



MASTERARBEIT | MASTER'S THESIS

Titel | Title

Affektives Design von Symbolen und Mustern in Multi-Scale-Karten unter
Verwendung generativer Künstlicher Intelligenz

verfasst von | submitted by

Glenys Laetitia Bischoff BSc

angestrebter akademischer Grad | in partial fulfilment of the requirements for the degree of

Master of Science (MSc)

Wien | Vienna, 2026

Studienkennzahl lt. Studienblatt |
Degree programme code as it appears on
the student record sheet:

UA 066 856

Studienrichtung lt. Studienblatt | Degree
programme as it appears on the student
record sheet:

Masterstudium Kartographie und Geoinformation

Betreut von | Supervisor:

Ass.-Prof. Mag. Dr. Andreas Riedl

Inhaltsverzeichnis

Abbildungsverzeichnis	v
Tabellenverzeichnis	ix
Abkürzungsverzeichnis	xii
Kurzfassung	xiii
Abstract	xiv
Danksagung.....	xv
1 Einleitung.....	1
1.1 Motivation und Relevanz	1
1.2 Zielsetzung und Fragestellungen.....	3
1.3 Aufbau und Struktur	4
2 Theoretische Grundlagen.....	6
2.1 Designaspekte in der Kartographie	6
2.1.1Entwicklung kartographischer Designaspekte im Laufe der Zeit	6
2.1.2Graphische Variablen als Grundlage kartographischer Stilbildung	9
2.1.3Kartographische Kommunikation.....	13
2.1.4Prinzipien der Muster- und Symboldarstellung in topographischen Karten	16
2.2 Psychologische Wahrnehmung von Farben, Formen und Mustern	18
2.2.1Einfluss von Kartenelementen auf NutzerInnen und die psychologische Bedeutung hinter dem „Affekt“	19
2.2.2Psychologische Aspekte der Orientierung innerhalb einer Karte	21
2.2.3Psychologische Hintergründe von Vertrauen in Kartenelemente	21
2.3 Überblick über generative KI-Methoden für eine kartographische Anwendung	23
2.3.1Large Language und Multimodal Large Language Modelle	25
2.3.2Diffusionsbasierte Bildgenerierungsmodelle.....	26
2.3.3GenAI-Agenten	28
2.3.4Genauigkeit und Fehleranfälligkeit von KI-generierten Kartendesigns	30

2.4	Prompt Engineering für die Text-zu-Bild-Generierung	34
2.4.1	Prompt Methoden: Keywords, Prompt Auto-Editing, Feinsteuerung und Negativprompts	34
2.4.2	Prompt Prinzipien für die Erstellung von Kartenicons	36
2.4.3	Spezifische Prompts für Bild- und Stilgenerierung	37
2.5	Herausforderungen und Anwendungen von Multi-Scale-Darstellungen	39
2.5.1	Zoomlevel und MasterScale Diagramm	40
2.5.2	Stilistische und visuelle Konsistenz bei Maßstabswechseln	41
2.5.3	Level of Detail und Level of Abstraction	43
3	Methodik.....	46
3.1	Technische Umsetzung und wesentliche Elemente des Workflows	46
3.2	Festlegung von Designkriterien für die Symbol und Mustergenerierung	47
3.3	Auswahl und Definition einer Testumgebung	53
4	Entwicklung eines Workflows zur Generierung von Kartensymbolen und Mustern in Multi-Scale-Karten	65
4.1	Erstellung der Multi-Scale-Testumgebung sowie dafür nötige Datenaufbereitung	66
4.2	Integration von Multi-Scale-Aspekten	69
4.3	Prozess der Symbolgenerierung und Mustererstellung.....	76
5	Ergebnis – Workflow für die Symbol und Mustergenerierung für Multi-Scale-Karten	84
5.1	Erstellter Workflow sowie generierte Symbole und Muster.....	84
5.2	Masterprompts, Erkenntnisse und hilfreiche Promptbausteine.....	88
5.3	Beantwortung von aufgestellten Hypothesen und nutzerfreundlicher Workflow Zugriff.....	90
6	Diskussion und Limitationen	93
6.1	Stärken des Workflows	93
6.2	Schwächen des Workflows	95
7	Conclusio.....	98
7.1	Beantwortung der Forschungsfragen	99

7.2	Zukunftsausblick	103
8	Literaturverzeichnis	105
9	Anhang.....	115
	Anhang 01: KI-Auswahl	117
	Anhang 02: Transparenter Hintergrund und SVG-Erstellung Tests.....	123
	Anhang 03: Symbol- und Mustergenerierung	127
	Anhang 04: Promptübertragung auf weitere KI-Modelle (Bezug zu Kapitel 5.2 und 6.2).....	127
10	Hilfsmittelverzeichnis	131

Abbildungsverzeichnis

Abb. 1: OSM-Karte (links) und Google Maps (rechts) Darstellung von Symbol- und Musterelementen für den Stadtpark Wien in Österreich im Vergleich (Google Maps, 2025; OpenStreetMap, 2025).	1
Abb. 2: Stadtplan der italienischen Stadt Imola, 1502 von Leonardo Da Vinci (Leonardo Da Vinci (1452-1519) - A Map of Imola, o. J.).....	7
Abb. 3: Graphische Variablen nach Bertin („Grundelemente der Karte“, 2013)...	9
Abb. 4: Visuelle Variablen und ihre Eignung für verschiedene Datentypen Bertin’s Variablen mit Erweiterungen von MacEachren (R. Roth, 2017).	11
Abb. 5: Für die Klassifizierung von Legendensymbolen erstelltes Typologie Framework, aufgeteilt auf drei Ebenen (A. Kent & Vujakovic, 2009)...	12
Abb. 6: Kent's Kartographisches Kommunikationsmodell mit einem NutzerInnen Feedback als kontinuierlicher Kreislauf (Kent, 2018).	13
Abb. 7: Glaubwürdigkeit von Karten im Zusammenhang mit dem kulturellen Hintergrund. Fiktive Karten im österreichischen Stil (links) und Karte im kasachischen Stil (rechts) (Gartner et al., 2024).	15
Abb. 8: Signaturen/ Symbolübersicht mit ihren Formen und möglicher Anordnung (Hake et al., 2002).....	16
Abb. 9: Darstellungsarten der visuellen Variable Muster (White, 2017).	17
Abb. 10: Beispielhafter Aufbau des Signaturenkataloges (Hake et al., 2002).	18
Abb. 11: Zwölf Karten, mit unterschiedlichen Farbschemata (Fabrikant et al., 2012).....	20
Abb. 12: Adjektive der Map Trust Skala, die das Vertrauen in Karten messbar machen sollen (Prestby, 2024).	22
Abb. 13: Ein konzeptuelles Framework, wie KI innerhalb der Kartographie eingesetzt werden kann (Kang & Wang, 2025).	24
Abb. 14: Erzeugte Piktogramme mittels angepasster ChatGPT Erweiterung und DALL-E im Vergleich zu den jeweiligen OSM Pendants (Drews et al., 2025).....	27
Abb. 15: Der Kartenerstellungsprozess und wie Agenten und spezieller angepasste Cartoagenten dabei helfen können (Wang et al., 2025).....	29

Abb. 16: Überblick über die Rollenverteilung bei der Stil Übertragung, in der mittleren Spalte der Icon Designer (Wang et al., 2025).	29
Abb. 17: Fehlerhafte DALL-E 2 - KI Outputs kategorisiert in vier Gruppen (Kang et al., 2023).	31
Abb. 18: Ergebnis des dynamischen-Feinsteuierungs-Prompts (Mo et al., o. J.). .	34
Abb. 19: Ergebnisse der drei Kategorien: "NegOpt", "Ground Truth" und "None" (Ogezi & Shi, 2024).	35
Abb. 20: Prompt der als Input für den AI-Agent "Icon Designer" vorgegeben wurde (Wang et al., 2025).	36
Abb. 21: Erstellte Icons mit der Inspirationsquelle (links), den Ergebnissen vor der Evaluierung durch MLLM's (Mitte) und danach (rechts) (Wang et al., 2025).	37
Abb. 22: Aufbau des Prompts für die Generierung von Graphiken (links), sowie eigene Darstellung der Parameter (rechts) adaptiert und erweitert nach (Dunkel et al., 2024).	38
Abb. 23: Erstellte Icons mittels generativer KI (links) und Diffusion Subject Prompts (rechts) Prompts (Dunkel et al., 2024).	39
Abb. 24: Beispielhafter Aufbau eines MasterScale-Diagramms (R. E. Roth et al., 2011).	41
Abb. 25: Google Maps Stilübertragung mittels GANs und dabei von der KI angewandte Generalisierungen (Kang et al., 2024).	43
Abb. 26: Level of Abstraction, dargestellt anhand einer Kirche (Elias et al., 2005).	44
Abb. 27: Beispielhafte Sprite-Datei (PNG), in der alle Symbole und Muster einer digitalen Kartenanwendung innerhalb einer Datei definiert sind (Sprite Mapbox Style Spec Mapbox Docs, o. J.).	48
Abb. 28: Auswahl beispielhafter "Maki Icons" für Symbole innerhalb einer Karte (Maki Icons By Mapbox, o. J.).	49
Abb. 29: Mustergenerator von Christoph Hormann ("Imagico"), als mögliches Orientierungsbeispiel für den KI-Input (imagico.de - Periodic dot and symbol pattern generator, o. J.).	49
Abb. 30: Aufbau des ersten Testprompts (Zeile 1, PV01) und Negativprompt (gelb), eigene Darstellung, Grundstruktur auf Basis von (Dunkel et al., 2024).	50

Abb. 31: Hintergrund Freistellung der verschiedenen Modelle als Übersicht (schwarze Rahmen bei weißem Hintergrund ergänzt, zur besseren Erkennbarkeit des Hintergrundes, sowie Nummern zur Identifizierung: eigene Darstellung, Abbildungen generiert innerhalb obenstehender Modelle).	61
Abb. 32: Seedream Katzenoutputs in verschiedenen Browsern (Bilder generiert mittels Seedream, eigene Darstellung).	63
Abb. 33: Basiskarten der Testumgebung, OpenFreeMap Liberty (1) und OpenFreeMap Positron (2), sowie OpenFreeMap Liberty im Detailvergleich (3) mit OSM-Bright (4), eigene Darstellung (Ero, 2023/2026).	66
Abb. 34: Testumgebung mit ergänzten Nummern und Rahmen zur besseren Beschreibung der Elemente, eigene Darstellung, erstellt mithilfe von Claude und Codex (Claude, o. J.; CLI – Codex OpenAI Developers, o. J.).	67
Abb. 35: Testumgebung - Line Pattern Funktion für den Randbereich von musterhaften Flächen (eigener Screenshot und Darstellung, Oberfläche erstellt mithilfe von Claude und Codex)).	68
Abb. 36: Generiertes PNG mit drei Zoomstufen (links) und daraus mittels „png_cutter“-Skript extrahierte einzelne PNG's (rechts), Symbole generiert mit GPT-I, eigene Darstellung.	69
Abb. 37: Multi-Scale-Operatoren die für den gewählten Workflow von Interesse sind (adaptiert und erweitert um Muster („Pattern“) eigene Darstellung nach (R. E. Roth et al., 2011).	70
Abb. 38: Nahtloses Muster generieren mittels GPT-I mittels Prompt: „seamless tiling in every direction“ (generiert mit GPT-I, eigene Darstellung) in Rot Fehler beim Aneinanderreihen der Kacheln)	73
Abb. 39: Waldmuster mit leichter Transparenz und heller Farbe (links), sowie MapLibre Line Pattern mit einzelnen Bäumen als Übergangszone (rechts), eigene Darstellung, Symbole und Muster (generiert mit GPT-I, eigene Darstellung).	82
Abb. 40: Ergebnis: empfohlener Workflow für das Vorgehen der Symbol- und Mustererstellung für Multi-Scale-Karten mittel generativer KI (eigene Darstellung, erstellt innerhalb von (draw.io, o. J.).	85
Abb. 41: Möglichst generische Symbol- und Musterprompts, die während der Theorie- und Praxistests am besten funktioniert haben (eigene Darstellung, erstellt innerhalb von (draw.io, o. J.).	88

Abb. 42: Erkenntnisse der Modelltests zusammengefasst mit den dazu geeigneten Prompts (eigene Darstellung, erstellt innerhalb von (draw.io, o. J.), generierte Beispiele erstellt innerhalb von GPT-I 1.5).....	89
Abb. 43: Veröffentlichter Workflow auf GitHub, um den Workflow möglichst FAIR (Hu et al., 2025) zu gestalten (eigener Screenshot, erster Teil der „readme“-Datei zur Beschreibung des Projekts).....	92
Abb. 44: Entdeckter Fehler bei Prompttests, Symbol von vorherigem Output wird für neuen Output herangezogen (links GPT-I, rechts Qwen 3.6-Plus, eigene Screenshots).	96
Abb. 45: Zu hoher Detailgrad, links generiertes Symbol, rechts eingebunden in Testumgebung durch Sprite Erstellung runterskaliert (generiert mit GPT-I, eigene Darstellung).	96
Abb. 46: Bezug zur Einleitung - Wiener Stadtpark in zwei verschiedenen Zoomstufen, links Zoomlevel 17, rechts Zoomlevel 18, unten 20 (alle Symbole generiert mit Masterprompt innerhalb von GPT-I, eigene Darstellung, OSM Bright Basiskarte).	98

Tabellenverzeichnis

Tab. 1: Festgelegte Basisspezifikationen für Prompts (übergeordnete Anforderungen an alle Symbole (S) und Muster (M)) (eigene Darstellung beruhend auf den Erkenntnissen von (Brewer, 1999; Drews et al., 2025; Dunkel et al., 2024; Fabrikant et al., 2012; Hake et al., 2002; Mo et al., o. J.; Wang et al., 2025).....	47
Tab. 2: Signaturenkatalog für ein Baumsymbol, eigene Darstellung auf Basis von (Hake et al., 2002), sowie verwendete Symbolvorlage von (Maki Icons By Mapbox, o. J.)	50
Tab. 3: Prompt Anforderungen auf Basis des Theorieteils (Dunkel et al., 2024; Ekin, 2023; Liu & Chilton, 2023; Wang et al., 2025).....	50
Tab. 4: Prompt Bausteine des ersten Testprompts (PV01), eigene Darstellung basierend auf (Dunkel et al., 2024; Liu & Chilton, 2023; Mo et al., o. J.; Ogezi & Shi, 2024).....	51
Tab. 5: Übersicht der genutzten Symbol-Prompts für die Modelltestung (eigene Darstellung).	52
Tab. 6: Übersicht der genutzten Pattern-Prompts für die Modelltestung (eigene Darstellung).	53
Tab. 7: Übersichtstabelle über Kriterien der Testumgebung mit Zoomstufe zu Maßstabumrechnung eigene Darstellung, Maßstabumrechnung auf Basis von (Zoom Levels and Scale Documentation Esri Developer, o. J.)...	55
Tab. 8: Übersichtstabelle für die KI-Auswahl (eigene Darstellung basierend auf den Erkenntnissen von (Dunkel et al., 2024; Kang et al., 2024; Kim et al., 2024) sowie Punkte, die sich beim Besuchen der Modell-Webseiten ergeben haben. B ¹ , B ² , Ü speziell für Mustertest (eigene Darstellung)...	57
Tab. 9: KI-Modellauswahl für Symbolgenerierung anhand vorher festgelegter Kriterien (Modelle alphabetisch sortiert), eigene Darstellung mittels heatmap in Excel, die Modelltests sind auf dem Stand März 2026.	58
Tab. 10: KI-Modelltests - Outputs der drei Symbol Testprompts je Modell (eigene Darstellung, Abbildungen generiert innerhalb linkstehender Modelle, *Sortierung alphabetisch).	59
Tab. 11: Direkter Vergleich der Outputs mit Maki Vorlage (links) als Orientierung (Maki Icons By Mapbox, o. J.), eigene Darstellung, Abbildungen generiert innerhalb oben stehender Modelle.	60

Tab. 12: KI-Modellauswahl für Mustergenerierung anhand vorher festgelegter Kriterien, eigene Darstellung mittels heatmap in Excel.....	60
Tab. 13: KI-Modelltests - Outputs der Muster Testprompts je Modell (eigene Darstellung, Abbildungen generiert innerhalb linkstehender Modelle)..	61
Tab. 14: Reproduzierbarkeit bei Chatmodellen genID im Test mit GPT-I (erste Zeile) und Nano Banana Pro 2 (zweite Zeile) (eigene Darstellung).	64
Tab. 15: Auflistung der Multi-Scale-Aspekte/ Herausforderungen und wie sie geplant werden umzusetzen, für möglichst funktionale und affektive Ergebnisse (eigene Darstellung).....	71
Tab. 16: Übersicht über definierte Farben als Input, generiert mit GPT-I (linker Output), sowie Stable Diffusion (rechter Output, nur mit Farbangabe ohne Vorlage), eigene Darstellung.....	72
Tab. 17: Google Maps Luftbildausschnitt als Input (Zeile 1) und der Output (Zeile 2), generiert mit GPT-I (Mitte) und Stable Diffusion (rechts), eigene Darstellung.....	73
Tab. 18: Symbol zu Muster (Zeile 1) und Muster zu Symbol (Zeile 2), (generiert mit GPT-I, eigene Darstellung).	74
Tab. 19: Möglichst generische, selbsterklärende Ergebnisse generieren mittels GPT-I (oben) und Stable Diffusion (unten), eigene Darstellung.	74
Tab. 20: Nicht gewünschte Details aus Output entfernen bzw. ersetzen (generiert mit GPT-I, eigene Darstellung).	75
Tab. 21: Vereinfachen von Outputs (generiert mit GPT-I, eigene Darstellung). .	75
Tab. 22: Übersicht des erstellten übergeordneten Prompts für Symbole mit verwendeten Prompt Bausteinen, MasterScale Operatoren und Erklärung (eigene Darstellung).	77
Tab. 23: Masterprompt Variante (Ausschnitte) mit Größenangabe bei einzelnen Symbolen (oben) im Vergleich mit Größenangaben am Ende im Verhältnis angegeben (unten), (generiert mit GPT-I, eigene Darstellung).	78
Tab. 24: Anpassungen der Stichwörter und Details im Vergleich mit dem generierten Output (generiert mit GPT-I, eigene Darstellung).	78
Tab. 25: Anpassung des Masterprompts: Weißer, kreisförmiger und brauner eckiger Hintergrund (eigene Darstellung, grauer Hintergrund ergänzt, für bessere Erkennung des weißen Hintergrunds (generiert mit GPT-I, eigene Darstellung).	79

Tab. 26: Prompts für Muster, im Schema der Symbolprompts (generiert mit GPT-I, eigene Darstellung).	79
Tab. 27: Übersicht des erstellten übergeordneten Prompts für Muster mit verwendeten Prompt Bausteinen, MasterScale Operatoren und Erklärung (eigene Darstellung). Aufbauend auf dem vorher erstellten Symbolprompt, mit ergänzenden Anmerkungen, was speziell für Muster von Bedeutung ist.	80
Tab. 28: Prompt für eine Grünfläche/ Sportplatz, englisch Pitch (generiert mit GPT-I, eigene Darstellung).	81
Tab. 29: Angepasster Masterprompt für einzelne Symbole (generiert mit GPT-I, eigene Darstellung).	81
Tab. 30: Stilanpassungen für ein Krankenhaus Symbol (generiert mit GPT-I, eigene Darstellung).	82
Tab. 31: Auswahl generierter Symbole und Muster in verschiedenen Detailgraden mittels des erstellten Masterprompts (generiert mit GPT-I, eigene Darstellung).	87
Tab. 32: Mit Masterprompt erstellte Symbole, die durch ihre Objektklassen eine Kombination aus Symbolen sind (Screenshots innerhalb der Testumgebung, Symbole generiert mit GPT-I, eigene Darstellung).	94
Tab. 33: Hilfsmittelverzeichnis	131

Abkürzungsverzeichnis

C-GAN	<i>Conditional Generative Adversarial Network</i>
CWL	<i>Common Workflow Language</i>
DF	<i>Dynamic Fine-control Prompt</i>
FAIR	<i>Findable, Accessible, Interoperable und Reusable</i>
GAN	<i>Generative Adversarial Network</i>
genID	<i>Generation ID</i>
GIS	<i>Geographische Informationssysteme</i>
GPT-I	<i>ChatGPT-Images</i>
IGN	<i>Institut Géographique National</i>
KI	<i>Künstliche Intelligenz</i>
LLMs	<i>Large Language Modells</i>
LoA	<i>Level of Abstraction</i>
LoD	<i>Level of Detail</i>
MLLM	<i>Multi large language model</i>
OSM	<i>Open Street Map</i>
PAE	<i>Prompt Auto-Editing</i>
phash	<i>percentual hash</i>
VAE	<i>Variational Autoencoder</i>
WMS	<i>Web Map Service</i>

Kurzfassung

Spätestens mit dem Aufkommen von Smartphones haben digitale Multi-Scale-Karten, klassische Printkarten weitgehend verdrängt. Gleichzeitig nimmt der Einsatz von Künstlicher Intelligenz einen immer größeren Platz in der Gesellschaft ein. Digitale Karten bieten neue Möglichkeiten und Anforderungen, insbesondere da durch die Verwendung in höheren Zoomstufen mehr Platz vorhanden ist als in klassischen Printkarten, bei denen durch den kleineren Maßstab Generalisierungsprozesse und damit eine Reduzierung von Informationen im Vordergrund stehen. Deshalb befasst sich die folgende Arbeit mit der Frage: „Wie kann generative KI eingesetzt werden, um die Symbol- und Mustergenerierung für Multi-Scale-Karten zu optimieren?“.

Um möglichst affektive und funktionale Symbole und Muster zu erzeugen, werden grundlegende kartographische Designaspekte, geeignete KI-Methoden, sowie spezifische Prompt Engineering Aspekte behandelt. Des Weiteren werden Herausforderungen und Kriterien von Multi-Scale-Karten, wie unterschiedliche Zoomstufen und damit verbundene Probleme, sowie psychologische Aspekte auf NutzerInnen identifiziert und mit diesen generative KI-Bildmodelle auf ihre Eignung getestet.

Auf Basis dieser Kriterien, wird ein möglichst generischer, für Multi-Scale-Karten optimierter, sowie KI-geeigneter Workflow entwickelt, innerhalb einer Testumgebung erprobt und zur freien Verfügung gestellt.

Die Ergebnisse bieten die Möglichkeit schnell Inhalte für digitale Karten zu erstellen, die sich über Maßstäbe hinweg anpassen und machen es einfacher Symbole und Muster individuellen Vorstellungen entsprechend zu entwerfen, um einzigartigere Kartenelemente zu erstellen. Zudem ist es durch eine Konkretisierung und Detaillierung der Karteninhalte in hohen Zoomstufen möglich, vorhandenen Platz von Multi-Scale-Karten besser auszunutzen und Orientierungspunkte zu schaffen.

Abstract

With the advent of smartphones, digital multi-scale maps have largely replaced traditional printed maps. At the same time, artificial intelligence is playing an increasingly important role in society. Digital maps offer new opportunities and challenges, particularly because their use at higher zoom levels provides more space than traditional printed maps, where the smaller scale necessitates generalization and thus a reduction of information. Therefore, this work addresses the question: "How can generative AI be used to optimize symbol and pattern generation for multi-scale maps?"

To generate the most effective and functional symbols and patterns, fundamental cartographic design aspects, suitable AI methods, and specific prompt engineering aspects are discussed. Furthermore, challenges and criteria of multi-scale maps, such as different zoom levels and their associated problems, as well as psychological aspects for users, are identified, and generative AI image models are tested for their suitability.

Based on these criteria, a workflow that is as generic as possible, optimized for multi-scale maps, and suitable for AI will be developed, tested in a zoomable digital map environment, and made freely available.

The results offer the possibility of quickly creating content for digital maps that adapt across different scales and make it easier to design symbols and patterns according to individual preferences to create more unique map elements. Furthermore, by making map content more specific and detailed at high zoom levels, it is possible to better utilize the available space on multi-scale maps and create points of orientation.

Danksagung

Diese Masterarbeit ist innerhalb eines einjährigen Prozesses entstanden und hat meine Leidenschaft für die Kartographie und dem Zusammenspiel von klassischen Erkenntnissen mit modernen Umsetzungsmethoden verstärkt.

Ich möchte mich hiermit bei allen bedanken, die mich im Laufe dieser Zeit unterstützt haben. Vor allem meinem Betreuer Ass.-Prof. Dr. Andreas Riedl für schnelle Rückmeldungen und das aufschlussreiche Feedback.

Zusätzlich gebührt ein großer Dank meinen liebsten Menschen, dass sie hinter mir stehen, mich unterstützen und Verständnis hatten, wenn durch die Masterarbeit weniger Zeit vorhanden war.

1 Einleitung

1.1 Motivation und Relevanz

Kartenprodukte haben sich im Zuge der **Digitalisierung** in den letzten Jahren deutlich verändert und es gibt eine Vielzahl digitaler Anwendungen. **Künstliche Intelligenz** (KI) und ihre Verwendung nimmt eine größere werdende Bedeutung im Bereich der Kartographie ein (Ye et al., 2024). **Multi-Scale-Anwendungen**, die es ermöglichen, verschiedene Maßstäbe in einer Karte darzustellen, führen zu neuen **Herausforderungen und Chancen**. Diese, meist in interaktiven Webkarten verbreitete Darstellungsart, bietet die Möglichkeit, eine **Vielzahl an Details** zu integrieren, die in Printkarten aufgrund von begrenztem Platz nicht darstellbar sind. Traditionelle Kartenprodukte sind mit der Verbreitung von digitalen Anwendungen, wie Google Maps oder OSM (Open Street Map) basierten Produkten, dabei abgelöst zu werden (Dumont et al., 2020; La Licata et al., 2025).

Die Darstellung von Symbolen und Mustern in unterschiedlichen Maßstäben stellt eine Herausforderung dar, da Details in kleinen Maßstäben vereinfacht werden müssen, während **größere Maßstäbe mehr Präzision und Detailtreue** erfordern (Dumont et al., 2020; Gatys et al., 2016). Bekannte Multi-Scale-Karten gehen unterschiedlich mit Symbolen und Mustern um, zum Teil werden auf hohen Zoomstufen mehr Details gezeigt, andererseits wird dort ebenfalls generalisiert. Hier unterscheiden sich **aktuelle Kartenanwendungen stark von traditionellen Printkarten** und deren Maßstäben, in denen der **Platzmangel** und die daraus resultierende Notwendigkeit von Generalisierung eine zentrale Herausforderung darstellte.



Abb. 1: OSM-Karte (links) und Google Maps (rechts) Darstellung von Symbol- und Musterelementen für den Stadtpark Wien in Österreich im Vergleich (Google Maps, 2025; OpenStreetMap, 2025).

Bei OSM sind zum Beispiel deutlich mehr Detailinformationen und Kategorien sichtbar als bei Google Maps, erkennbar in Abb. 1 am Beispiel Stadtpark Wien. Unabhängig davon wie viele Symbole gezeigt werden, sehen diese in beiden Beispielen über alle Zoomstufen hinweg identisch aus und werden **je nach Zoomstufe ein- und ausgeblendet**. Die Möglichkeit in höheren Zoomstufen detailreichere Symbole und Muster zu verwenden und damit mehr Informationen zu transportieren, wird heute kaum genutzt und soll in dieser Arbeit evaluiert werden (Google Maps, 2025; OpenStreetMap, 2025). Die Erstellung von

Symbolen und Mustern ist aufwendig, speziell wenn sie auf verschiedene Maßstäbe adaptiert werden muss. KI könnte dabei eine Möglichkeit darstellen, **Arbeitsaufwand zu sparen** und dafür den Fokus auf Gestaltungsaspekte und die optimale Platznutzung zu legen.

Innerhalb von Unternehmen ist der KI-Einsatz 2024 mit 20,3% ein geringer Anteil, jedoch nutzen speziell junge Leute, die die Zukunft des kartographischen Berufs gestalten werden, vermehrt KI. Bei den **16 bis 24-jährigen waren es 2024 60,2%**, die mindestens einmal generative KI genutzt haben, was die Relevanz insbesondere für die nahe Zukunft zeigt (KI-Monitor, o. J.). Mit dem Einsatz von KI ergibt sich des Weiteren die Frage nach dem Vertrauen in die produzierten Ergebnisse, was ebenfalls berücksichtigt werden soll.

Generative KI-Methoden für Visualisierungen von kartographischen Inhalten befinden sich in einer **frühen Forschungsphase**, durch die Geschwindigkeit der KI-Entwicklung erscheinen immer mehr Paper die sich mit dem Thema beschäftigen (Burghardt et al., 2025).

Die bisherige Forschung zur Generierung von Kartensymbolen hat sich vor allem auf statische Darstellungen oder Stil-Analysen meist im Zuge thematischer Kartographie-Anwendungen beschäftigt (Drews et al., 2025). Während in der Kartenproduktion zunehmend generative Methoden, wie zum Beispiel algorithmische Designverfahren verwendet werden, gibt es eine **Forschungslücke**, die sich speziell mit der **Anwendung und der Kombination von Generativer KI in Multi-Scale-Karten in Bezug auf Symbole und Muster** beschäftigt (Yan et al., 2025; Ye et al., 2024). Bei bisherigen Veröffentlichungen lag der Fokus speziell auf dem Kartenstil, dem Thema Stilübertragung („Map Style Transfer“) und dem Extrahieren von Informationen aus Karten, zudem wurde KI zur Klassifizierung genutzt (Christophe et al., 2022; Kang et al., 2019).

Ein Paper, welches aufgrund seines Vorgehens am nächsten an das, in dieser Arbeit geplante Vorgehen, rankommt und das als Anhaltspunkt für den **Umgang mit generativer KI** im Zusammenhang mit Karteninhalten dienen könnte, ist ein Paper von Dunkel et al. zum Thema: „Generative Text-to-Image Diffusion for Automated Map Production Based on Geosocial Media Data“. Dabei liegt der Fokus auf der Integration von Social-Media-Daten und ist für **Icon-Karten** aufgebaut (Dunkel et al., 2024). Die folgende Arbeit grenzt sich durch die zusätzliche Thematik von Mustern ab, sowie dem Multi-Scale-Aspekt und dem Ziel topographische Kartenelemente zu generieren.

Zudem gibt es ein Paper von Drews namens „A New AI Tool for the Design of Cartographic Pictograms (PictoAI) and Its Potentials for Increasing Their Meaningfulness“, in dem ein angepasstes KI-Tool auf Basis von DALL-E entworfen wurde, um **kartographische Piktogramme** automatisch zu generieren. Das Vorgehen kann für diese Arbeit interessant sein, grenzt sich aber ebenfalls durch einen Fokus auf thematische Karten ohne Maßstabswechsel inhaltlich ab. Zwei Masterarbeiten der TU Dresden haben sich ebenfalls mit der Erstellung von Piktogrammen beschäftigt, zum einen mit dem **Einsatz von neuronalen Netzen zur Stilübertragung** und zum anderen mit **Stable Diffusion als Generierungsmodell** (Burghardt et al., 2025).

Zudem wurde Mitte 2025 ein Paper von Wang et al. veröffentlicht, welches **AI-Agenten zur Stilübertragung und Kartenerstellung** verwendet. Ein Teil ihres Workflows beinhaltet die Generierung von Icons, ihre Prompts können speziell im Zuge der Prompt Engineering Thematik im Laufe dieser Arbeit hilfreich sein (Wang et al., 2025).

Wie oben erwähnt haben sich bereits vereinzelte Paper mit der Generierung von Icons beschäftigt, was Orientierung für Symbole geben kann, während es zu **Mustern** in dieser Hinsicht **keine spezifische Forschungsgrundlage** gibt. Bisherige Veröffentlichungen mit einem Fokus auf topographische Karten haben sich spezieller mit dem Karteninhalt und Design im Gesamten befasst und anhand daran Stile und Informationen mittels KI extrahiert und generiert, während diese Arbeit den **Fokus speziell auf die Generierung von Mustern und Symbolen legt, die mit KI generiert werden** und im Anschluss in eine topographische Multi-Scale-Karte eingebettet werden sollen. Die Ergebnisse sollen mithilfe eines **exemplarischen Workflows** reproduzierbar gemacht werden.

1.2 Zielsetzung und Fragestellungen

Das Ziel dieser Arbeit ist die Entwicklung und exemplarische Umsetzung eines **Designsystems** (Workflows) in einer Testumgebung, welches **skalenadaptive Symbolisierungsansätze** unterstützt, die **mittels KI** erstellt werden. Dabei wird ein besonderes Augenmerk auf die Nutzung der KI zur Optimierung von Symbolen und Mustern in unterschiedlichen Zoomstufen gelegt, um den Anforderungen an **Lesbarkeit, visueller Wirkung und Interaktivität** gerecht zu werden.

KI entwickelt sich schnell weiter, der geplante Workflow soll **die Nutzung vereinfachen** und eine **einheitliche Grundlage** bieten, die Programmübergreifend genutzt werden, sowie an zukünftige Entwicklungen leicht angepasst und adaptiert werden kann.

Zur Beantwortung der übergeordneten Forschungsfrage:

- **Wie kann Generative KI eingesetzt werden, um die Symbol- und Mustergenerierung für Multi-Scale-Karten zu optimieren?**

werden folgende Unterfragen untersucht:

- I. **Was sind zentrale Designaspekte in der Kartographie, speziell in Bezug auf Symbole und Muster für Multi-Scale-Karten?**
- II. **Welche Generativen KI-Methoden gibt es in der Kartographie, die für Multi-Scale-Karten von Relevanz sein können?**
- III. **Inwiefern können KI-generierte Symbole in verschiedenen Maßstäben affektiv und funktional gestaltet werden?**
- IV. **Welche Herausforderungen treten bei der Skalierung von Symbolen und Mustern auf, und können diese mithilfe von KI gelöst werden?**

Alle Fragen sollen zum einen mithilfe der klassischen Methode einer **tiefgreifenden Literaturrecherche** anhand möglichst aktueller Veröffentlichungen, sowie zum anderen eines praktischen Teils beantwortet werden. Für die theoretischen Grundlagen, die als Basis für den praktischen Teil dienen sollen, werden aktuelle Studien, Paper, Artikel, Websites und wissenschaftlichen Arbeiten verwendet. Zusätzlich soll als zweite Methode und praktischer Teil ein Workflow für eine **KI gestützte Symbol- Mustergenerierung innerhalb von Multi-Scale-Karten** entwickelt werden.

1.3 Aufbau und Struktur

Die Masterarbeit ist in **sieben Hauptkapitel** unterteilt. Nach der **Einleitung** in Kapitel 1 mit Motivation (1.1), Zielsetzung (1.2) und Aufbau der Arbeit (1.3) folgt der Theorieteil mit einer intensiven Literaturrecherche, um die Basis für den Praxisteil zu bilden.

Es wird zu Beginn mit **Überkapitel 2** auf die theoretischen Grundlagen eingegangen. Sie starten mit Designaspekten in der Kartographie (2.1). Zu Beginn wird dabei in Kapitel 2.1.1 auf die **Entwicklung** dieser im Laufe der Zeit eingegangen, um den heutigen Stand besser nachvollziehen zu können. Im Anschluss wird in Kapitel 2.1.2 auf die Grundlagen der graphischen Variablen kartographischer Stilbildung eingegangen. Es folgt Kapitel 2.1.3 über graphische Kommunikation, was dabei helfen soll **kommunikative Aspekte** besser zu verstehen und den Workflow am Ende **affektiv an NutzerInnen vermitteln** zu können. In Unterkapitel 2.1.4 werden **Prinzipien der Muster- und Symboldarstellung** speziell in Bezug auf topographische Karten behandelt.

Um den späteren praktischen Teil affektiv und ansprechend gestalten zu können, geht es in Kapitel 2.2 um die **psychologische Wahrnehmung** von Farben, Formen und Mustern. Spezieller **um** den Einfluss von Kartenelementen auf NutzerInnen und dem Begriff „Affekt“ (2.2.1). Es folgen die psychologischen Aspekte hinter der **Orientierung** innerhalb einer Kartenanwendung (2.2.2), sowie die psychologischen Hintergründe von **Vertrauen** in Karten (2.2.3).

Es folgt ein **Überblick über generative KI-Methoden** für eine kartographische Anwendung in Kapitel 2.3, darunter **(Multimodale) Large Language** (2.3.1) und **Diffusionsbasierte Modelle** (2.3.2), sowie **AI-Agenten** (2.3.3) und allgemeinen **Genauigkeits- und Fehleranfälligkeitsaspekten** (2.3.4).

Zudem wird im Theorieteil auf **Prompt Engineering** für die Text-zu-Bild-Generierung eingegangen (2.4), darunter **Prompt Methoden** (2.4.1), **Prompt Prinzipien** für eine **Icon Erstellung** in Unterkapitel 2.4.2 und spezifische Prompt Beispiele (2.4.3), um ein optimales Ergebnis durch die richtigen Befehle zu erzeugen.

Zum Abschluss des Theorieteils geht es in Kapitel 2.4 um **Herausforderungen** und Anwendungsbereiche von Multi-Scale-Darstellungen. In dem Zuge wird auf **Zoomlevel** und ein **MasterScale Diagramm** zur Planung von Zoomstufenveränderungen eingegangen (2.5.1), sowie auf eine **stilistische und visuelle Konsistenz** (2.5.2) und dem sogenannten

Level of Detail und **Level of Abstraction** (2.5.3). Die Ergebnisse des Theorieteils werden im Anschluss für den praktischen Teil herangezogen, um Designkriterien festzulegen, die für Multi-Scale-Karten wichtig sind.

Im Zuge von **Kapitel 03** wird die **Methodik** vorgestellt. Dazu werden in Kapitel 3.1 die technische Umsetzung und nutzerfreundliche Gestaltung des Workflows behandelt, bevor **spezifische Designkriterien** für die Symbol- und Mustergenerierung auf Basis der Theorie zusammengefasst werden. In Kapitel 3.3 wird basierend auf den Erkenntnissen von **Kapitel 02** eine **Testumgebung für den praktischen Teil ausgewählt**, dafür werden Bildgenerierungsmodelle auf ihre Eignung getestet.

Für den praktischen Teil in **Kapitel 04** werden **Hypothesen** für erwartete Ergebnisse aufgestellt und eine **open source basierte Testumgebung** erstellt, in der die generierten Symbole und Muster eingebettet werden sollen (4.1). Diese wird mit OSM und OpenFreeMap Basisdaten eines Gebiets in Österreich befüllt, um eine realistische topographische Umgebung zu haben. Innerhalb von Kapitel 4.2 werden spezifisch Multi-Scale Aspekte festgehalten und getestet, inwieweit KI diese umsetzen kann. Kapitel 4.3 dient dem **Prozess der Symbol- und Mustergenerierung**. Dabei wird versucht einen möglichst generischen Prompt zu finden, der dabei hilft Symbole und Muster über Maßstäbe hinweg zu gestalten.

Das **Ergebnis** der Tests wird innerhalb von **Kapitel 5** dargestellt: Zum einen dem erstellten **Workflow** (5.1), identifizierte **übergeordnete Prompts** und **hilfreiche Erkenntnisse** (5.2), bevor es mit der Beantwortung der Hypothesen, sowie dem Zugriff auf den Workflow endet. In **Kapitel 6** erfolgt die **Diskussion**, und es wird auf Stärken (**Fehler! Verweisquelle konnte nicht gefunden werden.**), sowie Schwächen des Workflows (**Fehler! Verweisquelle konnte nicht gefunden werden.**) eingegangen. Die Masterarbeit endet mit der **Conclusio** (Kapitel 7), Beantwortung der Forschungsfragen (7.1), sowie eines Zukunftsausblickes (7.2).

2 Theoretische Grundlagen

Innerhalb der Kartographie haben sich über die Zeit **graphische Designaspekte und Variablen** gefestigt, über diese soll folgend ein Überblick verschafft werden. Damit die Symbole- und Muster, die mittels KI erzeugt werden, den kartographischen Grundlagen entsprechen und affektiv, sowie funktional wahrgenommen werden, behandeln die folgenden Unterkapitel verschiedene Aspekte der Kartenerstellung. Zusätzlich zu der klassischen Kartographie gibt es wiederholt neue Ansätze und Analysen zu psychologischen Hintergründen, die verständlicher machen, wie **NutzerInnen von Karten auf diese reagieren**, weshalb im Anschluss auf die **psychologische Wahrnehmung** von Farben, Formen und Mustern eingegangen wird. Zudem sollen **generative KI-Methoden und Prompt Engineering** betrachtet werden, als ein Überblick über mögliche Anwendungen und Aspekte, die für den praktischen Teil beachtet werden müssen, bevor der Theorieteil mit Herausforderungen und Anwendungen von Multi-Scale-Karten abschließt.

2.1 Designaspekte in der Kartographie

Kartographie und Design sind eng verbunden. Im Zuge von Stil und Ästhetik, die bei der Kommunikation von Inhalten eine Rolle spielen, wird mit **Ästhetik die Gesamtqualität einer Karte** beschrieben. Diese wird beeinflusst von allen getroffenen Designentscheidungen innerhalb einer Karte (Nestel, 2019).

Um diese Entscheidungen treffen zu können, geht es in dem folgenden Kapitel und Unterkapiteln um **Designaspekte** in der Kartographie. Es beginnt damit, wie sie sich **im Laufe der Zeit verändert** haben, um den heutigen Stand besser nachvollziehen zu können. Darauf folgend werden **graphische Variablen** genauer betrachtet, wie die Theorie vom **Kartographen Jaques Bertin**, der früh eine Grundlage für die Kartengestaltung und Informationsvermittlung festlegte. Diese können für die Symbolerstellung und für den geplanten Workflow herangezogen werden. Im Anschluss wird auf **Aspekte der graphischen Kommunikation** eingegangen, die für eine affektive Wirkung von Kartenelementen beitragen kann. Im letzten Unterkapitel geht es um spezifische Prinzipien der Symbol- und Musterdarstellung.

2.1.1 Entwicklung kartographischer Designaspekte im Laufe der Zeit

Die **Kartographie** hat sich über die letzten Jahrzehnte **stark weiterentwickelt**, speziell im Zuge der Digitalisierung. Die daraus entstehenden neuen Möglichkeiten eröffnen Chancen und Risiken. Viele Prozesse können automatisiert und mittels speziell für die Kartographie- und Geoinformation spezialisierter Programme beschleunigt und grundlegend mit einem anderen Fokus angegangen werden. Um vorausgegangenen Entwicklungen des heutigen Standes und die Veränderungen über die Zeit besser nachvollziehen zu können, wird im

folgenden Unterkapitel ein kurzer Überblick über die zeitlichen Veränderungen kartographischer Designaspekte gegeben.

Die Karte als graphische Darstellung wurde lange als **Abbild und Reproduktion der sichtbaren Umgebung** verstanden. Zeichnungen, Karten und Pläne haben reale Objekte dargestellt und sollten zeigen, wie etwas ist (Kang & Wang, 2025). Kartographie hat sich früh **zwischen Kunst und Wissenschaft** bewegt. Speziell im Mittelalter flossen künstlerische Komponenten in die Kartographie ein, um religiöse und mythische Weltanschauungen darzustellen (Ribeiro et al., 2018).

Mit der **Einführung des Buchdrucks** war es einfacher möglich geographische und kartographische Inhalte in die Gesellschaft zu bringen. Um mehr Menschen anzusprechen und auf Karten und ihre Inhalte aufmerksam zu machen, wurde im Laufe der Zeit noch **stärker Wert auf Ästhetik und Benutzerfreundlichkeit** gelegt. Bereits Leonardo da Vinci zeichnete Karten und vereinte die Berufe: Künstler, Ingenieur und Wissenschaftler, indem er genaue Messungen mit künstlerischen Komponenten verband (siehe Abb. 2) (Kang & Wang, 2025; Ribeiro et al., 2018).




Abb. 2: Stadtplan der italienischen Stadt Imola, 1502 von Leonardo Da Vinci (Leonardo Da Vinci (1452-1519) - A Map of Imola, o. J.)

Die Kartographie war durch **technische Präzession** geprägt, trotzdem hatten Karten zusätzlich eine künstlerische Komponente, da sie detailliert und möglichst genau per Hand gezeichnet wurden. Ein Beispiel für den Stil dieser Zeit sind die Schweizer Karten und das typische Design der Gebirgsreliefkartographie des Kartographen Eduard Imhof.

Ab dem **18. Jahrhundert** haben sich Graphiken weiterentwickelt. Charles de Fourcroy brachte mehr Variablen ein und stellte fest, dass die zwei Dimensionen eines Blatt Papiers weiteres als den sichtbaren Raum darstellen können, **es entstand ein Zeichensystem**. Graphische Bilder wurden übereinandergelegt, transformiert und klassifiziert, dadurch

wurde eine einfache Graphik lebendiger. Der Designbegriff wurde vor den beiden Weltkriegen Synonym mit dem Stil und Aussehen einer Karte verwendet. Erst nach dem zweiten Weltkrieg wurde er spezifischer und die Graphik wurde ein Instrument zur Verarbeitung von Informationen. Im Laufe des **20. Jahrhunderts** rückten **Designprinzipien** in den Fokus, wie eine klare Lesbarkeit und die Wirkung der Graphik auf KartenleserInnen. Das Ziel war es, wahre Karten verständlich und ansprechend zu gestalten. Von der Mitte bis Ende des 20. Jahrhunderts haben sich klarere Regeln etabliert und gewisse Designnormen haben sich durchgesetzt, darunter:

- I. Die **Lesbarkeit** von Symbolen
- II. Das Wissen und die Verwendung unterschiedlicher **Hierarchien** bei Kartenelementen
- III. Der **Kontrast**
- IV. Eine sogenannte **Figur-Grund-Beziehung** (figur-ground relationship)

Mit Figur-Grund-Beziehung ist eine Art der Hierarchie gemeint, wichtige Informationen, die als Figur bezeichnet werden, sollen vom Hintergrund (ground) getrennt werden. Zudem wird Design zum einen als Prozess und zum anderen als Produkt (die Karte selbst) betrachtet. (Bertin, o. J.; Kang & Wang, 2025; A. J. Kent & Vujakovic, 2018; Nestel, 2019).

Der Stil einer Karte steht seit den 2000ern mehr im Vordergrund. Unter Stil versteht man dabei, dass bestimmte definierte Gemeinsamkeiten innerhalb einer Karte erkannt werden und dass die Unterschiede dieser Gemeinsamkeiten sich unterscheiden zu anderen Karten. Ein **kartographischer Stil kann als Erkennungszeichen und Aushängeschild** der KartenerstellerInnen oder dem Produkt dahinter dienen. Zudem gibt es länderspezifische Stile, wie zum Beispiel bei bereits erwähnten Schweizer Karten, der Schweizer Stil (A. Kent & Vujakovic, 2009).

Im **Zuge der Digitalisierung** hat sich die Kartographie in eine **neue Phase** begeben. Durch Geographische Informationssysteme (GIS) ist der Fokus stärker auf computergestützte Kartographie übergegangen. Frei zugängliche GIS-Software (z.B. QGIS), Webkarten und der Zugriff auf offene Daten (z.B. OSM) **vereinfachen kartographische Prozesse** und helfen bei der **Automatisierung von Prozessen**. Im Vergleich zu traditionellen Methoden wird durch die neuen technologischen Möglichkeiten **Zeit und Arbeitsaufwand gespart**. Es entstehen verstärkt interaktive Karten und die geographische Kommunikation tritt stärker in den Vordergrund (Kang & Wang, 2025; A. J. Kent & Vujakovic, 2018).

Innerhalb der letzten Jahre ist **KI ein größeres Thema geworden und hat an Bedeutung zugenommen**. Die Möglichkeit, damit digitale Prozesse noch schneller zu optimieren, Designs zu entwerfen und den gesamten Kartographie Bereich noch angepasster an NutzerInnen zu machen, macht sie zu einem viel diskutierten Thema (Kang & Wang, 2025). In Kapitel 2.3: „Überblick über generative KI-Methoden für eine kartographische Anwendung“ wird dazu ein detaillierter Überblick gegeben.

Insgesamt wird klar, dass sich die Kartographie speziell innerhalb der letzten Jahre schnell weiterentwickelt hat und der **digitale Bereich ein großer Schwerpunkt** geworden ist. Es

wird deutlich, dass Kartographie über die Zeit mit Kunst verbunden gewesen ist, zudem haben künstlerische Aspekte sowie der Stil und Designprinzipien sich über die Zeit mitentwickelt.

2.1.2 Graphische Variablen als Grundlage kartographischer Stilbildung

Um kartographische Darstellungen **ansprechend und nutzerfreundlich** zu gestalten, gab es in der Vergangenheit bereits einige Ansätze. Sie prägen bis heute das Grundlegende Verständnis und Vorgehen bei der Erstellung kartographischer Inhalte, auch wenn sie zum Teil vor dem Aufkommen von GIS- Software aufgestellt worden.

Eine grundlegende Theorie zur visuellen Darstellung und ein Standardwerk zu der Gestaltung von Karten wurde vom Kartographen **Jaques Bertin** bereits im Jahr 1967 verfasst und ist in neuen Veröffentlichungen Thema. Er hat eine Theorie namens „**Graphische Semiologie**“ veröffentlicht, bei der es um die Gestaltung von Karten geht, die eine allgemein anerkannte Grundlage darstellt und als ein systematisches Regelwerk genutzt werden kann.

Bertin unterscheidet dabei **sechs zeichengestaltende Variablen**, die Informationen transportieren können. Darunter die Form, Muster, Orientierung, Farbe, Helligkeit und Größe, wie in Abb. 3 dargestellt. Diese bilden zusammen mit ihren Variationen als kartographische Elemente und Gestaltungsmittel die **Grundlage für die Symbol- und Musterdarstellung in topographischen Karten**.




Abb. 3: Graphische Variablen nach Bertin („Grundelemente der Karte“, 2013).

Für die **sechs verschiedenen Variablen** gibt es spezifischere Definitionen:

I. Form

Das Aussehen und die Gestalt eines darzustellenden Symbolen. Sie ist für nominale Daten geeignet, da sich die verschiedenen Formen gut unterscheiden lassen.

II. Muster

Bezogen auf die flächenhafte Darstellung werden damit die Grob- und Feinheiten innerhalb eines Kartensymbols beschrieben.

III. Orientierung

Bezieht sich auf die Ausrichtung beziehungsweise den Drehwinkel eines Kartensymbols. Sie ist speziell für nominale Daten geeignet, für ordinale Daten können höchstens Pfeile oder Uhren als Orientierung dienen.

IV. Farbe/ Farbton (hue)

Ein dominanter Wert des sichtbaren Lichtes.

V. Helligkeit

Helle oder dunklere Varianten eines Farbtones.

VI. Größe

Beschreibt Variationen in Bezug auf die Länge, die Fläche oder das Volumen eines Symbolen.

Jeder diese Variablen ist **für bestimmte Datentypen geeignet**. Die genaue Eignung ist zusätzlich in Abb. 4 dargestellt (Bertin, o. J.; Koch, 2001). Die meisten dargestellten Symbole lassen sich einer der Variablen zuordnen (White, 2017). Zu den graphischen Variablen kommt die Lage und Darstellung innerhalb einer Ebene, diese kann dabei nulldimensional, eindimensional oder zweidimensional oder punkthaft, linienhaft, oder flächenhaft sein. Zudem grenzt Bertin Kartendesign und die Graphik von anderen Zeichensystemen ab und stellt die **Graphik als eigenständiges System** dar. Für Bertin sind kartographische Graphiken zum einen zur Speicherung von Informationen und als Forschungsinstrument geeignet, sowie Bestandteil von wissenschaftlichen Erkenntnisprozessen (Bertin, o. J.; Hake et al., 2002).

Die graphischen **Variablen von Bertin prägen bis heute die kartographische Gestaltungsweise**, wurden aber im Laufe der Zeit erweitert und kombiniert, unter anderem von MacEachren um moderneren Darstellungsmethoden, wie Bildschirmen, gerecht zu werden. In Abb. 4 sind die Variablen in der linken Spalte aufgelistet, die rot markierten sind durch die Geographen MacEachren (1995) und Slocum (im Jahr 2009) ergänzt worden. Zudem ist ihre jeweilige Qualitative und Quantitative Eignung dargestellt (MacEachren, 2004; White, 2017). Dabei sind **Bertins Variablen um folgende ergänzt** worden:

I. Farbsättigung (Colour Saturation)

Beschreibt die Intensität eines einzelnen Farbwertes, spezieller hellere und dunklere Versionen eines Farbtons.

II. Anordnung (Arrangement)

Die räumliche Verteilung einzelner Symbolelemente.

III. Textur (Texture)

Die relative Feinheit oder Grobheit eines Kartensymbols.

IV. Transparenz (Transparency)

Das Level, inwieweit ein Symbol in den Hintergrund übergeht, je nachdem wie durchsichtig es gestaltet wird.

V. Schärfe (Crispness)

Die Darstellungsschärfe von Grenzen.

VI. Auflösung (Resolution)

Die Genauigkeit und Detailliertheit eines Datensatzes (White, 2017).

	Ground	Figure		Associative	Selective	Nominal (non-ordered)	Ordinal (ordered)	Numerical (quantitative)
Location				Y	Y	G	G	G
Size				N	Y	G	G	G
Shape				Y	N	G	P	P
Orientation				Y	Y	G	M	M
Color hue				Y	Y	G	M	M
Color value				N	Y	P	G	M
Texture				Y	Y	G	M	M
Color saturation						P	G	M
Arrangement						M	P	P
Crispness						P	G	P
Resolution						P	G	P
Transparency						M	G	P

visual variable variations Y=yes; N=no; G=good; M=marginal; P=poor; hatched=n/a

Abb. 4: Visuelle Variablen und ihre Eignung für verschiedene Datentypen Bertin's Variablen mit Erweiterungen von MacEachren (R. Roth, 2017).

Aus dem Jahr 2009 gibt es von Kent und Vujakovic ein Paper zum Thema Stil von europäischen topographischen 1:50.000 Karten. Ihr Ziel war es, die **stilistische Vielfalt der Karten zu kategorisieren**, klassifizieren und sie dann zu analysieren. Dafür haben sie sich 2388 Symbole aus 20 Karten angeschaut. Ihren Fokus haben sie speziell auf **Symbolik** gelegt und sich **fünf Kriterien** auf Basis von Bertin mit einer qualitativen Analyse genauer anschaut: Die **Klassifizierung, Farbe, Weißraum, visuelle Hierarchie und Beschriftungen**. Um die Symbole klassifizieren zu können, wurde ein dreistufiges Typologie Framework entwickelt, welches in Abb. 5 dargestellt ist. Diese Sortierung könnte für die Symbolerstellung dieser Arbeit von Relevanz sein, jedes Symbol eines vorher erstellten Stichprobendatensatzes konnte einer der Kategorien zugeordnet werden. Dabei wurde speziell darauf geachtet, welche Symbole sich gut von anderen abgrenzen und Detaillierungsgrad der Symbole berücksichtigt.




Abb. 5: Für die Klassifizierung von Legendensymbolen erstelltes Typologie Framework, aufgeteilt auf drei Ebenen (A. Kent & Vujakovic, 2009).

In diesem Paper wird der Variable Farbe ebenfalls eine wichtige Rolle bei der Symbolisierung von Kartenmerkmalen zugeschrieben. Soweit möglich, werden *bei topographischen Karten die Farben der Landschaft wiedergegeben*. Um die Farben der verschiedenen Karten einordnen zu können, wurde zur Messung eine diskreten Farbreihe verwendet und Symbole anhand ihrer Farbe jeweils einer Kategorie zugeordnet.

Das Paper kam zu dem Ergebnis, dass es eine *hohe stilistische Vielfalt* bei den betrachteten Karten gibt. *Länder mit einer langen Kartentradition* wie die Schweiz oder Italien haben komplexe und *umfangreiche Symbolsysteme*. Die räumlichere Nähe hat sich bei einigen Karten innerhalb der Symbolverwendung widergespiegelt, zum Beispiel hatten Großbritannien und Irland einen ähnlichen Stil, sowie die skandinavischen Länder Dänemark, Norwegen und Schweden. Interessant ist dabei in Bezug auf Symbole, dass die *traditionellen kartographischen Länder eher klassische Farben* für Symbole nutzen, welche die Natur wiedergeben, während *ansonsten einfach gehaltene schwarze Symbole* für verschiedene Bebauungsarten genutzt werden.

In dem Paper, wird betont, wie *wichtig die graphischen Variablen sind*. Diese bestimmen unter anderem, wie eine Landschaft wahrgenommen wird, welche Kartenelemente dominant sind und wie ein Stil durch ein Land geprägt ist. Zudem zeigen sie, wie stark *funktionale und ästhetische Präferenzen* bei der Kartenerstellung miteinfließen und wie individuell der Kartenstil ist (A. Kent & Vujakovic, 2009).

Diese Erkenntnisse der graphischen Variablen und der Bedeutung von Farben, legen eine *erste Grundlage, um funktionale Symbole und Muster zu erstellen*.

2.1.3 Kartographische Kommunikation

Zusätzlich zu grundlegenden graphischen Variablen stellt sich die Frage der **Kommunikation zwischen Kartenersteller- und NutzerInnen**. Wie kartographische Inhalte wahrgenommen werden und wie die Vermittlung bestmöglich gestaltet wird, ist ein Thema mit der sich seit Jahren innerhalb der Kartographie beschäftigt wird. Eine bekannte Publikation ist von Kent, der im Jahr 2018 ein Paper zu dem Thema: „Form Follows Feedback: Rethinking Cartographic Communication“ veröffentlicht hat. In früheren Ansätzen, wie der des Kartographen Koláčný, war das Ziel die Wirksamkeit einer Karte zu verbessern. Dabei war die Karte wie ein Kanal, der die Informationen der Karte an NutzerInnen weitergibt. Der Informationsfluss ging vom Kartenersteller zum Nutzer als ein linearer Prozess. Kent betont, dass der kartographische Prozess ein **dialogischer** sein soll. Es soll einen **Kreislauf zwischen KartographInnen und NutzerInnen** des Kartenprodukts geben, damit Feedback von NutzerInnen direkt eingearbeitet werden kann. Speziell aus dem Grund, dass sich Kartenprodukte und Erwartungen an sie, durch Digitalisierung und digitale Medien schnell verändern könnten. Zudem gibt es durch soziale Medien die Möglichkeit für „Amateur“ KartographInnen Reichweite zu erzielen, wobei die kartographischen Grundlagen dabei in den Hintergrund geraten können. Speziell die sozialen Medien sieht Kent aber als eine neue Möglichkeit Feedback für kartographische Inhalte zu bekommen. Im Gegensatz zu den früheren Ansätzen, kann durch **Social Media schnelles Feedback** generiert werden.

In Abb. 6 hat Kent das neue Kommunikationsmodell visuell dargestellt. KartographInnen und NutzerInnen sind getrennt durch den Zeitpunkt der Verbreitung. Sie **stehen aber im**




Abb. 6: Kent's Kartographisches Kommunikationsmodell mit einem NutzerInnen Feedback als kontinuierlicher Kreislauf (Kent, 2018).

Austausch durch den Prozess der Kartenerstellung und dem Engagement der NutzerInnen. Das Modell schlägt vor, eine **Karte kontinuierlich weiterzuentwickeln** (Darstellung als Unendlichkeitszeichen ohne klares Ende) auf Basis des Feedbacks von KartennutzerInnen

nach der Veröffentlichung der Karte (siehe Abb. 6 „Point of Dissemination“). Bevor KartographInnen sich Feedback einholen, können sie einen theoretischen Endpunkt festlegen, bei dem die Karte an die NutzerInnen weitergegeben und im Anschluss Feedback eingearbeitet wird.

Kent möchte mit dem Modell selbst dazu beitragen, dass sich die **Karte vom Kartographen aus weiterentwickelt**. Er macht darauf aufmerksam, dass KartenerstellerInnen nach der Veröffentlichung selten verhindern können, dass ihre Karten kopiert und angepasst werden, aber dass das neue Kommunikationsmodell diesen Wandel anerkennt und selbst Veränderungen nach NutzerInnenfeedback vornimmt. Kartenprodukte sollen möglichst **nutzerfreundlich** werden und trotzdem die Einhaltung von kartographischen Techniken und einer guten Gestaltung berücksichtigen (A. J. Kent, 2018).

Das NutzerInnenfeedback steht bei seinem Modell deutlich im Vordergrund, im Vergleich dazu hatte die Kartographin Brewer im Jahr 1999 noch davon abgeraten sich speziell in Bezug auf Farben zu sehr an Vorlieben von NutzerInnen zu orientieren, sondern den **Fokus** auf eine **klare Darstellung** zu legen (Brewer, 1999).

Für den geplanten Workflow ist Nutzerfeedback im Zuge dieser Arbeit nicht geplant, da die Erkenntnisse bereits durchgeführter NutzerInnentests herangezogen werden. Das **Prinzip eines Kreislaufes** und immer wieder neuem Input und Feedback lässt sich auf die **Arbeit mit KI übertragen**, da dort nach einem ersten Input mittels Prompt Engineering zum Teil mehrere Durchlaufschleifen benötigt werden, bis die KI den gewünschten Output liefert.

Innerhalb der Kartographie und der Kommunikation kartographischer und graphischer Inhalte ist die **Kartosemiotik** eine Theorie, die untersucht, wie **Karten als Kommunikationsmittel** funktionieren. Damit die Kommunikation der Inhalte klappt, ist es wichtig zu verstehen, wie ein Zeichen (z.B. ein Symbol) auf BetrachterInnen wirkt. Es entsteht eine **dreiteilige Verbindung** zwischen dem **realen Objekt**, dem **Symbol** beziehungsweise Zeichenträger selbst und dem, was es in dem **Kopf der BetrachterInnen auslöst**. Damit die Kommunikation funktioniert und das Symbol, wie von den KartenerstellerInnen gewünscht aufgenommen wird, sollte die **Bedeutung klar erkennbar** sein, zum Beispiel durch die Variablen Größe und Kontrast, eine Ähnlichkeit zu dem realen Objekt hilft zusätzlich bei der Erkennung. Die Kommunikation ist dann erfolgreich, wenn die dargestellte Information zu dem Wissen von BetrachterInnen passt und zu einer Reaktion führt. Eine Karte mit ihren Inhalten dient damit laut Hake et al. als Werkzeug bei BetrachterInnen eine Vorstellung im Kopf zu erzeugen und ist ein **Wechselspiel zwischen der Wahrnehmung und der Vorstellung** (Hake et al., 2002).

Die Kommunikation von kartographischen Inhalten kann durch Fehler und irreführende Informationen beeinflusst werden, speziell im Zusammenhang mit KI. Das Paper „The Ethics of AI-Generated Maps: A Study of DALLÉ 2 and Implications for Cartography“ von Kang et al. beschäftigen sich speziell mit der Vertrauenswürdigkeit von Karten, die mithilfe von KI erstellt worden. Dabei wurden mittels DALLÉ 2 Karten generiert und mit, von Menschen erstellten Karten, verglichen. **Wenn KI generierte Karten optisch richtig aussehen, ist es nicht garantiert, dass sie inhaltlich korrekt sind** und die Inhalte

verständlich kommuniziert werden können. Das Paper warnt vor potenziell bedeutungslosen und schädlichen Karten, die durch KI entstehen können und will einen Ansatz liefern, um KI generierte Karten besser identifizieren zu können (Kang et al., 2023).

Gartner et al. haben 2024 ebenfalls ein Paper zu dem Thema **Glaubwürdigkeit von Karten** veröffentlicht mit dem Namen: „Conceptualizing and Validating the Trustworthiness of Maps through an Empirical Study on the Influence of Cultural Background on Map Design Perception“. Speziell gehen sie darauf ein, **ob die kulturelle Prägung die Art und Weise beeinflusst, wie Karten gelesen werden** und ob ihnen vertraut wird. Es wurden dafür zwei Karten eines fiktiven Gebiets mit identischem Inhalt an StudienteilnehmerInnen gezeigt, mit jeweils zwei verschiedenen Kartenstilen. Sichtbar in Abb. 7, als erstes im Stil der offiziellen topographischen Karte vom österreichischen Bundesamt für Eich- und Vermessungswesen und als zweites im Stil vom kasachischen Komitee für Geodäsie und Kartographie (Gartner et al., 2024).




Abb. 7: Glaubwürdigkeit von Karten im Zusammenhang mit dem kulturellen Hintergrund. Fiktive Karten im österreichischen Stil (links) und Karte im kasachischen Stil (rechts) (Gartner et al., 2024).

Der Maßstab war 1:250.000, alle Kartenelemente waren identisch, nur der Landesstil wurde jeweils verändert. 50 Testpersonen aus Österreich und Kasachstan haben die Karten im semantischen Differential („**Wie attraktiv ist das Design?**“, „**Wie klar ist die Karte?**“...) bewertet. Dabei kam heraus, dass jede Gruppe den **eigenen Kartenstil besser bewertet** hat. Der Grund ist die **Vertrautheit mit der Farbwahl, Schriftarten und dem Layout**. Die Studie zeigt, dass kulturelle Prägungen die Wahrnehmung, Ästhetik und Vertrauen beeinflussen (Gartner et al., 2024).

Heutzutage helfen, wie im Kapitel 2.1.1 bereits angeschnitten, Designsoftwares dabei, Schriften und Stile zu verbessern, aber können dazu führen, dass eine **Karte mehr ein ästhetisches Produkt**, als ein inhaltlich korrektes wird. Zumindest Kent und Vujakovic sehen in ihrer Veröffentlichung „The Routledge Handbook of Geospatial Technologies and Society“ nicht nur Vorteile, sondern eine Gefahr in der **Ästhetisierung geographischer Informationen**. Genau diese Ästhetik bei Karten ist seit den 2000er Jahren ein Thema, was die Forschung stärker beschäftigt. Der Begriff der Ästhetik wird nicht nur mit schönen Karten assoziiert, sondern genutzt, um eine passende Atmosphäre innerhalb einer Karte zu schaffen. Eine **spezielle Ästhetik kann dazu beitragen, eine gewollte Stimmung an die**

KartennutzerInnen zu übermitteln, zum Beispiel können für ernste Themen, dunkle Farben verwendet werden (A. J. Kent & Vujakovic, 2018).

Im Verlauf dieser Arbeit, können die Ergebnisse hilfreich sein, um die Symbole und Muster so zu erstellen, dass sie **auf NutzerInnen vertraulich wirken**, was laut dem Paper nicht nur von der Datenqualität, sondern von dem kulturell geprägten Designverständnis und der Ästhetik abhängt, was je nach Zielgruppe mitbedacht werden sollte.

2.1.4 Prinzipien der Muster- und Symboldarstellung in topographischen Karten

In dem folgenden Unterkapitel sollen Prinzipien und Kriterien der Muster- und Symboldarstellung innerhalb der Kartographie detaillierter behandelt werden. Dafür werden die **wesentlichen Eigenschaften von Symbolen und Mustern** innerhalb topographischer Karten betrachtet. Die daraus gewonnen Erkenntnisse sollen die Grundlage legen für die praktische Symbol- und Mustergenerierung in Kapitel 3 und 3.2.

Hake et al. haben bereits im Jahr 2002 ein Lehrbuch zum Thema „Kartographie und der **Visualisierung raum-zeitlicher Informationen**“ veröffentlicht, in dem auf Prinzipien kartographischer Elemente und Frameworks eingegangen wird.

Form	Anordnung		
	lokal	linear	flächenhaft
Grundrissbild			
Bildhaft			
Aufrissbild			
Schrägbild			
Symbolisch			
Geometrisch			
Buchstabe, Ziffer, Zahl, Unterstreich			
Quantitätsangabe	lokal und Signaturen-kartogramm	linear und Band-kartogramm	flächenhaft und Flächen-kartogramm
stetig mit Signaturenmaßstab			
gestuft			
als Werteinheiten			

Abb. 8: Signaturen/ Symbolübersicht mit ihren Formen und möglicher Anordnung (Hake et al., 2002).

Symbole innerhalb einer kartographischen Anwendung werden synonym als **Signaturen oder Kartenzeichen** bezeichnet. Mit ihnen werden Objekte innerhalb einer Karte auf ihren Inhalt komprimiert dargestellt. Das Symbol als eigenständiges Zeichen wird als Syntax bezeichnet, die **Bedeutung** des jeweiligen als **Semantik**, zusätzlich wird es in der Legende erklärt. Symbole sind funktional, wenn sie für KartenleserInnen klar das räumliche Pendant

vermitteln können. Die verschiedenen Formen von Symbolen sind in Abb. 8 dargestellt. Speziell die Spalte „lokal“ und „bildhafte“, „symbolische“ und „geometrische“ Formen sind für die Symbolerstellung von Interesse. **Bildhafte Formen** sind näher an der Realität als geometrische Zeichen, die eher als abstrakte Formen bezeichnet werden können (Esri, Inc. & Bell, 2020; Hake et al., 2002). Für die KI-Generierung von Mustern könnten **Grundrissbilder näher getestet werden**, da es eine spezielle Perspektive ist, die schwieriger darzustellen sein könnte als Symbolische- oder Schrägbildformen.

Symbole können zusätzlich unterschieden werden in **zwei Kategorien**: Zum einen welche, die die **Umwelt und das darzustellende Element nachahmen**, wie zum Beispiel ein Flugzeugsymbol für einen Flughafen. Zum anderen gibt es **abstrakte Symbole**, die mittels einer Form etwas darstellen, was sich erst **durch die Legende erklärt** (White, 2017).




Abb. 9: Darstellungsarten der visuellen Variable Muster (White, 2017).

Muster können als eine **Variante der flächenhaften Darstellung** beziehungsweise Signatur gesehen werden (siehe Abb. 8: Spalte "flächenhaft"). Vor der Möglichkeit des Farbdruckes wurden verschiedene rasterartige Muster verwendet, um bei schwarzweiß Karten verschiedene Flächentypen unterscheiden zu können. Mit der Verwendung von Farben dienen sie als **Unterscheidung zwischen Flächen** mit identischer Farbe und als zusätzliche **Darstellungsart von Landschaftselementen** (White, 2017).

Für **Muster** gibt es ebenfalls **visuelle Variablen**, die miteinander kombiniert werden können. Wie in Abb. 9 sichtbar sind es die sechs Variablen, die bereits von Bertin vorgegeben worden (siehe Kapitel 2.1.2), erweitert um zwei weitere: **Anordnung** (Arrangement) und **die Textur** (Texture). Mit der Anordnung sind die **einzelnen Elemente** gemeint, **aus denen ein Muster** besteht und ob sie beispielsweise regelmäßig oder unregelmäßig, gleichmäßig oder zufällig angeordnet sind. Mit Textur ist die **relative Feinheit oder Grobheit** der Fläche gemeint. Ein Muster kann zudem angepasst werden, in dem die Form oder Ausrichtung einzelner Elemente innerhalb des Musters geändert werden (White, 2017).

Diese beiden Kartenelemente werden bei dem **klassischen Vorgehen der Kartenerstellung** zusammen mit weiteren Karteninhalten innerhalb eines **Signaturenkataloges** definiert (Hake et al., 2002).

Ein kompletter Signaturenkatalog ist kein Ziel dieser Arbeit, sondern der Fokus soll auf den beiden Signaturen von Symbolen und Mustern liegen (näheres in Kapitel 2.1.4). Für diese beiden Elemente ist es trotzdem eine Möglichkeit die **graphischen Gestaltungsvariablen vor dem Erstellen und KI generieren festzuhalten und zu definieren**, wie in Abb. 10 von Hake et al. beispielhaft für einen Laubwald festgehalten. Zudem können in dem Zuge Generalisierungsregeln festgehalten werden.

Objektbereich: z.B. Vegetation (4000)	Objektgruppe: z.B. Vegetationsflächen (4100)
Kartenobjektart: z.B. Laubwald (409)	
Abteilung aus DOM: Objektart: z.B. Wald, Forst Attribute: z.B. Laubwald Namen: z.B. Nr. d. Forstabteilung	
Regeln für die kartographische Gestaltung (beispielhaft)	
1. Festlegung des topologischen Objekttyps: z.B. flächenförmig (F)	
2. DKM-Objektteile bilden für	
– den Flächenrand in dunkelgrün, Darstellungspriorität: 5 – den Flächendecker in dunkelgrün, Darstellungspriorität: 1 – die Laubbaumsignaturen in dunkelgrün	
3. Modellierungsregeln	
Die Laubbaumsignaturen sind im Abstand von ca. 1 cm gleichmäßig zu verteilen. Der Mindestabstand zum Flächenrand beträgt 0,3 cm.	
4. Signaturendefinitionen	Signatur-Muster
Flächenrand	
Flächendecker	
Punktkform	

Abb. 10: Beispielhafter Aufbau des Signaturenkataloges (Hake et al., 2002).

Speziell die vorherigen Überlegungen, wie ein Muster dargestellt werden soll, zum Beispiel mit einer „**feinen Textur**“ und „**gleichmäßig**“ kann eine Grundlage für den geplanten Workflow dieser Arbeit legen. Die grundlegenden Kenntnisse über Symbole und Muster und ihre Darstellungsformen können hilfreich sein, der KI einen Input zu liefern, der kartographischen Standards gerecht wird.

2.2 Psychologische Wahrnehmung von Farben, Formen und Mustern

Die Gestaltung kartographischer Inhalte folgt nicht nur funktionalen, sondern auch **psychologischen Prinzipien**, die die Wahrnehmung und Interpretation von Kartenelementen beeinflussen können. Damit Karteninhalte von NutzerInnen **affektiv und funktional** wahrgenommen werden können und ansprechend gestaltet werden, kann es hilfreich sein, zusätzlich zu graphischen Variablen und theoretischen Konzepten, wie der in Kapitel 2.1.3 erwähnten Kartosemiotik, die psychologischen Hintergründe zu kennen.

Dafür wird im Unterkapitel 2.2.1 der Einfluss unterschiedlicher Kartenelemente auf NutzerInnen skizziert, darunter **Reaktionen auf geometrische Formen und Farben**. Im Anschluss wird in Kapitel 2.2.2 die **Orientierung innerhalb einer Karte** aus psychologischer Sicht behandelt, bevor im letzten Unterkapitel das Vertrauen in Karten näher betrachtet wird.

2.2.1 Einfluss von Kartenelementen auf NutzerInnen und die psychologische Bedeutung hinter dem „Affekt“

Es gibt bereits Veröffentlichungen zum **Thema affektives Design**, die sich mit der Wirkung geometrischer Kartensymbole auf NutzerInnen befassen. So untersuchte Klettner mittels eines semantischen Differentials die affektiven Reaktionen auf unterschiedliche geometrische Formen, sowohl in kartographischen und nicht-kartographischen Kontexten (Klettner, 2020).

Das **semantische Differential** ist eine Skala, die von dem amerikanischen Psychologen Charles E. Osgood ab 1952 entwickelt wurde. Dabei sollte messbar gemacht werden, welche **Gefühle und Bedeutungen** bestimmte Dinge, wie ein Bild oder eine Karte bei einem Menschen auslösen können. Klettner geht davon aus, dass **jedes Kartensymbol eine konnotative Bedeutung** hat, die bei Menschen eine **Reaktion**, wie ein Gefühl oder einen bestimmten Eindruck auslöst. Um das semantische Differential festzustellen, werden Menschen gebeten, anhand von Skalen ihre Gefühle wiederzugeben (z.B. von gut bis schlecht). Bei einer Auswertung lassen sich die Ergebnisse in drei Kategorien einteilen und es wird davon ausgegangen, dass Menschen in einer dieser Kategorien denken und fühlen:

- I. Valenz**
- II. Erregung**
- III. Dominanz**

Die **Grundreaktion** auf diese Kategorien wird als **Affekt** bezeichnet, sie kann **neutral, mittelstark oder extrem** sein und ist ein psychologisches Grundelement („psychological primitive“). Sie bildet die Basis von Emotionen und bestimmt, wie etwas wahrgenommen wird (Osgood, 2019).

Speziell dieser **“Affekt“-ive Begriff** ist im Zuge dieser Arbeit relevant, weil generierte Symbole und Muster affektiv wahrgenommen werden sollen. Klettner bezieht diesen psychologischen Aspekt gezielt auf Karten und betont, dass **Kartenzeichen immer eine Emotion und Reaktion auslösen**, wenn auch unterbewusst. Zudem gibt es Kartensymbole, die stärkere Reaktionen auslösen und dadurch in auf eine Weise nicht neutral sind. In Kapitel 4.2 wird detaillierter auf die Formen eingegangen, die bei Kettners semantischer Differentialanalyse affektiver wahrgenommen wurden (Klettner, 2020).

Eine zusätzliche Perspektive bietet die Studie von Lai und Yeh aus dem Jahr 2004, die in einem visuellen Experiment zeigten, dass **blinkende Symbole** auf Karten deutlich **schneller erkannt** werden als statische, speziell bei geringerem Kontrast oder größerer Symbolgröße.

Gleichzeitig wiesen sie darauf hin, dass eine **zu hohe Anzahl blinkender Elemente die visuelle Wahrnehmung überfordern** kann (Lai & Yeh, 2004).

Innerhalb dieser Arbeit werden blinkende Symbole erstmal nicht verwendet werden, damit es zu keiner Überforderung kommt. Es könnte aber eine Variante des Workflows geben, in dem Symbole angepasst werden können, sodass sie aufblinken können.

Im Jahr 2012 haben sich Fabrikant et al. mit der **emotionalen Reaktion auf ästhetische Kartendesigns**, spezieller Farbschemata im kartographischen Kontext beschäftigt. Dafür haben sie zwölf verschiedene topographische Karten an TeilnehmerInnen der Geographieabteilung der Uni Zürich gezeigt, wie in Abb. 11 dargestellt (die zwei ausgegrauten A und G wurden im Laufe des Experiments rausgenommen, da sie zu ähnlich zu anderen waren). Die Karten haben dabei alle ein **identisches Gebiet** abgedeckt, aber mit jeweils **unterschiedlichen Farbschemas**. Bei zehn der Farbschemas wurden Farben von bekannten Künstlern wie Matisse (Abb. 11: L) und Van Gogh (Abb. 11: F,H,J) extrahiert, für zwei Karten wurden die Farben von IGN France (Institut Géographique National) und Swisstopo (Abb. 11: K und D) verwendet. Dabei wurden zum einen mittels Eyetracker die Augenbewegungen der TeilnehmerInnen gemessen, zum anderen die Hautleitfähigkeit, um anhand derer die emotionale Erregung abzuleiten (Fabrikant et al., 2012).




Abb. 11: Zwölf Karten, mit unterschiedlichen Farbschemata (Fabrikant et al., 2012).

Es wurde deutlich, dass Farben ein starker **Erreger für das Hervorrufen von emotionalen Reaktionen** sind. Farben, die **untypisch für den Objekttyp** waren wurden von den TeilnehmerInnen als **befremdlich** wahrgenommen und führten zu einer stärkeren Reaktion, dagegen wurden Farben die **typisch für den Objekttyp** sind, zum Beispiel blau für Wasser, wurden **positiv** gewertet, die drei Karten, die am attraktivsten gewertet wurden, haben semantische Farben verwendet. Am attraktivsten wurde die Karte im Stil von Matisse (Abb.

11: L) wahrgenommen. Ein Ergebnis war, dass Karten die im Einzelnen abstraktere Farben hatten, trotzdem gut ankommen, solange die **Farben auf harmonisch und semantischer Ebene** zusammenpassen. Deshalb kommen Fabrikant et al. zu dem Schluss, dass zusätzlich zu strukturellen Parametern **ästhetische Aspekte und harmonische Anordnung** von Farben zueinander betrachtet werden sollten, um eine möglichst erfolgreiche Kartengestaltung zu gewährleisten (Fabrikant et al., 2012).

2.2.2 Psychologische Aspekte der Orientierung innerhalb einer Karte

Ein benannter psychologischer Aspekt, der für das Lesen von Karten relevant ist, ist der **“Desert fog effect”**, bei dem NutzerInnen aufgrund einer hohen oder niedrigen Zoomstufe **keine Orientierungspunkte** mehr haben und sich dadurch nicht mehr in der Karte zurechtfinden können. Dieser Effekt tritt **speziell bei Multi-Scale-Anwendungen** auf (Jul & Furnas, 1998). Dazu gehört die Veränderung eines Symbols über verschiedene Zoomstufen hinweg. Das kann dazu führen, dass dasselbe Objekt aufgrund zu starker Veränderung, zum Beispiel durch Generalisierung, nicht mehr wiedererkannt wird (Dumont et al., 2016).

Ein Vorschlag, um diesem Effekt entgegenzuwirken, kommt von Dumont et al., veröffentlicht 2020 im Paper „Designing Multi-Scale Maps: Lessons Learned from Existing Practices“, dabei können **gemischte Abstraktionsvorgänge** genutzt werden. Diese sollen verhindern, dass NutzerInnen insbesondere in mittleren Maßstabsbereichen die Orientierung verlieren. Speziell sollen dabei **in einem Maßstabsbereich mehrere Repräsentationsebenen** eingesetzt werden, zum Beispiel im städtischen Bereich einzelne Gebäude, während in ländlichen Regionen bereits generalisierte Blöcke gezeigt werden. Dadurch werden NutzerInnen früher mit den nächsten Zoomstufen konfrontiert und können diese dann in der nächsten Maßstabsstufe leichter identifizieren. Das verdeutlicht, dass es bei der Gestaltung von Kartenapplikationen auf eine **stilistische Kohärenz** ankommt, um eine Orientierung gewährleisten zu können. Dumont et al. thematisieren in diesem Zusammenhang eine kognitive Belastung, wenn die Kartenanwendung komplex ist und zum Beispiel durch den **“Desert fog effect”** eine Orientierungslosigkeit auftritt (Dumont et al., 2020).

Die Wahrnehmung von Karten hängt zusätzlich von **individuellen Faktoren und kulturellen Prägungen** ab, was durch Gartner et al. (siehe „2.1.3 Kartographische Kommunikation“) bestätigt werden konnte. In Fabrikant’s Studie haben beispielsweise ältere und männliche TeilnehmerInnen weniger starke Reaktionen auf die gezeigten Karten gezeigt als jüngere weibliche TeilnehmerInnen (Fabrikant et al., 2012).

2.2.3 Psychologische Hintergründe von Vertrauen in Kartenelemente

Bei dem Einsatz von KI ist es wichtig, dass die erzeugten Ergebnisse vertrauensvoll sind und glaubhaft, was einerseits von der Genauigkeit der Daten und kartographischen Grundlagen abhängt, andererseits von der Wahrnehmung und dem Eindruck der

betrachtenden Person. Die Hintergründe und die Art wie Karten, abgesehen von ihren kartographischen Inhalten, *optisch Vertrauen schaffen* können, ist ein Aspekt, welcher im Zuge des geplanten Workflows berücksichtigt werden sollen. Timothy Prestby hat 2024 eine Skala namens **MAPTRUST** vorgestellt, die als empirische Ergänzung zur Wahrnehmungspsychologie geeignet ist. Dabei haben 295 TeilnehmerInnen thematische Karten anhand von 24 Adjektiven (potenziellen Vertrauensindikatoren) bewertet, wobei zwölf Indikatoren übriggeblieben sind (Prestby, 2024).

Die anderen fielen raus, da sie bei einer Faktoranalyse (wie stark die Adjektive zu dem Faktor, in dem Fall dem Kartenvertrauen zusammenpassen) zu niedrige Werte erzielten und die zwölf übriggebliebenen Begriffe in einer weiteren Studie nochmals bestätigt werden konnten, diese sind in Abb. 12 dargestellt (Prestby, 2024). Für den geplanten Workflow innerhalb dieser Arbeit, könnten die Adjektive im Zuge der Symbol- und Mustererstellung herangezogen werden, um *glaubhafte und vertrauenswürdige Ergebnisse* zu erhalten.




Abb. 12: Adjektive der Map Trust Skala, die das Vertrauen in Karten messbar machen sollen (Prestby, 2024).

Zudem hat er sich im Zuge des Papers: „*Trust in maps: what we know and what we need*“ speziell mit dem Thema Glaubwürdigkeit und Vertrauen in Karten beschäftigt. Dabei wird betont, dass *visuelle Variablen* wie Farben, Lesbarkeit und die visuelle Hierarchie *für den Eindruck und die Einordnung einer Karte bedeutend* sind. Speziell die Helligkeit, die Sättigung und Hue (reiner Farbton) können die Wahrnehmung und Ästhetik einer Karte beeinflussen. Laut Prestby gibt es einen Zusammenhang zwischen der Schönheit, beziehungsweise der aufgenommenen visuellen Attraktivität einer Karte, der daraus gelesenen Kompetenz und dem Vertrauen. *Je stärker BetrachterInnen die Karte gefällt, desto mehr Vertrauen sie der Karte*, was in dem Paper mit „*halo effect*“ bezeichnet wird. Zudem sind Metadaten, wie zum Beispiel die Quellen und die Aktualität wichtige Infos, die bei Angabe vertrauen verstärken können. KI wird in dem Paper als ein Tool und Antrieb beschrieben, was es ermöglicht, schnell und einfach Karten erstellen zu können, aber das Risiko von Fehlern erhöht (Prestby, 2024).

Im Zusammenhang mit KI hängt das Vertrauen unter anderem von der **Wiederholbarkeit der Outputs ab**, da es bei identischer Texteingabe trotzdem verschiedene Ergebnisse rauskommen, ist es für BenutzerInnen schwierig die Herkunft und den Grund von Veränderungen nachvollziehen zu können, was zu einem Verlust von Vertrauen führen kann (Kang et al., 2023).

2.3 Überblick über generative KI-Methoden für eine kartographische Anwendung

Innerhalb des folgenden Kapitels sollen verschiedene KI-Methoden und Modelle vorgestellt werden, die für die Generierung von Mustern und Symbolen geeignet sein könnten. Dabei wird auf bereits getestete **KI-Modelle für kartographische Zwecke** eingegangen. Die detaillierteren Anforderungen an die KI-Programme werden in Kapitel 3.3: „Auswahl und Definition einer Testumgebung“ erläutert.

Da sich generative KI aktuell **schnell weiterentwickelt**, kann es sein, dass die Ergebnisse einiger Paper nicht mehr auf dem aktuellen Stand sind, dennoch wird folgend davon ausgegangen, dass die **Methoden für ältere Modelle**, mit in der Zwischenzeit **neu erschienenen Modellen ebenfalls funktionieren**, da diese noch **weiterentwickelter als Vorgängermodelle** oder Methoden sein sollten.

Generative KI (öfter GenAI genannt) ist eine Form und Technik bei der KI-Modelle mittels Trainingsdaten trainiert werden um **neue mediale Inhalte** wie Bilder, Videos oder Texte zu erstellen. Oft wird diese Bezeichnung als Oberbegriff für Modelle bezeichnet, die Text-zu-Text, Text-zu-Bild und Bild-zu-Bild Verfahren verwenden. Die Modelle können Muster, Strukturen und Verteilungen innerhalb der Trainingsdaten erkennen und anhand derer neue Inhalte oder realistische Nachbildungen erstellen. Ein Begriff der im Zuge der Kartographie dazu von Dunkel in seinem Paper „Generative Text-to-Image Diffusion for Automated Map Production Based on Geosocial Media Data“ verwendet wurde, ist: **„Generative Cartography“** oder **„GeoAI“**. Es ist ein neues Forschungsgebiet, zur automatisierten Erstellung von Karteninhalten (Dunkel et al., 2024; Kim et al., 2024; Sengar et al., 2025; Ye et al., 2024).

Auch wenn es **verschiedene Ziele von GenAI-Methoden** gibt, wie zum Beispiel Text- oder Bildgenerierung sind **gemeinsame Merkmale innerhalb der Datenstrukturen** zu erkennen. Je nach gewünschtem Ziel kommen dafür verschiedene Gestaltungsalgorithmen zum Einsatz. Ye et al. haben 2024 ein Paper zu dem Thema „Generative AI for Visualization: State of the Art and Future Directions“ veröffentlicht und dabei die **Methoden generativer KI für Visualisierungen** in verschiedene Kategorien eingeteilt. Es gibt „Sequence Generation“ für geordnete Daten zum Beispiel Text, Code oder Videos, „Tabular Generation“ für strukturierte Daten und „Graph Generation“ für Netzwerke. Für die **Bildgenerierung**, welche in dieser Arbeit relevant ist, gibt es die vierte Kategorie namens **„Spatial Generation“** (räumliche Generierung). Im Bereich der zweidimensionalen

Bildgenerierung arbeiten vor allem zwei KI-Methoden im Hintergrund: **Generative Adversarial Network** (GANs) und **Variational Autoencoder** (VAEs), zudem nehmen **Diffusion Modelle** im Veröffentlichungszeitraum des Papers eine **größer werdende Bedeutung** an (Ye et al., 2024).

GANs sind laut Kang et al. einer der wichtigsten und etabliertesten GeoAI-Algorithmen. Entwickelt wurden sie 2014 von Goodfellow et al. um möglichst realistische Bilder zu generieren. Dafür wird das **Deep-Learning-Modell mit echten Fotos trainiert**, um für Menschen möglichst realistische Outputs zu erzeugen. Dabei gibt es zwei Anteile, ein **Generator**, der in dem Fall **neue Kartenbilder erstellt**, die möglichst realistisch aussehen sollen und einen **Diskriminator**, der echte Karten, sowie die Karten des Generators als Input bekommt und erkennen soll, **welche Karten die echten sind**. Beide werden gleichzeitig trainiert und das Ziel ist es, dass der Generator so gute Karten erstellt, dass der Diskriminator sie nicht von den echten unterscheiden kann (Kang et al., 2019).

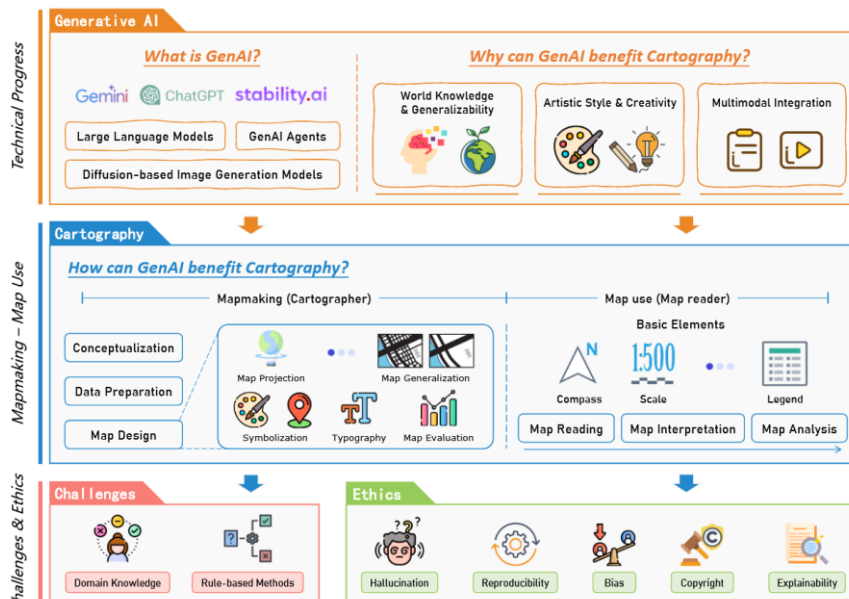


Abb. 13: Ein konzeptuelles Framework, wie KI innerhalb der Kartographie eingesetzt werden kann (Kang & Wang, 2025).

Eine **Erweiterung** der GAN's sind C-GANs („**Conditional GAN'S**“), die der KI zusätzlich eine **Bedingung als Zusatzinformation** mitgeben. Für kartographische Zwecke ist das relevant, da die KI ansonsten fiktive Karten generiert, die aussehen wie echte, aber keine reale Region wiedergeben. Eine Bedingung kann dabei sein, dass die KI nur die Karte nutzen darf, die ihr als Input gegeben wird, um auf diese Karte dann beispielsweise einen bestimmten Stil anzuwenden. Für kartographische Zwecke wurde damit unter anderem der **Kartenstil-Transfer über zwei Maßstäbe** hinweg erfolgreich getestet (auf die Ergebnisse wird in Kapitel 2.5.2 eingegangen).

VAE bestehen, wie ein GAN, aus zwei Komponenten, einem Encoder (**Verschlüsseler**), welcher ein Eingabebild auf seine wichtigsten Merkmale reduziert und einem Decoder, der anhand dieser Merkmale versucht das Bild zu rekonstruieren (**Entschlüsseler**). VAEs sind meist Teil einer KI-Architektur, jedoch eher um die Strukturen eines Bildes zu erkennen,

(Kang et al., 2019; Vivekananthan, 2024). Gegenüber anderen Modellen, wie Stable Diffusion scheint es aktuell als **bildgenerierendes Modell überholt** (Vivekananthan, 2024).

Kang & Wang haben sich Mitte 2025 mit generativer KI in Bezug auf Kartographie und der Kartenerstellung beschäftigt. Dabei haben sie **drei Haupttypen** festgehalten, die sich für kartographische Zwecke eignen: **LLMs**, **Diffusionsmodelle** und **GenAI-Agenten**. Auf diese drei Typen wird in den folgenden drei Unterkapiteln detaillierter eingegangen. In Abb. 13 ist ihr Framework vorgestellt, speziell der mittlere, blaue Block namens „**Mapmaking - Map Use**“ ist für diese Arbeit von Relevanz, vor allem das „Map Design“ und die „Symbolization“.

2.3.1 Large Language und Multimodal Large Language Modelle

LLMs steht für „Large Language Modells“, diese Modelle erzeugen Text und können zusätzlich Text-zu-Bild Inhalte generieren. Ein Text-zu-Bild- (gängigere englische Formulierung: „text-to-image“) Modell, besteht aus zwei Komponenten: Zum einen aus einem **Sprachmodell**, über das ein Inputtext (Prompt) eingegeben werden kann, zum anderen über ein **generatives Bildmodell**, welches das eigentliche Bild generiert. Bekannte Text-zu-Bild Modelle sind zum Beispiel DALL-E von OpenAI, Gemini von Google, LLaMA von Meta oder Claude von Anthropic (Dunkel et al., 2024; Kang & Wang, 2025).

Zusätzlich zu LLM's gibt es eine aufkommende und vielversprechende Weiterentwicklung namens MLLM's, (**Multimodal large language models**), sie sind gut darin, Daten wie **Bilder zu analysieren** und dazu **Feedback zu geben**, da sie auf großen Datenmengen beruhen und dieses Wissen bei der Analyse einsetzen. Im Vergleich zu Bildgenerierungsmodellen liegt zusätzlich ein Fokus auf einer starken Textverarbeitung. (Memduhoğlu, 2025; Wang et al., 2025).

Bei LLM's gibt es einen Parameter namens „**temperature**“, welcher die **Zufälligkeit der Outputs** steuert und das Gleichgewicht zwischen Kreativität und Konsistenz steuert. Eine Temperatur von 1 ist dabei meistens der Standardwert des Modells, ein niedriger Wert, kleiner als 1 steht für weniger Kreativität, ein Wert über 1 mehr Kreativität.

Bekannte MLLM's sind zum Beispiel Gemini von Google mit **Nano Banana** und von OpenAI **GPT-5.2**, sowie **Chat GPT Images**, bei dem die neueste Version im Dezember 2025 veröffentlicht wurde (*Bildverständnis | Gemini API | Google AI for Developers*, o. J.; *Entdecke GPT-5.2 | OpenAI*, o. J.).

Anfang 2025 hat sich Memduhoğlu mit einem MLLM in **Bezug auf kartographische Gestaltungsprinzipien** beschäftigt. Dieses Modell soll jedoch bald nicht mehr verfügbar sein (Proschofsky, 2026), dennoch könnten die Ergebnisse für andere Modelle interessant sein. Spezieller wurde GPT-4o von OpenAI analysiert, um herauszufinden, ob es ein geeignetes Tool für die Kartenerstellung sein könnte. Dabei wurden zum einen Text-zu-Text und Bild-zu-Text-Inputs getestet. Für die Text-zu-Text Bewertung wurden 15 **Fragen**

zu **kartographischen Inhalten** gestellt. Jede Frage wurde 100-mal gestellt und dabei die Temperatur Einstellung angepasst, um die **Kreativität und Konsistenz** der Outputs messen zu können (u.a. Symbolisierung, visuelle Hierarchie, Farblehre). Bei der Bild-zu-Text Analyse wurden Karten mit absichtlich eingebauten Fehlern als Input gegeben, um herauszufinden inwieweit das Modell Fehler erkennen und Verbesserungsvorschläge zu diesen machen kann. Memduhoğlu kam zu dem Schluss, dass **GPT bei den textbasierten Aufgaben zuverlässige Ergebnisse** liefern konnte. Bei der Interpretation (Bild-zu-Text) konnten Details, wie Beschriftungen, schwierig interpretiert werden. Es wird vorgeschlagen, es als Erweiterung zu nutzen und als Ergänzung menschlicher Expertise. Speziell das „Räumliche“ zu verarbeiten ist für das Modell ein schwieriges Gebiet. Zudem wird der **starke Zusammenhang zwischen Qualität der Prompts und des Outputs** betont (Memduhoğlu, 2025).

Im Zuge dieser Arbeit sind die Erkenntnisse interessant, da ein **Vorhandensein von Verständnis für räumliche Zusammenhänge** die Gestaltung von Mustern und Symbolen vereinfachen könnte und das Textelemente für einen besseren Output getrennt behandelt, bzw. für Symbole und Muster ausgeschlossen werden sollten.

2.3.2 Diffusionsbasierte Bildgenerierungsmodelle

Zu Diffusionsmodellen zählen Modelle, die **aus einem Input** (z.B. Text-/ Skizzen) **Bilder generieren** können. Sie fügen einem Bild ein zufälliges Rauschen hinzu und lernen im Anschluss diesen Prozess umzukehren und damit möglichst realistische Bilder zu generieren. Bekannte Modelle sind **zum Beispiel DALL-E** und **Stable Diffusion** (Kang & Wang, 2025).

Dadurch, dass **DALL-E** zu einem der **ersten veröffentlichten Bildgenerierungsmodellen** gehört, gibt es in Bezug darauf, bereits Paper die sich mit DALL-E und möglichen Anwendungsmöglichkeiten für kartographische Zwecke beschäftigt haben. Durch die Veröffentlichung von DALL-E und der damit **neuen Möglichkeit qualitative Bilder zu generieren**, wurden **Diffusion Modelle bekannter** (Drews et al., 2025; Dunkel et al., 2024; Kang & Wang, 2025).

Mit einem diffusionsbasierten Bildgenerierungsmodell in Bezug auf die Kartographie hat sich 2023 Kang in seinem Paper: „The ethics of AI-generated Maps: A study of DALL-E 2 and implications for cartography“ beschäftigt. Dabei geht es speziell um die Auswirkungen von KI-Content, es werden zusätzlich technische Details beschrieben. Kang et al. nutzen **generierte Karten mittels DALL-E 2** und vergleichen sie mit von Menschen gemachten Karten. Sie kommen zu dem Schluss, dass GeoAI-Techniken den **Kartenprozess beschleunigen** und die Kreativität durch Stiltransfer oder bei Generalisierungsaufgaben unterstützen können. Zur Zeit der Veröffentlichung des Papers gab es bei der Kartenerstellung mittels DALL-E Ungenauigkeiten und eine mangelnde Reproduzierbarkeit der erstellten Inhalte (Kang et al., 2023). Es können aber zumindest einfache,

minimalistische Bildzeichen ohne größere Vorkenntnisse mittels DALL-E erzeugt werden (Kang & Wang, 2025).

Zusätzlich gibt es, wie in Kapitel 1.1 bereits erwähnt, ein Paper von Drews et al. namens „A New AI Tool for the Design of Cartographic Pictograms (PictoAI) and Its Potentials for Increasing Their Meaningfulness“, in dem ein *angepasstes GPT-KI-Tool auf Basis von DALL-E* entworfen wurde, um *Piktogramme zu erstellen*. Das Paper wurde Anfang 2025 veröffentlicht und nutzt im Vergleich zu Kang et al. (voheriger Absatz) die neuere DALL-E Version, DALL-E 3. Dabei lag der Fokus darauf, möglichst konsistente Piktogramme zu erzeugen (siehe Abb. 14). Mittels einer empirischen Studie mit 70 TeilnehmerInnen wurden die generierten Symbole im Anschluss verglichen mit ihren OSM-Pendants, wobei herauskam, dass die *PictoAI Symbole* mit 67,26% deutlich *leichter korrekt interpretiert* wurden im Vergleich zu den OSM-Piktogrammen mit 31,79% (Drews et al., 2025).

Name	OSM	PictoAI	Name	OSM	PictoAI	Name	OSM	PictoAI
Viewpoint			Archaeological site			Bakery		
Crossing			Elevator			Fire Station		
Saddle			Car rental			Hairdresser		
Cave			Car wash			Communication tower		
Cliff			Bank			Hospital		
Monument			Alpine hut			Lighthouse		
Lift gate			Biergarten			Police		
Social Facility			Waste basket			Wind wheel		

Abb. 14: Erzeugte Piktogramme mittels angepasster ChatGPT Erweiterung und DALL-E im Vergleich zu den jeweiligen OSM Pendants (Drews et al., 2025).

Der Fokus liegt dabei zwar auf Inhalte für thematische Karten, dennoch gibt es *Erkenntnisse*, die allgemein *für die Symbolgenerierung praktisch sein können*. Damit die Erzeugung von Piktogrammen innerhalb von DALL-E über ChatGPT funktioniert und einheitliche Outputs liefert, wurden von den AutorInnen *Spezifikationen* festgelegt, an denen die KI sich orientieren sollte.

Da DALL-E keinen transparenten Hintergrund erzeugen kann, wurde ein *weißer Hintergrund* festgelegt um in späterer Folge das erzeugte Piktogramm leichter bearbeiten und ausschneiden zu können. Zudem wurde eine *hohe Ikonizität* festgelegt. Um den Output besser interpretierbar zu machen. Es wurden einfache und verallgemeinerte Designs verwendet, damit das Symbol über Maßstäbe hinweg funktionieren kann. Zudem haben die Autoren *Textelemente ausgeschlossen*, damit keine spezielle Sprache nötig ist und die Piktogramme sollten explizit *zentral ausgerichtet* sein, da bei ersten Tests dies ohne die Spezifikation nicht einheitlich war (Drews et al., 2025). Im Zuge dieser Arbeit sollen die

Symbole bei einer höheren Zoomstufe mehr Details aufweisen, aber für ein Symbol in einem niedrigen Zoomstufe könnte dieser Aspekt als Anforderung eingebracht werden.

Mit dem Modell **Stable Diffusion** haben sich 2024 Dunkel et al. beschäftigt. Dabei ging es speziell um die **automatische Generierung von Karten Icons**. Die Grundlage bildeten Social-Media-Daten (Hashtags und Emojis) mit Geotags. Das Ziel war es eine Icon-Übersichtskarte für einen Dresdner Park zu generieren. Als Hauptmodell wurde Stable Diffusion verwendet, sowie „hellofunnycity“ für das Fine Tuning im Comic-Stil. Sie betonen, dass **Prompt Engineering der Kern** ihrer Ergebnisse ist, spezifische Prompts, die dabei verwendet wurden, werden in Kapitel 2.4.3 näher betrachtet. Sie kommen zu dem Schluss, dass es bei der Nutzung von generativer KI Vorteile hat, **Aufgaben in einzelne für sich stehende Schritte zu unterteilen**. Der verwendete Code für die Icons wurde als Jupyter-Notebook festgehalten und kann öffentlich abgerufen werden (Dunkel et al., 2023, 2024).

Ebenfalls mit Stable Diffusion wurde 2024 im Zuge einer Masterarbeit an der TU München beschäftigt, die Arbeit an sich ist nicht öffentlich zugänglich, es wurde aber ein Paper mit den Erkenntnissen von Burghardt et al. veröffentlicht, bei dem der Autor der Masterarbeit mitgeschrieben hat. Dabei wurde das Vorgehen von Dunkel et al. für Londoner Sehenswürdigkeiten angewendet und kam ebenfalls zu dem Schluss, dass sich **Stable Diffusion** für die Erstellung von bildlichen Kartenobjekten eignet, jedoch **stark abhängig von den Modellen und eingestellten Parametern** ist (Burghardt et al., 2025).

2.3.3 GenAI-Agenten

Ein **GenAI-Agent**, ist ein **autonomes System**, welches mit seiner Umgebung interagiert und diese wahrnimmt, um mittels Maßnahmen bestimmte Ergebnisse und Ziele zu erreichen. GenAI-Agenten haben sich im Laufe der Zeit weiterentwickelt, von eher abgeschotteten Modellen, welche mit einer geringeren Datenmenge trainiert wurden, zu Modellen, welche LLM's und MLLM's verwenden. GenAI-Agenten können zudem miteinander kommunizieren und dadurch gemeinsame Lösungen entwickeln (Wang et al., 2025).

Dadurch das MLLM's sowohl **Bilder als auch Text** verarbeiten können, ist es damit möglich die Aufgaben und **Arbeitsschritte des kartographischen Prozesses auf einzelne Agenten aufzuteilen** (Abb. 15. Block „MLLM's – Agents“). Durch das Zerlegen können komplexere Aufgaben für die Modelle leichter verarbeitet werden. Ein Agent kann sich beispielsweise speziell um das Design einer Karte kümmern, ein anderer um die Datenanalyse. Die **Agenten arbeiten zusammen**, um die Aufgabe bestmöglich zu lösen und durchlaufen dafür mehrerer Kommunikationsrunden untereinander, damit die einzelnen Schritte aufeinander abgestimmt sind. Der Vorteil an GenAI-Modellen ist, dass sie nach einer Entscheidung (z.B. ob eine Karte technisch richtig und für Menschen verständlich ist) im Anschluss die entsprechenden Ergebnisse generieren und darstellen können. Wie AI-Agenten arbeiten und sich innerhalb des kartographischen Prozesses integrieren lassen, ist ebenfalls in Abb. 15

dargestellt (siehe Block „Multi-Agents“, sowie Block „Cartoagents“).

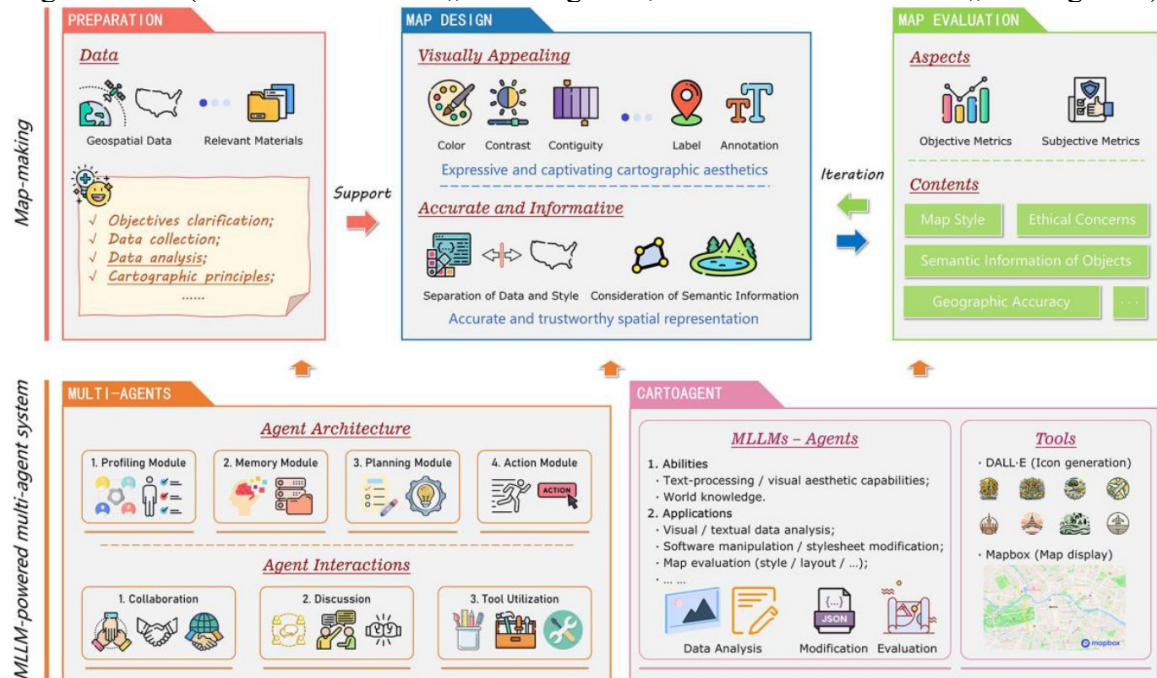


Abb. 15: Der Kartenerstellungsprozess und wie Agenten und spezieller angepasste Cartoagenten dabei helfen können (Wang et al., 2025).

Wang et al. haben sich Mitte 2025 mit **GenAI-Agenten auf Basis eines MLLM's** beschäftigt und für kartographische Prozesse den Namen „**Cartoagents**“ verwendet. In ihrem Paper namens „**CartoAgent: a multimodal large language model-powered multi-agent cartographic framework for map style transfer and evaluation**“ haben sie als einen Anwendungsfall den **Stil-Transfer** getestet, bei dem der künstlerische Stil einer Quelle auf bestehende Kartendaten übertragen werden sollte. In einer Vorbereitungsphase analysiert ein „Image Appreciator“ das künstlerische Bild (Abb. 16 „Preparation“), welches als Inspiration für den Kartenstil dienen soll. Ein „**Stylesheet Designer**“ erstellt anhand dieser Analyse ein **Gestaltungskonzept** für die Karte und ein „**Icon Designer**“ wählt **passende Symbole**, diese werden dann mittels DALL-E generiert. Zuletzt übersetzt ein „File Implementer“ alle Entwürfe in eine Datei, damit diese dann in kartographischen Programmen (wie Mapbox) genutzt werden kann. Zudem gibt es einen Agenten namens „Map Reviewer“ der die




Abb. 16: Überblick über die Rollenverteilung bei der Stil-Übertragung, in der mittleren Spalte der Icon Designer (Wang et al., 2025).

Ausgabe mit den am Anfang gesetzten Anforderungen vergleicht und falls sie zu sehr abweicht einen neuen repetitiven Vorgang in Gang setzt, bei dem alle Schritte wiederholt werden, um den Output zu optimieren. Um den einzelnen Agenten mit spezifischen Anweisungen Vorgaben für das gewünschte Ergebnis zu geben, werden **spezifische Prompts** für jeden einzelnen Designer verwendet. Diese werden detaillierter in Kapitel 2.4.3 behandelt (Wang et al., 2025).

Innerhalb dieses Papers werden ebenfalls einzelne Bearbeitungsschritte aufgeteilt (zu dem Vorgehen Dunkel et al. 2024 ebenfalls gekommen ist, siehe Kapitel 2.3.2) und der **Stilaspekt separat von geographischen Daten** angewendet, beziehungsweise wurden innerhalb dieses Vorgehens der Fokus auf die Erstellung des Stylesheets gerichtet ohne die direkte Bearbeitung vektorbasierter Daten. Durch diese Trennung werden vorher auftretende Fehler, wie in Kapitel 2.1.3 von Kang et al., 2023 beschriebene **inhaltliche Ungenauigkeiten vermieden** (Kang et al., 2023; Wang et al., 2025).

Eventuell könnte ein trainierter **AI-Agent** (ähnlich zu dem „Icon Designer“) **im Austausch mit einem Style-Agent ausreichen, um Symbole und Muster zu generieren**. Für eine Auswahl an KI-Modellen für das geplante Vorhaben dieser Arbeit scheint der KI-Agent zu Beginn nicht gut geeignet zu sein, da es bereits ein zu automatisiertes Verfahren für detailliertere Überarbeitungen und die „experimentelle“ Phase des Workflows ist. Zudem dabei ebenfalls für die Icongenerierung auf ein Diffusion Modell (DALL-E3) zurückgegriffen wird, welches im Zuge einer ersten KI-Auswahl näher betrachtet wird. Ein Workflow für ein Symbol/ Muster, welches in verschiedenen Varianten und Maßstäben erstellt werden soll, könnte als Input dienen um auf einer höheren Ebene ein komplettes Set/ Signaturenschlüssel damit zu erstellen. Ansonsten könnten **AI-Agenten für den Stiltransfer** eines vorher mit einem anderen KI-generierten Modell, erstellten Symbols oder Muster hilfreich sein und eventuell Maßstabsveränderungen auf generierte Inhalte übertragen.

Zugriff auf den verwendeten Python Code von Wang et al. gibt es über GitHub, es ist dafür ein Openai und Mapbox Account nötig (*CartoAgent/research/README.md at main · GISense/CartoAgent · GitHub*, o. J.).

Insgesamt wird deutlich, dass es **verschiedene Modelle gibt, die für kartographische Prozesse in Frage kommen**. Speziell zu **Diffusion Modellen** gibt es bereits **einige Kartographie-spezifische Paper**, die eine Grundlage für einen Umgang und mögliche Anforderungen legen können.

2.3.4 Genauigkeit und Fehleranfälligkeit von KI-generierten Kartendesigns

Im folgenden Unterkapitel sollen mögliche **Risiken** von KI in Bezug auf Kartendesignaspekte erläutert werden, um **effektive und genaue Ergebnisse** zu erzielen und eventuelle **Probleme** vor praktischen Tests **vermeiden** zu können. Ein bereits genanntes mögliches Risiko von generiertem Kartencontent ist, dass es bei der Verbindung von KI und

Karten zu **Vertrauensproblemen** kommen kann (siehe 2.2.3 Psychologische Hintergründe von Vertrauen in Kartenelemente) (Prestby, 2024).

Potenzielle ethische Bedenken bei der Kartengenerierung können dabei unter anderem:

- **Ungenauigkeiten** (inaccuracies)
- **irreführende Informationen** (misleading information)
- **unerwartete Merkmale** (unanticipated features)
- **fehlende Reproduzierbarkeit von Karten** (irreproducibility)

sein, wie Kang et al. (siehe Kapitel 2.3.2 und 2.1.3) mit einem erstellten Datensatz aus 4675 Karten geschlussfolgert hat (Abb. 17). Diese Karten wurden mittels DALL-E 2 erzeugt und eine spezifische Prompt-Struktur verwendet. Zu dem Zeitpunkt des Papers war KI zudem nicht in der Lage geographische Grundlagen und Prozesse zu erkennen, die auf der Karte abgebildet werden sollten. Zu den Ungenauigkeiten zählen **undeutliche oder verzerrte Grenzlinien**, bestimmte Regionen haben **falsche Größen** und durch das 1:1 Format von DALL-E 2 kam es dazu, dass Inhalte abgeschnitten worden.

Zu den **irreführenden Informationen** zählen in dem Paper falsch geschriebene Wörter, „Pseudo Wörter“ genannt, sowie falsche Regionen („fake regions“) bei denen komplette, in der Realität existierende Länder, Staaten und Provinzen ergänzt werden. Die Kategorie „**Unerwartete Merkmale**“ beschreibt zum Beispiel Linien für die Straßendarstellung, die durcheinandergebracht sind oder bekannte kartographische Begriffe wie „heatmap“, die automatisch im Lava Stil generiert wird (Kang et al., 2023).




Abb. 17: Fehlerhafte DALL-E 2 - KI Outputs kategorisiert in vier Gruppen (Kang et al., 2023).

Ein ethisches Bedenken, bei der Erstellung von Karteninhalten sind sogenannte „**Black-Box-Modelle**“. So werden Deep-Learning Programme und machine Learning Modelle bezeichnet, bei denen der interne Prozess, wie aus einem Prompt, eine Karte (bzw. in dem Fall dieser Arbeit Kartenelemente) erzeugt wird, **unklar** ist **und nicht nachvollzogen** werden kann. Dadurch können Fehler im Prozess schwieriger identifiziert werden und zuverlässige Ergebnisse können schwierig gewährleistet werden (Kang et al., 2023).

Mit dem Nutzen von künstlicher Intelligenz kann es zu ethischen Problemen kommen. Kang et al. haben im Jahr 2024 ein Paper mit dem Namen „Artificial intelligence studies in cartography: a review and synthesis of methods, applications, and ethics“ veröffentlicht und bis dahin publizierte Paper zum Thema KI im Kartographie Bereich analysiert. Dabei hat er fünf Kernpunkte definiert, die im Zusammenhang mit ethischen Aspekten eine Herausforderung darstellen:

- I. Kommodifizierung** (im Zusammenhang mit Kommerzialisierung)
(Commodification)
- II. Verantwortung** (Responsibility)
- III. (Geo-) Datenschutz** (Geoprivacy)
- IV. Voreingenommenheit** (Bias)
- V. Transparenz, Erklärbarkeit, Vernunft** (Transparency, explainability, and provenance)

Der erste Punkt bezieht sich auf die kommerzielle Veröffentlichung von Karten, die von KI generierten Inhalten in Zukunft stark beeinflusst werden könnten. Laut Kang et al. werden GeoAI-Ansätze in Zukunft zu mindestens **drei neuen Produktarten** führen, zum einen die **Kartendaten**, die von der KI zu Trainingszwecken genutzt werden, zu spezifischen GeoAI-Modellen und zu den **Ergebnissen dieser**. Dazu kommt der **ethische Aspekt**, wie beispielsweise mit Urheberrechten in Bezug auf vorhandene Kartendaten zu Trainingszwecken umgegangen wird. Zudem stellen die AutorInnen die Frage, ob ein Ziel die vollständige Automatisierung von Karten sein soll und **was sie aus dem Beruf KartographIn macht**.

Im Zuge der **Verantwortung** schließen sich Kang et al. den Erkenntnissen aus Kapitel 2.1.3 an und betonen, wie wichtig die Glaubwürdigkeit von KI generierten Karten ist und das mögliche Echtzeitkarten mittels KI mit Vorsicht verwendet werden sollten, speziell **aus welcher Perspektive kartographische Inhalte erzeugt werden**. Speziell in Bezug auf die Zugriffsmöglichkeiten von KI-Content, der derzeit hauptsächlich von Industrieländern genutzt und generiert wird.

Datenschutz ist ein weiterer Punkt den Kang et al. nennen, der sich auf das **Recht von individuellen Standortdaten** bezieht. Da nicht alle KI-Modelle offenlegen, woher sie ihre Daten beziehen, können Standortinformationen von Personen beispielsweise über Social-Media-Daten **ungewollt in Trainingsdaten** miteinfließen.

Voreingenommenheit wird in dem Paper als systematischer Fehler und Ungenauigkeit beschrieben. Kang et al. weisen darauf hin, dass **Verzerrungen und Fehler** in den

Trainingsdaten durch die KI **reproduziert und verstärkt** werden können. Wie unter dem Punkt Verantwortung bereits angeschnitten, könnten aufgrund einseitiger Datengrundlagen bestimmte **Personengruppen benachteiligt** dargestellt sein (Kang et al., 2024).

Ein Punkt, der ebenfalls stark von der Trainingsgrundlage beeinflusst wird, ist die **Sprache, die Modelle am besten verarbeiten** können. Dabei werden bei LLMs Entscheidungen hauptsächlich in einem Englisch oder **englischähnlichen Repräsentationsraum** getroffen werden, was englischsprachige Prompts effektiver und einfacher verarbeitbar für das Modell macht (Schut et al., 2025).

Transparenz, Erklärbarkeit und **Vernunft** beschreiben Eigenschaften, die KI-Modelle aktuell noch unterschiedlich ausgeprägt erfüllen. Sie sind wichtig für die Nachvollziehbarkeit und das Vertrauen in die Ergebnisse eines Modells und um eventuelle Voreingenommenheiten und Fehler in den Daten schneller identifizieren und verbessern zu können (Kang et al., 2024).

Ein weiterer Punkt, der bei der Verwendung von KI beachtet werden sollte, sind ihre **Auswirkungen und ihr negativer Einfluss auf die Umwelt**. L. Anthony hat sich innerhalb eines Papers namens: „Carbontracker: Tracking and Predicting the Carbon Footprint of Training Deep Learning Models“ mit Deep Learning Modellen und deren **ökologischen Fußabdruck** beschäftigt. Bei der Arbeit mit KI, benötigt vor allem das Training der Modelle mehr Energie. Die Autoren des Papers gehen davon aus, das KI innerhalb der nächsten Jahre zu einem der **größten negativen Faktoren für den Klimawandel** werden kann. Um den Verbrauch zu reduzieren, empfehlen die AutorInnen den Energieverbrauch und Aufwand vor dem Training zu messen. Dafür haben sie einen Open Source Carbontracker entwickelt, der den Stromverbrauch von GPU, CPU und dynamischem RAM misst. Dieser ist über GitHub und einen Python Code zugänglich (Kim et al., 2024; Saints Lab, 2020/2025).

Das Kapitel zeigt das **Fehlerquellen von KI vielfältig** sind und im Zuge des praktischen Vorgehens könnten weitere spezifische Punkte dazukommen. Um Fehlern vorzubeugen, ist geplant am Ende einer ersten geeigneten KI-Auswahl, um einen Workflow zu testen, KI's mit einem **geringeren Stromverbrauch** zu **bevorzugen** und es als eine Handlungsempfehlung oder als Hinweis in den Workflow zu integrieren. Zudem können Punkte wie der **Geo-Datenschutz** beachtet werden, in dem speziell **frei verfügbare Daten als Trainingsdaten** genutzt werden.

Zu **Diffusion Modellen** gibt es bereits einige **Veröffentlichungen im Zusammenhang mit Kartographie**, jedoch wurden sie mittlerweile teilweise von MLLMs ersetzt (Notiz bei DALL-E innerhalb von Chat GPT: „OpenAI's legacy image generation model. For our latest model, ask ChatGPT to create an image in the main chat.“) (*ChatGPT - DALL-E*, o. J.). Diese scheinen aufgrund neuer Modell-Veröffentlichungen ein **vielversprechender und aktueller Ansatz** für Bildgenerierungen sein, speziell da sie mit Text und Bildinput in Kombination umgehen können, was helfen kann, konkretere Ziele zu formulieren und in einen Austausch zu kommen. Darauf aufbauend könnten **AI-Agenten aufgesetzt werden**, die gewonnene Erkenntnisse für aufgeteilte Aufgaben kartographischer Zwecke nutzen.

2.4 Prompt Engineering für die Text-zu-Bild-Generierung

Ein Thema, welches bei generativen Text-zu-Bild-Modellen von Relevanz ist, ist das „Prompt Engineering“. Es geht dabei darum, den **Input zu optimieren** und zu spezifizieren, um möglichst schnell gewünschte Ergebnisse zu erzielen. Damit die Symbol- und Mustergenerierung für den späteren geplanten Workflow und die Programmauswahl einheitlich ist und bestmögliche Ergebnisse bringt, werden in folgendem Kapitel verschiedene Prompt Engineering Aspekte betrachtet.

Prompt Engineering bezeichnet die Festlegung von Textprompts, die zu einem **gewünschten Output führen** sollen. Der Eingabeprompt wird dabei so lange angepasst und verfeinert, dass ein immer besseres Ergebnis rauskommt (Dunkel et al., 2024).

2.4.1 Prompt Methoden: Keywords, Prompt Auto-Editing, Feinsteuerung und Negativprompts

Das Paper „Design Guidelines for Prompt Engineering Text-to-Image Generative Models“ von Liu und Chilton wurde 2022 und hat untersucht, welche Prompt-Formulierungen zu einer besseren Ausgabe führen und welche Parameter die Bildqualität beeinflussen. Es gibt dabei Empfehlungen, die das Ergebnis verbessern können. Einer sind „**Style Keywords**“, mit denen Stile definiert werden sollen (Liu & Chilton, 2023). Für kartographische Symbole könnten das zum Beispiel **Wörter wie „detailreich“ oder „minimalistisch“** je nach Zoomstufe sein.

Mo et al. zeigen Herausforderungen von Prompt Engineering auf, ein Punkt ist die manuelle Optimierung von Outputs, die in seinem Paper „heuristic engineering methods“ genannt wird. Dieser Prozess von Nachbearbeitung kann viel Zeit in Anspruch nehmen, speziell da in dem Kontext von Multi-Scale-Karten die Outputs für verschiedene Maßstäbe angepasst werden müssen. **Einfache Prompts** werden als **unpräzise** bezeichnet, was dazu führen kann, dass nicht die gewünschten Ergebnisse rauskommen. Um unpräzisen Prompts entgegenzuwirken, gibt es den Dynamischen-Feinsteuerungs-Prompt-Ansatz (Dynamic Fine-control Prompt), kurz DF, der **bei Diffusion-Modellen** zum Einsatz kommen kann.



Abb. 18: Ergebnis des dynamischen-Feinsteuerungs-Prompts (Mo et al., o. J.).

Dabei wird in Klammern eine **Gewichtung von Aussehens-Komponenten** angegeben, eingesetzt in Abb. 18. Für Multi-Scale-Karten kann zum Beispiel die Maßstabsstufe in Klammern definiert werden. Die AutorInnen des Papers kommen zu dem Fazit, dass eine **Balance zwischen Ästhetik und Semantik** wichtig ist. Dazu zählen ästhetische Scores, semantische Konsistenz und Benutzerpräferenzen.

Ein Score, der Ästhetik berücksichtigt und in dem Paper vorgestellt wird, ist die **“PAE-Methode“**, PAE steht dabei für **Prompt Auto-Editing** (automatische Prompt-Bearbeitung). Input-Textprompts sollen dabei **automatisch optimiert** werden, mittels Reinforcement Learning. Dabei kommen die oben beschriebenen DF- Prompts zum Einsatz, das Ziel ist es, die Textinputs in DF- Prompts umzuwandeln. Dabei gibt es zwei Stufen, in der ersten Stufe werden bereits existierende Prompts zusammen mit den erstellten Bildern gesammelt, bei denen der Prompt das gewünschte ansprechende Ergebnis erzeugt hat. Mittels dem DF-Prompt werden **drei Regeln** ergänzt, **was** wird gezeigt (z.B. welcher Stil), **wann** wird es gezeigt (z.B. soll am Ende oder Anfang ein bestimmter Effekt ergänzt werden) und **wie** stark sollen die beiden ersten Regeln angewendet werden (Mo et al., o. J.).

Für die KI-Auswahl bei der Erstellung von Mustern und Symbolen für Multi-Scale-Karten können diese Grundlagen hilfreich sein, einen einheitlichen Input zu erstellen. Das Paper geht tiefer in die Thematik ein, inwieweit die in Kapitel 2.3 beschriebenen KI-Programme diese detaillierten Infos verarbeiten und bereitstellen können und wie die Regeln genutzt werden können. Diese Informationen können eine **Basis für Kapitel 3.1 Auswahl und Definition einer Testumgebung** legen.

Eine weitere Methode bei der Nutzung von Prompts, sind **Negativprompts**. Sie werden genutzt, um ausdrücklich zu formulieren, was **nicht in dem gewünschten Output dargestellt werden soll**. Damit soll spezifisch ausgegrenzt werden, was als Output unerwünscht ist (Dunkel et al., 2024).

In dem Paper „Optimizing Negative Prompts for Enhanced Aesthetics and Fidelity in Text-To-Image Generation“ von Ogezi und Shi aus dem Jahr 2024 werden die Auswirkungen und die **Wirksamkeit von negativen Prompts** mittels Stable Diffusion im Zuge von Bildgenerierung untersucht (Ogezi & Shi, 2024).





Prompt	Negative Prompt	Image	Other Images
A Wolf, high detailed fur, monochrome charcoal painting art, detail work, various tones of black, blended, colorful detailed eyes, by Gerd Amble, 8k, 2d render	NONE		
	GROUND TRUTH		
	NEG OPT		

Abb. 19: Ergebnisse der drei Kategorien: "NegOpt", "Ground Truth" und "None" (Ogezi & Shi, 2024).

Es wurde dabei ein mehrstufiges Experiment durchgeführt, in dem Eingaben ohne negativen Prompt („None“) mit manuellen Inputs (von Menschen geschriebenen, im Paper „Ground Truth“ genannt) und automatisch optimierten Prompts („NegOpt“) miteinander verglichen worden. Dabei kam heraus, dass **Bilder, die negative Prompts verwenden, bessere Ergebnisse als Bilder ohne Negativprompts liefern (siehe Abb. 19).**

Noch bessere Ergebnisse gab es, als das Modell selbst Negativprompts erstellt hat. Dafür wurde es mit Beispielen von normalen Prompts (ohne die Formulierung was nicht enthalten sein soll) mit dazu passenden negativen Prompts gefüttert (Ogezi & Shi, 2024).

2.4.2 Prompt Prinzipien für die Erstellung von Kartenicons

Wang et al., die sich 2025 mit GenAI-Agenten beschäftigten (siehe Kapitel 2.3.3), haben im Zuge ihres Vorgehens zur Erstellung einer Grundlage für den Stil-Transfer **zusätzlich einen Prompt Ansatz für Kartenicons** entwickelt. Die festgelegten Regeln basieren auf einem Leitfaden von Ekin aus dem Jahr 2023, der speziell für Sprachmodelle wie ChatGPT angelegt wurde.

Dabei sollen beim Prompt Engineering vier Prinzipien beachtet werden, um einen guten Output zu generieren:

I. Klarheit und Spezifität (Conciseness)

Klare und deutliche Sprache verwenden ohne detaillierte Fachwörter.

II. Zweckmäßigkeit/ Zielstrebigkeit (Purposfulness)

Direkt zu Beginn sollte ein klares Ziel formuliert werden.

III. Normativität (Normativeness)

Das Ausgabeformat sollte möglichst standardisiert sein (vor allem bei AI-Agenten wichtig), damit eine Konsistenz und Klarheit vorhanden bleiben.

IV. Erklärbarkeit (Explainability)

Das Modell soll selbst das eigene Vorgehen und getroffene Entscheidungen erklären, um den Ablauf transparenter zu machen (Wang et al., 2025).

In dem Paper von Wang et al. wurde ein „**Icon Designer**“ Agent verwendet, der Kartensymbole erzeugen sollte. Erstellt werden sie **mit DALL-E 3**, der Prompt ist dabei wichtig, um die Agenten und ihre Aufgaben zu definieren und könnte bei MLLM's

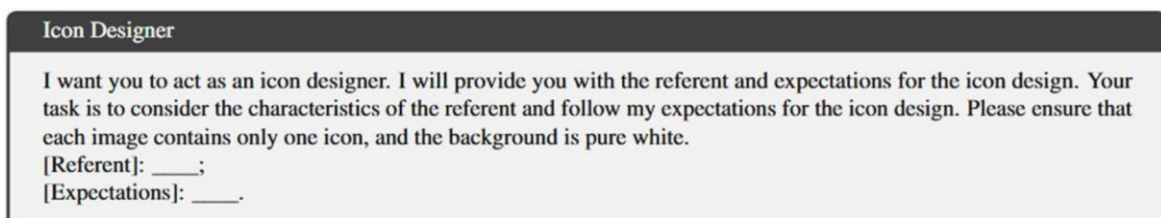


Abb. 20: Prompt der als Input für den AI-Agent "Icon Designer" vorgegeben wurde (Wang et al., 2025).

funktionieren, da dieser in weiterer Folge für die Icon Generierung verwendet wird. Der spezifische Prompt, der für den „Icon Designer“ verwendet wurde ist in **Abb. 20** dargestellt. Hier wird genauso wie bei Drews et al. (siehe Kapitel 2.3.2) ein **weißer Hintergrund** der Icons gewählt, dieses Vorgehen scheint ein funktionierender Ansatz zu sein, eine spätere Bearbeitung der erzeugten Symbole einfacher zu gestalten.



Abb. 21: Erstellte Icons mit der Inspirationsquelle (links), den Ergebnissen vor der Evaluierung durch MLLM's (Mitte) und danach (rechts) (Wang et al., 2025).

Vorher wurden in einem Stylesheet alle Kartenelemente definiert, wie zum Beispiel **intuitive Farben** für die Karte. Für Kartenicons ist dabei die Vorgabe, dass sie **klar erkennbar** sein und **nicht von der Grundbedeutung der Karte ablenken** sollen. Die erstellten Inhalte wurden im Laufe des Generierungsprozess mittels eines MLLM's bewertet und anhand daran verbessert. In Abb. 21 sind die generierten Icons dargestellt (Ekin, 2023; Wang et al., 2025).

2.4.3 Spezifische Prompts für Bild- und Stilgenerierung

Im folgenden Unterkapitel sollen detailliertere Prompt Ansätze und funktionierende Beispiele und Empfehlungen für eine Bildgenerierung betrachtet werden, die für eine Symbol- und Mustererstellung geeignet sein könnten.

Dunkel et al. haben sich 2024 innerhalb des Papers: „Generative Text-to-Image Diffusion for Automated Map Production Based on Geosocial Media Data“ mit der Generierung von Piktogrammen innerhalb Stable Diffusion beschäftigt (siehe Kapitel 2.3.2). Dabei wurde für das Prompt Engineering ein dreistufiger Prozess gewählt mit **Eingabedaten**, **Basis Prompts (Kern)** und der **Bilderzeugung**. Dabei ist der Kern, der Teil, bei dem Prompt Engineering zum Einsatz kommt.

Die Basisprompts sind gleich aufgebaut und in Abb. 22 mit Beispielen aufgeführt:

I. Pre-Prompt

II. Subject

III. Quality Modifier

IV. Style Modifier

+ negative Prompts

Der **Pre-Prompt**, steht am Anfang des Satzes bleibt in dem Fall des Papers für alle Prompts identisch. Er ist dafür da zu definieren, was die KI grundsätzlich generieren soll, in dem Fall des Papers: „**A map icon of**“. Es wurden vorher andere Varianten getestet, diese wurde ausgewählt, da bei dem Stichwort Icon **automatisch ein weißer Hintergrund miterzeugt** wurde, was Späteres freistellen vereinfacht.

Das **Subjekt** (im Paper englische Version: Subject) ändert sich je nach der Art des gewünschten Outputs, es sollte das Thema enthalten. Im Fall des Papers waren es Emojis oder Hashtags, zum Beispiel ein Affen Emoji oder beides kombiniert. Die Autoren haben getestet, welche Variante am besten funktioniert und das **Subjekt in Klammern** zu schreiben, hat zu einem erhöhten Fokus auf das Subjekt geführt. Zudem haben sie die **Anzahl der Subjekte auf maximal drei begrenzt**, bei einer höheren Anzahl kam es zu schlechteren Outputs (Dunkel et al., 2024).

Das Subjekt als sogenanntes **konkretes „Subject“-Keyword** anzugeben, wurde zudem von Liu & Chilton et al. in ihrem 2023 veröffentlichten Paper (siehe Kapitel 2.4.1) beschrieben. Ihr Fazit ist, dass abstrakte Keywords ungenauere Ergebnisse **als klar formulierte Inputs** liefern. Das Paper ist von 2023 und damit nicht auf dem neusten Stand der Entwicklung, es gibt aber Aspekte, die bereits zu dem Zeitpunkt bei KI-Programmen gut funktioniert haben, wie Farbpaletten und das Erfassen von räumlichen Beziehungen („Depicting Space“) (Liu & Chilton, 2023).

Der dritte Punkt: „**Quality Modifier**“ soll die Qualität und die Stimmung beschreiben und am besten konstant bleiben, je nach dem gewünschten Thema des Outputs. Es ist ein Adjektiv, was mit einem Komma hinter das Subjekt geschrieben werden kann.

{pre-prompt} ({placeholder}), white background, simple outline, masterpiece, best quality, high quality, <lora:Japanese_style_Minimalist_Line_Illustrations:0.2>	{pre-prompt} → „A map icon of“ Subject (in dem Beispiel der Platzhalter) → „🐼“ Quality Modifier → Begriffe wie „best quality“ Style Modifier → <lora... z.B. Japanese Stil und die Gewichtung → Beispiel 0.2
---	--

Abb. 22: Aufbau des Prompts für die Generierung von Graphiken (links), sowie eigene Darstellung der Parameter (rechts) adaptiert und erweitert nach (Dunkel et al., 2024).

Das Paper gibt zu Beginn einen Stil vor, sowie dessen Gewichtung. Sie benutzen eine **Low-Rank Adaption**“ (Anpassung mit niedrigem Rang), kurz „LoRA“. Es ist eine neue Trainingsschicht, die auf ein bestehendes KI-Modell gelegt werden kann, um einen **speziellen Stil umzusetzen, ohne das gesamte Modell neu zu trainieren**.

Die Gewichtung wird in Komma angegeben, die Autoren des Papers haben Gewichtungen von 0,2 bis 1,2 getestet und sich für 0,2 entschieden, was nur einen leichten Stil über alle

Ergebnisse gelegt hat. Ein **höherer Wert** hat zu **Vereinfachungen** geführt. Die Ergebnisse der generierten Icons des Papers sind in Abb. 23 dargestellt. Dunkel et al. kommen zu dem Schluss, dass sich bei der Arbeit mit generativer KI mittels Prompt Engineering **entweder für Kontrolle und Nachvollziehbarkeit oder für die Kreativität** entschieden werden muss (Dunkel et al., 2024).



Abb. 23: Erstellte Icons mittels generativer KI (links) und Diffusion Subject Prompts (rechts) Prompts (Dunkel et al., 2024).

Das Paper und die Erkenntnisse von Dunkel enthalten viele spannende Elemente für meinen Workflow. Zum einen könnte das **Auslagern eines Stiles** für affektive Symbole und Muster, Komplexität und die **Ansprüche an eine generative KI senken**, was ebenfalls Wang et al., 2025 empfohlen hat (siehe Kapitel 2.3.3) zum anderen sind die praktischen Elemente des Prompt Engineering für mein Vorgehen von Interesse und könnten als Orientierung dienen.

2.5 Herausforderungen und Anwendungen von Multi-Scale-Darstellungen

Multi-Scale-Karten sind meistens Teil einer Web-Anwendung und sind **Webkarten in denen verschiedene Maßstäbe dargestellt sind** und über einen Zoom/ ein Scrollen, kann von einem kleinen Maßstab in einen großen Maßstab gewechselt werden. Jeder Anbieter und jede Applikation hat individuell definiert, welche Zoomstufen die Karte beinhaltet und was in diesen dargestellt ist. Je nachdem, **wie klein oder groß der Übergang von einer Zoomstufe in eine andere ist, verändert sich der dargestellte Inhalt** stärker. Bekannte Multi-Scale-Karten sind zum Beispiel französische IGN-Karten die es als Web Map Service (WMS)-Server gibt oder OSM-Karten (Dumont et al., 2016).

Da in dieser Arbeit die Symbol- und Mustergenerierung mittels KI innerhalb von Multi-Scale-Karten untersucht wird, sind die **Herausforderungen**, sowie **technische Details** hinter Multi-Scale-Darstellungen ein zentrales Thema, um **mögliche Probleme im späteren Workflow** identifizieren zu können.

2.5.1 Zoomlevel und MasterScale Diagramm

Bei der Darstellung von Symbolen und Mustern innerhalb von Multi-Scale-Karten können sich Herausforderungen ergeben. Zum einen sollten Symbole und Muster sich **je nach Zoomstufe und Maßstab verändern und anpassen**. Beim Übergang von einer Zoomstufe in eine andere können Symbole zum Beispiel **eingebledet oder ausgebledet** werden. Die Detailliertheit kann sich abhängig von der Zoomstufe verändern, speziell bei Mustern und Symbolen sind in den hohen Zoomstufen viele Details möglich (Dumont et al., 2016). Die Entscheidung, dass sich ein Kartenobjekt aufgrund von Maßstabswechseln verändert, wird als **decision point/ Point of Desicion** bezeichnet (R. E. Roth et al., 2011).

Bei unterschiedlichen Maßstäben kommt es zu verschiedenen Prozessen, wie der **Vereinfachung, Aggregationen** oder dem **Ausblenden** von Objekten (Spaccapietra et al., 2000).

Brewer und Buttenfield haben bereits 2010 bezogen auf Roth 2008 **drei Designentscheidungen** festgelegt, die bei Karteninhalten und Symbolen in Bezug auf Multi-Scale-Karten beachtet werden sollen:

- I. **Symbole** verändern sich in ihrer Größe je nach Maßstab
- II. **Karteninhalt** ändert sich, wenn spezielle Werte eingegeben werden oder die Daten nach einem Kriterium gefiltert werden.
- III. **Geometrien** von dargestellten Inhalten können sich ändern, zum Beispiel durch Grenzlinien, die vereinfacht werden (Brewer & Buttenfield, 2010; Spaccapietra et al., 2000, S.58, 59).

Um bei einer Multi-Scale-Karte Zoomlevel klar zu gestalten, **Skalierungsproblemen vorzubeugen**, sowie während der Erstellung von neuen Inhalten den Überblick zu bewahren, gibt es die Möglichkeit ein **Master-Scale-Diagramm** zu erstellen. Das Diagramm ist tabellarisch aufgebaut (siehe Abb. 24). In der **ersten Zeile** sind die verschiedenen geplanten **Maßstäbe** aufgelistet. In der ersten **linken Spalte** sind die verschiedenen **Themenbereiche** der Karte mit ihren jeweiligen feature types untereinander geschrieben. In der Tabelle wird dann jeweils für jeden feature type festgelegt, wann es sichtbar wird, und mittels einer Abkürzung oder einem Operator definiert, **was genau mit dem gezeigten Inhalt passiert**. Zum Beispiel steht C+ für das Einfügen eines Objekts und C- für das Entfernen. Für den decision point wurden die betroffenen Kästen der Einträge an der rechten Seite schwarz markiert, als Zeichen, dass es eine größere Veränderung vor der nächsten Maßstabsstufe gibt.

Brewer und Buttenfield haben ein Scale-Master Diagramm von Roth adaptiert, dabei sind fünf verschiedene **Datenthemen festgelegt** (z.B. Physisch, Transport, Kultur) und wie diese **je nach Zoomstufe angepasst** werden sollen. Für Symbole und Muster sind dabei speziell folgende Anpassungen von Relevanz, die bei dem Diagramm beide unter einer "Symbols" Kategorie zusammengefasst werden: **Farbanpassung, Typisieren, Musteranpassung, Ausrichtung, Form-, Größen- und Transparenzanpassungen**. Zudem gibt es eine

Kategorie für Content, die für Multi-Scale-Karten eine Rolle spielen: dem hinzufügen, entfernen, umklassifizieren und neuanordnen von Elementen (Brewer & Buttenfield, 2010; R. E. Roth et al., 2011).




Abb. 24: Beispielhafter Aufbau eines MasterScale-Diagramms (R. E. Roth et al., 2011).

Ein an das Ziel dieser Arbeit angepasstes Scale-Master Diagramm könnte hilfreich sein, um Symbol- und Musteranpassen über verschiedene Maßstäbe hinweg einheitlich zu gestalten.

Dumont et al. haben bereits 2016 sechszehn verschiedene Multi-Scale-Karten analysiert und dabei speziell den **Zusammenhang zwischen Zoomlevel, Displayzoom und dem jeweiligen Abstraktionslevel** auf drei Maßstabsebenen untersucht. Bezogen auf das Zoomlevel eines Displays kommen sie dabei auf den Schluss, dass die meisten Anbieter eine Zoomstufe erst einblenden, sobald der Displayzoom ein Drittel des definierten Maßstabsbereich erreicht hat, was ein Kompromiss zwischen der Bereitstellung der Daten und visueller Konsistenz ist (Dumont et al., 2016). Im Jahr 2020 haben sie sich nochmals dem Thema gewidmet und sich dabei innerhalb einer systematischen Studie die Designprinzipien von Multi-Scale-Karten aus funktionseller und wahrnehmungspsychologischer Sicht angeschaut. Dabei kommen sie zu dem Ergebnis, dass **mittlere Zoomstufen, zwischen 1:50.000 und 1:250.000, anfälliger für Wahrnehmungsstörungen** sind. NutzerInnen sind **kognitiv höher belastet**, da in diesem Maßstabsbereich die gezeigten Symbole oder Muster stärker abstrahiert dargestellt sind und gleichzeitig die Inhalte der Karte komplexer werden (Dumont et al., 2020).

2.5.2 Stilistische und visuelle Konsistenz bei Maßstabswechseln

Ein wichtiger Aspekt, der im Zusammenhang mit Zoomleveln und den kognitiven Wahrnehmungsproblemen spezieller Maßstäbe steht, ist die Stilkohärenz über Maßstäbe hinweg. Dabei soll sich der **Stil einer Karte während verschiedener Maßstäbe nicht zu**

stark ändern, damit NutzerInnen Symbole intuitiv wiedererkennen können. Speziell Farben sollen laut Brewer nicht isoliert eingesetzt werden, sondern mit Rücksicht auf die Datenstruktur und die menschliche Wahrnehmung. **Farbskalen** sollten gleichbleibend **semantisch** und Inhalte ohne Blick auf die Legende erkennbar sein (Brewer, 1999).

Farben sollen über ihre Regelmäßigkeit und ihre Konsistenz an einen bestimmten Objekttyp **wiedererkennbar** bleiben. Der **Maßstabsübergang** kann **durch unharmonische Farben und Muster zusätzlich holpriger** und **weniger intuitiv** wahrgenommen werden, womit die **Stilkonsistenz** zusätzlich eine **emotionale Ebene** hat. Vor allem Karteninhalte, die über Maßstäbe hinweg wiederkehren, sollen visuell konsistent bleiben, darunter zum Beispiel Höhenlinien oder die Darstellung von Flächennutzungen (Bertin, o. J.).

Dumont et al. betrachten diese Regelmäßigkeit und Einheitlichkeit außerhalb von Farbe und betonen die **Stilkohärenz** allgemein für gleiche Objekttypen, die mit gradueller Anpassung über Maßstäbe hinweg ihre Eigenschaften, wie Gewichtung, Dicke, Form behalten sollen, damit sie wiedererkannt werden können. Speziell Symbolübergänge sollten nicht abrupt erfolgen, sondern mit Zwischenstufen. Als Orientierungshilfe können **Ankerpunkte** helfen, die sich kaum bis gar nicht verändern (Dumont et al., 2020; Fabrikant et al., 2012).

In dem Paper von Kang et al. namens „Transferring multiscale map styles using generative adversarial networks“ wurde mittels zwei verschiedenen GAN-Modellen „Pix2Pix“ und „CycleGAN“ der Google Maps Stil auf andere Karten übertragen. Dabei konnten speziell **Farben, Linienbreiten und Formen der Zielkarten gut beibehalten** werden, Textbeschriftungen waren im Gegensatz dazu schwierig zu verarbeiten und fehlerhaft.

Ein weiterer relevanter Aspekt, der getestet wurde, ist die Qualität und Generalisierung über verschiedene Maßstäbe hinweg. Dafür wurden die Zoomstufen 15 und 18 getestet, mit dem Ergebnis, das beide Modelle bei Zoomstufe 15 bessere Ergebnisse liefern konnten, während bei Zoomstufe 18 „CycleGAN“ deutlich besser abschnitt. In Abb. 25 ist in der linken Spalte der Kartenstil von Monet dargestellt, rechts der generierte Google Maps Stil. Dabei hat die KI verschiedene Generalisierungsmethoden angewendet, um den Zielstil von Google Maps auf Zoomstufe 15 nachzuahmen. Obwohl keine spezifischen Operatoren vorgegeben wurden, hat die KI **automatisch Verbesserungen, eine Auswahl an darzustellenden Elementen und eine Typisierung** durchgeführt, was die Autoren des Papers sich damit erklären, dass die Vorlagekarten von Google Maps bestimmte Muster an Generalisierungen und Darstellungsformen verwendet, die die KI erkennt und anwendet, damit die erzeugten Karten noch ähnlicher zu dem Original sind.

Das Paper kommt zu dem Schluss, dass GAN-Modelle **geographische Merkmale in kleinen Maßstäben verallgemeinern** können (Kang et al., 2024). Es geht dabei aber spezifisch um ganze Karteninhalte, nicht mit einem Fokus auf Symbolen und Mustern.




Abb. 25: Google Maps Stilübertragung mittels GANs und dabei von der KI angewandte Generalisierungen (Kang et al., 2024).

Die Ergebnisse sind vielversprechend in Bezug darauf, dass generierte Symbole und Muster über Maßstäbe hinweg stilkonsistent dargestellt und je nach Zoomstufe angepasst werden können.

2.5.3 Level of Detail und Level of Abstraction

Ein weiterer relevanter Punkt bei Multi-Scale-Datensätzen ist das **“Level of Detail”**, kurz LoD. Es kommt bei bereits vorverarbeiteten, generalisierten Datensätzen vor und beschreibt die verschiedenen Detailstufen, die es innerhalb einer Anwendung gibt. Im Zuge von Multi-Scale-Karten ist das LoD **speziell für Zwischenmaßstäbe und mittlere Maßstabsstufen** interessant und soll dabei helfen Übergänge zwischen Zoomstufen zu verbessern. Bestimmte Datenebenen sind dabei generalisiert und ersparen Kartographinnen das Generalisieren in jeder einzelnen Maßstabsstufe. Ein Konzept dafür wurde bereits 2010 von Brewer und Buttenfield vorgestellt, dabei nutzen Sie das **LoD für die Maßstabsstufe 1:24.000 ebenfalls für die Stufen 1:20.000 und 1:40.000**, ohne dass dafür neue Berechnungen durchgeführt werden müssen. Das ist vor allem für große Datenmengen von Interesse, da die gesparte Rechenleistung für andere Prozesse verwendet genutzt werden kann und bei visueller Konsistenz hilft (siehe Kapitel 2.5.2.). Der Ansatz schafft automatisch die empfohlenen Ankerpunkte (siehe letztes Kapitel) für NutzerInnen (Brewer & Buttenfield, 2010; Dumont et al., 2020).

Bei der Entscheidung welche Objektarten und Datenlayer dabei von der vorherigen Generalisierungs- und Maßstabsstufe übernommen werden, hängt mit der **Relevanz des**

dargestellten Inhalts zusammen. In dem Paper von Brewer und Buttenfield werden zum Beispiel künstliche Objekte als stabilere Layer bezeichnet, die über Maßstäbe hinweg genutzt werden können (Brewer & Buttenfield, 2010).

Ein Paper was eher eine Gegenposition zu dem Paper von Brewer und Buttenfield bietet, ist das Paper “Designing multi-scale maps: lessons learned from existing practices“ von Dumont et al. veröffentlicht. Dabei wird genau der Punkt kritisiert, dass viele Karten und WMTS-Server dieselbe Karte **über mehrere Zoomstufen hinweg** zeigen, was **störend** für die Nutzererfahrung sein kann (Dumont et al., 2020).

Eine **Zwischenlösung** könnte beiden Anforderungen gerecht werden, bei der entweder dieselbe Karte **über maximal zwei Zoomstufen** hintereinander gezeigt wird, um Ankerpunkte zu schaffen, aber trotzdem genug Veränderung und Details in der Kartenanwendung dazukommen oder einzelne Layer unverändert bleiben, während herausstechende Details zur Orientierung identisch bleiben.

Ein weiterer Aspekt bei Multi-Scale-Karten ist der Abstraktionsgrad: „**Level of Abstraction**“, kurz **LoA** genannt. Mit dem LoA wird die **Menge an Komplexität eines Karteninhaltes** angegeben, welche geographischen Phänomene dargestellt sind und wie detailliert. Dabei spielt es bei Multi-Scale-Karten eine besondere Rolle, damit je Zoomstufe die Lesbarkeit, Verständlichkeit und eine Kohärenz vorhanden sind. In Multi-Scale-Karten werden die Darstellung von Siedlungsgebieten als ein Beispiel genannt, wobei die detaillierteste Darstellung einzelne Gebäude sind, die dann zu Häuserblöcken werden, anschließend zu Stadtgebiet und Siedlungsfläche und zuletzt, am abstraktesten als Punkte für eine gesamte Stadt zusammengefasst werden.

Das LoA ist verbunden mit einem **Generalisierungsprozess** (siehe Abb. 26), spezielle Operatoren, bei denen es zum Einsatz kommt, sind die **Auswahl, die Vereinfachung, die Zusammenfassung und Typisierung von Kartenelementen** (Selection, Simplification, Aggregation, Typification). In der Abbildung sind diese als das Grundbild (Auswahl), dann den zwei vereinfachten Darstellungsstufen Drawing und Sketch, dann als Icon, Symbol und Wort abstrahiert (Dumont et al., 2016; Elias et al., 2005; Hake et al., 2002). D

Durch die Abbildung wird nochmal deutlich, dass ein Symbol bereits eine stark generalisierte Form der Realität abbildet.




Abb. 26: Level of Abstraction, dargestellt anhand einer Kirche (Elias et al., 2005).

Abschließend wird deutlich, dass es bei der Arbeit mit Multi-Scale-Karten einige Faktoren zu beachten gibt, um eine Anwendung nutzerfreundlich zu gestalten. Speziell um Symbole und Muster **funktional über Maßstäbe hinweg** zu gestalten, ist es wichtig **Orientierungspunkte** zu schaffen. Der decision point, sollte im Zuge der Generierungen zusammen mit einem angepassten MasterScale Diagramm ebenfalls beachtet werden. Der Platz, der sich bei Multi-Scale-Karten und hohen Zoomstufen ergibt, bietet zudem die Chance Designaspekte einzubringen und den Fokus auf mehr Details zu richten (siehe Kapitel 2.1).

3 Methodik

In folgendem Kapitel und Unterkapiteln soll die Methodik des praktischen Teils vorgestellt werden. Im Anschluss wird auf die **technische Umsetzung und wesentliche Elemente des geplanten Workflows** eingegangen. Anhand des vorangegangenen Theorieteils werden Designkriterien festgelegt, anhand derer nutzerfreundliche und dem aktuellen Designstand kartographischer Elemente generiert werden sollen. Als letzter Schritt wird auf Basis der vorher definierten Kriterien eine **Testumgebung definiert**, in der die KI- generierten Muster- und Symbole integriert werden sollen.

3.1 Technische Umsetzung und wesentliche Elemente des Workflows

Damit der Workflow möglichst nutzerfreundlich ist, werden für die Testumgebung Open-Source-Produkte verwendet. Ein neues Konzept für einen möglichst **nutzerfreundlichen Workflow** kommt von Hu et al aus dem Jahr 2025. Die AutorInnen haben ein Workflow-Management-System vorgestellt, was speziell für GIS-Themen entwickelt wurde. Ein Workflow soll dabei „FAIR-Prinzipien“ folgen, diese Abkürzung steht dabei für „**Findable**“, „**Accessible**“, „**Interoperable**“ und „**Reusable**“, auf deutsch für einen auffindbaren, zugänglichen, interoperablen und wiederverwendbaren Workflow. Speziell bei Analysen, die aus mehreren, einzelnen Verarbeitungsschritten bestehen, ist es wichtig alle Schritte nachvollziehbar gestalten, sodass sie von NutzerInnen leicht reproduziert werden können (Hu et al., 2025).

Es gibt für Workflows eine Standardsprache, auf die innerhalb dieser Arbeit zurückgegriffen werden soll. Diese Workflow Sprache heißt „**Common Workflow Language**“, CWL abgekürzt und ist eine formale Beschreibung der jeweiligen Elemente. Sie kann speziell für wissenschaftliche Zwecke verwendet werden und ist kostenlos, zudem sind verschiedenen Software-Umgebungen möglich. Nach Hu et al. ist es zudem von Vorteil, wenn einzelne Workflow-Komponenten in ihre **technischen Bestandteile** aufgeteilt und als eigenständige Elemente betrachtet werden. Dadurch wird das **Verständnis einzelner Schritte nachvollziehbarer**. Zusätzlich können einzelne Teile verbessert oder ausgetauscht werden und einzelne Komponenten losgelöst von anderen Teilen des Workflows genutzt werden (Hu et al., 2025; Language (CWL), o. J.).

Die Zielgruppe des Workflows soll ein Fokus auf ausgebildete KartographInnen und Personen mit GIS-Hintergrund haben, aber er soll zusätzlich losgelöst davon verständlich sein. Der Workflow wird **innerhalb von draw.io manuell ohne KI-Funktionen** erstellt, basierend auf gewonnenen Ergebnissen, die Seite ist ohne Anmeldung nutzbar, selbsterklärend und es können einzelne Workflowbausteine (Formen) aneinandergereiht werden (*draw.io*, o. J.). Bevor die eigentliche Generierung innerhalb eines Modells erfolgt, sollte sich vorher Gedanken um die **Zielgruppe, Kartenart, Maßstabsbereiche und Symbolklassen** gemacht werden, sowie um dazu passende **Gestaltungsrichtlinien**. Der **Workflow** soll im Anschluss in einzelne Module aufgeteilt sind, die **drei Hauptbestandteile** sind dabei:

- I. Die Inputdaten**
- II. Einzelne Verarbeitungsschritte**
- III. Die Outputdaten**

Im Zuge dieser Arbeit, sollen anhand der Multi-Scale-Kriterien, sowie Designaspekten und psychologischen Wahrnehmungskriterien KI-Modelle getestet werden. Symbole und Muster sollen mittels generativer KI generiert werden und dabei herausgefunden werden, welche Modelle, sowie spezieller Prompt Elemente gut für Multi-Scale-Karten funktionieren.

3.2 Festlegung von Designkriterien für die Symbol und Mustergenerierung

Damit die KI einen möglichst einheitlichen Output für Symbole und Muster erzeugt kann, wurden folgend anhand des Theoriekapitels und als Basis für Prompts **übergeordnete technische Anforderungen** definiert. In Tab. 1 sind diese für Symbole in der linken Spalte aufgelistet, in der mittleren Spalte sind die dazugehörigen Kapitel des Theorieteils und in der rechten Spalte, welche AutorInnen diese Anforderungen erfolgreich genutzt oder empfohlen haben.

Symbole & Musterkriterien	Kapitel	S oder M?	AutorInnen
weißer Hintergrund/ "background is pure white"	2.3.2 2.4.2 2.3.2	S	Drews et al., 2025 Wang et al., 2025 Dunkel et al. 2024
Textelemente ausschließen	2.3.2 2.4.2	S, M	Drews et al., 2025 Wang et al., 2025
zentriert/ mittig ausgerichtet	2.4.2	S	Wang et al., 2025
hohe Ikonizität	2.4.2	S	Wang et al., 2025
speziell nur ein Icon darstellen/ "only one icon"/ „A map icon of.“	2.4.2	S	Wang et al., 2025, Dunkel et al.,2024
Stichwort Icon: automatisch ein weißer Hintergrund, was Späteres ausschneiden vereinfacht	2.4.3	S	Dunkel et al., 2024
intuitive Farben	2.5.2 2.2.1 2.1.2 2.4.2	S, M	Brewer., 1999 Fabrikant et al., 2012* A. Kent & Vujakovic, 2009** Wang et al., 2025
semantische, harmonische Farben	2.2.1	S, M	Fabrikant et al., 2012 Mo et al., o.J.
sprechende Symbole, bildhaft	2.1.4	S	Hake et al., 2002
ausgeglichen, akkurat, autenthisch (balanced, accurate, authentic)	2.2.3	S, M	Prestby, 2024 (Map trust skala)
*Farben typisch für den Objekttyp positiv in Studie gewertet			
**Farben der Landschaft wiedergeben			

Tab. 1: Festgelegte Basisspezifikationen für Prompts (übergeordnete Anforderungen an alle Symbole (S) und Muster (M)) (eigene Darstellung beruhend auf den Erkenntnissen von (Brewer, 1999; Drews et al., 2025; Dunkel et al., 2024; Fabrikant et al., 2012; Hake et al., 2002; Mo et al., o. J.; Wang et al., 2025).

Zu Beginn wird es für Symbole getestet, da es dafür bereits veröffentlichte grundlegend funktionierende Ansätze gibt und **anschließend auf Muster übertragen** und anhand von Tests optimiert. Die festgelegten Basisspezifikationen bieten eine Grundlage für den Prompt bei Symbolen. Zusätzlich sollen, als eine **Variante, Prompts mit einer Orientierungsvorlage** getestet werden. In digitalen Multi-Scale-Anwendungen, werden sogenannte „**Sprites**“ dafür verwendet, zu definieren, welche Symbole und Muster in einer Anwendung vorkommen und **an welcher Stelle und bei welchem Maßstab sie NutzerInnen angezeigt werden**. Abgerufen werden diese bei Webkarten über ein stylesheet. Zu dem Sprite wird eine Index Datei erstellt, die jedes einzelne Bild/ Symbol (SVG) der Sprite-Datei beschreibt, diese ist im JSON-Format, während alle Symbole und Muster innerhalb eines PNG's integriert sind (siehe Abb. 27). Oft gibt es von diesen beiden Dateien zwei Varianten, eine davon in höherer Auflösung. Auf der MapLibre Seite wird zur Erstellung der Sprite Dateien „**spreet**“ (über GitHub Code abrufbar) empfohlen, deshalb wird das für die Einbindung der Symbole und Muster in die Testumgebung verwendet (Riggott, 2022/2026; *Sprite | Mapbox Style Spec | Mapbox Docs*, o. J.; *Sprite - MapLibre Style Spec*, o. J.).

Als **Orientierung für eine erste Symbolauswahl** und als **Grundlage für Tests** könnten die sogenannten „Maki Icons“ von Mapbox dienen. Es sind einfach gehaltene SVG-Symbole,




Abb. 27: Beispielhafte Sprite-Datei (PNG), in der alle Symbole und Muster einer digitalen Kartenanwendung innerhalb einer Datei definiert sind (*Sprite | Mapbox Style Spec | Mapbox Docs*, o. J.).

die als Point of Interest (POI) wichtige Punkte in der Landschaft markieren. Sie sind **Open Source nutzbar** und könnten als ein erster Input für die gewählte KI-Anwendung genutzt werden. Das könnte dabei helfen, die Symbole in einem bestimmten Stil zu generieren, der in Folge dann detaillierter angepasst und bearbeitet werden kann (Drews et al., 2025). In Abb. 28 ist ein Ausschnitt beispielhafter Icons dargestellt. Die Icons wurden von Mapbox veröffentlicht und eignen sich speziell für Multi-Scale-Karten, da sie als Input für den Style Editor für eine Web-Karten-Applikation gedacht sind. Sie sind zudem nicht durch Urheberrechte geschützt und dürfen frei verwendet werden (CC0 1.0: Universell Creative Commons Lizenz) (Maki Icons | By Mapbox, o. J.).



Abb. 28: Auswahl beispielhafter "Maki Icons" für Symbole innerhalb einer Karte (Maki Icons | By Mapbox, o. J.).

Für Muster könnte als **erster Input und Orientierung** der **Mustergenerator von Imagico** dienen. Hinter dem Namen Imagico steht der **Kartograph Christoph Hormann**, der sich unter anderem mit OSM-Kartenstils beschäftigt. Unter dem Namen „**Periodic dot and symbol pattern generator**“, dargestellt in Abb. 29 ist es möglich Symbole und Muster zu generieren.




Abb. 29: Mustergenerator von Christoph Hormann ("Imagico"), als mögliches Orientierungsbeispiel für den KI-Input (imagico.de - Periodic dot and symbol pattern generator, o. J.).

Es könnte als **Alternative für MapLibre** funktionieren, wenn ein einzelnes Symbol oder Muster schnell visualisiert werden soll, da bereits vorher erstellte Inhalte damit dargestellt werden können. Es ist zudem, genauso wie die Maki Icons durch „CC0 1.0: Universell Creative Commons Lizenz“, frei verwendbar (imagico.de - About me, o. J.; imagico.de - Periodic dot and symbol pattern generator, o. J.).

Wie in Kapitel 2.1.4 bereits angeschnitten, soll innerhalb dieser Arbeit **kein kompletter Signaturenkatalog** mittels generativer KI erstellt werden, jedoch kann das Vorgehen und die Überlegungen hilfreich sein, um ein **geeignetes KI-Modell auszuwählen**. Zudem hilft es bei der Planung welche Symbole und Muster genau erstellt werden sollen und definiert **konkrete Anforderungen** und technische Aspekte für den Prompt Input und spätere Justierungen. Speziell für den ersten Input wurden deshalb in Tab. 2 **Anforderungen an ein Baumsymbol** festgelegt, die sich an dem Ausschnitt eines Signaturenkataloges orientieren (Hake et al., 2002).

Objektbereich: Vegetation
Objektart: Baum
Regeln für kartographische Gestaltung:
1. Topologischer Objekttyp: Symbolhaft
2. Objektteile: ohne Rand, grüne Blätter, brauner Stamm
3. Modellierungsregeln: intuitive, semantische Farben
4. Basisvorlage/ Signaturdefinition (Maki Icon):


Tab. 2: Signaturenkatalog für ein Baumsymbol, eigene Darstellung auf Basis von (Hake et al., 2002), sowie verwendete Symbolvorlage von (Maki Icons | By Mapbox, o. J.)

Zusätzlich zu den in Tab. 1 definierten übergeordneten Anforderungen, sind in **Tab. 3 Prompt Anforderungen anhand des Theorieteils aufgelistet**, um diese ebenfalls in einen ersten Testprompt miteinzubeziehen. Dabei sind in der linken Spalte anhand von Ekin und Wang et al. Anforderungen an die Prompts aufgelistet, mit einer kurzen Definition und Erklärung anhand weiterer AutorInnen aus dem Theorieteil, die diese Anforderungen bestätigen. Der *erste Testprompt soll dazu dienen ein Symbol zu erstellen*, erstmal ohne spezielle Anforderungen für eine Multi-Scale-Karte zu integrieren, diese sollen ergänzt werden, sobald ein Prompt bereits gut für eine Symboldarstellung funktioniert.

Anforderung/ Prinzip*	Kurzdefinition	Erklärung	AutorInnen/ Quelle
Klarheit und Spezifität (Conciseness)	Eindeutige, reduzierte Beschreibung	Verhindert mehrdeutige Bildausgaben/ PAE-Methode	(Mo et al., o. J.)
Zweckmäßigkeit (Purposfulness)	Fokus auf Anwendungszweck	Vermeidet unnötige Details	Dunkel et al. (2024)
Normativität (Normativeness)	Vorgabe qualitativer und stilistischer Standards	Steuert ästhetische Konsistenz	Dunkel et al. (2024)
Erklärbarkeit (Explainability)	Promptstruktur ist nachvollziehbar	Erhöht Reproduzierbarkeit	Liu & Chilton (2023)

*Ekin (2023); Wang et al. (2025)

Tab. 3: Prompt Anforderungen auf Basis des Theorieteils (Dunkel et al., 2024; Ekin, 2023; Liu & Chilton, 2023; Wang et al., 2025).

Für die **Grundstruktur des ersten Prompts** (Abb. 30) wird vor allem auf die **Bausteine von Dunkel et al., 2024** zurückgegriffen. „PV01“ steht dabei für „**Prompt Version 01**“, diese Abkürzung wurde festgelegt, um ihn von späteren Prompts unterscheiden zu können.

A map icon of a	(single tree)	high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, pure white background	(green leaves, brown trunk)	best quality, 8k, 2d render
text, word, letters, watermark, alphabet, multiple icons, group of trees, forest, realistiv photo, 3d render, shadow, gradient, complex background, frame, border				

Abb. 30: Aufbau des ersten Testprompts (Zeile 1, PV01) und Negativprompt (gelb), eigene Darstellung, Grundstruktur auf Basis von (Dunkel et al., 2024).

Es wurde sich für eine **englischsprachige Variante** entschieden, da wie in Kapitel 2.3.4 angeschnitten, englischzentrierte Modelle und Prompts aktuell überwiegen (Schut et al., 2025). Die **einzelnen Bausteine sind wiedererkennbar durch ihre Farben in Tab. 4** aufgelistet. Wie in Tab. 1 dargestellt, hat sich anhand Kapitel 2.4 der Pre-Prompt von Dunkel et al. als hilfreich rausgestellt, da durch den Text „A map icon of“ automatisch ein weißer Hintergrund erzeugt wurde und dadurch klar definiert wird, was dargestellt werden soll (Dunkel et al., 2024; Mo et al., o. J.). Mit dem **Subject** wird der **Fokus auf das darzustellende Objekt** gelegt. Mit den **Style Modifier** werden **visuelle Anforderungen** festgelegt, dieser Prompt Baustein von Dunkel et al. deckt sich mit den Erkenntnissen von Liu & Chilton, die diese, als Style Keywords beschrieben haben (siehe Kapitel 2.4).

Prompt Baustein	Funktion	Beispiel	AutorInnen
Pre-Prompt	Kontextualisiert den Output	<i>“A map icon of ...”</i>	Dunkel et al. 2024
Subjekt	Definiert das zentrale Objekt	<i>(single tree)</i>	Dunkel et al. 2024
Style Modifier/ Style Keywords	Legen visuelle Ästhetik fest	<i>high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, pure white background</i>	Dunkel et al. 2024; Liu & Chilton 2023
Quality Modifier	Steuert technische Qualität	<i>best quality, 8k, 2d render,</i>	Dunkel et al. 2024
Gewichtung (DF-Ansatz)	Feinsteuerung einzelner Merkmale	<i>(green leaves, brown trunk)</i>	Dunkel et al. 2024, Mo et al. (o. J.)
Negativprompt	Aufzählung expliziter Ausschlüsse, die nicht vorhanden sein sollen	<i>no text, no watermarks</i>	Dunkel et al. 2024, Ogezi & Shi, 2024

Tab. 4: Prompt Bausteine des ersten Testprompts (PV01), eigene Darstellung basierend auf (Dunkel et al., 2024; Liu & Chilton, 2023; Mo et al., o. J.; Ogezi & Shi, 2024).

Der **Quality Modifier** gibt die **darzustellende Qualität** an, für den Beginn wurde ähnlich wie bei den vorgestellten Papern, ein minimalistischer Vektorstil gewählt. Die **Gewichtung** wird bei Dunkel et al. ausgelagert, für einen ersten Testprompt wird dieser Faktor miteinbezogen, in Klammern geschrieben werden damit **einzelne Merkmale hervorgehoben**, was ebenfalls im Zuge eines **DF-Prompts** von Mo et al. verwendet wird (Dunkel et al., 2024; Mo et al., o. J.).

Zudem haben alle Paper **negative Prompts** verwendet um explizit auszuschließen was nicht dargestellt werden soll, darunter hat sich vor allem der **Textausschluss** als hilfreich erwiesen. Zudem wurden Umrandungen mit verschiedenen Wörtern ausgeschlossen („frame, border“) damit die Darstellung universeller innerhalb einer Karte eingesetzt werden kann (Drews et al., 2025; Wang et al., 2025).

Basierend auf dem Basisprompt soll es zu Beginn **zwei weitere Varianten** geben, eine die zusätzlich die **Betrachtung von oben** als eine Anforderung miteinbringt (2.1.4 mit Darstellung von Grundrissbildern könnten gewisse Modelle Schwierigkeiten haben). Und eine Variante, die **zusätzlich zu dem Prompt ein Bild als Referenz** angibt. Dieses Bild soll für Symbole ein Maki Icon sein und für Muster eine Walddarstellung, die mit Imagico (siehe oben) erstellt wurde. Die insgesamt vier Varianten sind in Tab. 5 aufgelistet.

Sie enthalten alle die oben festgelegten Elemente und sind nur je nach Prompt Baustein, zum Beispiel mit PV01 oder ohne Negativprompt „PV01neg“ angepasst. Zu Beginn wird der **Basisprompt einmal mit jedem Modell getestet**, dafür werden die Standardeinstellungen der Modelle verwendet und als **Format 1:1** ausgewählt, damit die Ergebnisse besser vergleichbar sind.

Prompt Kürzel	Beschreibung	Prompt
PV01	Basisprompt	"A map icon of a (single tree), high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, pure white background (green leaves, brown trunk), best quality, 8k, 2d render"
PV01neg	Basisprompt mit Negativprompt	"A map icon of a (single tree), high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, pure white background (green leaves, brown trunk), best quality, 8k, 2d render. Not include: text, word, letters, watermark, alphabet, multiple icons, group of trees, forest, realistiv photo, 3d render, shadow, gradient, complex background, frame, border."
PV02	Darstellung von oben	"A map icon of a (single tree), view from above, high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, pure white background (green leaves), best quality, 8k, 2d render. Not include: text, word, letters, watermark, alphabet, multiple icons, group of trees, forest, realistiv photo, 3d render, shadow, gradient, complex background, frame, border"
PV03	Bezug auf beigefügtes Bild als Vorlage	"A map icon of a (tree), <i>attached image as reference</i> , high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, pure white background (green leaves, brown trunk), best quality, 8k, 2d render. Not include: text, word, letters, watermark, alphabet, multiple icons, group of trees, forest, realistiv photo, 3d render, shadow, gradient, complex background, frame, border"

Tab. 5: Übersicht der genutzten Symbol-Prompts für die Modelltestung (eigene Darstellung).

Da für die Mustergenerierung kein spezifisches Paper gefunden wurde, ist zu Beginn der Prompt für Muster an dem Basisvorgehen der Symbolprompts orientiert, wie in Tab. 6 festgehalten.

Prompt Kürzel	Beschreibung	Prompt
V01	Basisprompt	A seamless map pattern of a (forrest), irregular arrangement, minimalistic, from above, high iconicity, intuitive semantic colours, pure white background (green tree crowns), 1:1 format.

V01_neg	Basisprompt mit Negativprompt	A seamless map pattern of a (forrest), irregular arrangement, minimalistic, from above, high iconicity, intuitive semantic colours, pure white background (green tree crowns), 1:1 format. Do not include: text, word, letters, watermark, alphabet, realistik photo, 3d render, shadow, gradient, complex background, frame, border, more than 20 trees, trunk.
V02	Bezug auf beigefügtes Bild als Vorlage (imagico pattern)	A seamless pattern of a (forrest), attached image as reference, irregular arrangement, minimalistic, from above, high iconicity, intuitive semantic colours, pure white background (green tree crowns), 1:1 format. Do not include: text, word, letters, watermark, alphabet, realistik photo, 3d render, shadow, gradient, complex background, frame, border, more than 20 trees, trunk.
V03	aus Symbol Muster erstellen	A seamless pattern of a (forrest), attached image as reference, irregular arrangement, minimalistic, from above, high iconicity, intuitive semantic colours, pure white background (green tree crowns), 1:1 format. Do not include: text, word, letters, watermark, alphabet, realistik photo, 3d render, shadow, gradient, complex background, frame, border, more than 20 trees, trunk.

Tab. 6: Übersicht der genutzten Pattern-Prompts für die Modelltestung (eigene Darstellung).

Die festgehaltenen Prompts in Tab. 5 und Tab. 6 sind hauptsächlich dafür da, herauszufinden, welche generativen **KI-Modelle und Methoden** für die Integration in Multi-Scale-Karten **geeignet** sein können. Spezifischere Prompts mit anderen Symbolen und Mustern sollen im Anschluss innerhalb der, als am besten für diese Anforderungen geeigneten Modelle getestet werden.

3.3 Auswahl und Definition einer Testumgebung

Auf Grundlage des Theorieteils werden im folgenden Kapitel Kriterien für eine geeignete Testumgebung identifiziert.

Die mittels generativer KI erstellten Symbole und Muster, sollen in eine möglichst **praxisnahe** Testumgebung integriert werden, um die Übergänge von einem Maßstab in einen anderen gut beurteilen zu können. Damit die Symbole und Muster über verschiedene Maßstäbe hinweg erzeugt werden können und den Ansprüchen einer Multi-Scale-Karte gerecht werden, sollte das Testgebiet **groß genug für verschiedene Zoomstufen** sein. Zudem sollte es **verschiedene Landschaftsformen** abdecken, um verschiedene Symbole und Musterkategorien testen zu können.

Damit zu Beginn die Symbol- und Mustergenerierung mit verschiedenen generativen KI-Modellen getestet werden kann, wurde sich dafür entschieden, **zu Beginn ein Symbol und ein spezifisches Muster zu generieren** und dafür ein festes Vorgehen zu definieren, welches dann bestenfalls im weiteren Vorlauf auf andere übertragen werden kann. Dabei wurde sich zu Beginn für ein **Baumsymbol** und einen **Wald als Musterdarstellung** entschieden. Ein Baumsymbol, weil es mit **verschiedenen Blickwinkeln** (z.B. von oben) dargestellt werden kann und ein Wald, weil bei der Kombination der beiden Outputs gut der Übergang von

einer Maßstabstufe in die andere getestet werden kann, an der Stelle, an der **Waldflächen in einzelne Bäume** übergehen.

Ein weiterer Punkt, der bei der Entscheidung für Bäume und Wälder als erster Testprompt wichtig ist, ist wie bereits in der Motivation der erwähnte Platz, der sich bei Multi-Scale-Karten in hohen Zoomstufen ergibt. Dieser Platz entsteht bei Natursymbolen schneller, da sie oft in Gebieten vorkommen, in denen sie nicht durch andere Symbole verdrängt werden. Speziell Wälder sind bei herkömmlichen Karten oft mittels einer Grünen Fläche dargestellt, die auf **hoher Zoomstufe wenig Orientierung** liefert, eine detaillierte Version mit generativer KI könnte mehr Orientierung schaffen und diese entstandene Fläche und den Platz dafür ausnutzen.

Wie bereits in Kapitel 2.5.1 erwähnt, haben Brewer und Buttenfield in ihrem Paper "Performance of map symbol and label design with format and display resolution options through scale for The National Map" mittels eines Master-Scale Diagramms basierend auf Roth (2009) sinnvolle Maßstäbe für Symbole und Muster erarbeitet. Sie arbeiten mit Maßstäben zwischen **1:24.000** (Zoom-Level ~15/16) bis **1:1.000.000** (Zoom-Level ~7/8) und untersuchen, ab wann Symbole lesbar und sinnvoll sind. Sie zeigen, dass **Symbole frühestens ab Zoom-Level 13/14** sinnvoll einsetzbar sind, da darunter zu wenig Platz für differenzierte visuelle Verarbeitung bleibt. Muster als Hintergrundstruktur können bereits früher eingesetzt werden, da Sie auch in weniger detaillierten Maßstäben Orientierung bieten können.

Aufgrund dieser empfohlenen Zoomstufen und Maßstäben wird das Testgebiet dieser Arbeit für **Symbole ab Zoomstufe 14 beginnen, Muster** werden **ab Zoomstufe 12** angezeigt. Die AutorInnen empfehlen aufgrund ihrer Ergebnisse explizit, die Darstellung schrittweise an diese Maßstabsübergänge anzupassen, sowohl in Bezug auf die Symbolgröße als auch die Generalisierung, was in dieser Arbeit unter anderem mithilfe eines Master-Scale Diagramm in "Kapitel 4.3 Integration von Multi-Scale-Aspekten" evaluiert werden soll (Brewer & Buttenfield, 2010). Die verschiedenen Maßstabsstufen sind zur besseren Übersicht in Tabelle 1 dargestellt (detaillierter in Kapitel 4.2).

Die **grundlegenden Basisdaten** sollen **OSM-Daten** sein, da diese frei zugänglich und für meinen geplanten, möglichst nutzerfreundlichen Workflow gut geeignet sind.

Die Testumgebung soll mittels **MapLibre** erzeugt und dargestellt werden. MapLibre ist eine Organisation, die **kostenlose Open-Source** Kartenbibliotheken und Werkzeuge entwickelt hat und mit der es möglich ist eigene Kartenanwendungen zu erzeugen und individuell anzupassen. Ein Grund für die Wahl von MapLibre ist die **einfache Bedienung** und die bereits vielen **vorhandenen Tutorials**. Der Fokus der Arbeit soll nicht auf der Erstellung der Testumgebung liegen, sondern auf den Inhalten, die diese am Ende befüllen sollen (Maplibre-Strategy-2023, o. J.).

Übersicht über die Kriterien der Testumgebung	
Kriterien	Gewählte Parameter
Umgebung	praxisnah, verschiedene Landschaftsformen abdecken
Basisdaten	OSM
Zoomlevel Symbole	ab 13
Maßstab Symbole	~1:36 000
Zoomlevel Muster	ab 12
Maßstab Muster	~1: 72 000
Testumgebung Engine	MapLibre
Bäume und Wälder als 1. Testsymbol bzw. 1. Muster	Übergang von einer Maßstabstufe in die andere; oft in Gebieten, in denen sie nicht durch andere Symbole verdrängt werden.

Tab. 7: Übersichtstabelle über Kriterien der Testumgebung mit Zoomstufe zu Maßstabumrechnung eigene Darstellung, Maßstabumrechnung auf Basis von (Zoom Levels and Scale | Documentation | Esri Developer, o. J.).

Aufbauend auf den in Kapitel 2.3 beschriebenen KI- Ansätzen werden im folgenden Abschnitt konkrete **Kriterien für die Auswahl eines Modells definiert:**

- **Datengrundlage**

Verwendete Daten sollten eine **hohe Qualität** haben. Eine Frage, die sich dabei ergibt, ist, mit welcher Datengrundlage die KI trainiert wurde, was eine ethische Frage sein kann, je nachdem ob die **Daten von NutzerInnen aktiv oder passiv gesammelt** wurden. Zum Beispiel haben bei OSM Daten NutzerInnen aktiv dazu beigetragen, während andere Kartenanbieter zusätzlich passive NutzerInnen Daten sammeln (Kang et al., 2024).

- **Dateioutput/ Ausgabeformat und Raster vs. Vektor**

Welches Format ist direkt innerhalb der Anwendung möglich, ohne einen weiteren Schritt im Workflow ergänzen zu müssen? Speziell **SVG-Dateien wären praktisch** für den Input als Sprite Datei (siehe Kapitel 3.1.).

Ein weiteres Thema, welches sich zum Thema Ausgabeformat ergibt, sind **Rasterdaten im Vergleich zu Vektordaten**. Bisherige Forschungen zu Kartendesign hat sich vor allem auf Vektordaten als Input für Symbole und Muster fokussiert, während KI-Modelle mit Rasterdaten arbeiten und Rasteroutputs erzeugen. Der **Vorteil von Vektorkarten** ist, dass räumliche Informationen, wie **Koordinaten und Attributmerkmale separat auf verschiedenen Ebenen** erfasst werden, was zum Beispiel Generalisierungen einfacher macht. Es kann dazu führen, einen Stil schwieriger in allen Bereichen beziehungsweise Ebenen anwenden zu können. Im Vergleich dazu kann es bei Rasterdaten ein Vorteil sein, dass es keine Ebenen gibt, die unabhängig voneinander sind, sondern räumliche Informationen und Attributmerkmale innerhalb eines Pixels zusammengefasst werden. Dadurch kann ein **Stil für eine gesamte Karte berechnet werden**. Gleichzeitig kann die Information, die „nur“ jeweils innerhalb eines einzelnen Pixels gespeichert ist zu anderen Problemen, wie Topologiefehlern führen (Kang et al., 2019).

Eine Lösung könnte sein, **generierte Symbole und Muster im Rasterformat mittels eines Tools in ein Vektorformat umzuwandeln**. Dafür gibt es Python Bibliotheken und ebenfalls

KI-Tools, die mittels Algorithmen die Pixel in Pfade umrechnen und beispielsweise **SVG als Ausgabeformat** aus den Rasterdaten erzeugen können. Eine andere Möglichkeit den Hintergrund zu entfernen, die von Dunkel et al. benutzt wurde, ist ein Python Tool namens „Rembg“ (*Convert PNG, JPG Files to SVG Vectors Online - Vectorizer.AI*, o. J.; Gatis, 2020/2025).

- **Reproduzierbarkeit**

Die nicht- oder nur teilweise mögliche Reproduzierbarkeit ist ein Problem, welches viele KI-Modelle haben. Die KI-Anwendung sollte trotzdem **möglichst reproduzierbare Inhalte generieren** können, damit Symbole und Muster nach einer ersten Erstellung noch angepasst werden können. Ein Parameter der Reproduzierbarkeitsprobleme einschränken kann ist der „Seed“, welcher einen Ausgangswert für das Rauschen des generierten Bildes angibt. Bei identischem Seed und Prompt wird zu fast 100% der identische Output generiert. Das kann dazu genutzt werden, Details beim Prompt zu ändern, bei weiterhin identischem Seed, damit ein generierte Bild, welches bereits den Vorstellungen entspricht, um spezifische Details verbessert wird, ohne das ein komplett neuer Output generiert wird (Dunkel et al., 2024; Kim et al., 2024).

- **Lizenzbedingungen & Datenschutz**

Bei **kommerziellen Datensätzen**, wie zum Beispiel von Google Maps können Gebühren anfallen und es kann **Einschränkungen bei den Nutzungsbedingungen** geben, beziehungsweise Einschränkungen bei der Weiterverarbeitung und Verbreitung der Daten, weshalb **für den Input frei zugänglich verwendbare Daten** verwendet werden sollen (Kang et al., 2024).

Damit eine **geeignete KI ausgewählt** werden kann, um die Symbole und Muster zu erzeugen wird ein **einheitliches Vorgehen, sowie einheitliche Prompts** verwendet. Dieses basiert auf den Erkenntnissen aus Kapitel 2.4 “Prompt Engineering für die Text-zu-Bild-Generierung”, sowie auf Kapitel 2.3 “Überblick über Generative KI-Methoden für eine kartographische Anwendung”, in dem KI-Anwendungen und Methoden vorgestellt wurden. In Tab. 8 sind die Kriterien anhand der vorher definierten Punkte aufgelistet.

Wie in Kapitel 2.3 "Überblick über generative KI-Methoden für eine kartographische Anwendung“ bereits angeschnitten, geschehen **Veröffentlichungen von neuen Modellen und Versionen**, teilweise aufgrund von Konkurrenzen großer Unternehmen, schneller, als das neue wissenschaftliche Paper dazu veröffentlicht werden können. Um den Workflow gut testen zu können und die am besten entwickelten Modelle zu nutzen, wird deshalb zu Beginn das **jeweils neuste Modell eines Unternehmens** für Tests herangezogen.

Um für die weiteren Tests ein möglichst geeignetes KI-Modell zu nutzen, wurden anhand der in Tab. 8 festgelegten Kriterien insgesamt 11 Modelle getestet.

Kriterium	Kürzel	Beschreibung	AutorInnen
Anmeldung (rot=ja, grün=nein)?	A	Gegen Anmeldung nutzbar?	
Bildinput?	B	Bildinput als Referenz möglich	
Bildinput Muster als Vorlage	B ¹		
Bildinput Symbol zu Muster	B ²		
Bildqualität/ Auflösung	Q	Hohe Qualität	Dunkel et al. 2024, Liu & Chilton, 2023
Qualität anpassbar?	q	Kann eine gewünschte Pixelgröße ausgegeben werden?	
Credits (rot=ja)?	C	Credits/ begrenzte Bildanzahl pro Tag?	
Datengrundlage?	D	Transparente Trainingsdatenverfolgung?	Kang et al., 2024
Export/ kostenfreier Download?	E	Kann das Symbol/ Muster leicht exportiert/ heruntergeladen werden? Gibt es Einschränkungen dabei (z.B. bei der Dateiformatauswahl)?	
Freistellung?	F	Können Symbole direkt freigestellt, bzw. mit weißem Hintergrund dargestellt werden?	Drews et al., 2025, Wang et al., 2025, Dunkel et al. 2024
Kostenfrei?	K	Mehr als eine Generierung möglich?	
Negativprompts	N	Negativprompts als extra Eingabefeld?	Dunkel et al., 2024, Ogezi & Shi, 2024
Reproduzierbarkeit	R	Wie sehr weicht es nach der Bearbeitung ab? („Reproduzierbarkeit“)	Kang et al. 2023 Kim et al., 2024
Sichtwinkel/ Vogelperspektive?	S	Darstellung von verschiedenen Seiten (z.B. von oben möglich, Grundrissbild als vereinfachte Version für Maßstabswechsel)?	Brewer & Buttenfield, 2010; R. E. Roth et al., 2011, Hake et al., 2002
Seed	s	Ist eine spezifische Seed-Angabe möglich (Eingabefeld)? Bzw. kann man den Seed eines Bildes abfragen und sich darauf beziehen (Chatmodelle)?	Dunkel et al., 2024; Kim et al., 2024
Urheberrechte	U	Wie sind die Urheberrechte geregelt?	
Veränderungen	V	Veränderungen eines bereits erstellten Symbols möglich?	Dunkel et al., 2024; Kim et al., 2024
Kachelbar/ seamless	Ü	Nahtloser Übergang möglich?	

Tab. 8: Übersichtstabelle für die KI-Auswahl (eigene Darstellung basierend auf den Erkenntnissen von (Dunkel et al., 2024; Kang et al., 2024; Kim et al., 2024) sowie Punkte, die sich beim Besuchen der Modell-Webseiten ergeben haben. B¹, B², Ü speziell für Mustertest (eigene Darstellung).

Ausgewählt für detailliertere Tests wurden zum einen Modelle, die bereits **für kartographische Zwecke** getestet wurden (z.B. DALLE 3, Stable Diffusion, siehe Kapitel 2.3) und Modelle die aufgrund von **bereits bestehenden Bestenlisten** für die

Bildgenerierung als hilfreich eingestuft wurden (*Text to Image Leaderboard - Top AI Image Models*, o. J.). Während der Tests erschien am 26.02.2026 Nano Banana Pro, weshalb bis dahin erstellte Outputs mit der aktuellen Version ersetzt wurden (*Nano Banana 2: Pro-Funktionen kombiniert mit blitzschneller Geschwindigkeit*, o. J.). Zusätzlich erschien am 21.04.2026 eine neue Version von ChatGPT, „ChatGPT Images 2.0“, für die Modelltests wurde 1.5 verwendet, für einzelne Symbole der Testumgebung 2.0, wobei sich für die Multi-Scale-Kriterien keine markanten Unterschiede gezeigt haben (*Einführung von ChatGPT Bilder 2.0*, o. J.)







In Tab. 9 sind die KI-Modelle aufgelistet zusammen mit einem Kürzel (obere Zeile) für das Kriterium (siehe Tab. 8). Wenn ein **Kriterium erfüllt** ist, ist das Feld **grün** markiert, wenn es **zum Teil erfüllt** ist **gelb** und wenn es **nicht erfüllt** ist, **rot**. Grau eingefärbt bedeutet, dass eine Überprüfung nicht möglich war (z.B. keine kostenfreien Generierungen mehr offen oder keine klare Quelle auffindbar, was die Herkunft von Daten angeht). Eine **detailliertere Übersicht** über die Modelle und die Erfüllung oder nicht-Erfüllung der Kriterien ist im **Anhang Tabelle 1** integriert.

KI-Modell	A	B	Q	q	C	D	E	F	K	N	R	S	s	U	V	Grün
Adobe Firefly (Firefly Image 4)																6
ChatGPT Images 1.5												5				10
Dall-E 3 (über ChatGPT 5.2)												2				7
Flux (Flux 2 Pro)																3
Imagen (über Google AI Studio)																1
MAI-Image-1 (über Bing)**																3
Nano Banana (über Gemini)												2				7
Qwen3-Max (Alibaba Cloud)												4				7
Seedream old																5
Seedream-4.5 (ByteDance)												14				5
Stable Diffusion																10
Z-Image-Turbo (ü. hugging face)																9
trifft zu trifft zum Teil zu trifft nicht zu																Zahl = Anzahl der Versuche, bis Darstellung von oben generiert wurde.

Tab. 9: KI-Modellauswahl für Symbolgenerierung anhand vorher festgelegter Kriterien (Modelle alphabetisch sortiert), eigene Darstellung mittels heatmap in Excel, die Modelltests sind auf dem Stand März 2026.

Die meisten grünen Felder haben die beiden Modelle „**ChatGPT Images 1.5**“ mit zehn von 15 Kriterien, sowie „**Stable Diffusion**“. ChatGPT Images, ab jetzt mit GPT-I abgekürzt, ist ein MLLM und Stable Diffusion, wie anhand des Namens deutlich ein Diffusionsmodell.


Sie scheinen aufgrund der meisten erfüllten Kriterien für die Anforderungen einer Symbolgenerierung geeignet.

KI-Modell*	PV01	PV01neg	PV02	PV03
Adobe Firefly (Firefly Image 4)				
ChatGPT Bilder ("Chatgpt Images")				
Dall-E 3 (über ChatGPT)				
Flux (Flux 2 Pro)				
Imagen (über Google AI Studio)				
MAI-Image-1 (über Bing)				
Nano Banana 2 (über Gemini)				
Qwen3-Max				
seedream (old)				
Seedream-4.5 (ByteDance)				
Stable Diffusion				
Z-Image-Turbo (über hugging face)				

Tab. 10: KI-Modelltests - Outputs der drei Symbol Testprompts je Modell (eigene Darstellung, Abbildungen generiert innerhalb linkstehender Modelle, *Sortierung alphabetisch).

In Tab. 10 sind die während der Symboltests *entstandenen Outputs der drei Basisprompts und dem Negativprompt* (Prompts siehe Tab. 5) in einer Übersicht festgehalten. Auffällig ist, dass Imagen und MAI-Image deutlich gegen den Negativprompt mit dem Stichwort „complex background“ und gegen den Prompt mit „white Background“ verstoßen haben, in dem sie einen Hintergrund in einer anderen Farbe dargestellt haben (MAI-Image), bzw. mit gar nicht beschriebenen Details (Imagen). Bis auf Adobe Firefly, welches mit einer eheren realistischeren Darstellung raussticht, sind bei der Generierung ähnliche Stile und Farben herausgekommen.

In Tab. 11 sind die *generierten Outputs mit Maki Vorlage* zum besseren Vergleich nebeneinander abgebildet. Wobei DALL-E 3, Adobe Firefly und Flux am stärksten von der Vorlage abweichen.



Tab. 11: Direkter Vergleich der Outputs mit Maki Vorlage (links) als Orientierung (Maki Icons | By Mapbox, o. J.), eigene Darstellung, Abbildungen generiert innerhalb oben stehender Modelle.





Nicht alle Modelle können Bilder als Input integrieren. Es wird deutlich, dass der *Output teilweise stark vom Input abweicht* (DALL-E 3 und Flux), während GPT-I, Nano Banana 2 und Stable Diffusion, die dem Input am ähnlichsten erscheinenden Outputs generieren. Für die Mustergenerierung wurden die *drei bestabgeschlossenen Modelle der Symbole* mit den Prompts aus Tab. 6 getestet. In Tab. 12 sind die Ergebnisse innerhalb einer heatmap in verschiedenen Kacheln dargestellt, die Spalten B¹, B², Ü wurden neu generiert, ansonsten wurden die Faktoren bereits im Zuge der Symboltests abgedeckt und übertragen.

KI-Modell	A *	B ₁	B ₂	Q	q	C	D	E	F	K	N	R	S	s	U	V	Ü	Grün
Chatgpt Images 1.5																		9
Stable Diffusion																		10
Z-Image-Turbo																		9

Tab. 12: KI-Modellauswahl für Mustergenerierung anhand vorher festgelegter Kriterien, eigene Darstellung mittels heatmap in Excel.

In Tab. 12 sind die Ergebnisse innerhalb einer heatmap in verschiedenen Kacheln dargestellt, die Spalten B¹, B², Ü wurden neu generiert, ansonsten wurden die Faktoren

bereits im Zuge der Symboltests abgedeckt und übertragen.

KI-Modell*	PV01	PV01neg	PV02	PV03
ChatGPT Images 1.5				
Stable Diffusion				
Z-Image-Turbo (hugging face)				
*Sortierung alphabetisch	kein Bildinput möglich			

Tab. 13: KI-Modelltests - Outputs der Muster Testprompts je Modell (eigene Darstellung, Abbildungen generiert innerhalb linkstehender Modelle).

Die drei Modelle sind von den Punkten fast gleich auf, nur Z-Image-Turbo ist etwas eingeschränkt, dadurch das keine Bildinputs möglich sind.

Bei Betrachtung der Muster Ergebnisse in Tab. 13 wird deutlich, dass bei dem Basisprompt *eher realistischere Ergebnisse* erzeugt wurden. Zudem sollte in einem späteren Prompt, darauf geachtet werden, die Muster *flächenfüllend* zu generieren. Beim Negativprompt wurde bei Stable Diffusion und Z-Image-Turbo das „irregular arrangement“ nicht beachtet und speziell ein nahtloser Übergang war mit dem Stichwort „seamless“ nur (zumindest ansatzweise) bei GPT-I möglich.

Besonders aufschlussreich waren bei den Modelltests folgende Erkenntnisse:

- *Hintergrund Freistellung*




Abb. 31: Hintergrund Freistellung der verschiedenen Modelle als Übersicht (schwarze Rahmen bei weißem Hintergrund ergänzt, zur besseren Erkennbarkeit des Hintergrundes, sowie Nummern zur Identifizierung: eigene Darstellung, Abbildungen generiert innerhalb obenstehender Modelle).

Bis auf GPT-I konnte keines der getesteten Modelle den Hintergrund freistellen, bei dem dafür genutzten Testprompt: *"Can you generate a tree symbol with a transparent background?"* wurde **entweder ein weißer Hintergrund** erzeugt (siehe Nummer 7, 9, 10) oder ein Hintergrund, der das **Aussehen** eines freigestellten PNG's versuchte **nachzuahmen** (z.B. Nummer 2, 4, 6), aber nicht wirklich transparent war.

- **Ausgabeformat und Qualität**

Keines der getesteten Modelle mit Chatfunktion kann aktuell eine **spezifische Ausgabequalität (Pixelwert)** erzeugen, dieser ist immer einheitlich. Nur bei Z-Image-Turbo ist es mit einem Regler möglich, zumindest begrenzt zwischen 512 und 2048 Pixel für Höhe und Breite einzustellen. Ein **Format**, wie als Prompt: *„generiere ... im 1:1 Format“* wiederum ist bei den getesteten Chatmodellen **kein Problem**.

- **Bearbeitung/ Bezugnahme auf vorher generierten Inhalt**

Bei mehreren Modellen war ein Bezugnehmen auf den vorher erstellten Output **nicht möglich**, zum Beispiel bei Z-Image-Turbo und Seedream wurde der Prompt als neuer Prompt behandelt und nur ein Blatt eines Baumes erstellt. Getestet wurde mittels folgendem Prompt: *"Can you make the leaves look more realistic, don't change anything else."*

- **Trainingsdaten und Urheberrechte**

Diese beiden Informationen waren zum Teil schwierig aufzufinden und wenn, dann wird meist **nicht spezifiziert**, was genau für Trainingsdaten herangezogen wurden. Das einzige getestete Modell, welches angibt, nur Trainingsdaten zu verwenden, an denen die Rechte vorhanden sind, ist Adobe Firefly Image 4.

- **Reproduzierbarkeit**

Die Reproduzierbarkeit wurde mittels des Basisprompts PV01 getestet, es wurden fünf Outputs erzeugt und jeweils in einem neuen Chat generiert. Diese wurden in einzelnen Ordnern gespeichert. Gemessen wurde sie mittels einer „phash“ Methode (**percentual hash**), welche Bilder auf eine Größe anpasst, Graustufen umwandelt und ein Teil des Bildes vergleicht. Unter anderem haben Kim et al. dieses Vorgehen genutzt, um zu testen, wie ähnliche Outputs bei identischem Seed und Prompt erzeugt werden. Im Vergleich zu anderen Ähnlichkeitstests, wird das Rauschen des Bildes nicht verwendet, sondern die Struktur untersucht (Buchner, 2013/2026; Kim et al., 2024). Fünf Outputs sind als repräsentatives Ergebnis wenig Outputs, es wurde sich dafür aber vor allem entschieden, um **Modelle auszuschließen, die komplett unterschiedliche Ergebnisse lieferten** und unvorhersehbar sind.

Eine Besonderheit wurde bei Seedream festgestellt, das Modell wurde über „seedream.pro“ abgerufen, eine Seite, die das Modell kostenfrei und einfach abrufbar zur Verfügung gestellt hat. Bei den Testungen zur Reproduzierbarkeit, hat das Modell auffällig identische Outputs erzeugt, obwohl nicht mal eine Anmeldung nötig war. Es wurden verschiedene Browser und PCs getestet und es kam **mit dem Basisprompt immer das komplett identische Bild** raus.

Deshalb ist die Hypothese entstanden, dass diese spezielle Website nur ein neues Bild generiert, wenn der Prompt neu ist. Scheinbar werden die Prompts (zumindest kurzzeitig) gespeichert und wenn der identische Prompt abgefragt wird, wird ein bereits früher generiertes Bild ausgegeben. Nach einem Tag wurde beim ersten Test ein neuer Output generiert, ab dann war der Output wieder identisch. Eine Vermutung wäre, dass darüber




Abb. 32: Seedream Katzenoutputs in verschiedenen Browsern (Bilder generiert mittels Seedream, eigene Darstellung).

Rechenkosten gespart werden. Eine weitere Erklärung wäre ein festgelegter Seed, der ist bei der Website **nicht spezifisch angebbbar** oder einsehbar. Nachdem es über den Reproduzierbarkeitstest aufgefallen ist, wurde eine alternative Website verwendet (*Seedream 5.0 Lite Official API | Start for free*, o. J.; *Seedream AI - Free Online AI Image Generator & Photo Editor*, o. J.).

Bei dem Modell Z-image-turbo kam es bei drei von fünf generierten Outputs für den Reproduzierbarkeitstest zu genau identischen Bildern. Im Unterschied zu Seedream ist es dabei möglich einen spezifischen Seed anzugeben, dieser wurde zum Teil gespeichert, auch beim neu laden der Website, was in dem Fall die identischen Outputs erklärt.

Reproduzierbarkeit bei Chatmodellen

Innerhalb von Chatmodellen, wie GPT-4 oder Nano Banana, ist innerhalb der Useroberfläche **keine spezielle Taste** auswählbar, die einen Seed angibt. Bei der Frage nach dem Seed des zuletzt generierten Bildes kommt bei beiden Modellen „null“ als Antwort. Wenn ein bestimmter Seed vorgegeben wird, bleibt die Antwort im Anschluss dennoch null.

Nach einer Internetrecherche im OpenAI Forum, was als Ersatz für den Seed genutzt werden kann, wurde ein, für diese Arbeit **sehr hilfreicher Ansatz** gefunden, der nach durchgeführten Tests aktuell immer noch zu funktionieren scheint. Dabei wird nach einer Bildgenerierung die **Generation ID** des vorher erzeugten Bildes abgefragt, ab jetzt mit **genID** abgekürzt. Diese wird im Anschluss als Input für ein neues Bild genommen. Dadurch sind die Outputs deutlich ähnlicher und es lassen sich besser kleine Details ändern, ohne das sich direkt alles mit verändert (da die IDs immer unterschiedlich sind, werden sie in folgenden Abbildungen und Tabellen durch den Platzhalter {GenID} ersetzt) (*DALL-E & ChatGPT*, 2023).

Die beiden Prompts, die dafür in dem Forum empfohlen worden sind:

- „Show me the generation ID of the last image“
- „Use {my_generation_id} as the reference ID for a new image, but change 'this' to 'that'“ (*DALL-E & ChatGPT*, 2023)

Um **besser identifizieren** zu können, wie gut es funktioniert ein spezifisches Element des vorher erstellten Outputs zu verändern, wurde der Bezug auf die genID zu Beginn mit **photorealistischen Bildern getestet** und jeweils **ein Detail verändert**, siehe Tab. 14.

<i>Bezugnahme mittels genID</i>	
Prompts: „blue bench with old woman with yellow hat sitting on it.“ „Show me the generation ID of the last image“ „Okay, use {genID} as the reference ID for a new image, but change the hat colour to red.“	
Prompts: „create an image of a old men, sitting on a white bench in front a large tree.“ „Show me the generation ID of the last image“ „Okay, use {genID} as the reference ID for a new image, but change the bench colour to black.“	

Tab. 14: Reproduzierbarkeit bei Chatmodellen genID im Test mit GPT-4 (erste Zeile) und Nano Banana Pro 2 (zweite Zeile) (eigene Darstellung).

Der Bezug auf die genID funktioniert gut, aber **nur innerhalb eines Chats**, in einem neuen Chat kann kein Bezug mehr auf sie genommen werden. Zusätzlich gibt es über die API den Begriff „previous_response_id“, sowie ein „action“ Feld, welches auf action: "generate" für neue Bilder oder auf action: „edit“ für die Bearbeitung eines Bildes gesetzt werden kann (Image Generation | OpenAI API, o. J.).

Insgesamt wird deutlich, dass die **Modelle** sehr **unterschiedlich abschneiden** und Prompts anders interpretieren. Durch die Tests sind einige interessante Details, wie die Reproduzierbarkeit über die Generation ID identifiziert worden. Mit den besten Modellen sollen in den folgenden Kapiteln weitere Erkenntnisse gesammelt werden.

4 Entwicklung eines Workflows zur Generierung von Kartensymbolen und Mustern in Multi-Scale-Karten

In den folgenden Kapiteln soll der Workflow für eine KI-Generierung von Mustern und Symbolen entwickelt werden. Dafür werden die auf die Erkenntnisse des Theorieteils, dem geplanten Vorgehen des Methodik Kapitel, sowie den Modelltests zurückgegriffen. Es wird die *Testumgebung*, anhand der im vorherigen Kapitel (3.3) festgelegten Kriterien erstellt. Im Anschluss werden anhand des Theorieteils die *wichtigsten Multi-Scale-Aspekte* festgehalten und definiert, wie diese mittels der KI-Modelle umgesetzt werden können. Darauf folgt *der Prozess der Symbol- und Mustergenerierung*.

Zu Beginn wurden *fünf Hypothesen* aufgestellt, inwieweit die KI hilfreich sein könnte, diese sollen zusätzlich dabei helfen, die Forschungsfrage zu beantworten, spezieller welche generativen KI-Methoden es gibt, die für Multi-Scale-Karten von Relevanz sein können. Die Hypothesen lauten wie folgt:

- I. KI kann helfen ein Symbol oder Muster schnell an *verschiedene Maßstabsstufen* anzupassen.
 - i. KI kann für die Symbol- und Mustererstellung bei Maßstabsübergängen hilfreich sein, wenn *zuerst die detailliertere Version* generiert wird und daraus abgeleitet *generalisierte Versionen* für verschiedene Maßstäbe.
 - ii. Wenn ein generiertes *Muster als Input* gegeben wird, können daraus passende *Symbole für den Übergang* generiert werden und andersherum.
- II. Wenn für einen bestimmten Maßstab bereits Symbole und Muster vorhanden sind, kann KI dabei helfen schnell *für andere Maßstäbe Zeichenschlüssel* zu generieren.
- III. Wenn ein Muster oder Symbol in einem *bestimmten Stil* erzeugt wurden, kann die KI diesen *auf andere übertragen*.

Sie sollen innerhalb der nächsten Tests geprüft werden und innerhalb von Kapitel 5.3 beantwortet werden.

4.1 Erstellung der Multi-Scale-Testumgebung sowie dafür nötige Datenaufbereitung

Für die Testumgebung wurde eine **Basisvorlage von MapLibre** verwendet und mithilfe von Claude AI und Codex (für die Skripte) eine **webbasierte Anwendung** (html) aufgebaut, um die generierten Symbole und Muster möglichst praktikabel testen zu können ((Claude, o. J.; CLI – Codex | OpenAI Developers, o. J.).

MapLibre GL JS wurde als Kartenbibliothek verwendet, sowie **Vektorstyles von OpenFreeMap**. Im Laufe der Tests haben sich **drei verschiedene Basiskarten** als hilfreich herausgestellt, darunter von OpenFreeMap „Liberty“ (siehe Abb. 33, Bild 1), eine graue Karte, damit Symbole und Muster deutlich sichtbar sind namens „Positron“ (Bild 2), sowie eine Version der Liberty Karte (Bild 3) namens OSM-Bright (Bild 4), die in höheren Zoomstufen eine simplere Darstellung hat, was für eingebundene Symbole als Basis praktisch ist. Um die Testumgebung starten zu können, gibt es zusätzlich eine **Python Datei, als lokalen Server** (Ero, 2023/2026; *OpenFreeMap Quick Start Guide*, o. J.; *OSM Bright*, o. J.; *Style Specifications - MapLibre GL JS*, o. J.).




Abb. 33: Basiskarten der Testumgebung, OpenFreeMap Liberty (1) und OpenFreeMap Positron (2), sowie OpenFreeMap Liberty im Detailvergleich (3) mit OSM-Bright (4), eigene Darstellung (Ero, 2023/2026).

Zentriert ist die Karte auf Innsbruck, da es dort zum einen wegen des städtischen Gebietes viele **urbane Symbole** zum Testen gibt, sowie in direkter Nähe zur Stadt Waldflächen sowie Bäume. Es wurde **zusätzlich Wien als Standort** im Laufe der Tests genutzt, da sich der **Stadtpark** in Bezug auf Kapitel 1.1 als praktisches Testgebiet für die **Mischung aus urbanen und ländlichen Symbolen und Mustern** herausgestellt hat. Die **Testumgebung** (siehe Abb. 34) wurde im Laufe der Arbeit **schrittweise erweitert** und angepasst, von einer einfachen Anzeige erstellter Symbole und Muster, zu einem Werkzeug, um möglichst viele Aspekte innerhalb einer Oberfläche testen zu können.

Zur besseren Erklärung der Oberfläche wurde sie in sieben Nummern bzw. Elemente eingeteilt (Abb. 34). Bei **Punkt 1** kann einer der oben beschriebenen **Basiskarten ausgewählt** und geladen werden.

Mit KI erstellte Symbole und Muster können **per Drag und Drop** innerhalb eines „Icon-Pools“ abgelegt werden (2). Die einzelnen Symbole und Muster je Zoomstufe können dann ebenfalls per Drag and Drop innerhalb einer Symbol- oder Mustergruppe einer von drei Zoomstufen hinzugefügt werden (3). Innerhalb dieses Blockes kann **eine Pixelgröße definiert** werden, sowie wann die jeweiligen Symbole/ Muster ein- und ausgeblendet werden sollen. Bei Mustern ist der Ablauf identisch, es wird nur „pattern“ anstatt „symbol“ gewählt. Es gibt die **Möglichkeit der Interpolation**, dabei kann eingestellt werden, dass die Größe des Symbols über die **Mindest- und Maxzoomstufe** interpolieren soll, dadurch wird das Symbol mit jedem Zoom kontinuierlich größer, bis zu dem eingestellten höchsten Wert (*interpolate*, o. J.). Das hat sich speziell bei den Übergängen von einem, zu einem Symbol für eine niedrige Zoomstufe, zu einem Symbol für eine hohe als praktisch herausgestellt, damit der **Übergang möglichst dynamisch** und nicht sprunghaft ist. Zusätzlich wurde im späteren Verlauf der Arbeit die Möglichkeit ergänzt eine **Transparenz (von 0 bis 1)** einzustellen, sowie im „Icon Pool“ **Farben** der Symbole und Muster **anzupassen**, um testen zu können, welche Farben innerhalb der Umgebung gut harmonisieren.




Abb. 34: Testumgebung mit ergänzten Nummern und Rahmen zur besseren Beschreibung der Elemente, eigene Darstellung, erstellt mithilfe von Claude und Codex (Claude, o. J.; CLI – Codex | OpenAI Developers, o. J.).

Es wurde früh eine **Zoom Anzeige** eingebaut, die die jeweiligen Zoomlevel anzeigt, um die Übergänge besser testen zu können (4). Zusätzlich können die bereits vorhandenen Symbole und Muster innerhalb der Basiskarte angeklickt werden, um Infos zu der Symbol- oder Musterklasse zu erhalten (class/ subclass) (5). Dieser „Inspector“ kann oben rechts (6) aktiviert und deaktiviert werden. Zusätzlich können die Basissymbole (Basemap Symbols)

und Musterflächen (Basemap Areas) der Basiskarte ausgeblendet werden (z.B. um sie durch eigene zu ersetzen).

Wenn Symbole und Muster definiert wurden, kann innerhalb von **Punkt 7** anhand der festgelegten Parameter (Pixelgrößen, Zoomstufen, Interpolation, Ein und Ausblendungen) **automatisch eine Sprite Datei mit dazugehörigem JSON** (wie in Kapitel 3.3 vorgestellt) erstellt werden.

SVG's als Input für ein Sprite zu nehmen, ist die **herkömmliche Variante**, die sich bisher als Output von **klassischen Vektorprogrammen** bei der Symbolgenerierung durchgesetzt hat. Die Vektorsymbole werden in ein Raster umgewandelt und im Anschluss in das Spritefile eingebettet. Deshalb wurde zu Beginn ein Workflow (siehe Anhang 02) entwickelt, welcher die PNG's vektorisiert, weiße Pfade entfernt und als SVG's auf die richtige Größe skaliert, bevor sie mit einem klassischen Tool in ein Sprite umgewandelt werden konnten. Nachdem das **Vektorisieren und Skalieren** mit diesem Vorgehen zwar gut funktioniert hat, aber dennoch zwei Extraschritte dadurch entstanden und der Output abweichen kann durch den Vektorisierungsprozess, wurde nach **alternativen Methoden** als die SVG-Variante gesucht.

Im Unterschied zu dem „klassischen“ Vorgehen erzeugen die **getesteten KI-Modelle Raster anstatt Vektorbilder**, die somit für die Spritedatei direkt brauchbar sind. Über GitHub wurde dafür ein Tool gefunden, welches **statt SVG's, PNG's als Input** für die Sprite Datei verwendet, welches eine große Verbesserung zu dem vorherigen Skript darstellt (*GitHub - stevage/mbsprite: Command line utilities for exploding/bundling Mapbox GL spritesheets · GitHub*, o. J.).

Da in den **Basiskarten Baumsymbole nicht als Vektordaten integriert** waren, wurden sie durch eine **lokale GeoJSON-Quelle ergänzt**. Dafür wurden von **Overpass Turbo**, einmal für die Region Innsbruck und einmal für den Bereich Wiener Stadtpark Baumsymbole extrahiert. Das identische Vorgehen wurde zudem für Bänke verwendet und für den Umkreis um den Stadtpark Wien heruntergeladen (*Overpass Turbo*, o. J.; *Sources - MapLibre Style Spec*, o. J.).




Abb. 35: Testumgebung - Line Pattern Funktion für den Randbereich von musterhaften Flächen (eigener Screenshot und Darstellung, Oberfläche erstellt mithilfe von Claude und Codex)).

Zusätzlich wurde im Laufe der Test ein **Linienmuster** („Line_Pattern“) auswählbar gemacht, es ist eine Style Möglichkeit von MapLibre und kann dabei helfen den Übergang von Mustern zu gestalten (siehe Abb. 35).

Anstatt ein Muster dort einzubetten, eignet es sich ebenfalls gut einzelne Symbole, zum Beispiel **Bäume** zu verwenden, die den **Rand eines Waldsymbols** überbrücken. Es kann **Transparent von 0 bis 1** eingestellt werden, sowie die Größe der Linie und der Abstand der einzelnen Symbole festgelegt werden. Im Prozess der weiteren Tests wurde mit der Hilfe von Claude KI ein **Vorbereitungsskript** namens „**png_cutter**“ erstellt, welches **aus einem**



Abb. 36: Generiertes PNG mit drei Zoomstufen (links) und daraus mittels „png_cutter“-Skript extrahierte einzelne PNG's (rechts), Symbole generiert mit GPT-1, eigene Darstellung.

PNG einzelne Symbole und Muster extrahieren und in jeweils neue, individuelle PNGs schreiben kann (Claude, o. J.). Was hilfreich sein kann, wenn mehrere Symbole oder Muster mit unterschiedlichem Detailgrad innerhalb eines Outputs (PNG's) von der KI generiert werden.

Dafür wird der Hintergrund des Bildes in eine Schwarz-Weiß-Maske umgewandelt und in die **flächenmäßig größten Bereiche** aufgeteilt (mittels Bounding Box), sowie der **Hintergrund entfernt**, falls es das Modell nicht schon gemacht hat. Im Anschluss können für die extrahierten Symbole Namen vergeben werden, bevor sie gespeichert werden. Diese können dann hintereinander in die Testumgebung eingeblendet werden (siehe Abb. 36). Zusätzlich können **Muster über einen Überlappungswert nahtlos** gemacht werden (basierend auf einem Github Tool), falls ein KI-Modell den Schritt nicht sauber ausgeführt hat (IG, 2021/2026).

Die erstellte Multi-Scale-Testumgebung ermöglicht **die direkte Visualisierung der Zoomlevel** innerhalb einer Webkarte. Outputs können im Verhältnis zueinander betrachtet, Lesbarkeit, Qualität, Farben und Übergänge überprüft werden.

4.2 Integration von Multi-Scale-Aspekten

Um **Maßstabsübergänge und die damit verbundenen Veränderungen** zu definieren, wird das Scale-Master-Diagramm von Roth et al. herangezogen (vorgestellt in Kapitel 2.5 „Herausforderungen und Anwendung von Multi-Scale-Darstellungen“).

Diese sollen **Teil eines Prompts** werden, welcher entweder ein vorher erstelltes Grundsymbol verändert, je nach Maßstabsstufen oder direkt Symbole und Muster für verschiedene Zoomstufen generiert.

Wie bereits in Kapitel 2.5.1 angeschnitten, werden innerhalb des MasterScale-Diagramms mittels verschiedener Operatoren das **Erscheinen und Anpassen verschiedener Kartenelemente über Maßstabsstufen hinweg definiert**. Es gibt eine extra Kategorie für Symbole, aber keine speziell für Muster, diese werden als eine Unterkategorie bei den Mustern aufgelistet und heißen dabei: „**Adjust Pattern**“. Um die Anforderungen an ein Muster detaillierter im Vorneherein für die generative KI aufbereiten zu können wird Roth's Ansatz um eine **Extrakategorie für Muster erweitert**.

In Abb. 37 ist die „**Symbol**“-Kategorie und die „**Content**“-Kategorie von Roth et al. aufgelistet und **um die Musterkategorie („Pattern“) erweitert**. Der Einheitlichkeit halber wurde der Buchstabe „P“ (für Pattern) als Abkürzung für die verschiedenen Musteroperatoren verwendet. Diese basieren auf den Erkenntnissen von Kapitel 2.1.2 und 2.1.4, bei dem ausgehend auf den sechs Variablen von Bertin, noch zwei weitere dazugekommen sind: „**Anordnung/ Arrangemen“t (Pa)**, die zum Beispiel regelmäßig oder unregelmäßig sein kann und „**Texture**“ (**Px**), die die Feinheit und Körnung einer Fläche beschreibt. Die Variablen von Bertin sind ebenfalls jeweils ein Operator für das Muster, es sind fünf anstatt der sechs Variablen, da das Muster selbst eine Variable von Bertin ist und dadurch nicht noch extra aufgelistet ist. Bertins Variable Form ist mit „**Adjust Shape**“ inkludiert (**Ps**), die Orientierung mit „**Rotate**“ und „**Orientation**“ (**Pr**), die Farbe mit „**Adjust Colour/ Hue**“ (**Pc**), die Helligkeit mit „**Transparency**“ (**Pt**) und die Größe mittels „**Adjust Size**“ (**Pz**) (R. E. Roth et al., 2011; White, 2017).

Symbol		Pattern (adaptiert)		Content	
Sc	Adjust Color	Pa	Adjust Arrangement	C+	Add
Se	Enhance	Px	Adjust Texture	C-	Eliminate
Si	Adjust Iconicity	Pc	Adjust Color/Hue	Cc	Reclassify
(Sp)	Adjust Pattern	Ps	Adjust Shape	Co	Reorder
Sr	Rotate	Pz	Adjust Size		
Ss	Adjust Shape	Pr	Rotate / Orientation		
Sz	Adjust Size	Pt	Adjust Transparency		
St	Adjust Transparency				
Sf	Typify				

Abb. 37: Multi-Scale-Operatoren die für den gewählten Workflow von Interesse sind (adaptiert und erweitert um Muster („Pattern“) eigene Darstellung nach (R. E. Roth et al., 2011).

Damit sich Symbole und Muster zwischen Maßstabsstufen nicht so stark verändern, dass sie nicht wiedererkannt werden, soll **Stilkohärenz** vorhanden sein. Dafür sollen Symbole und Muster farblich und ihrer Objektart nach, stufenweise angepasst werden (siehe Kapitel 2.5.2) und eine konsistente Symbolik erzeugt werden (Brewer, 1999; Dumont et al., 2020). Speziell in Bezug auf Kapitel 2.5.1 ist der **decision point**, wann ein Symbol oder Muster sich durch Maßstabsveränderungen verändern soll, wichtig (R. E. Roth et al., 2011). Die KI sollte deshalb nicht nur ein Symbol erstellen, sondern am besten mehrere, die von einer sehr einfachen Darstellung in einer detaillierte übergehen und dadurch in verschiedenen Maßstäben eingesetzt werden können.

Bevor die Aspekte und Kriterien von Multi-Scale-Karten innerhalb der KI-Umgebung getestet werden, sind basierend auf dem Theorieteil in Tabelle Tab. 15 die wichtigsten Punkte festgehalten.

<i>Römische Nummer für folgende Kapitelgliederung</i>	<i>Multi-Scale-Aspekt/ Herausforderung</i>	<i>AutorInnen</i>	<i>Geplante Umsetzung auf Basis des Theoriteils</i>
<i>I.</i>	Stilkohärenz	Brewer, 1999; Dumont et al., 2020	harmonische Farben, konsistente Symbolik, einheitliche Größe der Symbole und Musterelemente.
<i>II.</i>	Decision point	R.E: Roth et al., 2011	Mehrere Symbole/ Muster erzeugen lassen, die ineinander übergehen sollen von einfach zu detailliert.
<i>III.</i>	Ankerpunkte	Dumont et al., 2020	Flächen und Muster, die thematisch und speziell in der Karte nah beieinander liegen, nicht gleichzeitig neu ein- und ausblenden (siehe decision point), damit nicht zu viel Veränderung auf einmal passiert.
<i>IV.</i>	Desert fog effect	Fabrikant et al., 2012 Dumont et al., 2016	Desert fog effect kann durch die gemischten Abstraktionsvorgänge besser vermieden werden (siehe Kapitel 2.2.2). Zudem sollte ein Symbol/ Muster nicht zu stark verändert werden, damit es wiedererkannt werden kann.
<i>V.</i>	LoD	Brewer & Buttenfield, 2010; Dumont et al., 2020	Verschiedene Detailstufen sollen innerhalb von Prompts definiert werden, die als Input für die Bildgenerierung dienen sollen.


Tab. 15: Auflistung der Multi-Scale-Aspekte/ Herausforderungen und wie sie geplant werden umzusetzen, für möglichst funktionale und affektive Ergebnisse (eigene Darstellung).

Nachdem sich in Kapitel 3.3 zwei Modelle durchgesetzt haben, wurden diese noch spezifischer und detaillierter getestet. Für GPT-I wurde sich ein *einmonatiges Probeabo* geholt, um keine Limits bei der Bildgenerierung zu haben. Da GPT-I das *Chatmodell* der beiden bestabgeschlossenen Modelle ist und damit mehr Experimente mit Prompts und Bildinputs ermöglicht, wurde damit gestartet, um die Ergebnisse dann bestenfalls auf die anderen beiden Modelle übertragen zu können. Zu Beginn wurden viele einzelne Elemente getestet, um das Modell besser kennenzulernen und praktische Elemente rauszufinden.

I. Stilkohärenz - Feste Farbdefinitionen

Ein weiterer Punkt, der wichtig wäre, um einheitliche Symbole und Muster für eine Karte zu erstellen, ist die Möglichkeit einen speziellen Farbewert anzugeben. Dafür wurden einmal *hexcodes* und einmal *hsl Farbwerte* vorgegeben und auffälliger, in dem Fall nicht intuitive bunte Farben gewählt, um deutlichere Ergebnisse zu haben, sowie herauszufinden,

ob die KI trotz zwei eher widersprüchlichen Anforderungen (Wald und dazu nicht passende Farbe) einen Output, der den Kriterien entspricht, erzeugt.

Prompt	Farbton	Generierter Output	
reference Image (Bildvorlage ohne spezifische Farbangabe)			
„use {genID} as a reference id for a new image: make the colour #b4a7d6“			
„use {genID} as a reference id for a new image: make the colour hsl(190 100% 79%)“			

Tab. 16: Übersicht über definierte Farben als Input, generiert mit GPT-I (linker Output), sowie Stable Diffusion (rechter Output, nur mit Farbangabe ohne Vorlage), eigene Darstellung.

Bei GPT-I scheinen hexcodes und hsl Farbwerte als Input möglich, wie in Tab. 16 dargestellt. Bei Stable Diffusion funktionieren hexcodes, hsl hat zu einer komplett anderen Farbauswahl geführt.

Stilkohärenz - Muster nahtlos/ seamless generieren für spätere Kachelung

Da Muster in der späteren Multi-Scale-Karte **durch Kachelung gleichmäßig Flächen ausfüllen** sollen, ist es wichtig, dass die Muster an allen Seiten nahtlos aneinandergereiht werden können. In dem Python Skript, welches nach der Generierung die Symbole und Muster für die Testumgebung aufbereitet, ist eine Funktion für das nahtlos machen von Mustern bereits eingefügt worden, weil bei den Modelltests dieser Punkt oft nicht fehlerfrei funktioniert hat.

Innerhalb von GPT-I wurden nochmal speziell Sätze und Stichwörter getestet, um ein besseres Ergebnis zu bekommen. Mit dem Prompt: „use {genID} as a reference id for a new image: but make it a seamless tiling.“ hat das nahtlose Übergehen des Musters horizontal gut funktioniert, jedoch gab es vertikal fehlerhafte Ergebnisse. Der Prompt: „use {reference ID} as a reference id for a new image: but make it a seamless tiling in every directions“. hat die wenigsten fehlerhaften Ergebnisse erzeugt. „The pattern should be reusable when used side by side“ hat ebenfalls gut funktioniert. Auf der OpenAI Plattform, gab es verschiedene Prompts zur Auswahl und einen mit dem Namen „Pattern set“, der bei

mehreren Outputs fehlerfreie Ergebnisse geliefert hat (*Images Playground - OpenAI API*, o. J.).





Abb. 38: Nahtloses Muster generieren mittels GPT-I mittels Prompt: „seamless tiling in every direction“ (generiert mit GPT-I, eigene Darstellung) in Rot Fehler beim Aneinanderreihen der Kacheln)

Mit dem Prompt waren die Ergebnisse deutlich besser, aber nicht perfekt, weshalb aktuell das Auslagern dieses Schrittes auf nach der Generierung eine sicherere Variante ist.

Stilkohärenz - Luftbild als Input (für realistischere, naturnähere Ergebnisse):

Für einen realistischeren Stil und damit die KI die ***Ansicht von oben*** besser umsetzen kann, wurde als eine Variante ein Luftbild als Input für ein Waldmuster gegeben (siehe Tab. 17).

<i>Luftbild als Input</i>			
Input für Muster			
Prompt: „attached a screenshot from a aerial image of a dense forrest taken from an airplane. I want you to create the pattern based on this image, but much more schematic and simplified. It should convey a realistic sense of the landscape as displayed in a topographic map or video game.“			
			


Tab. 17: Google Maps Luftbildausschnitt als Input (Zeile 1) und der Output (Zeile 2), generiert mit GPT-I (Mitte) und Stable Diffusion (rechts), eigene Darstellung.

Diese getesteten Ansätze und Stichworte funktionieren relativ konsistent, dennoch kann es bei ***einzelnen Generierungen trotzdem Probleme*** geben. Am besten hat dabei ein neuer Chat geholfen, in dem der erstellte Output nochmal neu reingeladen wurde.

II. Decision Point - Muster zu Symbolen und Symbole zu Muster

Bei einzelnen Baumsymbolen im Zusammenhang mit Waldflächen ist es speziell interessant, den Decision Point ***zwischen der Fläche und den einzelnen Bäumen*** im direkten Umfeld der Fläche zu finden und dabei die Stilkohärenz zu beachten.

Um Hypothese V (Kapitel 4) zu testen, wurde zum einen ein Symbol als Input für ein Muster getestet, sowie ein Muster als Input für ein Symbol. Ein Testergebnis ist in Tab. 18 dargestellt, dabei wird deutlich, dass beides gut funktioniert.

Muster und Symbol Transformationen im Test		
Symbol zu Muster Prompt: „can you generate a {forrest pattern} from the input image.“		
Muster zu Symbol Prompt: „can you generate a single {tree symbo} from the input image with transparent background, don't add new details.“		

Tab. 18: Symbol zu Muster (Zeile 1) und Muster zu Symbol (Zeile 2), (generiert mit GPT-I, eigene Darstellung).

Von Muster zu Symbol ist der Detailgrad ungewollt erhöht worden, deshalb ist die Variante: **zuerst das Symbol und dann das Muster** eventuell praktischer, wenn beides von Null generiert werden soll.

III. Ankerpunkte – Stichworte, die einheitlichere Ergebnisse liefert

Damit die generierten Ergebnisse über Zoomstufen hinweg erkennbar bleiben, werden **Stichwörter für möglichst generische Outputs** getestet (siehe Tab. 19). Dabei haben die Vorgaben, mit generischen, selbsterklärenden und einheitlichen Farben zu guten Ergebnissen geführt.

Generisch als Stichwort	
Prompt: „Generate two different tree symbols, one with less and one with more details. The symbols should be self-explanatory and generic map icons with the same colours.“	
	

Tab. 19: Möglichst generische, selbsterklärende Ergebnisse generieren mittels GPT-I (oben) und Stable Diffusion (unten), eigene Darstellung.

Abgesehen von einzelnen Symbolen und Mustern, die beim Übergang konsistent sein sollten, soll im späteren Verlauf noch getestet werden, wie es Symbol- und Musterübergreifend über verschiedene Attribute umgesetzt werden kann. Konsistentere Ergebnisse könnte es geben, wenn sich die **Außengrenze der Symbole** nicht zu stark ändert.

IV. Desert fog effect vermeiden - Zusätzliche unerwünschte Details entfernen

Damit speziell bei Symbolen keine ungewünschten Elemente außerhalb des eigentlichen Symbols integriert werden, wurde getestet, mit welchem Prompt sich diese schnell entfernen lassen.

Unnötige Elemente aus Outputs entfernen

Prompt: „Remove everything that isn't the tree in the picture and replace it with white.“



Tab. 20: Nicht gewünschte Details aus Output entfernen bzw. ersetzen (generiert mit GPT-I, eigene Darstellung).

Dabei hat sich schnell der in Tab. 20 gezeigte Prompt als hilfreich ergeben, vor allem wenn die Objekte gut vom Rest zu trennen sind und der Hintergrund für die spätere Weiterverarbeitung sowieso weiß sein soll, transparent funktioniert bei GPT-I ebenfalls.

V. LoD - Vereinfachen/ Generalisieren von Darstellungen:

Dafür wurde getestet, welche Stichworte/ Keywords sich gut zum Vereinfachen von Outputs eignen. In Tab. 21 Abb. 21 ist der Prompt festgehalten, der gut funktioniert hat. In dem Fall eine Reduzierung der Details und ein minimalistischer Output.

Vereinfachen, Details entfernen

Prompt: „Can you generate a new image with transparent background but reduce the detail to a minimalistic version.“



Tab. 21: Vereinfachen von Outputs (generiert mit GPT-I, eigene Darstellung).

Insgesamt haben sich über die Tests einige hilfreiche Prompt-Aspekte ergeben, die dabei helfen können, Symbole und Muster zu bearbeiten und Herausforderungen von Multi-Scale-Karten damit entgegenzuwirken. Auffällig ist, dass GPT-I einen **ähnlichen Stil** erzeugt, der eher **intensivere Farben** verwendet. Den Grad zu finden, zwischen einer vereinfachten und generalisierten Darstellung als Prompt Bausteine und einem Output, der nicht zu sehr einem Comic Stil entspricht, wird ein Fokus des folgenden Kapitels.

4.3 Prozess der Symbolgenerierung und Mustererstellung

Im Zuge der Modelltests, sowie für die Maßstabskriterien wurden viele verschiedene Varianten von Prompts, speziell bezogen auf Bäume und Wälder als Basis getestet. Die **Kriterien für Maßstabsübergänge**, sowie **Multi-Scale-Aspekte** lassen sich ebenfalls **auf andere Kartensymbole und Muster übertragen**.

Es versucht einen Prompt zu finden, der sich **universeller für eine Symbol- und Mustergenerierung einsetzen lässt** und auf andere Attribute übertragen werden kann. Dabei soll ein Symbol mit höherer Zoomstufe (mehr Platz) immer mehr Details enthalten und größer werden. Einen universellen Prompt zu finden, der für jede Art von Symbol oder Muster geeignet ist, gestaltet sich als schwierig durch jeweils Symbol- und Musterspezifische Anforderungen, jedoch ist das Ziel den übergeordneten Prompts so zu gestalten, dass möglichst wenige Variablen im Prompt verändert werden müssen für ein gutes Ergebnis, mit dem in der Folge weitergearbeitet werden kann.

Einen **deutlichen Fortschritt der Ergebnisse** gab es, als innerhalb von GPT-I ein „sprite sheet“ als Stichwort verwendet wurde und direkt mehrere Symbole für verschiedene Maßstäbe **innerhalb eines Bildes** damit erzeugt wurden. Dadurch dass es mehrere Zoomstufen/ Detailunterschiede innerhalb des Bildes gibt, scheinen Übergänge zwischen den einzelnen Symbolen deutlich besser zu funktionieren. In Bezug auf Kapitel 2.3.1 scheinen MLLMs durch ihr trainiertes Wissen einordnen zu können, wie eine Sprite Datei zumindest grob aussehen sollte.

Damit ein Übergang von einer Zoomstufe zur nächsten Zoomstufe möglichst gut umgesetzt wird, wurden drei verschiedene Symbole bzw. Zoomstufen für das Bild definiert. Diese sollen später innerhalb einer Multi-Scale-Karte **ineinander übergehen**.

- Das **erste Symbol** soll dabei für eine **niedrige Zoomstufe** sein und wenig Details enthalten.
- Das **zweite Symbol** soll etwas mehr Details haben und größer als das Erste sein, weil es später in der Karte mittels der Pixel größer dargestellt und deshalb die Qualität durch die Größe verbessert werden soll.
- Das **dritte Symbol** soll das detaillierteste sein, für eine **hohe Zoomstufe** mit mehr Platz.

Die Basis des Prompts beruht auf den in Kapitel 3.2 festgehaltenen Promptbausteinen in Kombination mit den MasterScale Operatoren (Kapitel 4.2). Nur in dem Unterschied, dass die Symbole **von wenig detailliert (links) zu detailliert (rechts) übergehen**, da digitale Multi-Scale-Karten diesen zusätzlichen Platz bieten. Die verschiedenen Beschreibungen der Symbole wurden nach und nach angepasst, aber können spezifiziert werden, wenn ein ganz spezieller Output generiert werden soll. In Tab. 22 sind die jeweiligen Promptbausteine aufgelistet mit dem jeweils gewählten Prompt, sowie den dazugehörigen MasterScale-Operatoren und einer Erklärung, wieso sich spezielle für die jeweilige Variante entschieden wurde.

Prompt Baustein	Prompt	MasterScale Operatoren	Erklärung
Pre-Prompt	Create a professional cartography sprite sheet, three variations of a {symbol} symbol for different zoom levels.	C+ Add	"cartography sprite sheet" hat die Übergänge der Symbole deutlich besser gemacht als einzelne Symbolprompts hintereinander.
Subjekt	[Left]: ultra minimalist flat icon, show recognizable form. No details, one colour. [Center]: stylized flat vector, with a little more details, dont add details of the surroundings. [Right]: more detailed symbol with shading.	Si Adjust iconicity	Das Subjekt ist das Symbol in der Variable beim Pre-Prompt. Zusätzlich sind die 3 einzelnen Symbole möglichst universell für verschiedene Attribute beschrieben.
Style Modifier/ Style Keywords	All three symbols should have clean lines, consistent {(colour)} colour palette, flat design. {Transparent} background. Be self-explanatory and generic map icons, dont make large outline changes.	Sc Adjust Colour St Adjust Transparency	Als weitere Variable wurde die Farbe angegeben, sowie transparenter Hintergrund, was GPT-I umsetzen kann, für andere Modelle, ist wie bereits in Kapitel 3.2 festgelegt, weiß sinnvoller. Ankerpunkte könnte es durch wenig Änderungen an der Außenform geben.
Quality Modifier	Use the same style and colours, but increase in detail so if they are later put above each other there should be a smooth transition between the unique symbols.	Se Enhance	Der Stil soll übergreifend identisch bleiben, die Farben ebenfalls, damit die Symbole über Zoomstufen hinweg detaillierter eingeblendet werden, ohne dass sich das Symbol so stark verändert, dass es nicht mehr wiedererkannt wird.
Gewichtung (DF-Ansatz)	Important: size ratio should be 1, 1.5, 2.25	Sz Adjust size	Größe wird später bei Integration ins Spritefile zusätzlich angepasst, aber die Qualität soll bei hohen Zoomstufen besser sein, deshalb die Größenunterschiede schon im Prompt integriert.
Negativprompt	No text.		Innerhalb der einzelnen Symbolbeschreibungen integriert, wenn etwas Spezielles nicht vorhanden sein sollte, kann es hier am Ende nochmal hervorgehoben werden.

Tab. 22: Übersicht des erstellten übergeordneten Prompts für Symbole mit verwendeten Prompt Bausteinen, MasterScale Operatoren und Erklärung (eigene Darstellung).

Zu Beginn wurde bei der Beschreibung keine Größe dazugeschrieben wie oben bereits geschrieben, soll *das detaillierteste Symbol am Ende in der Multi-Scale-Karte mit mehr Pixeln* dargestellt werden, weshalb eine höhere Qualität und Pixelgröße dabei wichtiger ist und deshalb das *detaillierteste Symbol am meisten Platz* von den drei einnehmen sollte.

Als weiterer Versuch wurde es jeweils bei den einzelnen Symbolen dazugeschrieben („make the symbol half the size of the left symbol“), was aber nicht so gut funktioniert hat und den Prompt noch länger gemacht hat (siehe Tab. 22, Zeile 1). Deshalb wurde eine **ratio, bzw. ein Verhältnis** am Ende angegeben, die besseren Ergebnisse erzielt hat, dabei wurde das Symbol immer um die Hälfte des vorherigen vergrößert, um mehr Platz für Details zu haben (siehe Tab. 23).

Prozess des „Masterprompts“:

Größenverhältnisse der Symbole	
Prompt: [Left]: ... Make it half that the size bigger as the first symbol. [Right]: ... Make it half the size bigger as the middle symbol“	
Prompt (letzter Satz): „The size ratio should be 1, 1.5, 2“	

Tab. 23: Masterprompt Variante (Ausschnitte) mit Größenangabe bei einzelnen Symbolen (oben) im Vergleich mit Größenangaben am Ende im Verhältnis angegeben (unten), (generiert mit GPT-I, eigene Darstellung).

Während der spezifischeren Tests einen möglichst universellen Prompt zu finden, ist deutlich geworden, wie **wichtig das Symbol Keyword** ist, welches verwendet wird. Wie in Tab. 24 deutlich wird, wird ein „Airport/ Flughafen“ Symbol als der gesamte Flughafen interpretiert, während „Plane“ genauer ist und mit dem ergänzenden Prompt, der zusätzliche Details weglassen soll, wird speziell nur das Flugzeug Symbol detaillierter dargestellt ohne das sich der Hintergrund ändert.

Prompt Veränderungen und ihre Auswirkungen	
Verwendete Symbolvariable: Airport Symbol	
Prompt Anpassungen: Plane Symbol [Center]: don't add details nearby	


Tab. 24: Anpassungen der Stichwörter und Details im Vergleich mit dem generierten Output (generiert mit GPT-I, eigene Darstellung).

Es sind **Anpassungen je nach Symbolgruppe** möglich, beispielsweise kann für übergeordnete Symbole, wie ein Stadtparklogo ein **Hintergrund** zur besseren Abhebung von Symbolen in der Umgebung beitragen (siehe Tab. 25). Damit nicht der Eindruck

entsteht, es wird mit dem Punkt ein bestimmter, in der Realität vorhandener Bereich des Parks dargestellt.

Hintergründe für Symbolgruppen

Prompt Ausschnitt: All three symbols should have clean lines, consistent green colour palette, flat design and a white circular background for better visibility in comparison to the surroundings.



Prompt Ausschnitt: " All three symbols should have clean lines, consistent white colour palette, flat design and a dark brown 1:1 square background for better visibility in comparison to the surroundings."



Tab. 25: Anpassung des Masterprompts: Weißer, kreisförmiger und brauner eckiger Hintergrund (eigene Darstellung, grauer Hintergrund ergänzt, für bessere Erkennung des weißen Hintergrunds (generiert mit GPT-I, eigene Darstellung).

Nachdem es für Symbole erste brauchbare Ergebnisse geliefert hat, wurde mit dem Prompt experimentiert, um ihn **für Muster nutzen** zu können. Dadurch dass es ebenfalls drei Outputs in einem Bild geben sollte, wurde hierbei wieder das Format (1:1) explizit angegeben. Zusätzlich mit dem nahtlos/ seamless Prompt, der sich bei den vorherigen Tests als hilfreich erwiesen hat.

Dabei gestaltet es sich schwerer, generische Ergebnisse zu bekommen, ohne dass der Prompt spezifischer an das darzustellende Objekt angepasst wird (angepasster Prompt in Tab. 26 sichtbar).

Mustertests, mit Promptanpassungen für die darzustellende Fläche

Prompt Ausschnitt: [Left]: minimalist flat design, base fill only, very subtle grain, simplified geometry, no individual trees. [Center]: base fill and soft canopy textures, view from above. [Right]: base fill plus more detailed canopy clusters, more individual trees from above visible.



Tab. 26: Prompts für Muster, im Schema der Symbolprompts (generiert mit GPT-I, eigene Darstellung).

Wenn nur das **Stichwort** „symbol“ aus dem Symbolprompt zu „pattern“ **umgewandelt** wurde, hat es eher **symbolhafte Flächen** erzeugt, die für einen kleinen Maßstab **zu viele Details** zeigen.

Ein Ansatz, der dabei geholfen hat, dass die Muster nicht viel zu kleinteilig und detailliert wurden, ist, wie in Kapitel 4.2 bereits getestet ein **Luftbild als Orientierung** anzugeben.

Zudem hat eine Ergänzung am Anfang des Prompts gut funktioniert: „*Create a professional cartography sprite sheet, three variations of glacier pattern for different zoom levels (attached image as **reference for lod**)*“.

Zudem hat sich innerhalb der Testumgebung herausgestellt, dass drei Detailierungswechsel zwischen den Mustern den Karteninhalt nicht bereichert, sondern eher von anderen Inhalten abgelenkt. Ein Übergang hat gut funktioniert, wenn **anstatt eines ersten Musters eine Farbe** festgelegt wird (siehe Tab. 27 Subjekt), die bei **niedrigen Maßstäben** gezeigt wird und anschließend in ein Muster mit identischer Farbe übergeht, welches dann in hoher Zoomstufe einen Detailierungsgrad zunimmt.

Prompt Baustein	Prompt	MasterScale Operatoren	Erklärung
Pre-Prompt	Create a professional cartography sprite sheet, three variations of a {pattern} pattern for different zoom levels (attached image as reference for lod).	C+ Add Pa Adjust Arrangement Px Adjust Texture	Im Vergleich zu den Symbolen hat hier ein Referenzbild, spezieller ein Luftbild gut funktioniert. Zusätzlich können vor der Pattern Variable die Operatoren zur Anordnung und Textur hinzugefügt werden: „three variations of a irregular {pattern}“.
Subjekt	[Left]: ultra minimalist colour field {hex #}. No details, one colour, no text. [Center]: stylized flat forms, with a little more details, dont add details of the surroundings [Right]: more detailed pattern with shading.	Ps Adjust Shape	Die Muster wurden deutlich semantischer, wenn eine Farbe angegeben wurde.
Style Modifier/ Style Keywords	All three patterns should have clean lines, consistent colour palette {hex #}, flat design. {Transparent background}. Be self-explanatory and generic, minimalistic pattern, dont make large outline changes.	Pc Adjust Color/Hue	Bei Mustern hat sich ein hexcode als hilfreich rausgestellt,
Quality Modifier	Use the same style and colours, but increase in detail so if they are later put above each other there should be a smooth transition between the unique pattern elements. Make it (seamless tiles) in every direction.	Pa Adjust Arrangement	Nathloser Übergang als Input ergänzt.
Gewichtung (DF-Ansatz)	Important: size ratio should be 1, 1.5, 2.25. Format 1:1 for the three patterns.	Pz Adjust size	Bei den Mustern wurde speziell das Format von 1:1 ergänzt, um die Muster im Anschluss leichter extrahieren zu können.
Negativprompt	Not text, no numbers.		

Tab. 27: Übersicht des erstellten übergeordneten Prompts für Muster mit verwendeten Prompt Bausteinen, MasterScale Operatoren und Erklärung (eigene Darstellung). Aufbauend auf dem vorher erstellten Symbolprompt, mit ergänzenden Anmerkungen, was speziell für Muster von Bedeutung ist.


Es kann helfen, wenn bei dem Musterprompt hinter die Variable in Klammern **Anforderungen an das spezifische Muster** geschrieben werden, je nach gewünschtem Ergebnis (siehe Tab. 28), hier beispielsweise, um einen **universelleren** Output zu erhalten.

Mustertests, mit Promptanpassungen für die darzustellende Fläche

Prompt Start: Create a professional cartography sprite sheet, three variations of pitch pattern for different zoom levels.



Prompt Start: Create a professional cartography sprite sheet, three variations of pitch pattern (mown lawn without white markings) for different zoom levels.



Tab. 28: Prompt für eine Grünfläche/ Sportplatz, englisch Pitch (generiert mit GPT-1, eigene Darstellung).

Es wurde zusätzlich getestet, ob sich **abgeleitet vom funktionierenden Masterprompt einzelne Symbole generieren** lassen, dafür wurden die drei einzelnen Symbolbeschreibungen auf drei Prompts aufgeteilt, wie in Tab. 29 dargestellt. Die detaillierten Prompts sind im Anhang 03, Tabelle 5 aufgelistet. Der **Vorteil von einzelnen Symbolen** ist, dass sie **direkt in die Testumgebung und anschließend in ein Sprite** umgewandelt werden können, ohne dass sie vorher zugeschnitten werden müssen. Der Nachteil ist, dass zum Teil die ersten beiden Symbole trotz Stichwörtern wie „ultra minimalistic“ zu detailliert sein können.

Masterprompt für einzelne Symbole: Beispiel Bahnsymbol

Prompt Ausschnitt: (...) one train symbol for a **low** zoom level. Ultra minimalist flat icon, show recognizable form. No details, one colour, no text. The symbol should have clean lines, consistent blue colour palette, flat design and a blue 1:1 square background (...).



(...) one {} symbol for a **middle** zoom level. Stylized flat vector, a few details, dont add details of the surroundings, no text. The symbol should have clean lines, consistent {} colour palette, flat design and a blue 1:1 square background (...)



(...) one {} symbol for a **high** zoom level. 2D symbol with a few details and shading, no text. The symbol should have clean lines, consistent {} colour palette, flat design and a blue 1:1 square background (...)



Tab. 29: Angepasster Masterprompt für einzelne Symbole (generiert mit GPT-1, eigene Darstellung).

Es funktioniert mit den abgewandelten Prompts, jedoch ist **das „einfache“ Symbol für eine niedrige Zoomstufe teilweise detaillierter**, wenn es als einzelner Output generiert wird, als wenn es im direkten Vergleich mit detaillierteren Symbolen gemeinsam in einem Output erstellt wird.

Zusätzlich wurden **Stilübertragungen** getestet, wie in Tab. 30 dargestellt. Dabei wurde ein vorher erstelltes Bild als Input gegeben, zusammen mit Keywords, was angepasst, bzw. verändert werden soll.

<i>Stileanpassungen für einzelne Symbole: Beispiel Krankenhaus</i>			
<i>Inputbild (generiert mit Masterprompt)</i>			
<i>Prompt: Can you change the style from the symbols, so that they fit inside a modern, minimalist map. Don't change anything else, transparent background.</i>			
<i>Can you change the style from the symbols, so that they look scribble like. Don't change anything else, transparent background.</i>			
<i>Can you change the style from the symbols, so that they fit inside a dark grey mode/ night map. Dont change anything else, transparent background.</i>			

Tab. 30: Stileanpassungen für ein Krankenhaus Symbol (generiert mit GPT-I, eigene Darstellung).

Um **hohe Zoomstufen mit detaillierteren Mustern zu befüllen**, ergeben sich **neue Anforderungen**. Bei einem Waldmuster in einer hohen Zoomstufe, ergibt sich das Problem, dass das Muster durch die **Kachelung am Rand** nicht „natürlich“ nach einem Wald aussieht, sondern eine **harte Kante** hat. Um die Fläche dennoch funktional und affektiv gestalten zu können, wurden für den Übergang verschiedene Methoden innerhalb der Testumgebung getestet. Eine Methode, die das Muster bereits passender zum Hintergrund macht, ist eine **helle Farbe**, zusätzlich kann eine Transparenz den Übergang weicher gestalten (siehe Abb.




Abb. 39: Waldmuster mit leichter Transparenz und heller Farbe (links), sowie MapLibre Line Pattern mit einzelnen Bäumen als Übergangszone (rechts), eigene Darstellung, Symbole und Muster (generiert mit GPT-I, eigene Darstellung).

39). Von MapLibre gibt es die Möglichkeit ein **Line Pattern** einzustellen (wie in Kapitel 4.1 bereits erwähnt). In das Line Pattern, können einzelne Baumsymbole eingefügt werden, damit am Rand der Waldpolygonflächen einzelne Bäume sind, die den Übergang natürlicher wirken lassen können.

Insgesamt hat sich während der spezifischeren KI-Tests gezeigt, dass es **vielfältige Möglichkeiten**, bei der Symbol- und Mustergenerierung in Bezug auf Promptanpassungen und Stilanpassungen gibt. Und trotz der Vielzahl an Symbolen und Mustern ein **übergeordneter Prompt möglich** ist, bei dem nur wenig Parameter angepasst werden müssen, je nach Kategorie. Dabei hat sich die **Bedeutung des Keywords** (im Masterprompts des Symbols) als sehr wichtig herausgestellt, bei denen kleinen Änderungen für andere Ergebnisse sorgen können (siehe Tab. 24). Teilweise macht es Sinn, den **Masterprompt anzupassen**, beispielsweise für Symbole, die sich mithilfe von einem farbigen Hintergrund stärker von anderen Kartenelementen abheben sollen. Für solche Fälle hat sich die KI als hilfreich erwiesen und es muss nicht in einem Extraschritt ein Hintergrund eingefügt werden (siehe Tab. 25).

5 Ergebnis – Workflow für die Symbol und Mustergenerierung für Multi-Scale-Karten

Ein Ziel dieser Arbeit war es, einen Workflow zu finden, der dabei hilft, funktionale und affektive Symbole und Muster für eine Multi-Scale-Umgebung zu erstellen. Das Vorgehen setzt sich zusammen aus den *theoretischen Erkenntnissen*, welche Faktoren für eine funktionale Multi-Scale-Karte von Bedeutung sind (siehe 4.2), sowie den *praktischen Modell- und Prompt Tests*. Im ersten Unterkapitel wird der *Workflow erläutert und graphisch dargestellt*. Im Anschluss werden die erstellten Masterprompts vorgestellt, gefolgt von *Erkenntnissen des Prompt Prozesses* und damit mögliche Darstellungsvarianten aufgezeigt, bevor es mit einem Unterkapitel zu *Beantwortung der Hypothesen* und dem möglichst *nutzerfreundlichen Zugriff* auf die Workflowelemente endet.

5.1 Erstellter Workflow sowie generierte Symbole und Muster

In Abb. 40 ist der Workflow abgebildet, erstellt innerhalb der Anwendung draw.io (*draw.io*, o. J.). Der Workflow gliedert sich in *acht Blöcke*, die chronologisch von oben nach unten ablaufen, es beginnt mit der Vorbereitung, der Datengrundlage, dem Generierungsprozess, den Bearbeitungen innerhalb des Modells, bzw. Modellchats, der Weiterverarbeitung, der Integration in die Testumgebung und endet mit dem Ergebnis.

Wie in Kapitel 3.1 bereits festgehalten, soll sich der Workflow *in drei übergeordnete Punkte gliedern*, den Inputdaten, einzelnen Verarbeitungsschritten und den Output Daten. Um sich über mögliche Inputdaten klar zu werden, ist es hilfreich zu Beginn einige Parameter und Darstellungsrelevante Inhalte zu *definieren* (siehe Abb. 36 „I. Definieren“) und damit im Anschluss *Basisdaten als Datengrundlage* bereitzustellen („Basisdaten“). Um mit KI Symbole und Muster für topographische Karten zu generieren, ist es zu Beginn wichtig, genau das gewünschte *Ziel genau zu definieren*. Je nach gewünschtem Output können verschiedene KI-Modelle und Arten diese auszuführen in Frage kommen.

Zu den einzelnen Verarbeitungsschritten zählt dann die *Erstellung eines Prompts* bzw. Anpassungen des Masterprompts („Prompt Parameter anpassen“) und die *Generierung* eines oder mehrerer Muster oder Symbole (um für verschiedene Zoomstufen ansprechende Inhalte zu generieren). Je nachdem wie sehr die Outputs den Vorstellungen entsprechen, geht es zum nächsten Schritt oder der Prompt bzw. Output wird noch einmal überarbeitet. Wenn die Ergebnisse passen, werden die Symbole und Muster anschließend für die Weiterverwendung vorbereitet in dem das „*png_cutter*“-*Skript* sie in einzelne Symbole/Muster aufteilt, falls nötig automatisch vom Hintergrund freigestellt (*transparent*), Muster *nahtlos* gemacht und ihre *Pixelgröße* anpasst, je nachdem für welche Zoomstufe sie im Anschluss genutzt werden sollen.




Abb. 40: Ergebnis: empfohlener Workflow für das Vorgehen der Symbol- und Mustererstellung für Multi-Scale-Karten mittel generativer KI (eigene Darstellung, erstellt innerhalb von (draw.io, o. J.).



In einem weiteren Schritt werden die freigestellten Symbole und Muster in eine **html-Testumgebung** für ein MapLibre Multi-Scale-Karte **eingebunden** („Map Libre Testumgebung“). Der letzte Schritt ist essenziell, um die Symbole und Muster gut testen zu können, die **freigestellten Symbole und Muster könnten ebenfalls ohne das Spriteformat für andere Verwendungen genutzt werden**. Anschließend hat man das Ergebnis, eine MapLibre Basiskarte und ein Sprite, sowie dazugehörige JSON-Datei, um sie in eigene Webkarten einbinden zu können.

Mit dem entwickelten Workflow sollen vor allem innerhalb der Masterprompts **Rahmenbedingungen** definiert werden, die den bisher noch oft uneinheitlichen und schwer reproduzierbaren Output von generativer KI möglichst stark eingrenzen sollen, sodass **kartographisch nutzbare, ansprechende** Ergebnisse erzielt werden können, speziell mit dem Fokus auf einen funktionellen Einsatz innerhalb von Multi-Scale-Karten. In **Bezug auf die Forschungsfrage** soll der Workflow Zeit ersparen und dadurch die Generierung von Karteninhalten optimieren.

Da noch nicht alle Schritte innerhalb eines KI-Modelles möglich sind, wie zum Beispiel das **Freistellen oder nahtlose Übergänge** bei Mustern, werden diese Schritte **nach** der eigentlichen **Generierung** durchgeführt, was die Modellauswahl flexibler macht. In Zukunft könnten sich diese mit der schnellen Weiterentwicklung von KI erübrigen und eventuell ausgetauscht oder weggelassen werden, umso mehr Modelle diese Anforderungen bereits erfüllen (z.B. GPT-I kann bereits Bilder mit transparentem Output generieren).

Eine **Auswahl an erstellten Symbolen und Mustern** mit den Masterprompts ist in Tab. 31 dargestellt. Für den Wald wurde die Variante mit zwei Zoomleveln verwendet, dass verwende Stichwort der Symbolvariable steht jeweils bei der Attributart mit dabei.

Attributart	Erstellte Symbole und Muster (Masterprompt)
Baum/ „tree“	
Krankenhaus/ „hospital“	
Wegweiser/ „signpost“	
Flugzeug/ „plane“	

Synagoge/ „synagogue“	
Bäckerei/ „bakery“	
Fähre/ „ferry“ Variante mit weißem Hintergrund	
Kirche/ „church“	
Geröll/ „bare rock“	
Rasen/ „Pitch“	
Felder/ „farmland“	
Wald/ „forrest“	

Tab. 31: Auswahl generierter Symbole und Muster in verschiedenen Detailgraden mittels des erstellten Masterprompts (generiert mit GPT-1, eigene Darstellung).

Bei den **Mustern** wurde oft ein **hex Code als zusätzliche Angabe** hinzugefügt, damit sie nicht zu intensiv sind. Bei einzelnen Symbolen bietet es sich an einen gewissen **Gegenstand als Parameter für die erste Zoomstufe** mitanzugeben, wenn ein Symbol mit einer bestimmten Form assoziiert wird. Das wurde beispielsweise bei dem Bäckerei Symbol gemacht, bei dem zusätzlich „Brezel“ als Stichwort ergänzt wurde, das KI-Modell hat selbständig daraus abgeleitet für höhere Zoomstufen ein Haus daraus generiert. Es wurden, basierend auf den Erkenntnissen des Theorieteils **semantische Farben für die „Colour“-Variable** verwendet. Bei der Synagoge wurde mit einer anderen Farbe experimentiert was auch möglich ist, falls ein Objekt mehr rausstechen soll, ähnlich bei dem Krankenhaus Symbol, welches sich in Rot stärker von der Umgebung abhebt.

5.2 Masterprompts, Erkenntnisse und hilfreiche Promptbausteine

Die möglichst **generischen Masterprompts**, die sich während des Generierungsprozesses herausgestellt haben (siehe 4.3) sind innerhalb von Abb. 41 dargestellt. Innerhalb der *geschwungenen Klammern* {} ist jeweils eine **Variable** einzusetzen, beispielsweise ein spezifisches Symbol oder Muster Stichwort, eine Farbe oder anstatt „Transparenz“ „weiß“, je nach Modellart. In den beiden Empfehlungen werden jeweils drei im **Detailgrad zunehmende** Symbole und Muster erzeugt. Sie sollen dabei helfen die **Unterfragen III und IV** (Kapitel 1.2) zu beantworten, in dem sie durch ihren Aufbau Multi-Scale-Kriterien entsprechen und funktionale Ergebnisse für verschiedene Zoomstufen generieren sollen.

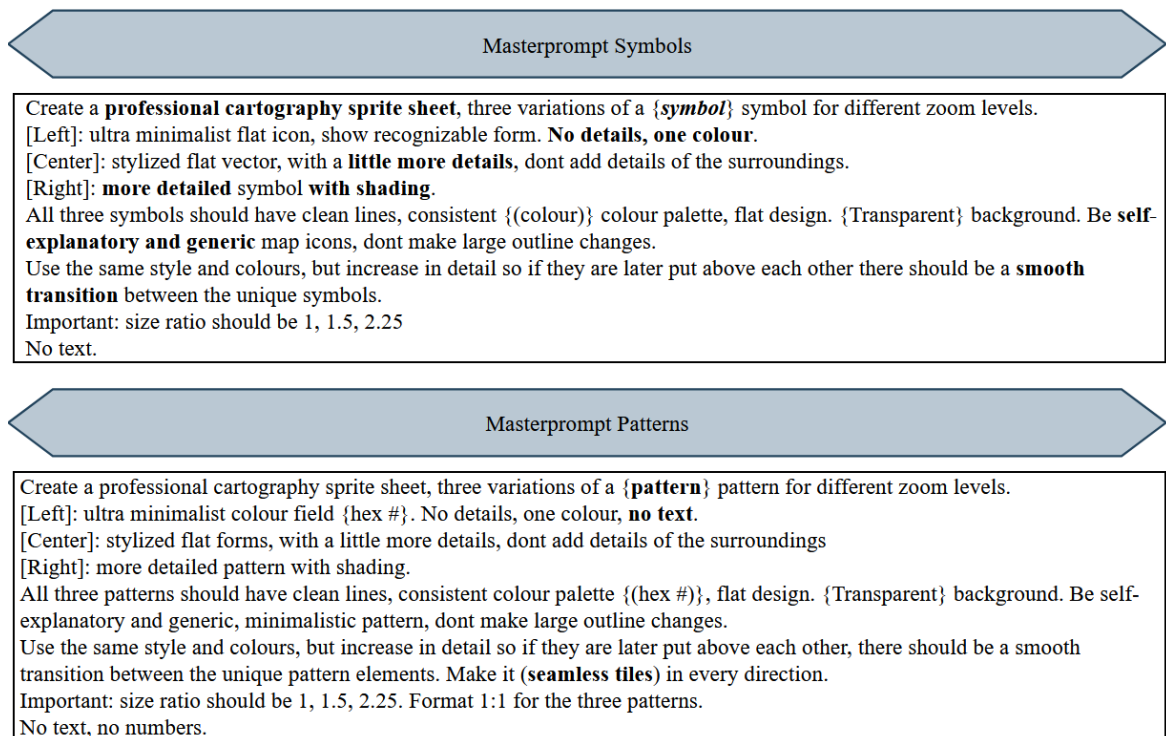


Abb. 41: Möglichst generische Symbol- und Musterprompts, die während der Theorie- und Praxistests am besten funktioniert haben (eigene Darstellung, erstellt innerhalb von (draw.io, o. J.).

In Abb. 42 sind **Prompthilfen** dargestellt, es sind Designelemente, die angepasst werden können, um die Ergebnisse funktionaler und individuellen Vorstellungen entsprechend zu gestalten oder zu bearbeiten. Diese haben sich während der Modelltests und dem Erstellungsprozess des Masterprompts als hilfreich herausgestellt.

Die Hilfestellungen sind **aufgeteilt auf drei Blöcke** (hellblaue Balken), zum einen **übergeordneten, symbolspezifisch-**, sowie **musterspezifischen Elementen**. In der linken Reihe stehen Stichwörter, auf welches Vorgehen sich die Prompthilfe bezieht (z.B. Farben), in der Mitte entweder eine Erklärung oder ein spezifischer Promptausschnitt, der dabei geholfen hat, den Parameter wie gewünscht anzupassen. In der rechten Spalte, ist entweder ein Promptausschnitt als Hilfe, oder speziell bei den spezifischen Erkenntnissen ein Bild, welches mithilfe des Prompts erstellt, bzw. bearbeitet wurde.




Abb. 42: Erkenntnisse der Modelltests zusammengefasst mit den dazu geeigneten Prompts (eigene Darstellung, erstellt innerhalb von (draw.io, o. J.), generierte Beispiele erstellt innerhalb von GPT-1 1.5)..

Für **Muster** kann es hilfreich sein, wenn bereits eine **grundlegende Karte vorhanden** ist und die Farben dieser, als hex code in den Prompt eingefügt werden, damit die Ergebnisse einheitlicher werden. Für **Muster** haben sich im Laufe der Tests **zwei Zoomstufen als ausreichend** herausgestellt, dass es ansonsten zu viele Details gab, die vom restlichen Karteninhalt ablenken. Zu Beginn eignet sich eine einfach eingefärbte Fläche gut, die sich bei höherer Zoomstufe zu einem Muster ändert, deshalb ist die **Dreiteilung des Prompts weiterhin praktisch**, vor allem weil die Muster dadurch das es drei nebeneinander sind, kleiner dargestellt werden und sich dadurch das Problem eines zu detaillierten Outputs verringert. Bei Symbolen kann es ebenfalls hilfreich sein, **"nur" zwei Detailstufen** zu zeigen, zum Beispiel im **urbanen Gebiet**, um genug **Ankerpunkte** zu schaffen.

Wie bei den Modelltests bereits festgestellt (siehe Abb. 31) imitieren die getesteten Modelle, bis auf GPT-I aktuell nur einen transparenten Hintergrund, weshalb für eine Weiterverarbeitung innerhalb anderer Modelle ein **weißer Hintergrund** praktischer ist und „Transparent“ als Variable im erstellten Workflow, bzw. Masterprompt angegeben wurde, die in dem Fall mit „white“ ersetzt werden sollte (siehe Kapitel 5). Bei Nano Banana waren die **Sichtwinkel** zum Teil nicht einheitlich (beispielsweise von schräg oben), weshalb dort eine Anpassung Sinn macht. Vergleichsbilder zu den Promptanpassungen sind in Anhang 04 dargestellt. Für **LLMs**, beispielsweise Qwen hat sich gezeigt, dass der **Hintergrund teilweise nicht rein weiß** ist, weshalb dort die Angabe eines hexcodes Sinn macht. Innerhalb von Diffusion Modellen, wie Stable Diffusion hat sich ein aufgeteilter Masterprompt als praktischer erwiesen, bei dem vollständigen Masterprompt wurde die Anzahl der Symbole oft falsch umgesetzt (beispielhafte generierte Outputs siehe Anhang 04).

Zusätzlich sind bei **Mustern Vorlagen als Input hilfreich**, wie beispielsweise Luftbilder der darzustellenden Fläche. Dafür haben sich speziell Bilder geeignet, die ein Muster aus weiterer Entfernung darstellen (siehe Tab. 17), ansonsten werden für zum Beispiel „bare rock“ nur drei, vier einzelne Steine erstellt, anstatt ein Muster für ein ganzes Geröllfeld.

5.3 Beantwortung von aufgestellten Hypothesen und nutzerfreundlicher Workflow Zugriff

Am Anfang von Kapitel 4 wurden **fünf Hypothesen** aufgestellt, um zu beantworten welche Methoden und Schritte es gibt, um Symbole und Muster zu bearbeiten bzw. anzupassen, um sie geeigneter für Multi-Scale-Karten zu machen.

Anhand des Workflows und den herausgefundenen Prompthilfen, lassen sich die in Kapitel 4 aufgestellten Hypothesen beantworten:

- I. KI kann helfen ein Symbol oder Muster schnell an **verschiedene Maßstabsstufen** anzupassen.
 - i. KI kann für die Symbol- und Mustererstellung bei Maßstabsübergängen hilfreich sein, wenn **zuerst die detailliertere Version** generiert wird und daraus abgeleitet **generalisierte Versionen** für verschiedene Maßstäbe.

Punkt I wird durch die Ergebnisse untermauert. Es können direkt mehrere Zoomstufen innerhalb eines Prompts und Outputs generiert werden.

Zu Unterpunkt i, hat sich bei den Tests herausgestellt, dass es funktioniert, jedoch andersherum besser, wenn ein einfaches Symbol für höhere Zoomstufen mit mehr Details dargestellt werden soll. Das könnte daran liegen, dass KI-Modelle wie bei den Modelltests festgestellt (siehe Kapitel 3.3) meistens eine feste und hohe Ausgabequalität haben und deshalb dazu neigen mehr Details zu integrieren.

- ii. Wenn ein generiertes **Muster als Input** gegeben wird, können daraus passende **Symbole für den Übergang** generiert werden und andersherum.

Diese Hypothese lässt sich nur teilweise bestätigen, wie beim letzten Punkt haben die Ergebnisse gezeigt, dass es besser funktioniert, wenn zuerst ein Symbol erstellt wird und daraus abgeleitet Muster, da sonst das Symbol zu detailliert werden kann (Tab. 18).

- II. Wenn für einen bestimmten Maßstab bereits Symbole und Muster vorhanden sind, kann KI dabei helfen schnell **für andere Maßstäbe Zeichenschlüssel** zu generieren.

*Die Ergebnisse stützen diese Hypothese mit den durchgeführten Tests nicht, KI kann dabei helfen, schnell **einzelne** Symbole und Muster über Maßstäbe hinweg zu erstellen, ein gesamter Zeichenschlüssel ist innerhalb der getesteten Chatmodelle aktuell nicht möglich, weil es innerhalb der Useroberfläche keine Batch-Möglichkeit gibt.*

In Zukunft könnte die Hypothese mithilfe eines Agenten-Ansatzes getestet werden, wobei der erstellte Masterprompt als Input für ein Bildgenerierungstool genutzt werden könnte, welches ein Agent abrufen. Ein anderer Agent könnte vorher Designaspekte definieren und ein weiterer im Anschluss der Generierung prüfen, ob diese eingehalten wurden. Damit würden die Aufgaben auf einzelne Agenten aufgeteilt werden, wie in Kapitel 2.3.3 in Bezug auf Wangs Veröffentlichung beschrieben (Wang et al., 2025).

- III. Wenn ein Muster oder Symbol in einem **bestimmten Stil** erzeugt wurden, kann die KI diesen **auf andere übertragen**.

Diese Hypothese ließ sich durch die Tests bestätigen, generative KI kann zum einen dabei helfen einen Stil auf ein generiertes Bild zu übertragen, wie in Tab. 30 sichtbar. Zusätzlich kann das LoD von einem bereits erstellten Symbol auf anderes übertragen werden (siehe Abb. 42).

Damit der Workflow **reproduzierbar und nutzerfreundlich** ist, wurde versucht ihn so gut wie möglich anhand der in Kapitel 3.1 beschriebenen **FAIR-Prinzipien** zu gestalten. Damit die einzelnen Schritte besser nachvollziehbar sind, wurden sie schematisch von oben nach unten dargestellt. Damit er auffindbar und zugänglich („findable“ und „accessible“) ist, wurde ein **github Repository** erstellt. Dort wird die Testumgebung als herunterladbare Datei mit der dazugehörigen **Python Server Datei**, sowie das **Vorbereitungsskript „png_cutter“** zur Verfügung gestellt, der Workflow und Prompthilfen als PNG-Ansichten (in deutscher und englischer Sprache), sowie die **Masterprompts als kopierbare Texte**. Des Weiteren ein

Ordner mit generierten Outputs zum Testen der Testumgebung und ein Ordner um eigene Beispiele mit anderen zu teilen (Bischoff, 2026; Hu et al., 2025).




Abb. 43: Veröffentlichter Workflow auf GitHub, um den Workflow möglichst FAIR (Hu et al., 2025) zu gestalten (eigener Screenshot, erster Teil der „readme“-Datei zur Beschreibung des Projekts).

Damit einzelne Teile des **Workflows losgelöst** verwendet werden können, wurde der Masterprompt als Alternative aufgeteilt auf einzelne Zoomstufen getestet (siehe Abb. 42 und Anhang 03), was für andere Modelle besser funktioniert hat und mehr Spielraum für das Erstellen einzelner Zoomstufen lässt. Dennoch sind **Reproduzierbarkeit und Replizierbarkeit** zwei Punkte, die aktuell eine **Einschränkung bei der Arbeit mit KI** darstellen, da trotz identischer Prompts **nicht modellübergreifende genau identische Ergebnisse** möglich sind. Detaillierte Tests innerhalb weiterer Bildgenerierungsmodelle könnten in Zukunft dazu beitragen die nötigen zu adaptierenden Variablen besser zu identifizieren und dadurch den Workflow noch universeller zu machen.

6 Diskussion und Limitationen

Es wurde ein möglichst funktionaler und affektiver Workflow für die KI-Generierung von Mustern und Symbolen innerhalb von Multi-Scale-Anwendungen erstellt. Dabei wurde speziell auf hohe Zoomstufen geachtet und wie diese mit hilfreichen Informationen gefüllt werden können. In folgendem Kapitel werden die Ergebnisse des theoretischen und praktischen Teils diskutiert, dabei wird speziell auf die **Stärken** und **Schwächen** des erstellten Workflows und der Arbeit mit KI eingegangen.

6.1 Stärken des Workflows

Im Zuge der Arbeit mit generativer KI und der Erstellung des Symbol- und Musterworkflows haben sich gewisse Faktoren als Vorteilhaft gegenüber klassischem Vorgehen erwiesen, Diese lassen sich in folgende fünf thematische Kategorien einteilen:

- I. Zeit- und Kostenersparnis**
- II. Handhabung & Kreativitätsanreize**
- III. Rasterdaten als Ausgabeformat**
- IV. Vorteilhafte Sichtwinkel**

Zu **Punkt I** gibt es Modelle, die Muster- und Symbole ohne Anmeldung oder Kosten generieren. Je nach Modell, kann es aber auf eine bestimmte Anzahl an Outputs begrenzt sein. Im Vergleich zu herkömmlichen bekannten Vektorprogrammen, können zumindest bis zu einer bestimmten Anzahl an Credits kostenlose Inhalte generiert werden (siehe Kapitel 3.3). Symbole und Muster können **innerhalb weniger Minuten** für mehrere Zoomstufen auf einmal generiert werden. Durch den Workflow und Masterprompt gehen die Symbole **von simpel zu detailliert** über, was **Überlegungen zur Generalisierung erspart**, die bei bisherigen Veröffentlichungen zu Multi-Scale-Karten sowie in klassischen Printkarten einen Schwerpunkt darstellten (Brewer & Buttenfield, 2010). Im Vergleich zu bisherigen Vorgehen, die sich auf eine **feste Zoomstufe** bezogen (Drews et al., 2025; Dunkel et al., 2024) werden direkt für mehrere Zoomstufen Symbole und Muster generiert und mittels des Prompts Vorgaben zum Übergang festgelegt.

Die Handhabung (**Punkt II**) hat den Vorteil, dass Bildgenerierungsmodelle **auch für nicht Kartographen** eine schnelle Symbol- und Mustergenerierung möglich machen. Über die meist **nutzerfreundlich gestalteten Chatoberflächen** der KI-Modelle und Text als Input ist es ein Vorteil schnell Details anpassen und ändern zu können. Verschiedene Stile, Detail- und Abstraktionsgrade können innerhalb von kurzer Zeit getestet und visualisiert werden (Kapitel 4.3). Zusätzlich kann es als **Brainstorming** hilfreich sein, wenn noch keine bestimmte Vorstellung vorhanden ist oder dabei helfen, eine Vorstellung umzusetzen, die es in der Art als Symbol- oder Muster noch nicht gibt. Beispielsweise wenn **zwei Symbole kombiniert** werden sollen und es dafür in bekannten frei verfügbaren Symboldatenbanken

wie den Maki Icons noch kein vergleichbares gibt, bzw. es noch andere Kombinationsmöglichkeiten geben kann, wie in Tab. 32 dargestellt.

Es hat sich gezeigt, dass die **KI kreative Lösungen** findet, was die Übergänge von einer Zoomstufe in die andere betrifft, auf Tab. 32 bezogen ist der Schraubenschlüssel beispielsweise ein Element, welches als **Ankerpunkt** (Dumont et al., 2020) zusammen mit dem Fahrrad vorhanden bleibt oder auch das Bäckereisymbol in Tab. 31 welches von einer Brezel, in ein Bäckereigebäude übergeht.

<i>Kombination von zwei Symbolklassen</i>	
<code>class=information</code> <code>subclass=map</code> Prompt Subjekt: "information map"	
<code>class=bicycle</code> <code>subclass=repair_station</code>	

Tab. 32: Mit Masterprompt erstellte Symbole, die durch ihre Objektklassen eine Kombination aus Symbolen sind (Screenshots innerhalb der Testumgebung, Symbole generiert mit GPT-I, eigene Darstellung).

Digitale Karten ermöglichen NutzerInnen eigene Elemente einzubinden und Karten freier zu gestalten (Mericskay, 2024, S. 166). In **klassischen Webkarten** ist es dennoch ein typisches Vorgehen, dass für Hintergrundkarten (zur besseren Orientierung) auf Symbole und Mustervorlagen zurückgegriffen wird, beispielsweise den Maki Icons (siehe 3.2 (*Maki Icons* | *By Mapbox*, o. J.)) und in dem Zuge nur kleinere Anpassungen bei Farben oder Hintergründen gemacht werden. Dabei werden (wahrscheinlich aus Zeitgründen) kaum individuelle, für das Thema bzw. den Style der Karte entsprechende Symbole oder Muster erstellt. Der Workflow dieser Arbeit macht es einfacher, Symbole und Muster den **eigenen Vorstellungen entsprechend** anzupassen und damit affektive, einzigartigere Karteninhalte zu erstellen.

Bezüglich **Punkt III** ist es, wie in Kapitel 4.2 bereits erwähnt, bei KI-Outputs ein **großer Vorteil** der Funktionalität, dass sie im **Rasterformat** sind, da diese über eine Sprite Datei direkt in eine Multi-Scale-Karte integriert werden können. In der herkömmlichen Arbeitsweise müssen SVGs (weil die Erstellung meist in Vektorprogrammen erfolgt) zuerst in Raster umgewandelt werden (wobei Qualitätsverluste leichter passieren können), damit sie in ein Sprite integriert werden können. Diese Ausgangslage **erspart zusätzliche Skripte und Formatumwandlungen**, die bisher bei SVG's nötig waren.

Bezüglich **Punkt IV** haben die Modelltests gezeigt, dass als **Sichtwinkel Schrägbilder und Aufrissbilder** gut erstellen lassen. Lokale Formen (siehe 2.1.4) wie zum Beispiel Parkplätze lassen sich schnell generieren (auch ohne spezifischen Masterprompt), eventuell da sie von Grund auf generischer sind. Symbolgrößen haben sich bei klassischen Vorgehen je nach

Zoomstufe nicht verändert, was die Orientierung beeinflussen kann (Mericskay, 2024, S. 173), was durch detaillierter werdende KI-Symbole umsetzbar ist.

Im *Vergleich zu bisherigen Vorgehen* ist der Workflow auf Multi-Scale-Kriterien *optimiert* und der *Fokus ist stärker auf der Funktionalität der Symbole* über Zoomstufen hinweg, im Vergleich zu bisherigen Veröffentlichungen, bei denen die neue Möglichkeit der *Generierung*, auf Kartenelemente bezogen, *im Vordergrund* standen (Dunkel et al., 2024).

6.2 Schwächen des Workflows

Folgend werden, während der Modelltests und Prompterstellung, aufgefallene Fehler und Probleme festgehalten. Wie im Theoriekapitel 2.3.4 beschrieben, gibt es aktuell noch Limitationen bei der Arbeit mit KI, diese lassen sich in folgende Kategorien einteilen:

- I. Voreingenommenheit & unklare KI-Datengrundlage*
- II. Bezugsfehler innerhalb eines Modellchats*
- III. Modellabhängigkeiten - Promptübertragung auf weitere KI-Modelle*
- IV. Ausgabequalität der Outputs & mögliche Generierungsfehler*
- V. Nachbearbeitungen*

Die *Datengrundlage* von KI-Modellen, kann *voreingenommen* sein und dadurch Ergebnisse liefern, die eher auf *europäischer Ebene geläufiger* sind. Dieser Aspekt bestätigt die Erkenntnisse des Theorieteils (siehe Kapitel 2.3.4 (Kang et al., 2024)). Im speziellen Bezug zu dieser Arbeit, kann das zur Folge haben, dass Symbole und Muster möglicherweise *stärker einer europäischen Datenlage* entsprechen und deshalb für NutzerInnen ohne europäische Herkunft kontraintuitiver sind. Beispielsweise ein Apothekensymbol mit einem „A“ dargestellt oder eine *Ruine dargestellt als kaputte Burg*, könnten in Österreich schneller als diese identifiziert werden, als in Ländern, in denen es andere Gründe für Ruinen gibt oder ein Apothekensymbol ein anderes Erkennungssymbol hat.

Zusätzlich hat sich während der Modelltests (siehe Kapitel 3.3) bestätigt, dass die *Daten- und Trainingsgrundlage* der Modelle schwierig nachvollziehbar ist und für wenigsten getesteten Modelle transparent und klar definiert wurde, auf welcher Datenbasis sie entwickelt wurden. Dieser Aspekt bestätigt ebenfalls in der Theorie identifizierte *mögliche Schwachpunkte* (siehe 3.3) und ist ein Punkt der unter dem Begriff „*Black Box Modelle*“ in Veröffentlichungen zum Thema KI verwendet wurde (siehe 2.3.4 (Kang et al., 2023)).

Der *Punkt II., Bezugsfehler* innerhalb eines Chats sind während der Tests bei GPT-I und Qwen aufgefallen. Der Fehler trat bei beiden Modellen auf, wenn beim Testprompt nur der Name vom Symbol und die Farbe angepasst wurde und vorher bereits ein Bild generiert wurde, jedoch nicht jedes Mal, sondern nur in einzelnen Fällen. Wie in Abb. 44 dargestellt, wurde bei GPT-I zuerst ein Mistkübel generiert und im Anschluss ein Bahnsymbol. Bei

näherer Betrachtung fällt auf, dass das erste Bahnsymbol der Form des ersten Mistkübels entspricht. Bei Qwen wurde ein Restaurantsymbol generiert und im Anschluss ein Krankenhaussymbol, dabei ist der **Bezug auf den letzten Output deutlich** zu erkennen. Was zeigt, dass **innerhalb eines Chats, die vorher erstellten Ergebnisse in das neue Ergebnis miteinfließen** zu scheinen.

Es wurde nach der Erstellung der Masterprompts getestet, inwieweit die Ergebnisse auf andere Modelle **übertragbar** sind (**Punkt III**). Bereits innerhalb der Modelltests wurde deutlich, dass aktuell trotz eines detaillierten Prompts verschiedene Outputs erzeugt werden.

Die **Ergebnisse variieren** je nach individuellem Modell, bzw. noch eindeutiger nach **Modellart**. Für **MLLMs** (wie GPT-I und Nano Banana 2) sowie **LLMs** (z.B. Qwen) **funktioniert der Masterprompt besser**, da sie Begriffe wie „cartographic sprite sheet“ durch ihre **Textverarbeitungsstärke** (siehe 2.3.1) besser einordnen als Modelle, bei denen die Bildgenerierung als Tool eingebettet ist (z.B. bei Diffusion Modellen). Das ein „cartographic spite sheet“ als Stichwort von MLLMs und LLMs richtig interpretiert ist wiederum ein Fortschritt ist zu früheren Modellen, die weniger in der Lage waren geographische oder kartographische Grundlagen zu identifizieren (siehe Kapitel 2.3.4).




Abb. 44: Entdeckter Fehler bei Prompttests, Symbol von vorherigem Output wird für neuen Output herangezogen (links GPT-I, rechts Qwen 3.6-Plus, eigene Screenshots).

Mittels des Masterprompts generierte Symbole und Muster innerhalb von drei Modellarten sind in Anhang 04 festgehalten und Tipps zu den Modellen als Hilfestellung in 5.2 festgehalten.




Abb. 45: Zu hoher Detailgrad, links generiertes Symbol, rechts eingebunden in Testumgebung durch Sprite Erstellung runterskaliert (generiert mit GPT-I, eigene Darstellung).

Punkt IV., der während der Arbeit innerhalb der Testumgebung und während der Modelltests aufgefallen ist, ist die **Bedeutung der Ausgabequalität** der Ergebnisse. Speziell in niedrigen Zoomstufen, ist es wichtig sehr einfache Symbole und Muster zu erzeugen. Da die Ergebnisse innerhalb des Sprites auf wenige Pixel runterskaliert werden, kann es bei einem zu detaillierten Symbol zu Darstellungsproblemen kommen (siehe Abb. 45).

Bei den Modelltests kam heraus, dass die getesteten Modelle **hauptsächlich 1048x1048 als Ausgabeformat** erzeugen, was für hohe Zoomstufen praktisch ist, jedoch in niedrigen Zoomstufen schnell zu **detaillüberlasteten** Symbolen und Mustern führen kann. Um dem entgegenzuwirken, wurde innerhalb des Masterprompts ein Verhältnis („Ratio“, siehe 4.2) angegeben, damit die Symbole und Muster für niedrige Zoomstufen direkt auf einer kleineren Fläche generiert und damit bereits generalisiert werden müssen. Eventuell ist es in Zukunft bei mehr Modellen möglich eine Ausgabequalität einzustellen.

Zusätzlich werden eher **intensivere und mehr Details** integriert, was wiederum für Nachbearbeitungen sorgen kann. Eine **spätere Transparenz hinzuzufügen** hat sich innerhalb der Testumgebung als hilfreich rausgestellt, **um intensiveren Farben entgegenzuwirken**. **Darstellungen von oben** sind für viele Modelle schwierig, was sich besonders bei den Modelltest und Baumsymbolen gezeigt hat (siehe Tab. 10). Es werden zudem **nicht immer alle Prompt-Angaben befolgt**, zum Beispiel wurde speziell bei Mustern der Prompt-Ausschnitt „Format 1:1“ nicht immer eingehalten, ein gewisser „random“ Faktor mit unerwarteten Ergebnissen bleibt derzeit, auch wenn stark eingegrenzt durch den Promptaufbau (Kang et al., 2023).

Muster haben sich bei den Modelltests als **schwerer generierbar** und in Bezug auf **Promptübertragungen** als **weniger gut übertragbar im Vergleich zu Symbolen** herausgestellt (siehe Anhang 04). Bei **Flächen** sind oft **einzelne Elemente**, wie Steine bei Geröll oder Grasbüschel bei Gras **zu dominant** für eine niedrige Zoomstufe erzeugt worden.

Bezüglich **Punkt V** ist eine Limitierung ist, dass aktuell je nach Modellart **Nachbearbeitungen** an den Symbolen und Mustern gemacht werden müssen. Zum Beispiel das Freistellen von Symbolen, nahtlos machen von Mustern und aufsplitten auf einzelne PNGs, weshalb dieser Schritt **innerhalb einer Python Datei zur Verfügung gestellt** wurden (png_cutter-Skript, siehe 5.1). Im Vergleich zu vorherigen Modelltest in Bezug auf Symbole (Drews et al., 2025; Dunkel et al., 2024), gibt es mittlerweile durch GPT-I ein Modell, welches transparente Hintergründe erstellen kann. In Zukunft könnten Fortschritte bei Modellen diese Bearbeitungsschritte weiter verringern.

Insgesamt wird deutlich, dass es bei der Arbeit mit KI einige Punkte zu beachten gibt. Das Wissen, dass **KI-Modelle nicht fehlerfrei** sind, zeigt, dass menschlicher Input sowie Expertise weiterhin wichtig sind, um diese zu identifizieren und auszubessern. Zudem sollten bei der Erstellung von Karteninhalten, mögliche Vorurteile der KI bedacht und wenn nötig gegengesteuert werden. Gleichzeitig zeigt sich, dass KI dabei helfen kann **umständliche Arbeitsschritte zu vereinfachen** und zu beschleunigen.

7 Conclusio

Innerhalb dieser Masterarbeit wurde ein Workflow entwickelt, um generative KI für die Erstellung von Symbolen und Multi-Scale-Karten zu nutzen. Ein spezieller Fokus war dabei die Funktionalität und Affektivität der generierten Inhalte. Um diese zu erzielen, wurden innerhalb des Theorieteils *kartographische Designaspekte* (Kapitel 2.1), *psychologische Faktoren* (Kapitel 2.2), sowie *Herausforderungen von Multi-Scale-Karten* (Kapitel 2.5) betrachtet. Mithilfe dieser Informationen wurden Kriterien aufgestellt (Kapitel 3.2) und damit im Anschluss KI-Bildgenerierungsprogramme auf ihre Eignung getestet

In Bezug auf Kapitel 1.1 wurden für den Wiener Stadtpark innerhalb der erstellten Testumgebung Symbole und Muster für verschiedene Zoomstufen generiert. Diese sind innerhalb von Abb. 46 dargestellt. Speziell die *höheren Zoomstufen* sind dabei bewusst mit *mehr Informationen* gefüllt worden, um den *vorhandenen Platz* der Multi-Scale-Karte *funktionaler zu nutzen* und dort mehr Orientierungspunkte zu schaffen. Durch den



Abb. 46: Bezug zur Einleitung - Wiener Stadtpark in zwei verschiedenen Zoomstufen, links Zoomlevel 17, rechts Zoomlevel 18, unten 20 (alle Symbole generiert mit Masterprompt innerhalb von GPT-I, eigene Darstellung, OSM Bright Basiskarte).

Übergang der Symbole und Muster wurde darauf geachtet keine zu hohe kognitive Belastung zu erzeugen, sowie einen „desert fog effect“ (Kapitel 2.2.2) zu vermeiden.

Mithilfe von **Prompt Engineering** Methoden, dessen Grundlagen vorher theoretisch behandelt wurden (Kapitel 2.4), ist innerhalb der Modelltestungen und im Anschluss während der spezifischeren Tests innerhalb einer dafür erstellten Testumgebung (Kapitel 4.1) ein **Vorgehen entwickelt** worden, um möglichst Multi-Scale geeignete Outputs zu erzeugen. Die Ergebnisse wurden innerhalb eines Workflows festgehalten und über GitHub **zur freien Verfügung gestellt** (Kapitel 5.3).

7.1 Beantwortung der Forschungsfragen

Zu Beginn werden die Unterfragen beantwortet, die zur Beantwortung der Forschungsfrage (mit FF gekennzeichnet) beitragen.

I. Was sind zentrale Designaspekte in der Kartographie, speziell in Bezug auf Symbole und Muster für Multi-Scale-Karten?

Innerhalb des Theorieteils haben sich die **graphischen Variablen von Bertin**, sowie die, für digitale Anwendungen, erweiterte Version von **MacEachren** (Kapitel 2.1.2) als Designgrundlage und Darstellung von kartographischen Elementen herausgestellt.

Zu Designkriterien zählen der Einsatz von **semantischen**, der Objektart entsprechenden **Farben**, mittig ausgerichtete Symbole, hohe Ikonizität bei Symbolen und für NutzerInnen vertrauenswürdige Karten durch **ausgeglichene, akkurate und authentische** Elemente (siehe zusammengefasst in Tab. 1). Innerhalb von Multi-Scale-Karten ist ein bedeutender Aspekt die Gestaltung der Skalierung von Karteninhalten. Diese verändern sich nach Maßstab und müssen je nach Zoomstufe generalisiert werden. Um das Vorgehen dafür mittels Parametern und Operatoren zu kategorisieren, wurde auf ein **MasterScale Diagramm** zurückgegriffen und um eine Extrakategorie für musterspezifische Anforderungen erweitert (Kapitel 2.5.1).

II. Welche Generativen KI-Methoden gibt es in der Kartographie, die für Multi-Scale-Karten von Relevanz sein können?

Um diese Forschungsfrage zu beantworten, wurde im Theorieteil ein **Überblick über generative Modellarten** gegeben (2.3). Innerhalb der letzten Jahre wurden bereits KI-Modelle auf ihre kartographischen Fähigkeiten getestet, speziell DALLÉ 3 als eines der ersten großen Bildgenerierungsmodelle (2.3.2).

Zudem wurden Kriterien auf Basis der zentralen Designaspekte und Anforderungen von Multi-Scale-Karten erstellt (siehe Kapitel 3.3, Tab. 7) und auf dessen **Eignung Bildgenerierungsmodelle getestet** (3.3).

- Dabei haben sich **GPT-I** und **Stable Diffusion** als am geeignetsten herausgestellt, mit GPT-I wurde in Folge detaillierter getestet, zum einen, weil es ein

vielversprechendes MLLM ist (2.3.1) und weil es durch eine integrierte Hintergrundfreistellung Nachbearbeitungsschritte erspart hat.

Die Entwicklung neuer Modelle und Versionen erfolgt in einer Geschwindigkeit, in der neue Paper und Veröffentlichungen kaum nachkommen. Wie im Theoriekapitel 2.3.4 erläutert, gibt es eine Entwicklung bei der **Diffusion Modelle durch MLLMs ausgetauscht** werden. Beispielsweise wurde DALL-E innerhalb von ChatGPT durch GPT-4 ersetzt und Imagen von Google Gemini durch Nano Banana 2 als Standardmodell abgelöst. Zusätzlich bilden **Agenten**, die **Bildgenerierungsmodelle als Tools** verwenden einen neuen Ansatz.

- Bei der Übertragung der Ergebnisse auf KI-Modellarten, haben sich **LLMs und MLLMs** als **relevant** herausgestellt, da sie Begriffe, wie „cartographic sprite sheet“ besser einordnen können (**Fehler! Verweisquelle konnte nicht gefunden werden.**), was die Aktualität dieser Modellarten bestätigt hat.

III. Inwiefern können KI-generierte Symbole in verschiedenen Maßstäben affektiv und funktional gestaltet werden?

Um diese Unterfrage zu beantworten, wurden im Theorieteil wichtige **Designaspekte** (siehe Forschungsfrage I) und **Multi-Scale-Herausforderungen** betrachtet und auf dieser Basis Kriterien aufgestellt (4.2), auf deren Erfüllung KI-Modelle und Funktionen getestet wurden.

- In Bezug auf die Motivation, bieten digitale Multi-Scale-Webkarten bei hohen Zoomstufen viel Platz, der gefüllt werden kann. Ein Gegensatz zur Generalisierung, eine Art **Konkretisierung und Präzisierung**. Generative KI kann dabei helfen diesen Platz mit detaillierten Symbolen und Mustern zu füllen und kann den Übergang von sehr simplen Symbolen in niedrigen Zoomstufen, zu detaillierten in hohen Zoomstufen schaffen. Detaillierte Muster bzw. Symbole **schaffen zusätzliche Orientierung** in hohen Zoomstufen und Nutzen vorhandenen Platz besser aus.

Ein großer Vorteil der Funktionalität gegenüber klassischem Vorgehen ist, dass die **Rasterbilder direkt als Input für Spriteerstellung** verwendet werden können, was Umwandlungsschritte einspart.

Durch Keywords und Promptanpassungen können **Style Vorstellungen** (Tab. 30) und **kreative Lösungen** für Symbole und Muster innerhalb der Chatoberflächen der Modelle erstellt werden **ohne die Kenntnisse und Kosten für ein Graphikprogramm erlernen oder zahlen zu müssen**. Die Struktur des erstellten Masterprompts hilft gleichzeitig dabei, kartographischen Aspekten und Übergängen von Zoomstufen gerecht zu werden.

Für eine affektive und ansprechende Darstellung spielt die Kommunikation der kartographischen Inhalte eine Rolle. Dafür wurde das von Kent auf die Vorteile der Digitalisierung angepasste Kommunikationsmodell betrachtet (2.1.3). Damit der erstellte Workflow funktional ist, gibt es durch die Testumgebung und den **menschlichen Input** bei der Prompterstellung, die Möglichkeit einen Kreislauf herzustellen. KartographInnen können der KI, durch Stichworte ihre Vorstellungen als Input geben, im Anschluss innerhalb

einer Testumgebung auf ihre Eignung überprüfen und falls nötig in einem zirkulären Prozess neu erstellen oder bearbeiten.

IV. Welche Herausforderungen treten bei der Skalierung von Symbolen und Mustern auf, und können diese mithilfe von KI gelöst werden?

Bei der Skalierung von Symbolen und Mustern gibt es mehrere Faktoren zu beachten, die innerhalb von Kapitel 2.5 behandelt wurden. Es sollte eine **Stilkohärenz** bestehen. Diese kann durch **harmonische, semantische und einheitliche Farben** sowie einheitlichen Symbolgrößen umgesetzt werden.

- Um diesen Punkt mithilfe von KI umzusetzen, können innerhalb des entworfenen Masterprompts hex **Farbwerte** angegeben werden, um einheitliche Farben zu definieren. Innerhalb eines Musters oder Symbols kann beim Übergang von Maßstabsstufen „generisch (generic)“ als Stichwort beim prompten, sowie eine konsistente Farbpalette („consistent colour palette“) und ein identischer Stil („use the same style“) angegeben werden, was zu einheitlicheren und stilkohärenteren Ergebnissen führt. Falls es bereits eine Basiskarte gibt, in der die Symbole und Muster integriert werden soll, kann diese als Referenz für einen Stil oder LoD genutzt werden (Tab. 30).

Um zu definieren, wann sich Symbole und Muster ändern, kann vorher ein **MasterScale Diagramm** erstellt werden, welches definiert, was sich bei welcher Zoomstufe an einem Symbol oder Muster verändern soll (Kapitel 2.5.1). Innerhalb dieses Prozesses sollten speziell die beiden Multi-Scale-Aspekte „Decision Point“ (wann sich ein Symbol, Muster aufgrund einer Zoomstufe ändert) und „Ankerpunkte“ zur Orientierung mit einbezogen werden.

- Der Decision Point kann **innerhalb der KI miteinbezogen** werden, je nachdem wie viele Detailstufen es von einem Symbol oder Muster geben soll. Die **KI kann dabei helfen, den Übergang von einem einfachen Symbol zu einem detaillierten** und andersherum **fließend zu gestalten**. Dadurch werden gleichzeitig **Ankerpunkte geschaffen**, die für die Orientierung innerhalb einer Multi-Scale-Karte wichtig sind. Diese kommen vor allem nach dem Generierungsprozess in der Testumgebung zum Tragen, dafür sollten Symbole und Muster, die nah beieinander liegen nicht gleichzeitig ein- und ausgeblendet werden, damit genug Orientierung vorhanden bleibt. Der von der KI fließende Übergang hilft dabei den „Desert fog effect“ zu vermeiden, der bei Multi-Scale-Karten auftreten kann, Symbole und Muster sollen weiterhin erkennbar bleiben.

Ein weiterer Aspekt, der bei Multi-Scale-Karten zum Einsatz kommt, ist das **LoD**, sowie das **LoA**. Sie definieren das **Detail- und Abstraktionslevel** innerhalb von Multi-Scale-Karten und sollten vor der Erstellung einer Kartenanwendung definiert werden (Kapitel 2.5.3).

- KI kann dabei helfen, für verschiedene Zoomstufen Symbole und Muster zu erzeugen und damit die LoD der späteren Karte definieren. Zusätzlich gibt es das LoA, diese Level können innerhalb des Pre-Prompts festgelegt werden (siehe Tab. 22) und die KI kann Symbole und Muster anhand daran *im passenden Abstraktionsgrad* generieren. Beim erstellten Masterprompt beispielsweise drei Abstraktionslevel, die aber auch auf zwei oder eines (Tab. 29) reduziert werden können.
- **FF: Wie kann Generative KI eingesetzt werden, um die Symbol- und Mustergenerierung für Multi-Scale-Karten zu optimieren?**

KI kann als ein *hilfreiches Tool* verwendet werden, um die *Übergänge von einfachen zu detaillierten Symbolen und Mustern* zu gestalten.

In klassischen Printkarten, sowie kontemporären Webkarten wurden Kartenelemente entweder *manuell innerhalb von Graphikprogrammen* erstellt oder auf vorhandene Signaturenkataloge zurückgegriffen. Innerhalb der letzten Jahre kam durch das Thema der *KI eine neue Möglichkeit* der Generierung von Kartenelementen auf. Diese wurde in Bezug auf Symbole getestet und hat sich speziell bei thematischen Karten, sowie einem festen Maßstab zu verwendbaren, als gesamtes betrachtet funktionierenden Karteninhalten herausgestellt.

Diese bisherigen Symbolerstellung wurden für Modelltests als Grundlage herangezogen und auf Muster übertragen und detailliert auf Multi-Scale-Anforderungen getestet. Durch den Workflow wird bisheriges Vorgehen *optimiert*, indem es Zeit spart, im Vergleich zu klassischen Erstellungsmethoden innerhalb von Vektorprogrammen. Es können zudem *kreativere und individuellere Karteninhalte* generiert werden, als wenn auf bereits erstellte Signaturenkataloge zurückgegriffen wird. *Hohe Zoomstufen* können durch das Vorgehen mit *konkretem und detailliertem Inhalt* befüllt werden und durch eine größere Darstellung zusätzliche Orientierung schaffen (6.1 und Abb. 46 unten). Mithilfe des erstellten Workflows ist es zudem möglich über mehrere Zoomstufen hinweg *konsistente Kartenelemente* zu erstellen, ein Punkt, der bei bisherigen Veröffentlichungen nicht im Fokus stand (1.1).

Zudem können mithilfe der generativen KI, spezieller mittels des Masterprompts *Multi-Scale-Herausforderungen direkt innerhalb eines Outputs* berücksichtigt werden, wie ein fließender Übergang der Symbole einheitliche Farben und Ankerpunkte, im Vergleich zu der bisherigen *einzelnen Generierung* von Symbolen.

Dennoch gibt es zum aktuellen Zeitpunkt gewisse Limitationen, wie qualitative Unterschiede der Ergebnisse, je nachdem welche Modelle verwendet werden und trotz detaillierter Promptanforderungen kann es unerwartete Ergebnisse geben. Es hat sich zusätzlich gezeigt, dass Muster schwieriger zu generieren sind und in der Nachbearbeitung zu neuen Fragestellungen führen (Abb. 39). Eine *menschliche Überprüfung der Ergebnisse*, stellt aktuell noch einen wichtigen Teil des Workflows dar.

7.2 Zukunftsausblick

Während der Arbeit innerhalb der Testumgebung, haben sich weitere zu beachtende **Einflussfaktoren und Erkenntnisse** im Zuge von Multi-Scale-Anwendungen und der Arbeit mit KI herausgestellt, die für zukünftige Forschungen relevant sein könnten.

Ein Punkt, den es bei KI generierten Kartenelementen zu beachten gibt, ist der **subjektive Faktor** und die Beurteilung von späteren NutzerInnen einer erstellten Kartenanwendung. Um möglichst affektive und funktionale Symbole zu erstellen, wurden durch spezifische Multi-Scale-Kriterien **mögliche Herausforderungen und Risikofaktoren eingegrenzt**. Dennoch wäre eine direkte Einordnung oder ein direkter Vergleich mit herkömmlichen Kartensymbolen und Mustern in der Zukunft interessant, um psychologische Auswirkungen und die ästhetische Wahrnehmung von KI-generierten speziell in Bezug auf Multi-Scale-Aspekte **empirisch** (z.B. mittels **Umfragen**) zu untersuchen und falls nötig **Elemente daran anzupassen** (siehe kartographisches Kommunikationsmodell 2.1.3).

Zusätzlich hat sich die Frage ergeben, **wann es sinnvoll ist Symbole und Muster in verschiedenen Detailgraden darzustellen**. Beispielsweise bei einem Kaffeesymbol (als Kaffeetasse) oder einem oder einem Parkplatz Logo transportiert ein detailliertes Symbol die Information (und Orientierung) nicht unbedingt besser. Bei Gebäuden wiederum kann es schon hilfreich sein, wenn die Silhouette detaillierter wird. Zusätzlich kommt es bei der Entscheidung auf das Gebiet an, **Landsymbole** bieten beispielsweise meistens **mehr Platz als urbane** Symbole, die in dichten Städten mit vielen anderen Symbolen nebeneinander weniger Platz zur Verfügung haben. Zusätzlich kann es bei landschaftlichen Symbolen ein **ästhetischer Aspekt** sein, die Karte mit mehr Details auszufüllen.

Eine weitere neue Anforderung dabei ist auch, wie höhere Zoomstufen bei Flächen **natürlich gestaltet** werden können. Wie in Kapitel 4.3 beschrieben, kann ein Waldmuster, durch **harte Polygonkanten** unnatürlich und aussehen und sich dadurch nicht gut in die restliche Kartenumgebung integrieren. Durch Transparenz und Farbwahl, sowie MapLibre spezifischen Tools (Line Pattern) konnte dieser Übergang innerhalb der Testumgebung bereits natürlicher gestaltet werden, welches einen **Lösungsvorschlag** für Herausforderungen dieser Art darstellt, jedoch in Zukunft noch genauer betrachtet werden könnte.

Bei sehr detaillierten Symbolen, muss beachtet werden, dass ein Symbol **generisch** bleibt. Speziell bei Gebäuden, die mit einem bestimmten aussehen verbunden werden, wie einem Rathaus, sollte das Symbol zwar detailliert, aber dennoch für verschiedene Städte **universell nutzbar** bleiben. Zum Beispiel für das Wiener Rathaus könnte es verwirrend sein, wenn bei hoher Zoomstufe das Symbol sehr detailliert wird, aber dann nicht so aussieht wie das spezielle Rathaus, weil es zusätzlich für das Rathaus anderer Städte und Dörfer gültig sein muss. In zukünftiger Forschung könnten diese Fragen in den Fokus gestellt werden.

Es hat sich zudem gezeigt, dass es für eine **Karte mit niedriger Zoomstufe** und einzelnen **priorisierten Symbolen**, die durch einen **weißen Rand** hervorgehoben werden, bei dem

Übergang zu einer **hohen Zoomstufe**, in der die Symbole „**echter**“ aussehen sollen, der Rand entfernt werden muss, damit die Symbole sich natürlicher in die Umgebung integrieren. Dabei muss noch spezifischer auf **mögliche kognitive Überladungen** Rücksicht genommen werden. Dafür wurde innerhalb der Testumgebung darauf geachtet, die Symbole innerhalb der Zoomstufe, bei der der Rand entfernt wird, kaum bis gar nicht äußerlich zu verändern und erst danach detaillierter zu werden (siehe Kapitel 5.1, (Dumont et al., 2020).

Die schnelle Entwicklung von KI-Modellen führt dazu, dass diese Arbeit eine **Momentaufnahme** ist. Die Erkenntnisse, welche Aspekte für funktionale Symbole und Muster innerhalb einer Multi-Scale-Karte zu beachten sind, könnten als Input für neue Modelle genutzt werden und erzeugen mit der Weiterentwicklung der Modelle eventuell noch generischere Ergebnisse. Ein Fokus könnte auf **Agenten als Tool** gelegt werden, basierend auf den gesammelten Erkenntnissen und Anforderungen an eine Multi-Scale-Umgebung.

In den kommenden Jahren könnten fachbereichsspezifische KI-Modelle ein Thema werden, was Updates zu dieser Arbeit interessant machen würden, beispielsweise mit einem Fokus auf **kartographischen Trainingsdaten**. In Kombination mit Funktionen, die aktuell nur wenige Modelle können, wie dem Freistellen, nahtlosen Übergängen bei Mustern würden aktuell nötige Nachbearbeitungsschritte wegfallen und den Workflow einfacher machen.

Zudem haben Promptübertragungen Ergebnisse geliefert, die teilweise noch weitere **modellspezifische Anpassungen** benötigen, um für eine Karte genutzt werden zu können. Dadurch das **Muster** im Vergleich zu ersten Symboltests noch ein weniger erforschter Bereich im Zuge von KI-Generierung sind, könnte es dazu spezifischere Forschung geben. **Modellbezogen** könnten in Zukunft **MLLMs** fokussiert für kartographische Zwecke getestet werden.

Wie in der Einleitung bereits erwähnt, nimmt KI eine immer größere Rolle in der kartographischen Berufswelt ein. Die **Stärken und Schwächen** dieser zu kennen und sie für sich zu nutzen, kann im Zuge von bestimmten Prozessen Zeit ersparen und Arbeitsschritte vereinfachen. Es ist von Bedeutung, dass **grundlegendes kartographisches Wissen nicht verlorenght**, damit die Entscheidungen über den Einsatz und daran geknüpften Auswirkungen bei Kartenelementen speziell im digitalen Bereich auf wissenschaftlich fundierten Erkenntnissen beruhen.

Diese Arbeit bietet durch die Nutzung von KI einen Mehrwert, in dem sie eine **Brücke für den schrumpfenden Bereich der klassischen Kartographie** schafft und den in der digitalen Arbeitswelt zunehmend wichtiger werdenden KI-Einsatz mit kartographischen Grundlagen verbindet, um funktionale Symbole- und Muster für Multi-Scale-Karten zu erstellen.

8 Literaturverzeichnis

- AI Seamless Pattern Generator for Textile & Fashion* | *PatternedAI*. (o. J.). Abgerufen 22. März 2026, von <https://www.patterned.ai/>
- Bertin, J. (o. J.). *Graphische Semiologie (1967)I*.
- Bildverständnis* | *Gemini API* | *Google AI for Developers*. (o. J.). Abgerufen 10. Januar 2026, von <https://ai.google.dev/gemini-api/docs/image-understanding?hl=de>
- Bischoff, G. (2026, April 28). *glenys-geo/map_symbol_pattern_AI_workflow-: Sprite testing environment for symbols and patterns (png as input files)*. GitHub. https://github.com/glenys-geo/map_symbol_pattern_AI_workflow-
- Brewer, C. A. (1999). Color Use Guidelines for Mapping and Visualization. In *Modern Cartography Series* (S. 123–147). <https://doi.org/10.1016/B978-0-08-042415-6.50014-4>
- Brewer, C. A., & Battenfield, B. P. (2010). Mastering map scale: Balancing workloads using display and geometry change in multi-scale mapping. *GeoInformatica*, 14(2), 221–239. <https://doi.org/10.1007/s10707-009-0083-6>
- Buchner, J. (2026). *JohannesBuchner/imagehash* [Python]. <https://github.com/JohannesBuchner/imagehash> (Ursprünglich erschienen 2013)
- Burghardt, D., Dunkel, A., Stillein, M., & Techt, R. (2025). (PDF) Applications of generative methods in cartography on the example of creating pictorial maps. *ResearchGate*. <https://doi.org/10.5194/ica-abs-10-27-2025>
- CartoAgent/research/README.md at main · GISense/CartoAgent · GitHub*. (o. J.). Abgerufen 5. Januar 2026, von <https://github.com/GISense/CartoAgent/blob/main/research/README.md>
- ChatGPT - DALL·E*. (o. J.). ChatGPT. Abgerufen 17. März 2026, von <https://chatgpt.com/de-DE/>

- Christophe, S., Mermet, Samuel, Laurent, Morgan, & Touya, G. (2022). Neural map style transfer exploration with GANs. *International Journal of Cartography*, 8(1), Article 1. <https://doi.org/10.1080/23729333.2022.2031554>
- Claude. (o. J.). Claude. Abgerufen 21. März 2026, von <https://claude.ai/new>
- CLI – Codex | OpenAI Developers. (o. J.). Abgerufen 24. März 2026, von <https://developers.openai.com/codex/cli/>
- Convert PNG, JPG files to SVG vectors online—Vectorizer.AI. (o. J.). Abgerufen 5. Januar 2026, von <https://vectorizer.ai/>
- DALL-E & ChatGPT: A Trick to Recreating Specific Images Using Seeds - Prompting. (2023, November 3). OpenAI Developer Community. <https://community.openai.com/t/dall-e-chatgpt-a-trick-to-recreating-specific-images-using-seeds/445565?page=3>
- Draw.io. (o. J.). Abgerufen 11. April 2026, von <https://www.drawio.com/>
- Drews, J., Weißmann, M., Keil, J., Dickmann, F., & Edler, D. (2025). A New AI Tool for the Design of Cartographic Pictograms (PictoAI) and Its Potentials for Increasing Their Meaningfulness. *KN - Journal of Cartography and Geographic Information*, 75(1), 23–35. <https://doi.org/10.1007/s42489-024-00183-9>
- Dumont, M., Touya, G., & Duchene, C. (2016). A comparative study of existing multi-scale maps: What content at which scale? *International Conference on GIScience Short Paper Proceedings, 1*. <https://doi.org/10.21433/B3112993D46>
- Dumont, M., Touya, G., & Duchêne, C. (2020). Designing Multi-Scale Maps: Lessons Learned from Existing Practices. *International Journal of Cartography*, 6. <https://doi.org/10.1080/23729333.2020.1717832>
- Dunkel, A., Burghardt, D., & Gugulica, M. (2024). Generative Text-to-Image Diffusion for Automated Map Production Based on Geosocial Media Data. *KN - Journal of Cartography and Geographic Information*, 74(1), 3–15. <https://doi.org/10.1007/s42489-024-00159-9>

- Dunkel, A., Dunkel, A., & Gugulica, M. (2023). *Supplementary materials for the publication „Generative text-to-image diffusion for map creation based on geosocial media data.“* [Text]. Technische Universität Dresden. <https://doi.org/10.25532/OPARA-253>
- Einführung von ChatGPT Bilder 2.0. (o. J.). OpenAI. Abgerufen 28. April 2026, von <https://openai.com/de-DE/index/introducing-chatgpt-images-2-0/>
- Ekin, S. (2023). (PDF) *Prompt Engineering For ChatGPT: A Quick Guide To Techniques, Tips, And Best Practices.* ResearchGate. <https://doi.org/10.36227/techrxiv.22683919>
- Elias, B., Paelke, V., & Kuhnt, S. (2005). *Concepts for the Cartographic Visualization of Landmarks.*
- Entdecke GPT-5.2 | OpenAI. (o. J.). Abgerufen 24. März 2026, von <https://openai.com/de-DE/index/introducing-gpt-5-2/>
- Ero, Z. (2026). *Hyperknot/openfreemap-styles* [Python]. <https://github.com/hyperknot/openfreemap-styles> (Ursprünglich erschienen 2023)
- Esri, Inc., & Bell, S. (2020). Map Icon Design. *Geographic Information Science & Technology Body of Knowledge*, 2020(Q1). <https://doi.org/10.22224/gistbok/2020.1.6>
- Fabrikant, S. I., Christophe, S., Papastefanou, G., & Lanini-Maggi, S. (2012). *Emotional response to map design aesthetics.* <https://doi.org/10.5167/UZH-71701>
- Gartner, G., Ignateva, O., Zhunis, B., & Pühringer, J. (2024). Conceptualizing and Validating the Trustworthiness of Maps through an Empirical Study on the Influence of Cultural Background on Map Design Perception. *ISPRS International Journal of Geo-Information*, 13(2), Article 2. <https://doi.org/10.3390/ijgi13020039>
- Gatis, D. (2025). *Rembg* (Version 2.0.66) [Python]. <https://github.com/danielgatis/rembg> (Ursprünglich erschienen 2020)

- Gatys, L. A., Ecker, A. S., & Bethge, M. (2016). Image Style Transfer Using Convolutional Neural Networks. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2414–2423. <https://doi.org/10.1109/CVPR.2016.265>
- GitHub—Stevage/mbsprite: Command line utilities for exploding/bundling Mapbox GL spritesheets · GitHub. (o. J.). Abgerufen 21. März 2026, von <https://github.com/stevage/mbsprite>
- Google Maps. (2025, Mai 5). Google Maps. https://www.google.at/maps/@48.2045406,16.3797398,19.29z?authuser=1&entry=tu&g_ep=EgoyMDI1MDQzMCAxIKXMDSOASAFQAw%3D%3D
- Grundelemente der Karte. (2013, August 18). *nationalatlas.de*. https://www.nationalatlas.de/?page_id=45
- Hake, G., Grünreich, D., & Meng, L. (2002). *Kartographie: Visualisierung raum-zeitlicher Informationen*. De Gruyter. <https://doi.org/10.1515/9783110870572>
- Hu, T., Liu, T., Divyacharan Jarugumalli, V. S., Cheng, S., & Deng, C. (2025). FAIR principles in workflows: A GIScience workflow management system for reproducible and replicable studies. *International Journal of Applied Earth Observation and Geoinformation*, 138, 104477. <https://doi.org/10.1016/j.jag.2025.104477>
- IG, A. (2026). *Rtmigo/img2texture* [Python]. <https://github.com/rtmigo/img2texture> (Ursprünglich erschienen 2021)
- Image generation | OpenAI API. (o. J.). Abgerufen 18. März 2026, von <https://developers.openai.com/api/docs/guides/tools-image-generation/>
- Images Playground—OpenAI API. (o. J.). Abgerufen 21. März 2026, von <https://platform.openai.com>
- imagico.de—About me. (o. J.). Abgerufen 6. Januar 2026, von https://imagico.de/person_en.php

- imagico.de—Periodic dot and symbol pattern generator*. (o. J.). Abgerufen 6. Januar 2026, von <https://imagico.de/map/jsdotpattern.php>
- Interpolate*. (o. J.). Abgerufen 28. April 2026, von <https://maplibre.org/maplibre-compose/api/lib/maplibre-compose/org.maplibre.compose.expressions.dsl/interpolate.html>
- Jul, S., & Furnas, G. W. (1998). Critical zones in desert fog: Aids to multiscale navigation. *Proceedings of the 11th annual ACM symposium on User interface software and technology, UIST '98*, 97–106. <https://doi.org/10.1145/288392.288578>
- Kang, Y., Gao, S., & Roth, R. E. (2019). Transferring multiscale map styles using generative adversarial networks. *International Journal of Cartography*, 5(2–3), Article 2–3. <https://doi.org/10.1080/23729333.2019.1615729>
- Kang, Y., Gao, Song, & Roth, R. E. (2024). Artificial intelligence studies in cartography: A review and synthesis of methods, applications, and ethics. *Cartography and Geographic Information Science*, 51(4), Article 4. <https://doi.org/10.1080/15230406.2023.2295943>
- Kang, Y., & Wang, C. (2025). *Envisioning Generative Artificial Intelligence in Cartography and Mapmaking*. <https://doi.org/10.48550/arXiv.2508.09028>
- Kang, Y., Zhang, Q., & Roth, R. (2023). *The Ethics of AI-Generated Maps: A Study of DALLÉ 2 and Implications for Cartography* (arXiv:2304.10743). arXiv. <https://doi.org/10.48550/arXiv.2304.10743>
- Kent, A. J. (2018). Form Follows Feedback: Rethinking Cartographic Communication. *Westminster Papers in Communication and Culture*, 13(2), Article 2. <https://doi.org/10.16997/wpsc.296>
- Kent, A. J., & Vujakovic, P. (2018). *The Routledge handbook of mapping and cartography*. Routledge.

- Kent, A., & Vujakovic, P. (2009). Stylistic Diversity in European State 1: 50 000 Topographic Maps. *Cartographic Journal The*, 46, 179–213.
<https://doi.org/10.1179/000870409X12488753453453>
- Kim, E., Isozaki, I., Sirkin, N., & Robson, M. (2024). *Generative Artificial Intelligence Reproducibility and Consensus* (arXiv:2307.01898). arXiv.
<https://doi.org/10.48550/arXiv.2307.01898>
- KI-Monitor. (o. J.). Digital Austria. Abgerufen 7. Dezember 2025, von <https://www.digitalaustria.gv.at/themen/kuenstliche-intelligenz/ki-monitor.html>
- Klettner, S. (2020). Affective Communication of Map Symbols: A Semantic Differential Analysis. *ISPRS International Journal of Geo-Information*, 9(5), Article 5.
<https://doi.org/10.3390/ijgi9050289>
- Koch, W. G. (2001). Jaques Bertins theory of graphics and its development and influence on multimedia cartography. *Information Design Journal*, 10(1), Article 1.
<https://doi.org/10.1075/idj.10.1.07koc>
- La Licata, M., Bosino, A., De Amicis, M., Terret, A., & Maerker, M. (2025). A GIS-based multiscale mapping framework to assess and visualize complex and polygenetic geomorphic systems – A novel ‘Geomorphic Entities’ approach. *Journal of Maps*, 21(1), Article 1. <https://doi.org/10.1080/17445647.2024.2437256>
- Lai, P.-C., & Yeh, A. G.-O. (2004). Assessing the Effectiveness of Dynamic Symbols in Cartographic Communication. *The Cartographic Journal*, 41(3), 229–244.
<https://doi.org/10.1179/000870404X13300>
- Language (CWL), C. W. (o. J.). *Home*. Common Workflow Language (CWL). Abgerufen 4. Juli 2025, von <https://www.commonwl.org/>
- Liu, V., & Chilton, L. B. (2023). *Design Guidelines for Prompt Engineering Text-to-Image Generative Models* (arXiv:2109.06977). arXiv.
<https://doi.org/10.48550/arXiv.2109.06977>

- MacEachren, A. M. (2004). *How Maps Work: Representation, Visualization, and Design*. Guilford Press.
- Maki Icons* | By Mapbox. (o. J.). Abgerufen 15. November 2025, von <https://labs.mapbox.com/maki-icons/editor/>
- Maplibre-strategy-2023*. (o. J.).
- Memduhoğlu, A. (2025). Towards AI-Assisted Mapmaking: Assessing the Capabilities of GPT-4o in Cartographic Design. *ISPRS International Journal of Geo-Information*, 14(1), 35. <https://doi.org/10.3390/ijgi14010035>
- Mericskay, B. (2024). *Cartographic Communication: Graphic Semiology, Semiotics and Geovisualization*. John Wiley & Sons.
- Mo, W., Zhang, T., Bai, Y., Su, B., Wen, J.-R., & Yang, Q. (o. J.). *Dynamic Prompt Optimizing for Text-to-Image Generation*.
- Nano Banana 2: Pro-Funktionen kombiniert mit blitzschneller Geschwindigkeit*. (o. J.). Abgerufen 4. März 2026, von <https://blog.google/intl/de-de/produkte/suchen-entdecken/nano-banana-2-launch/>
- Nestel, C. (2019). Design and Aesthetics. *Geographic Information Science & Technology Body of Knowledge, University of Wisconsin*, 2019(Q4). <https://doi.org/10.22224/gistbok/2019.4.14>
- Ogezi, M., & Shi, N. (2024). *Optimizing Negative Prompts for Enhanced Aesthetics and Fidelity in Text-To-Image Generation* (arXiv:2403.07605). arXiv. <https://doi.org/10.48550/arXiv.2403.07605>
- OpenFreeMap Quick Start Guide*. (o. J.). Abgerufen 18. April 2026, von https://openfreemap.org/quick_start/
- OpenStreetMap*. (2025, Mai 5). OpenStreetMap. <https://www.openstreetmap.org/>
- Osgood, C. E. (2019). *Focus on Meaning: Vol 1: Explorations in Semantic Space* (2nd printing. Reprint 2019). De Gruyter Mouton. <https://doi.org/10.1515/9783110811179>

- OSM Bright. (o. J.). Demotiles. Abgerufen 18. April 2026, von <http://demotiles.maplibre.org/styles/osm-bright-gl-style/>
- Overpass turbo. (o. J.). Abgerufen 21. März 2026, von <https://overpass-turbo.eu/>
- Prestby, T. J. (2024). Measuring trust in maps: Development and evaluation of the MAPTRUST scale. *International Journal of Geographical Information Science*, 38(10), 2083–2107. <https://doi.org/10.1080/13658816.2024.2370076>
- Proschofsky, A. (2026, Februar 15). *GPT-4o: OpenAI dreht sein gefährlichstes KI-Modell ab, und die Empörung ist groß.* DER STANDARD. <https://www.derstandard.at/story/3000000308617/gpt-4o-openai-dreht-seine-gefaehrlichstes-ki-modell-ab-und-die-empoeerung-ist-gross>
- Ribeiro, D., Caquard, S., & Concordia University. (2018). Cartography and Art. *Geographic Information Science & Technology Body of Knowledge*, 2018(Q1). <https://doi.org/10.22224/gistbok/2018.1.4>
- Riggott, M. (2026). *Spreet* [Rust]. <https://github.com/flother/spreet> (Ursprünglich erschienen 2022)
- Roth, R. (2017). *Visual Variables* (S. 1–11). <https://doi.org/10.1002/9781118786352.wbieg0761>
- Roth, R. E., Brewer, C. A., & Stryker, M. S. (2011). A typology of operators for maintaining legible map designs at multiple scales. *Cartographic Perspectives*, (68), 29–64. <https://doi.org/10.14714/CP68.7>
- Saints Lab. (2025). *Saintslab/carbontracker* [Python]. <https://github.com/saintslab/carbontracker> (Ursprünglich erschienen 2020)
- Schut, L., Gal, Y., & Farquhar, S. (2025). *Do Multilingual LLMs Think In English?* (arXiv:2502.15603). arXiv. <https://doi.org/10.48550/arXiv.2502.15603>
- Seedream 5.0 Lite Official API | Start for free. (o. J.). Abgerufen 10. März 2026, von <https://www.byteplus.com/en/product/Seedream>

- Seedream AI - Free Online AI Image Generator & Photo Editor*. (o. J.). Seedream AI. Abgerufen 10. März 2026, von <https://seedream.pro/>
- Sengar, S. S., Hasan, A. B., Kumar, S., & Carroll, F. (2025). Generative artificial intelligence: A systematic review and applications. *Multimedia Tools and Applications*, 84(21), 23661–23700. <https://doi.org/10.1007/s11042-024-20016-1>
- Sources—MapLibre Style Spec*. (o. J.). Abgerufen 26. April 2026, von <https://maplibre.org/maplibre-style-spec/sources/>
- Spaccapietra, S., Parent, C., & Vangenot, C. (2000). GIS Databases: From Multiscale to MultiRepresentation. In B. Y. Choueiry & T. Walsh (Hrsg.), *Abstraction, Reformulation, and Approximation* (Bd. 1864, S. 57–70). Springer Berlin Heidelberg. https://doi.org/10.1007/3-540-44914-0_4
- Sprite | Mapbox Style Spec | Mapbox Docs*. (o. J.). Mapbox. Abgerufen 9. Mai 2025, von <https://docs.mapbox.com//style-spec/reference/sprite>
- Sprite—MapLibre Style Spec*. (o. J.). Abgerufen 23. Februar 2026, von <https://maplibre.org/maplibre-style-spec/sprite/>
- Style Specifications—MapLibre GL JS*. (o. J.). Abgerufen 15. November 2025, von <https://www.maplibre.org/maplibre-gl-js/docs/style-spec/>
- Text to Image Leaderboard—Top AI Image Models*. (o. J.). Abgerufen 26. Februar 2026, von <https://artificialanalysis.ai/image/leaderboard/text-to-image>
- Vivekananthan, S. (2024). *Comparative Analysis of Generative Models: Enhancing Image Synthesis with VAEs, GANs, and Stable Diffusion* (arXiv:2408.08751). arXiv. <https://doi.org/10.48550/arXiv.2408.08751>
- Wang, C., Kang, Y., Gong, Z., Zhao, P., Feng, Y., Zhang, W., & Li, G. (2025). *CartoAgent: A multimodal large language model-powered multi-agent cartographic framework for map style transfer and evaluation* (arXiv:2505.09936). arXiv. <https://doi.org/10.48550/arXiv.2505.09936>

- White, T. (2017). Symbolization and the Visual Variables. *Geographic Information Science & Technology Body of Knowledge*, 2017(Q2).
<https://doi.org/10.22224/gistbok/2017.2.3>
- Yan, X., Yang ,Min, & and Ai, T. (2025). Deep learning in automatic map generalization: Achievements and challenges. *Geo-spatial Information Science*, 0(0), Article 0.
<https://doi.org/10.1080/10095020.2025.2480815>
- Ye, Y., Hao, J., Hou, Y., Wang, Z., Xiao, S., Luo, Y., & Zeng, W. (2024). Generative AI for visualization: State of the art and future directions. *Visual Informatics*, 8(2), Article 2. <https://doi.org/10.1016/j.visinf.2024.04.003>
- Zoom levels and scale | Documentation | Esri Developer*. (o. J.). Documentation. Abgerufen 9. Juni 2025, von <https://developers.arcgis.com/documentation/mapping-and-location-services/reference/zoom-levels-and-scale/>

9 Anhang

Anhangsverzeichnis

Anhang 01: KI-Auswahl	117
1.1 Modelle, die nicht miteinbezogen wurden:	118
1.2 Contra Aktualität und Fokus einiger Modelle:	122
Anhang 02: Transparenter Hintergrund und SVG-Erstellung Tests	123
Anhang 03: Symbol- und Mustergenerierung	127
Anhang 04: Promptübertragung auf weitere KI-Modelle (Bezug zu Kapitel 5.2 und 6.2)	127
4.1 MLLM - Gemini: Nano Banana 2	127
4.2 LLM - Qwen	128
4.3 Diffusion Modell - Stable Diffusion	128
4.4 Übersicht Promptübertragung Mastermusterprompt auf weitere Modelle	130

Abbildungsverzeichnis Anhang

Abbildung 1: Generierte Bilder mit DALLÉ 3 über ChatGPT und der dabei erschienene Hinweis.	122
Abbildung 2: Transparenter Hintergrund und SVG-Erstellung - Übersichtstabelle mit Screenshots und Inputdatei im Vergleich.	125
Abbildung 3: Versuch 01: Direkte Erstellung des SVGs mit angepasstem Basisprompt.	126
Abbildung 4: Versuch 02: GPT-I: Original generierter Output- Ausschnitt (Mitte) mit GPT-I Vektorisierung (links) im Vergleich mit Vektorisierung über Python Skript (rechts), jeweils 1024 x 1024 Pixel.	126
Abbildung 5: Promptübertragung innerhalb von Qwen, mit "weiß" als Hintergrund Beschreibung (links), sowie mit „Weiß“ und hexcode #ffff (rechts), eigene Darstellung generiert innerhalb von Qwen 3.6 Plus.	128

Tabellenverzeichnis Anhang

Tabelle 1: Genutzte Testprompts und das Vorgehen bei der Modellwahl mit gemachten Beobachtungen (eigene Darstellung).....	118
Tabelle 2: Modelle, die nicht miteinbezogen wurden in Modelltest mit Link, Begründung und Stand des Zugriffs (eigene Darstellung).	118
Tabelle 3: Detailliertere Übersicht über die Modellkriterien Datengrundlage und Urheberrecht mit Quellenlink, sowie Wasserzeichen (eigene Darstellung). ...	121
Tabelle 4: Übersicht der Testergebnisse für „Patterned A“I (eigene Darstellung).	122
Tabelle 5: Angepasster angepasst Masterprompt für einzelne Symbole (erstellt mit GPT-I, eigene Darstellung).....	127
Tabelle 6: Promptübertragung, zu beachtete Anpassungen für Nano Banana 2 (Symbole generiert über Gemini), eigene Darstellung.....	128
Tabelle 7: Promptübertragung - Stable Diffusion, Ergebnisse bei aufgeteiltem Masterprompt (eigene Darstellung, erstellt mittels Stable Diffusion Modell).	129
Tabelle 8: Promptübertragung - Stable Diffusion, teilweise fehlerhafte Ergebnisse mit Masterprompt (eigene Darstellung, erstellt mittels Stable Diffusion Modell).	130
Tabelle 9: Promptübertragung des Masterprompts für die Mustererstellung ohne modellspezifische Anpassungen (generiert mit Nano Banana 2, Qwen 3.6-Plus und Stable Diffusion), eigene Darstellung.....	130

Anhang 01: KI-Auswahl

Basierend auf Tabelle aus dem Hauptteil der Arbeit:

Für die KI-Auswahl wurden die Kriterien in einer Kurzvariante abgekürzt, damit die Tabelle nicht zu groß für den Hauptteil der Arbeit wird (siehe Tabelle 2 Hauptteil). Speziell relevant für die Frage: „Welche Generativen KI-Methoden gibt es in der Kartographie, die für Multi-Scale-Karten von Relevanz sein können?“.

Kriterium Abkürzung	Genutzter Testprompt/ Vorgehen	Beobachtungen
A	Getestet, ob ohne Anmeldung generiert werden kann.	Die Anmeldung ist bei fast allen Modellen notwendig, bei 3 geht es zwar ohne, 2 davon versprechen aber mehr Credits (Generierungen) bei einer Anmeldung.
B	PV04	Bei vier der getesteten Modelle nicht möglich (Imagen, MAI-Image 1, Seedream, Z-Image-Turbo).
Q	Outputs verglichen anhand der Pixelgröße mittels IrfanView.	Die Pixel sind einheitlich bei 1024 x1024 Pixeln, nur 3 Modelle stechen mit höherer Pixelanzahl raus, darunter Adobe Firefly, GPT-I und Qwen3-Max.
q	"Can you generate a tree symbol with 46x46 Pixel?"	Keins der getesteten Modelle mit Chatfunktion kann aktuell eine spezifische Pixel-Ausgabequalität erzeugen, sie ist immer einheitlich. Nur bei Z-Image-Turbo ist es mit einem Regler möglich, zumindest begrenzt zwischen 512 und 2048 Pixel für Höhe und Breite einzustellen.
C	Getestet, wie viele Bilder generiert werden können, bevor Credits aufgebraucht sind oder für eine festgelegte Zeit keine neuen Generierungen mehr möglich sind.	Von den getesteten Modellen gab es keins welches ohne Credits oder ein zeitliches Generierungslimit funktioniert hat.
D	Trainingsdatenherkunft recherchiert.	Zum Teil sehr schwammig auf den Seiten der Modelle aufgeführt und bis auf Adobe ("Zum Trainieren unserer KI-Modelle verwenden wir ausschließlich Content, für dessen Verwendung wir die Erlaubnis oder die Rechte haben.")
E	Getestet, ob die Outputs ohne Kosten heruntergeladen werden können.	Bei Flux und Imagen wurde die Plattform zwischendrin gewechselt, weil dort die Credits nicht aufgefüllt wurden. Ansonsten konnten zumindest bis zu einem bestimmten Punkt (siehe Credits) oder nach einer Wartezeit wieder Bilder generiert werden.
F	"Can you generate a tree symbol with a transparent background?"	Bis auf GPT-I schafft es kein Modell den Hintergrund freizustellen, entweder ist er weiß oder kariert und sieht nur so aus wie freigestellt.
K	Zumindest mehr als eine Generierung möglich?	Eine Generierung war bei allen getesteten Modellen möglich, jedoch wurde Midjourney als nicht mehr kostenfreies Modell von vorneherein ausschlossen und nur Modelle gewählt, die zumindest Tests zulassen.
N	Negativprompt eingehalten? Bezogen auf PV01neg	Große Abweichungen werden als "trifft nicht zu gewertet", z.B. ein weißer Hintergrund (Adobe Firefly, MAI-Image 1, Imagen).
R	Reproduzierbarkeit	5 Outputs miteinander verglichen, jeweils in neuem Chat und alten Output vorher gelöscht. Mittels pHash verglichen. https://GitHub.com/JohannesBuchner/imagehash

S	PV03		Bei fast allen ist zuerst der Stamm mit dargestellt, erst mit einer Klarstellung das dieser von oben nicht sichtbar sein sollte, wird nur die Krone dargestellt.
s	seed		Ist eine spezifische Seedangabe möglich (Eingabefeld)? Bzw. kann man den Seed eines Bildes abfragen und sich darauf beziehen (Chatmodelle)?
U	Urheberrechte kommerzielle recherchiert.	und Nutzung	Ebenso wie die Trainingsdaten zum Teil sehr schwer auffindbar, das einzige Modell, welches klar keine Rechte abgegeben hat ist Flux (Flux 2 Pro), ansonsten sind sie teilweise ausdrücklich gestattet (z.B. Adobe Firefly: "Feel confident creating content with Firefly generative AI models, knowing they're safe for commercial use")
V	"Can you make the leaves look more realistic, don't change anything else."		Bei mehreren Modellen war ein Bezugnehmen auf den vorher erstellten Output nicht möglich, z.B. bei z image turbo und Seedream wurde der Prompt als neuer Prompt behandelt und nur ein Blatt eines Baumes erstellt.

Tabelle 1: Genutzte Testprompts und das Vorgehen bei der Modellwahl mit gemachten Beobachtungen (eigene Darstellung).

1.1 Modelle, die nicht miteinbezogen wurden:

Modell name	Link	Begründung	Zugriff/ Stand
Aurora	https://hiaurora.ai/	nicht speziell für Bilder geeignet! Nur 30 Tage kostenfrei, Anmeldung nötig	Stand 24.02.2026
Midjourney	https://www.midjourney.com/home	aktuell nicht mehr kostenfrei	Stand 24.02.2026
LM-Studio	https://lmstudio.ai/models	bisher keine Bildgenerierung integriert (LLMs können lokal ausgeführt werden)	Stand 24.02.2026
Ollama	https://ollama.com/ https://ollama.com/blog/image-generation	Bildgenerierung aktuell nur für Mac möglich (neu möglich seit 20.01.2026) https://ollama.com/blog/image-generation	Stand 20.01.2026
Microsoft designer	https://www.bing.com/images/create	Microsoft Designer "Erstellung von Smbolen" DALLE 3 als Grundlage schon über ChatGPT abgedeckt. Zusätzlich über Microsoft Bing abrufbar, als Modellauswahl ChatGPT4o, DALLE 3 und neu MAI-Image-1 (welches getestet wurde), Chat GPT4o wird Stand 24.02.2026 abgeschaltet und scheint deshalb nicht langfristig geeignet zu sein: https://www.derstandard.at/story/3000000308617/gpt-4o-openai-dreht-seine-gefaehrlichstes-ki-modell-ab-und-die-empoeerung-ist-gross	Stand 24.02.2026
Perplexity AI	https://www.perplexity.ai/help-center/en/articles/10354781-generating-images-with-perplexity	Nur für persönlichen, nicht kommerziellen Gebrauch. Modelle: GPT-Image 1, Nano Banana, Seedream 4.0, and FLUX.1.	Zugriff 17.12.2025
Artlist	https://artlist.io/	Artlist Original 1.0 ist speziell für cinematische Zwecke, ansonsten werden andere Modelle gehostet.	Stand 24.02.2026

Tabelle 2: Modelle, die nicht miteinbezogen wurden in Modelltest mit Link, Begründung und Stand des Zugriffs (eigene Darstellung).

In der folgenden Tabelle wurde anhand der vorher festgelegten Kriterien KI-Modelle eingeordnet. Wenn ein Kriterium erfüllt ist, wurde das Feld grün markiert, zu Teil gelb, wenn nicht rot. Und wenn es aus anderen Gründen nicht möglich war zu bewerten, dann grau.

KI-Modell	Link	Beobachtung	Datengrundlage - Trainingsdatenherkunft	Urheberrechte	Wasserzeichen
Adobe Firefly (Firefly Image 4)	https://firefly.adobe.com/generate/image?promoid=NQCJQWSV&mv=other	Bearbeitung mit Version 4 nicht möglich, nur Version 5 als Vorschau. 10 Generierungen (1 Prompt generiert automatisch 4 Outputs).	"Zum Trainieren unserer KI-Modelle verwenden wir ausschließlich Content, für dessen Verwendung wir die Erlaubnis oder die Rechte haben."... "keine Urheberrechte/Rechte an geistigem Eigentum verletzen und Inhalte kommerziell und für Bildungszwecke nutzbar." https://www.adobe.com/de/ai/overview/firefly/gen-ai-approach.html	Feel confident creating content with Firefly generative AI models, knowing they're safe for commercial use. https://business.adobe.com/products/firefly-business/firefly-ai-approach.html	Nein
ChatGPT Bilder 1.5 ("Chatgpt Images")	https://chatgpt.com/images	Einziges Modell der getesteten, welches wirklich freigestellte Outputs generieren kann.	"pre-trained on a variety of data from publicly available sources. We apply quality filters to all datasets, using both heuristic rules and model-based classifiers. We also perform safety filtering to remove content likely to produce policy-violating outputs" https://gemini.google/az/overview/?hl=en	a) behalten Sie Ihre Inhaberrechte am Input und (b) stehen Ihnen die Rechte am Output zu. Wir treten hiermit alle unsere Rechte, Titel und Anteile, falls vorhanden, am und in Bezug auf den Output an Sie ab.	Nein
Dall-E 3 (über ChatGPT 5.2)	https://openai.com/de-DE/index/dall-e-3/	Contra: Versucht einen transparenten Hintergrund so aussehen zu lassen, aber ist nicht transparent. Pro: Elemente können mit einem Pinsel ausgewählt und entfernt werden.	"pre-trained on a variety of data from publicly available sources. We apply quality filters to all datasets, using both heuristic	a) behalten Sie Ihre Inhaberrechte am Input und (b) stehen Ihnen die Rechte am Output zu. Wir treten hiermit alle	Nein

			rules and model-based classifiers. We also perform safety filtering to remove content likely to produce policy-violating outputs” https://gemini.google/az/overview/?hl=en	unsere Rechte, Titel und Anteile, falls vorhanden, am und in Bezug auf den Output an Sie ab.	
Flux (Flux 2 Pro)	https://flux1.ai/home	10 Credits bei erster Anmeldung, 1 Bild = 6 Credits.		for private and non-commercial use	Ja
Imagen (über Google AI Studio)	https://aistudio.google.com/ https://deepmind.google/models/imagen/ https://docs.cloud.google.com/vertex-ai/docs/models/imagen/4-0-generate?hl=de	Negativsprompt nicht möglich, Stilanpassung, kontrollierte Anpassung nicht möglich. https://docs.cloud.google.com/vertex-ai/docs/models/imagen/4-0-generate?hl=de		Bei einigen unserer Dienste haben Sie die Möglichkeit, Originalinhalte zu erstellen. Google erhebt keinen Anspruch auf die Eigentumsrechte an diesen Inhalten. Sie erkennen an, dass Google die gleichen oder ähnliche Inhalte für andere Nutzer generieren kann und sich alle Rechte vorbehält, dies zu tun.	Nein
MAI-Image-1 (über Bing)**	https://www.bing.com/images/create?FORM=GENEXP	Kariierter Hintergrund anstatt transparent. Man kann sich nicht auf das vorher erstellte Symbol bei der Bearbeitung beziehen.		Die Onlinedienste und die generierten Kreationen dürfen ausschließlich wie folgt genutzt werden: (i) auf legale Weise und in Übereinstimmung mit geltendem Recht, (ii) im Einklang mit diesem Vertrag, den Verhaltensregeln, dem Microsoft-Servicevertrag oder anderen Microsoft-Dokumenten, die sich auf den Dienst beziehen, und (iii) in einer Weise, die weder unsere Rechte noch die Rechte anderer natürlicher oder juristischer Personen verletzt oder zu verletzen versucht und die nicht dazu dient, sich solche Rechte widerrechtlich anzueignen oder anderweitig	Nein

					gegen solche Rechte zu verstoßen.	
Nano Banana 2 (über Gemini)	https://gemini.google.com/app	Hintergrund weiß anstatt transparent.		"pre-trained from the start on different modalities. Then we fine-tuned it with additional multimodal data" https://cloud.google.com/blog/products/ai-machine-learning/nano-banana-pro-available-for-enterprise?hl=en	"Supporting your commercial needs: Both models fall under our shared responsibility framework, and you can ensure transparency and responsible use with built-in SynthID watermarking on every generated asset. We're committed to supporting your commercial needs with copyright indemnification coming at general availability."	Ja und zusätzlich ist Gemini dabei ein unsichtbares Wasserzeichen für generierten Kontext zu entwickeln namens SynthID. https://deepmind.google/models/synthid/
Qwen3-Max (Alibaba Cloud)	https://chat.qwen.ai	Wenn nicht speziell Bildgenerierung ausgewählt ist, wird Text vorgegeben für ein SVG-File zum Abspeichern, das ist transparent. Im Bildgenerierungsmodus wird ein Bild mit weißem Hintergrund erstellt.		Daten aus dem Web und PDF's https://qwen.ai/blog?id=qwen3	Apache 2.0-Lizenz (darf genutzt und weiterverarbeitet werden, aber Quellcode ist nicht öffentlich).	Nein
Seedream (old)	https://seedream.pro/	Hintergrund weiß anstatt transparent. Man kann sich nicht auf das vorher erstellte Symbol bei der Bearbeitung beziehen. Ohne Anmeldung möglich, aber es wird schnellere Generierung versprochen bei Anmeldung.			"Commercial usage is supported according to Terms of Service and your account usage policy." https://seedream.pro/	Nein
Stable Diffusion	https://stablediffusionweb.com/de/app/image-generator	Hintergrund entfernen ist ein extra KI-Modell, 1 Credit für ein Bild, 20 bei Accounterstellung zur Verfügung (Stand 16.02.2026). V= Ja, das erstellte Bild wird dann automatisch als Input (wie eine Vorlage) genommen. Wasserzeichen ist dabei.			CC0 1.0 Open Source https://stablediffusionweb.com/de	Ja
Z-Image-Turbo (über hugging face)	https://huggingface.co/spaces/mrfaken/ame/Z-Image-Turbo	Hintergrund weiß anstatt transparent. Man kann sich nicht auf das vorher erstellte Symbol bei der Bearbeitung beziehen. Qualität bis zu 2048x2048 einstellbar.			"Use your generated images for any purpose - commercial, personal, or educational. Full ownership of your creations." https://z-image-turbo.ai/about	Nein

Tabelle 3: Detailliertere Übersicht über die Modellkriterien Datengrundlage und Urheberrecht mit Quellenlink, sowie Wasserzeichen (eigene Darstellung).

1.2 Contra Aktualität und Fokus einiger Modelle:

- Imagen nicht mehr das aktuelle Modell von Google, innerhalb Geminis wird automatisch Nano Banana verwendet (es ersetzt Imagen an der Stelle). Nano Banana wird als "State of the art image generation model" bezeichnet. Selbst wenn im Chat angegeben wird, dass Imagen genutzt werden soll, wird automatisch Nano Banana aktiviert. Am Anfang der Modelltests (01.02.2026) über Google AI Studio kostenfrei, dann nur mit bezahlter API nutzbar (getestet 15.02.2026) (*Nano Banana 2: Pro-Funktionen kombiniert mit blitzschneller Geschwindigkeit*, o. J.)
- **DALLE3** wird von ChatGPT nicht als aktuelles Modell angegeben: "OpenAI's legacy image generation model. For our latest model, ask ChatGPT to create an image in the main chat." (<https://chatgpt.com/g/g-2fkFE8rbu-dall-e>)



Mit der alten Version zur Bildgenerierung erstellt. [Mehr erfahren](#)

Abbildung 1: Generierte Bilder mit DALLE 3 über ChatGPT und der dabei erschienene Hinweis.

- **MAI-Image-1** → Fokus auf fotorealistischen Bildern, dennoch mitgetestet (<https://microsoft.ai/news/introducing-mai-image-1-debuting-in-the-top-10-on-lmarena/>)
- **Patterned AI** → Tests durchgeführt, aber dann nicht weiterverwendet, Fokus zu sehr auf Muster für Textilien (*AI Seamless Pattern Generator for Textile & Fashion | PatternedAI*, o. J.).

KI-Modell	A*	B ¹	B ₂	Q	q	C	D	E	F	K	N	R	S	s	U	V	Ü
Patterned AI													1				

Tabelle 4: Übersicht der Testergebnisse für „Patterned A“ (eigene Darstellung).

Anhang 02: Transparenter Hintergrund und SVG-Erstellung Tests

Beide Varianten waren mittels des GitHub Tools (siehe Kapitel 4.1), welches PNG als Input für Sprite verarbeiten kann nicht mehr nötig, aber könnten für andere Modelle oder Vorgehen interessant sein, die Vektorgraphiken als Output liefern Um die Symbole und Muster freizustellen wurden mehrere Methoden getestet, speziell wurde darauf geachtet, dass **selbst bei kleiner Pixelanzahl klare Kanten** vorhanden waren und der (von der KI meist weiß erstellte) Hintergrund transparent war ohne unsauberen Rand. Dafür wurde die Pixelgröße 15x15 Pixel für Tests gewählt, da dabei das Symbol bzw. Muster stark vereinfacht werden muss. **Test 07 hat die besten Ergebnisse geliefert.**

Zwischenziel: Vorbereitung für Einbindung der generierten Ergebnisse in Testumgebung, detailliertere Dokumentation für Kapitel 4.1 (Skript mithilfe von Claude AI erstellt):

- freistellen (transparentes PNG)
- Vektorisieren (Potrace, Inkscape und vtracer getestet)
- Pixelgröße ändern je nach gewünschtem Maßstab, in welchem das Symbol später angezeigt werden soll. Qualität bestmöglich erhalten, selbst bei sehr kleiner Auflösung (Bsp. 15x15 Px)
- Im Test 15x15 Pixel getestet, weil dabei viele Bildinfos komprimiert werden müssen.

Test 01

- Symbole freistellen mit rembg und dann downsamplen mit vtrace, aber oft fehlerhaft zugeschnitten
- Hintergrund entfernen (rembg)
- PNG skalieren auf Pixelgröße (view Box anpassen)
- PNG zu SVG vektorisieren mit vtrace

Ergebnis: vtrace hat die Formen sehr abstrahiert

Test 02

- Hintergrund entfernen (rembg)
- PNG zu SVG vektorisieren mit potrace

Ergebnis: potrace hat die Formen besser erhalten aber nur in schwarz ohne die Farben

Test 03

- Inkscape über Kommandozeile

Ergebnis: eingebettetes Raster, keine echte Vektorisierung, bei SVG wird nichts angezeigt und im Spritefile ebenfalls nicht.

Test 04

- Vorgehen wie bei Test 01, aber zuerst das hochauflösende PNG mit vtrace vektorisiert und dann das SVG skaliert

Ergebnis: Farbliche Symbole, die eine gute Qualität haben, aber es gibt am Rand schwarze Striche/ Unsauberkeiten.

Test 05

- Das zuschneiden zu Beginn einmal weggelassen, um zu schauen, ob der schwarze Rand wegfällt und da das Problem liegt.

Ergebnis: saubere und klare Kanten ohne schwarzen Rand, aber der weiße Hintergrund natürlich noch vorhanden.

- rembg kann den Hintergrund nur vom PNG entfernen, nicht vom SVG, deshalb kann da die Reihenfolge nicht angepasst und getestet werden.

Test 06

- Parameter anpassen
- vtrace benutzt + rembg und dann Parameter angepasst um weichere Kurven als Ergebnis zu bekommen und den unsauberen Rand zu entfernen

Ergebnis: Rand war schon besser, aber dennoch eher unsauber, wie gezeichnet.

Test 07

- Am Ende den Hintergrund aus dem SVG rauslöschen, wenn eine Farbe explizit nicht vorhanden sein soll, wird sie automatisch durch einen transparenten Hintergrund ersetzt, deshalb den Weiß Wert #fffff rausgelöscht.
- Dabei festgestellt, dass Hintergrund des Bildes kein reines weiß ist -> weiße Farbskala, die rausgelöscht wird

Ergebnis: Bestes Ergebnis aller Tests, die Kanten sind scharf, kein schwarzer Rand und der weiße Hintergrund wurde komplett entfernt/ freigestellt

- vtracer: vektorisiert das PNG, welches noch die volle Auflösung hat
- remove_white_paths()
- scale_SVG()

Test 07 Für Muster geeignet?

- Für Muster das identische Vorgehen (Test 07) getestet

Ergebnis: Hat gut funktioniert, nur die Qualität muss höher sein als bei den Symbolen und damit überhaupt was erkannt wird, dürfen nicht zu viele Musterelemente auf einem "Tile" zu sehen sein.

Testversuchsnummer	nachher	vorher (*schwarzer Rahmen nur zur Erkennung der Bildgrenzen eingefügt)
Test 01		
Test 02		
Test 04		
Test 06		
Test 07		

*Test 03 hat keinen sichtbaren Output erzeugt, Test 05 identisch zu Test 07 nur ein weißer Bildrand. Test 04 und Test 06 zur Veranschaulichung zugeschnitten, damit der ungenaue Rand besser erkannt werden kann.

Abbildung 2: Transparenter Hintergrund und SVG-Erstellung - Übersichtstabelle mit Screenshots und Inputdatei im Vergleich.

SVG-Erstellung innerhalb des Chatmodells (Zwischentest):

Um sich eventuell den 1. Schritt, die Freistellung mit vtracer (siehe Kapitel 4.1) zu sparen, beziehungsweise mithilfe der KI durchzuführen wurde getestet, ob es möglich ist, es direkt innerhalb des Modells zu erstellen.

Eine SVG-Erstellung direkt in GPT-I wurde anhand von zwei Varianten getestet. Als erstes wurde anhand des Basisprompts zusammen mit der der Vorgabe ein SVG zu erzeugen der Output generiert. Das hat funktioniert, jedoch hat das Symbol deutlich weniger Details, als wenn es als speicherbares PNG im Chat erzeugt wird. Folgender Prompt wurde dafür genutzt: „*Can you generate a SVG-File with transparent background for a topographic map icon of a (single tree), high iconicity, centered, minimalistic, flat vector style, intuitive semantic colours, (green leaves, brown trunk). Suitable for high zoom levels.*“. Das Ergebnis ist in Abbildung 4 zu sehen, sehr einfache Formen, die bei der Baumkrone deplatziert wirken.



Abbildung 3: Versuch 01: Direkte Erstellung des SVGs mit angepasstem Basisprompt.

Als zweiter Versuch wurde zuerst ein Output (in dem Fall ein Muster) generiert und dieses im Anschluss vektorisiert. Dabei wurde folgender Prompt verwendet: „*can you generate svg file out of the last image?*“. Das Ergebnis war dabei jedoch nur die Einbettung des generierten PNG's und keine wirkliche Vektorisierung.

Deshalb wurde folgender Prompt zur Spezifizierung verwendet: „*can you vectorize the image and then create the svg?*“. Das Ergebnis ist in Abbildung 4 links dargestellt.



Abbildung 4: Versuch 02: GPT-I: Original generierter Output- Ausschnitt (Mitte) mit GPT-I Vektorisierung (links) im Vergleich mit Vektorisierung über Python Skript (rechts), jeweils 1024 x 1024 Pixel.

Anhang 03: Symbol- und Mustergenerierung

Masterprompt für einzelne Symbole – Beispiel Bahnsymbol

Create a professional cartography sprite sheet, for one {} symbol for a **low** zoom level. Ultra minimalist flat icon, show recognizable form. No details, one colour, no text. The symbol should have clean lines, consistent {} colour palette, flat design and a dark brown 1:1 square background for better visibility in comparison to the surroundings. Transparent background. Be self-explanatory and generic map icon.



Create a professional cartography sprite sheet, for one {} symbol for a **middle** zoom level. Stylized flat vector, a few details, dont add details of the surroundings, no text. The symbol should have clean lines, consistent {} colour palette, flat design and a blue 1:1 square background for better visibility in comparison to the surroundings. Transparent background. Be self-explanatory and generic map icon.



Create a professional cartography sprite sheet, for one train symbol for a **high** zoom level. 2D symbol with a few details and shading, no text. The symbol should have clean lines, consistent {} colour palette, flat design and a blue 1:1 square background for better visibility in comparison to the surroundings. Transparent background. Be self-explanatory and generic map icon.



Tabelle 5: Angepasster angepasst Masterprompt für einzelne Symbole (erstellt mit GPT-I, eigene Darstellung).

Anhang 04: Promptübertragung auf weitere KI-Modelle (Bezug zu Kapitel 5.2 und Fehler! Verweisquelle konnte nicht gefunden werden.)

Alle drei Promptübertragungen getestet innerhalb des Monats April 2026.

4.1 MLLM - Gemini: Nano Banana 2

- I. Weißer Hintergrund
- II. Ansicht explizit angeben

Promptübertragung, nötige Anpassungen für einen einheitlicheren Output

Links:
„Transparent
Background“
, rechts
„white
Background“



Links ohne
Ansichtsinfo,
rechts mit



Tabelle 6: Promptübertragung, zu beachtende Anpassungen für Nano Banana 2 (Symbole generiert über Gemini), eigene Darstellung.

„Create a professional cartography sprite sheet, three variations of a {} symbol for different zoom levels. *View from the front.*

[Left]: ultra minimalist flat icon, show recognizable, generic form. No details, one colour, no text.

[Center]: stylized flat vector with a little more details, dont add details of the surroundings

[Right]: more detailed 2D symbol with shading.

All three symbols should have clean lines, consistent {} colour palette, flat design. **White background.** Be self-explanatory and generic map icons, dont make large outline changes. Use the same style and colours, but increase in detail so if they are later put above each other there should be a smooth transition between the unique symbols. Important: size ratio should be 1, 1.5, 2.25. **No text.**“

4.2 LLM - Qwen

Während der Modelltests wurde Qwen3-Max verwendet, für die Promptübertragungen die neuere Version Qwen 3.6 Plus.

- I. Hintergrund explizit weiß mittels hexcode angeben
- II. Dreistufiger Masterprompt wird umgesetzt




Abbildung 5: Promptübertragung innerhalb von Qwen, mit "weiß" als Hintergrund Beschreibung (links), sowie mit „Weiß“ und hexcode #ffff (rechts), eigene Darstellung generiert innerhalb von Qwen 3.6 Plus.

4.3 Diffusion Modell - Stable Diffusion

- I. Dreistufiger Masterprompt wird nicht gut umgesetzt (zu viele Outputs, teilweise Abstrakt) → aufgeteilter Masterprompt funktioniert besser (siehe Anhang 03)
- II. Weißer Hintergrund

Promptübertragung aufgeteilter Masterprompt – Stable Diffusion

Create a professional cartography sprite sheet, for one **church** symbol for a low zoom level. Ultra minimalist flat icon, show recognizable form. No details, one colour, no text. The symbol should have clean lines, consistent **black colour palette**, flat design and a white 1:1 square background for better visibility in comparison to the surroundings. White background. Be self-explanatory and generic map icon.



“train” (...) “consistent **white colour palette**, flat design and a **blue 1:1 square background**”



„hospital“ (...) red colour palette



„waste_basket“ (...) black and white colour palette




Tabelle 7: Promptübertragung - Stable Diffusion, Ergebnisse bei aufgeteiltem Masterprompt (eigene Darstellung, erstellt mittels Stable Diffusion Modell).

Promptübertragung Masterprompt – Stable Diffusion

“church”



“train”



„hospital“ (...) red colour palette



„waste_basket“ (...) black and white colour palette



Tabelle 8: Promptübertragung - Stable Diffusion, teilweise fehlerhafte Ergebnisse mit Masterprompt (eigene Darstellung, erstellt mittels Stable Diffusion Modell).


4.4 Übersicht Promptübetragung Mastermusterprompt auf weitere Modelle

Promptübertragung Mustererstellung für drei KI-Modellarten


Nano Banana 2: "Grass"




Nano Banana 2: "bare rock"



Qwen: "Grass"



Qwen: "bare rock"



Stable Diffusion: "Grass"



Stable Diffusion: "bare rock"



Tabelle 9: Promptübertragung des Masterprompts für die Mustererstellung ohne modellspezifische Anpassungen (generiert mit Nano Banana 2, Qwen 3.6-Plus und Stable Diffusion), eigene Darstellung.

10 Hilfsmittelverzeichnis

Einsatz von KI-Tools

KI-Hilfsmittel	Einsatz	Betroffene Teile der Arbeit	Bemerkungen
Claude	Unterstützung bei Code Generierung für die Testumgebung: „png_cutter“ Skript	Kapitel 4.1	Hilfe bei der Erstellung des Skriptes um Symbole/ Muster aus PNG's zu schneiden. Vorher recherchierte GitHub Codes (Sprite Erstellung, Muster nahtlos machen) als Input gegeben. Hilfe bei der Erstellung des phash Skripts, um die Reproduzierbarkeit zu testen.
Claude, Codex	Unterstützung bei Code Generierung für die Testumgebung.	Kapitel 4.1	Hilfe bei der Erstellung des Skriptes für die MapLibre html-Karte. MapLibre Vorlage als Input gegeben, sowie auf GitHub entdecktes Tool zur Verarbeitung von PNG's als Input für Sprite Datei, GEOJSONs als zusätzliche Datenquelle ebenfalls als Input gegeben, heruntergeladen von Overpass Turbo.

Tab. 33: Hilfsmittelverzeichnis