

Forschungsparadigmen und Methoden für RSEs
Sitzung 5: Grundlagen empirischer Evaluation von Forschungssoftware


Traditionelle Formen der Softwareevaluation (Karat 1988)

Evaluationstechniken I

Methode	Art der Information	Geeigneter Einsatz
Fragebogen	Subjektive Antworten auf gestellte Fragen. Besonders geeignet für spezifische Fragestellungen.	In jeder Phase geeignet, wenn konkrete Fragen formuliert werden können
Verbaler Bericht	Aufzeichnung kognitiver Prozesse bei der Systemnutzung.	Früh im Entwicklungsprozess, wenn allgemeine Informationen benötigt werden
Kontrollierte Experimente	Spezifische Messwerte in einer kontrollierten Umgebung.	Für gezielte Tests wichtiger Alternativen oder Hypothesen

Evaluationsmethoden II

Methode	Art der Information	Geeigneter Einsatz
Design Review	Plausibilitätsprüfung des Designs hinsichtlich allgemeiner Akzeptanz.	Früh im Designprozess, um frühe Entscheidungen zu überprüfen
Formale Analyse (GOMS)	Vorhersagen über das Verhalten erfahrener Nutzer	Als Ersatz für Nutzertests zur Vorhersage der Gebrauchstauglichkeit
Produktions-systemanalyse	Vorhersagen über Lernen, Nutzung und Transferverhalten	Zur Ergänzung anderer Analysedaten



Evaluationsmethoden III: Moderne Varianten

- ▶ Agentenbasierte GUI-Tests (Chen 2026)
- ▶ Verhaltensspuren
 - ▶ Logdaten
 - ▶ Zeitstempel
 - ▶ Mobile Sensoren: Geolokation, Richtungsänderung . . .

Oculus
VR-Headset



Myo
Gestensteuerungs-Armband



Hautleitungsfähigkeitsmessung
(Galvanische Hautreaktion, GSR)



EKG
(Elektrokardiographie)



Evaluationsmethoden IV: Kommerzielle Schnittstellen

- ▶ Reihe von kommerziellen Sensorsystemen: Oculus, Kinect und Myo armband
- ▶ Messbare Daten (Rechy-Ramirez, Marin-Hernandez, and Rios-Figueroa 2018):
 - ▶ emotionale Veränderungen
 - ▶ Gesichtsausdrücke
 - ▶ Gedanken
 - ▶ Kopfbewegungen
 - ▶ Skeletale Bewegungen
 - ▶ ...

- ▶ MaxQDA installiert?
- ▶ Breakout-Rooms (sortiert nach MaxQDA-Besitzer:innen)
- ▶ Kodierung von Beispielen für Forschungssoftwareentwicklung und empirische Evaluation von Forschungssoftware
- ▶ 30 min
- ▶ Kreuztabelle: Was fällt auf?
- ▶ Diskussion im Plenum

- ▶ einfache Kodierung mit MaxQDA und Auswertung dort
- ▶ Kodierung mit MaxQDA und Segmentanalyse mit Statistiksoftware (R)
- ▶ Kodierung mit MaxQDA als Goldstandard für LLM-Labeling
- ▶ LLM-Tournament:
 - ▶ Automatische Kodierung mittels LLMs
 - ▶ Deselektion derjenigen LLMs die systematisch daneben liegen
 - ▶ Kodierung der Stellen, wo sich drei LLMs unterscheiden

Für jeden der 1052 Beiträge wurde aus den LLM-Begründungen per Dependency-Parsing das grammatikalische Objekt der Softwareevaluation (SE) und der empirischen Studie (EMP) extrahiert und als *software-intern* oder *extern* klassifiziert.

Ausrichtung von Softwareevaluation und empirischer Studie

Muster	n	%
Nur externe Empirie (SE=0, EMP=1)	289	27,5 %
Unklar	218	20,7 %
Zwei getrennte Studien	199	18,9 %
Eine Studie, Software-Fokus	158	15,0 %
Keine Studie (SE=0, EMP=0)	115	10,9 %
Eine Studie, externer Fokus	48	4,6 %
Invertiert (vermutl. Misklass.)	19	1,8 %
Nur Softwareevaluation (EMP=0)	6	0,6 %

Häufigste Typen in den 878 Beiträgen mit Forschungssoftware (Mehrfachzuordnung pro Beitrag möglich):

Typ	n	% von 878
Tool	251	28,6 %
System	188	21,4 %
Algorithmus	124	14,1 %
Plattform	101	11,5 %
Berechnungsworkflow	62	7,1 %
Virtual Reality	52	5,9 %
Quellcode	52	5,9 %
Framework	48	5,5 %
Learning Management System	40	4,6 %
Web-Applikation	39	4,4 %
Modul	37	4,2 %
Spiel	34	3,9 %

Tentative Verteilung in der DeLFI-Community

Anwendung der obigen Taxonomie auf 1052 DeLFI-Beiträge (2003–2025),
klassifiziert per Regex-Mustererkennung auf LLM-Annotationen (GPT-4o-mini):

Methode	n	% von 205
Fragebogen	154	75,1 %
Kontrolliertes Experiment	23	11,2 %
Verhaltensspuren	15	7,3 %
Design Review	11	5,4 %
Kommerzielle Sensorsysteme	6	2,9 %
Verbaler Bericht	5	2,4 %
Formale Analyse (GOMS)	1	0,5 %
Agentenbasierte GUI-Tests	0	0 %
Produktionssystemanalyse	0	0 %

Vorläufige Daten

847 von 1052 Beiträgen (80,5 %) ließen sich keiner Kategorie zuordnen — meist wegen abstrakter Methodenbeschreibungen in den LLM-Annotationen.

Bezugsgröße der Prozentwerte: $n = 205$ klassifizierte Beiträge (9 davon in mehr als einer Kategorie). Quelle: ICSE-2027-Sekundärstudie zum DeLFI-Korpus.

Forschungssoftware-Typ × Evaluationsmethode

Absolute Häufigkeiten (Top-8 Typen × Karat-Methoden mit ≥ 1 Fall):

Typ	Survey	Kontr.Exp.	Spuren	Review	Sensoren	Bericht
Tool	37	9	3	2	0	2
System	26	1	2	1	2	0
Algorithmus	10	1	1	3	0	1
Plattform	20	3	2	1	1	0
Berechnungsworkflow	9	3	0	2	0	0
Virtual Reality	8	5	0	0	1	0
Framework	6	1	2	1	0	0
LMS	8	0	3	0	0	0




Fig. 6: An idealized decision model for transformative empirical research software

The RIGHT framework (Dehne 2026)

- ▶ [R]elevance: Is this specific RS really necessary to conduct the research?
- ▶ [I]nteraction: Does the RS interact with variables during the execution phase?
- ▶ [G]eneration: Can the empirical results be synthetically generated to allow for the simulation method?
- ▶ [H]uman-In-the-Loop: Are humans both users of the RS and part of the research context?
- ▶ [T]ransformation: Does the RS transform the research context and forces reinterpretation of the variables?

- Chen, Chunyang. 2026. “Towards Human-Like Software Testing.” Wissenschaftliche Keynote at Software Engineering 2026 (SE 2026).
- Dehne, Julian. 2026. “To Be FAIR or RIGHT? Methodological [r]esearch [i]ntegrity [g]iven [h]uman-Facing [t]echnologies Using the Example of Learning Technologies.” <https://arxiv.org/abs/2603.15366>.
- Karat, John. 1988. “Software Evaluation Methodologies.” In *Handbook of Human-Computer Interaction*, 891–903. Elsevier.
<https://doi.org/10.1016/B978-0-444-70536-5.50046-4>.
- Rechy-Ramirez, Ericka Janet, Antonio Marin-Hernandez, and Homero Vladimir Rios-Figueroa. 2018. “Impact of Commercial Sensors in Human Computer Interaction: A Review.” *Journal of Ambient Intelligence and Humanized Computing* 9 (5): 1479–96. <https://doi.org/10.1007/s12652-017-0568-3>.