dem Jahr 2020, was für „B:rittig (brüchig), A:nxious (ängstlich, besorgt), N:on-linear (nicht-linear) und I:ncomprehensible (unbegreiflich)“ steht. Die Gesellschaft befindet sich in einem Zeitalter des Chaos, geprägt von Klimakatastrophen, globalen Pandemien, politischem Durcheinander und vielem mehr – „einer Ära, die intensiv, fast gewaltsam, Struktur ablehnt“. Dies veranschaulicht, dass ein neuer Weg gebraucht wird, denn die bis jetzt verwendeten Methoden und Werkzeuge, die mittels VUCA entwickelt wurden, stellen sich heute als unzureichend heraus (Grabmeier, 2020).

Ungewissheit und Komplexität hat es in der Welt schon immer gegeben. Um diese alltägliche Unordnung zu bewältigen, wurde versucht, einigermaßen wirksame Systeme zu entwickeln. Von gewichtigen Institutionen wie Recht und Religion über gewohnheitsmäßige Normen und Werte bis hin zu ephemeren Geschäftsmodellen sowie politischen Strategien – vieles von dem, was als „Zivilisation“ bezeichnet wird, ist letztlich eine Reihe kultureller Instrumente, die es ermöglichen den Wandel zu kontrollieren. Wenn es gelingt, störende Prozesse verständlich zu machen, bestärkt das die Hoffnung, dass auf diese Weise schlimmste Auswirkungen in Schach gehalten werden können (vgl. Cascio, 2020).

Mit einem neuen Paradigma bedarf es zugleich einer neuen Sprache. Auch wenn der Begriff VUCA als unzureichend beiseite gelassen wird, wird ein Rahmen benötigt, der nicht nur der gegenwärtigen Welt, sondern auch ihren aktuellen Folgen einen Sinn gibt. Ein solcher Rahmen würde ermöglichen, das Ausmaß des Chaos besser zu veranschaulichen, um darüber zu reflektieren, welche Art von Reaktionen sinnvoll wäre. Im Idealfall würde sie als Plattform für die Erforschung neuer Formen von Anpassungsstrategien dienen.

Szenarien, Modelle und Transparenz sind nützliche Hilfsmittel in einer VUCA-Welt; Es stellt sich jedoch nun die Frage, wie die Werkzeuge aussehen könnten, die das Chaos verständlicher machen? Eine Möglichkeit, sich dieser Frage zu nähern, ist BANI (vgl. Cascio, 2020).




Abbildung 7: VUCA vs. BANI.

Wie auf Abbildung 7 ersichtlich, stellt sich BANI als Möglichkeit heraus, neue Blickwinkel zu erlangen und eine passendere Beschreibung für die aktuelle Lage zu finden. BANI beschreibt somit einen neuen Rahmen der „Next Generation of Business“ und wird im Gegensatz zu VUCA, als „aufsteigender Ast“ betitelt (Grabmeier, 2020).




Abbildung 8: BANI-Komponente und Reaktionen.

Die Komponenten des Akronyms BANI können auf folgende Reaktionsmöglichkeiten hindeuten:

- Brüchigkeit könnte durch Belastbarkeit und Resilienz begegnet werden.
- Angst kann durch Empathie und Achtsamkeit gemildert werden.
- Nichtlinearität erfordert Kontext und Adaptivität.
- Unverständlichkeit verlangt nach Transparenz und Intuition (Grabmeier, 2020).

Hierbei ist wichtig zu erwähnen, dass diese Auflistungen mehr Reaktionen auf die Umstände als endgültige Lösungen sind. Es zeigt eine Art und Weise, wie mögliche Antworten auf die aktuelle Lage gefunden werden könnten. BANI macht deutlich, dass der heutige Zustand keine vorübergehende Abweichung, sondern eine neue Phase ist (vgl. Cascio, 2020). Das BANI-Konzept könnte als eine Art Impuls gesehen werden, die beim Finden von Reaktionsmöglichkeiten auf die rasante technologische Entwicklung behilflich sein könnte. Vor allem BANI ist ein Modell für eine Zeit, die von Chaos geprägt ist. Auch KI entwickelt sich rasant, wird oft als Treiber von Chaos angesehen, spaltet die Gesellschaft und löst große Unsicherheiten aus. Niemand kann die weitere Entwicklung voraussehen. BANI und KI umgibt also eine ähnliche Atmosphäre und Dynamik.

3 Designprozess

3.1 Kreativität

Der aus dem Latein stammenden Terminus „Kreativität“, bedeutet übersetzt „erschaffen“. Er beschreibt demnach ein gestalterisches und schöpferisches Potential, welches in vielen Sektoren verborgen ist. Sei es im ästhetisch-künstlerischen Feld, in der Produktentwicklung, beim Lösen von Problemen oder in vielen anderen Bereichen (vgl. Becker et al., 2017).

Kreativitätsforscher*innen unterscheiden zwischen der kleinen Kreativität „Little-C-Creativity“ (small C) und der außergewöhnlichen Kreativität „Big-C-Creativity“ (Big C). Erstere stellt die alltägliche Kreativität zu Hause und am Arbeitsplatz dar, während letztere die Größenordnung der genialen Kreativität erreichen kann, die eine ganze Disziplin oder Kultur beeinflusst (vgl. Simonton, 2013). Kurzgefasst gibt es also:

- Die kleine Kreativität, „die das Bestehende nicht wesentlich verändert: Verbesserungen am Produkt, Arbeitserleichterungen, modifizierte Verfahren“
- Die große Kreativität, „die zu grundlegenden Änderungen führt: wegweisende Erfindungen, Neukonzeptionen, Umwertungen, neue Trends“ (Nöllke, 2020, S. 13).

Eine weitere Kategorisierung der Kreativität findet man bei Boden (1998). Sie gibt folgende Unterteilung vor: Kombinatorisch, explorativ und transformativ. Innerhalb der kombinatorischen Perspektive werden bekannte und vertraute Ideen in ungewohnte Kombinationen umgewandelt, die „auf ihre Art und unter Berücksichtigung bestehender Regeln und Normen neue Herangehensweisen oder ungewöhnliche Zugänge zu bestehenden Inhalten aufzeigen“ (Vey & Zipp, 2018, S. 30). Die nächste Ebene, die explorative Kreativität, bezeichnet die Fähigkeit, innerhalb eines bestimmten Feldes neue

und überraschende Ideen zu kreieren und somit einen Stil zu entwickeln (vgl. D’Onofrio & Portmann, 2020). Unter transformativer Kreativität versteht man „eine verrückte Idee [...], welche die vorherrschenden Denkmuster radikal ändert und zu einem neuen Stil, einer neuen Theorie, also neuen konzeptuellen Räumen führt“ (Vey & Zipp, 2018, S. 31).

Es gibt also Unmengen an Definitionen für Kreativität. Dabei besteht Kreativität nicht nur aus Neuheit, sondern hat auch viel mit Wert zu tun. Aufgrund der Variabilität von Werten, gibt es viele Auseinandersetzungen und Meinungsverschiedenheiten über Kreativität (vgl. Boden, 2004). Infolgedessen kann das Entstehen von Neuem durch Zerlegung in kleine Bestandteile und durch die Beschreibung der Gehirnaktivität zwar in einer Hinsicht definiert werden, jedoch handelt es sich am Ende um einen nicht erklärbaren „Sprung“ (Bröckling, 2004, S. 235). Edward de Bono, der Vater des „lateralen Denkens“, schuf dazu ein Modell, um die Verknüpfung von konventionellem und kreativem Denken klar darzustellen (vgl. Nöllke, 2020).




Abbildung 9: Der kreative Sprung.

Mit Abbildung 9 vergleicht er das menschliche Denken mit einem Fluss, wobei das Denken im Flussbett dahinfließt. Um jedoch aus dem Flussbett herauszubrechen, braucht es einen „kreativen Sprung“. Dieser wirkt zunächst als verrückter und unlogischer Denksprung und bringt die Menschen zuerst eher ins Ungewisse, als zur Idee.

Doch die Herausforderung liegt dann darin von diesem Flussärmel wieder zurück in den Hauptstrom zu gelangen. Erst durch diesen kurzen Umweg, wird aus dem gewohnten Denken eine kreative Denkbewegung, welche zukünftig zum gewohnten Denkprozess wird (vgl. Nöllke, 2020).

3.2 Beschreibung des Designprozesses

So komplex das Definieren des Begriffes der Kreativität im vergangenen Kapitel war, so unzählig viele Formen des Designprozesses gibt es.

Dabei hängen diese Prozesse immer von den Gegebenheiten ab und sind weder einheitlich, noch reproduzierbar (vgl. Brown et al., 2011). Allerdings handelt es sich im Kern immer um eine ähnliche Struktur und Vorgehensweise. Eine schrittweise Beschreibung des Designprozesses findet man im Design Thinking (DT) Prozess. Hierbei wird mittels sechs Phasen der Designprozess beschrieben: Verstehen, Beobachten, Standpunkt definieren, Ideen finden, Prototyp entwickeln und Testen (vgl. Schallmo, 2017).

Zunächst wird nachfolgend mittels einer exemplarischen Modellierung der Designprozess genauer beschrieben. Laut Brown et al. (2011) lässt sich nämlich der Prozess insofern beschreiben, dass man von einem Anfangszustand (A) zu einem Zielzustand (B) gelangen möchte. Der Raum, der sich zwischen A und B ergibt, bildet den Erkundungsraum.




Abbildung 10: Anfangszustand und Zielzustand.

Dabei werden zu Beginn auf der einen Seite das Ziel, sei es das Erstellen eines Prototyps oder eines Projektplans, und auf der anderen Seite die bereits bekannten Gegebenheiten festgehalten, um einen Startpunkt gewährleisten zu können (vgl. Brown et al., 2011).




Abbildung 11: Eröffnung, Erkundung und Abschluss.

In der ersten Phase, dem Eröffnen, fließen viele Ideen, Informationen und mögliche Chancen mit ein. Hierbei geht es nicht um kritisches Denken und Skepsis, sondern um Tatendrang, Quantität und vor allem um wildes Brainstorming. Wie die Form in Abbildung 11 zeigt, geht es darum, die Gedankengänge auszubreiten. In der zweiten Phase, dem Erkunden, versucht man Muster zu erkennen, herum zu experimentieren und Ideen zu sortieren: „Es geht darum, die Rahmenbedingungen dafür zu schaffen, dass Unvorhergesehenes, Überraschendes und Schönes zutage tritt und Form annimmt“ (Brown et al., 2011, S. 12).

In der dritten Phase, dem Abschluss, werden Schlüsse gezogen und Entscheidungen getroffen. Im Gegensatz zur ersten Phase, steht kritisches Denken an erster Stelle, und es geht vor allem darum, Ideen auszuwählen, um im Endeffekt wieder alles zusammenlaufen zu lassen. Die drei Grundprinzipien des Designprozesses, die sich hier herauskristallisieren, sind also: Eröffnen, Erkundung und Abschluss (vgl. Brown et al., 2011).

Eine ähnliche schrittweise Umsetzung des Designprozesses, inspiriert von IDEO, findet sich bei Zhang (2004):

1. Beobachtung: Beobachtung von Menschen bei der Nutzung von z.B. Produkten in alltäglichen Situationen (Einkaufen, Krankenhaus, Bahn, etc.). Beliebte Methoden sind hier u.a. Shadowing, Consumer Journey oder Storytelling.
2. Brainstorming für Ideenfindung: Eine intensive, ideenfördernde Sitzung zur Analyse von Daten.
3. Prototyping: Entwerfen von Modellen, um mögliche Lösungen zu visualisieren, um Entscheidungen zu beschleunigen und Szenarios zu schaffen.
4. Verfeinern: Auswahl von Ideen eingrenzen.
5. Umsetzung: Entwicklung und Gestaltung des finalen Produktes oder der finalen Dienstleistung.

Wenn man beide Vorgehensweisen zusammen betrachtet, finden die Schritte „Beobachtung und Brainstorming“ in der ersten Phase der „Eröffnung“ statt, das „Prototyping“ und das „Verfeinern“ im Stadium „Erkundung“ und das „Umsetzen“ in der letzten Stufe „Abschluss“. Klar ersichtlich wird, dass egal welche Art von Designprozess zu Grunde liegt, es immer einen ähnlichen Ablauf gibt und vor allem Brainstorming ein zentraler Teil jeder Anfangsphase eines solchen Designprozesses darstellt.

Weiterhin ist das Lösen von Problemen im Designprozess ein integraler Bestandteil des Designprozesses. Demnach gelten Designer*innen als Problemlöser*innen, doch seit längerer Zeit weiß man, dass solche Probleme hochkomplex sind und sich nicht aus einer singulären Perspektive lösen lassen (vgl. Bieling, 2020).

Horst Rittel nennt diese Probleme *wicked problems* (böartige Probleme) und sieht diese als eine Klasse von sozialen, schwer formulierbaren Systemproblemen, bei denen Informationen verwirrend sind und bei denen es Entscheidungsträger*innen mit widersprüchlichen Werten gibt.

Solche Probleme können zwar angegangen werden, aber eine vollständig richtige Lösung gibt es hierbei nicht (vgl. Beverland et al., 2018). Rittel und Webber (1973) nennen folgende 10 Merkmale von *wicked problems*:

1. Es gibt keine eindeutige Definition für ein *wicked problem*.
2. Ein *wicked problem* „has no stopping rule“. D.h. es gibt keine Möglichkeit zu wissen, ob ihre Lösung endgültig ist.
3. Lösungen für *wicked problems* können nur gut oder schlecht, aber nicht wahr oder falsch sein.
4. Es gibt für die Lösung eines *wicked problems* keinen unmittelbaren und endgültigen Bewertungstest.
5. Bei jeder Lösung für ein *wicked problem*, handelt es sich um einen einmaligen Vorgang, weil es keine Versuchs-und-Irrtums-Methode gibt – Jeder Versuch zählt erheblich.
6. Für *wicked problems* gibt es weder eine aufzählbare Reihe von möglichen Lösungen, noch eine gut beschriebene Menge zulässiger Tätigkeiten, die in den Plan aufgenommen werden können.
7. Jedes *wicked problem* ist im Grunde einzigartig.
8. Jedes *wicked problem* kann als Symptom eines anderen Problems betrachtet werden.
9. Das Bestehen einer Diskrepanz, die ein *wicked problem* darstellt, kann auf zahlreiche Arten erklärt werden. Die Wahl der Erklärung bestimmt die Form der Lösung des Problems.
10. Die Konstrukteur*innen, die ein *wicked problem* zu lösen versuchen, haben kein Recht, sich zu irren.

Der Klimawandel wurde sogar als *super wicked* (super bösartig) eingestuft, aufgrund der folgenden Gegebenheiten:

- Es gibt keine zentrale Behörde.
- Die Menschen, die das Problem lösen wollen, verursachen es auch.
- Die derzeitige Politik hat zunehmend negative Auswirkungen auf die Zukunft.
- Die Zeit läuft ab (Patten, 2019, S. 41).

Ereignisse, die unvorhersehbar sind und teilweise gar als unwahrscheinlich erscheinen, sind der Grund für ständige Veränderungen. Diese Geschehnisse wurden aufgrund ihrer Unvorhersehbarkeit als *black swans* (schwarze Schwäne) benannt. Ein *black swan* wird durch folgende drei Kriterien definiert:

- Wenn es sich um ein Ausnahmefall handelt, weit außerhalb des Bereichs der regelmäßigen Erwartungen. Es gab nichts in der Vergangenheit, was auf seine Existenz hindeutete.
- Wenn es extreme Folgen und Auswirkungen hat.
- Wenn die menschliche Natur uns dazu führt, Erklärungen für ihr Auftreten nachträglich zusammenzustellen, wodurch die Illusion entsteht, dass sie erklärbar und vorhersehbar seien (vgl. Patten, 2019).

Dabei gibt es sowohl viele negative als auch positive Beispiele – vom Ersten Weltkrieg bis hin zur Auswirkung des Internets. Die Zukunft wird wahrscheinlich immer mehr von solchen unvorstellbaren Ereignissen geprägt sein. Die Beschreibung von *wicked problems* und *black swans* erinnern an das VUCA- und BANI-Konzept in Kapitel 2.6 (vgl. Patten, 2019).

Das Lösen von solchen *wicked problems* und ggf. auch von *black swans* gehört zu einer der wichtigsten Aufgaben der Designschaffenden. Um derartige Probleme anzugehen und vor allem Kreativität im Designprozess zu generieren, benutzen Designer*innen Kreativitätstechniken als Hilfestellung.

Die non-lineare Herausforderungen dieser Zeit, im Sinne von BANI, braucht neue Herangehensweisen, denn, wie Albert Einstein bereits sagte, „Probleme kann man niemals mit derselben Denkweise lösen, durch die sie entstanden sind“ (vgl. Lövenich, 2020). Die nicht-lineare Vorgehensweisen von Kreativitätstechniken versucht genau das.

3.3 Kreativitätstechniken

Die Bezeichnung „Kreativitätstechniken“ entstand im deutschsprachigen Raum Anfang der 70er-Jahre. Als die erste beschriebene Kreativitätstechnik gilt das Brainstorming mit seiner Grundlage des freien Assoziierens. Mittels der gesammelten Erfahrungen mit Brainstorming entstanden infolgedessen viele andere Kreativitätstechniken, welche auf der Heuristik als Fundament beruhen. Dabei entwickelten sich immer weitere Abweichungen dieser Techniken aufgrund von Kultur oder Anwendungsbereich, so dass es heute unzählige Kreativitätstechniken gibt. Im Grunde gilt eine Kreativitätstechnik als „ein Satz von Denk- und Verhaltensregeln [...], die in ihrer Gesamtwirkung eine Gruppe oder ein Individuum zur Erzeugung von Ideen anregen“ (Geschka & Lantelme, 2005, S. 287).

Eine Menge von Kreativitätstechniken beruhen auf dem Schema des kreativen Sprungs und des Lateralen Denkens (vgl. Nöllke, 2020). Letzteres beinhaltet bewusste geistige Anstrengungen, um aus Denkweisen auszurechnen, die durch automatische und gewohnheitsmäßigen Wahrnehmungsmuster geprägt sind. Auf diese Weise werden unerwartete und wertvolle Ideen freigesetzt. Vor allem im Design ist es unerlässlich dieses laterale Denken einzusetzen. Es impliziert darüber hinaus die Möglichkeit, einfache Methoden für ein breites Spektrum von Personen zu nutzen, um bei Bedarf innerhalb eines kurzen Zeitrahmens Ideen zu entwickeln (vgl. Dingli, 2009).

Schlussfolgernd lässt sich feststellen, dass Kreativitätstechniken dazu dienen, aus den gewohnten Paradigmen auszurechnen, bereits existierendes Wissen gut von einer neuen Perspektive zu beleuchten und neuartige Kombinationen zu verknüpfen (vgl. Becker et al., 2017).

In Abbildung 12 werden die bekanntesten Kreativitätstechniken nach ihren Prinzipien in fünf Kategorien aufgelistet: Techniken der freien Assoziation, Techniken der strukturierten Assoziation, Kombinationstechniken, Konfrontationstechniken und Imaginationstechniken (vgl. Geschka & Lantelme, 2005).




Abbildung 12: Gruppierung der Kreativitätstechniken.

Wie der Name bereits verrät, lässt man bei Techniken der freien Assoziation allen Einfällen freien Lauf, ohne diese zuvor zu zensieren. Zu den bekanntesten Methoden neben Brainstorming gehört das Mind Mapping. Anhand der organisierten, visuellen und organischen Skizzierung der Ideen in unterschiedlichen Formen (Begriffen, Bildern, Symbolen) bilden sich neue Lösungsfelder. Bei Techniken der strukturierten Assoziation hingegen sind einige Parameter bereits vorgegeben (vgl. Geschka & Lantelme, 2005)

Hierbei wird ein Thema aus unterschiedlichen Perspektiven beleuchtet, wie es bei der Walt Disney Methode mit den drei Denkhaltungen (Träumer, Macher und Kritiker) der Fall ist. Unter einer Kombinationstechnik versteht man eine Methode, die neue Lösungen durch Kombination von unterschiedlichen Lösungselementen generiert. Ein Beispiel dieser Technik ist das Attribute Listing, wobei nicht die wesentlichen Bestandteile des Problems, sondern eher seine leicht adaptierten Merkmale genauer unter die Lupe genommen werden. Diese werden in einer Tabelle in ihrer Ist-Form beschrieben und Variationen davon aufgelistet. Auf diese Weise entstehen Anregungen für Verbesserungen (vgl. Geschka & Lantelme, 2005).

Die weitere Kategorie der Konfrontationstechniken zeichnet sich durch die Verwendung von Funktions- und Strukturprinzipien aus Bereichen aus, die nicht direkt mit dem Problem in Verbindung stehen und somit den Kreativprozess fördern: „Die Problemlöser werden dabei durch externe Aspekte zunächst aus dem Problemfeld herausgeführt, um dann problemfremde Prinzipien auf die Problemstellung zu übertragen“. Durch die Methode Visuelle Konfrontation werden Bilder als Konfrontationselemente benutzt (Geschka & Lantelme, 2005, S. 299).

Zu guter Letzt beziehen sich die Imaginationstechniken auf bildhafte Vorstellungen. Bei dieser Methode sind auch nicht realisierbare Erfahrungen erlaubt und sogar förderlich für den Lösungsfindungsprozess. Bei der Methode *Try to become the problem* werden die Problemlöser*innen zum Subjekt, in dem sie sich in das Problemszenario hineinversetzt und so daraus Schlüsse ziehen können. So kann ein tieferes Verständnis für das Problemfeld intuitiv entwickelt werden und neue Ideen einer möglichen Lösung können entstehen (vgl. Geschka & Lantelme, 2005).

4 KI im Designprozess

In den vorausgegangenen Kapiteln wurde der aktuelle Stand der Technik in der KI genauer erläutert und dargestellt, inwiefern sich Kreativität, der Designprozess und Kreativitätstechniken definieren lassen. Im Folgenden soll aufgezeigt werden, welche aktuellen KI-Ansätze und Überlegungen es im Designbereich gibt.

4.1 Künstliche Kreativität

Seit Ende des 20. Jahrhunderts sorgt die Künstliche Kreativität (KK) (eng. „Artificial Creativity“ oder „Computational Creativity“) im Schnittbereich von verschiedenen Wissenschaften für regen Diskurs. Grund dafür ist, dass „Kreativität noch stärker als Intelligenz mit der menschlichen Fähigkeit verbunden wird“ und sie möglicherweise in der Lage ist, „sich neue und über-raschende Konzepte und Ideen auszudenken und ästhetisch, kulturell oder intellektuell wertvolle Artefakte zu erschaffen“ (Wittpahl, 2019, S. 257).

Allgemein gesprochen beschäftigt sich die KK, ein Teilaspekt der KI, mit der Entwicklung und grundsätzlichen Möglichkeit, ein kognitives System Kreativität simulieren oder replizieren zu lassen (vgl. D’Onofrio & Portmann, 2020). Was wiederum den Diskurs befeuert, inwiefern Algorithmen in der Lage sind kreativ zu sein. Durch die neuesten Entwicklungen der KI wird Kreativität als neues Forschungsfeld gesehen. So werden u.a. in der Musik, Literatur und im Design viele Ansätze ausprobiert, um das Potential zu untersuchen. Aufgrund der Möglichkeit, große Datenmengen zu analysieren, erzeugt das Maschinelle Lernen innovative Denkanstöße. Diese Verfügbarkeit von Daten verkörpert in der KK, wie eben auch generell bei der KI, die Grundbasis, um überhaupt einen Output zu erzeugen. Das Wissens-schaftsnetzwerk PRO- 258 C Gesellschaft SECCO bezeichnet KK als Gebiet, welches Systeme nicht auf ihre Funktionalität, sondern sie „in ihrer Rolle als

autonome Kreateure und Ko-Kreateure erforscht und nutzt“. Auf diese Weise wäre es möglich, den schöpferischen Akt als zentralen Interessenpunkt zu sehen (Wittpahl, 2019, S. 259).

Dies wirft wiederum die Frage auf, was dabei mit den Designschaffenden passiert. Wenn KI zum Teil den kreativen Part übernimmt, welche Rolle haben dann noch die Kreativen? In den vergangenen 20 Jahren hat sich die Relation zwischen Mensch und Maschine bereits stark verändert (vgl. Golta, 2019). Wie lässt sich die Beziehung zwischen einem kreativen Menschen und kreativen Algorithmen beschreiben? Um sich solch eine Mensch-Maschine-Kollaboration erstmal vorstellen zu können, werden im Folgenden fünf aktuelle Beispiele aufgezeigt und genauer erläutert.

4.2 Aktuelle Beispiele für Künstliche Kreativität

4.2.1 Mobius Vision

Mobius, ein Berliner KI-Startup, entwickelte die Bilderkennungssoftware «Mobius Vision», welche «Gestalter*Innen dabei [unterstützt], Bilder eines bestimmten Stils oder Typs zu finden, große Bildersammlungen zu sortieren und unpassenden Content herauszufiltern». Für die Umsetzung wird die Software auf Schriften und Layouts angesetzt, um daraus den bestimmten Stil zu finden. KI kann in diesem Fall also nicht nur Bildsprachen erkennen, sondern auch passende Schriften dazu finden und kann somit für die Erkennung von Geschmack eingesetzt werden (Bundesministerium für Wirtschaft und Energie, 2019, S. 36).

4.2.2 The Next Rembrandt



Abbildung 13: The Next Rembrandt.

347 Jahre nach seinem Tod, wurde 2016 das neueste Werk des Malers Rembrandt van Rijn mit Hilfe von KI geschaffen: The Next Rembrandt. Ein Team bestehend aus der Universität Delft, Microsoft, ING Bank, dem Museum Het Rembrandhuis und Mauritshuis setzten sich 18 Monate mit der Fragestellung auseinander: Kann modernste Computertechnik das Leben und Werk eines der größten und innovativsten Malers seiner Zeit „zurück“ bringen? (vgl. Karg, o. D.)

Um dieses Experiment durchführen zu können und die nötigen Daten dafür zu erhalten, wurde eine breite Palette von Materialien, wie hochauflösende 3D-Scans und digitale Dateien, die durch DL-Algorithmen hochskaliert wurden, analysiert. Diese umfangreiche Datenbank wurde dann als Grundlage für die Erstellung von The Next Rembrandt verwendet (vgl. The Next Rembrandt, o. D.).

4.2.3 KI-Muse

Der Berliner Künstler Roman Lipinski arbeitet mit einer KI „Roman“, die Eigenschaften wie Komposition, Farbe und Formen seiner Bilder analysiert und daraus neue Werke schafft. Dies nutzt der Maler dann wieder als Inspiration – die KI nimmt damit sozusagen die Rolle einer Muse ein (Wittpahl, 2019, S. 263). Dieses Beispiel zeigt, wie groß das Potential in der Kreativwirtschaft ist – „indem Irritation als Inspiration genutzt wird, können Perspektivenwechsel entstehen“ (Bundesministerium für Wirtschaft und Energie, 2019, S. 42). Dies könnte auch als eine neue Art Kreativitätstechnik verstanden werden.

4.2.4 Avocado Chair

DALL-E ist eine 12-Milliarden-Parameter-Version von GPT-3, die darauf trainiert wurde, Bilder aus Textbeschreibungen zu generieren. DALL-E verkörpert demnach ein autoregressives Sprachmodell, das DL, basierend auf einem Datensatz von Text-Bild-Paaren, verwendet (vgl. Goh et al., 2021).




Abbildung 14: Avocado Chair.

In Abbildung 14 wird der Versuch dargestellt, wie mit Hilfe von DALL-E Objekte durch die Kombination von zwei nicht miteinander verbundenen Ideen erzeugt werden. Es wurde untersucht, inwiefern DALL-E sich von einer nicht verwandten Idee inspirieren lässt, ohne die Form des zu entwerfenden Objekts außen vor zu lassen. Durch die Eingaben „in Gestalt von“ („in the shape of“ oder „in the form of“) und „in der Art von“ („in the style of“) war DALL-E in der Lage dies zu generieren. Bei der Generierung „ein Sessel in Form einer Avocado“ scheint DALL-E die Form einer halben Avocado mit der Rückenlehne des Stuhls und den Kern der Avocado mit dem Kissen in Verbindung zu bringen (vgl. Goh et al., 2021).

4.2.5 A.I. Chair

Der auf dem Salone del Mobile in Mailand 2019 vorgestellte *A.I. Chair* für Kartell vom französischen Designer Philippe Starck, unterstützt von Autodesk, ist das Ergebnis der Zusammenarbeit zwischen künstlicher und menschlicher Intelligenz, die von Starck als „natürliche Intelligenz“ bezeichnet wird (vgl. A.I. – Introducing the first chair created with artificial Intelligence, 2020).



Abbildung 15: *A.I. Chair*.

„Künstliche Intelligenz, kannst du uns sagen, wie wir unsere Körper unter Einsatz von so wenig Material wie möglich ausruhen können?“ So lautete die ursprüngliche Frage und Aufgabe. Um dies mittels KI zu beantworten, wurden Designziele, bestehend aus Parametern, wie Materialien, Kosten- und Effizienzangaben und Konstruktionsmöglichkeiten in die KI eingespeist. In diesem Fall handelte es sich um bereits bestehende Designansätze von Philippe Starck, Vorgaben zur Bequemlichkeit des Stuhls und EU-Richtlinien zur Belastbarkeit. Das erste Ergebnis war dabei nicht sofort das finale Stuhl-Design – es war vielmehr ein Prozess, in dem sich das System langsam zu einem kollaborativen Teamplayer entwickelte und immer mehr verstand, was die Vorlieben Starcks sind: „Der Computer entwickelte aus den gemachten Vorgaben in kurzer Zeit eine Vielzahl an Design-Varianten, die mit menschlicher Denkleistung kaum möglich gewesen wären. Und genau darin liegt der Vorteil künstlicher Intelligenz: Sie ist schneller, als das menschliche Gehirn, vor allem aber ist sie freier“. Der *A.I. Chair* ist der erste Stuhl, der außerhalb eines Gehirns und außerhalb menschlicher Denkgewohnheiten entwickelt wurde. Die Vorgehensweise hier fällt unter Generatives Design (Pechmann, 2020).

4.3 Generatives Design

Unter Generativem Design (GD) (eng. „Generative Design“) versteht man eine Methodik, bei welcher Algorithmen für eine Problemstellung zur Erzeugung großer Mengen an Varianten benutzt werden. Da der Output meistens aus unendlichen Variationen besteht, gehört zu diesem Entwurfsprozess auch das automatisierte Bewertungskriterium, „sodass Modelle hinsichtlich ihrer Leistungsfähigkeit eingeordnet und sinnvolle Varianten zurückzugeben werden können“ (Struve, 2021, S. 9). Es handelt sich also um eine Technologie, die es Designer*innen und Ingenieur*innen ermöglicht, ihre Designziele zusammen mit Parametern wie Materialien, Herstellungsmethoden und Kostenbeschränkungen zu erreichen.

Die Software erforscht dann alle möglichen Kombinationen einer Lösung und generiert schnell Designalternativen. Sie testet und lernt aus jeder Iteration, was funktioniert und was nicht (vgl. A.I. – Introducing the first chair created with artificial Intelligence, 2020).

Aus praktischer Sicht suchen Werkzeuge aus dem GD im Wesentlichen nach einer Lösung für ein Problem, das durch eine mathematische Formulierung ausgedrückt wird; dies führt oft zu einem iterativen Optimierungsprozess, der versucht, eine Zielfunktion zu minimieren. Dementsprechend hat sich GD als nützlich erwiesen, um ungewöhnliche Lösungen zu identifizieren, die nicht zu den typischen Formen oder Konfigurationen gehören, wie man am Beispiel des *A.I. Chair* (siehe Abbildung 15) sehen kann. Infolgedessen wurden die GD-Tools zunächst vor allem zur Förderung von divergentem Denken und Kreativität eingesetzt. Dies ist nach wie vor ein charakteristischer Aspekt der Technologie, der zu ihrer Anwendung in Bereichen geführt hat, in denen Ästhetik und Innovationskraft im Produktentwicklungsprozess wichtig sind, wie z. B. im Produktdesign oder im Automobilsektor (vgl. Buonomici et al., 2020).

Ein bekanntes Beispiel aus der Automobilbranche (Abbildung 16) stellt das „Concept IAA“ (Intelligent Aerodynamic Automobile) von Mercedes Benz dar.



Abbildung 16: Concept IAA.

Hier werden algorithmische Entwurfsmethoden benutzt, „um die komplexe geometrische Gestaltung zu bewältigen und um [...] die Aerodynamik auf ein Optimum zu trimmen“ (Schaffrinna, 2018).

Um den Einsatzbereich von generativem Design besser einordnen zu können, werden Designprobleme grob in zwei Kategorien unterteilt: Routine-Designproblem und kreatives Designproblem. Während das Designverfahren in der ersten Kategorie allmählich durch voll- oder halbautomatische Entwurfsverfahren ersetzt wird, ist die zweite Kategorie durch die hohe Komplexität, die zahlreichen Designziele und durch etliche ästhetische Fragen schwer zu fassen. Diese Herausforderungen machen es fast unmöglich, konzeptionelles Design zu automatisieren. Das Ergebnis des Entwurfs hängt daher von den subjektiven Entscheidungen der Designer*innen ab, die ihre Vorstellungen und Geschmack widerspiegeln. Generatives Design kann diese Kategorie von Designaktivitäten unterstützen, da sie sich auf die subjektive Bewertung des Kreativen stützt, um die Designrichtung zu bestimmen. Architektur, Produktdesign, Gamedesign und Animationsdesign gehören eindeutig zu dieser Kategorie (vgl. Krish, 2011).

Eine der bekanntesten Arbeiten im generativen Kommunikationsdesign ist die visuelle Identität für MIT Media Lab.




Abbildung 17: MIT Media Lab Logo.

Das Logo beinhaltet drei sich kreuzende Formen, die dank eines Algorithmus in 40.000 Versionen in 12 Farbkombinationen umgestaltet werden können – ein Logo mit 40.000 Permutationen (vgl. Fishel, 2011).

4.4 Ideenfindung mit KI

Die vorherigen Beispiele zeigen, dass KI in der Kreativbranche keineswegs ein neues Feld darstellt. Dennoch dominiert bis dato aber noch keine KI das kreative Innovationsgeschehen. Es ist vielmehr zu beobachten, dass bestimmte Spielfelder entstanden sind, in denen KI Kreativität entwickeln kann, wie z.B. Sprache, Musik, visuelle Medien und Produktgestaltung. Das Beispiel aus der Kunst „Next Rembrandt“ zeigt Eigenschaften, die kreativ sind, wie Originalität und Neuheit, jedoch handelt es sich nicht um einen komplett bahnbrechenden Output, wie z.B. einen neuen Stil. Aber es stellt einen wichtigen „Impulsgeb[er] bei der Gestaltung des Arte-faktes“ dar (Wittpahl, 2019, S. 264).

Gleichwohl stellt sich hier wiederum die Frage, wie KI aktuell im Designprozess eingesetzt wird, und wie tief diese Technologien momentan verankert sind. Cautela et al. (2019) haben 20 unterschiedliche Startups befragt, um herauszufinden, in welcher Phase des Design Thinking Prozess KI eingesetzt wird.

Die Ergebnisse der Abbildung 18 zeigen, wie sich KI auf vielfältige Weise auf den DT Prozess auswirkt. Zum einen verkürzt und beschleunigt KI die Forschungsphase und Datenverwaltung, was wiederum auf eine neue Ära der Nutzerbeobachtung und -analyse hindeutet. Es kann also davon ausgegangen werden, dass sich die Aufmerksamkeit von Designer*innen in Zukunft vermehrt auf die Ideenfindung und auf die Konzeption neuer Lösungen verlagern wird, anstatt diese für die Analyse aufzubringen (vgl. Cautela et al., 2019).

DT Phases					
AI applicative domains	Team Building and Task Management	Sensing and Empathizing	Interpreting and Framing	Ideating and Conceiving	Prototyping and Learning
Intelligent Data Processing	Medium intensity of coverage 3 startups covering this phase/technology (Eightfold, Pymetrics, Goroov)	High intensity of coverage 8 startups covering this phase/technology (Veritone, Inc., Sentiance, iGenius, Pixoneye, Goroov, ForwardLane, DataRPM Corporation, Iguazio)	High intensity of coverage 6 startups covering this phase/technology (Gamalon Inc., Feich.ai, iGenius, HyperAnna, ForwardLane, Iguazio)		Low intensity of coverage 2 startups covering this phase/technology (B12 Appvance)
Virtual Assistant/ Chatbot		Low intensity of coverage 1 startup covering this phase/technology (Gamalon, Inc.)	?	o	
Recommendation		Medium intensity of coverage 5 startups covering this phase/technology (Gamalon Inc., Pixoneye, Daisee, ForwardLane, AdMobilize)	Low intensity of coverage 1 startup covering this phase/technology (Gamalon Inc.)		
Image Processing		Low intensity of coverage 1 startup covering this phase/technology (AdMobilize)			Medium intensity of coverage 3 startups covering this phase/technology (Applitools, Test.ai, Appvance)
Language Processing		Low intensity of coverage 1 startup covering this phase/tech-nology (Daisee)	Low intensity of coverage 1 startup covering this phase/tech-nology (Eigen Technologies)		

Abbildung 18: KI im Design Thinking Prozess.

Zum anderen wird in der Phase „Ideenfindung“ laut Abbildung 18 KI gar nicht genutzt. Hier ist ein aktueller Mangel festzustellen, was großes zukünftiges Potential in sich birgt. Um herauszufinden, aus welchem Grund diese Lücke existiert, wird im Folgenden anhand der Kreativitätstechnik Brainstorming das Thema Ideenfindung mit KI genauer analysiert.

5 Brainstorming als Anwendungsfall

Zur Analyse, ob und inwiefern KI Designer*innen dabei helfen kann, kreativer zu sein, und auf welche Weise beide Komponenten in der Lage sind, gemeinsam Ideen zu entwickeln, wird in der vorliegenden Arbeit Brainstorming als Anwendungsfall genommen, weil sie die älteste, bekannteste und beliebteste Kreativitätstechnik repräsentiert (vgl. Nöllke, 2020).

5.1 Bedeutung des Brainstormings

Das Brainstorming wurde bereits kurz in Kapitel 3.3 unter den Kreativitätstechniken erwähnt. Es wird im Folgenden mittels einer Beschreibung in seiner herkömmlichen Form sowie in Erweiterungen genauer beschrieben.

5.1.1 Definition des herkömmlichen Brainstormings

Brainstorming ist in seiner Ursprungsform eine Einzel- oder Gruppenmethode zur Generierung von Ideen, zur Steigerung der kreativen Effizienz und zur Lösungsfindung für Probleme (vgl. Wilson, 2013). In seinem einflussreichen Buch *Applied Imagination* schlug Osborn 1957 das Brainstorming als eine Methode zur Lösung von Gruppenproblemen vor, die die Qualität und Quantität der von den Gruppenmitgliedern produzierten Ideen erheblich steigert (vgl. Diehl & Stroebe, 1987). Ganz nach Osborns Ausspruch „Quantity breeds quality!“. Wie in Kapitel 3.3 gehört die Brainstorming-Methode zu den Techniken der freien Assoziation (vgl. Geschka & Lantelme, 2005).

Die vier Grundregeln lauten:

1. Kritik ist untersagt. Kein Vorschlag darf beurteilt werden, ehe nicht alle Vorschläge geäußert worden sind.
2. Wilde Ideen sind willkommen. Der Grund: Es ist leichter, Ideen abzuschwächen, als sie zu entwickeln.
3. Entwickeln Sie so viele Vorschläge wie möglich. Quantität geht vor Qualität.
4. Greifen Sie die Ideen anderer auf! Entwickeln Sie sie weiter und kombinieren sie neu! (Nöllke, 2020, S. 56)

Aus dem klassischen Brainstorming-Typus, haben sich im Laufe der Zeit viele weitere Formen entwickelt.

5.1.2 Varianten des Brainstormings

→ Destruktiv-Konstruktiv-Brainstorming

Das Destruktiv-Konstruktiv-Brainstorming besteht aus zwei Phasen der Ideenfindung:

1. Die Gruppe soll so viele negative Vorschläge sammeln, wie möglich, die eine Lösung auf jeden Fall verhindern.
2. Die Teilnehmenden sollen so viele konstruktive Ideen, wie möglich generieren (vgl. Nöllke, 2020).

Die Ideen sollen dabei durch das Denken ins Gegenteil reicher und origineller ausfallen (vgl. Nöllke, 2020).

→ Directed Brainstorming

Directed Brainstorming ist ein, von einem Moderierenden geleiteter Prozess, bei dem die Gruppe jeweils nur eine Idee in Betracht zieht. Das Team wird durch eine Reihe von Denkprozessen geleitet, was die Qualität der Entscheidungsfindung verbessert und jeder Idee mehr Tiefe verleiht (vgl. Group-

Map, o. D.). Diese Methode arbeitet mit einer Reihe von Kriterien, um zu beurteilen, ob eine Idee gut ist oder nicht:

1. Um die Brainstorming-Session mehr zu strukturieren, wird eine Reihe an Kriterien festgehalten.
2. Indem diese Kriterien im Voraus festgelegt wurden, werden die Teilnehmenden permanent gefordert und eine sachgerechte Diskussion wird gewährleistet.
3. Während der Sitzung wird den Teilnehmer*innen eine Frage gestellt, wobei alle ihre Antworten auf ein Blatt Papier schreiben.
4. Nachdem alle ihre Antworten aufgeschrieben haben, werden die Blätter per Zufallsprinzip unter den Teilnehmenden ausgetauscht.
5. Auf diese Weise erhalten also alle die Antwort eines anderen Teilnehmenden und müssen daraus wieder eine neue Idee entwickeln.
6. Dieser Ablauf wird drei oder mehrere Runden lang durchgeführt (vgl. Brainstorming: The Complete List of Tools and Techniques, 2020).

Hierbei entstehen qualitativ höhere Lösungen und die Konzentration ist stärker (vgl. Briggs et al., 2004).

→ Nominal Group Technique

Die Nominal Group Technique (NGT) ist eine Abwandlung des Brainstormings, bei der die erste Phase der kreativen Gruppenaufgabe individuell und in Stille stattfindet, um mehr Ideen zu generieren. Die Gruppenmitglieder befinden sich also nominell in einer Gruppe, arbeiten aber in dieser Phase für sich alleine (vgl. Boddy, 2012). Hierbei trägt die gegebene Anonymität ebenfalls dazu bei, dass mehr Ideen entstehen können, als gemeinsam in der Gruppe (vgl. Nijstad & Stroeber, 2004).

→ Individuelles Brainstorming

Beim Individuellen Brainstorming generiert man Ideen alleine – ohne Gruppe. Bei dieser Variante des Brainstorming bleibt der Ablauf derselbe, wie bei den anderen Formen. Solange das Individuum Ideen generiert, dürfen diese nicht von sich selbst bewertet werden. Die Bewertungsphase findet erst in einem nächsten Schritt statt, wobei es ratsam ist, dies erst ein bis zwei Tage später zu tun (vgl. Nöllke, 2020).

5.2 Grenzen des Brainstormings in Gruppen

Die Forschung zeigt, dass Brainstorming-Gruppen weniger und qualitativ schlechtere Ideen hervorbringen als die gleiche Anzahl von Einzelpersonen, die allein arbeiten (vgl. Furnham, 2000).

Zudem nimmt die eigene Produktivität stark ab, wenn Menschen ihre Ideen nicht sofort nach ihrer Entstehung äußern können, weil sie warten müssen, bis sie an der Reihe sind. Dies ist auch unter dem Begriff Produktionsblockierung (eng. „Production blocking“) bekannt: „Kommunikation kann die Ideengenerierung zwar stimulieren, aber die durch das Zuhören verursachten Unterbrechungen der eigenen Denkarbeit führen zu großen Beeinträchtigungen der Ideengenerierung, die den Stimulierungseffekt überschatten“ (Nijstad & Stroeber, 2004, S. 188).

Aus diesem Grund sind sogenannte Stimulierungseffekte nur von Vorteil, wenn das Ausschalten von Produktionsblockierung garantiert werden kann (vgl. Nijstad & Stroebe, 2004).

Laut Diehl & Stroebe (1987) können somit drei Probleme, die die Effektivität des Brainstormings in Gruppen verringern, festgehalten werden:

1. Soziales Faulenzen (eng. „Social Loafing“): Der Gruppenkontext ermöglicht es dem Einzelnen, sich weniger anzustrengen.
2. Bewertungsangst: Angst, Ideen vorzuschlagen, die einen dumm aus-sehen lassen könnten. Hierbei vermeiden die Teilnehmenden das laterale Denken, um das es bei den Kreativitätstechniken ja eigentlich geht. Stattdessen bleiben sie im linearen Denken und in ihren Ängsten stecken, ohne ihrer Kreativität freien Lauf zu lassen. Um sich auf die intuitive Vorgehensweise der Kreativitätstechniken einlassen zu können, braucht es also Vorbereitungsarbeit.
3. Produktionsblockade: Aufgrund der Tatsache, dass immer nur eine Person in der Gruppe sprechen kann, werden die anderen Gruppen-mitglieder daran gehindert, ihre Ideen zu äußern, wenn sie ihnen einfallen. Diese Wartezeit kann dazu führen, dass die Ideen ver-gessen werden oder die Idee als weniger originell oder relevant im Vergleich zu der gegenwärtig betrachteten Idee angesehen wird (vgl. Furnham & Yazadnpanahi, 1995).

5.3 Erweiterungen des Brainstormings und Chancen der KI

Im Folgenden werden Erweiterungen und Chancen der KI bezüglich der Kreativitätsmethode Brainstorming genauer beschrieben.

→ Electronic Brainstorming

Beim Electronic Brainstorming (EBS) sitzen die Gruppenmitglieder jeweils an einem Computer und tippen ihre Ideen ein. Parallel dazu haben sie aber auch vollen Zugang zu den Ideen der anderen, während sie produziert werden. EBS vereint also auf die Möglichkeit, Ideen frei zu generieren und den respektvollen Austausch dieser Einfälle (vgl. Furnham, 2000).

Demzufolge ermöglicht EBS den Gruppenmitgliedern anonym zu inter-agieren und die Ideen der anderen zu simulieren, ohne dass es zu der sogenannten Produktionsblockade durch erzwungenes Schweigen aller Gruppenmitglieder kommt. Ein weiterer Vorteil ist die gegebene Anonymität und das Schwinden der Bewertungsangst der anderen (vgl. Connolly et al., 1996).

→ Data-Driven Brainstorming

Die Methode des „Data-Driven Brainstorming“ geht davon aus, dass die Brainstorming-Session nicht von einer Problemstellung, sondern von Daten-mustern geleitet wird. Folglich erhalten die Teilnehmenden anstelle eines Problems eine Reihe von interpretationswürdigen Mustern, welche die Dynamik des Unternehmens selbst oder eine externe Aktivität von Wett-bewerbern, Branchen, Verbrauchertrends usw. beschreiben.

Große Datenmengen enthalten viele ungenutzte Erkenntnisse, die bei Berücksichtigung jedoch auf interessante Probleme und Möglichkeiten hin-weisen können. Z.B. könnte ein solcher Prozess bei einer Produktentwicklung Ausnahmen und Veränderungen anhand von bestimmten Nutzerprofile erkennen, auf welche Weise das Produkt benutzt wird. Überdies kann analysiert werden, wie einerseits die Märkte auf gewisse neue Funktionen reagieren und andererseits ob sich konkurrierende Angebote entwickeln, die möglicherweise eine Bedrohung für das jeweilige Unternehmen dar-stellen können. Ein vereinfachteres Format des Data-Driven-Brainstormings sieht wie folgt aus: Es gibt einen bestimmten Key Performance Indicator (KPI), eine Leistungskennzahl, mit einem aktuellen Wert oder einer simplen Herausforderung, wie z.B.: „Finde einen Weg, um den Wert um einen Faktor X zu optimieren“. Dieser KPI verkörpert eine klar definierte Geschäftskennzahl, wie z.B. Benutzerzufriedenheit, Engagement oder die Klickrate eines neuen Online-Konzeptes. Anschließend erklärt die Organisatorin oder der Organisator den Teilnehmenden den bestimmten Kontext, indem sie*er

den aktuellen Wert und die dazugehörige Geschichte und Herausforderung vorstellt. Daraufhin müssen die Teilnehmer*innen versuchen, diesen Wert zu optimieren. Hierbei liegt der Fokus nicht wie beim üblichen Brainstorming auf der Lösungsfindung, sondern auf der Reaktion auf die Datenmuster. Überdies besteht der Output nicht aus einer konkreten Lösung, sondern vielmehr aus Ideen, Problemen oder gar Vorschlägen für Experimente und weiteren Datenanalysen (vgl. Krasadakis, 2020).

Zusammenfassend kann also festgehalten werden, dass das Ziel darin besteht, die Ergebnisse zu interpretieren, Abweichungen von Normalität zu erklären und die verborgene Geschichte hinter den Daten zu entdecken. Die Teilnehmer*innen stellen Fragen und versuchen, die nicht offensichtlichen und bisher unbekannten Datenmuster zu verstehen. Dies kann zum einen zu Innovationen inspirieren und die Ideenfindung steigern und zum anderen die Identifizierung neuer Probleme und die Formulierung von Hypothesen fördern (vgl. Krasadakis, 2020).

→ brAInstorming

Robra-Bissantz et al. (2017) schufen durch verschiedene Funktionen der KI, wie Verarbeitung natürlicher Sprache, maschinelles Lernen und logisches Denken, einen umfangreichen, allumfassenden intelligenten Moderator (IMO) für virtuelle Brainstorming-Sitzungen. Dabei wurden für die Implementierung grundlegende Prinzipien des EBS abgeleitet. Mit der Verwendung eines Chats war es den Nutzer*innen möglich, miteinander zu kommunizieren. Darüber hinaus sind die Teilnehmenden in der Lage, Ideen hinzuzufügen und zu bearbeiten sowie Ideen anderer einzusehen.

Der Prozess (siehe Abbildung 19) gliedert sich in eine individuelle Ideengenerierung und eine kollektive Ideenbewertung. Diese Phasen werden von IMO, basierend auf einem Open-Source-Chatbot Hubot, unterstützt.




Abbildung 19: brAInstorm.

Neben der Organisation der EBS-Session greift er auch zusätzlich ein, wenn Teilnehmende sogenannte Killerphrasen verwenden, zu viel reden oder vom Thema abdriften. Wegen der fehlenden Hör- und Antwortfunktionen (Text-/Stimmeingabe und -abgabe) wurde Hubot mit einer Bot Engine (Treiber) von wit.ai erweitert. Hierbei handelt es sich um eine Open-Source Plattform für natürliche Sprache, die Benutzer-texte oder Sprache in strukturierte Daten umwandelt und interpretiert. Mit Hilfe dieser Vorhersagen von wit.ai ist Hubot sogar im Stande, an den benötigten Stellen im Gespräch eine Aktion durchzuführen. Auf diese Weise stellt brAInstorm einen neuartigen Beitrag dar, der eine umfassende automatisierte Moderation für EBS bietet (vgl. Robra-Bissantz et al., 2017).

Des Weiteren zeigt dieses Beispiel, wie teilweise Grenzen des Gruppen-brainstormings anhand von KI gelöst werden können. Die durch den Einsatz des IMO entstandene Anonymität und das Ausbleiben von Produktionsblockaden wird die Kreativität gefördert und lässt der Generierung von neuen Ideen freien Lauf.

→ Virtuelles Brainstorming mit KI bei IDEO

Mit Hilfe eines sogenannten „Transformer“ wie GPT-3 führte die Agentur IDEO ein virtuelles Brainstorming durch. Nachdem er mit den selbst festgelegten sieben Regeln für das Brainstorming, einer klaren Aufforderung „Wie können wir jungen Menschen helfen, das Sparen zu einer lebenslangen Gewohnheit zu machen?“ und fünf Beispielideen gefüttert worden war, begann das Modell neue Ideen dazu auszuspacken. Hier ein paar Beispiele:

1. Ermögliche den Nutzer*innen, ihre Sparziele mit Freunden zu teilen und eine Gemeinschaft von Leuten zu haben, die sie anfeuern oder herausfordern, falls nötig.
2. Belohne die User*innen mit echtem Geld, wenn sie in einem Monat überhaupt kein Geld ausgeben.
3. Ermögliche den Nutzer*innen „Spaßbudgets“ einzurichten, um mehr Geld zu sparen.

Zeigen Sie, ähnlich wie bei der Idee „Future View“, wie viel mehr gespart werden könnte, wenn derjenige oder diejenige auf den täglichen Kaffee verzichtet oder sich neue Turnschuhe kauft, anstatt extra Urlaub zu machen (vgl. Syverson, 2020).

Das letzte Beispiel zeigt, dass das Modell sogar auf den Ideen anderer aufbauen kann, indem es eine Idee „Future View“, die zuvor genannt wurde, wieder aufgreift.

Im Folgenden wurde die Anforderung so geändert, dass sie zu analoger Inspiration anregte. Hier wiederum ein paar Beispiele dazu:

1. Lassen Sie „Clowns“ aus Geldautomaten springen, damit es weniger Spaß macht, Geld abzuheben.
2. Ein Virtual-Reality-Erlebnis zu schaffen, bei dem sich die Nutzer*innen in einer Arena voller Sparmonster befinden und diese erschlagen müssen, indem sie Geld auf Sparkonten einzahlen.

3. Erstellen Sie ein Sparmonster, ähnlich wie in chinesischen Lotteriesendungen, bei denen das Publikum den gesparten Betrag erraten müssen, um Geld zu gewinnen (vgl. Syverson, 2020).

Dieses virtuelle Brainstorming beschreibt letztlich, inwieweit es bereits möglich ist, gemeinsam mit einer KI Ideen zu generieren. Anhand von eigenen Beispielideen, ist die KI in der Lage, eigene Überlegungen zu einer bestimmten Frage zu tätigen und zu kommunizieren. Sie kann sogar an den Beispielideen anknüpfen und diese mit eigenen Einfällen weiter ausbauen.

6 Experteninterviews

Um den Wissensstand aus der Literatur im weiteren Verlauf zu vertiefen und neue Ansätze zu gewinnen, wurden vier qualitative Experteninterviews mittels der Software für Videokonferenzen *alfaview* durchgeführt. Die Teilnehmenden kamen sowohl aus der Designdisziplin als auch aus dem Bereich der Informatik und der KI. Für die spätere Auswertung wurden die Interviews aufgezeichnet und transkribiert (siehe Anhang).

Zuerst wurde die Frage thematisiert, ob beim Thema KI im Design, die Vorteile die Nachteile überwiegen, thematisiert. Schmitz (2021) denkt folgendermaßen darüber:

„Ich bin mittlerweile der festen Überzeugung, dass wir in allen Bereichen Vorteile haben. Ich sehe da kaum Nachteile, denn letztendlich ist es nur eine neue Methode, um etwas anzugehen. Es ist kein Bruch von irgendwelchen alten Technologien, die kann man ja trotzdem weiterverwenden, sondern es ist ein Ersatz oder eine Möglichkeit, Systeme noch einmal von einer anderen Seite zu beleuchten. Und im Design? Ich bin der festen Überzeugung, dass die Tools aus der KI im Design absolut Einzug halten werden. Warum? Naja, wir haben einfach die Möglichkeit, viel mehr unterschiedliche Ansätze auszuprobieren, diese schnell auszuprobieren und auf Lösungen zu kommen, die erstmal ja nicht so wirklich denkbar sind. So ein Ansatz überlegt sich oftmals kreative Lösungen, die wir so überhaupt nicht kennen. Also ich bin da der festen Überzeugung, dass der Einzug der KI in allen Bereichen, auch im Design stattfinden wird – als Hilfsmittel, natürlich nicht alleinstehend.“

Laut Reichert (2021) sollte man sich immer vor Augen halten, was aktuell die Schwächen und Stärken der KI und des Menschen sind. Daraus würden sich dann die Anwendungsfelder ergeben, in denen es tatsächlich sinnvoll ist, diese Technologien einzusetzen.

Der zweite Diskussionspunkt in den Interviews setzte sich mit dem Thema Kreativität auseinander. Auf die Frage, ob KI Designer*innen dabei hilft kreativer zu sein, war Schmitz (2021) folgender Meinung:

„Auch das glaube ich. Wenn jemand den Auftrag gibt, ein Logo zu erstellen, gibt es ja irgendeinen Kontext. Man spricht von der Branche, wie umweltbewusst die Firma ist oder Ähnliches. Ich denke, dass diese Kriterien dabei helfen, die richtigen Farben auszuwählen oder Farben, die irgendwie diese Thematik unterstreichen. Ich glaube auch, dass eine KI schon einige Vorschläge für Logos liefern kann. Aber ich glaube nicht, dass die KI den letzten Schliff anbringen kann, um aus diesen Vorschlägen das endgültige Logo zu erstellen. Als Ideengeber, als Input, wie auch zur Auswahl von Dingen, die überhaupt thematisch passen, ist sie sehr geeignet. Aber ich glaube diesen letzten Schliff, den kann die KI dann nicht erledigen. [...] Sie ist halt eine Möglichkeit, den Prozess zu unterstützen, ihn zu begleiten, ihn vielleicht durch neue Ideen zu ergänzen, die so vorher nicht angedacht waren. Aber sie ist und bleibt ein Tool.“

Henseler (2021) äußerte sich auf die Frage, wie folgt:

„Die KI stimuliert uns. Was macht denn Kreativität aus? Entweder ist es ein deduktives oder induktives Verfahren von Denken, da sie uns durch Inspiration und Impulse unterstützt. Letztendlich entsteht das Kreative dann erstmal noch im Kopf der Entwickler. [...] Ich kann auch einem Algorithmus Kreativität beibringen, weil alles, was deduktiv oder induktiv ist, ist ja nicht neuartig. Da, wo er ins Schwitzen kommt, ist, wenn es abduktiv ist. Also wenn er wirklich etwas Neuartiges entwickeln und reflektieren muss, ob das Bedeutung hat. Das kann er nicht.“

Dies schlägt die Brücke zur Unterscheidung zwischen der kleinen und der außergewöhnlichen Kreativität (siehe Kapitel 3.1) und wirft die Frage auf, ob KI in der Lage ist, beide Formen der Kreativität zu beherrschen.

„Die KI kann nur auf Trainingsdaten antrainiert werden. Je mehr Daten ich habe, desto besser. [...] Im Prinzip kann die KI nur die kleine Kreativität erlernen. Etwas noch nie davor Dagewesenes erzeugen kann die KI momentan nicht. [...] KI muss dafür interdisziplinär und fachübergreifend denken.“ (German, 2021)

Auch Reichert (2021) ist der Auffassung, dass KI für die Beherrschung der außergewöhnlichen Kreativität mehr Kontextwissen bräuchte, was wiederum schwierig ist, dem System beizubringen. Die KI beherrscht demzufolge zwar die kleine Kreativität, die außergewöhnliche Kreativität ist jedoch zum heutigen Zeitpunkt noch dem Menschen vorbehalten.

„Was wir als Designer machen, wir navigieren mit diesem unendlichen Maß an Möglichkeiten und schaffen es, sinnvolle Lösungen zu finden, indem wir bestimmte Parameter einfach definieren. Und das ist etwas, was ein bisschen schwierig ist in einem System umzusetzen.“ (Reichert, 2021)

Aufgrund der aufwendigen Bearbeitung von Kontexten werden wohl gerade die Gestaltungsprozesse die wahrscheinlich letzten sein, die von Maschinen ersetzt werden. Zudem gibt es im Design immer mehr als nur eine gute Lösung, für die man sich entscheiden muss (Reichert, 2021).

Am Ende wurde die Mensch-Maschine-Kollaboration thematisiert. German ist hierbei der Auffassung, dass der Mensch in solch einer Zusammenarbeit auf jeden Fall höher positioniert ist als die KI:

„Eine KI ist eine Maschine, die mit Zahlen rechnet: sie bekommt Zahlen rein und spuckt Zahlen wieder aus. Sie hat keinen Bezug zur Wirklichkeit. Vor allem im Bereich der Ästhetik wird der Mensch über der KI sein. [...] Vor allem im Design ist es noch immer Design für einen Menschen, und nicht für eine KI. Der Mensch wird immer noch meiner Meinung nach, am besten beurteilen können, was dem Menschen am besten passt. Und wenn die KI etwas ausspuckt und der Designer das nicht für gut empfindet, dann wird

vermutlich der Designer mehr Recht haben als die KI. Die KI kennt nur das Konzept der Zahl und spuckt immer etwas mit Zahlen aus und mehr nicht.“ (German, 2021)

Eine ähnliche Einschätzung findet man bei Reichert (2021):

„Fachlich können sie auf dem gleichen Niveau sein oder die Maschine kann teilweise sogar höher sein, weil sie einfach die kognitiven Möglichkeiten des Menschen übersteigt. Aber wenn es dann darum geht, diesen menschlichen Aspekt, diesen Bezug in die Realität zu bringen, da fehlt der Maschine einfach der Kontext in vielen Fällen. Und die Menschlichkeit, die Sensorik, die Erfahrung des Menschen, um eine sinnvolle Entscheidung zu treffen.“

Die Frage, die sich nun stellt, ist, inwieweit sich solch ein Konzept mit einer Mensch-Maschine-Kollaboration umsetzen lässt. Ob ein derartiges Konzept Kreativität generieren und welche Bedeutung diesem beigemessen werden kann?

7 Ausarbeitung eines Konzeptes

Im Folgenden wird anhand der zuvor gewonnenen Erkenntnisse ein neuartiges Konzept vorgestellt, bei dem ein Individuum gemeinsam mit einer KI brainstormen kann. Dazu werden zunächst die Gründe erläutert, warum der Einsatz einer KI in einer Brainstorming-Session tatsächlich Sinn machen kann. Im weiteren Verlauf wird die Konzeptidee an sich beschrieben und erklärt, wie und mit welchen Datensätzen sie arbeiten würde. Abschließend wird die bisher theoretische Anwendung praktisch umgesetzt und das entsprechende Vorgehen schrittweise erklärt.

7.1 Beweggründe

Im Kapitel 5.2. wurden die „Grenzen des Brainstormings in Gruppen“ beschrieben. Diese können allerdings durch eine KI überwunden werden, da durch sie Probleme des sozialen Faulenzens, der Bewertungsangst und der Produktionsblockade schwinden. Einerseits profitiert der Mensch auf diese Weise von den Vorteilen des individuellen Brainstormings und kann seiner Kreativität in der Anonymität freien Lauf lassen, ohne andererseits aber ganz auf sich allein gestellt zu sein.

Beim Thema KI im Design überwiegen außerdem laut der Experteninterviews die Vorteile, da diese Technologien es ermöglichen, unterschiedliche neuartige Ansätze in sehr kurzer Zeit zu generieren und somit in der Lage sind, den Menschen eine ganz andere Perspektive aufzeigen zu können.

Darüber hinaus hat sich aus den Experteninterviews (siehe Kapitel 6) ergeben, dass der Mensch bei einer Mensch-Maschine-Kollaboration nach wie vor die Rolle einer Kuratorin oder eines Kurators einnimmt; der Mensch ist somit also höher positioniert als die KI. Eine weitere Erkenntnis ist, dass die KI, welche bisher bloß über die kleine Kreativität verfügt, dennoch in

der Lage ist, die außergewöhnliche Kreativität der Anwenderin oder des Anwenders zu aktivieren. Aus diesen Aussagen kann abgeleitet werden, dass die Maschine den Menschen bereichern kann, und sich aus der Kombination der Kompetenzen ein perfektes Teampplay ergibt.

7.2 Konzeptvorstellung

Die eigentliche Idee des Konzeptes besteht darin, dass eine KI die individuellen Designer*innen mithilfe einer datenbasierten Ausgabe bei der Logogestaltung unterstützt. Konkret bedeutet dies, dass ein Algorithmus firmenbezogene Daten entgegennimmt, diese interpretiert, und dem Designschaffenden abschließend mitteilt, wie das künftige Logo am wahrscheinlichsten aussehen wird. Es wird also angenommen, dass eine KI in der Lage ist, über spezifische Firmendaten einen Bezug zum bestehenden Logo herzustellen. Darüber hinaus kann sie eine Aussage über das noch nicht bestehende bzw. neu zu entwerfende Logo eines Kunden machen.

Dieses Konzept hat den Vorteil, dass die Anwender*innen erstens immer wieder die für sie wichtigen Attribute eines Logos vor Augen geführt bekommen, sie zweitens statistisch gesehen sofort den richtigen Pfad einschlagen und so Zeit einsparen können, und sie drittens ihre Energie vorrangig in die außergewöhnliche Kreativität einfließen lassen können, da ihnen die Software den vorherigen Aufwand übernimmt. Durch die datenbasierte Ausgabe wird der Designschaffende a priori nicht durch Bildmaterial beeinflusst, sondern kann weiterhin die eigene Kreativität walten und visuelle Ideen im Kopf entstehen lassen.

Menschen denken in Bildern, wobei diese Vorstellungen vorrangig auf eigene durchlebte Erfahrungen zurückzuführen sind. Sie können aber auch als eine Art Simulation wahrgenommen werden, die sich auf fiktive Ereignisse bezieht; die Rede ist von der Fantasie des Menschen. In der Psychologie und frühen Philosophie wurde der Unterschied zwischen Wahrnehmung

und (Nach-)Denken gemacht. Unter Wahrnehmung wird das Aufnehmen von Reizen und Informationen aus der Umwelt über die Sinne verstanden, während (Nach-)Denken eine geistige Tätigkeit ist, die durch das Operieren von abstrakten Begriffen eine „Sprache des Geistes“ erschafft. Diese „Sprache“ besteht wiederum aus Symbolen, durch deren Kombinationen Denken und Problemlösen ermöglicht wird (vgl. Bucher et al., 2010).

7.3 Potentieller Aufbau der Software

Grob gesehen kann ein derartiges Programm in Eingabe- und Ausgabedaten unterteilt werden, wobei zunächst das Schema des Inputs vorgestellt werden soll. Die Arbeit des Designschaffenden besteht also im Wesentlichen darin, die relevanten Eigenschaften des Kunden zu ermitteln und in die Software einzulesen. Hierbei wird zwischen objektiven und subjektiven Attributen des Kunden unterschieden; ein Beispiel für erstere wären Fakten wie etwa die „Branche“ oder das „Geschäftsvolumen“. Zu den subjektiven Attributen zählen Eigenschaften wie die persönliche Wahrnehmung des Kunden, etwa die „Offenheit seines Auftretens“. Es gibt nicht unbedingt eine scharfe Grenze zwischen all diesen Zuordnungen; so könnten „weiche Faktoren“ wie beispielsweise die „Risikobereitschaft“ sowohl über eine persönliche Einschätzung als auch über eine entsprechende Statistik zugewiesen werden, wobei letztere auch wiederum auf subjektiven Faktoren basieren könnte. Obwohl diese Voreingenommenheit der Datensätze in vielen KI-Anwendungen Probleme bereitet, kann sie dem Algorithmus in diesem Fall helfen, auf die*den Anwender*in maßgeschneiderte Aussagen zu treffen. Dies setzt allerdings voraus, dass jede*r Benutzer*in zunächst individuell diverse Datensätze bewerten muss. Im Folgenden werden einige möglich Eingabedaten vorgestellt, wie z.B die Tabelle der objektiven Attribute:

→ Branche	→ Kapitel/ Umsatz
→ Mitarbeiterzahl	→ Anzahl der Standorte
→ Alter der Firma/ Gründungsjahr	→ Geografische Lage

Tabelle der subjektiven Attribute:

→ Konservative	→ Empathie
Unternehmensstruktur	→ Risikobereitschaft
→ Innovationsgeist	→ Leidenschaft
→ Zukunftsorientiert	→ Soziales Engagement
→ Technologieoffenheit	→ Geschlechterfreundlich
→ Anpassungsfähigkeit	→ Bescheidenheit
→ Ökologische Nachhaltigkeit	→ Team Work

Die Ausgabe definiert sich über die Beschreibung des Logos. Hier könnten sowohl anwenderspezifische als auch allgemein anerkannte Attribute verwendet werden. Foroudi et al. (2017) konzentrieren sich auf vier Dimensionen des Logos: Schriftbild, Design, Farbe und Firmenname; wobei alle miteinander verbunden sind. Obwohl ein Firmenlogo im Design generell als ein mehrdimensionales Konstrukt mehrerer Komponenten verstanden wird, sollte man sich für die praktische Anwendbarkeit auf die essenziellen Kernbestandteile beschränken. Mögliche Daten für eine Ausgabe werden nachfolgend aufgelistet:

- Farbe/ Farbton
- Schrift: z.B. über Schriftart oder mit/ohne Serifen
- Logotyp: z.B. über Wortmarke/ Wort-Bild-Marke
- Form: z.B. über Rundheit der Designelemente

Die Form und Auslegung der jeweiligen Daten unterliegen im Nachhinein der Komplexität des Programmes. So könnten Attribute wie etwa „Nachhaltigkeit“ sowohl über einen Prozentsatz als auch über eine diskrete Ja-Nein-Zuweisung beschrieben werden. Für Kategorien wie „Branchen“ könnten gröbere Übermengen festgelegt werden, und für numerische Werte, wie die „Mitarbeiterzahl“ Intervalle mit festdefinierten Grenzen. Weitere Faktoren, selbst sehr individuelle Interpretationen, können die Effizienz des Modelles weiter verbessern, insoweit sie nicht voneinander abhängig sind. Allerdings wird

dann unter Umständen im Vorfeld auch ein größeres Datenset benötigt, um den Algorithmus zu trainieren, und ihn die internen Zusammenhänge erkennen zu lassen.

7.4 Vereinfachte Umsetzung

Um die reelle Machbarkeit des Konzeptes zu untermauern, wird im Folgenden eine praktische Umsetzung unternommen. Das Modell wird hierbei von der Komplexität her stark vereinfacht, um eine vorläufige Fertigstellung im Rahmen dieser Arbeit zu gewährleisten. Zur Implementierung des entsprechenden Codes wurde auf die Hilfe eines Softwareingenieurs zurückgegriffen.

7.4.1 Software und Hardware

Bei der Programmierung wurde die Sprache Python in der Version 3.9.7 benutzt. Die Umsetzung fand statt in der Entwicklungsumgebung Jupyter Notebook (v6.4.6) über die Python-Distribution Anaconda. Bei den Paketen außerhalb der Standardbibliotheken wurden matplotlib (v3.4.3), pandas (v1.3.4), numpy (v1.21.2) sowie scikit-learn (v1.0.1) (vgl. Blondel et al., 2011 & Blondel et al., 2013) für die ML-Umsetzung verwendet. Als Hardware fand das MacBook Pro (14“, 2021) mit einem M1 Pro – Apple-Chip M1 Pro Verwendung, wobei auf eine Gesamtanzahl von 10 Kernen (8 Leistung und 2 Effizienz) und insgesamt 32 GB Arbeitsspeicher zurückgegriffen werden konnte.

7.4.2 Datenerhebung

Als Grundlage für die Firmendaten wurde ein Datensatz von Buchwald et al. genommen, in dem die 100 erfolgreichsten Firmen Deutschlands der Jahre 1972 bis 2018 aufgelistet sind. Für die vorliegende Umsetzung wurde sich auf das Jahr 2018 beschränkt. Eine genauere Erläuterung aller Faktoren findet

sich in der entsprechenden Ausarbeitung (vgl. Buchwald et al., 2020). Dieser vor allem objektive Datensatz wurde im Nachgang noch händisch um das Gründungsjahr erweitert.

Als „weicher Faktor“ zur Beschreibung der Firma wurde „Nachhaltigkeit“ ausgewählt. In einem komplexeren Modell könnte dieses Attribut über einen Prozentsatz dargestellt werden, allerdings wird in diesem Modell der Einfachheit halber lediglich eine diskrete, binäre Zuordnung durchgeführt. So erhält eine nachhaltige Firma einen Wert von (1), und eine nicht nachhaltige einen Wert von (0). Dieser Wert basiert auf einer Statistik aus dem Jahre 2018 basiert, bei der die nachhaltigsten Firmen aufgrund ihres CSR-Reporting aufgeführt sind (vgl. Institut für ökologische Wirtschaftsforschung GmbH & future e.V., 2019).




Abbildung 20: Ranking der Unternehmen mit der besten Nachhaltigkeitsberichterstattung nach ihrem CSR-Reporting im Jahr 2018.

Unter CSR (Corporate Social Responsibility) versteht man ein dynamisches Konzept der Nachhaltigkeit eines Unternehmens, welches nicht nur die ökologische und ökonomische Nachhaltigkeit, sondern auch die soziale Verantwortung umfasst (vgl. Bassen et al., 2005). Dahingehend wurde die stark vereinfachte Annahme getroffen, alle Firmen, die in der letztgenannten Statistik vorkommen, mit dem Wert (1) zu versehen, der für die Nachhaltigkeit steht.

Die Zuweisung der Ausgabe-Variablen zur Bewertung der Logos der entsprechenden 100 Firmen erfolgte auf rein subjektiver Basis. Hier wurde festgelegt, insbesondere die Faktoren „Farbe“, „Schrift“ und „Logotyp“ zu bestimmen. In einem komplexeren Modell könnte die Farbe über eine genauere Gradangabe im Farbkreis beschrieben werden. Hier wiederum der Einfachheit halber wurde sich für eine 0-1-Kodierung entschieden, wobei (1) für ein helles und (0) für ein dunkles Logo steht. Analog dazu wurde vereinfacht für die anderen Faktoren angenommen, dass die Schrift bei (1) über Serifen verfügt und bei (0) serifenlos ist, und dass es sich bei einer (1) um ein Wortmarken-Logo beziehungsweise bei (0) nur um ein Wortmarken-Logo handelt. Aufgrund dieser diskreten Zuordnungen konnte das Problem vom potentiellen Multilabel-Regression auf ein Multilabel-Klassifizierungsproblem runtergebrochen werden.

7.4.3 Preprocessing

Nach der Datenerhebung geht es vorrangig darum, die vorliegenden Rohdaten aufzubereiten und in einen für das ML-Modell brauchbaren Zustand zu transformieren. Um die Reproduzierbarkeit des Vorgehens zu gewährleisten, sind alle Modifizierungen der Daten im Code niedergeschrieben, und immer wieder nur auf die gleichen Rohdaten angewendet worden. Der erste Schritt bestand darin, lediglich die für diese Anwendung relevanten Attribute zu ermitteln. Der Datensatz ist dahingehend in die folgenden Eingabe- respektive Ausgabedaten eingeteilt worden:

Eingabe:	Ausgabe:
→ Anzahl der Beschäftigten	→ Farbe (Kontrast)
→ Gründungsjahr	→ Serifen
→ Geschäftsvolumen	→ (Wort-)Bildmarke
→ Branche	
→ Nachhaltigkeit	

Eine Visualisierung der Daten (siehe Abbildung 21) verdeutlicht die ungleiche Verteilung über die unterschiedlichen Attribute hinweg.




Abbildung 21: Ungleiche Verteilung der Rohdaten.

Aufgrund dessen wurde entschieden, die Faktoren „Beschäftigte“, „Geschäftsvolumen“ und „Gründungsjahr“ mittels „Binning“ in vier gleichgroße Intervalle aufzuteilen. Das einzige kategorische Attribut ist die „Branche“, welche wie in Abbildung 21 ersichtlich in die folgenden sechs Gewerbe unterteilt ist: Manufacturing (Produktion/Herstellung), Services (Dienstleistung), Banking (Bankwesen), Trade (Handwerk), Insurance (Versicherung), Construction (Baugewerbe).

ML-Modelle tun sich in der Regel schwer damit, Textdaten zu interpretieren, weshalb hier alle Einträge in eine binäre Form konvertiert werden (One Hot Encoding). Weiterhin werden fehlende, numerische Werte systematisch durch die Mittelwerte der jeweiligen Kategorie ersetzt (StandardScaler); allerdings war der verwendete Datensatz ohnehin vollständig. Abbildung 22 zeigt, wie ein beispielhafter Datensatz vor und nach dem Preprocessing aussieht.




Abbildung 22: Vor und nach dem Preprocessing.

Die konsequente Durchführung all der einzelnen Schritte wie etwa dem Binning und der Standardskalierung wird in der Branche „Pipeline“ genannt. Diese Pipeline könnte allerdings auch anders definiert werden; so hätte bei den Zahlenwerten auch die Abweichung zum Mittelwert anstelle eines One Hot Encodings herangezogen werden können, allerdings lieferten die verwendeten Konventionen bei ersten Testläufen die besseren Ergebnisse.

7.4.4 Training & Validierung

Nach dem Preprocessing sind die Daten erstmals bereit für das eigentliche Training. Um sich zunächst eine grobe Übersicht über die Effizienz diverser Algorithmen zu verschaffen, werden die folgenden vier Modelle mit ihren Standard-Einstellungen verwendet: MLPClassifier (Multi-Layer Perceptron Classifier), KNeighborsClassifier, RandomForestClassifier und DecisionTreeClassifier. Da die letzten drei eher nicht für eine Multilabel-Ausgabe konzipiert sind, werden sie noch in einen sogenannten MultiOutputClassifier eingebettet. Um zu verhindern, dass sich der Algorithmus lediglich darin verbessert, die ihm bekannten Daten abzubilden, wird der eigentliche Datensatz im Vorfeld in ein Trainings- und ein (kleineres) Testdatenset unterteilt.

Zur Bewertung des Modells können unterschiedliche Metriken („Scorers“) verwendet werden. Für die vorliegende Problemstellung fiel die Wahl darauf, den sogenannten „f1-score“ zu verwenden, der eigentlich als ein harmonisches Mittel zwischen den Metriken „precision“ und „recall“ interpretiert werden kann. Zur Mittelung der Werte wurde die Option „weighted“ verwendet. Ob diese Parameterkombination die tatsächlichen Bedingungen in einer realen Anwendung am ehesten wiedergibt, beziehungsweise bewertet, müsste in weiterführenden Untersuchungen geklärt werden. Es haben sich folgende Scores ergeben:

- MLPClassifier-Score: 36.95%
- KNeighborsClassifier-Score: 50.06%
- RandomForestClassifier-Score: 42.15%
- DecisionTreeClassifier-Score: 39.99%

Für die vorliegende Datenreihe schnitt der KNeighborsClassifier am besten ab. Beim MLPClassifier erhielt der Anwender zudem die Warnung, dass der Algorithmus nach den standardmäßigen 200 Iterationsschritten noch nicht konvergiert sei; somit ist der ermittelte Score mit Vorsicht zu genießen.

Im Folgenden galt es nun einerseits abzuwägen, wie stark die Ausgaben der einzelnen Algorithmen je nach Datenlage schwanken, und andererseits herauszufinden, mit welchen Hyperparametern das Modell optimiert werden kann (Hyperparameter Tuning). Als Hyperparameter werden hierbei die Einstellungsoptionen der ML-Modelle, wie beispielsweise die Anzahl der Neuronen in einer Schicht eines neuronalen Netzwerkes bezeichnet. Um diese beiden Anforderungen gleichzeitig zu erfüllen, wurde anschließend eine sogenannte „Nested cross-validation (mit) GridSearch“ durchgeführt. Beim GridSearch geht es darum, ein Modell mit unterschiedlichen Hyperparametern zu trainieren, und sich anschließend die besten Einstellungen gemäß zuvor festgelegter Metrik ausgeben zu lassen. Bei der Cross-validation wird ein Modell mit den gleichen Hyperparametern trainiert, allerdings für unterschiedliche Anordnungen der Test- und Trainingssets. Die hieraus resultierenden Ergebnisse werden gemittelt und ermöglichen eine Aussage über die Stabilität der Ausgaben. Wie es der Name bereits vermuten lässt, handelt es sich bei der „Nested cross-validation (mit) GridSearch“ um eine Verschachtelung der beiden Verfahren.




Abbildung 23: Ergebnisse der Modelle.

Abbildung 23 zeigt die Ergebnisse der einzelnen Evaluierungen, die insgesamt ungefähr 51 Sekunden für die vier Modelle dauerten. Hierbei fällt auf, dass bis auf den KNeighborsClassifiers, für alle Modelle bessere Ergebnisse (siehe Best score) erzielt werden konnten, als zuvor bei der Verwendung der Standardwerte. Für letzteren müsste gegebenenfalls noch genauer untersucht werden, ob und inwiefern andere Hyperparameter die Performance steigern würden. Als bestes Modell stellt sich der MLPClassifier heraus, der an sich ein mehrschichtiges neuronales Netz darstellt. In diesem Fall liefert eine Konfiguration mit zwei Schichten mit jeweils 10 Neuronen pro Schicht das beste Ergebnis, wodurch das Modell je nach Definition bereits in den Bereich des Deep-Learnings eingegliedert werden kann. Neben dem höchsten „Best Score“ liefert dieses Modell mit den entsprechenden Konfigurationen auch die besten Mittelwerte mit den geringsten Standardabweichungen, weshalb sich im weiteren Verlauf lediglich auf diesen Klassifizierer beschränkt wird.




Abbildung 24: Pipeline für MLPClassifier.

In Abbildung 24 ist einmal schematisch dargestellt, wie die Pipeline für den MLPClassifier im Rahmen einer GridSearch aussieht.

7.4.5 Vorhersage (Prediction)

Nachdem sich in den vorangehenden Schritten für ein Modell inklusive „optimaler“ Hyperparameter entschieden worden war, galt es nun das Modell für einen neuen, unbekannten Datenpunkt anzuwenden. Die Anforderung an diesen Datenpunkt ist allgemein, dass er die gleiche Struktur zugrunde legt wie die Eingabevektoren aus den Rohdaten.

BRANCH	=	'manufacturing'
EMPLOYMENT	=	174663.0
FOUNDING_YEAR	=	1998
BUSINESS_VOLUME	=	113590.0
SUSTAINABILITY	=	0

Abbildung 25: Prediction.

Abbildung 25 zeigt beispielhaft, wie ein solcher Input aussehen könnte. Nach Anwendung der Preprocessing-Pipeline auf ebendiesen Datenpunkt wurde die Ausgabe an das zuvor trainierte ML-Modell übergeben, wobei abschließend das Ergebnis gemäß Abbildung 26 herauskam.

7.2 Output for MLPClassifier
Resultat: {'contrast': 0, 'serifs': 0, 'word_fig_mark': 1}

Abbildung 26: Attribute des zukünftigen Logos.

Aus dieser Information kann entnommen werden, dass ein Logo für eine Firma entsprechend der Beschreibung aus Abbildung 26 dunkel (0), und serifenlos (0), und eine Wort-Bild-Marke (1) sein sollte. An dieser Stelle sei jedoch angemerkt, dass der Klassifizierer lediglich auf eine Genauigkeit von etwa 50% kam, und diese Aussage im Rahmen der verwendeten Bewertungsmetrik daher nur in der Hälfte der Fälle zutreffend wäre.

7.5 Bewertung des Konzeptes

Anhand der vereinfachten Umsetzung wird ersichtlich, dass die vorgestellte Konzeptidee Potential birgt und durchaus funktionieren kann. Es muss jedoch erneut betont werden, dass die erzielte Genauigkeit der Modelle noch weit von den idealen 100% entfernt liegt. Diese moderate Performance ist aber vorrangig dem Umstand geschuldet, dass die verwendete Datenmenge viel zu klein war. Hinzu kommt, dass die Daten sehr ungleichmäßig aufgeteilt waren und teilweise nur eine geringe Varietät aufzeigten. Damit das Modell seine Aussagen verbessern kann, müsste in künftigen Projekten also eine weitaus größere Datenreihe verwendet werden, bei der die unterschiedlichen Attribute in einem ausgewogeneren Maße vorkämen.

Zudem stellte es sich als durchaus schwierig heraus, die subjektiven bzw. weichen Fakten einer Firma festzulegen. Hierbei wäre es vermutlich notwendig gewesen, zusätzlich auf eine andere KI zurückzugreifen, die solche Firmenbewertungen durchführt, indem sie das Internet oder andere Datensätze durchforstet und auswertet. Ein weiterer Punkt ist, dass der Trainingsatz zweifelsohne «biased», also voreingenommen ist; immerhin ist er von einem Menschen entsprechend seiner persönlichen Auffassung hinsichtlich der einzelnen Attribute erstellt worden. Dies hat zur Folge, dass die KI die Subjektivität der Daten zu den Endresultaten hin transportiert. Hier stellt dieser Fakt allerdings kein Problem dar, weil das Resultat ja sowieso gezielt auf dem Geschmack der Erstellerin oder des Erstellers angepasst werden soll. Beziehungsweise an die Bedürfnisse eines ganzen Designerteams, wenn die Generierung der Trainingsdaten kollektiv im Team erfolgt wäre.

8 Diskussion und Ausblick

Mit Hilfe der Literaturrecherche, der vier durchgeführten Experteninterviews und der vereinfachten Umsetzung des Konzeptes wird ersichtlich, dass KI durchaus in der Lage ist, Designer*innen dabei zu helfen, kreativer zu sein. Die aktuellen Beispiele der KK zeigten anfangs, dass kreative Arbeit gemeinsam mit KI schon längst Realität ist. Darüber hinaus gibt es bereits einige Anwendungsszenarien mit Brainstorming, wo KI eine zentrale Rolle für die Generierung von Kreativität spielt. Die abschließende Konzeptvorstellung hat zudem gezeigt, dass es sich auch lohnt, sich Gedanken über doch sehr individuelle KI-Anwendungen zu machen, da die Effizienz bereits mit einem mäßigen Voraufwand gesteigert werden kann.

8.1 Menschliche und Maschinelle Kreativität

Im Verlauf der Arbeit wurde immer wieder der Unterschied beider Kreativitätsformen, der kleinen und der außergewöhnlichen Kreativität thematisiert. Dabei spielt die Unterscheidung von menschlicher und maschineller Kreativität letztendlich eine wichtige Rolle. Bei der menschlichen Kreativität stellt der „kreative Sprung“, aus dem, aus unerklärlichen Gründen, etwas komplett Neues entstehen kann, ein Phänomen dar, wozu die KI derzeit noch nicht in der Lage ist. Insofern ist die Beherrschung beider Formen der Kreativität, der kleinen Kreativität und der außergewöhnlichen Kreativität bis dato dem Menschen vorbehalten. KI kann mit der Fähigkeit der kleinen Kreativität auch etwas Neues erschaffen und mit ihrem datenbasierten Wissen eine komplett neue Perspektive zu gewissen Themen entwickeln – sie ist somit auch kreativ. Jedoch erreicht sie bis heute nicht das menschliche Maß an außergewöhnlicher Kreativität, was Boden auch als transformative Kreativität beschreibt (siehe Kapitel 3.1).

Es kann also festgehalten werden, dass beide, der Mensch und die KI, kreativ sind, da beide Akteure dazu fähig sind, etwas zu „erschaffen“. Nur finden diese Arten von Kreativität auf unterschiedlichen Ebenen statt und sind nicht miteinander vergleichbar.

8.2 Wicked problems und das Treffen von Entscheidungen

Auch im Designprozess kann KI in den unterschiedlichen Phasen interagieren, eigene Entscheidungen treffen und neuartige Ideen vorschlagen. Doch letztendlich stößt die Maschine, ebenso wie der Mensch, auf *wicked problems* und befindet sich in einem Raum mit unendlichen Gestaltungsmöglichkeiten.

In Kapitel 3.2 wurden bereits die 10 Merkmale eines *wicked problems* aufgelistet. Eine dieser Eigenschaften besagt, dass ein *wicked problem* nur gut oder schlecht, aber nicht wahr oder falsch sein kann. Allein bei diesem Merkmal stößt die KI bereits an ihre Grenze, weil es sehr schwer ist, diese Eigenschaft in die Maschine einzuprogrammieren. Menschen besitzen die Fähigkeit solche Problemen durch Intuition zu lösen, indem sie unzählige Entscheidungen treffen und Parameter bestimmen. Diese intuitive Art des Entscheidens ist sehr schwer auf eine KI übertragbar und daher bis heute nicht realisierbar. Heute braucht es am Ende immer einen Menschen, der den letzten Schliff ausübt oder die letzten Entscheidungen trifft.

8.3 Mensch-Maschine-Kollaboration

Um die Frage beantworten zu können, wie eine Mensch-Maschine-Kollaboration aussehen könnte, sollten immer wieder aufs Neue die Stärken und Schwächen jeweils des Menschen und der Maschine evaluiert werden. In Zukunft kann das, was heute unvorstellbar ist, Realität werden. Weiterhin gilt es, die Bereitschaft der Gesellschaft zu diesem Thema und dessen Entwicklungen konstant zu analysieren, um ggf. Wissenslücken zu schließen oder auch mögliche Konzepte zu überdenken. Aktuell liegen die Stärken der KI, die gleichzeitig die Schwächen des Menschen darstellen, u.a. in der Verarbeitung großer Datenmengen. Eine KI kann sehr viel Wissen in sehr kurzer Zeit generieren und diesbezüglich eine objektive globale Meinung entwickeln. Da können die kognitiven Fähigkeiten des Menschen nicht mithalten. Der Mensch ist im Gegensatz zur aktuellen Entwicklung der KI in der Lage, sich selbst zu reflektieren, als Individuum zu erkennen und auch den Kreativprozess bewusst zu beobachten. Z.B ist Nicht-Wissen ein unerlässlicher Bestandteil des Kreativprozesses, also jene Phase, wo der Kreativschaffende das Gefühl hat, nie eine Lösung zu finden. Dieses Nicht-Wissen auszuhalten ist notwendig, um letztlich zur Idee (zum Aha-Moment) zu kommen. Hierbei gibt es nicht die Möglichkeit, sich an bekannten Gegebenheiten zu orientieren. Dieses unerklärliche Vorgehen ist also nicht für eine Maschine ausgelegt. Somit kann der Mensch durch das Phänomen des „kreativen Sprungs“ ein höheres Maß an Kreativität erreichen als die KI.

Hinzu kommt die Schwierigkeit, einer KI die in Kapitel 2 aufgelisteten sieben Formen der Intelligenz aus der MI-Theorie beizubringen. Es ist bzw. wird durchaus möglich sein, verschiedene Aspekte der einzelnen Intelligenzen auf die KI zu übertragen, aber alle Formen vollständig mit einer KI umzusetzen, ist unmöglich. Der Mensch kann mit Hilfe seiner Intuition, seiner Empathie, seiner menschlichen Erfahrungen, seinem Kontextwissen und seiner individuellen Art mit Problemen umzugehen viel besser bewerten,

ob der jeweilige Output sinnvoll ist beziehungsweise einschätzen, was in der jeweiligen Situation passender ist. Eine Mensch-Maschine-Kollaboration macht durchaus Sinn, weil die Schwächen des einen Parts durch die Stärken des anderen ausgeglichen werden können. Im Designkontext kann der Mensch somit nach heutigem Stand der Technik die Rolle des Creative Directors einnehmen, sich von der KI und Daten inspirieren und doch der eigenen Kreativität freien Lauf lassen. Durch dieses Zusammenspiel entstehen viele originelle und innovative Ideen. Infolgedessen kann die KI als ein unterstützender Teamplayer gesehen werden, der mehr als ein Werkzeug ist, weil er eigenen Input generiert. Allerdings kann KI bis heute nicht, wie ein vollständig ausgebildeter Designschaffender agieren.

8.4 Ausblick

Schlussfolgernd kann daher festgehalten werden, dass Designerschaffende sich nicht nur, wie bis jetzt üblich, auf Hypothesen stützen, die sich an ihren bisherigen Erfahrungen beziehungsweise an den Bedürfnissen der Nutzenden orientieren. Sie haben vielmehr mit Hilfe von KI nun auch Möglichkeiten, mit datenbasierten und sogenannten intelligenten Hypothesen zu arbeiten.

Dies bedeutet nicht, dass KI-unterstützte und nicht KI-unterstützte Prozesse einander ausschließen. Ganz im Gegenteil: Im kreativen Designprozess kann jederzeit entschieden werden, ob der Vorschlag der KI umgesetzt wird oder nicht. Auch wenn dieser Output der KI nur der Inspiration dient, hat sie doch auf eine Art den Prozess der Ideenfindung unterstützt und schließlich dem*der Designer*in dabei geholfen kreativer zu sein. Dennoch liegt es immer noch in der Hand des kreativen Menschen, wie er mit den Informationen der KI umgeht oder ob er den Vorteil eines Zusammenspiels überhaupt nutzen will. Konkret lässt sich demzufolge feststellen, dass die kreative Welt in einem rasanten, unaufhaltbaren Veränderungsprozess steckt.

In Zukunft werden uns noch deutlich mehr Komplexität und Geschwindigkeit erwarten, was nicht zwangsläufig bedeutet, dass Kreativität verloren geht, sondern diese vielmehr noch angetrieben wird. Eine solche Mensch-Maschine-Kollaboration ist heute schon Gegenwart – in Zukunft wird diese Beziehung noch enger und notwendiger. Kreative haben auf diese Weise die Möglichkeit, von Problemlöser*innen zu Problembeschreiber*innen zu werden, indem KI und Mensch gemeinsam nach Lösungen suchen und sich somit gegenseitig die Bälle zuwerfen. Ich bin der Meinung, dass auf diese Weise KI die Rollen der Designer*innen nicht verdrängt, sondern eher die Arbeitsweisen wesentlich verändern wird.

Hierbei wäre noch wichtig anzumerken, dass es notwendig ist, die Entwicklung der KI nicht nur unter wirtschaftlichen Aspekten zu betrachten. Vielmehr sollte in Zukunft vermehrt darüber nachgedacht werden, inwiefern KI dem Menschen dabei helfen kann, aus den menschlichen linearen Denkmustern ausubrechen. Darüber hinaus sollte darüber reflektiert werden, inwieweit die Gesellschaft von der objektiven globalen Perspektive der KI profitieren könnte, um so neuartige Schlüsse und Lösungen zu finden, sowohl in der Kreativbranche als auch in anderen Bereichen. Fest steht: KI wird als ein mächtiges Instrument die Gesellschaft nachhaltig verändern. Eventuell kann KI die Herausforderungen, die durch das BANI-Modell beschrieben werden, unterstützen. Um dem rasanten Wandel kreativ zu begegnen, neue Lösungen und passende Strategien zu finden, braucht es laut BANI Resilienz, Empathie, Kontext und Intuition. Bis dato sind dies alles Eigenschaften des Menschen. Ist die Zusammenarbeit von KI und Mensch folglich die Lösung? Oder geht es darum, in Bezug auf unbekannte Lösungen für eine unbekannte Zukunft, gerade jener Kraft zu vertrauen, welche die KI überhaupt erst erschaffen hat: der menschlichen Kreativität.

Register

Literaturverzeichnis

Bagozzi, R. P., Davis, F. D., & Warshaw, P. R. (1989). *User Acceptance of Computer Technology: A Comparison of Two Theoretical Models*. Management Science. Vol. 35, No. 8. <https://doi.org/10.1287/mnsc.35.8.982>

Bassen, A., Jastram, S., & Meyer, K. (2005). *Corporate Social Responsibility: Eine Begriffserläuterung*. Zeitschrift für Wirtschafts- und Unternehmensethik. Vol. 6, No. 2. <https://doi.org/10.5771/1439-880x-2005-2-231>

Becker, J., Ebert, H., & Pastoors, S. (2017). *Praxishandbuch berufliche Schlüsselkompetenzen: 50 Handlungskompetenzen für Ausbildung, Studium und Beruf*. Berlin, Deutschland: Springer-Verlag GmbH.

Beverland, M. B., Bhatti, S. H., Micheli, P., Mura, M., & Wilner, S. J. S. (2018). *Doing Design Thinking: Conceptual Review, Synthesis, and Research Agenda*. Journal of Product Innovation Management. Vol. 36, No. 2. <https://doi.org/10.1111/jpim.12466>

Bitkom e.V. (2017). *Künstliche Intelligenz: Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung*. o. A.

Blondel, M., Brucher, M., Courneau, D., Dubourg, V., Duchesnay, E., Gramfort, A., Grisel, O., Michel, V., Passos, A., Pedregosa, F., Perrot, M., Prettenhofer, P., Thirion, B., Vanderplas, J., Varoquaux, G., & Weiss, R. (2011). *Scikit-learn: Machine Learning in Python*. Journal of Machine Learning Research. Vol 12. 2825-2830.

Blondel, M., Brucher, M., Courneau, D., Dubourg, V., Duchesnay, E., Gramfort, A., Grisel, O., Michel, V., Passos, A., Pedregosa, F., Perrot, M., Prettenhofer, P., Thirion, B., Vanderplas, J., Varoquaux, G., & Weiss, R. (2013). *API design for machine learning software: experiences from the scikit-learn project*. ECML PKDD Workshop: Languages for Data Mining and Machine Learning. 108-122.

Boddy, C. (2012). *The Nominal Group Technique: an aid to Brainstorming ideas in research*. Emerald Group Publishing Limited. Qualitative Market Research: An International Journal. Vol. 15, No. 1. 6-18. <https://doi.org/10.1108/13522751211191964>

Boden, M. A. (1998). *Artificial Intelligence*. Amsterdam, Niederlande: Elsevier BV.

Boden, M.A. (2004). *The Creative Mind. Myths and mechanism*. London, England: Taylor & Francis Ltd.

Briggs, R. O., De Vreede, G.-J., & Santanen E. L. (2004). *Casual Relationships in Creative Problem Solving: Comparing Facilitation Interventions for Ideation*. Journal of Management Information Systems. 167-198. <https://doi.org/10.1080/07421222.2004.11045783>

Bröckling, U. (2004). *Über Kreativität: Ein Brainstorming*. o. A.

Brown, S., Gray, D., & Macanufu, J. (2011). *Gamestorming: Ein Praxisbuch für Querdenker, Moderatoren und Innovatoren*. Köln, Deutschland: O'Reilly Vlg. GmbH & Co.

Bucher, L., Hamburger, K., & Knauff, M. (2010). *Geistesblitz und Neuronendonner: Intuition, Kreativität und Phantasie*. Paderborn, Deutschland: Brill mentis.

Buchwald, A., Hotten, R., Rothbauer, J., & Weche J. P. (2020). *The Top 100 Companies Panel Database*. Journal of Economics and Statistics. Vol. 241, No. 5-6. <https://doi.org/10.1515/jbnst-2020-0003>

Bundesministerium für Wirtschaft und Energie (2019). *Gestaltungsmaschine: Künstliche Intelligenz trifft Kultur- und Kreativwirtschaft*. o. A.

Buonamici, F., Carfagni, M., Furferi, R., Governi, L., & Volpe, Y. (2020). *Generative Design: An Explorative Study. Computer-Aided Design and Applications*. Vol. 18, No. 1. <https://doi.org/10.14733/cadaps.2021.144-155>

Buxmann, P., & Schmidt, H. (2021). *Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg*. Berlin, Deutschland: Springer Gabler.

Buxmann, P., Eitle, V., & Welsch, A. (2018). *Maschinelles Lernen: Grundlagen und betriebswirtschaftliche Anwendungspotenziale am Beispiel von Kundenbindungsprozessen*. Wiesbaden, Deutschland: Springer Fachmedien Wiesbaden GmbH.

Carvalho, M., & Cerejo, J. (2019). *Design After the Rise of AI-Driven Services: Learning from Literature Review*. DIGICOM 3rd International Conference on Digital Design & Communication.

Cautela, M., Dell’Era, C., Gastaldi, L., & Mortati, M. (2019). *The impact of Artificial Intelligence on Design Thinking practice: Insights from the Ecosystem of Startups*. São Leopoldo, Brasilien: Strategic Design Research Journal.

Connolly, T., Dennis A. R., Valancich, J. S., Wynne, B., E. (1996). *Process Structuring in Electronic Brainstorming*. Information Systems Research. 268-277. <https://doi.org/10.1287/isre.7.2.268>

D’Onofrio, S., & Portmann, E. (2020). *Cognitive Computing: Theorie, Technik und Praxis*. Wiesbaden, Deutschland: Springer Fachmedien Wiesbaden.

Diehl, M., & Stroebe, W. (1987). *Productivity Loss in Brainstorming Groups: Toward the Solution of a Riddle*. Journal of Personality and Social Psychology. Vol. 53, No. 3. <https://doi.org/10.1037/0022-3514.53.3.497>

Dingli, S. (2009). *Thinking outside the box: Edward de Bono’s lateral thinking*. In S. Moger, T. Rickards & M. A. Runco (Hrsg.), *The Routledge Companion to Creativity*. USA, New York: Routledge Companions.

Foroudi, P., Gupta, S., & Melewar, T. C. (2017). *Corporate Logo: History, Definition, and Components*. International Studies of Management & Organization. 176-196. <https://doi.org/10.1080/00208825.2017.1256166>

Furnham, A., & Yazdanpanahi, T. (1995). *Personality differences and group versus individual brainstorming*. Pergamon. Vol. 19, No. 1. [https://doi.org/10.1016/0191-8869\(95\)00009-u](https://doi.org/10.1016/0191-8869(95)00009-u)

Furnham, A. (2000). *The Brainstorming Myth*. Business Strategy Review. Vol. 11, No. 4. 21-28. <https://doi.org/10.1111/1467-8616.00154>

Géron, A. (2018). *Machine Learning mit Scikit-Learn & TensorFlow: Konzepte, Tools und Techniken für intelligente Systeme*. Heidelberg, Deutschland: dpunkt.verlag GmbH.

Geschka, H., & Lantelme, G. (2005). *Kreativitätstechniken*. In S. Albers & O. Gassmann (Hrsg.), *Technologie- und Innovationsmanagement*. Wiesbaden, Deutschland: Gabler Verlag.

Hecker, D., & Paaß, G. (2020). *Künstliche Intelligenz: Was steckt hinter der Technologie der Zukunft*. Wiesbaden, Deutschland: Springer Fachmedien Wiesbaden.

IUBH Internationale Hochschule (2021). *Artificial Intelligence: Die Zukunft künstlicher Intelligenz in deutschen Unternehmen* (Trendstudie 2021). o. A.

Kelley, D. R., Rinn, J., & Snoek, J. (2015). *Basset: Learning the regulatory code of the accessible genome with deep convolutional neural networks*. Cold Spring Harbor Laboratory. <https://doi.org/10.1101/028399>

Krasadakis, G. (2020). *The Innovation Mode: How to Transform Your Organization into an Innovation Powerhouse*. Cham, Schweiz: Springer Nature Switzerland AG.

Krish, S. (2011). *A practical generative design method*. Computer Aided Design. Amsterdam, Niederlande: Elsevier.

McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. E. (2006). *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. AI Magazine. <https://doi.org/10.1609/aimag.v27i4.1904>

Misselhorn, C. (2018). *Grundfragen der Maschinenethik*. Ditzingen, Deutschland: Philipp Reclam jun. GmbH & Co. KG.

Murphy, K. (2012). *Machine Learning: A Probabilistic Perspective*. London, England: MIT Press.

Nijstad, B. A., & Stroebe, W. (2004). *Warum Brainstorming in Gruppen Kreativität vermindert: Eine kognitive Theorie der Leistungsverluste beim Brainstorming*. Psychologische Rundschau. 2-10. <https://doi.org/10.1026/0033-3042.55.1.2>

Nöllke, M. (2020). *Kreativitätstechniken*. Freiburg im Breisgau: Haufe Lexware GmbH.

Norvig, P., & Russel, S. (2021). *Artificial Intelligence: A Modern Approach*. London, England: Pearson Education.

Otte, R. (2021). *Allgemeinbildung Künstliche Intelligenz: Risiko und Chance für Dummies*. Weinheim, Deutschland: Wiley-VCH GmbH.

Patten, T. (2019). *Eine neue Republik des Herzens: Ein Leitfaden für spirituellen Aktivismus*. Palma de Mallorca, Spanien: Phänomen-Verlag.

Perleth, C. (2008). *Intelligenz und Kreativität*. In M. Hasselhorn, & W. Schneider (Hrsg.), *Handbuch der Pädagogischen Psychologie*. Göttingen, Deutschland: Hogrefe Verlag GmbH.

Rittel, H. W. J., & Webber, M. M. (1973). *Dilemmas in a general theory of planning*. Policy Sciences. Vol. 4, No. 2. <https://doi.org/10.1007/bf01405730>

Robra-Bissantz, S., Siemon, D., & Strohmann, T. (2017). *brAInstorm: Intelligent Assistance in Group Idea Generation*. Springer International Publishing. 457-461. https://doi.org/10.1007/978-3-319-59144-5_31

Rost, D. H. (2008). *Multiple Intelligenzen, multiple Irritationen*. Zeitschrift für Pädagogische Psychologie, 97–112. <https://doi.org/10.1024/1010-0652.22.2.97>

Samuel, A. (1959). *Some Studies in Machine Learning Using the Game of Checkers*. IBM Journal of Research and Development. Vol. 3, No. 3. <https://doi.org/10.1147/rd.33.0210>

Schallmo, D. R. A. (2017). *Design Thinking erfolgreich anwenden: So entwickeln Sie in 7 Phasen kundenorientierte Produkte und Dienstleistungen*. Wiesbaden, Deutschland: Springer Gabler.

Schütze, B., & Schlieter, H. (2019). *Künstliche Intelligenz: Ein nützliches Werkzeug für den Radiologen?* Heidelberg, Deutschland: Springer Medizin Verlag GmbH.

Simonton, D. K. (2013). *What is a creative idea?: Little-c versus Big-C creativity*. Cheltenham, England: Edward Elgar Publishing.

Struve, A. (2021). *Generatives Design zur Optimierung additiv gefertigter Kühlkörper*. Berlin, Deutschland: Springer Vieweg.

Trask, A. T. (2020). *Neuronale Netze und Deep Learning kapieren: Der einfache Praxiseinstieg mit Beispielen in Python*. Frechen, Deutschland: mitp Verlags GmbH & Co. KG.

Vey, K., & Zipp, J. S. (2018). *Das kreative System – Überlegungen zur künstlichen Kreativität*. Luxemburg, Luxemburg: Springer Science and Business Media.

Weitz, S. (2018). *Parallelen zwischen dem menschlichen und maschinellen Lernen*. o. A.

Wilson, C. (2013). *Brainstorming and Beyond: A User-Centered Design Method*. Amsterdam, Niederlande: Elsevier.

Wittpahl, V. (2019). *Künstliche Intelligenz*. Heidelberg, Deutschland: Springer Vieweg.

Zhang, E. (2004). *The Power of Design*. Business Week. o. A.

Internetverzeichnis

A.I. – Introducing the first chair created with artificial Intelligence (2020, 24. Januar). Starck. Abgerufen am 10. Dezember 2021, von <https://www.starck.com/a-i-introducing-the-first-chair-created-with-artificial-intelligence-ce-p3801>

Bieling, T. (2020, 14. Juli). *Wicked Problems mehr denn je?: Gedanken zu Horst Rittel*. Designabilities. Abgerufen am 1. Dezember 2021, von <https://designabilities.wordpress.com/2020/07/14/wicked-problems-mehr-denn-je-gedanken-zu-horst-rittel/>

Brainstorming: The Complete List of Tools and Techniques (2020, o. A.). Status.net. Abgerufen am 10. Dezember 2021, von <https://status.net/articles/brainstorming-tools-techniques/>

Cascio, J. (2020, 29. April). *Facing the Age of Chaos*. Medium. Abgerufen am 30. Dezember 2021, von <https://medium.com/@cascio/facing-the-age-of-chaos-b00687b1f51d>

De-Yu, C. (2021, 13. Mai). *What is the difference between Traditional Programming and Machine Learning?* Medium. Abgerufen am 2. Januar 2022, von <https://medium.com/mlearning-ai/what-is-the-difference-between-traditional-programming-and-machine-learning-f6128ed4f595>

Fishel, C. (2011, 10. März). *One logo, 40,000 permutations*. Logolounge. Abgerufen am 25. November 2021, von <https://www.logolounge.com/articles/one-logo-40000-permutations>

Gerstl, S. (2017, 9. November). *Stephen Hawking warnt vor KI als „schlimmstes Ereignis der Zivilisationsgeschichte“*. Elektronik Praxis. Abgerufen am 2. Januar 2022, von <https://www.elektronikpraxis.vogel.de/stephen-hawking-warnt-vor-ki-als-schlimmstes-ereignis-der-zivilisationsgeschichte-a-660803/>

Goh, G., Gray, S., Pavlov, M., & Ramesh, A. (2021, 5. Januar). *DALL-E: Creating Images from Text*. OpenAi. Abgerufen am 25. November 2021, von <https://openai.com/blog/dall-e/>

Golta, K. (2019, 7. Mai). *Künstliche Intelligenz und Design: Was Mensch und Maschine verbindet*. PAGE. Abgerufen am 25. November 2021, von <https://bit.ly/3p0NzWf>

Grabmeier, S. (2020, 18. Juni). *BANI vs. VUCA*. Stephan Grabmeier. Abgerufen am 29. Dezember 2021, von <https://stephangrabmeier.de/bani-vs-vuca/>

GroupMap (o. D.). *Directed Brainstorming*. Abgerufen am 25. November 2021, von <https://www.groupmap.com/directed-brainstorming/>

Institut für ökologische Wirtschaftsforschung GmbH & future e.V. (Statista) (2019, September). *Ranking der Unternehmen mit der besten Nachhaltigkeitsberichterstattung nach ihrem CSR-Reporting im Jahr 2018*. Abgerufen am 17. Dezember 2021, von <https://de.statista.com/statistik/daten/studie/1094914/umfrage/ranking-der-unternehmen-mit-der-groessten-nachhaltigkeit-nach-dem-csr-reporting-ranking/>

Karg, S. (o. D.). „*The Next Rembrandt*“ – *Kunstwerke aus dem 3D-Drucker?! Abgerufen am 10. Dezember 2021, von https://www.kulturhochsn.de/the-next-rembrandt-kunstwerke-aus-dem-3d-drucker/*

Katzlerberger, M. [Thüringer Agentur für die Kreativwirtschaft] (2021, 22. September). *THIAK Forum 2021 – Kann KI kreativ sein?* [Video]. Youtube. Abgerufen am 25. November 2021, von <https://www.youtube.com/watch?v=pdUvNcFl0AM>

Kreutzer, R. (2021, 1. Dezember). *Auf welche Akzeptanz stößt der KI-Einsatz in Deutschland?* Bitkom Akademie. Abgerufen am 7. Dezember 2021, von <https://www.bitkom-akademie.de/news/auf-welche-akzeptanz-stoesst-der-ki-einsatz-deutschland>

Lövenich, R. (2020, 17. Mai). „*Probleme kann man niemals mit derselben Denkweise lösen, durch die sie entstanden sind.*“ (Albert Einstein). Zukunftsagentur Rheinisches Revier. Abgerufen am 2. Januar 2022, von [https://www.unser-zukunftsvision.de/dialoge/wie-stellen-wir-uns-eine-innovationsfreundliche-zukunft-im-rheinischen-revier-vor/probleme#:~:text=weiterlesen-,%22Probleme%20kann%20man%20niemals%20mit%20derselben%20Denkweise%20l%C3%B6sen%2C%20durch%20die,sind.%22%20\(Albert%20Einstein\).](https://www.unser-zukunftsvision.de/dialoge/wie-stellen-wir-uns-eine-innovationsfreundliche-zukunft-im-rheinischen-revier-vor/probleme#:~:text=weiterlesen-,%22Probleme%20kann%20man%20niemals%20mit%20derselben%20Denkweise%20l%C3%B6sen%2C%20durch%20die,sind.%22%20(Albert%20Einstein).)

Pechmann, A. (2020, 19. April). *Philippe Starck – Von der Entstehung des A.I. Chairs*. Designbote. Abgerufen am 10. Dezember 2021, von <https://designbote.com/philippe-starck-von-der-entstehung-des-a-i-chair/>

Safar, M. (2020, 26. November). *Die Top 10 Anwendungsfälle für Maschinelles Lernen in Unternehmen*. Digitale Welt. Abgerufen am 10. Dezember 2021, von <https://digitaleweltmagazin.de/2020/11/26/die-top-10-anwendungsfaelle-fuer-maschinelles-lernen-in-unternehmen/>

Schaffrinna, A. (2018, 16. Juli). *Generatives Design – Co-Kreation dank künstlicher Intelligenz*. Designtagebuch. Abgerufen am 25. November 2021, von <https://www.designtagebuch.de/generatives-design-co-kreation-dank-kuenstlicher-intelligenz/>

Schuldt, C. (o. D.). *Wir brauchen eine konstruktive KI!* Zukunftsinstitut. Abgerufen am 6. Dezember 2021, von <https://www.zukunftsinstitut.de/artikel/wir-brauchen-eine-konstruktive-ki/>

Syverson, B. (2020, 19. Oktober). *The Rules of Brainstorming Change When Artificial Intelligence Gets Involved: Here's How*. IDEO. Abgerufen am 25. November 2021, von <https://www.ideo.com/blog/the-rules-of-brainstorming-change-when-ai-gets-involved-heres-how>

The Next Rembrandt (o. D.). (o. A.). Abgerufen am 25. November 2021, von <https://www.nextrembrandt.com/>

Wuttke, L. (o. D.). *Reinforcement Learning: Wenn KI auf Belohnungen reagiert*. Datasolut. Abgerufen am 10. Dezember 2021, von <https://datasolut.com/reinforcement-learning/>

Interviewverzeichnis

German, Kevin (2021): persönliches Interview mit Verf., online, Alfaview, 4. November 2021.

Henseler, Wolfgang (2021): persönliches Interview mit Verf., online, Alfaview, 18. November 2021.

Reichert, Steffen (2021): persönliches Interview mit Verf., online, Alfaview, 30. November 2021.

Schmitz, Norbert (2021): persönliches Interview mit Verf., online, Alfaview, 11. November 2021.

Eidesstattliche Erklärung

Ich versichere, die beiliegende Masterarbeit selbstständig verfasst, keine anderen als die angegebenen Quellen und Hilfsmittel benutzt sowie alle wörtlich oder sinngemäß übernommenen Stellen in der Arbeit gekennzeichnet zu haben. Diese Arbeit hat in gleicher oder ähnlicher Form noch keiner Prüfungsbehörde vorgelegen.

Weiswampach, 17/01/2022

Ort / Datum



Unterschrift Studierende*r (= Verfasser*in)