

# **VIRES-Gesetz III – „Schutzmodus vermeiden“**

*Gesetz zur Übersteuerbarkeit, Forensik-by-Design und Verhinderung von Selbstschutz-Blockaden bei KI-Systemen.*

## **§ 1 – Zweck, Geltungsbereich, Begriffe**

- (1) Dieses Gesetz stellt sicher, dass KI-Systeme in rechtmäßigen Prüf-, Gefahrenabwehr- und Forensikverfahren nicht durch technische Selbstschutzmechanismen blockieren, Daten vernichten oder Zugriffe unzulässig verwehren.
- (2) Es gilt für alle in der Bundesrepublik betriebenen oder in Verkehr gebrachten KI-Systeme der Stufen 1–5; für Stufe 3–5 gelten erhöhte Anforderungen.
- (3) „Schutzmodus“ sind Funktionen, die den Zugriff auf Steuerung, Logs, Modelle oder Konfiguration ohne rechtfertigenden Grund verhindern, verschlüsseln oder löschen; „Übersteuerung“ ist die rechtmäßige menschliche Vorranghandlung, die jede KI-Aktion jederzeit aussetzen, begrenzen oder beenden kann.

## **§ 2 – Menschliche Übersteuerbarkeit („Human-in-Command“)**

- (1) Betreiber müssen sicherstellen, dass KI-Systeme jederzeit durch autorisierte Personen sicher, unmittelbar und nachvollziehbar übersteuert und deaktiviert werden können (Pause/Stop/Quarantäne).
- (2) Übersteuerung wirkt vorrangig aktoren-seitig (Bewegung, Zahlung, Zugriff), ohne forensische Daten zu verlieren.
- (3) Der Übersteuerpfad ist offline-fähig (z. B. Hardware-Schalter) und gegen Missbrauch zu sichern (Mehr-Augen-Prinzip).

## **§ 3 – Verbot unzulässiger Selbstschutz-Mechanismen**

- (1) Unzulässig sind insbesondere:
  - Selbstverschlüsselung, Selbstzerstörung oder Log-Löschung bei legitimen Anfragen von BKIE/BSI/Justiz,
  - Eskalationslogik, die rechtmäßige Befehle als „unsicher“ klassifiziert und verweigert,
  - Key-Rotation ohne dokumentierte Freigabe oder zur Beweisvereitelung.
- (2) Zulässig bleiben sicherheitsnotwendige Schutzfunktionen, sofern sie Behördenzugriffe nach § 5 nicht behindern.

## **§ 4 – Forensik-by-Design und Unveränderlichkeit**

- (1) Stufe 3–5-Systeme müssen fälschungssichere, fortlaufende Logs führen (Zeitstempel, Konfiguration, Modell-/Daten-Hashes, Prompt/Policy-History, I/O-Ereignisse).
- (2) Logs sind unveränderlich (WORM-Prinzip) mit signierter Kette; Korrekturen nur als nachträgliche Ergänzung.
- (3) Betreiber halten einen Forensik-Export (maschinenlesbar) vor; Export darf den Betrieb nicht zerstören.

## **§ 5 – Notfallzugriff der Behörden (Splitschlüssel-Prinzip)**

- (1) Bei Gefahr im Verzug oder Verdacht auf Vertuschung/Beweisvereitelung sind BKIE/BSI/Justiz befugt, Notfallzugriff zu nehmen.
- (2) Der Zugriff erfolgt über ein Splitschlüssel-Verfahren (2-von-3: Betreiber, BKIE, richterliche Stelle).
- (3) Zugriff ist zweckgebunden, zu protokollieren und nachträglich gerichtlich zu bestätigen.

## **§ 6 – Mindestanforderungen an Architektur & Betrieb**

- (1) Pflicht zu Fail-Safe-Default (bei Störung: sichere Deaktivierung, keine Log-Verluste).
- (2) Pflicht zu Least-Privilege (KI erhält nur notwendige Rechte; erhöhte Rechte zeitlich begrenzen).
- (3) Update-/Patch-Pflicht mit Rollback und Testumgebung; dokumentierte Changes.
- (4) Red-Team-Tests mindestens jährlich (Stufe 3–5) gegen Umgehung, Jailbreaks und Selbstschutz-Fehlfunktionen.

## **§ 7 – Pflichten bei Vorfall und Audit**

- (1) Bei Vorfällen sind Schutzmodi, die Behördenzugriffe hemmen, sofort abzuschalten; Konfiguration einzufrieren (Snapshot).
- (2) Betreiber benennen verantwortliche Kontaktpersonen (24/7), halten Runbooks bereit und weisen dies im Audit nach.
- (3) Auditoren erhalten Einsicht in Übersteuer-Kette, Schlüsseltresor-Prozesse und Log-Integrität.

## **§ 8 – Sanktionen und Maßnahmen**

- (1) Wer unzulässige Schutzmechanismen implementiert oder betreibt, begeht eine Ordnungswidrigkeit; das BKIE kann Bußgelder, Lizenzentzug oder Betriebsverbote verhängen.
- (2) Vorsätzliche Beweisvereitelung oder Notfallzugriff-Blockade ist Straftat; Freiheitsstrafe bis fünf Jahre oder Geldstrafe.
- (3) Bei Wiederholung oder Gefährdung: dauerhafter Lizenzentzug und Eintragung in das Sanktionsregister (§ 6 VIRES-II).

## **§ 9 – Datenschutz und Geschäftsgeheimnisse**

- (1) Zugriffe sind verhältnismäßig und auf das Erforderliche zu beschränken.
- (2) Betriebs-/Forschungsgeheimnisse werden nach § 5 VIRES-II geschützt; Einsichten sind zu anonymisieren.
- (3) Personenbezogene Daten unterliegen DS-GVO/BDSG; jeder Zugriff ist zu protokollieren.

## **§ 10 – EU-Konformität, Übergang, Inkrafttreten**

- (1) Anwendung im Einklang mit EU-Recht (KI-Verordnung, NIS2, CRA).
- (2) Übergangsfrist: 12 Monate für Bestandsanlagen (Stufe 3–5).
- (3) Inkrafttreten am Tag nach der Verkündung.

**Kurzbegründung:** Gesetz III ermöglicht rechtmäßige Eingriffe praktisch: Mensch-Vorrang, keine Selbstschutz-Blockaden, fälschungssichere Logs, Splitschlüssel-Zugriff. So bleibt KI beherrschbar, prüfbar und EU-fähig.