

Ein KI-gestützter Workflow für die Qualitative Inhaltsanalyse nach Mayring

Dr. Rupert Beinhauer, FH JOANNEUM

Abstract:

Diese Arbeit konzipiert einen methodisch fundierten Workflow, der Large Language Models (LLMs) zur Unterstützung der Qualitativen Inhaltsanalyse (QIA) nach Philipp Mayring einsetzt. Ziel ist es, den etablierten, aber ressourcenintensiven Analyseprozess durch eine strukturierte, prompt-basierte Architektur nicht nur effizienter, sondern auch methodisch transparenter zu gestalten. Der entwickelte Workflow übersetzt die zentralen Analyseschritte Mayrings – von der deduktiven Kodierung bis zur induktiven Kategorienbildung – in konkrete Handlungsanweisungen für einen LLM. Der zentrale Beitrag liegt in der Bereitstellung einer praxistauglichen Durchführungsempfehlung, die die Stärken maschineller Verarbeitung mit der unerlässlichen Interpretationskompetenz des Forschenden in einem hybriden Mensch-KI-Ansatz verbindet.

Keywords: Qualitative Inhaltsanalyse, Large Language Models, Philipp Mayring, Methodik

1. EINLEITUNG

Die Analyse qualitativer Daten stellt eine zentrale, aber auch herausfordernde Aufgabe in den Sozialwissenschaften dar. Forschende sehen sich mit einer stetig wachsenden Menge an Textmaterial konfrontiert, sei es aus Interviews, Dokumenten oder digitalen Medieninhalten. Um diese Daten systematisch zu erschließen, hat sich die Qualitative Inhaltsanalyse (QIA) als eine etablierte Methode bewährt. Insbesondere im deutschsprachigen Raum wurde sie durch Philipp Mayring zu einem systematischen, regelgeleiteten und damit intersubjektiv überprüfbaren Verfahren entwickelt, das eine Brücke zwischen interpretativen und quantifizierenden Ansätzen schlägt (Mayring, 2022).

Während die QIA einen rigorosen methodischen Rahmen bietet, ist ihre manuelle Durchführung in der Praxis oft mit einem erheblichen Zeit- und Ressourcenaufwand verbunden. Die sorgfältige Durcharbeitung, Kodierung und Kategorisierung umfangreicher Textkorpora erfordert hohe Konzentration und ist anfällig für Inkonsistenzen. An dieser Stelle eröffnet der technologische Fortschritt im Bereich der künstlichen Intelligenz, insbesondere durch Large Language Models (LLMs), neue Perspektiven, die über reine Effizienzsteigerung hinausgehen und das Potenzial bergen, die methodische Strenge zu erhöhen.

Dies führt zur zentralen Forschungsfrage dieser Arbeit: Wie kann ein strukturierter, auf Large Language Models (LLMs) basierender Workflow die Durchführung der Qualitativen Inhaltsanalyse nach Mayring methodisch fundiert unterstützen und effizienter gestalten?

Um diese Frage zu beantworten, wird zunächst das theoretische Fundament der QIA nach Mayring gelegt und von verwandten Ansätzen abgegrenzt. Darauf aufbauend wird das Potenzial von LLMs für die qualitative Analyse beleuchtet und ein methodischer Rahmen für deren Integration entwickelt. Das Kernstück der Arbeit bildet die detaillierte Vorstellung eines schrittweisen, prompt-basierten Workflows, der Forschenden als praktische Durchführungsempfehlung dient. Abschließend werden die Chancen und Herausforderungen dieses Ansatzes kritisch diskutiert und die sich wandelnde Rolle des Forschenden im hybriden Analyseprozess reflektiert. Die Entwicklung eines solchen Workflows erfordert eine solide theoretische Fundierung, die im folgenden Kapitel geschaffen wird.

2. THEORETISCHE GRUNDLAGEN DER QUALITATIVEN INHALTSANALYSE

Um den hier vorgestellten KI-gestützten Workflow methodisch einordnen zu können, ist eine gemeinsame Wissensbasis unerlässlich. Dieses Kapitel erläutert daher die zentralen Konzepte, Akteure und Verfahren der Qualitativen Inhaltsanalyse, die das Fundament für die spätere technologische Integration bilden.

2.1. Definition, Ziele und Abgrenzung

Die Qualitative Inhaltsanalyse ist eine Methode der empirischen Sozialforschung, deren Ziel in der systematischen Ordnung und Strukturierung von manifesten und latenten Inhalten liegt (Mayring, 2010; Mathes, 1992). Als Material können dabei vielfältige Datenquellen wie Interviewtranskripte, Zeitungsartikel, Dokumente oder auch Videoaufnahmen dienen. Die Methode wurde entwickelt, um sprachliches Material trotz seiner Interpretationsbedürftigkeit und Bedeutungsfülle wissenschaftlichen Ansprüchen an Systematik und Überprüfbarkeit gerecht zu werden.

Im Gegensatz zu rein quantitativen Ansätzen, die auf die Messung numerischer Zusammenhänge und Repräsentativität abzielen, verfolgt die QIA das hermeneutische Ziel, menschliches Verhalten und dessen sprachlichen Ausdruck zu verstehen. Es geht primär um die Erschließung von Bedeutungsgehalten und nicht um statistische Verallgemeinerungen.

2.2. Methodische Ansätze im Vergleich: Mayring und Kuckartz

Innerhalb der QIA haben sich im deutschsprachigen Raum vor allem die Ansätze von Philipp Mayring und Udo Kuckartz etabliert. Obwohl sie große Ähnlichkeiten aufweisen, lassen sich zentrale Unterschiede in ihrer Ausrichtung und Regelstrenge feststellen.

- Philipp Mayring gilt als der Wegbereiter und "Klassiker" der QIA. Sein Ansatz ist durch einen stark theoriegeleiteten, strukturierten und regelbasierten Prozess gekennzeichnet, für den er detaillierte Ablaufmodelle beschreibt. Der Fokus liegt auf der expliziten Formulierung von Interpretationsregeln und der systematischen Anwendung eines Kategoriensystems.
- Udo Kuckartz hat eine "qualitative Modernisierung" der Methode vorgenommen. Sein Vorgehen ist durch offenere Formulierungen ("Guidelines" statt "Regeln") und eine stärkere Orientierung am Material geprägt. Kuckartz betont die Wichtigkeit des Fallbezugs durch eine "initiiierende

Textarbeit" und integriert stärker die Möglichkeiten moderner QDA-Software (z.B. MAXQDA, dessen Erfinder er ist).

Man kann sagen: Mayring liefert den Algorithmus für die Analyse, noch bevor der Computer eingeschaltet wird. Seine Methode ist wie ein strenges Computerprogramm (Input -> Reduktion -> Output) aufgebaut, was sie für die Automatisierung durch LLMs prädestiniert. Kuckartz hingegen verlangt eine menschlich-hermeneutische Haltung („Verstehen“), die ein LLM nur simulieren, aber (noch) nicht methodisch sauber replizieren kann.

2.3. Der Kernprozess: Deduktive, Induktive und kombinierte Kategorienbildung

Der zentrale Prozess der QIA ist die Entwicklung und Anwendung eines Kategoriensystems, um das Material zu strukturieren. Hierbei werden drei grundlegende Vorgehensweisen unterschieden:

1. Deduktive Kategorienanwendung (strukturierende Inhaltsanalyse): Bei diesem theoriegeleiteten Verfahren wird das Kategoriensystem vor der Analyse aus der Fachliteratur oder einer bestehenden Theorie abgeleitet. Diese vorab definierten Kategorien werden dann an das Material herangetragen, um relevante Textstellen zu identifizieren und zuzuordnen (Mayring, 2010).
2. Induktive Kategorienbildung (zusammenfassende Inhaltsanalyse): Hier werden die Kategorien direkt "am Material" entwickelt. Ausgehend von einzelnen Textpassagen werden durch schrittweise Abstraktion (z. B. Paraphrasierung und Generalisierung) neue, verallgemeinernde Kategorien gebildet (Mayring, 2010).
3. Deduktiv-induktive Kombination: In der Forschungspraxis hat sich eine Kombination beider Ansätze als besonders fruchtbar erwiesen. Dabei wird zunächst eine deduktive Grundstruktur aus der Theorie abgeleitet, um den Prozess zu leiten. Material, das nicht in dieses Schema passt, oder überraschende Erkenntnisse werden anschließend genutzt, um das Kategoriensystem induktiv zu erweitern oder zu verfeinern, z. B. durch die Bildung von Unterkategorien (shriebl, 2021). Dieses Vorgehen verbindet die Struktur der Theorie mit der Offenheit für neue Entdeckungen im Datenmaterial und wird sowohl von Mayring als auch von Kuckartz befürwortet.

Nachdem die methodischen Grundlagen der QIA etabliert sind, wird im nächsten Kapitel die Brücke zur Integration moderner KI-Technologien geschlagen.

3. METHODIK: KONZEPTION EINES KI-GESTÜTZTEN ANALYSEPROZESSES

Dieses Kapitel schlägt die Brücke von der etablierten qualitativen Methodik zum technologischen Potenzial von Large Language Models. Es begründet das Design des hier vorgestellten Workflows, indem es zunächst die generellen Fähigkeiten und Grenzen von LLMs in der qualitativen Analyse beleuchtet und anschließend die zentralen methodischen Instrumente – den Kodierleitfaden und die Prompt-Architektur – als Fundament für die KI-Integration definiert.

3.1. Das Potenzial von LLMs in der Qualitativen Datenanalyse

Aktuelle Forschungsarbeiten zeigen, dass LLMs den qualitativen Analyseprozess maßgeblich unterstützen können. Ihr Potenzial liegt insbesondere in der Beschleunigung und Systematisierung von Routineaufgaben. Studien belegen, dass Modelle wie GPT-3.5 eine deduktive Kodierung auf einem Niveau durchführen können, das mit menschlichen Kodierern vergleichbar ist, während sie den Zeitaufwand signifikant reduzieren (Chew et al., 2023; Xiao et al., 2023). Sie eignen sich hervorragend zur Erkennung von Mustern in großen Datenmengen und zur konsistenten Anwendung vordefinierter Kategoriensysteme.

Gleichzeitig sind die Limitationen der Technologie klar dokumentiert. LLMs haben oft Schwierigkeiten bei der Erfassung von emotionalen Nuancen, subtilem Kontext und impliziten Bedeutungen, die ein menschlicher Forscher intuitiv erfasst (Shanwetter Levit et al., 2025). Sie können strukturelle und logistische Aspekte eines Textes effizient hervorheben, stoßen aber bei der tiefgehenden Interpretation psychosozialer Themen an ihre Grenzen.

Aus diesen Erkenntnissen leitet sich die zentrale Schlussfolgerung ab, dass ein hybrider Mensch-KI-Ansatz der effektivste Weg ist. In diesem Modell fungiert der LLM nicht als Ersatz, sondern als "analytischer Partner" (Hayes et al., 2025), der den Forschenden von repetitiven Aufgaben entlastet, während die finale Interpretation, die kritische Reflexion und die theoretische Einbettung in der Verantwortung des Menschen verbleiben.

3.2. Der Kodierleitfaden als strukturelles Fundament

Der Kodierleitfaden ist das zentrale methodische Instrument der strukturierenden Inhaltsanalyse nach Mayring. Er gewährleistet die Regelgeleitetheit und Nachvollziehbarkeit des Kodierprozesses. Für die Zusammenarbeit mit einem LLM ist er von entscheidender Bedeutung, da er die "Anweisungen" für die Maschine präzise und unmissverständlich formuliert. Nach Mayring (2015, S. 97) besteht ein Kodierleitfaden aus drei essenziellen Bestandteilen:

1. **Kategorie-Definition:** Hier wird festgelegt, was unter eine Kategorie fällt. Mayring formuliert: „Es wird genau definiert, welche Textbestandteile unter eine Kategorie fallen“. Diese Definition dient als primäre Anweisung für die Zuordnung.
2. **Ankerbeispiel:** Für jede Kategorie wird eine prototypische Textstelle angeführt. „Es werden konkrete Textstellen angeführt, die unter eine Kategorie fallen und als Beispiel für diese Kategorie gelten sollen“. Dies hilft sowohl Menschen als auch der KI, das Abstraktionsniveau der Kategorie zu verstehen.
3. **Kodierregel:** Diese Regeln lösen Abgrenzungsprobleme. „Es werden dort, wo Abgrenzungsprobleme zwischen Kategorien bestehen, Regeln formuliert, um eindeutige Zuordnungen zu ermöglichen“. Sie stellen eine eindeutige Zuordnung sicher und erhöhen die Reliabilität der Kodierung.

3.3. Entwicklung einer Prompt-Architektur

Der Kern des hier vorgestellten methodischen Ansatzes liegt in der Übersetzung der einzelnen Analyseschritte von Mayrings Vorgehen in spezifische, handlungsorientierte Prompts für einen LLM. Ein Prompt ist eine präzise formulierte Anweisung, die das KI-Modell anleitet, eine

bestimmte Aufgabe auszuführen. Diese Übersetzung ist mehr als eine technische Notwendigkeit; sie ist eine methodische Innovation. Sie operationalisiert den komplexen kognitiven Prozess der qualitativen Analyse und überführt ihn in maschinell ausführbare, dokumentierte und replizierbare Schritte. Dadurch wird die von Mayring geforderte Regelgeleitetheit nicht nur befolgt, sondern technologisch erzwungen und transparent gemacht. Anstatt den LLM vage nach "Themen" zu fragen, wird der Analyseprozess in seine logischen Bestandteile zerlegt (z. B. Paraphrasieren, Generalisieren, Kodieren), die jeweils durch einen zielgerichteten Prompt gesteuert werden.

Die in diesem Paper verwendeten Prompts basieren auf dokumentierten Abläufen, die im Forschungsprozess erarbeitet wurden. Sie bilden das Rückgrat des im folgenden Kapitel vorgestellten Workflows.

Nachdem die methodischen und technologischen Grundlagen etabliert sind, werden diese nun im folgenden Kapitel zu einer konkreten und anwendbaren Schritt-für-Schritt-Anleitung für die KI-gestützte Qualitative Inhaltsanalyse zusammengeführt.

4. DURCHFÜHRUNGSEMPFEHLUNG: EIN KI-ASSISTIERTER ABLAUF DER QIA

Dieses Kapitel überführt den zuvor entwickelten theoretischen Rahmen in einen praxistauglichen, schrittweisen Workflow. Es dient Forschenden als konkrete Anleitung, um die Qualitative Inhaltsanalyse nach Mayring unter Zuhilfenahme eines Large Language Models systematisch und nachvollziehbar durchzuführen. Abhängig vom verwendeten Large Language Model kann es dabei notwendig sein dem Modell entsprechende Beispiele zur Verfügung zu stellen um zu einer adäquaten Durchführung zu gelangen.

4.1. Phase 1 - Vorbereitung und deduktive Strukturierung

In der ersten Phase wird das Analysematerial aufbereitet und die theoriegeleitete, deduktive Grundstruktur für die Analyse geschaffen. Dies beginnt mit der Festlegung des zu analysierenden Materials und der Entwicklung eines deduktiven Kategoriensystems, das im Kodierleitfaden präzise dokumentiert wird.

Schritt 1: Segmentierung des Materials Zunächst wird der gesamte Text in thematisch kohärente und überschaubare Analyseeinheiten unterteilt. Dies schafft eine klare Struktur für die nachfolgende Kodierung.

Prompt: Segmentierung "[Basierende auf diesem Beispiel] Teile den Text in kohärente Segmente basierend auf thematischen Verschiebungen. Weise jedem Segment eine ID zu und bewahre die Originalformulierung. Überschrift: SEGMENTIERUNG."

Schritt 2: KI-gestütztes Kodieren Die so erstellten Segmente werden nun mithilfe des zuvor erstellten Kodierleitfadens den deduktiven Kategorien zugeordnet. Der LLM wendet die definierten Regeln systematisch auf das gesamte Material an.

Um sicherzustellen, dass relevante Informationen, die nicht durch das theoretische Vorwissen abgedeckt sind, nicht verloren gehen, wird eine explizite Restkategorie eingeführt. Dies folgt der Logik der deduktiv-induktiven Kombination: Segmente, die nicht in die deduktive Struktur passen, werden gesammelt, um das Kategoriensystem im Anschluss induktiv zu verfeinern oder zu erweitern

Prompt: Kodieren "Ordne jedes Segment der passendsten Kategorie aus dem Kodierleitfaden zu. Nutze die definierten Kategorien als Grundlage. Überschrift: KODIEREN."

4.2. Phase 2 - Induktive Analyse und Differenzierung

Diese Phase widmet sich, falls notwendig, jenem Material, das durch das deduktive Kategoriensystem nicht abgedeckt werden konnte. Hier kommt die induktive Methode nach Mayring zur Anwendung, um neue, datengestützte Kategorien zu entwickeln.

Schritt 3: Paraphrasieren Um die Kernaussagen der relevanten Segmente zu extrahieren, werden diese paraphrasiert. Unwesentliche Informationen werden entfernt, um den Inhalt auf das Wesentliche zu reduzieren.

Prompt: Paraphrasieren "Entferne nicht-essentielle Elemente und bewahre die Kernaussage. Formuliere eine prägnante, grammatikalisch optimierte Version. Überschrift: PARAPHRASIEREN."

Schritt 4: Generalisieren und Reduzieren Die Paraphrasen werden nun auf ein höheres Abstraktionsniveau gehoben und inhaltlich ähnliche Aussagen zusammengefasst, um Redundanzen zu eliminieren.

Prompt: Generalisieren "Schreibe spezifische Details in allgemeinere, abstraktere Begriffe um. Bewahre logische Genauigkeit und vermeide übermäßig spezifische Formulierungen. Überschrift: GENERALISIEREN."

Prompt: Reduktion (I) "Identifiziere die zentrale Bedeutung jeder Paraphrase. Entferne Paraphrasen mit gleicher oder sehr ähnlicher Bedeutung. Eliminiere alle Paraphrasen ohne Mehrwert. Behalte nur jene, die wesentlich sind. Stelle die Ergebnisse in einer Tabelle dar. Überschrift: REDUKTION."

Schritt 5: Bildung induktiver Kategorien Aus den verdichteten und generalisierten Paraphrasen werden nun neue, datengestützte Kategorien gebildet. Der LLM kann hierbei Vorschläge für wiederkehrende Konzepte unterbreiten.

Prompt: Kategoriedefinition "Durchsuche die Paraphrasen nach wiederkehrenden Konzepten. Schlage Kategorien vor und definiere diese inklusive Inklusions-/Exklusionskriterien und Ankerbeispielen. Überschrift: KATEGORIEDEFINITION."

4.3. Phase 3 - Synthese und Interpretation

In der finalen Phase wird das gesamte Kategoriensystem – bestehend aus deduktiven und induktiven Kategorien – konsolidiert und für die abschließende Auswertung und Interpretation aufbereitet.

Schritt 6: Revision des Kategoriensystems Die neu gebildeten induktiven Kategorien werden mit den bestehenden deduktiven Kategorien abgeglichen. Überschneidungen werden identifiziert und Kategorien gegebenenfalls zusammengefasst oder neu definiert.

Prompt: Kategorien-Revision "Erkenne sich überschneidende Kategorien und fasse sie zusammen. Aktualisiere Definitionen und ordne Segmente ggf. neu zu. Überschrift: KATEGORIEN-REVISION."

Schritt 7: Kategorienbasierte Zusammenfassung und Interpretation Abschließend werden die den Kategorien zugeordneten Inhalte aggregiert und aufbereitet. Der LLM kann eine erste Zusammenfassung erstellen und sogar Interpretationsansätze vorschlagen, die jedoch einer kritischen menschlichen Überprüfung bedürfen.

Prompt: Automatisierte Zusammenfassung "Fasse Paraphrasen pro Kategorie in einer strukturierten Liste oder Tabelle zusammen. Nutze extraktive oder abstraktive Methoden, um prägnante Übersichten zu erstellen. Überschrift: AUTOMATISIERTE ZUSAMMENFASSUNG."

Prompt: Automatisierte Interpretation "Überprüfe Ergebnisse mit externen Quellen und zitiere diese im APA7-Stil. Formuliere Hypothesen oder Erklärungen für beobachtete Muster."
Anmerkung: Hierbei ist es entscheidend, den LLM so zu konfigurieren, dass er ausschließlich auf verifizierte, externe wissenschaftliche Quellen zurückgreift.

Nachdem dieser strukturierte Prozess vorgestellt wurde, muss er im Folgenden im Hinblick auf seine praktischen Implikationen und methodischen Herausforderungen kritisch diskutiert werden.

5.5. DISKUSSION

Die Vorstellung eines KI-gestützten Workflows erfordert eine kritische Reflexion seiner methodischen Implikationen. Dieses Kapitel bewertet die Chancen und Risiken des vorgeschlagenen Ansatzes, ordnet ihn in den Kontext der qualitativen Gütekriterien ein und diskutiert die daraus resultierende Neudefinition der Rolle des Forschenden.

5.1. Analyse der Chancen und Potenziale

Der Einsatz von LLMs in der Qualitativen Inhaltsanalyse bietet signifikante Vorteile, die den Forschungsprozess optimieren können:

- **Effizienz und Skalierbarkeit:** Der offensichtlichste Vorteil liegt in der massiven Beschleunigung von zeitintensiven Prozessen wie der Segmentierung und Kodierung. Dies ermöglicht es Forschenden, wesentlich größere Datenmengen zu bearbeiten, als es manuell möglich wäre (Chew et al., 2023; Rasheed et al., 2024).
- **Konsistenz:** Ein LLM wendet die im Kodierleitfaden definierten Regeln systematisch und ohne Ermüdungserscheinungen auf den gesamten Datenkorpus an. Dies kann die Konsistenz der Kodierung im Vergleich zu manuellen Verfahren, bei denen die Konzentration schwanken kann, potenziell erhöhen.

- **Methodische Nachvollziehbarkeit:** Der hier skizzierte, auf spezifischen Prompts basierende Ablauf fördert eine explizite Dokumentation der einzelnen Analyseschritte. Jeder Schritt ist durch einen Prompt definiert und sein Ergebnis nachvollziehbar. Dies unterstützt unmittelbar eines der zentralen Gütekriterien nach Mayring: die Verfahrensdokumentation, welche die wissenschaftliche Nachvollziehbarkeit des gesamten Forschungsprozesses fordert (Mayring, 2016, S. 144).

5.2. Reflexion der Herausforderungen und Gütekriterien

Trotz der Potenziale birgt der Einsatz von KI auch Risiken und stellt die Einhaltung qualitativer Gütekriterien vor neue Herausforderungen. Typische Fehler bei der manuellen Inhaltsanalyse, wie das Überspringen von Prozessschritten oder ein mangelnder Fokus auf die Forschungsfrage (Kröger, o. D.), können durch einen strukturierten Workflow zwar eingedämmt werden. Dennoch bleiben spezifische Herausforderungen bestehen:

- **Grenzen der KI-Interpretation:** Wie bereits erwähnt, haben LLMs Schwierigkeiten, subtile Kontexte, Ironie oder emotionale Tiefe zu erfassen (Shanwetter Levit et al., 2025). Eine unreflektierte Übernahme der KI-Ergebnisse würde die interpretative Tiefe der Analyse erheblich reduzieren.
- **Sicherung der Interpretationsqualität:** An dieser Stelle greift ein weiteres Gütekriterium Mayrings: die argumentative Interpretationsabsicherung (Mayring, 2016, S. 144). Die von der KI generierten Kodierungen, Zusammenfassungen und Muster sind nicht als finale Ergebnisse, sondern als argumentationsbedürftige Vorschläge zu verstehen. Der menschliche Forscher muss jede Zuordnung kritisch prüfen, validieren und die finale Interpretation argumentativ begründen. Die Letztverantwortung für die Geltung der Ergebnisse verbleibt beim Menschen.

5.3 Neudefinition der Forscherrolle im hybriden Prozess

Der KI-gestützte Workflow ersetzt den Forschenden nicht, sondern transformiert seine Rolle fundamental. Die Tätigkeit verschiebt sich weg von der repetitiven, manuellen Arbeit des Kodierens hin zu strategischeren und konzeptionellen Aufgaben:

- **Der Forscher als Architekt:** Die Hauptaufgabe liegt in der a-priori-Konzeption des Analyseprozesses. Dies umfasst die sorgfältige theoriegeleitete Entwicklung des Kategoriensystems, die präzise Ausarbeitung des Kodierleitfadens und das Design einer effektiven Prompt-Architektur.
- **Der Forscher als Validierer:** Während des Prozesses agiert der Forscher als kritische Instanz, die die Ergebnisse der KI kontinuierlich überprüft, validiert, korrigiert und verfeinert. Er ist der "human-in-the-loop", der die Qualität der maschinellen Analyse sicherstellt.
- **Der Forscher als Interpret:** Die ultimative Aufgabe, die nicht an eine Maschine delegiert werden kann, ist die Synthese der Ergebnisse, deren Einbettung in den theoretischen Kontext und die Generierung von neuem Wissen. Die kritische Reflexion und die Geltungsbegründung der Forschungsergebnisse bleiben die Kernkompetenzen des menschlichen Intellekts.

Nach dieser kritischen Einordnung der Methode und der Forscherrolle werden im Folgenden die zentralen Erkenntnisse zusammengefasst und ein Ausblick auf zukünftige Entwicklungen gegeben.

6. FAZIT UND AUSBLICK

Diese Arbeit hat sich der Forschungsfrage gewidmet, wie ein auf Large Language Models basierender Workflow die Qualitative Inhaltsanalyse nach Mayring methodisch fundiert unterstützen und effizienter gestalten kann. Die Antwort liegt in einem strukturierten, hybriden Mensch-KI-Ansatz, der die systematischen Analyseschritte Mayrings in eine präzise, prompt-basierte Architektur übersetzt. Es wurde gezeigt, dass LLMs als "analytische Partner" fungieren können, die Forschende von repetitiven Aufgaben entlasten, die Konsistenz der Analyse erhöhen und die Bearbeitung größerer Datenmengen ermöglichen.

Der Hauptbeitrag dieser Arbeit ist die Konzeption und detaillierte Beschreibung eines solchen praxistauglichen Workflows. Er stellt eine methodische Brücke zwischen der etablierten qualitativen Forschungstradition und den technologischen Möglichkeiten des KI-Zeitalters dar. Dabei wurde betont, dass die kritische Reflexion, die argumentative Absicherung der Interpretation und die theoretische Einbettung der Ergebnisse Kernkompetenzen des menschlichen Forschenden bleiben und die Forscherrolle sich hin zum Architekten und Validierer des Analyseprozesses wandelt.

Zukünftige Forschung sollte den hier konzipierten Workflow empirisch erproben und seine Anwendbarkeit in verschiedenen sozialwissenschaftlichen Feldern evaluieren. Weiterführende Arbeiten könnten sich zudem der Entwicklung noch differenzierterer Prompt-Architekturen widmen, die beispielsweise die Erfassung kontextueller Nuancen weiter verbessern.

Die Zukunft der qualitativen Forschung liegt nicht in einer vollständigen Automatisierung, sondern in einer intelligenten Symbiose aus menschlicher Interpretationsfähigkeit und maschineller Effizienz. Wenn wir diese Technologien methodisch fundiert und kritisch-reflektiert einsetzen, eröffnen sie uns die Chance, komplexe soziale Phänomene noch tiefgreifender und umfassender zu verstehen.

Literaturverzeichnis

Chew, R. F., Xiao, Z., & Tai, R. H. (2023). *LLM-assisted content analysis (LACA)*.

Hayes, A. S., Lai, V., & Lai, E. T. C. (2025). *Chatting with my data: A new path to meaning*.

Kröger, M. (o. D.). *7 häufige Fehler bei der Inhaltsanalyse (Mayring oder Kuckartz)* [Video]. YouTube.

Kuckartz, U. (2016). *Qualitative Inhaltsanalyse. Methoden, Praxis, Computerunterstützung* (3. Aufl.). Beltz Juventa.

Mathes, R. (1992). Hermeneutisch-klassifikatorische Inhaltsanalyse von Leitfadengesprächen. In J. H. P. Hoffmeyer-Zlotnik (Hrsg.), *Analyse verbaler Daten: über den Umgang mit qualitativen Daten* (S. 410). Westdeutscher Verlag.

Mayring, P. (2010). Qualitative Inhaltsanalyse. In G. Mey & K. Mruck (Hrsg.), *Handbuch Qualitative Forschung in der Psychologie* (S. 601–613). VS Verlag für Sozialwissenschaften.

Mayring, P. (2015). *Qualitative Inhaltsanalyse. Grundlagen und Techniken* (12. Aufl.). Beltz.

Mayring, P. (2016). *Einführung in die qualitative Sozialforschung: Eine Anleitung zu qualitativem Denken* (6. Aufl.). Beltz.

Mayring, P. (2022). *Qualitative Inhaltsanalyse. Grundlagen und Techniken* (13. Aufl.). Beltz.

Rasheed, Z., Riaz, A., & Yan, C. (2024). *The potential of multi-agent models for qualitative data analysis*.

Shanwetter Levit, N., Finzi, D., Lipman, O., & Pick, C. G. (2025). *A comparative analysis of human-led versus LLM-assisted thematic analysis*.

shribe!. (2021, 2. August). *Deduktiv Induktiv Kombination Qualitative Inhaltsanalyse (Mayring & Co.)*. <https://www.shribe.de/deduktiv-induktiv-kombination-qualitative-inhaltsanalyse-mayring/>

Xiao, Z., Chew, R. F., & Tai, R. H. (2023). *Evaluating LLMs for deductive coding in qualitative analysis*.

Dieser Beitrag wurde unter unterstützender Verwendung des KI-Modells **NotebookLM** erstellt. Alle Inhalte wurden durch die Autoren geprüft und finalisiert. Die Autoren tragen die volle Verantwortung für den veröffentlichten Inhalt.