

PERSONENDATEN IM ZEITALTER VON MACHINE LEARNING – EINE ERSTE ANNÄHERUNG

20. Februar 2025, IRIS 2025 in Wien

Dr. iur. Philip Glass
Fachstelle für Datenschutz- und IT-Recht

ART. 5 BST. A DSG

- Angaben über bestimmte oder bestimmbare Personen
- ⇒ 4 Informationskategorien: Angaben, Person, Verknüpfung, Identifizierung
- Personendaten sind stets ein Datenmuster (das erhalten werden soll)
 - Kern des Musters ist die Verknüpfung mit Personen (Personenbezug)
 - Personendaten sind stets eine Form der Bearbeitung
 - zB auch data at rest ist Bearbeitung i.S. des Datenschutzrechts
 - Personenbezug: Zusammenspiel von syntaktischen und semantischen Informationen in Datenform
 - Passive und aktive Verknüpfung

Datenschutzrechtlicher (identifizierender) Personenbezug

FORMEL PERSONENBEZUG IM CH-RECHT (BOTSCHAFT DSG 2017, BBL 2017 6941, 7019)

«Ist der Aufwand für die Bestimmung der betroffenen Personen derart gross, dass **nach der allgemeinen Lebenserfahrung** nicht damit gerechnet werden muss, dass ein Interessent diesen auf sich nehmen wird [...], liegt keine Bestimmbarkeit vor.»

(Botschaft DSG 1988, BBl 1988 II 444)

Vielmehr muss die **Gesamtheit der Mittel** betrachtet werden, die **vernünftigerweise eingesetzt** werden können, um eine Person zu identifizieren. Ob der Einsatz dieser Mittel vernünftig ist, muss mit Blick auf die **Umstände, etwa den zeitlichen und finanziellen Aufwand** für die Identifizierung, beurteilt werden. Dabei sind die zum Zeitpunkt der Bearbeitung **verfügbaren Technologien und deren Weiterentwicklung** zu berücksichtigen.

⇒ Setzt eine gewisse Berechenbarkeit des Risikos voraus

Syntaktischer und semantischer Personenbezug

ZWEI VERSCHIEDENE ASPEKTE VON INFORMATION

- Syntaktischer Personenbezug
 - Logische Zuweisung von Daten zu Personen mittels Syntax
 - «Verknüpfung» von Daten mit Personen mittels «Identifikatoren»
 - aktive / passive Verknüpfung
 - aktiv: Personendaten werden initial generiert
 - passiv: Nutzung bestehender Verknüpfungsmuster
- Semantischer Personenbezug
 - Bedeutungsgehalt der Daten bezieht sich notwendigerweise auf Personen (Menschen)

⇒ Betreffen beide nicht notwendigerweise (für jeden) bestimmbar Personen

Syntaktischer und Semantischer Personenbezug

IM EINZELNEN

- Syntaktische Komponente
 - Singularisierung durch syntaktisch korrekte Verknüpfung von Daten im Hinblick auf eine Person
 - benötigt Platzhalter für diese Person (beliebige Bezeichnung denkbar)
 - systeminterne Identifizierung
- Semantische Komponente
 - Semantische Übersetzung der syntaktischen Verknüpfung
 - erkennen der Bedeutung als Personendatum einer identifizierten Person)
 - Identifikatoren aus der Systemumwelt
 - Externe Identifizierung

Beobachtungen in Zusammenhang mit ML

AUSGANGSLAGE

- ML: Mehrdimensionale stochastische Analysen transformieren Input zu Output
 - Output nicht notwendigerweise empirisch belastbar
 - mit statistischen Methoden berechnete Prognose generiert aus Input
 - syntaktische Verknüpfungen innerhalb des Modells unklar (noch?)
 - semantische Interpretation von Verknüpfungen innerhalb des Modells irrelevant (noch? AGI... :))
- Komplexe syntaktische Verknüpfungen; semantisch kaum interpretierbar (Opazität des Modells)
 - generiert jeweils «neue» (Personendaten)Daten (nicht: recall)
 - bestenfalls ex post nachvollziehbar
 - Unterscheidung aktive/passive Verknüpfung irrelevant
 - unklar, ob bearbeiten oder erheben von Personendaten

Beobachtungen in Zusammenhang mit ML

BEARBEITUNGSKONSTELLATIONEN

- Input Personendaten /Daten => Output Personendaten
 - Bearbeitung von Personendaten /Profiling (grundsätzlich rechtlich erfassbar)
- Auslesen von Trainingsdaten
 - umstritten ob durch recall oder generiert (grundsätzlich generiert)
 - Erfolg folgt offenbar nicht linear dem Aufwand.

⇒ Risikoprognose nach der klassischen Formel «fraglich».

- Lösung: ML-Modelle sollen als Pseudonyme für Trainingsdaten mit Personenbezug behandelt werden
⇒ Informationspflichten etc.