

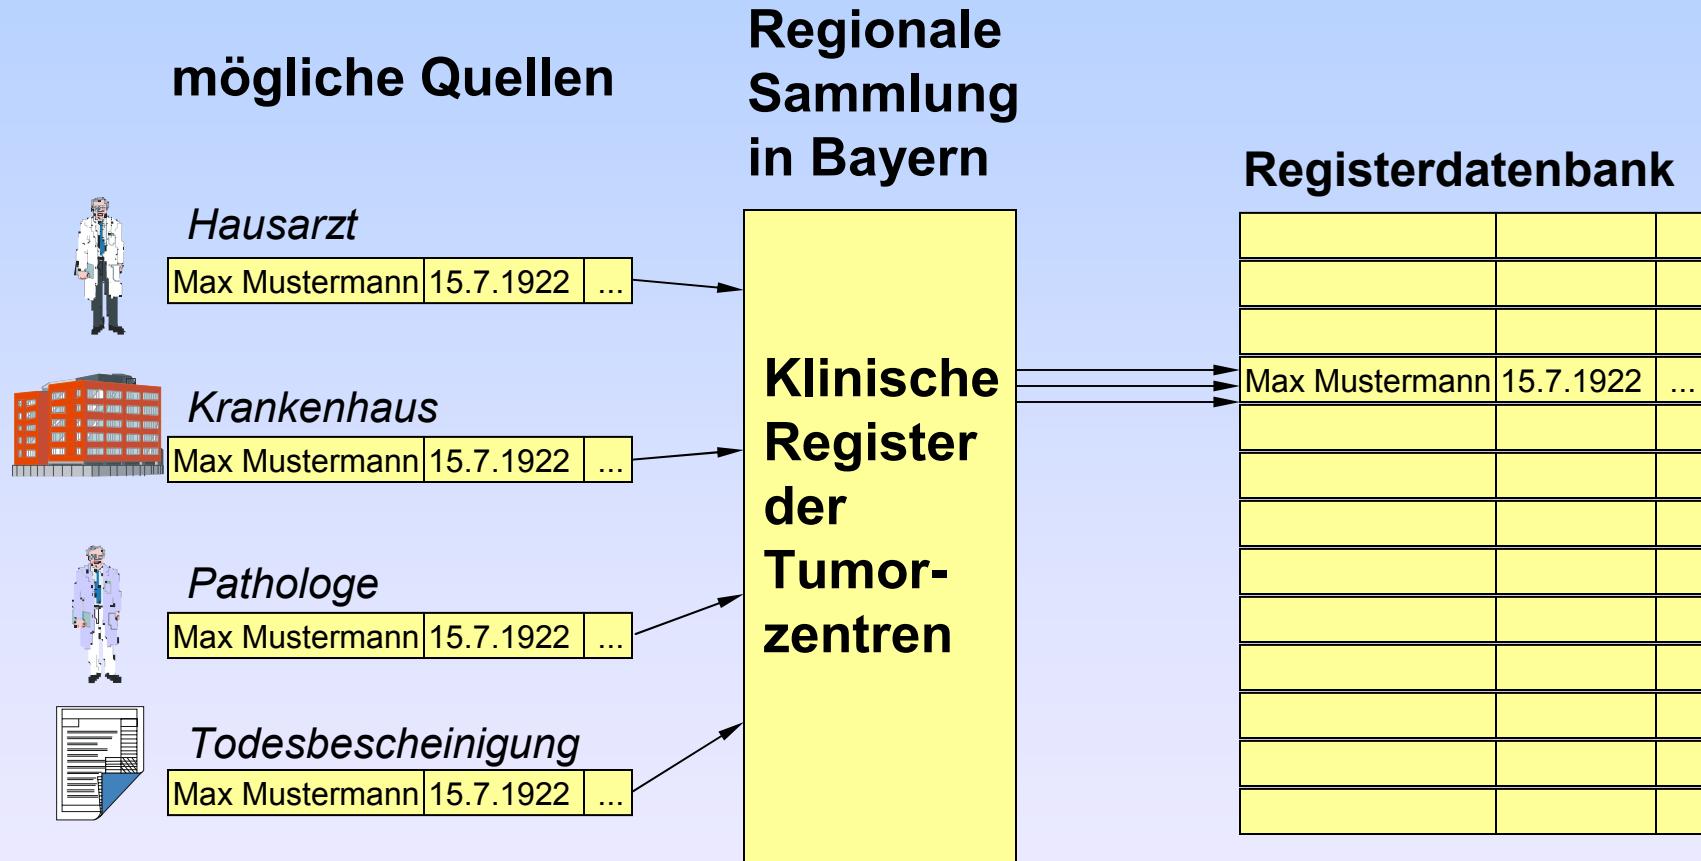


**M. Meyer, M. Radespiel-Tröger, C. Vogel**

# **Probabilistisches Record- Linkage mit anonymisierten Krebsregistermeldungen**



## **Eingehende Meldungen im Krebsregister (nicht anonymisiert)**

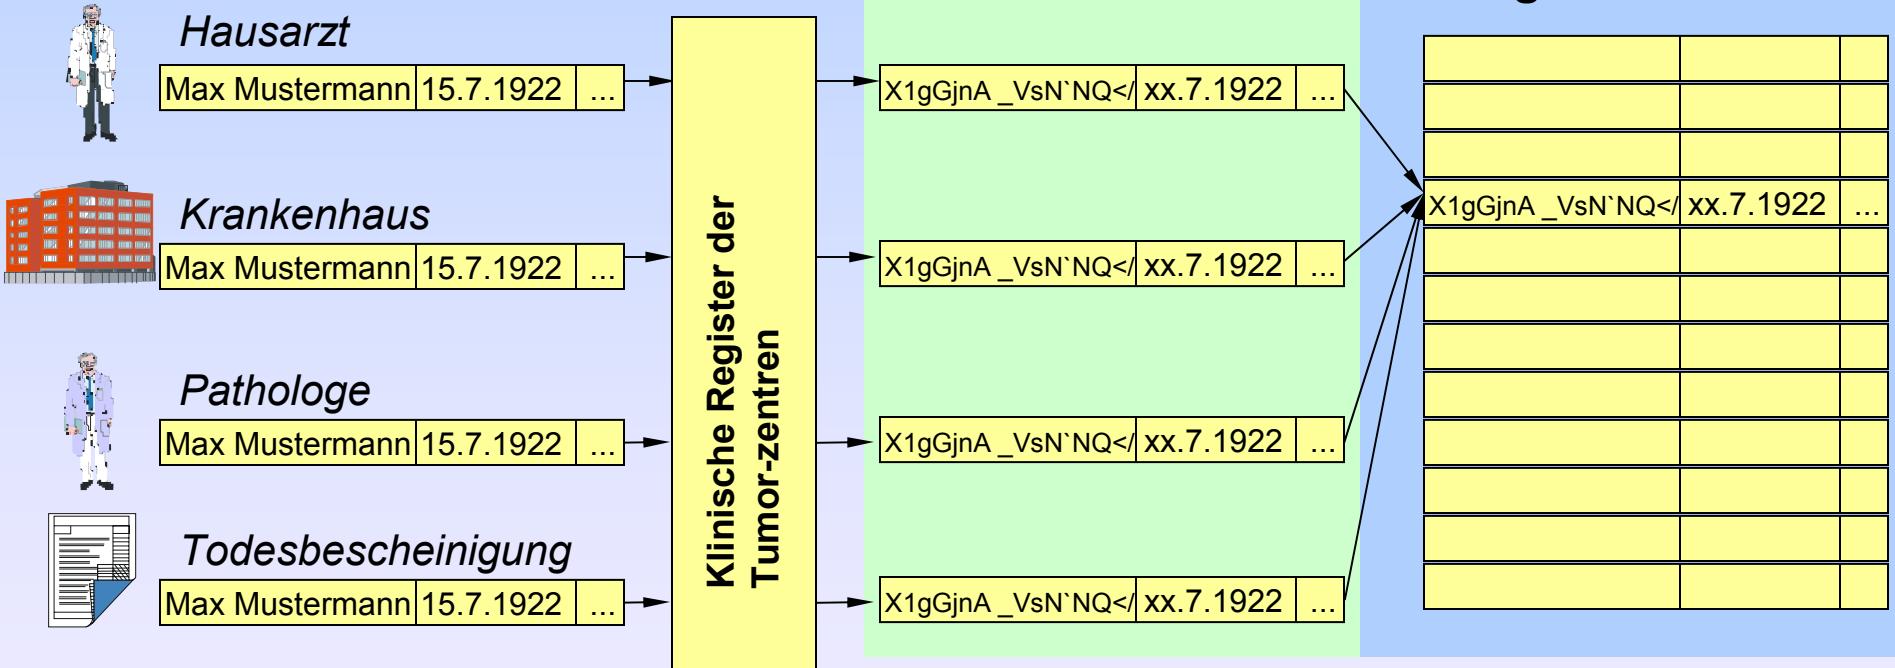


Meldungen treffen im Allgemeinen zu verschiedenen Zeiten ohne Berücksichtigung einer logischen Reihenfolge (auch bei Zweittumoren) ein.



### Eingehende Meldungen im Krebsregister (anonymisiert)

#### mögliche Quellen



Durch die Anonymisierung kann keine Person mehr namentlich identifiziert werden, aber es bleibt für die wissenschaftliche Auswertung möglich zu unterscheiden, ob sich zwei Meldungen auf dieselbe oder auf verschiedene Personen beziehen.

## Aufgabe des Record-Linkage

- **Finden und Zusammenführen aller zu einer Person gehörenden Datensätze**
- **Fehlertoleranz:**  
**Zusammenführung auch bei nicht völlig identischen Identifikationsmerkmalen**  
z.B. - **Schreibfehler**  
- **Wohnortwechsel**  
- **Namenswechsel durch Heirat**  
- **Vertauschung von Geburtsmonat und -tag**

## Mögliche Fehler beim Record-Linkage

### Homonymfehler

Datensätze werden zusammengeführt, obwohl sie zu verschiedenen Personen gehören

**Ursache:** Zufällige Merkmalsidentität oder zu geringe Trennschärfe des Linkageverfahrens  
z.B. häufiger Name und Großstadt als Wohnort

### Synonymfehler

Datensätze werden nicht zusammengeführt, obwohl sie zu einer Person gehören

**Ursache:** Schreibfehler oder Änderungen in zu vielen Identifikationsmerkmalen



## Linkage - Algorithmus (1)

### Quelle

Ivan P. Fellegi, Alan B. Sunter:

*A theory for record linkage.*

American Statistical Association Journal,  
December 1969; 40:1183-220

### Grundlage für die meisten probabilistischen Record-Linkage-Anwendungen (auch kommerzieller Programme)

## Linkage - Algorithmus (2)

### Ausgangssituation

**Mengen A und B von Meldungen**

**Alle möglichen Paare:**

$$A \times B = \{ (a,b); a \in A, b \in B \}$$

**Gesucht werden Paare von Meldungen, die zur selben Person gehören („matched“):**

$$M = \{ (a,b); a = b, a \in A, b \in B \}$$

**Alle anderen Paare gehören zur Menge der nicht zusammengehörenden („unmatched“):**

$$U = \{ (a,b); a \neq b, a \in A, b \in B \}$$

### Anwendung beim Online-Record-Linkage im Krebsregister

**A = {neu eingetroffene Meldung}**

**B = {alle schon vorhandenen Meldungen}**

## Linkage - Algorithmus (3)



### Merkmalsvektor der Matchvariablen

$a = (a_1, \dots, a_n), \quad b = (b_1, \dots, b_n),$

z.B. (Nachname, Vorname, Geburtsname, Geburtsdatum, Wohnort)

## Linkage - Algorithmus (4)

### Übereinstimmungswahrscheinlichkeiten $m$

$$m_{ik} = P(a_i = b_i \wedge a_i = x_{ik} | (a, b) \in M)$$

Wahrscheinlichkeit, dass zwei Meldungen  $a$  und  $b$  von der gleichen Person im  $i$ -ten Merkmal übereinstimmen und dieses Merkmal die Ausprägung  $x_{ik}$  besitzt

$m_{ik}$  werden aus geprüftem Datenbestand ermittelt oder geschätzt, falls geschätzt, wird  $m_{ik} = m_i$  für alle Merkmalsausprägungen angenommen

z.B.  $m_{\text{Geburtsdatum}} = 0,99$

$m_{\text{Vorname}} = 0,975$

(1 - Wahrscheinlichkeit eines Schreibfehlers, Namensänderung, Umzugs, usw.)

## Linkage - Algorithmus (5)

### Übereinstimmungswahrscheinlichkeiten $u$

$$u_{ik} = P(a_i = b_i \wedge a_i = x_{ik} \mid (a, b) \in U)$$

Wahrscheinlichkeit, dass zwei Meldungen a und b von verschiedenen Personen im i-ten Merkmal übereinstimmen und Ausprägung  $x_{ik}$  haben

Auf Grund der wesentlich kleineren Mächtigkeit der Menge M im Vergleich zu U vereinfacht sich die Berechnung der  $u_{ik}$ : Diese können der Häufigkeitsverteilung für Merkmal i aus der Population entnommen werden (gegebenfalls nach Anonymisierung der einzelnen Ausprägungen)

z.B.	$u_{\text{Wohnort, „München“}}$	= 0,168
	$u_{\text{Wohnort, „Oberstdorf“}}$	= 0,001
	$u_{\text{Nachname, „Müller“}}$	= 0,01121
	$u_{\text{Nachname, „Hotzenplotz“}}$	= 0,00003

## Linkage - Algorithmus (6)

### Übereinstimmungsgewicht

$$w = \sum w_i$$

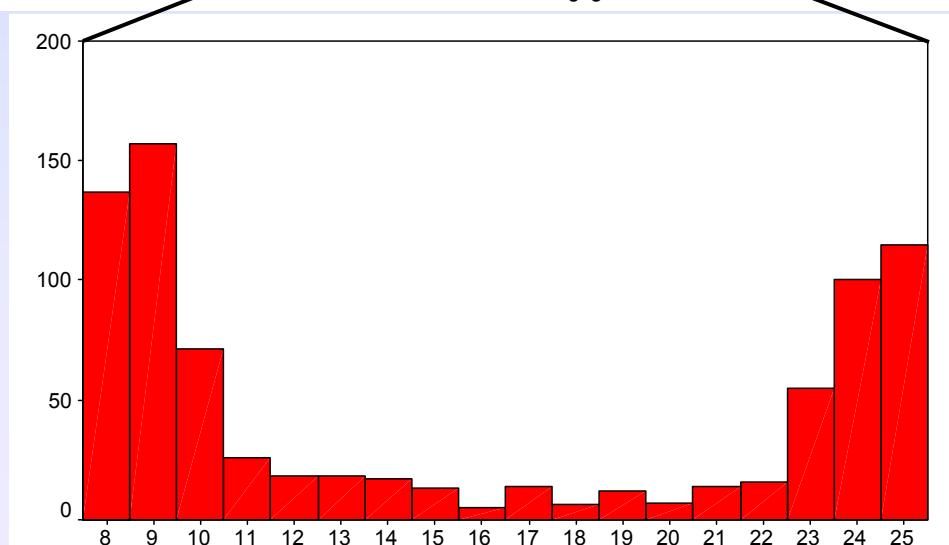
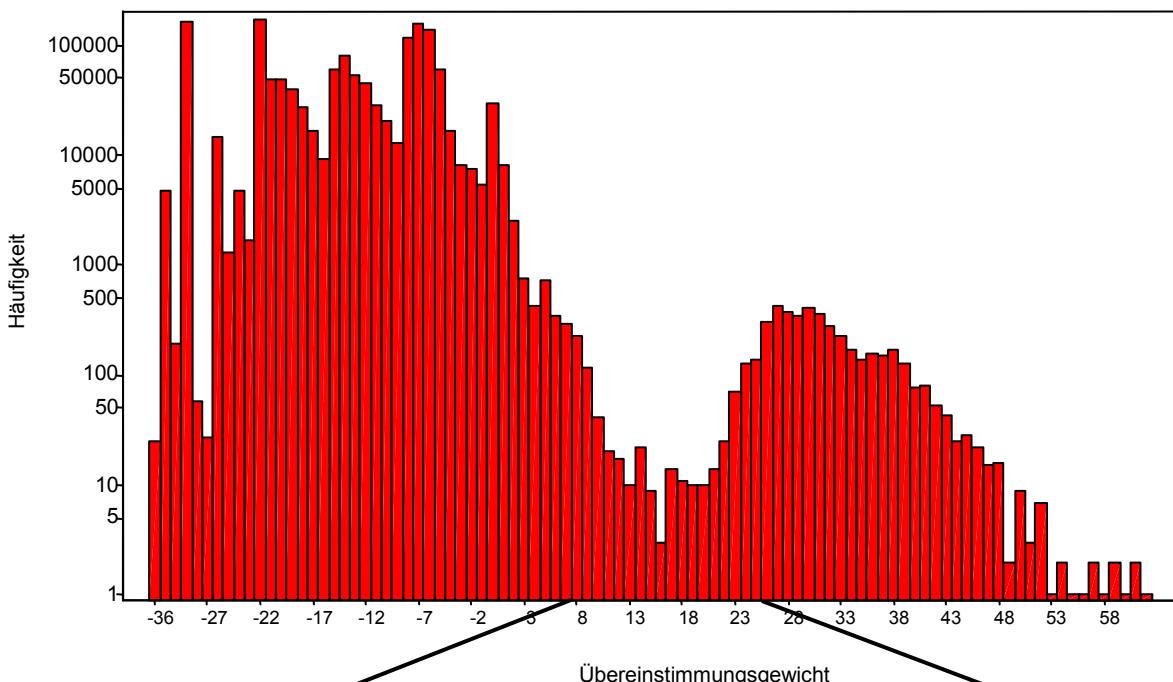
wobei

$$w_i = \log (m_i / u_{ik}) \quad , \text{ falls } a_i = b_i \wedge a_i = x_{ik}$$

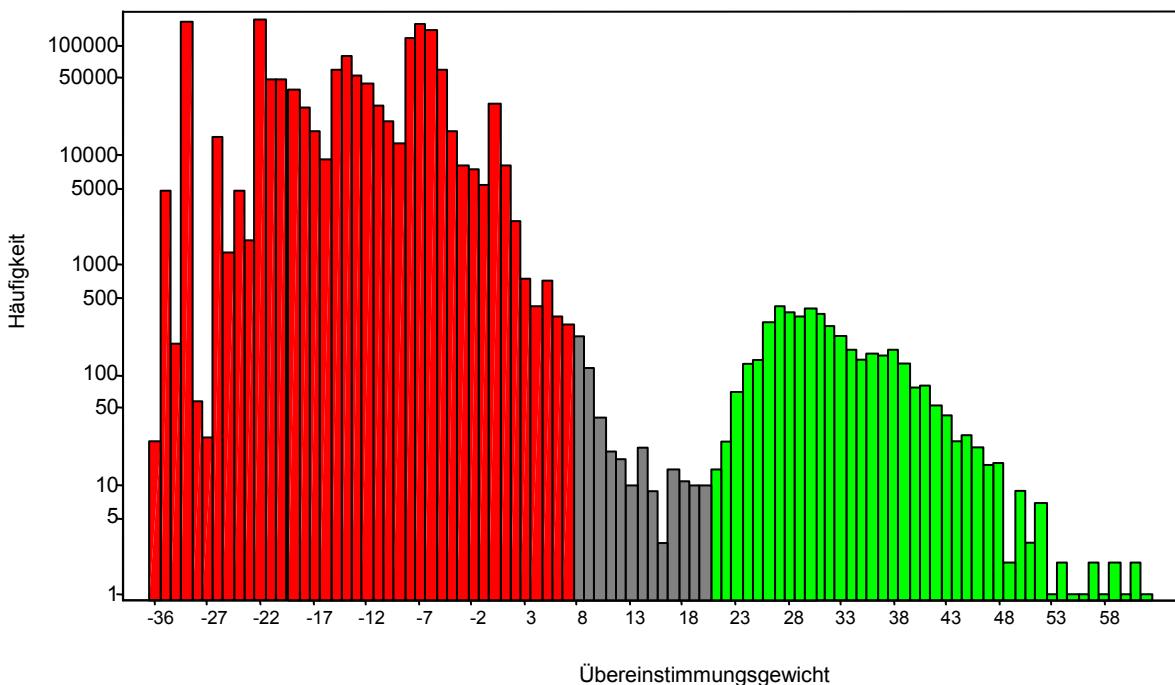
$$w_i = \log ((1-m_i) / (1-u_{ik})) \quad , \text{ falls } a_i \neq b_i \wedge a_i = x_{ik}$$

Die Gewichtsbeiträge  $w_i$  sind bei Übereinstimmung positiv, sonst negativ (Die Wahrscheinlichkeit, dass Übereinstimmung vorliegt, ist in der Menge M größer als die Wahrscheinlichkeit für zufällige Übereinstimmung).

## Krebsregister: Übereinstimmungs- gewichte für alle in Frage kommenden Meldungspaare (1,4 Mio.)



## Krebsregister: Übereinstimmungs- gewichte für alle in Frage kommenden Meldungspaare (1,4 Mio.)



positiver Nicht-Link

möglicher Link

positiver Link

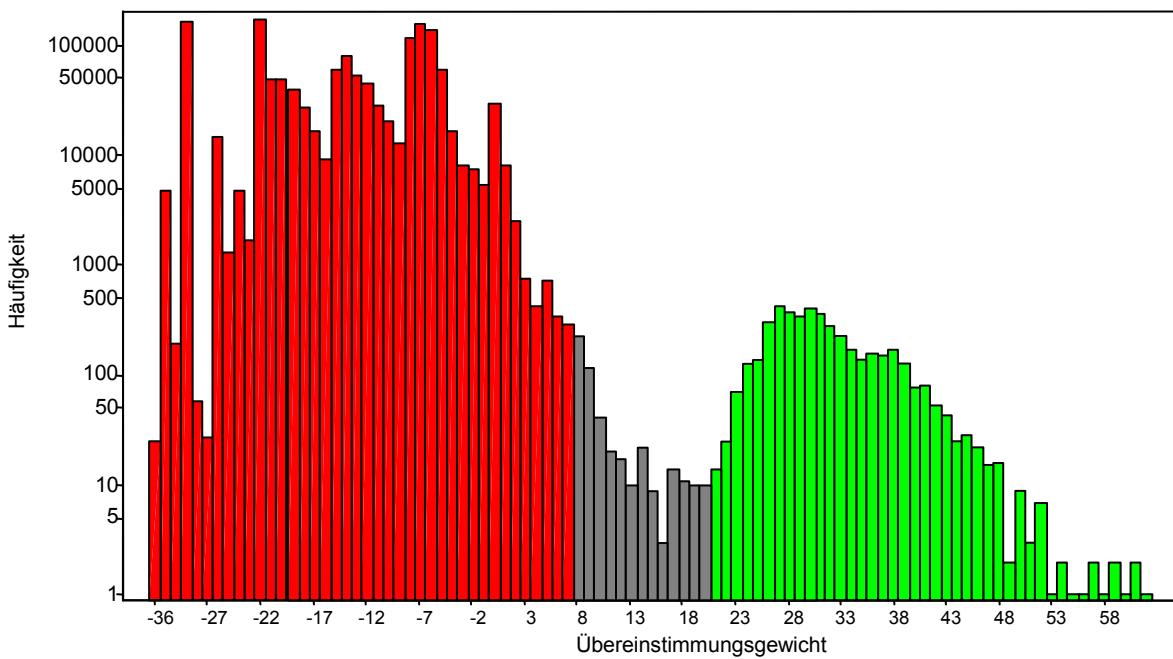


Automatische  
Weiterverarbeitung  
einzelner Meldungen

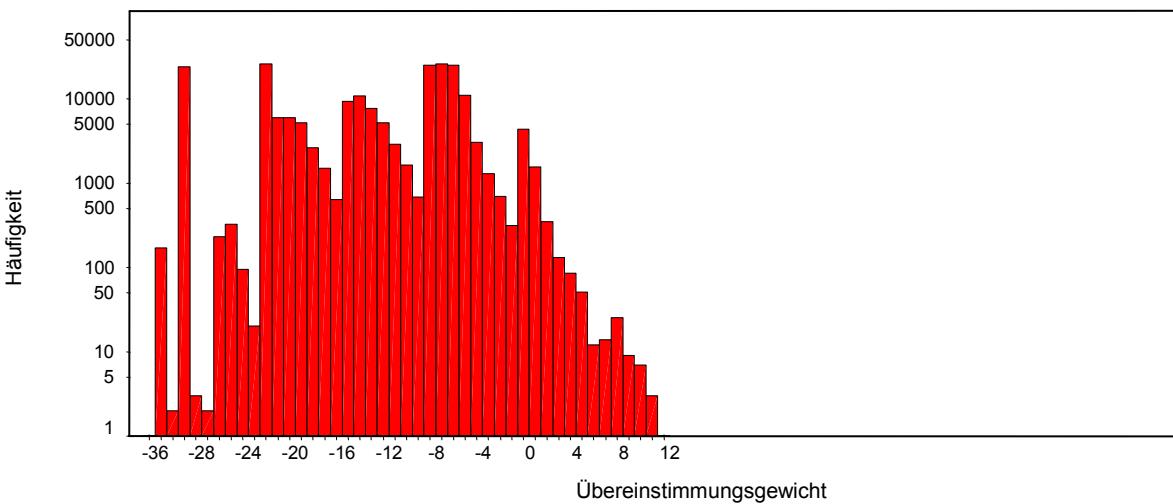
Interaktive Gewinnung  
der besten Information  
aus zusammengehörigen Meldungen  
(automatisch generierte Vorschläge)

## Validierung

### Alle Gewichte



**Gewichte für Meldungen aus  
einer einzigen Auswertung  
von Totenscheinen  
(hier kann es keine  
Mehrfachmeldungen geben)**





## Interaktives Zusammenführen

Record Linkage

Zuordnung suchen für—

alle Meldungen (nur Gewichte berechnen)  
 neu hinzugekommene Meldungen  einschließlich zurückgestellter Meldungen  
 einzelne Meldung  
 alle Folgemeldungen

Einstellungen ...

Aktuell bearbeitete Meldung 66

Meldung	Block	Gewicht	Personen-ID	NN I	II	III	VN I	II	III	GN I	II	III	FN I	II	III	G.tag	Ph.NN	Ph.VN	Ph.GN	Ph.FN	Titel 1	2	Sex	G.mon.	G.jahr	G.schlüssel	Mehr.	D.mon.	D.jahr	ICD-9	ICD-10
66	0			0	6...	*	*	k...	D...	*	*	*	*	*	*	0G...	\@...	_q...	*o+...	*o+...	*	M	5	1941	09574155	N	7	1998	150.4		
<input checked="" type="checkbox"/> 65	1	38,3411		0	6...	*	*	k...	D...	*	*	*	*	*	*	0G...	\@...	_q...	*o+...	*o+...	*	M	5	1941	09574155	N	7	1998	150.4		
<input checked="" type="checkbox"/> 64	2	28,0474		0	6...	*	*	k...	D...	*	*	*	*	*	*	0G...	\@...	\$b...	*o+...	*o+...	*	M	5	1941	09574155	N	7	1998	150.4		

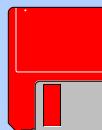
Start Stop Weiter Aus den markierten Meldungen Person erzeugen... Markierte Meldungen vorerst von der Bearbeitung zurückstellen Manuelle Nachfrage erzeugen ... Schliessen



## Interaktives Zusammenführen (2)



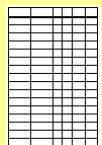
# Population Based Cancer Registry Bavaria



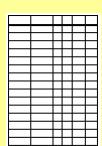
Incidence records from  
confidential office

## External Dictionary

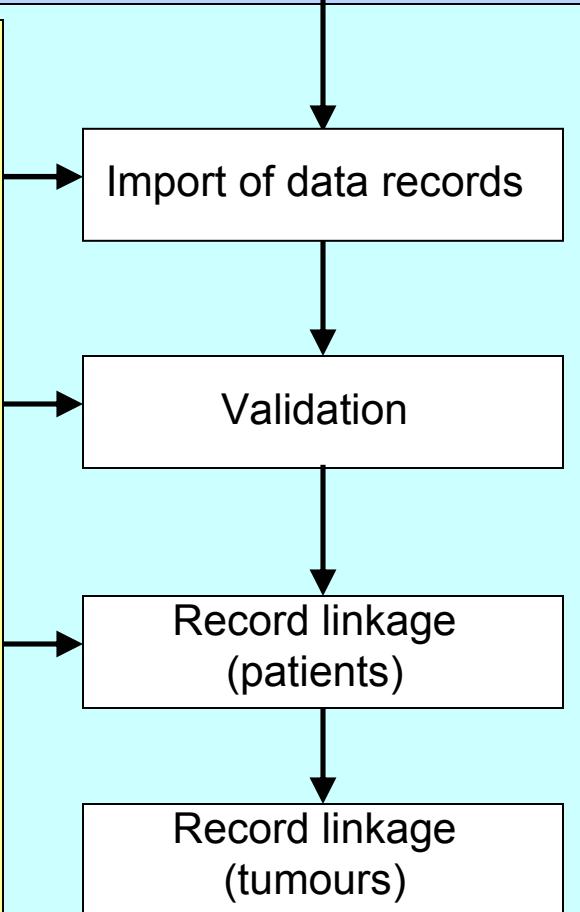
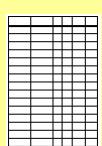
Data Dictionary



Validation rules



Linkage  
parameters



## Processes within the bavarian registration office

### Automated

Matching of imported to internal variables

Formal validation (e.g. column format)

Simple validation

Cross-field validation

Computer generated error reports

Positive non-links

Positive links

Computer aided suggestions

Post-update validation

### Interactive

Possible links

Cross-record validation

Final decision