


Sicherheits- und Datenschutzaspekte von Big Data

Herbert.Leitold@a-sit.at


ADV-Tagung Big Data 2016

Übersicht

- Einleitung
- Sicherheitsanforderungen
- Big Data und Datenschutz
- Forschungsprojekte




Umfeld und Fokus des Vortrags



Quelle: Modifiziert aus
Joel Gurin „Open Data Now“, 2014.

Ist „Big Data“ speziell bzgl. Sicherheit?

- Ergeben sich aus Big Data Charakteristika spezifische Sicherheits-Anforderungen?
- Big Data Charakteristika
 - *Volume* – Datenmenge
 - *Velocity* – kurze Lebensdauer
 - *Variety* – Quellen, Datenarten
 - *Veracity* – Richtigkeit



Quellen

cloud
CSA security
alliance™

Top Ten Big Data Security
and Privacy Challenges

CSA, 2012



Positionspapier zu Big Data in der
öffentlichen Verwaltung
(Stand 06.06.2016)

White Paper

Big Data – 1.0.0

Ergebnis der PG

Kurzbeschreibung

Der exponentielle
Maschine erzeugten
öffentliche Verwaltu
Chancen mit sich.

BLSG,
2016

ARTICLE 29 DATA PROTECTION WORKING PARTY



14/EN
WP 221

Statement on Statement of the WP29 on the impact of the development of
big data on the protection of individuals with regard to the processing of
their personal data in the EU

Art. 29, 2014

Übersicht

- Einleitung
- **Sicherheitsanforderungen**
- Big Data und Datenschutz
- Forschungsprojekte



Top Ten nach CSA

1. Secure Computations in Distributed Programming Frameworks
2. Security Best Practices for Non-Relational Data Stores
3. Secure Data Storage & Transaction Logs
4. End-Point Input Validation/Filtering
5. Real-time Security/Compliance Monitoring
6. Scalable & Composable Privacy-Preserving Data Mining & Analytics
7. Cryptographically Enforced Access Control & Secure Communication
8. Granular Access Control
9. Granular Audits
10. Data Provenance



Secure Computation / NoSQL

1. Rechnen in verteilter Umgebung

- Massive Parallelisierung. zB *MapReduce Framew.*
- Kompromittierter Mapper kann falsche Daten liefern, daraus falsche aggregierte Ergebnisse
- Mapper könnten vertrauliche Daten leaken

2. NoSQL Security Best Practices

- Entwicklung aus Analyse-Sicht, Sicherheit meist kein Schwerpunkt der Entwicklung

Secure Storage / Input Validation

3. Sichere Speicherung und Transaction Logs

- Multi-tiered storage benötigt auto-tiering für storage management. Wo liegen die Daten?
- **Rechtsraum-bewusstes Speichern (legislation-aware)?**

4. End-point Input-Validation, Filtering

- Hohe Zahl an Sensoren, BYOD, ...
- Authentizität der Quelle, zB rogue virtual sensors

Real-Time Monitoring / PET

5. Echtzeit Security/Compliance Monitoring
 - Über hohe Volumen herausfordernder
 - Mehr Daten und Analyse kann schnellere und bessere Einschätzung/Entscheidung bringen
6. Skalierbare Datenschutz-wahrende Daten-Sammlung und -Analyse
 - Aus besserer Korrelation potentiell stärkerer Personenbezug und Profile

7. Kryptographie-gestützte Zugangskontrolle
 - Traditionelle Verschlüsselung „alles oder nichts“
 - Forschung zu Attribute-Based Encryption
 - Rechnen mit Secure Multiparty Communication
8. Granulare Zugangskontrolle
 - Traditionell grob-granular; höhere Granularität macht Management aufwändiger
 - Automatisierung policy-enforcement

Granulares Audit / Provenance

9. Granulare Audits


- Für Audit/Forensik mehr Datenquellen, die potentiell verteilt sind
- Audit-Daten aus Compliance-Anforderungen

10. Datenherkunft

- Metadaten zur Herkunft steigen im Volumen
- Anforderungen aus Compliance, zB Insider-Handel


Aus Big Data Eigenschaften

- Wie stehen die diskutierten Herausforderungen zu Big Data Charakteristika?
- Was macht Big Data spezifisch?




Herausforderung aus Volumen

- Sicheres Rechnen in verteilten Systemen
- Rechtsraum-bewusstes Speichern
- Anforderungen an Effizienz von kryptographischen Verfahren, aber auch an die Funktionalität (z.B. ABE, SMPC)
- Granulare Audits oder Zugangskontrolle




Herausforderung aus Lebensdauer

- Echtzeit Security-Monitoring
- Nachweis zu Datenherkunft
- Anforderungen an Effizienz von kryptographischen Verfahren




Herausforderung aus Richtigkeit

- Authentizität der Daten von Mappern aus massiver Parallelisierung
- Authentizität der Datenquellen, z.B. von Sensoren oder BYOD



Herausforderung aus Vielfalt/Datenarten

- Input-validation bei hoher Anzahl (verschiedener) Quellen
- Mehr Daten und bessere Analyse zielt auf bessere Ergebnisse ab
- Damit aber auch potentiell höhere Qualität im Personenbezug => *Datenschutz*



Überblick

- Einleitung
- Sicherheitsanforderungen
- **Big Data und Datenschutz**
- Forschungsprojekte



Automatisierte Entscheidungen

- Big Data verspricht bessere (automatisierte) Entscheidungen

EU DSGVO §22: Die betroffene Person hat das Recht, nicht einer ausschließlich auf einer automatisierten Verarbeitung — einschließlich Profiling — beruhenden Entscheidung unterworfen zu werden, die ihr gegenüber rechtliche Wirkung entfaltet oder sie in ähnlicher Weise erheblich beeinträchtigt.

Zweckbindung der Datenverarbeitung

- Bei Verknüpfung von Daten mit Personenbezug ist Zweckbindung ggf. verletzt

EU DSGVO §5(b): Personenbezogene Daten müssen ... für festgelegte, eindeutige und legitime Zwecke erhoben werden und dürfen nicht in einer mit diesen Zwecken nicht zu vereinbarenden Weise weiterverarbeitet werden

- Art. 29 WP sieht in Zweckbindung u.a. auch ein Vermeiden von Marktverzerrungen.

Sicherheit der Datenverarbeitung

- Verantwortliche der Datenquellen haben geeignete Schutzniveaus sicherzustellen

EU DSGVO §21: Unter Berücksichtigung des Stands der Technik, der Implementierungskosten und der Art, des Umfangs, der Umstände und der Zwecke der Verarbeitung sowie *[etc. etc.]* treffen der Verantwortliche und der Auftragsverarbeiter geeignete technische und organisatorische Maßnahmen ...

- Bei mehreren Quellen *Maximum* einzelner Schutzniveaus *Minimum* der Verknüpfung

Anonymisierung, Pseudonymisierung


- Open Data oft ohne Personenbezug
 - Pseudonymisiert / Anonymisiert?

EU DSGVO (26): Bei der Feststellung, ob Mittel nach allgemeinem Ermessen wahrscheinlich zur Identifizierung der natürlichen Person genutzt werden, sollten alle objektiven Faktoren, wie die Kosten der Identifizierung und der dafür erforderliche Zeitaufwand, herangezogen werden, wobei die zum Zeitpunkt der Verarbeitung verfügbare Technologie und technologische Entwicklungen zu berücksichtigen sind.

- Aus Vielzahl an Quellen ist möglich, dass urspr. nicht gegebener Personenbezug aus Verknüpfung hergestellt wird.


Zusammenfassung Datenschutz

- Vor allen Zusammenführung von Daten mehrerer Quellen ist zu bedenken
 - neuer Zweck der Datenverarbeitung
 - Personenbezug über Korrelation möglich



Überblick


- Einleitung
- Sicherheitsanforderungen
- Big Data und Datenschutz
- **Forschungsprojekte**



- Horizon 2020 Forschungsprojekt zu fördern von private Clouds der öff. Verwaltung
- Pilotierung in drei Use Cases
 - *Private Cloud Federation, with a Segregated Environment;*
 - *Hybrid Cloud Federation (Private and Public Cloud) a Segregated Environment;*
 - *Private Cloud Federation, with a Secure Multiparty Computation Environment.*

- Regional Organised Crime Units (ROCUs) in UK halten große Mengen sensibler Daten
 - zB aus Beweissicherungen
- Lokale Such-Indizes in jeder ROCU, jedoch auch inter-ROCU Suche erforderlich, ohne Information über Quelle und Inhalt zu geben
- Unter Leitung von Cybernetica (EE) Such-Indizes für Secure Multiparty Communication gebildet
 - SMPC: Operiert auf verschlüsselten Daten


Such-Index mit SMPC



Cloud for Europe



- Vorkommerzielle Auftragsvergabe zur Unterstützung der EK Mitteilung Cloud
- 3 Lose vergeben
 - *Federated Certified Services Brokerage for EU Public Administration Cloud*
 - *Secure Legislation-Aware Storage*
 - *Legislation Execution Cloud Services*



Arbeiten der Auftragnehmer starten erst

Danke für Ihre
Aufmerksamkeit!



Herbert.Leitold@a-sit.at

ADV-Tagung Big Data 2016