



UNIVERSITÄTSmedizin.
MAINZ

Datenabgleich mit dem Deutschen Kinderkrebsregister

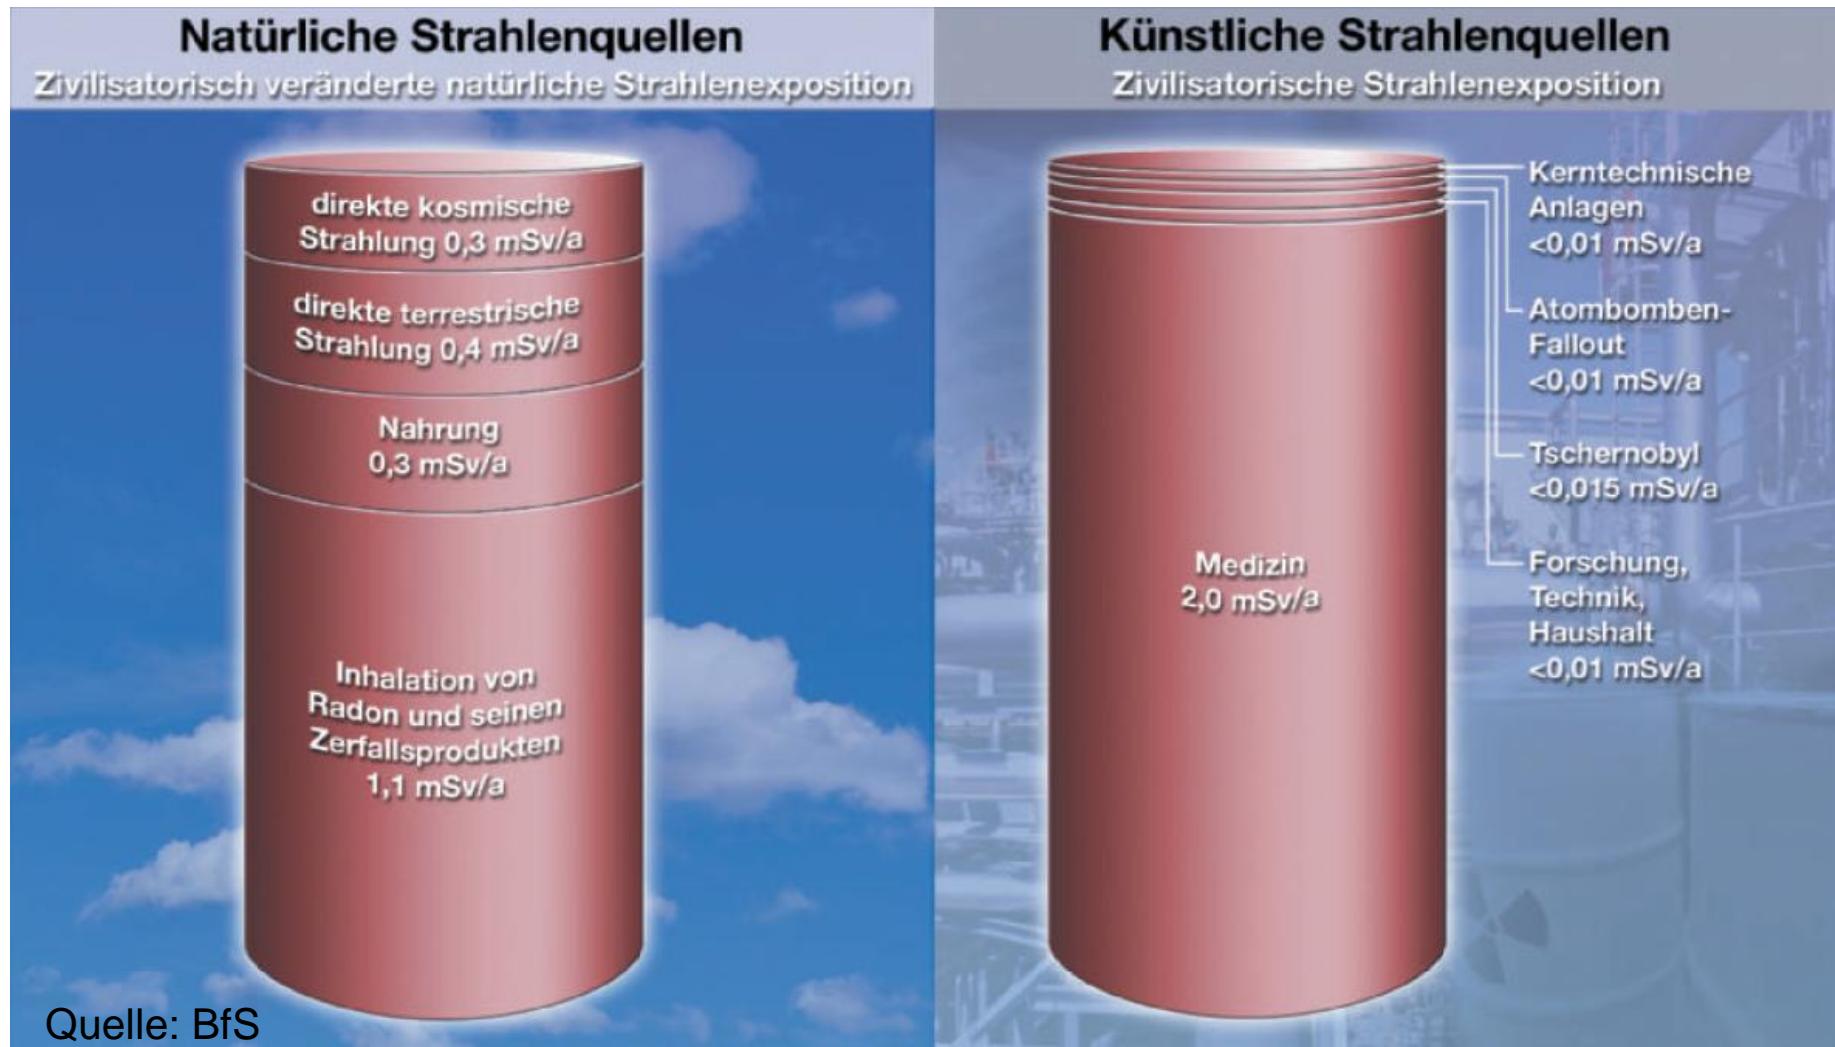
Erfahrungsbericht aus einer epidemiologischen Kohortenstudie

Dr. Gaël Hammer

Gliederung

- Die RICC-Studie
- Epidemiologische Krebsregister in Deutschland
- Datenschutz in der RICC-Studie
- Garbage in ...
- Stochastisches Record-Linkage
- ... und was hinten 'rauskommt

Die RICC-Studie



RICC-Studie - Hintergrund



UNIVERSITÄTSmedizin.
MAINZ

Institut für Biometrie, Epidemiologie
und Medizinische Informatik



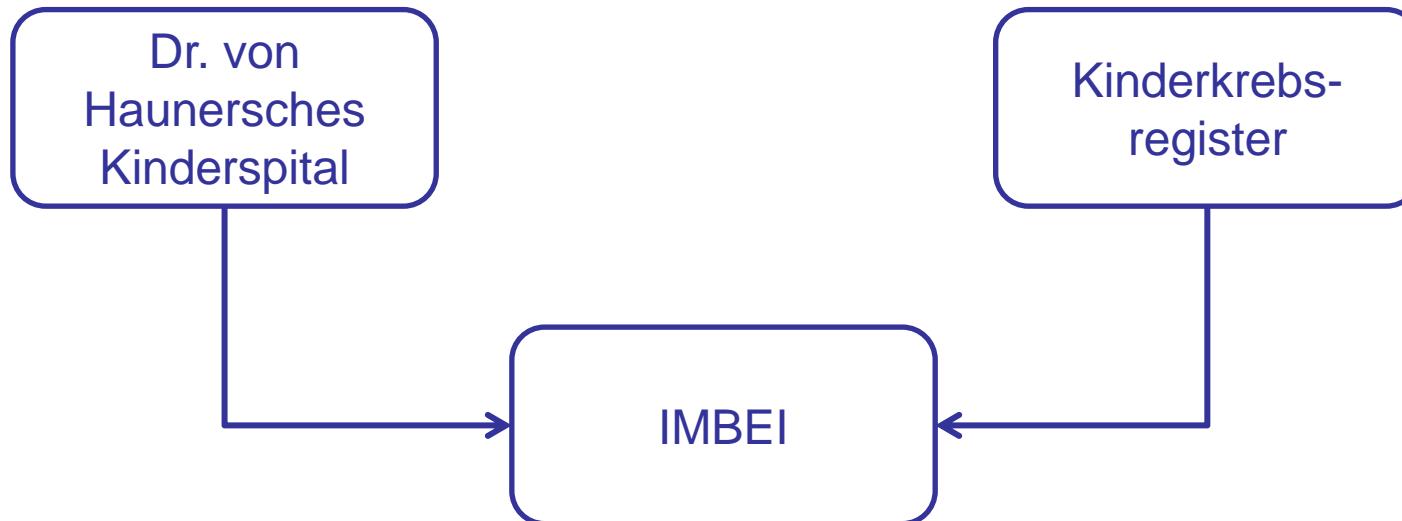
Quelle: Wikipedia: Kingofears

- Röntgenverordnung 1973
- Datensammlung am Dr. von Haunerschen Kinderspital der LMU München
- Protokoll aller Röntgenaufnahmen seit 1976 in Datenbanken (MINDIUS I-III, ab 1998 RIS-System)
- Auswertungen
 1. Strahlendosen
 2. Strahlenrisiko

Einschlusskriterien

- Rekrutierungszeitraum 1976-2003
- krebsfrei zu Beginn (inkl. erste 6 Monate)
- Hauptwohnsitz in Deutschland
- Alter bei Einschluss \leq 14,5 Jahre
- Am 1.1.1980 noch \leq 15 Jahre alt

- Abgleich Pseudonymisierter Daten mit dem Gesamtbestand des deutschen Kinderkrebsregisters (erweiterte Registerbevölkerung)
- Beobachtungszeitraum: 1980-2006

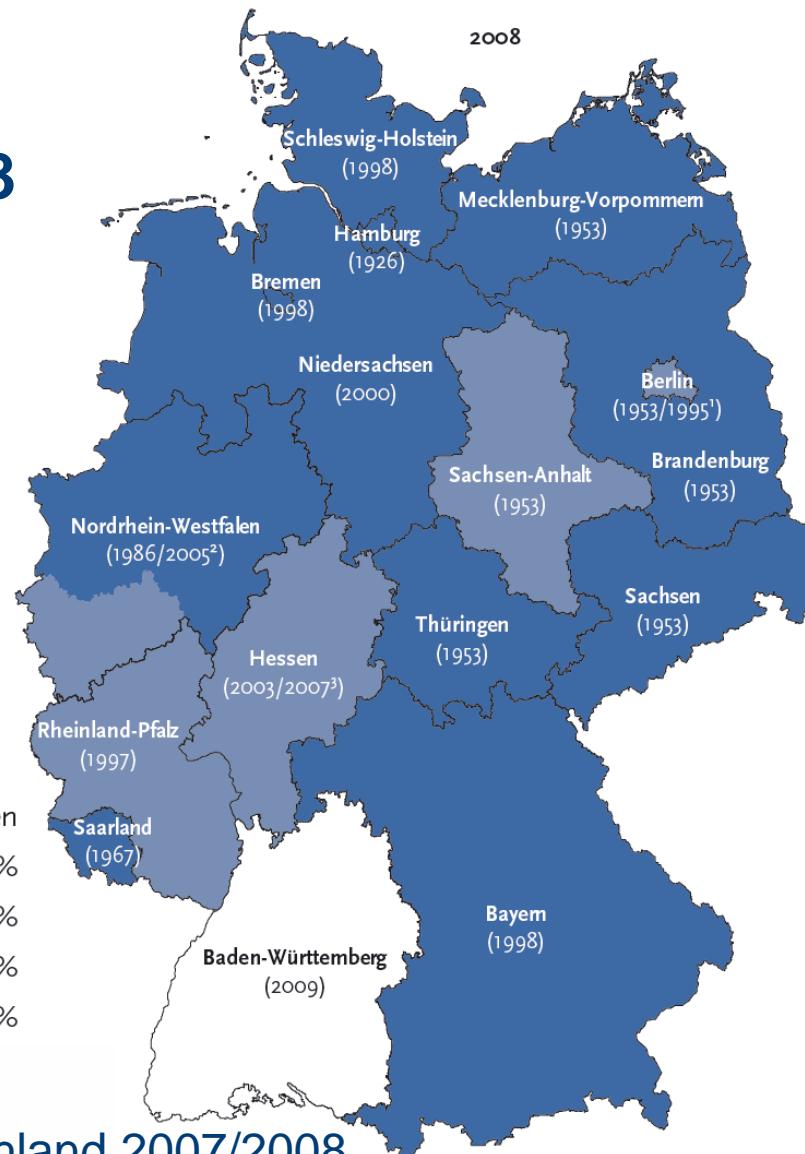


Epidemiologische Krebsregister in Deutschland

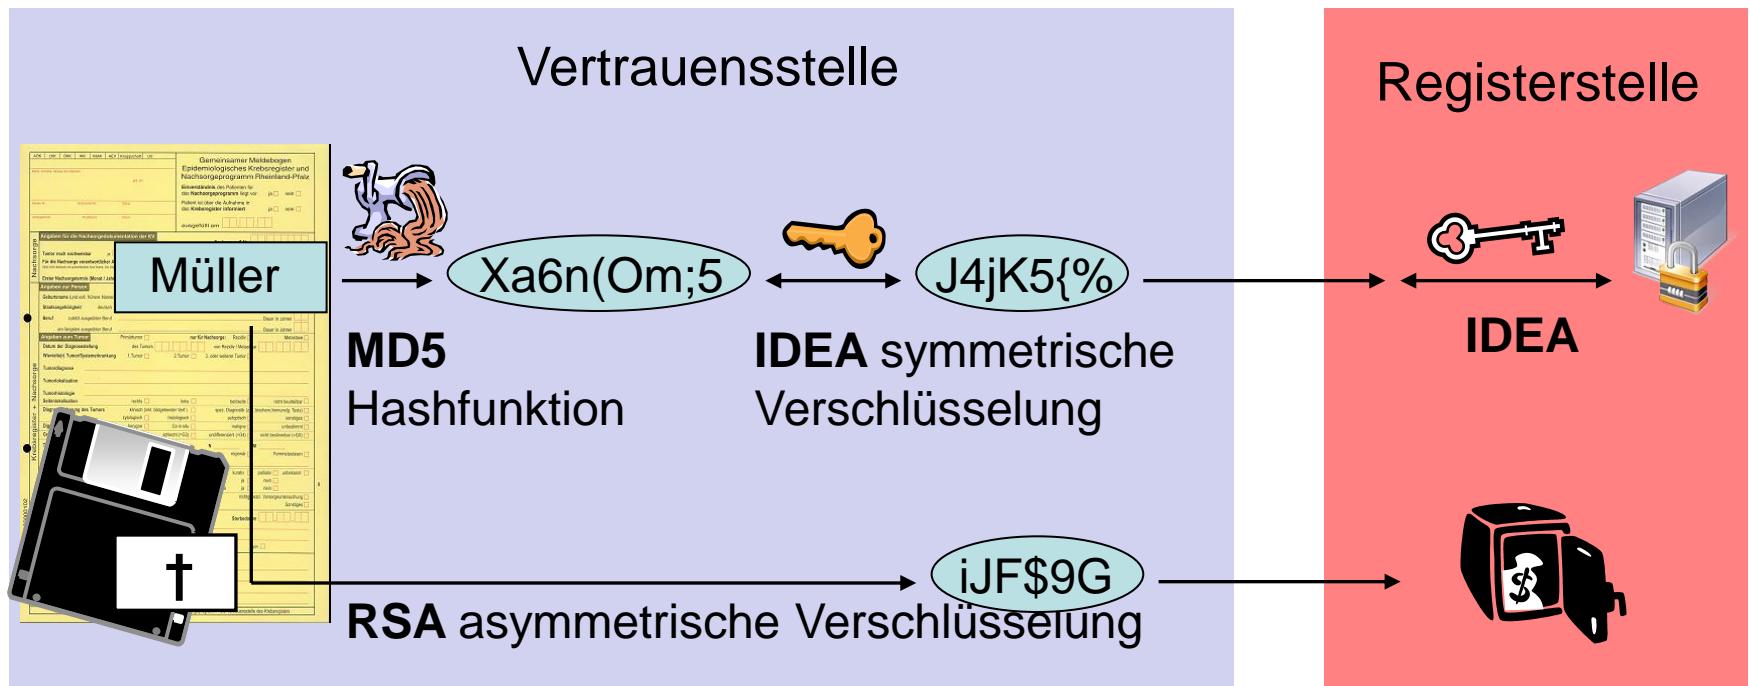
Epidemiol. Krebsregister in Deutschland



geschätzte
Vollzähligkeit 2008



Quelle: RKI: Krebs in Deutschland 2007/2008



Epidemiol. Krebsregister gespeicherte Daten



Personenidentifizierende Merkmale

- Vorname(n)
- Nachname(n)
- frühere(r) Name(n)
- Geschlecht
- Straße
- PLZ
- Ort
- Geburtsdatum
- Todesdatum
- Diagnosedatum

Epidemiologische Daten

- Geschlecht
- Geburtsmonat und -jahr
- Gemeindekennziffer
- Nationalität
- Letzte und längste Beschäftigung(en)
- Tumor-Klassifikation (ICD-10)
- Topologie und Morphologie (ICD-O-3)
- Tumorlokalisation, Lateralität
- Diagnosemonat und -jahr
- Stadium (TNM)
- Basis der Diagnose
- Methode der Ersterkennung
- Erstbehandlung
- Todesmonat und -jahr
- Todesursachen
- Ersttumor ja/nein

Bildung von Kontrollnummern

1. Verarbeitung

- Zerlegung in 3 Einzel-
Bestandteile ✗
- Phonetischer Code

2. Kodierung (MD5, IDEA)

- Ergibt „KontrollNummern“

Kölner Phonetik

a, ae, ai, au, ay, e, ei, eu, ey, i, ie, j, oe,	→ e
oi, ue, y	
b, p	→ b
c, ck, g, k, q	→ k
ch, cz, s, sc, sz, tz, x, z	→ s
d, dt, t	→ d
f, ph, v, w	→ f
m, n	→ m
o, ou, u, uo	→ u
l	→ l
r	→ r
h, Leerzeichen, Akzente, Spezialzeichen	→ weg

1.

Meyer-Heide



MEYER

HEIDE



MEYERHEIDE



MEEREDE

(Phonetischer Code)

2.

MAIER



b4CGiH3nw14r4aZy

MD5

MEYER

9z7uMteaU84w9jb8

Record Linkage

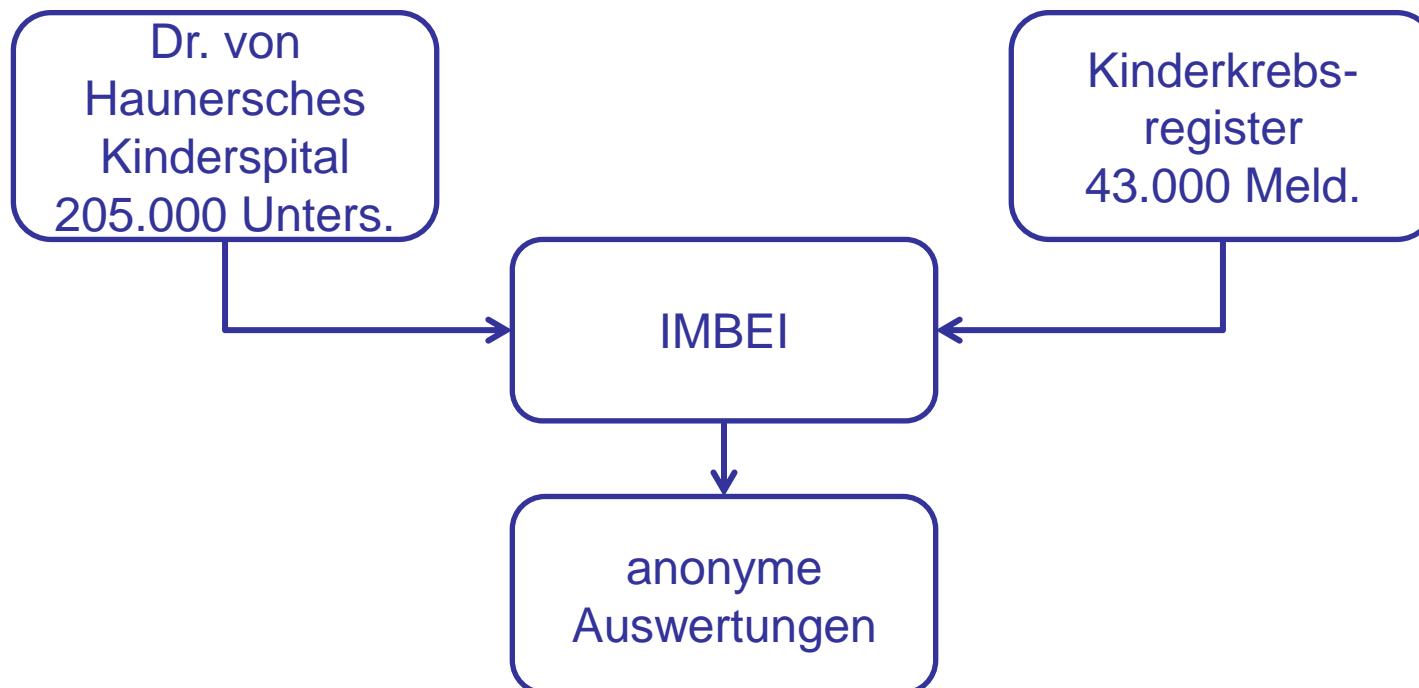
- Fragen: Gibt es mehrere Meldungen
 - zur gleichen Person?
 - zum gleichen Tumor?
 - Vergleich der neuen Meldungen mit allen Bestandsmeldungen
 - Problem: Abweichungen, Daten passen *niemals* perfekt
 - Verfahren: Stochastisches Record-Linkage

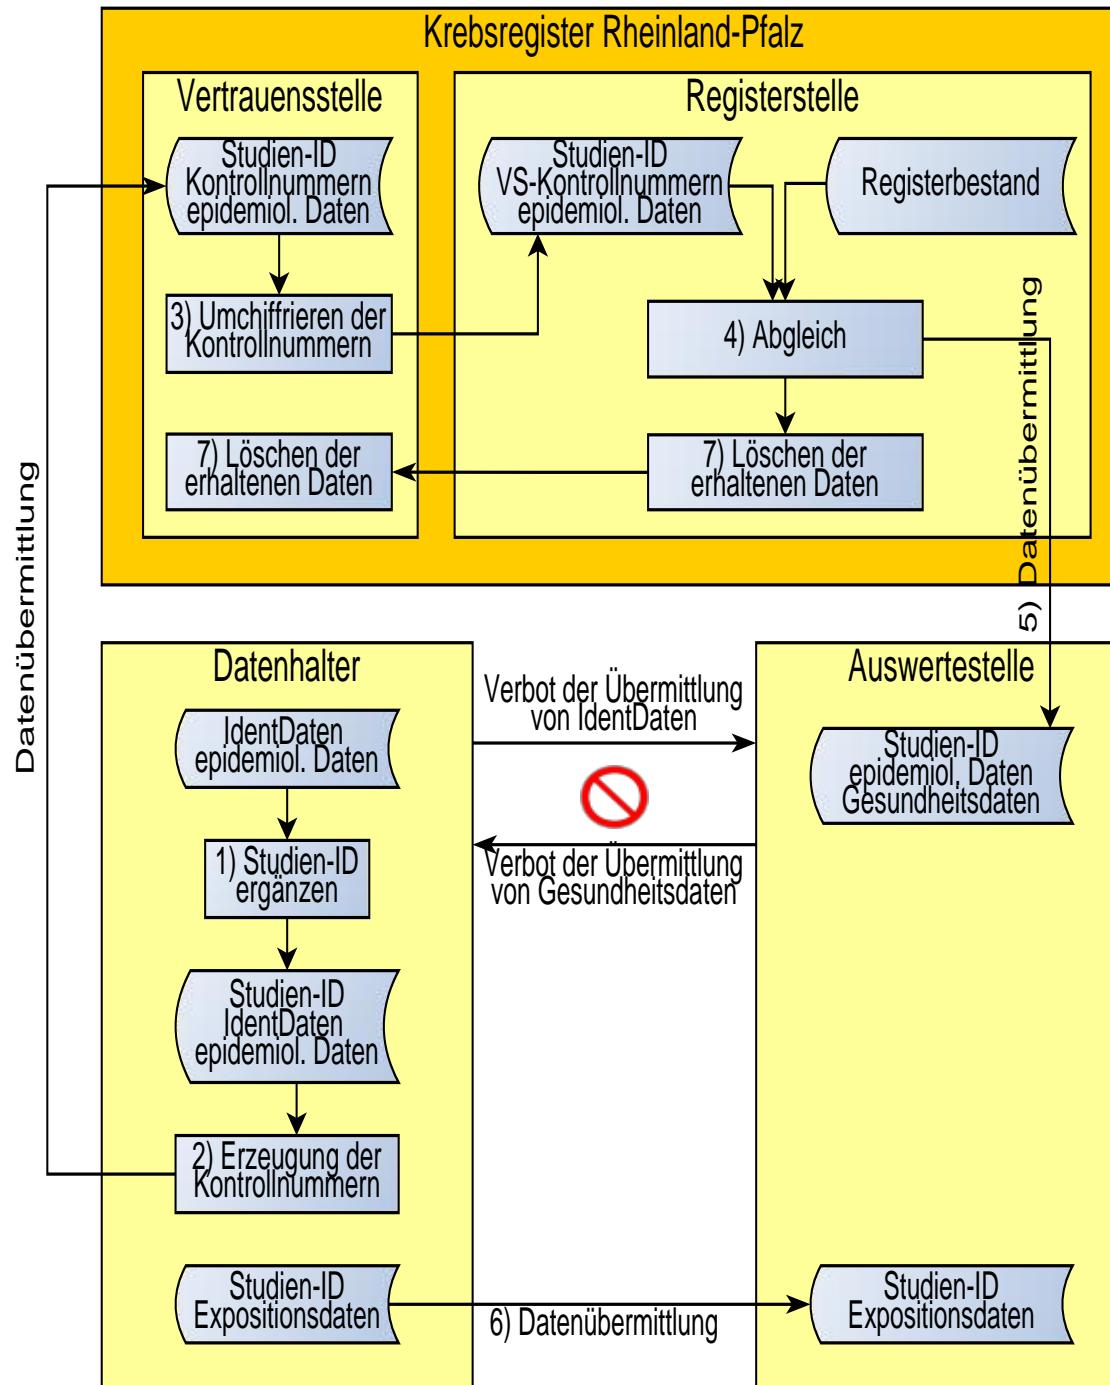
X27\$4i]8cu	X27\$4i]8cu	Kn ₁
Guir7'd0ma	Guir7'd0ma	Kn ₂
8v#rS2o+d3		Kn ₃
bi6ks4i]ul	0jKmD3a..5	
X27\$4i]8cu	X27\$4i]8cu	Kn ₂₂
C67.3	C67.9	Diagnose
8120	8130	Histologie
2	3	Grading
12.2005	01.2006	Datum
07336055	07336055	Gemeinde
↓	↓	
gleiche Person?		
gleicher Tumor?		

Datenschutz in der RICC-Studie

Datenschutz in der RICC-Studie

- IMBEI als Treuhänder und Auswerter
- Verwendung von Kontrollnummern mit studienspezifischem IDEA-Schlüssel
- Keine Rückübermittlung von Daten





Garbage in ...

- 205.000 Untersuchungen in der Kohorte
- Deduplizieren: 103.000 Kinder
- Adressbereinigung

Vorn ame	Name	Geb.da tum	PLZ	Ort	Straße
		8	M	Lindwurm 4	
			Moos	3	
			Oberschleißheim		
			Oberschleißheim		
		8	M	Konsulat	

Stochastisches Record-Linkage in der RICC-Studie

- Verwendung von Kontrollnummern, binärer Vergleich
- Merge Toolbox
- Mehrstufige Strategie
 - In jeder Stufe werden festgelegt:
 1. Variablen deren Ausprägungen exakt übereinstimmen müssen ("Block-Variablen") (sozusagen ein deterministischer Teil)
 2. Variablen zur Berechnung des Scores ("Match-Variablen", "stochastischer Teil")
 3. Schwellenwerte für die Kategorisierung des Scores in "Match / Graubereich / Non-Match"

Klassisches Modell von Fellegi-Sunter

- Definiere die bedingten Wahrscheinlichkeiten
 - $m_i = P(\text{Gleicher Wert in Variable } i \mid \text{Datensätze gehören zusammen})$
 - $u_i = P(\text{Gleicher Wert in Variable } i \mid \text{Datensätze gehören nicht zusammen})$
- Berechne Übereinstimmungs-Scores aus den Odds:

Werte von Variable i	Wahrscheinlichkeiten		Odds	Score $_i$
	Matches	Non-Matches		
gleich	m_i	u_i	$m_i : u_i$	$\ln(m_i : u_i)$
ungleich	$1 - m_i$	$1 - u_i$	$1 - m_i : 1 - u_i$	$\ln(1 - m_i : 1 - u_i)$

$$\text{Gesamtscore} = \sum (\text{Score}_i)$$

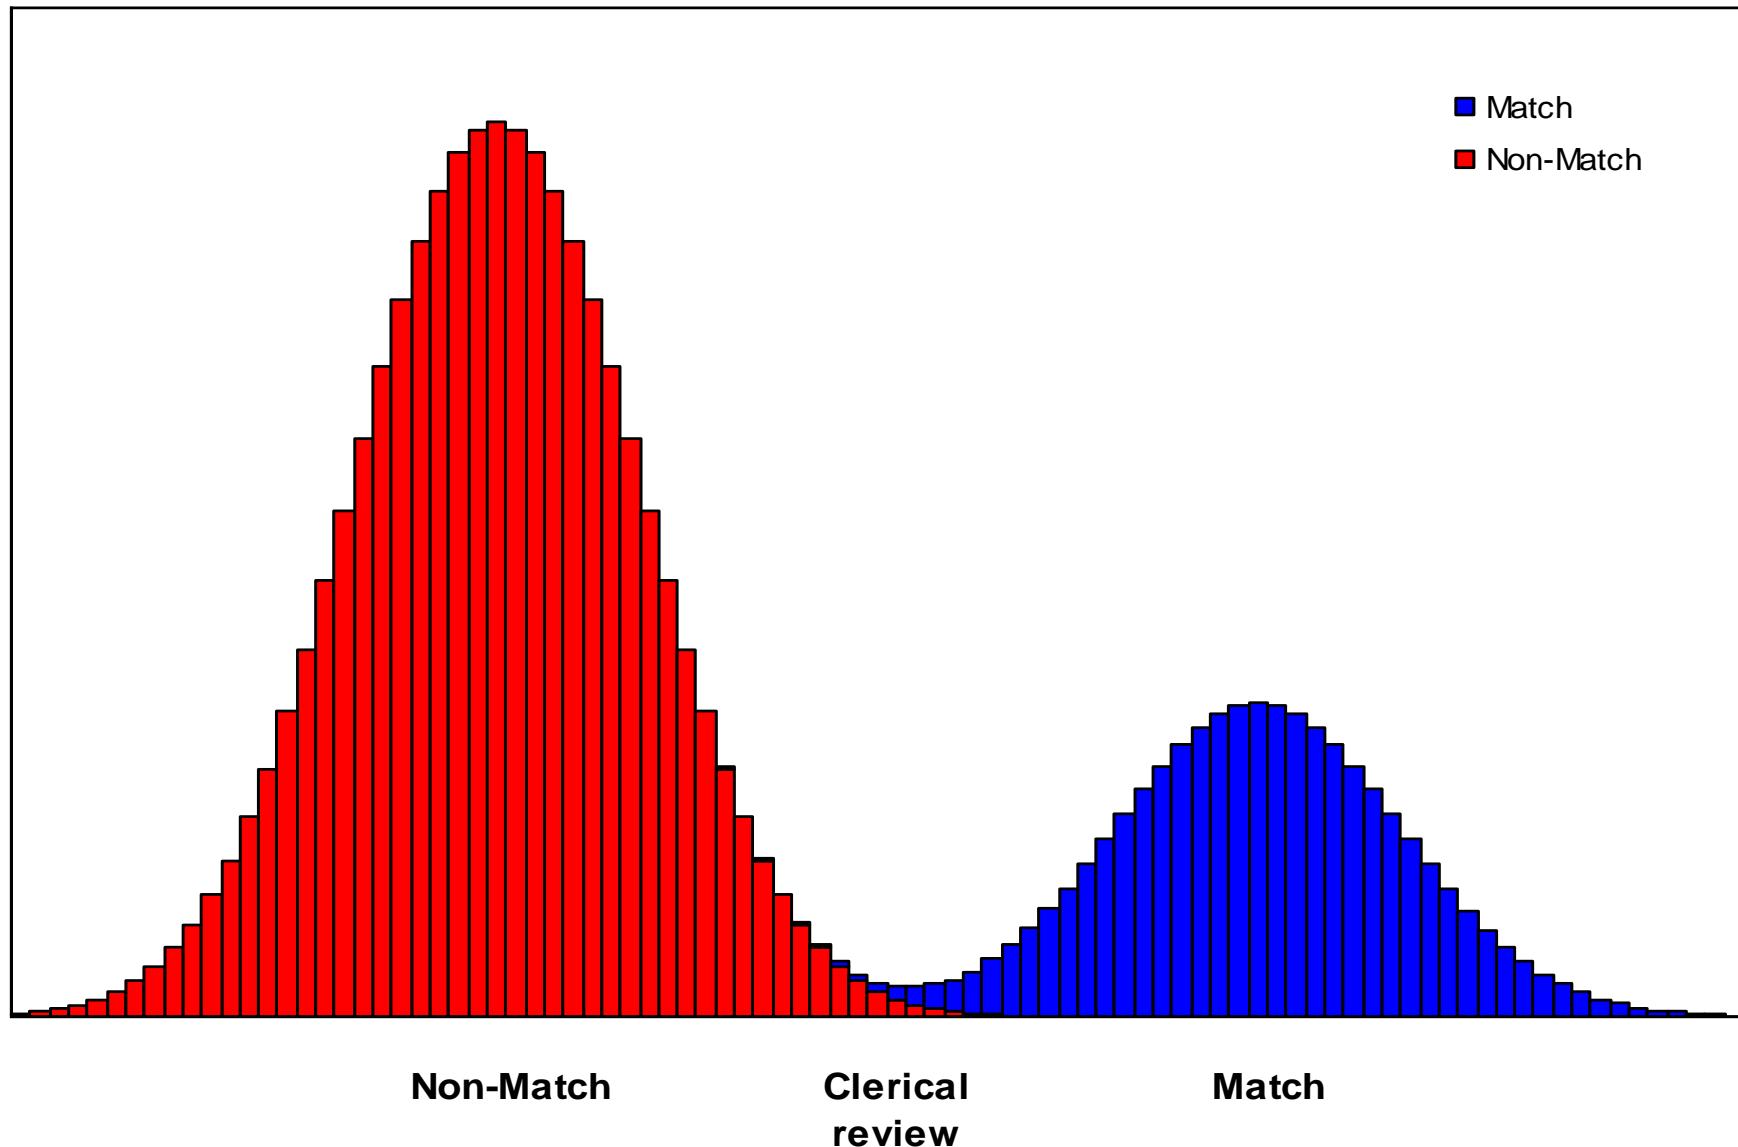
- Beispiel

Institut für Biometrie, Epidemiologie
und Medizinische Informatik

Variable	Ausprägung	m	u	Score	
				Gleichheit	Ungleichheit
Vorname	Thomas	0,95	0,01	+4,55	-2,99
	Gaël	0,95	0,000001	+13,76	-3,00
	(andere)	0,95	0,01	+4,55	-2,99
Geschlecht		0,99	0,5	+0,7	-1,6

- Das Geschlecht trägt viel weniger Information bei als der Vorname, ob übereinstimmend oder nicht.
- Die Wahrscheinlichkeit u kann aus den Daten geschätzt werden als 1/Häufigkeit der jeweiligen Ausprägung

Beispiel Scores



- Stufen

- erste Stufe: perfekte Übereinstimmung
 - Alle Variablen sind Block-Variablen
- nächste Stufen: Relaxierungen
 - unterschiedliche Block-Variablen
- unveränderte Match-Variablen

– Beispiel Stufen

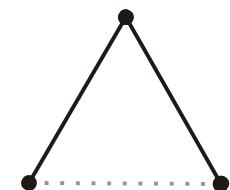
	Stufe						<i>m</i>	<i>u</i>
	1	2	3	4	5	6		
Block- Variablen	Vorname1	VornameΦ	Vorname1	VornameΦ	Vorname1	Geschlecht		
	Nachnam1	NachnamΦ	Nachnam1	NachnamΦ	Nachnam1	GebTag		
	GebTag	GebTag	GebJahr	GebJahr	PLZ5	GebMonat		
	GebMonat	GebMonat	Ort	Ort		GebJahr		
	GebJahr	GebJahr						
Match- Variablen	Vorname						0,95	0,01
	Nachname						0,90	0,01
	Geschlec						0,80	0,50
	GebTag						0,90	0,03
	GebMonat						0,90	0,08
	GebJahr						0,98	0,01
	PLZ4						0,80	0,02
	PLZ5						0,85	0,01
	Ort						0,80	0,01
	Diagnose-Monat+Jahr						0,90	0,01

– Ergebnis (n:m)

Datei A		Datei B	
ID		ID	Score
1		198	51,28
1		217	45,38
1		1024	26,11
4		1024	49,70
6		37	33,45

Clerical Review

- RL-Software liefert: Liste von Paaren vergleichener Meldungen + Übereinstimmungs-Score
- Aufbereitung (SAS): Gruppen potentiell zusammengehöriger Meldungen
- Handarbeit: Meldungen gehören zusammen/nicht



Grp	G	Vorname	Nach	Geb	Str	Ort	Tod	Diagn	Topo	Morph
9876	M	FRANZ	PUSICHA	13.02. 1939	HERFO RDER	BIELEF ELD		11.2004	C349	80423
9876	W	LUDWIG FRANZ	PUSICHA	13.02. 1939	HERFO RDER	BIELEF ELD		11.2004	C349	80423
9876	U	FRANZ	PURSICHA	13.02. 1938	HERFO RDER	BIELEF ELD	18.11.2 008			

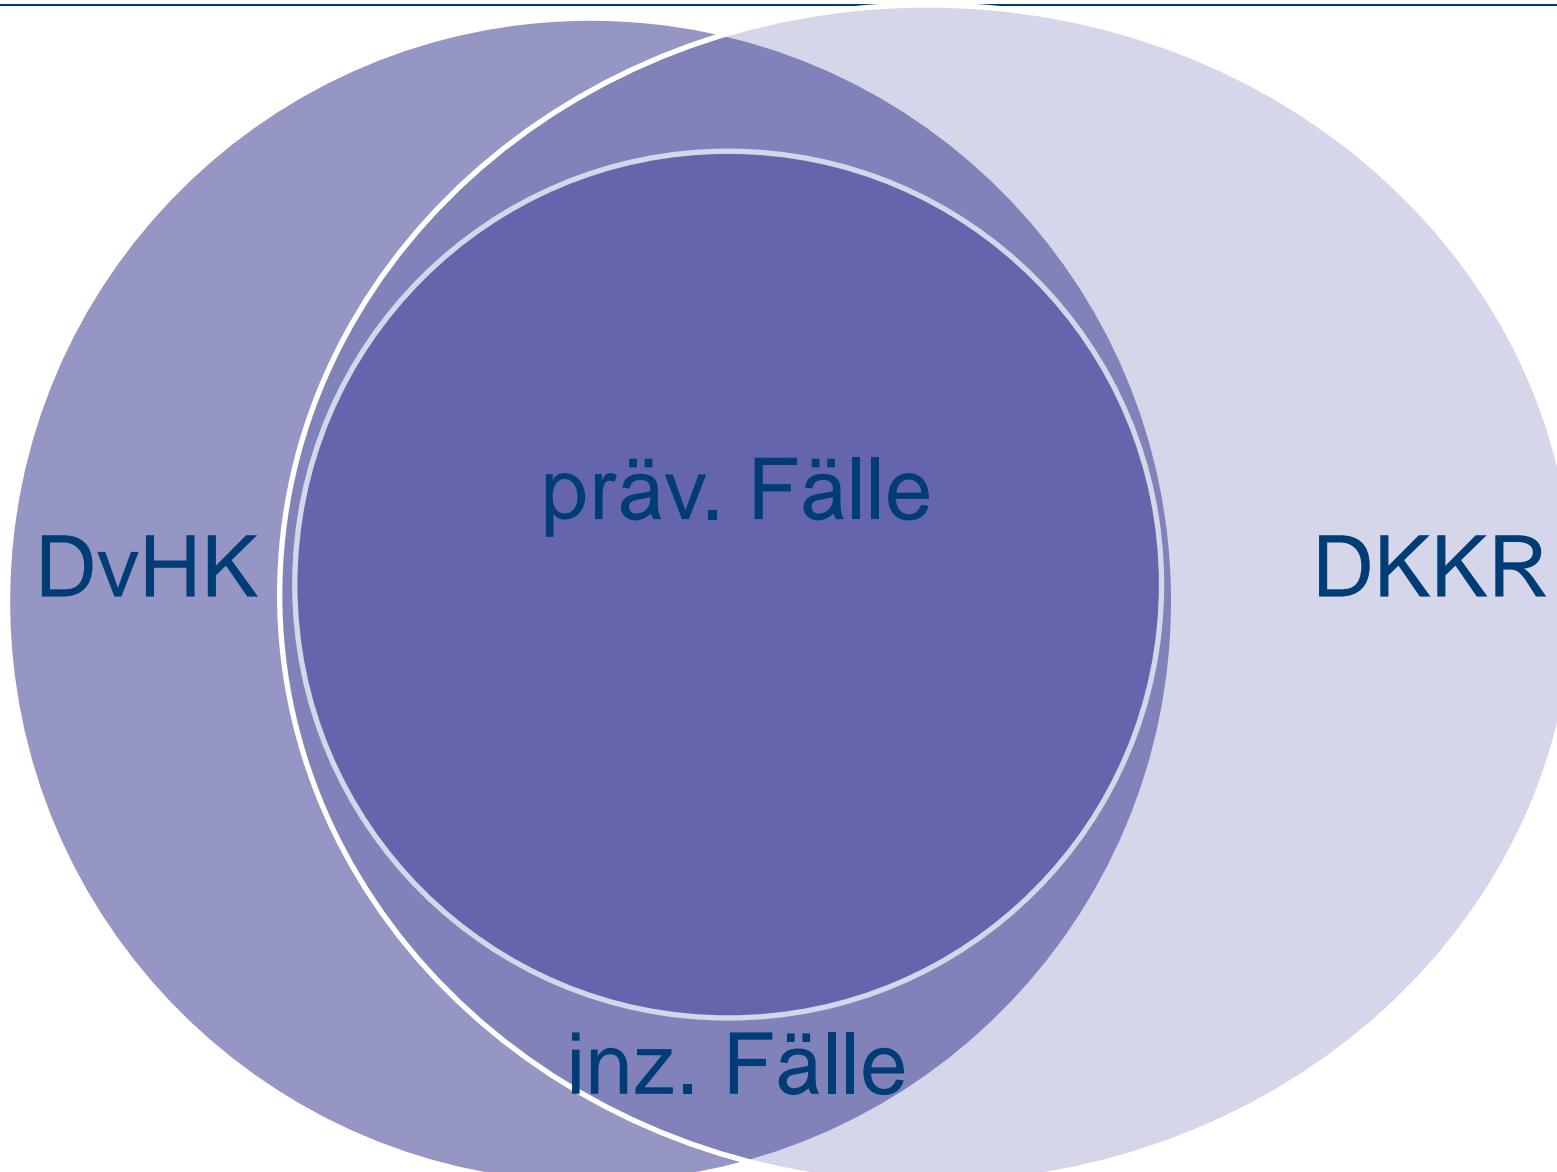
– Beispiel Clerical Review

Institut für Biometrie, Epidemiologie
und Medizinische Informatik

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	
1	Ma	Weight	Ident	Patient	Unters	Adr	G	Geburt	Vorname	Vers.	Nachname	VersName	PLZ	Ort	Unters/Dia	Alt	Indikation	
2	ch	Weight			Malig	ZT	G	T MM JJJJJ	1+b 2+b 3+b	K+Vorname	1+b 2+b 3+b	Frühname	4 5		TT MM JJJJJ	er	ICD03 ICD03	
14699	MA	33.12					alt	M	F 01 1979	H	J	G		I	B 02 1990	183	SCHMERZEN UNI	
14700	MB	33.12	1				1	M	F 01 1979	H	J	G G		I	D 01 08 1990	89203 91		
14701	+A						alt	M	F 01 1979	H	J	G		I	B 02 1990	183	SCHMERZEN UNI	
14702																		
14703	MA	32.92					neu	M	T 01 1976	I B	L E	D H R		S	F 08 1982	91	SCHMERZEN UNI	
14704	MB	32.92	2				1	M	T 01 1976	I	L	Q Q		P	F 12 08 1987	96913 22		
14705																		
14706	MA	32.77					alt	M	L 04 1989	F	H	G			A 02 1995	70	SEPTISCHER SI	
14707	MB	32.77	1				1	M	L 04 1989	F	H	G G		J	K 07 03 1994	96003 41		
14708																		
14709	MA	32.53					alt	M	F 05 2002	G	D	K			E 11 2003	18		
14710	MB	32.53	1				1	M	F 05 2002	G	D	H H		I	J 11 08 2003	89703 71		
14711																		
14712	MA	32.41					alt	M	O 07 1992	H	A	I			J 09 2001	110		
14713	MB	32.41	1				1	M	O 07 1992	H	R	I I		U	S 28 09 2001	96593 21		
14714	+A						alt	M	O 07 1992	H	A	I			G 10 2001	111		
14715	+A						alt	M	O 07 1992	H	A	I			T 11 2001	112		
14716	+A						alt	M	O 07 1992	H	A	I			B 02 2002	115		
14717	+A						alt	M	O 07 1992	H	A	I			N 05 2002	118		
14718	+A						alt	M	O 07 1992	H	A	I			V 08 2002	121		
14719	+A						alt	M	O 07 1992	H	A	I			Q 11 2002	124		
14720	+A						alt	M	O 07 1992	H	A	I			L 01 2003	126		
14721	+A						alt	M	O 07 1992	H	A	I			K 05 2003	130		
14722	+A						alt	M	O 07 1992	H	A	I			E 07 2003	132		
14723	+A						alt	M	O 07 1992	H	A	I			P 10 2003	136		
14724																		
14725	MA	31.78					alt	W	G 04 2001	M	A	D			K 06 2002	14		
14726	MB	31.78	1				1	W	G 04 2001	I	L	A	D E L	J	C 01 07 2005	89603 61		
14727																		
14728	MA	31.48					alt	M	O 07 1992	N	H	P			B 01 1993	6	HNI	
14729	MB	31.48	1				1	M	O 07 1992	J	H	P P		I	B 03 08 2005	90643 101		
14730	+A						alt	M	O 07 1992	N	H L	P		Q	B G 12 1994	29	TRAUMA	
14731																		
14732	MA	30.95					alt	W	J 08 1992	B	D	M			K 07 2003	181		
14733	MB	30.95	1				1	W	J 08 1992	B	I	M M	M M	N	C 20 10 1997	94703 88		
14734	+A						alt	W	J 08 1992	B	D	M			F 09 2001	109		
14735																		
14736	MA	30.57					alt	W	H 08 1997	A	E	I			G 01 2001	46		
14737	MB	30.57	1				1	W	H 08 1997	B	E	I I	I I	C	F 26 07 1999	98363 11		

... was hinten 'rauskommt

RICC-Studie – Ergebnis des Clerical Review



RICC-Studie – Ergebnis des Clerical Review



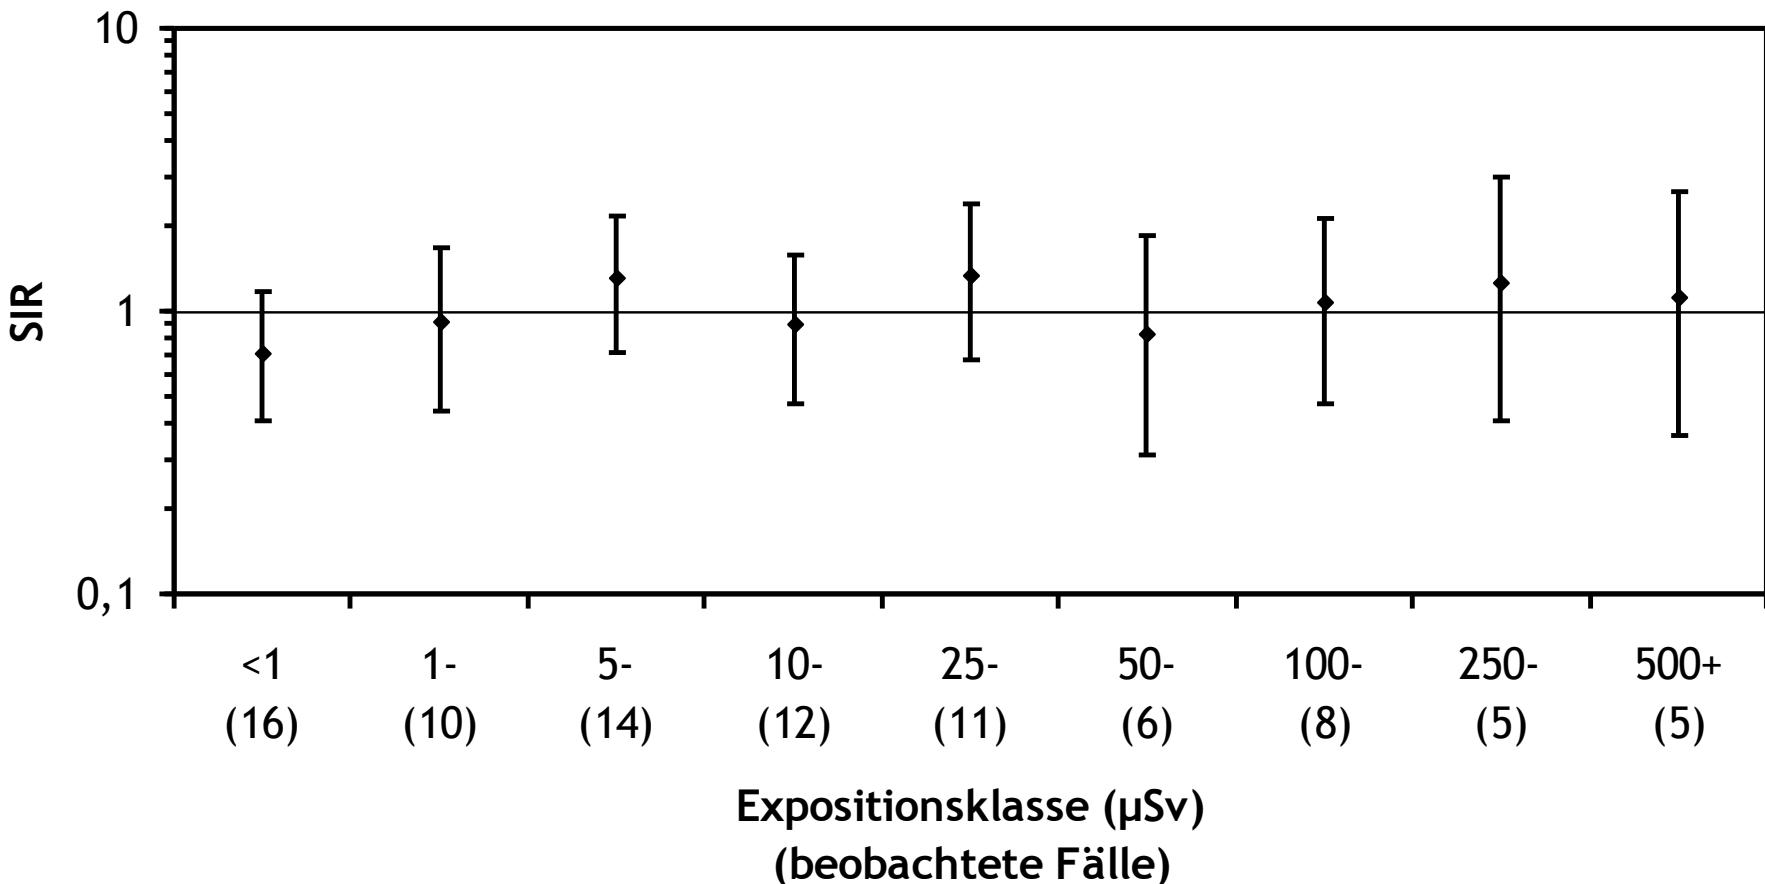
- 1210 Gruppen potentieller Treffer
 - Alle Gruppen wurden geprüft
 - 40 Gruppen telefonisch geklärt
- 25 Non-Matches
- 1185 Matches
 - 1098 Prävalente Krebsfälle = Ausschlüsse
 - 87 Inzidente Krebsfälle im Studienzeitraum
- 9 Weitere, potentielle Krebsfälle in der Kohorte
 - plausible Gründe, warum nicht an das Kinderkrebsregister gemeldet
- Kinderkrebsregister kennt weitere Fälle aus dem DvHK, die nicht in der Radiologie vorgestellt wurden

Ergebnisse der RICC-Studie

Standardisierte Inzidenz-Ratio (SIR)

	O	E	SIR	95%-KI
Geschlecht				
Jungen	52	52,8	0,99	0,74-1,29
Mädchen	35	35,2	1,00	0,69-1,38
Krebs insgesamt	87	88,0	0,99	0,79-1,22
Leukämie	33	30,5	1,08	0,74-1,52
lymphatische Leukämie	24	24,5	0,98	0,63-1,45
akute myeloische Leukämie	5	4,3	1,16	0,38-2,70
Lymphome	13	13,4	0,97	0,52-1,66
ZNS-Tumore	10	19,3	0,52	0,25-0,95
andere Tumore	31	24,8	1,25	0,85-1,77

Dosis-Wirkungs-Beziehung



Fazit

Fazit

- Wichtig
 - Qualität, Qualität, Qualität der Eingangsdaten
 - Bildung von „Match-Gruppen“
 - Nutzung von Zusatzinformationen im Clerical Review
- Der Abgleich von Kohorten mit Krebsregistern
 - ist machbar
 - kann dem Register nützen
 - Kontrollnummern statt Klartext kein Hinderungsgrund

Der PID-Generator der TMF

TMF-Workshop „Tools zum ID-Management in der klinischen Forschung“

Berlin, 24. September 2010

Prof. Dr. Klaus Pommerening, Dr. Murat Sariyar

Universitätsmedizin Mainz, IMBEI

KN Pädiatrische Onkologie und Hämatologie

TMF-AG Datenschutz



UNIVERSITÄTS **medizin.**
MAINZ

