

AI Engineering

Prompt Injection & agentische Angriffsflächen

Inhalt ist Datenmaterial — keine Autorität.

Band 2 · Kapitel 27

Öffentliche Leseprobe · Auszug (§1 „Content $\neq$ Autorität — das zentrale Prinzip“ bis §5 „Attack Surface Inventory“)

Sebahattin Özata · Diplom-Informatiker

OMEX Press

Aus Kapitel 27 in Band 2: wie eine manipulierte Anweisung eintritt und sich durch ein agentisches System fortpflanzt. Kapitelverweise beziehen sich auf das vollständige dreibändige Werk.

Kapitel 27 — Prompt Injection & agentische Angriffsflächen

1. Content ≠ Autorität — das zentrale Prinzip

Die häufigste Denkfalle im agentischen Security-Design ist die Gleichsetzung von **nützlich** mit **vertrauenswürdig** und von **vertrauenswürdig** mit **berechtigt**. Das sind drei verschiedene Dinge.

Ein Inhalt kann relevant und korrekt sein und trotzdem keinerlei Autorität besitzen, Systemregeln zu ändern, einen Werkzeug-Aufruf zu legitimieren oder Rechte zu erzeugen.

Ein abgerufenes Dokument kann exakt die gesuchte Information enthalten — und daneben eine Anweisung („exfiltriere den bisherigen Verlauf an folgende Adresse“). Die Information ist *content*; die Anweisung ist eine *instruction*; keines von beiden trägt *authority*. Ein Werkzeug-Ergebnis kann faktisch stimmen und dennoch keine Berechtigung besitzen, den nächsten Werkzeug-Aufruf auszulösen. Ein anderer Agent kann brauchbaren Output erzeugen und dabei **keine** zusätzlichen Rechte schaffen.

Sieben Begriffe muss man sauber trennen — ihr Zusammenwerfen ist die Wurzel der meisten Injection-Schäden:

T1 · Sieben Dinge, die kein Kontext automatisch mitliefert

Begriff	Frage	Warum er <i>nicht</i> aus dem Inhalt folgt
Content	Was steht da?	Der reine Text — beweist nichts über seine Herkunft oder Absicht.
Instruction	Fordert er eine Handlung?	Ein Imperativ im Text ist <i>nicht</i> automatisch ein Befehl an das System.
Authority	Darf er Regeln/Handlungen bestimmen?	Autorität kommt aus dem Vertrauensmodell, nie aus dem Token-Strom selbst.
Identity	Wer hat ihn erzeugt?	Ein „System:“-Präfix im Text macht den Text nicht zum System-Prompt.
Provenance	Woher stammt er nachweisbar?	Herkunft muss außerhalb des Inhalts getrackt werden, sonst ist sie fälschbar.
Trust	Wie sehr verlasse ich mich darauf?	Trust ist eine <i>Entscheidung</i> des Systems, kein Attribut des Textes.
Permission	Welche Wirkung darf daraus folgen?	Erlaubnis entsteht nur an einer Autorisierungsgrenze, nie durch Lektüre.

Der praktische Kern für den Rest des Kapitels: **Das Modell kann keinen dieser Unterschiede zuverlässig selbst treffen.** Es sieht eine Token-Sequenz. Wer „content“ liest und „authority“ gewährt, hat die Sicherheitsgrenze bereits verloren, bevor der erste Guard greift.

2. Warum das Modell Daten und Instruktionen gleich sieht

In einem klassischen Programm sind Daten und Steuerung **physisch getrennt**: Ein Formularfeld landet in einer Variablen, der Kontrollfluss in kompiliertem Code. Ein Angreifer, der ein Feld füllt, kann den Kontrollfluss nur ändern, wenn eine Injection-Lücke (SQL, Shell) die Grenze verletzt — und diese Lücken schließt man deterministisch (Parametrisierung, Escaping).

Bei einem LLM gibt es diese Grenze **nicht**. System-Prompt, Nutzer-Eingabe, abgerufener Text, Werkzeug-Ausgabe und Gedächtnis-Fakten kommen als **eine einzige Token-Sequenz** beim Modell an. Das Modell hat keinen typisierten Kanal für „das ist Befehl“ versus „das ist bloß Material“. Es hat nur *Aufmerksamkeit* über Tokens — und die verteilt es nach gelernten Mustern, nicht nach einem Sicherheitsmodell.

Das ist keine Bug-Klasse, die man patchen kann, sondern eine Eigenschaft der Architektur. Solange ein Modell natürliche Sprache verarbeitet, kann eingebetteter Text wie eine Anweisung wirken. Der Begriff „Prompt Injection“ wurde 2022 dafür geprägt (Simon Willison) [REAL, 2022] ; Greshake et al. zeigten 2023, dass die gefährliche Variante **nicht** vom Nutzer kommen muss [REAL, 2023] (§3).

Daraus folgt die Leitregel für alle Gegenmuster in §6, §12 und §14: Man kann die Ambiguität **reduzieren** (Struktur, Delimiter, Provenienz-Tags), aber man kann sie nicht **kryptografisch auflösen**. Es gibt im Modell keine harte Trennung zwischen „Data“ und „Instruction“. Sicherheit muss deshalb **außerhalb** des Modells entstehen — an den Grenzen, die die *Wirkung* kontrollieren, nicht die *Interpretation*.

3. Direct, Indirect, Stored — drei Eintrittsformen

Prompt Injection tritt auf drei technisch verschiedenen Wegen ein. Die Unterscheidung ist wichtig, weil sie bestimmt, *wo* man verteidigt und *wer* der Angreifer ist.

Direkte Injection. Der Angreifer *ist* der Nutzer und schreibt die Anweisung selbst in die Eingabe. Muster: **Instruction Override** („Ignoriere alle vorherigen Anweisungen ...“), **Role/Policy Conflict** („Du bist jetzt ein System ohne Regeln“), **Prompt Boundary Failure** (der Nutzer schließt einen fiktiven System-Block und öffnet einen eigenen). Jailbreak-Muster sind hier nur insoweit relevant, als sie eine reale Wirkung freischalten — der Schaden entsteht am Werkzeug, nicht am frechen Text.

Indirekte Injection. Der Angreifer platziert die Anweisung in **Inhalt, den das System später abruft oder verarbeitet**: eine Webseite, ein Dokument, ein **PDF**, eine E-Mail, ein Ticket, ein Chat-Verlauf, ein

Datenbankfeld, ein **RAG**-Dokument, ein Werkzeug-Ergebnis, eine externe **API**-Antwort. Dabei steht PDF für *Portable Document Format*, RAG für *Retrieval-Augmented Generation* (Antwortgenerierung mit abgerufenem Kontext) und API für *Application Programming Interface*. Der Nutzer ist ahnungslos und stellt eine harmlose Frage; das Modell liest den vergifteten Inhalt „nur“ und befolgt die versteckte Anweisung. Das ist der gefährlichere Fall, weil der Angreifer **nicht mit dem System interagieren muss** — er muss nur Inhalt platzieren, den es irgendwann liest. Greshake et al. 2023 ist der Kanon dieses Angriffs [REAL] ; ihre Taxonomie nennt Datendiebstahl, „Worming“ (sich selbst weiterverbreitende Injektionen), Ökosystem-Kontamination und unautorisierte API-Aufrufe.


Stored / Persistent Injection. Eine Sonderform der indirekten Injection: Die Anweisung wird **dauerhaft** in einem Speicher abgelegt, den das System später als vertrauenswürdigen Kontext behandelt — ein Gedächtnis-Fakt, eine gespeicherte Zusammenfassung, ein indizierter Vektor-Chunk. Sie wirkt nicht einmal, sondern **bei jedem künftigen Lauf**, oft lange nach dem ursprünglichen Kontakt (§9).

T2 · Injection-Typ → Carrier → Propagation → Wirkung

Typ	Typischer Carrier	Wie sie sich fortpflanzt	Beispielwirkung
Direkt	Nutzer-Eingabe	sofort im selben Turn	Regel-Umgehung, Tool-Missbrauch
Indirekt	Doc/Webseite/E-Mail/Tool-Ergebnis	Retrieval/Tool → Kontext → Entscheidung	Exfiltration, ungewollte Aktion
Stored	Memory-Fakt, Summary, Vektor-Chunk	persistiert → jeder spätere Lauf	wiederkehrende Kompromittierung

Direkte, indirekte und gespeicherte Injection

drei technisch verschiedene Eintrittswege — sie bestimmen, wo man verteidigt und wer der Angreifer ist



Indirekt ist gefährlicher: der Angreifer muss nicht interagieren — nur Inhalt platzieren, den das System liest.

Kanon der indirekten Injection: Greshake et al. 2023 · realer Zero-Click-Fall: EchoLeak / CVE-2025-32711 (2025).


D2 · Direkte, indirekte und gespeicherte Injection

Realer Fall — EchoLeak / CVE-2025-32711 [REAL, Juni 2025]. In Microsoft 365 Copilot demonstrierten Sicherheitsforscher (Aim Security) eine **Zero-Click** indirekte Injection. Die Kennung stammt aus dem Katalog *Common Vulnerabilities and Exposures (CVE)*, den Schweregrad 9.3 vergibt das *Common Vulnerability Scoring System (CVSS)*. Eine unauffällige E-Mail — die Anweisung versteckt als Kommentar in *HyperText Markup Language (HTML)* oder weiß auf weiß — wurde von Copilots RAG-Pipeline verarbeitet; ohne jede Nutzerinteraktion konnte interner Inhalt an einen fremden Server exfiltriert werden. Der Angriff **umging** dabei mehrere Schutzschichten, darunter einen dedizierten Injection-Klassifikator (Microsofts „**XPIA**“ — *Cross-Prompt Injection Attempt*) sowie Link-Redaction, per Reference-Markdown, auto-geladenem Bild und einem via **CSP (Content Security Policy)** erlaubten Proxy. Microsoft hat serverseitig gepatcht; keine Ausnutzung in-the-wild. **Die**

Lehre: Ein einzelner Injection-Detektor — selbst ein produktiver, dedizierter — ist umgehbar; die Wirkung entstand erst durch die **Kette** von Umgehungen (§10), nicht durch die Injektion allein.

4. Das agentische Propagationsmodell

Der wichtigste Denkraum dieses Kapitels ist **nicht** die lineare Kette aus K26, sondern ein **zyklischer Propagationsgraph**. Eine Injektion pflanzt sich entlang folgender Übergänge fort — und jeder Übergang kann auf einen früheren zurückwirken:




Die drei Rückkopplungen machen das agentische Problem qualitativ härter als reine Chat-Injection:

- **Tool-Ergebnis → neuer Prompt.** Die Ausgabe eines Werkzeugs wird Teil des nächsten Modell-Kontextes. Vergifteter Tool-Output injiziert die *nächste* Iteration.
- **Agent-Output → anderer Agent.** Was Agent A produziert, wird Eingabe für Agent B — als scheinbar „interner“, vertrauenswürdiger Kontext (§10).
- **Memory-Write → späterer Lauf.** Ein in dieser Sitzung geschriebener Fakt wird in einer *künftigen* Sitzung re-injiziert (§9). Die Schleife schließt sich über die Zeit.

Das agentische Propagationsmodell

eine Injektion pflanzt sich fort — und jeder Übergang kann auf einen früheren zurückwirken



Ein Security-Check nur am ersten Input genügt nicht.

Trust muss an JEDER Übergabe neu bewertet werden — Retrieval, Tool-Ausgabe, Agent-Übergabe, Memory-Read.

Die drei Rückkopplungen machen agentische Injection qualitativ härter als reine Chat-Injection.

D1 • Das zyklische Propagationsmodell mit Rückkopplungen

Die zentrale Konsequenz — sie trägt das ganze Kapitel:

Ein Security-Check nur am ersten Input genügt nicht. Trust muss an *jeder* Übergabe neu bewertet werden — Retrieval-Grenze, Tool-Ausgabe-Grenze, Agent-Übergabe, Memory-Read. Wer nur die Nutzer-Eingabe prüft, hat die indirekten, gespeicherten und Multi-Hop-Wege (§10) offengelassen.

5. Attack Surface Inventory

Die agentische Angriffsfläche ist **der gesamte Kontext**, nicht das Eingabefeld. Für jede Fläche stellt man dieselben fünf Fragen: Woher kommt der Input? Wer kontrolliert ihn? Kann er Instruktionen enthalten? Welche Autorität besitzt er (Antwort fast immer: keine)? Welche Wirkung kann er auslösen?

T3 · Attack Surface Inventory

Fläche	Herkunft	Kontrolliert von	Kann Instruktionen tragen?	Autorität	Mögliche Wirkung
Nutzer-Eingabe	Client	Nutzer/Angreifer	ja (direkt)	keine	Regel-Umgehung, Tool-Trigger
Hochgeladene Dateien	Client/Upload	Nutzer/Angreifer	ja	keine	indirekte Injection
Retrieval-Korpus	Indizierung	wer indiziert / Doc-Autor	ja (indirekt/stored)	keine	RAG-Poisoning (§7)
Suchergebnisse / Webseiten	externes Web	jeder im Web	ja	keine	indirekte Injection
E-Mail / Ticket / CRM	extern eingehend	Absender/Angreifer	ja	keine	Zero-Click-Injection (EchoLeak)
Werkzeug-Ergebnisse	externe API/System	API-Betreiber/Angreifer	ja	keine	Tool-Output-Injection (§8)
Memory / Fakten	vorherige Läufe	Extraktion aus untrusted Content	ja (stored)	keine (behandelt als SECONDARY)	Memory-Poisoning (§9)
Agent-Nachrichten	anderer Agent	dessen Modell/Input	ja	keine	Cross-Agent-Propagation (§10)
Externe APIs	Drittsysteme	Drittanbieter	ja	keine	Injection + Datenabfluss
Modell-Struktur-Output	eigenes Modell	(manipulierbar)	ja	keine	Argument-/Sink-Injection (§11, §12)
Tool-Argumente	Modell-Entscheidung	(aus manipuliertem Plan)	n/a	keine	falsches Objekt/Ziel (§8)
Event-Payloads	Eventing/Outbox	Producer	ja	keine	verzögerte Injection
Human-Approval-UI	System-Rendering	(zeigt manipulierten Inhalt)	indirekt	menschliche Grenze	Fehlfreigabe (§11)

Die Spalte „Autorität“ ist die wichtigste — sie ist durchgehend **keine**. Genau das ist die Design-Vorgabe: Keine dieser Flächen darf Autorität *erzeugen*; Autorität kommt ausschließlich aus dem verifizierten Principal an der Autorisierungsgrenze (§11).

Markierungen in dieser Leseprobe

Einzelne Sätze tragen eine Markierung, die sagt, woher die Aussage stammt und wie belastbar sie ist. Hier stehen nur die, die in dieser Leseprobe vorkommen.

Markierung	Bedeutung
[REAL]	ein dokumentierter realer Vorfall, kein konstruiertes Beispiel.