

# Record Linkage von unterschiedlichen Datenarten: Beispiele aus der epidemiologischen Forschung

Timm Intemann, Bianca Kollhorst, Stefan Rach,  
Wolfgang Ahrens und Iris Pigeot



**Leibniz-Institut**  
für Präventionsforschung und  
Epidemiologie – BIPS



68. GMDS-Jahrestagung

Workshop: Record Linkage von  
unterschiedlichen Datenarten

20. September 2023



# Motivation: Record Linkage bietet großartige Möglichkeiten

z. B. Krebsregister

ID	Var1	Var2
1		
2		
3		
4		

z. B. Versicherungs-  
daten

ID	Var3	Var4
1		
2		
3		
4		

Mit einer Datenquelle:

- Verteilung von *Var1*
- „Wie viele Krebsfälle?“

# Motivation: Record Linkage bietet großartige Möglichkeiten

z. B. Krebsregister

ID	Var1	Var2
1		
2		
3		
4		

z. B. Versicherungsdaten

ID	Var3	Var4
1		
2		
3		
4		



Mit einer Datenquelle:

- Verteilung von *Var1*
- „Wie viele Krebsfälle?“

# Motivation: Record Linkage bietet großartige Möglichkeiten

z. B. Krebsregister

ID	Var1	Var2
1		
2		
3		
4		

z. B. Versicherungsdaten

ID	Var3	Var4
1		
2		
3		
4		



ID	Var1	Var2	Var3	Var4
1				
2				
3				
4				

Mit einer Datenquelle:

- Verteilung von *Var1*
- „Wie viele Krebsfälle?“

Mit den verknüpften Daten:

- Zusammenhang zwischen *Var1* und *Var3*
- „Gibt es eine Assoziation zwischen Medikament und Krebs?“

# Motivation: Record Linkage bietet großartige Möglichkeiten

*“Anonymous data and statistical information **have some value** especially for descriptive epidemiological purposes, but the **real value** of register-based information systems depends on the possibility for record linkages.”*

(Sund et al. 2014)

# Record Linkage mit unterschiedlichen Datenarten: Beispiele aus der epidemiologischen Forschung

---

Ohlmeier et al. (2015) Verknüpfung von Routinedaten der Gesetzlichen Krankenversicherung mit Daten eines Krankenhausinformationssystems: Machbar, aber auch „nützlich“? doi:10.1055/s-0034-1395644

Dreger et al. (2020) Cohort study of occupational cosmic radiation dose and cancer mortality in German aircrew, 1960–2014. doi:10.1136/oemed-2019-106165

Riedel et al. (2023) Quality of life in bariatric patients up to twelve years after surgery - Results from a nationwide retrospective cohort study. doi:10.1016/j.orcp.2023.08.001

Langner et al. (2019) Implementation of an algorithm for the identification of breast cancer deaths in German health insurance claims data: a validation study based on a record linkage with administrative mortality data. doi:10.1136/bmjopen-2018-026834

Kollhorst et al. (2022) Record linkage of claims and cancer registries data — evaluation of a deterministic linkage approach based on indirect personal identifiers. doi:10.1002/pds.5545

# Record Linkage mit unterschiedlichen Datenarten: Beispiele aus der epidemiologischen Forschung

- Krankenkassendaten ↔ Daten aus Krankenhausinformationssystem (Ohlmeier et al. 2015)
  - Machbarkeitsanalyse eines indirekten Linkage-Ansatzes

---

Ohlmeier et al. (2015) Verknüpfung von Routinedaten der Gesetzlichen Krankenversicherung mit Daten eines Krankenhausinformationssystems: Machbar, aber auch „nützlich“? doi:10.1055/s-0034-1395644

Dreger et al. (2020) Cohort study of occupational cosmic radiation dose and cancer mortality in German aircrew, 1960–2014. doi:10.1136/oemed-2019-106165

Riedel et al. (2023) Quality of life in bariatric patients up to twelve years after surgery - Results from a nationwide retrospective cohort study. doi:10.1016/j.orcp.2023.08.001

Langner et al. (2019) Implementation of an algorithm for the identification of breast cancer deaths in German health insurance claims data: a validation study based on a record linkage with administrative mortality data. doi:10.1136/bmjopen-2018-026834

Kollhorst et al. (2022) Record linkage of claims and cancer registries data — evaluation of a deterministic linkage approach based on indirect personal identifiers. doi:10.1002/pds.5545

# Record Linkage mit unterschiedlichen Datenarten: Beispiele aus der epidemiologischen Forschung

- Krankenkassendaten ↔ Daten aus Krankenhausinformationssystem (Ohlmeier et al. 2015)
  - Machbarkeitsanalyse eines indirekten Linkage-Ansatzes
- Strahlenschutzregister ↔ Flugpersonaldatenbanken (Dreger et al. 2020)
  - Untersuchung der Krebssterblichkeit beim Flugpersonal

---

Ohlmeier et al. (2015) Verknüpfung von Routinedaten der Gesetzlichen Krankenversicherung mit Daten eines Krankenhausinformationssystems: Machbar, aber auch „nützlich“? doi:10.1055/s-0034-1395644

Dreger et al. (2020) Cohort study of occupational cosmic radiation dose and cancer mortality in German aircrew, 1960–2014. doi:10.1136/oemed-2019-106165

Riedel et al. (2023) Quality of life in bariatric patients up to twelve years after surgery - Results from a nationwide retrospective cohort study. doi:10.1016/j.orcp.2023.08.001

Langner et al. (2019) Implementation of an algorithm for the identification of breast cancer deaths in German health insurance claims data: a validation study based on a record linkage with administrative mortality data. doi:10.1136/bmjopen-2018-026834

Kollhorst et al. (2022) Record linkage of claims and cancer registries data — evaluation of a deterministic linkage approach based on indirect personal identifiers. doi:10.1002/pds.5545

# Record Linkage mit unterschiedlichen Datenarten: Beispiele aus der epidemiologischen Forschung

- Krankenkassendaten ↔ Daten aus Krankenhausinformationssystem (Ohlmeier et al. 2015)
  - Machbarkeitsanalyse eines indirekten Linkage-Ansatzes
- Strahlenschutzregister ↔ Flugpersonaldatenbanken (Dreger et al. 2020)
  - Untersuchung der Krebssterblichkeit beim Flugpersonal
- Krankenkassendaten ↔ Epidemiologische Primärdaten
  - z. B. Untersuchung der Lebensqualität von Patient:innen nach bariatrischen Eingriffen (Riedel et al. 2023)
  - CoVerlauf und NAKO

---

Ohlmeier et al. (2015) Verknüpfung von Routinedaten der Gesetzlichen Krankenversicherung mit Daten eines Krankenhausinformationssystems: Machbar, aber auch „nützlich“? doi:10.1055/s-0034-1395644

Dreger et al. (2020) Cohort study of occupational cosmic radiation dose and cancer mortality in German aircrew, 1960–2014. doi:10.1136/oemed-2019-106165

Riedel et al. (2023) Quality of life in bariatric patients up to twelve years after surgery - Results from a nationwide retrospective cohort study. doi:10.1016/j.orcp.2023.08.001

Langner et al. (2019) Implementation of an algorithm for the identification of breast cancer deaths in German health insurance claims data: a validation study based on a record linkage with administrative mortality data. doi:10.1136/bmjopen-2018-026834

Kollhorst et al. (2022) Record linkage of claims and cancer registries data — evaluation of a deterministic linkage approach based on indirect personal identifiers. doi:10.1002/pds.5545

# Record Linkage mit unterschiedlichen Datenarten: Beispiele aus der epidemiologischen Forschung

- Krankenkassendaten ↔ Daten aus Krankenhausinformationssystem (Ohlmeier et al. 2015)
  - Machbarkeitsanalyse eines indirekten Linkage-Ansatzes
- Strahlenschutzregister ↔ Flugpersonaldatenbanken (Dreger et al. 2020)
  - Untersuchung der Krebssterblichkeit beim Flugpersonal
- **Krankenkassendaten ↔ Epidemiologische Primärdaten**
  - z. B. Untersuchung der Lebensqualität von Patient:innen nach bariatrischen Eingriffen (Riedel et al. 2023)
  - **CoVerlauf** und NAKO
- **Krankenkassendaten ↔ Krebsregisterdaten**
  - Validierung der Angaben zur Todesursache in Krankenkassendaten (Langner et al. 2019)
  - **DFG-Linkage** (Kollhorst et al. 2022)

Ohlmeier et al. (2015) Verknüpfung von Routinedaten der Gesetzlichen Krankenversicherung mit Daten eines Krankenhausinformationssystems: Machbar, aber auch „nützlich“? doi:10.1055/s-0034-1395644

Dreger et al. (2020) Cohort study of occupational cosmic radiation dose and cancer mortality in German aircrew, 1960–2014. doi:10.1136/oemed-2019-106165

Riedel et al. (2023) Quality of life in bariatric patients up to twelve years after surgery - Results from a nationwide retrospective cohort study. doi:10.1016/j.orcp.2023.08.001

Langner et al. (2019) Implementation of an algorithm for the identification of breast cancer deaths in German health insurance claims data: a validation study based on a record linkage with administrative mortality data. doi:10.1136/bmjopen-2018-026834

Kollhorst et al. (2022) Record linkage of claims and cancer registries data – evaluation of a deterministic linkage approach based on indirect personal identifiers. doi:10.1002/pds.5545

# Krankenkassendaten

- 96 gesetzliche Krankenkassen (GKV) (Mai 2022)
- 73 Mio. GKV-versichert (87% der Bevölkerung)
- > 46 private Krankenkassen
  
- Individuelle Daten zu Abrechnungszwecken
  - Demografische Daten
  - **Arzneimittelverordnungen, ambulante/stationäre Leistungen, Diagnosen**
  
- Vorteile gegenüber Befragungsdaten:
  - Objektiv
  - Kein Aufwand für Studienteilnehmer:innen
  - Keine Erinnerungs- oder Wissenslücken

## Fallbeispiel 1:

Krankenkassendaten ↔ Epidemiologische Primärdaten

 CoVerlauf

# CoVerlauf: Hintergrund und Ziele

- Studie zum Erkrankungsverlauf bei Personen mit einer COVID-19-Erkrankung bzw. einem positiven Test auf SARS-CoV-2
- Häufigkeit schwerer Erkrankungsverläufe
- Determinanten schwerer Erkrankungsverläufe
- **Demonstration: Krankenkassendaten zur Untersuchung von Erkrankungsverläufen nützlich?**

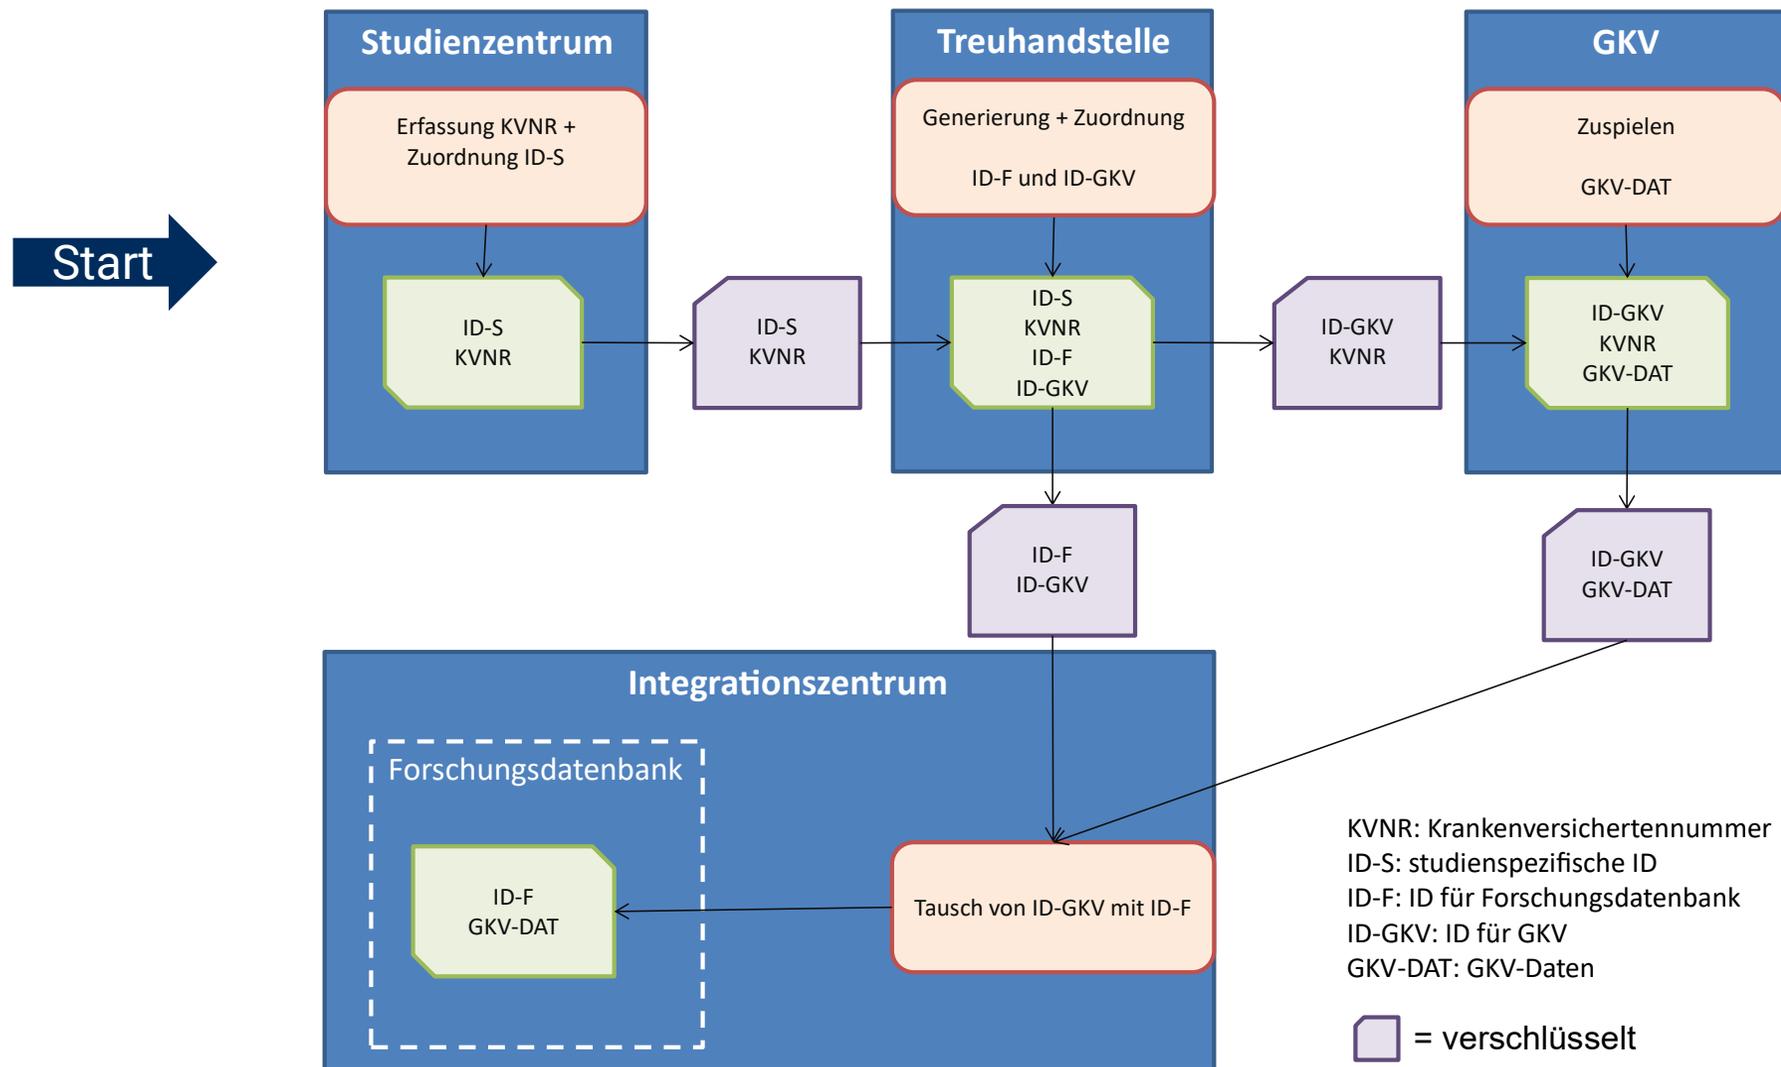
# CoVerlauf: epidemiologische Primärdaten

- Kontaktaufnahme über Gesundheitsamt Bremen
- Einladungsschreiben an 12.995 Personen
- 1908 Personen in Studie eingewilligt (Responsequote: 15%)
- Befragungsdaten u.a. zu
  - Soziodemografie
  - Vorerkrankungen und Medikamenten
  - Lebensstil
- 1617 (85%) Personen in Verknüpfung mit Krankenkassendaten eingewilligt und Krankenversicherungsnummer (KVNR) übermittelt

# CoVerlauf: Einwilligungsquoten für Record Linkage zwischen epidemiologischen Primärdaten und Krankenkassendaten

Studie	Erhebungszeitraum	Stichprobenumfang	Einwilligungs-/ Einverständnisquote
KORA	1997-1999	796	64%
	2005	313	78%
Heinz-Nixdorf-Recall-Studie	Bis 2010	4.814	90%
AGil	Bis 2011	361	100%*
Iida	2011	6.265	55%
	2014	4.244	63%
SHIP	Ab 2008	>5000	95%
NAKO	Ab 2014	~200.000	94%
LIFE (Follow-Up)	Ab 2017	5.665	88%
CoVerlauf	2021	1.908	<b>85%</b>

# CoVerlauf: Datenfluss analog zur NAKO Gesundheitsstudie



# CoVerlauf: Herausforderungen und Fazit

- Einholung der Einwilligungserklärungen über das Gesundheitsamt → Responseverluste
  - Einwilligungsbereitschaft zum RL in Bevölkerung sehr hoch
  - Organisatorischer Aufwand für die Kooperation mit **101** Krankenkassen
    - Einschluss: Kassen mit mindestens 20 Proband:innen:
      - **Reduktion des Stichprobenumfangs auf 1352 (71%) und 14 Kassen**
  - Zweigliedriges Krankenversicherungssystem in Deutschland
    - GKV- und PKV-Daten fallen unter verschiedene Datenschutzregeln
    - Ausschluss der PKV
      - **Reduktion des Stichprobenumfangs auf 1325 (69%)**
- **Unsicherere und möglicherweise verzerrte Ergebnisse aufgrund verringerter Fallzahlen und Selektionseffekten**

# Fallbeispiel 2: Krankenkassendaten ↔ Krebsregisterdaten

## DFG-Linkage

# DFG-Linkage: Hintergrund und Ziele

- Ziel: Evaluierung eines Linkage-Ansatz basierend auf **indirekten** Identifikatoren im Vergleich zu einem Ansatz mit **direkten** Identifikatoren
- Anhand **Beispielstudie** zum Risiko einer Krebsneuerkrankung und der Krebsmortalität bei Patient:innen mit Typ-2-Diabetes unter Behandlung mit verschiedenen Antidiabetika
- Antidiabetika: Sulfonylharnstoffe und Metformin
- Für zwei Krebsentitäten: Schilddrüsen- und Darmkrebs

# DFG-Linkage: Datenquellen

- Vier epidemiologische Krebsregister
  - Tumorstadium
  - Tumordiagnose
- Pharmakoepidemiologische Forschungsdatenbank (GePaRD):  
**Abrechnungsdaten von ~25 Mio. Versicherten** (TK, DAK, hkk, AOK Bremen)
  - Diabetesmedikation



AOK Bremen/Bremerhaven



DAK-Gesundheit

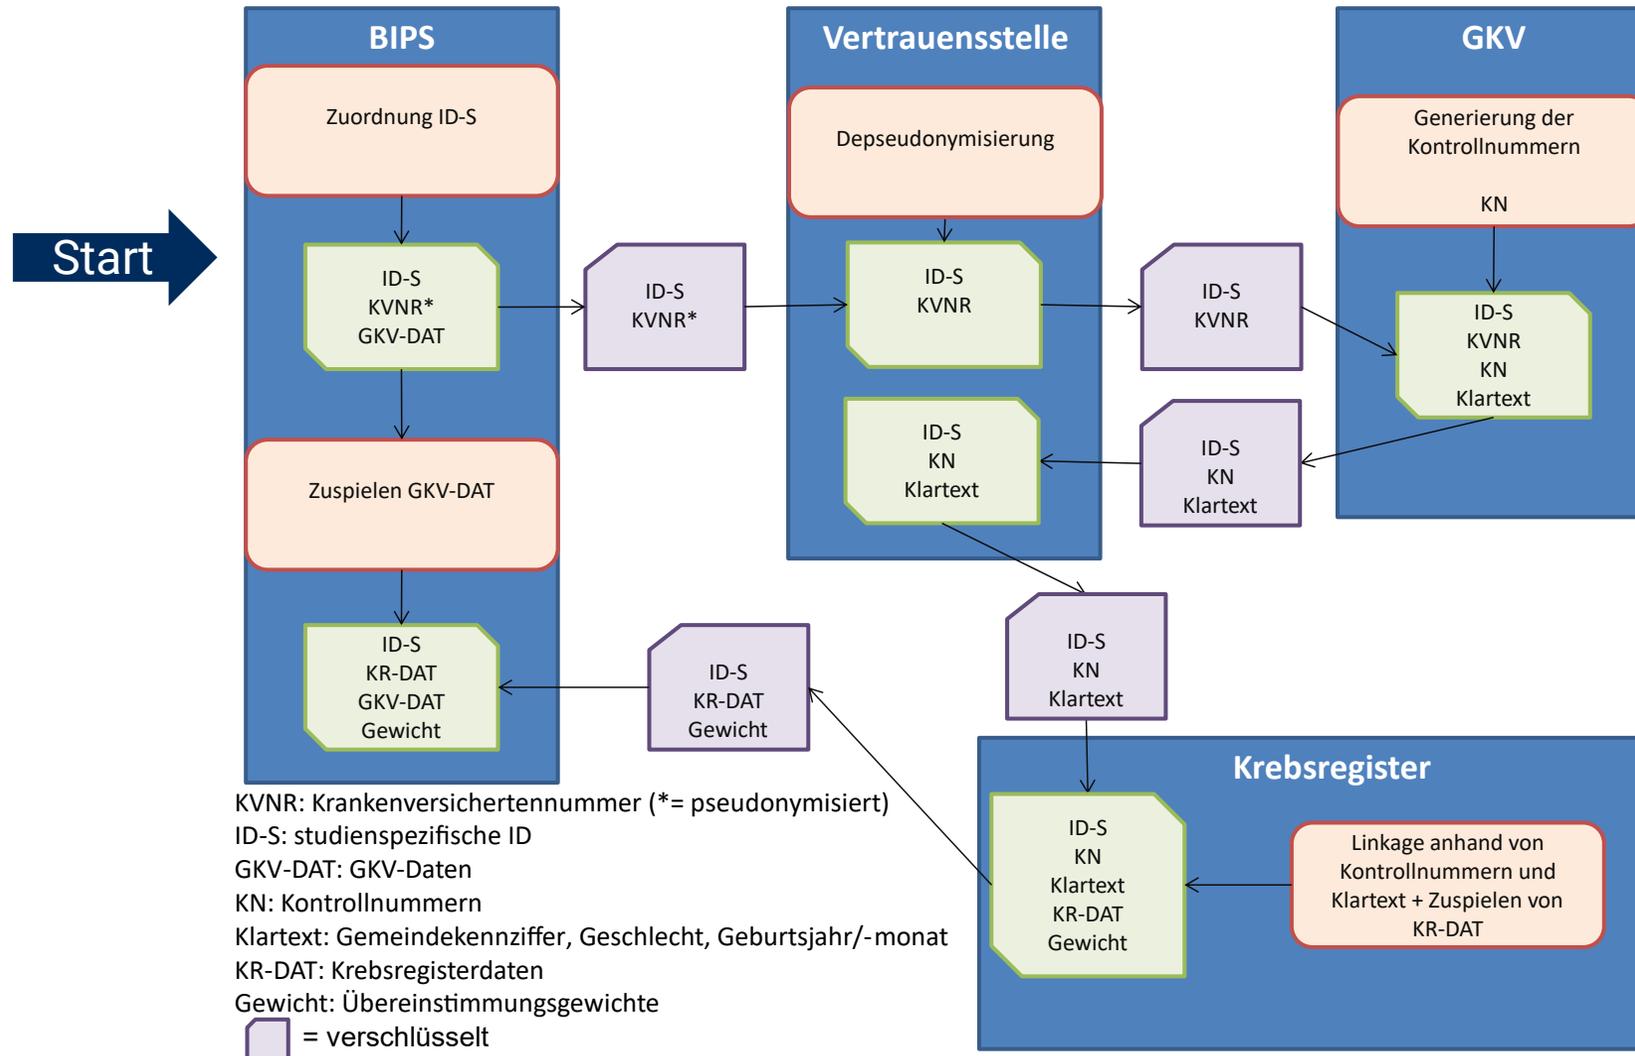


hkk Krankenkasse



Techniker Krankenkasse (TK)

# DFG-Linkage: Datenfluss



# DFG-Linkage: Identifier und Record Linkage-Methoden

## 1. Probabilistisches Linkage basierend auf *direkten* Identifikatoren

- Etabliertes Kontrollnummernlinkage der Krebsregister
- Kontrollnummern abgeleitet aus u.a. *Vorname, Nachname, Tag der Geburt...*

# DFG-Linkage: Identifier und Record Linkage-Methoden

## 1. Probabilistisches Linkage basierend auf *direkten* Identifikatoren

- Etabliertes Kontrollnummernlinkage der Krebsregister
- Kontrollnummern abgeleitet aus u.a. *Vorname, Nachname, Tag der Geburt...*

## 2. Deterministisches Linkage basierend auf *indirekten* Identifikatoren

- Identifier:
  - *Geburtsjahr,*
  - *Geschlecht,*
  - *Gemeindekennziffer,*
  - *Krebsart und*
  - *Diagnosedatum*
- Falls keine eindeutige Zuordnung: *Genauigkeit der ICD-Kodierung, stationäre Diagnose, Differenz des Diagnosedatums*

# DFG-Linkage: Vergleich beider Linkage-Ansätze

- Linkage basierend auf indirekten Identifiern **datenschutzrechtlich weniger aufwändig**, da keine Vertrauensstelle notwendig

# DFG-Linkage: Vergleich beider Linkage-Ansätze

- Linkage basierend auf indirekten Identifiern **datenschutzrechtlich weniger aufwändig**, da keine Vertrauensstelle notwendig
- Kontrollnummernlinkage als **Goldstandard** zur Evaluation des indirekten Ansatzes
- **Sensitivität** des indirekten Linkage:
  - Darmkrebs: **72%**
  - Schilddrüsenkrebs: **67%**

# DFG-Linkage: Vergleich beider Linkage-Ansätze

- Linkage basierend auf indirekten Identifiern **datenschutzrechtlich weniger aufwändig**, da keine Vertrauensstelle notwendig
- Kontrollnummernlinkage als **Goldstandard** zur Evaluation des indirekten Ansatzes
- **Sensitivität** des indirekten Linkage:
  - Darmkrebs: **72%**
  - Schilddrüsenkrebs: **67%**
- **Ereigniszeitanalyse** für Darmkrebsrisiko mit beiden Ansätzen:

Record Linkage-Methode	Hazard Ratio (Sulfonylharnsäure vs. Metformin)
Prob. mit direkten Identifiern	0.71
Determ. mit indirekten Identifiern	0.81

- Unterschied zwischen Diabetesmedikation um **10%-Punkte unterschätzt**

# DFG-Linkage: Vergleich beider Linkage-Ansätze

- Linkage basierend auf indirekten Identifiern **datenschutzrechtlich weniger aufwändig**, da keine Vertrauensstelle notwendig
- Kontrollnummernlinkage als **Goldstandard** zur Evaluation des indirekten Ansatzes
- **Sensitivität** des indirekten Linkage:
  - Darmkrebs: **72%**
  - Schilddrüsenkrebs: **67%**
- **Ereigniszeitanalyse** für Darmkrebsrisiko mit beiden Ansätzen:

Record Linkage-Methode	Hazard Ratio (Sulfonylharnsäure vs. Metformin)
Prob. mit direkten Identifiern	0.71
Determ. mit indirekten Identifiern	0.81

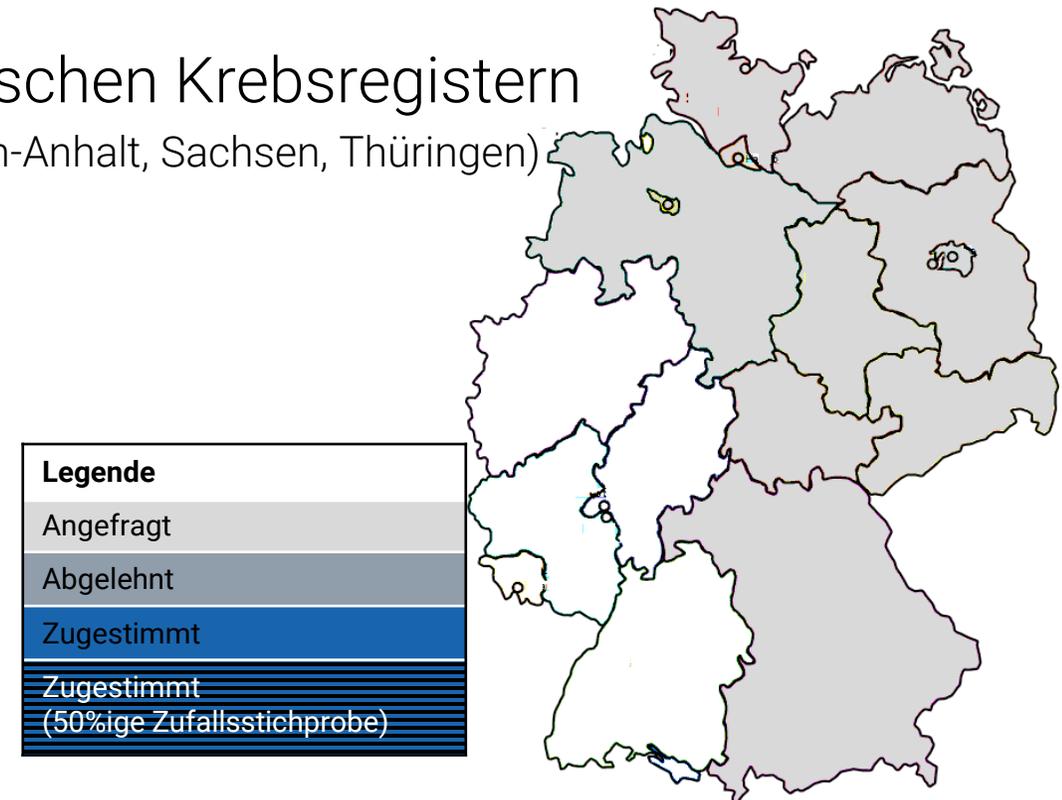
- Unterschied zwischen Diabetesmedikation um **10%-Punkte unterschätzt**
- **Deswegen Linkage mit diesen indirekten Identifikatoren nicht zu empfehlen**

# DFG-Linkage: Herausforderungen

- **Problem:** keine Verlinkung über Zentrum für Krebsregisterdaten (ZfKD) aus rechtlichen Gründen möglich

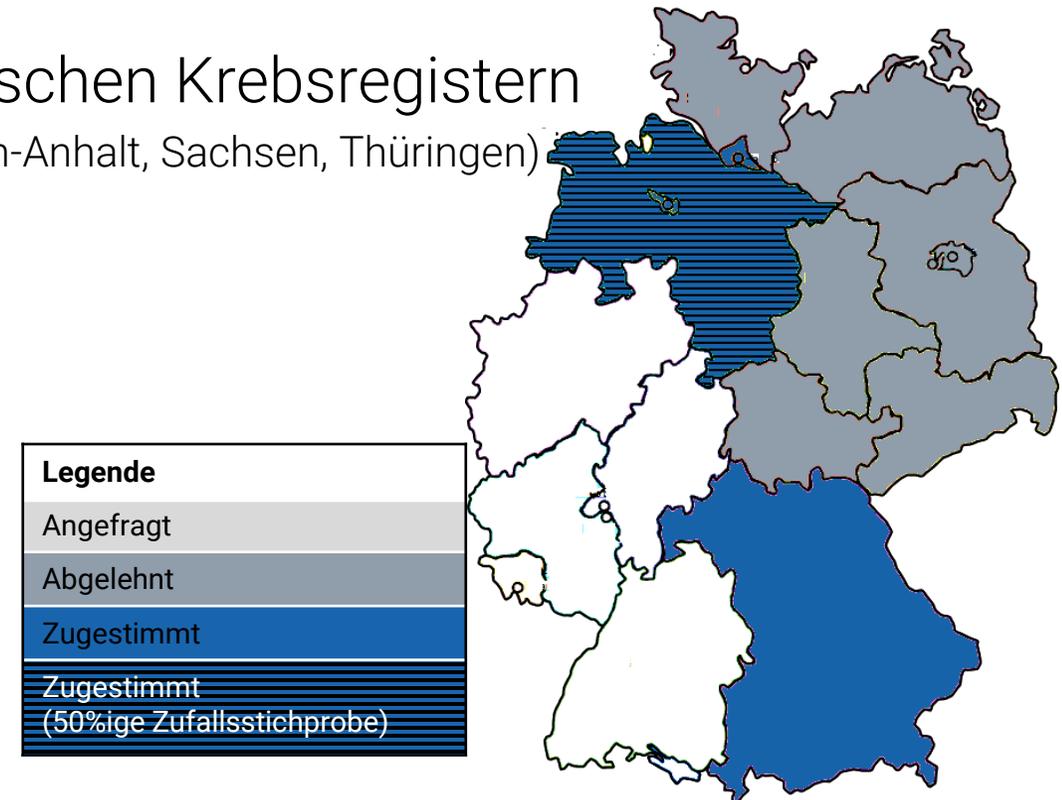
# DFG-Linkage: Herausforderungen

- **Problem:** keine Verlinkung über Zentrum für Krebsregisterdaten (ZfKD) aus rechtlichen Gründen möglich
- **Konsequenz:** Anfrage bei sechs epidemiologischen Krebsregistern
  - GKR (Berlin, Brandenburg, Mecklenburg-Vorpommern, Sachsen-Anhalt, Sachsen, Thüringen)
  - Bayern
  - Bremen
  - Hamburg
  - Niedersachsen
  - Schleswig-Holstein



# DFG-Linkage: Herausforderungen

- **Problem:** keine Verlinkung über Zentrum für Krebsregisterdaten (ZfKD) aus rechtlichen Gründen möglich
- **Konsequenz:** Anfrage bei sechs epidemiologischen Krebsregistern
  - GKR (Berlin, Brandenburg, Mecklenburg-Vorpommern, Sachsen-Anhalt, Sachsen, Thüringen)
  - Bayern
  - Bremen
  - Hamburg
  - Niedersachsen
  - Schleswig-Holstein
- **Unterschiede:**
  - Art der Antragstellung
  - Antragsformulare
  - Zuständige Stelle
  - Geäußerte datenschutzrelevante Bedenken
  - Entscheidung nach Bundesland verschieden



# DFG-Linkage: Herausforderungen und Fazit

- Kontrollnummernlinkage für Krebsregistrierung entwickelt, dafür nötige Merkmale nicht in gleicher Form in Versicherungsdaten enthalten
- Record Linkage-Projekte mit Krebsregister- und Krankenkassendaten zeit- und kostenintensiv: weitere Anträge und Genehmigungen
  - Zustimmung der Kassen
  - Zustimmung der Aufsichtsbehörden nach §75 SGB X
- Flächendeckende bundesweite Analysen mit verlinkten Daten aus Krebsregistern und von Krankenkassen erscheinen *momentan* unrealistisch

# DFG-Linkage: Ausblick

- Mittlerweile **bundeseinheitliches Antragsformular** der Krebsregister verfügbar
  - Antragstellung wird vereinfacht
- Zukünftig **KVNR als zusätzliche Kontrollnummer in Krebsregistern**
  - Linkage-Qualität des Kontrollnummernlinkage erhöht
- **Gesundheitsdatennutzungsgesetz** löst Linkage-Probleme voraussichtlich nur beschränkt
  - Linkage zwischen FDZ Gesundheit und Daten der klinischen Krebsregister vorgesehen

## Link zum *White Paper: Verbesserung des Record Linkage für die Gesundheitsforschung in Deutschland*



<https://doi.org/10.4126/FRL01-006461895>

**Vielen Dank für die  
Aufmerksamkeit!**



**Kontakt:**

**Timm Intemann**

[intemann@leibniz-bips.de](mailto:intemann@leibniz-bips.de)

**Leibniz-Institut für  
Präventionsforschung und  
Epidemiologie - BIPS**

[www.nfdi4health.de](http://www.nfdi4health.de)



**Leibniz-Institut**  
für Präventionsforschung und  
Epidemiologie – BIPS

Gefördert durch



Deutsche  
Forschungsgemeinschaft



## Link zum *White Paper: Verbesserung des Record Linkage für die Gesundheitsforschung in Deutschland*



<https://doi.org/10.4126/FRL01-006461895>