


Smart Data Management: Shaping und Optimierung mit Splunk Edge Processor und S3

Splunk Public Sector Summit



Ihre Ansprechpartner



Nahbar, Direkt & Erreichbar



Jorg Veit

Senior Technical Consultant Analytics Engineering

E-Mail jorg.veit@controlware.de



Daniel Seifert

Teamlead Analytics Engineering

E-Mail daniel.seifert@controlware.de

Ausgangssituation



Es kommen im mehr Daten an

Neue Datenquelle mit erhöhtem Volumen
Bestehende Datenquellen verbrauchen höhere Volumina



Regeln für Compliance werden immer strenger

Aufbewahrungszeiten müssen erhöht werden
Log Level / Detaillierung muss angepasst werden



Begrenztes Budget bzw. Splunk Lizenzvolumen

Budget wird nur gering oder gar nicht erhöht
Lizenzvolumen stagnieren

Zielbild



Alle relevanten Daten und Felder in Splunk indizieren

Gesteigerten Anforderungen gerecht werden
Neu Datenquellen anbinden



Gleichzeitig vollständiges Rohdatenarchiv für Compliance & Forensik

Aufbewahrung aller ankommenden Daten in Ihrem Ursprungs-Format
Schnelle Wiederherstellungsmöglichkeit der Rohdaten



Volle Kontrolle

Keine Beschaffung neuer Lizenzen
Keine Einführung neuer Software
Kein Ausleiten an Cloud Services (onPrem S3)

Ausgangssituation & Zielbild

Zielbild

Splunk Edge Processor

- Annahme der Daten
- Datenvorverarbeitung und shaping

Splunk Enterprise

- Indizierung relevanter Daten

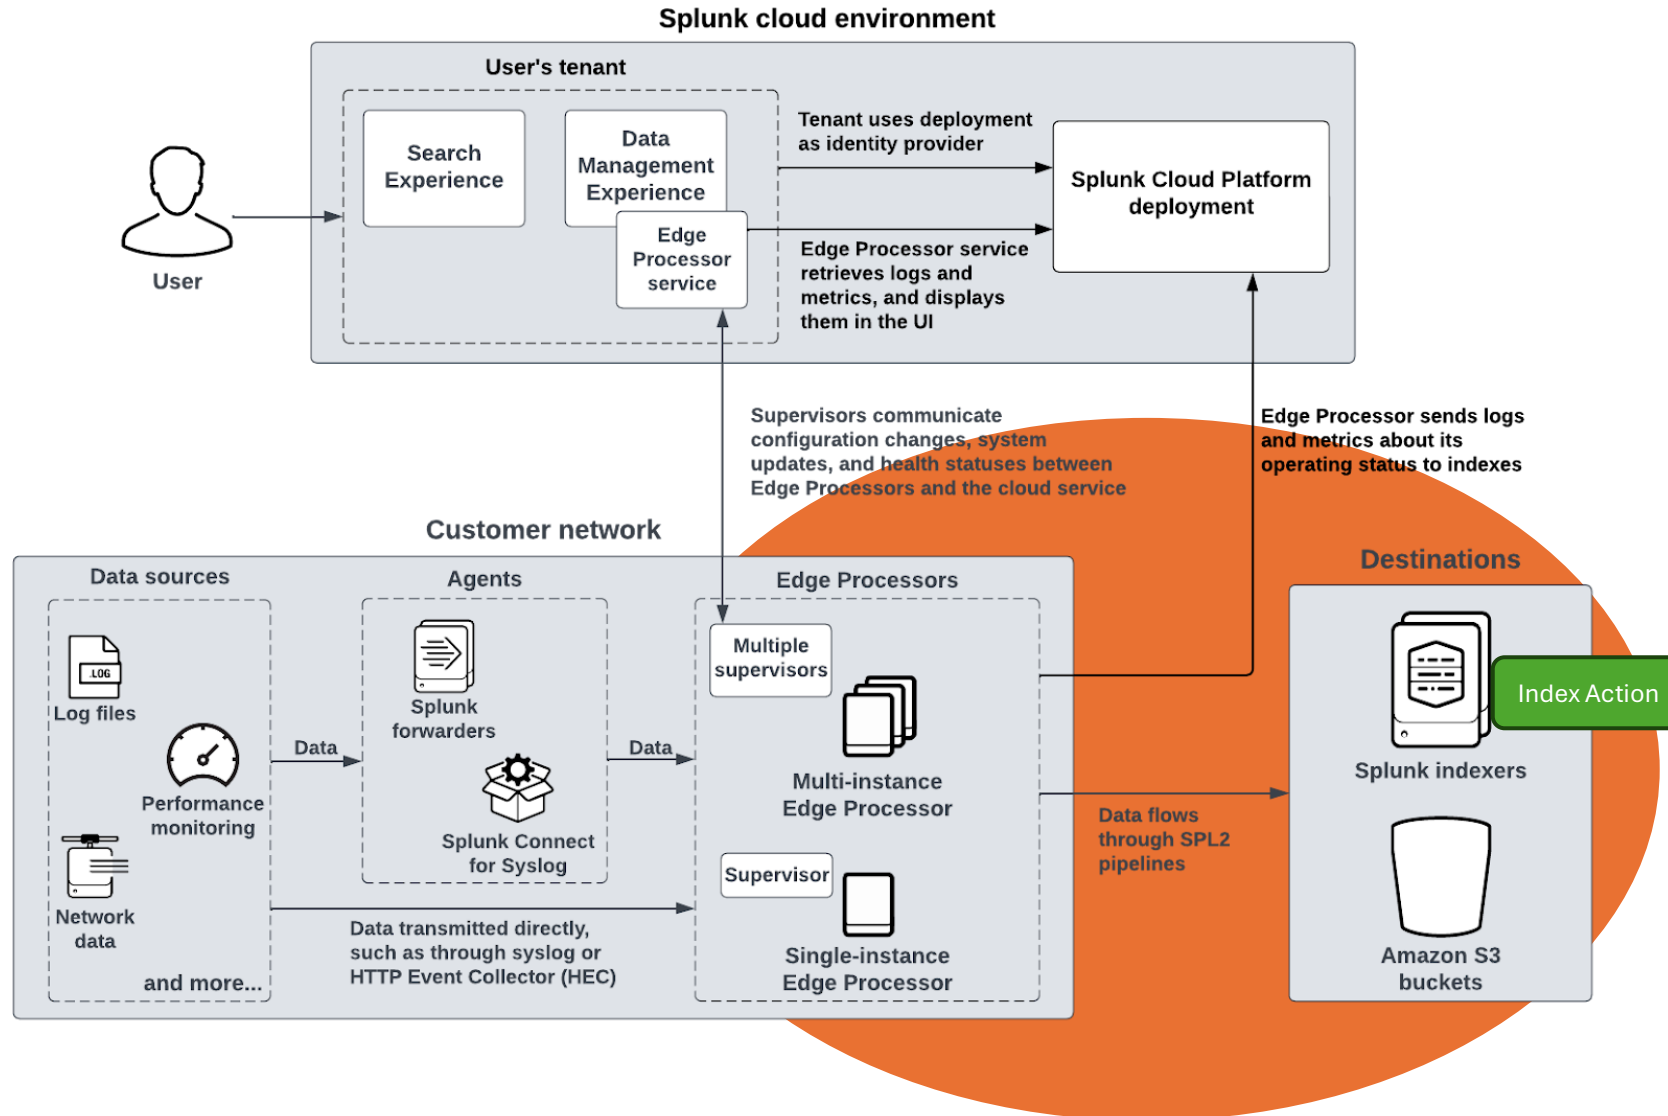
Splunk Custom Command

- Durchsuchen der S3 Daten
- Wiederherstellung S3 Daten

Splunk Index Actions

- Weiterleitung an S3 kompatiblen Speicher

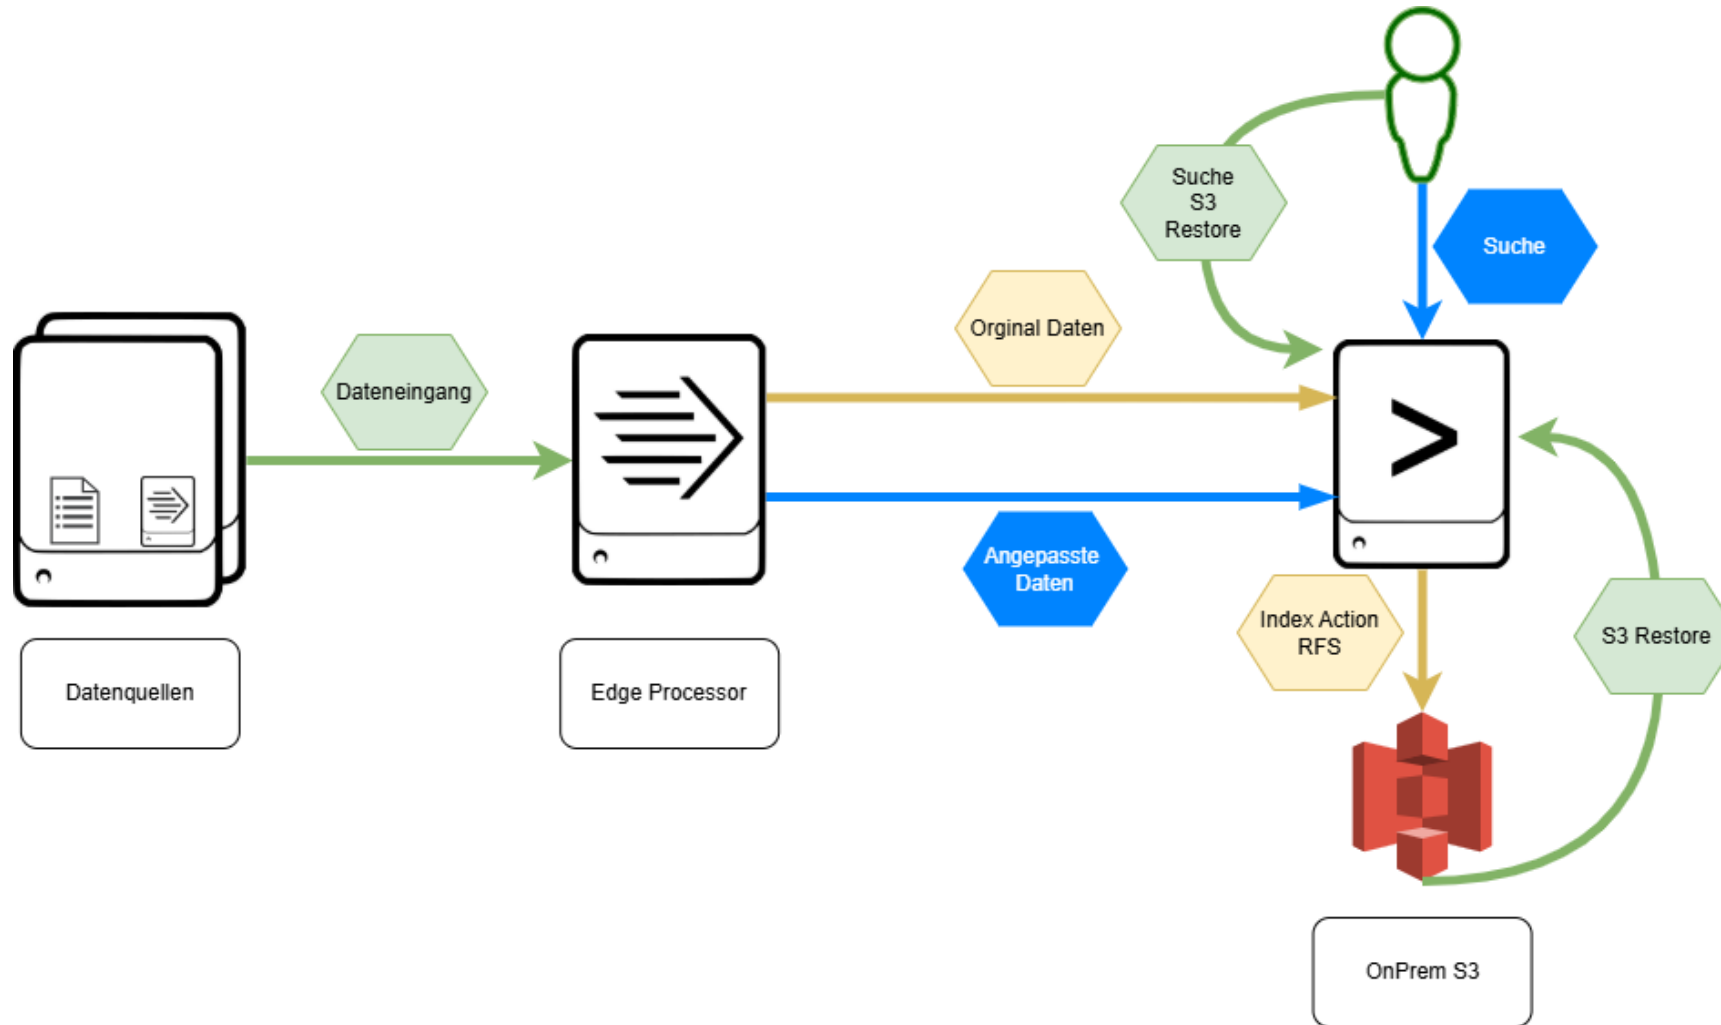
Herausforderungen:



Herausforderungen

- Edge Processor kann aktuell keine Daten an OnPrem S3
- Ablagestruktur der S3 Daten durch Splunk (Pfad)
- Index Actions finden nach dem Edge Processor statt
- Wiederherstellung sollte einfach für den Anwender sein
- Welche Daten brauchen wir wirklich?
 - Filtern von technischen „Noise“-Events (z. B. Health-Checks)
- Welche Felder sollen bleiben?
 - Konzentration auf Felder, die für Use Cases relevant sind
- Welche Informationen sind sensibel?
 - Maskierung von Benutzernamen, IP-Adressen, E-Mail-Adressen etc.

Lösungsmöglichkeit:



Lösungsmöglichkeit

- Ein Event kommt beim Edge Processor an
- Es wird einmal geparkt und verstanden
- Dann passieren zwei Dinge parallel:
 - **Kopie 1 (für Splunk):**
 - Entrümpelt und aufbereitet
 - Nur die wesentlichen Felder bleiben
 - Event wird in Splunk indiziert
 - **Kopie 2 (für S3):**
 - Unverändert als Rohdaten
 - Wird im S3-Bucket abgelegt
- User kann auf zwei arten auf die Daten zugreifen
 - Splunk: Suche in den angepassten Daten
 - Splunk: Suche über ein Custom-Command
 - Direkt in S3 oder
 - Restore der Daten anfordern

Details Edge Processor

- Universal Forwarder sendet Roh-Events per S2S an den Splunk Edge Processor
- Im Edge Processor wird der Datenstrom dupliziert (zwei parallele Pipelines)
 - **Stream 1 (transformiert):**
 - Events werden beschnitten
 - Weiterleitung der optimierten Events an Splunk
 - **Stream 2 (roh):**
 - Events bleiben unverändert
 - 1:1-Weiterleitung per S2S an Splunk

Details Ingest Action

- Der Splunk Edge Processor sendet vorverarbeitete Daten an eine Index Action auf einem dedizierten Port.
- Die Index Action übernimmt die Daten, führt keinen Indexierungsvorgang in Splunk durch.
- Stattdessen werden die Events über das Remote File System (RFS) als Dateien geschrieben.
- RFS ist mit einem on-prem S3-kompatiblen Storage verbunden; die Daten landen direkt im S3 Bucket.

Details Custom Command

- Custom Command liest S3-Objekte ein und schreibt deren Metadaten in den Splunk KV Store (Index, Host, Source, Sourcetype)
- Zuerst wird nur der KV Store durchsucht: schnelle Identifikation relevanter S3-Objekte anhand von Zeit, Source, etc.
- Für die im KV Store identifizierten S3-Objekte lädt das Custom Command bei Bedarf die Rohdaten aus dem S3-Bucket
- Bereitstellung in Splunk (temporär oder in definiertem Re-Index) zur Analyse mit gewohnter SPL

Vielen Dank für Ihre
Aufmerksamkeit.
Thank you very much
for your attention.

