

# KI und Nachhaltigkeit bei Siemens

Fallbeispiele: Siemens Environmental Reporting Assistant &  
Siemens Environmental Knowledge Graph

DRSC Fachausschuss Nachhaltigkeitberichterstattung

16.06.2026

Sven Kristen

P&O EHS EP DA

# Siemens Environmental Reporting Assistant (SERA)

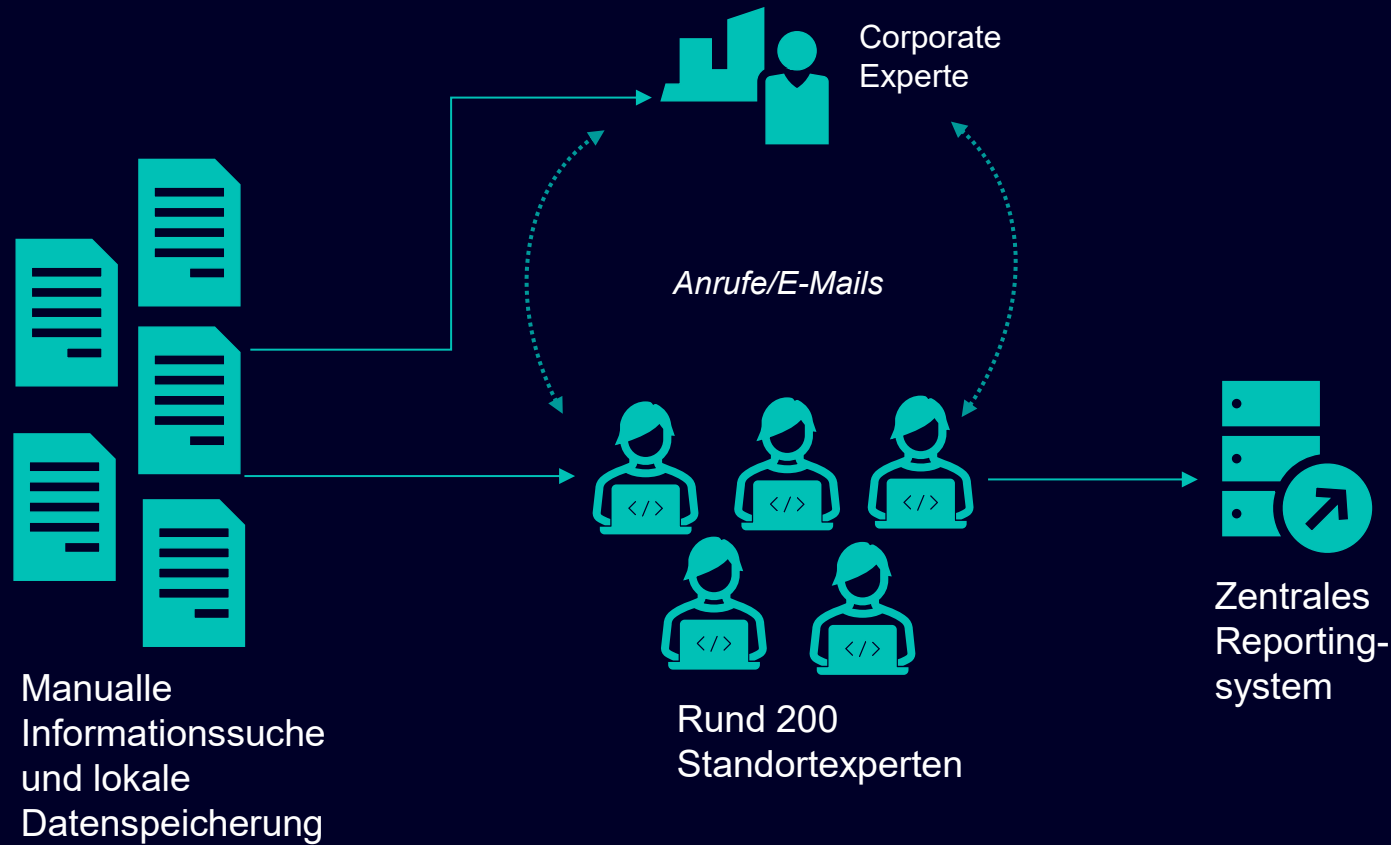
# Siemens Wasser Strategie & Wasserrisikoanalyse

2021 implementierte Siemens die [Siemens Water Strategy](#), um Wasser Management effektiver zu steuern. Ein zentraler Bestandteil der Siemens Water Strategy ist eine regelmäßige Wasserrisikoanalyse an allen relevanten Standorten.



<sup>1</sup> Do No Significant Harm | <sup>2</sup> Corporate Sustainability Reporting Directive | <sup>3</sup> Carbon Disclosure Project

# Vor Siemens Environmental Reporting Assistant (SERA)



## Herausforderungen

**Manueller** Analyse, basierend auf einem Fragebogen

**Manuelles** 4-Augenprinzip

**Begrenzte** analytische Erkenntnisse und Übertragbarkeit durch dezentrale Datenhaltung

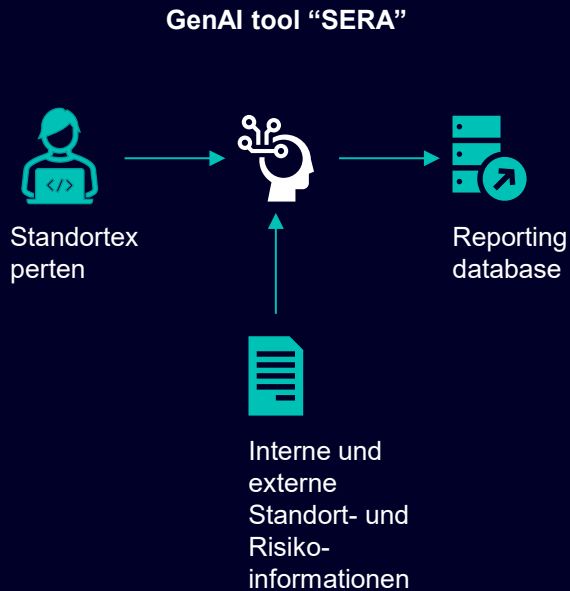
**SERA ist ein GPT-basierter Assistant der direkt in das Reportingsystem integriert wurde, um lokale Experten zu unterstützen sowie Vergleichbarkeit und Qualität der Daten zu erhöhen**

### Konzept

Fragebogenbasiertes, modulares **prompt-engineering**, welches intern validiert wurde und interne sowie externe Informationen in Echtzeit zur Verfügung stellt, sowie Eingaben prüft

### Integration

SERA wurde direkt in den **bestehenden Prozess** und das vorhandene Reportingsystem integriert



## Bewertung

Ca. **70% Aufwandreduzierung** durch Vermeidung von manuellen Abstimmungen

Ca. **50% Kosteneffizienzsteigerung** durch Entlastung

**24/7 Erreichbarkeit** sowie Skalierbar

Höher Nutzerfreundlichkeit

Höhere Datenqualität


# Siemens Environmental Knowledge Graph (SiEKG)

# Der Siemens Environmental Knowledge Graph wurde entwickelt, um fehlende Stoffinformationen zu modellieren und deren Gewichte pro Materialnummer zu schätzen

Die CSRD<sup>1</sup> verlangt die Offenlegung von Metriken aus der Wertschöpfungskette, wie die Menge der SoC<sup>2</sup>.


Offenlegung der Gesamtmengen der SoC, die bei der Produktion entstehen oder verwendet bzw. beschafft werden, sowie die Gesamtmengen an SoC, die die Standorte als Emissionen, als Produkte oder als Bestandteil von Produkten oder Dienstleistungen in den Verkehr bringen.

⚡ Mengenangaben zu SoC liegen nur teilweise vor, da diese bisher nicht gesetzlich verlangt wurden. Daher müssen sie geschätzt werden.



## Datensammlung

Nutzung von verschiedenen internen und externen Datenquellen, um Informationen zu Stoffen und zusätzlichen Attributen zu extrahieren.



## Datenvernetzung

Aufbau des "Knowledge Graphs" um verfügbare Daten und Attribute zu verknüpfen und deren Beziehungen zu definieren.



## Prädiktive Modelle

KI zur Schätzung fehlender Gewichtswerte sowie deren Wahrscheinlichkeiten

<sup>1</sup> Corporate Sustainability Reporting Directive | <sup>2</sup> Substances of Concern


# Die gesammelten Informationen werden in einem "Knowledge Graph" strukturiert und in Beziehungen gesetzt

## Datenvernetzung



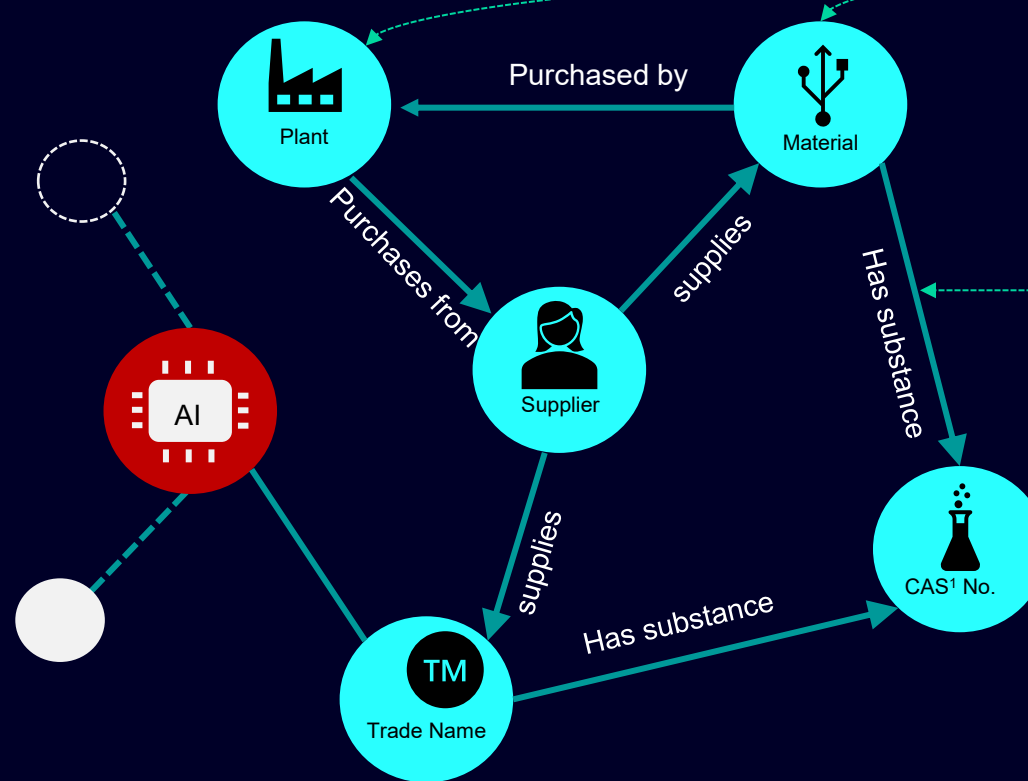
Die extrahierten Daten werden in einem Knowledge Graph miteinander verknüpft.

Ein Knowledge Graph ist eine strukturierte Verknüpfung von Daten, deren Eigenschaften sowie die Definition der Beziehungen zwischen ihnen. Diese Struktur ermöglicht eine komplexe Datenanalyse sowie den Einsatz von prädiktiven Modellen.

 Nach Verknüpfung aller vorhandenen Informationen enthält der Knowledge Graph noch Datenlücken

## Vereinfachter Knowledge Graph

Beispiel:



20,078,247  
Knotenpunkte

97 Beziehungen

62,504,482  
Datenpunkte

<sup>1</sup> Unique Identifier for Chemical Substances

# Der Knowledge Graph kann anschließend genutzt werden um mit Prädiktiven Modellen wie Neuronalen Netzen (ANN) Schätzungen fehlender Werte durchzuführen



## 1 Prädiktives Modell

Implementierung von KI, um fehlende Werte von Substanzen und deren Konzentrationen zu schätzen.

Je besser die Qualität und je höher die Abdeckung der erfassten Daten, desto besser sind die Modelergebnisse.

## Beispiel:

### Modell input

Material no.	Supplier	Volume	Weight	Substance	Concentration	Source	Likelihood
A12031...	xxx.	100k	1,2 t	Chromium	0.3%	Predicted	0.6
A53911...	xxx.	56k	0,5 t	Lead	1.1%	Declaration	1.0
A00231...	xxx	1200k	1500 t	-	-	-	-

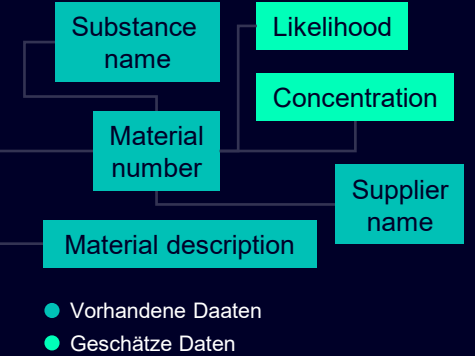


### Methode

Implementierung von KI, wie etwa künstliche neuronale Netze (ANNs), um Stoffkonzentrationen und die jeweiligen Genauigkeiten vorherzusagen.



### Modell output



Das Modell liefert zudem eine Wahrscheinlichkeitsschätzung, um die Genauigkeit der Vorhersagen zu bewerten.

### Vorhandene Einkaufsdaten

### Schätzwerte aus dem SoC<sup>4</sup> Modell

### Dummy Daten

Material no.	Supplier	Volume EUR	Weight	Substance	Concentration	Source	Likelihood	...
A12031...	xxx.	100k	1,2 t	Chromium	0.3%	Predicted	0.6	...
A53911...	xxx.	56k	0,5 t	Lead	1.1%	Declaration	1.0	...
A00231...	xxx	1200k	1500 t	-	-	-	-	...

# Erkenntnisse aus dem Siemens Environmental Knowledge Graph Audit

## Wenig Standardisierung

- Wenig oder keine Standardisierung für Prädiktive Modelle im Nachhaltigkeitsbereich
- Aufwändige Dokumentation
- Rolling Audit notwendig

## Neues Set-Up bei Prüfung

- Gemischte Auditorenteams (Data-Scientists und Nachhaltigkeitsprüfer)
- Neue Herangehensweise über statistische Prüfverfahren

## Mögliche Skalierung

- In das Modell können weitere Daten integriert werden, z.B.: Sekundärmaterialien
- Zusätzliche Daten erhöhen Genauigkeit

# Simple und bewährte Prädiktive Modelle können adaptiert und auf Nachhaltigkeitsinformationen in der Lieferkette angewandt werden

## Datensammlung und Stichprobe erstellen

- Auswahl der notwendigen Features für Schätzung
- Fokus auf representative Stichprobe mit hoher Qualität
- Notwendige Stichprobengrößen können berechnet werden

## Datenbereinigung / Qualitätsprüfung

- Bereinigen der Daten
- Prüfen auf Qualität und systematische Verzerrung

## Modelltraining und Datenschätzung

- Modell wählen (können aus anderen Disziplinen, e.g. Banken, Versicherungen, Tech, Wissenschaft, etc.)
- Modell trainieren und Schätzer berechnen

## Modellvalidierung, Auditierung und Verbesserung

- Statistische Testverfahren zur Validierung
- Auditierungsverfahren
- Sukzessive Integration von neuen Daten



## Herausforderungen

Einige qualitativ hochwertige Daten müssen zur Verfügung stehen

Notwendiges Know-How muss aufgebaut werden

Geringe Standardisierung verursacht hohen Auditierungsaufwand



## Vorteile

Genauigkeit der Modelle wird erhöht und ist quantifizierbar

Primärdaten können sukzessive in das Model eingefügt werden

Model ist leicht skalierbar

# Diskussion

# Kontakt

Siemens AG

**Sven Kristen**

**P&O EHS EP DA**

[sven.kristen@siemens.com](mailto:sven.kristen@siemens.com)

[Link zum Whitepaper:  
How can AI elevate sustainability reporting?](#)

