



Bundesnetzagentur

Trendthemen für DIN SPECs: Grundpfeiler der KI-Normung

Taras Holoyad

**Workshop „Anforderungen an KI-Prüfungen:
Standardisierungspotenziale identifizieren“**

Berlin, 11.09.2023



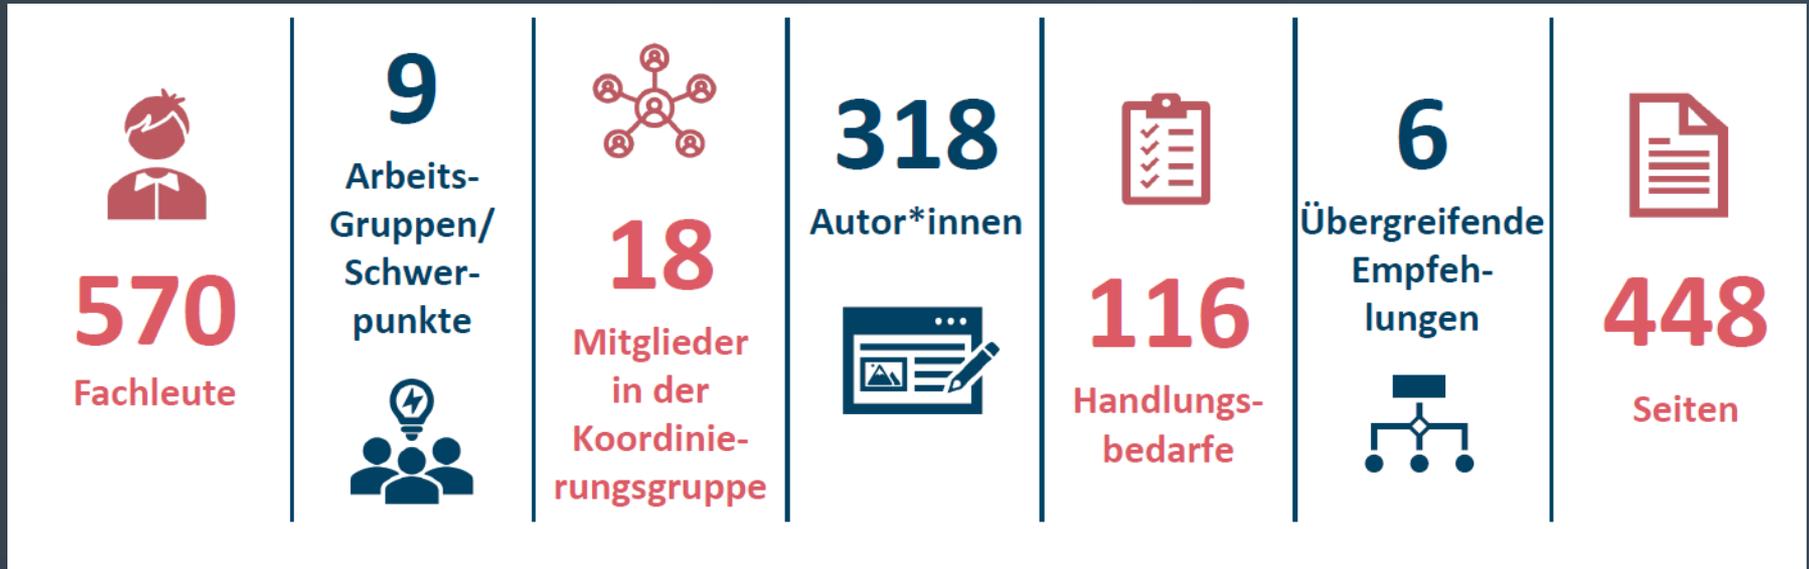
www.bundesnetzagentur.de



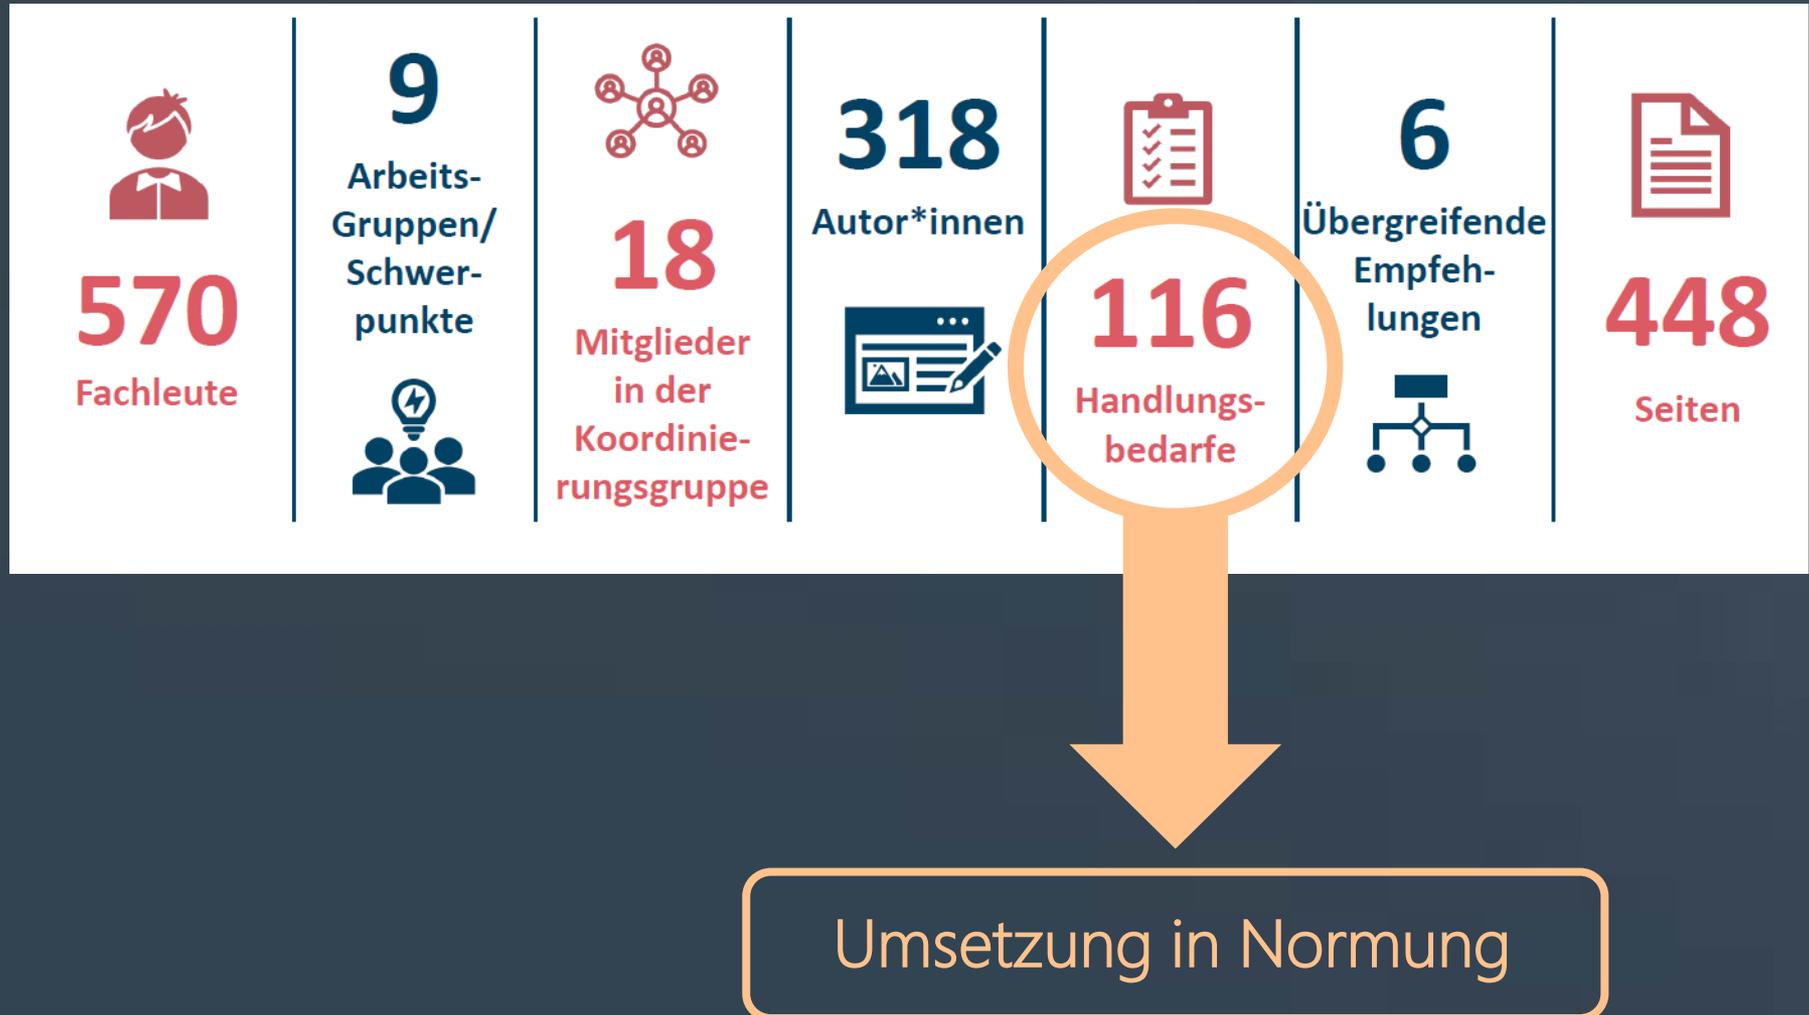
DIN SPECs zu KI:

- Einführung
- Mehrwert der DIN SPEC
- Vorstellung der Normungsbedarfe
- Priorisierung

Normungsroadmap KI Version 2:



Normungsroadmap KI Version 2:





Ausgewählte Bedarfe:

- Operationalisierung der „Erklärgüte“ von XAI-Methoden
- Entwicklung von Funktionalitätsklassen für KI-Technologien
- Entwicklung von Werkzeugkriterien für die Prüfung von KI-Systemen
- Standardisierung von Guidance-Dokumenten für die Abbildung von Risiken eines Systems, mit Fokus auf Funktionalität von KI-Komponenten
- Entwicklung von ineinandergreifenden Standards für KI-Systeme und notwendiger Konformitätsbewertungsverfahren
- Entwicklung von Qualifikationskriterien für Prüfer und Zertifizierer zu „Cybersecurity“ und „Privacy“ für KI
- Vernetzung aller Akteur*innen
- Definition von Kontrollpunkten



Ausgewählte Bedarfe:

- Operationalisierung der „Erklärgüte“ von XAI-Methoden
- Entwicklung von Funktionalitätsklassen für KI-Technologien
- Entwicklung von Werkzeugkriterien für die Prüfung von KI-Systemen
- Standardisierung von Guidance-Dokumenten für die Abbildung von Risiken eines Systems mit Fokus auf Funktionalität von KI-Komponenten
- Entwicklung von ineinandergreifenden Standards für KI-Systeme und notwendiger Konformitätsbewertungsverfahren
- Entwicklung von Qualifikationskriterien für Prüfer und Zertifizierer zu Cybersecurity und Privacy für KI
- Vernetzung aller Akteur*innen
- Definition von Kontrollpunkten



- **Deutscher Standard zu KI**
- **Nennung der Beteiligten** im Vorwort
- **Vollständige Finanzierung** durch Projekt „**Zertifizierte KI**“
- Erarbeitung: Ausschließlicher **Fokus** auf das Dokument
- Hohe **Geschwindigkeit**:
 - Keine öffentliche Kommentierung erforderlich
 - Mehrheitsentscheide & keine Konsenspflicht



Vorarbeit für weltweite Standardisierung!

- **Europa: CEN-CENELEC JTC 21 „Artificial Intelligence“**
- **International: ISO/IEC JTC 1/SC 42 „Artificial Intelligence“**

Themen für DIN SPECs



Operationalisierung der „Erklärgüte“ von XAI-Methoden



Entwicklung von Funktionalitätsklassen für KI-Technologien



Entwicklung von Werkzeugkriterien für die Prüfung von KI-Systemen



Operationalisierung der „Erklärgüte“ von XAI-Methoden

Hintergrund:

Explainable Artificial Intelligence (XAI) - Methoden:

- **Schaffung von Erklärbarkeit
für Entscheidungsfindung & Wissensverarbeitung**
- **Unterstützung bei ethischer und rechtlicher
Bewertung von KI-Systemen**



Operationalisierung der „Erklärgüte“ von XAI-Methoden

a) Anforderungen an XAI-Methoden

- Abhängig von
 - Anwendungsfällen & Interessierten
 - Was will man genau erklären?
 - Welche Entscheidung möchte man treffen?
 - Welche Handlungen kann man rechtfertigen?
 - Rolle einbezogener Daten
 - z.B. Test, Trainingsdaten/Verteilung,
 - Einfluss von Punkten auf ein Modell



Operationalisierung der „Erklargute“ von XAI-Methoden

b) Ground truth-Referenzdatensatze & Metriken

- Ground truth-Datenerzeugung:
 - mathematische Bildungsvorschriften,
physikalische Simulation und Manipulation realer Daten
- Metriken fur ground truth-Datensatze, z.B.
 - Precision/Recall
 - Metriken aus der Signaldetektionstheorie



Operationalisierung der „Erklärgüte“ von XAI-Methoden

c) Verifizierung: XAI bei Qualitätssicherung

- Nutzen von XAI für Qualitätssicherung bei ML-basierten Systemen
- Praktische Relevanz und Auswirkungen
- Benchmarking-Ansätze zur Beurteilung der Qualitätssicherung
- Generierung von Antworten mittels XAI-Methoden
 - Breite Bewertbarkeit von XAI-Methoden



Entwicklung von Funktionalitätsklassen für KI-Technologien

Hintergrund:

KI-Produkte: Spezifische Anforderungen an Vertrauen

- **Erfüllung von Anforderungen an KI-Systeme mittels technischer Funktionen, z.B.**
 - **Fehlererkennung**
 - **Abwehr von Angriffen**



Entwicklung von Funktionalitätsklassen für KI-Technologien

a) Definition und Klassifizierung von Funktionalitäten:

- Beschreibung von Funktionalitäten im Zusammenhang mit dem Kontext eines KI-Systems
- Funktionalitätsspezifische Formulierung von Anforderungen, z.B. an Fehlererkennung



Entwicklung von Funktionalitätsklassen für KI-Technologien

b) Charakteristiken für Vertrauen in Funktionalitäten:

- Bewertung von Korrektheit und Wirksamkeit von Funktionalitäten
- Überprüfbarkeit der Funktionalitäten im Entwicklungs- und Betriebsprozess



Entwicklung von Funktionalitätsklassen für KI-Technologien

c) Baukasten für Funktionalitätsklassen

- Überblick über Funktionalitäten, die KI-Systeme bei Entwicklung & Betrieb begleiten können
- In Abhängigkeit von KI-System und Kontext:
 - Überblick über umsetzbare Funktionalitäten
 - Einheitlich strukturierte, umsetzbare Anforderungen



Entwicklung von Werkzeugkriterien für die Prüfung von KI-Systemen

Hintergrund:

Charakterisierung von Werkzeugen für KI-Prüfungen:

- **Erfordernis:**
 - Entwicklung spezifischer Kriterien für Prüfung und Zertifizierung der Werkzeuge
- **Teil eines KI-Zertifizierungsprogramms**



Entwicklung von Werkzeugkriterien für die Prüfung von KI-Systemen

a) Beschreibung von Werkzeugen für KI-Prüfungen:

- Charakterisierung messbarer Gütekriterien bei KI-Systemen
- Festlegung von Gütecharakteristiken für Werkzeuge, um hohe Aussagekraft und Zuverlässigkeit sicherzustellen



Entwicklung von Werkzeugkriterien für die Prüfung von KI-Systemen

b) Prüfverfahren für Werkzeuge:

- Festlegung grundlegender Anforderungen an Prüfung und Zertifizierung der Werkzeuge
- Beschreibung von Prüfkriterien und Prüfmethoden
- Konzipierung von Testabläufen



I

**Operationalisierung
der „Erklärgüte“
von XAI-Methoden**

- a) Anforderungen an XAI-Methoden
- b) Ground truth-Referenzdatensätze & Metriken
- c) Verifizierung: XAI bei Qualitätssicherung

II

**Entwicklung von
Funktionalitätsklassen
für KI-Technologien**

- a) Definition und Klassifizierung von Funktionalitäten
- b) Charakteristiken für Vertrauen in Funktionalitäten
- c) Baukasten für Funktionalitätsklassen

III

**Entwicklung von
Werkzeugkriterien
für die Prüfung
von KI-Systemen**

- a) Beschreibung von Werkzeugen für KI-Prüfungen
- b) Prüfverfahren für Werkzeuge



Bundesnetzagentur

Trendthemen für DIN SPECs: Grundpfeiler der KI-Normung

Taras Holoyad

Standardisierung künstlicher Intelligenz

06131/18 1459

Taras.Holoyad@bnetza.de