Privacy vs. Analytics

Smals
ICT for society

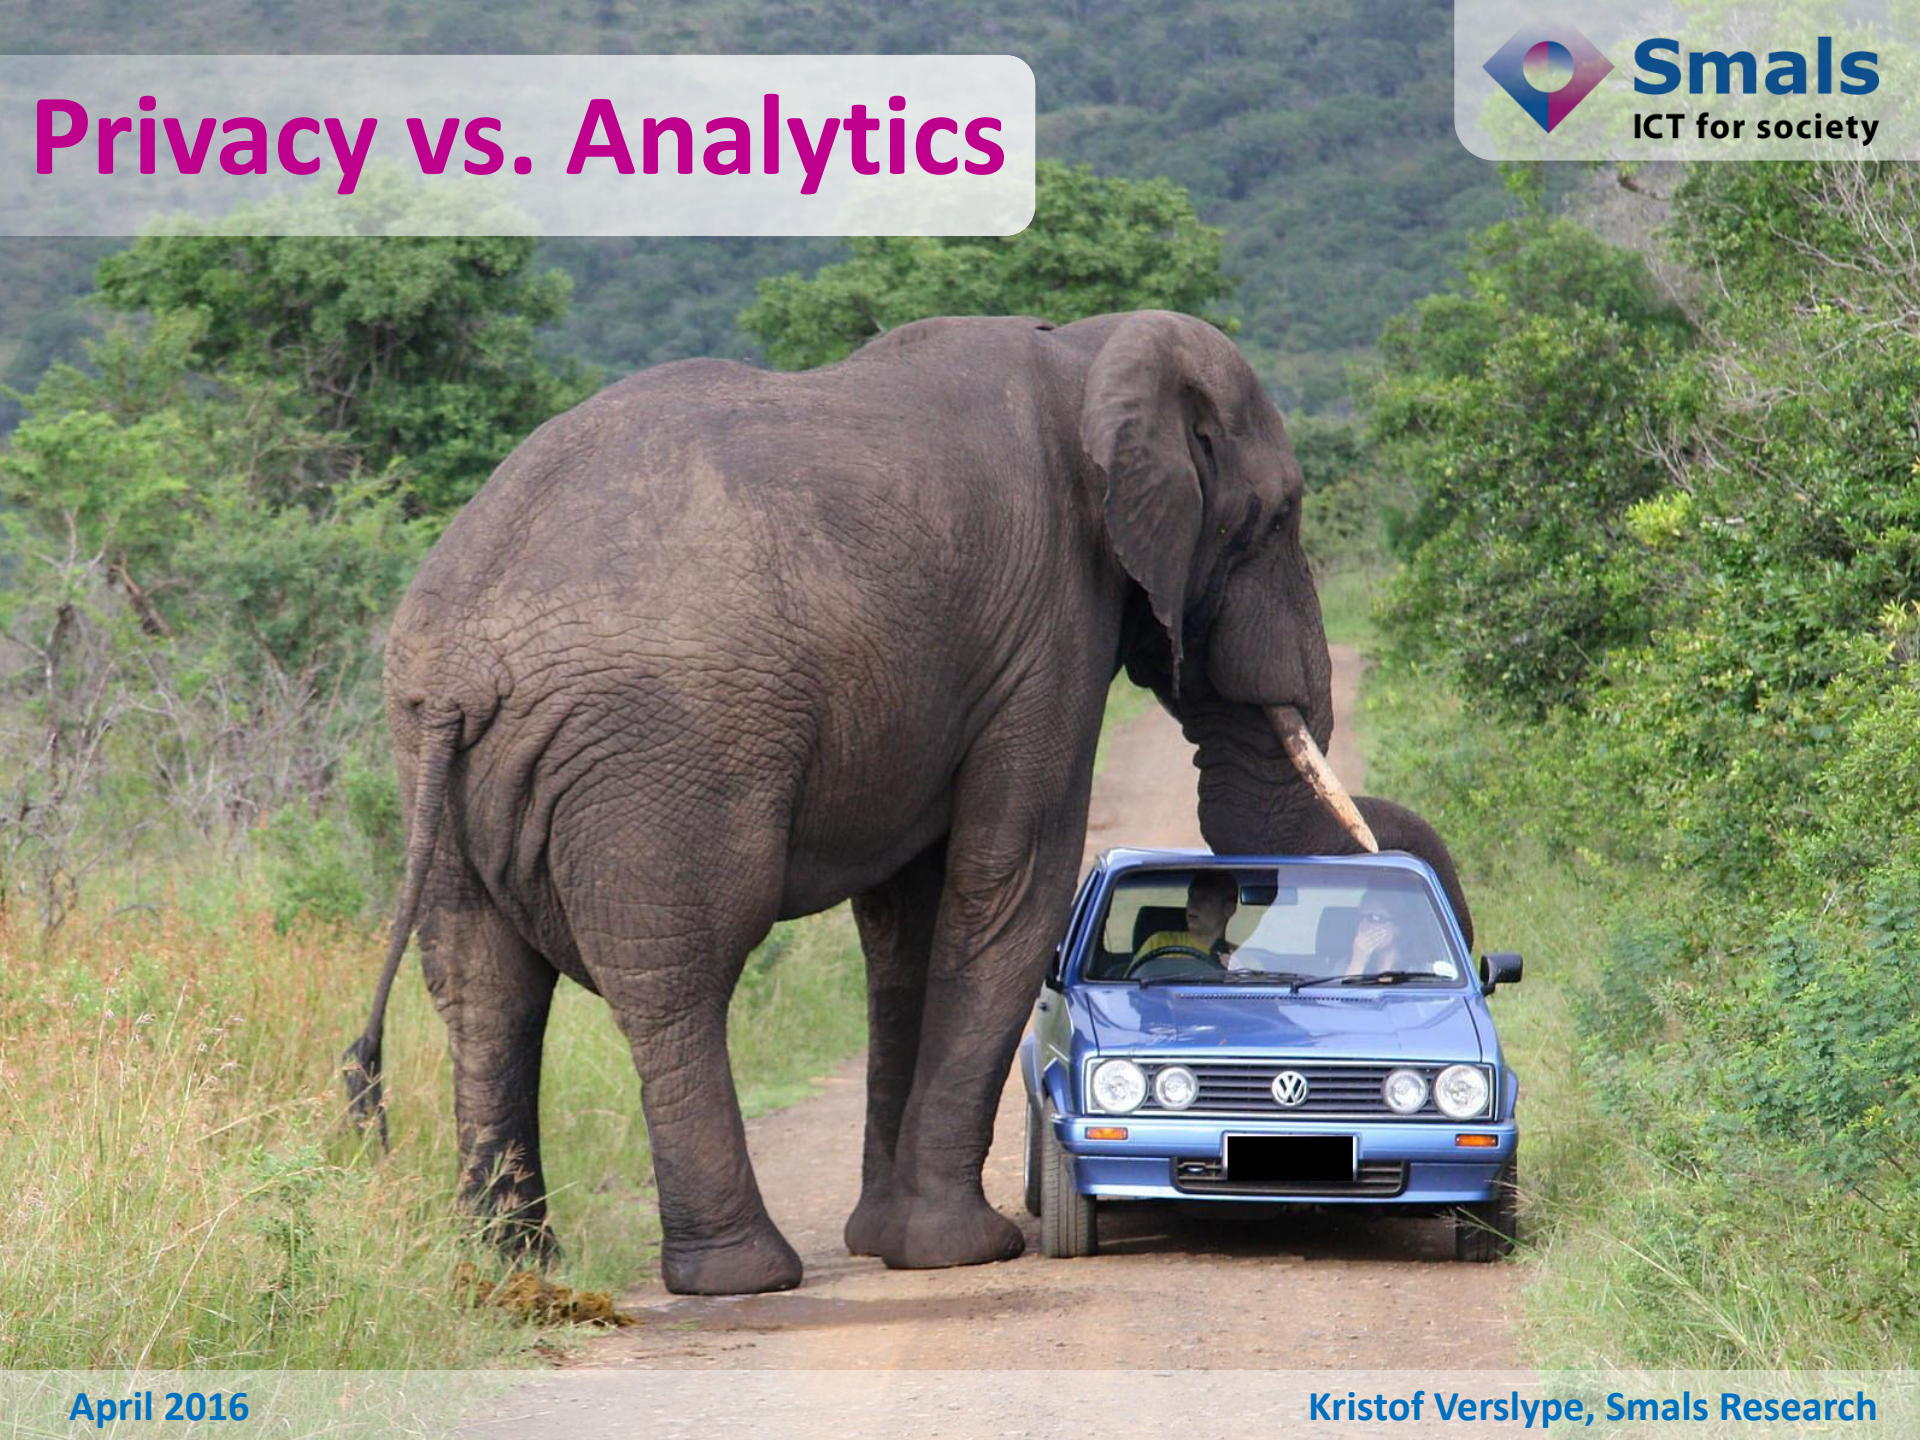

April 2016

Kristof Verslype, Smals Research

Data Explosie

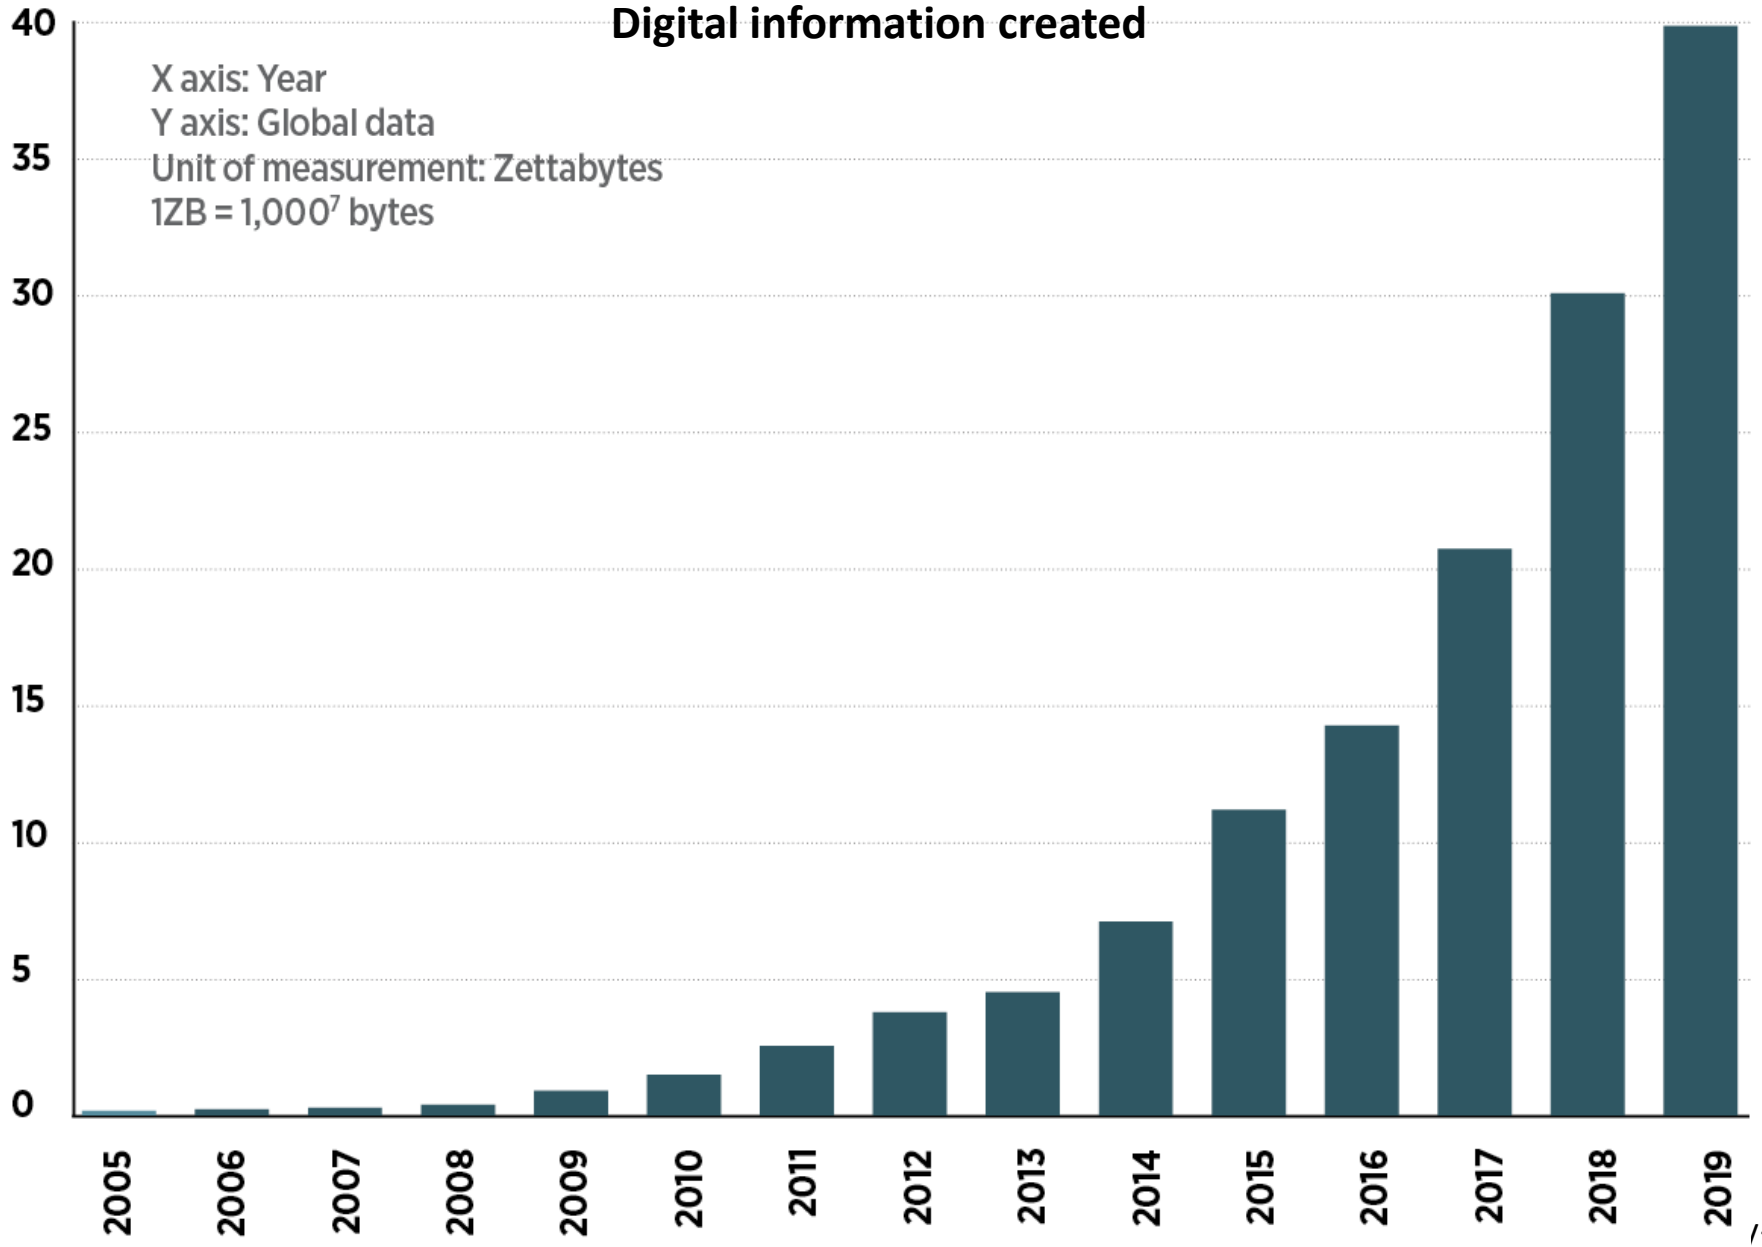

Data Explosie

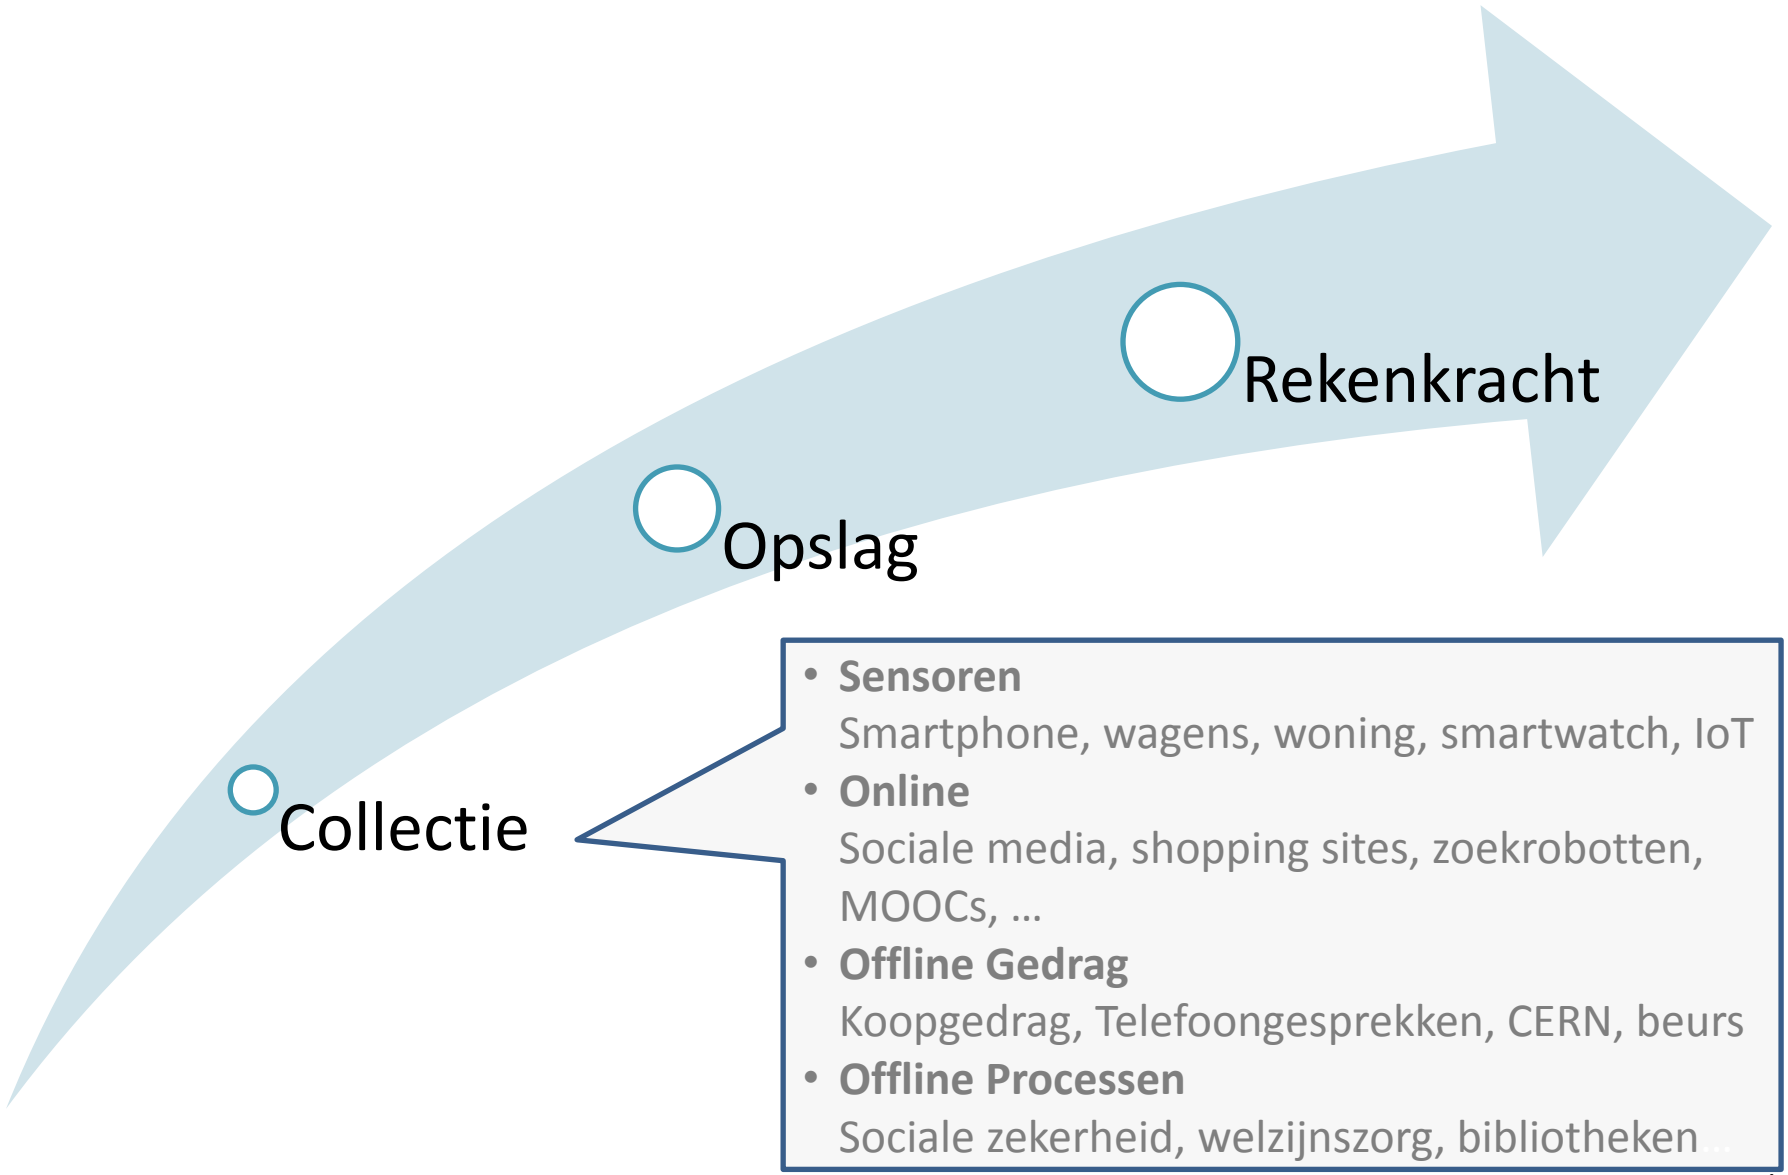

Data Explosie

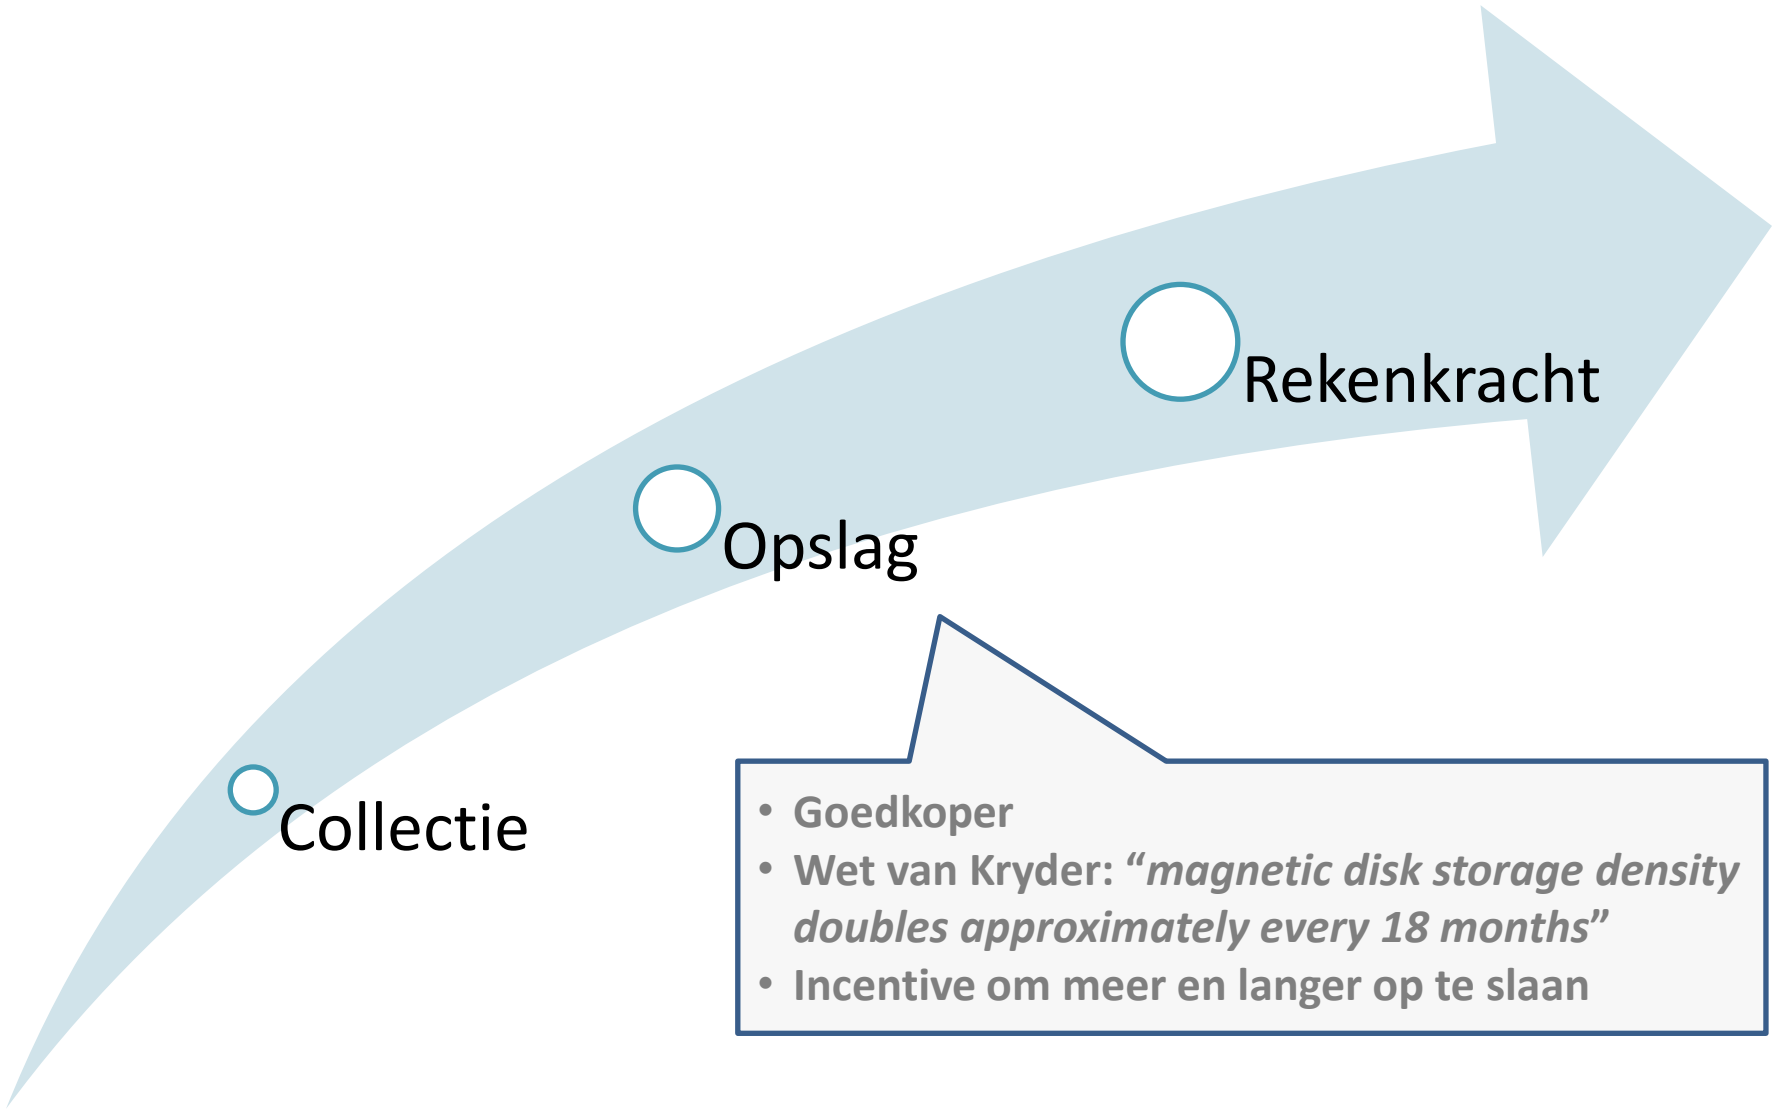

Data Explosie

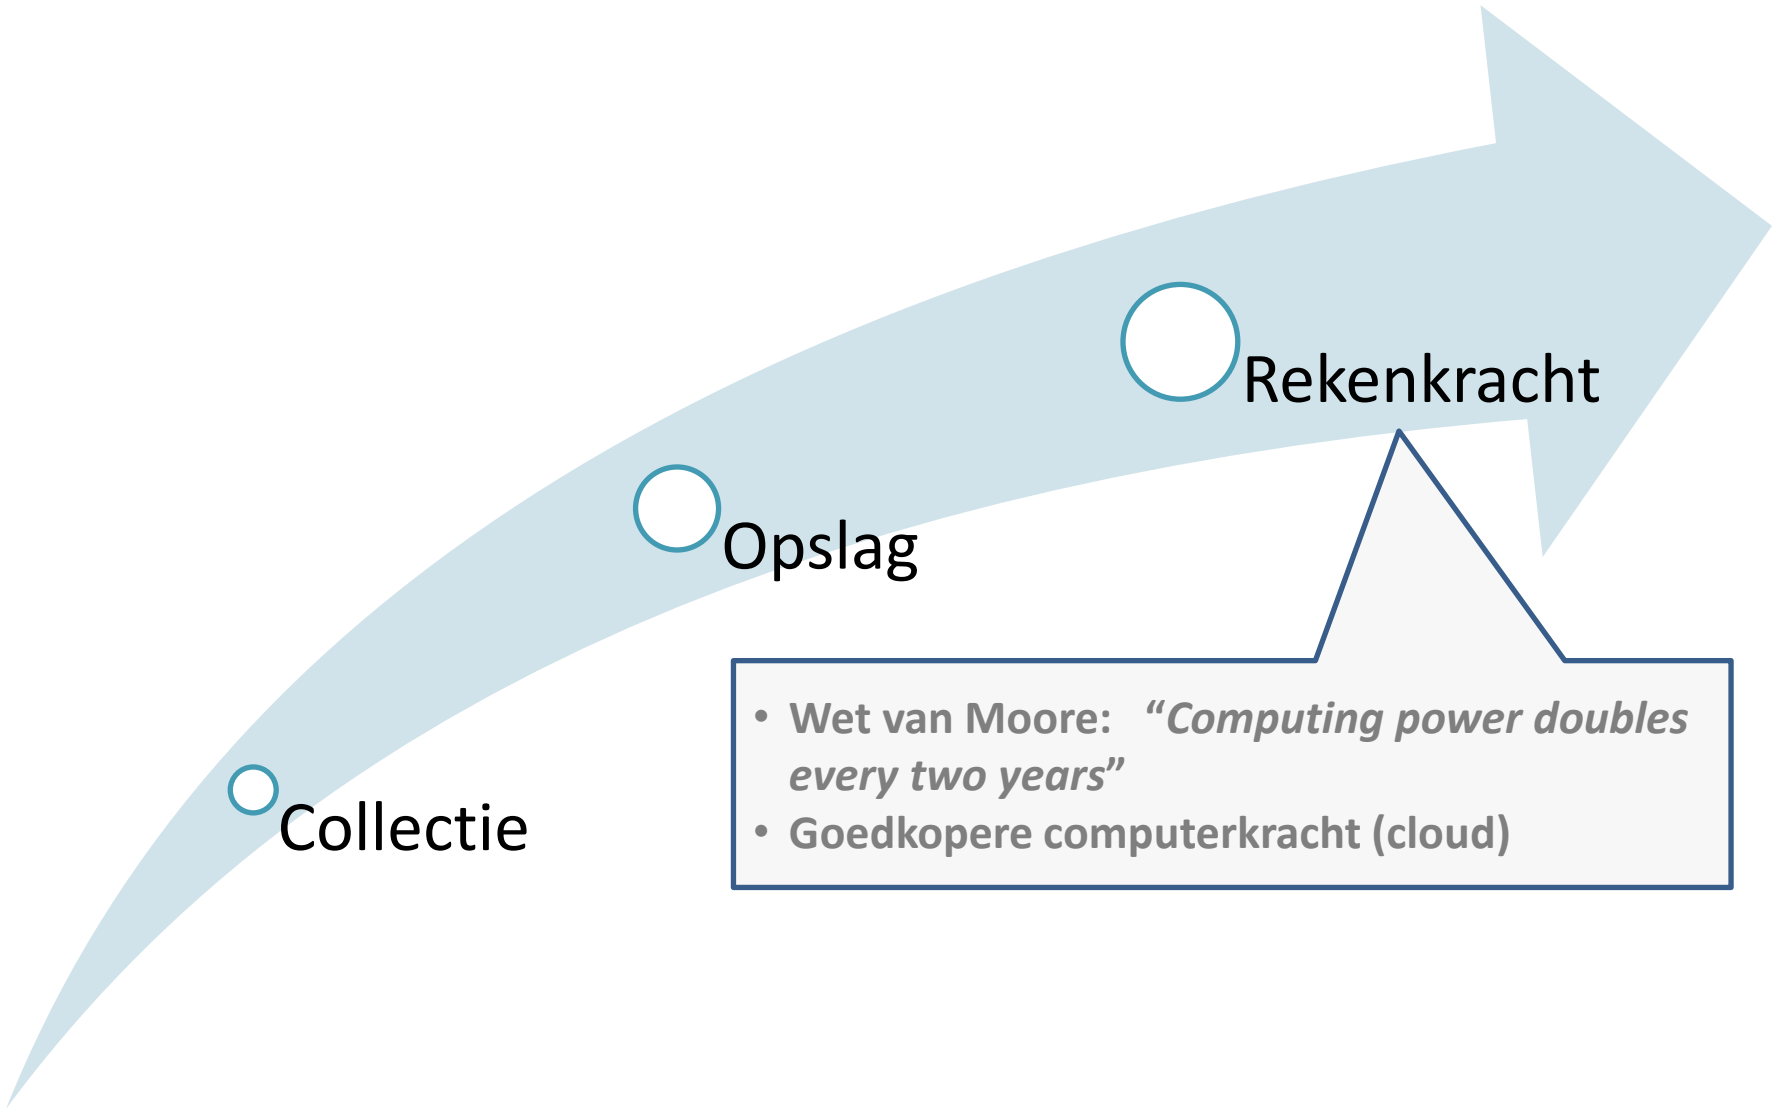

Analytics

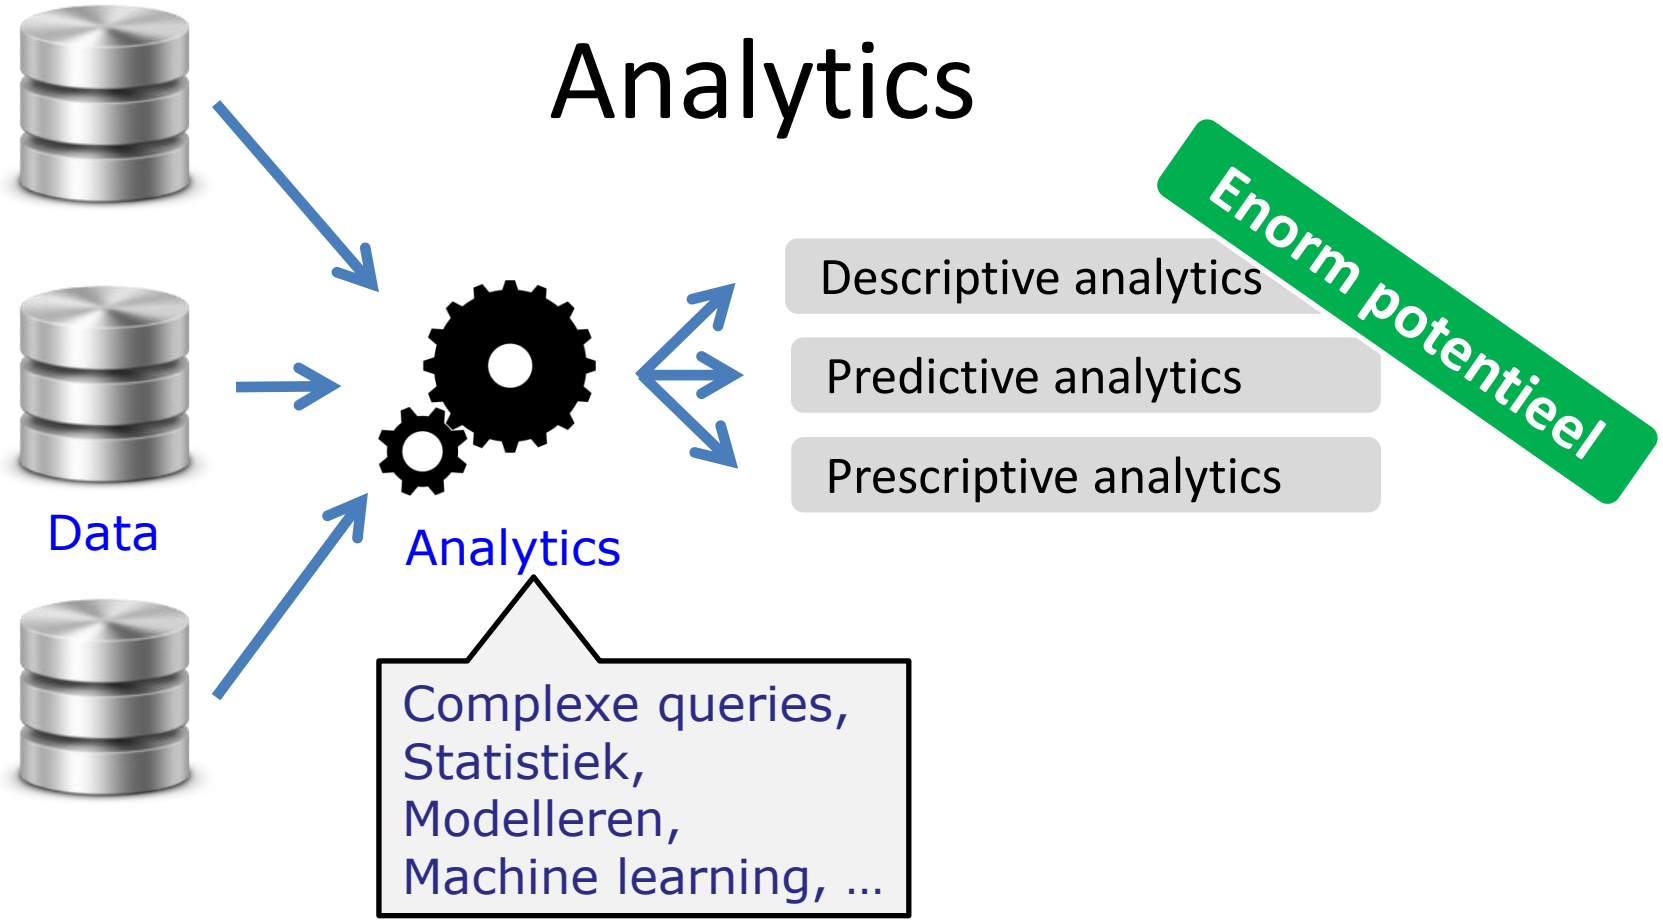

Fraudedetectie

Wetenschappelijk onderzoek

Medische analyses

Beleids-ondersteuning

Rechten / premies burger

…

In geval van persoonsgegevens is er…

De privacywet

(aka Wet tot bescherming van de persoonlijke levensfeer
ten opzichte van de verwerking van persoonsgegevens (8/12/1992)

[B92]

Privacywet

Anonieme gegevens
Onidentificeerbaar

Persoonsgegevens
Identificeerbaar/
Geïdentificeerd

Privacywet niet van toepassing

- Finaliteit
- Proportionaliteit
- Transparantie
- Information security practices
- Recht toegang & correctie
- Expliciete toelating
- Data kwaliteit

Waarschijnlijkheid op identificatie

Privacywet

Anonieme gegevens
Onidentificeerbaar

Persoonsgegevens
Identificeerbaar/
Geïdentificeerd

Recht toegang & correctie

Expliciete toelating

Finaliteit

Transparantie

practices

Data kwaliteit

Identificeerbaar:
- Direct: identificatienummer
  vb. INSZ-nummer
- Indirect: a.d.h.v. één of meer specifieke elementen die kenmerkend zijn
  vb. geslacht, postcode en geboortedatum

Waarschijnlijkheid op identificatie

Kruisen van Persoonsgegevens

Een fictief voorbeeld

Een onderzoeksteam wil medische, financiële en demografische persoonsgegevens analyseren van alle burgers die na 1990 geboren zijn, die zelfstandige in bijberoep zijn met een loon van minstens € 50 000.

Deze gegevens worden echter beheerd door verschillende overheidsbedrijven en moeten dus gekruist worden.

Kan technologie steeds persoonsgegevens converteren naar anonieme gegevens die vervolgens geanalyseerd kunnen worden?

Nee ☹

Wat is er technisch mogelijk binnen het wettelijke kader?

AGENDA

- Introductie
- Technieken Anonimisatie
  - Wat
  - Beperkingen
- Data Archipel
  - Concept

  - Proof of concept
  - Een beetje crypto
  - Deanonimisatie
  - Sleutelbeheer
  - Transparantie
  - Small cells
- Conclusies

Anonimisatie-technieken

Smals
ICT for society

Anonimisatietechnieken

Transformeren van persoonsgegevens zodat identificatie moeilijker wordt

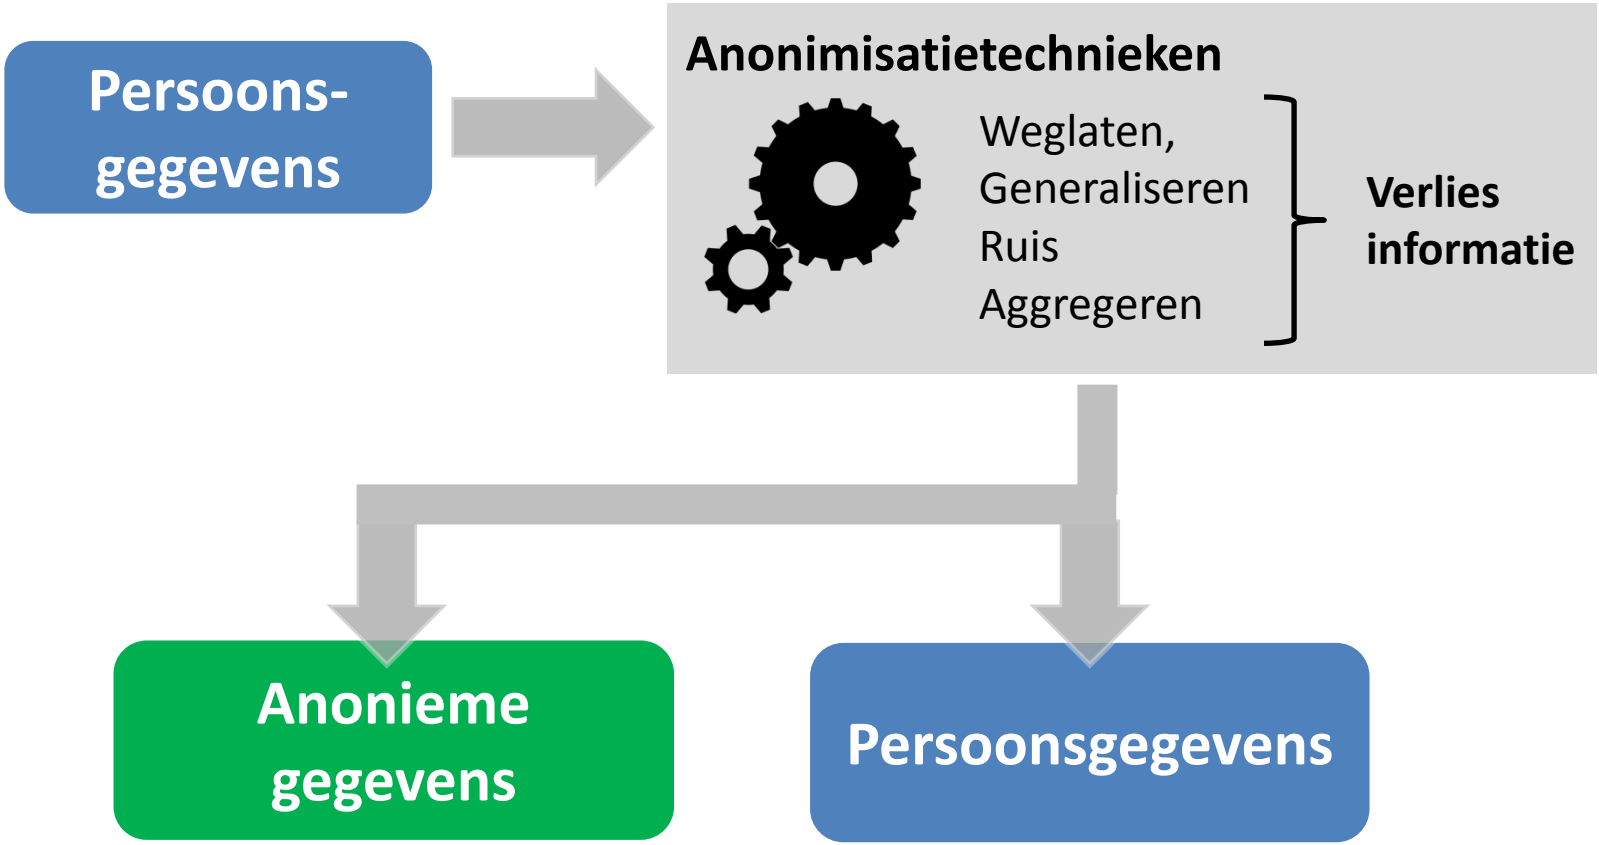

Toepassen anonimisatietechnieken ⇏ juridisch anonieme gegevens

Verwijderen IDs

Naam	RRN	DoB	Sex	ZIP	Problem
Kristof Verslype	84052010955	20/05/1984	M	3211	Antisocial personality disorder
Jan Vandesmals	76011320675	13/01/1976	M	9300	Schizofrenie
Paola Ruffo di Calabria	37091100247	11/09/1937	F	1060	Perfect gezond
Dick Tatuur	50111221385	12/11/1950	M	4000	Megalomanie

Naam	RRN	DoB	Sex	ZIP	Problem
[redacted]	[redacted]	20/05/1984	M	3211	Antisocial personality disorder
[redacted]	[redacted]	13/01/1976	M	9300	Schizofrenie
[redacted]	[redacted]	11/09/1937	F	1060	Perfect gezond
[redacted]	[redacted]	12/11/1950	M	4000	Megalomanie

Coderen IDs

RRN	Code
84052010955	X38LS45
76011320675	X38DI56
37091100247	X38XD12
50111221385	X38MP68

Naam	RRN	DoB	Sex	Z	
Kristof Verslype	84052010955	20/05/1984	M	3211	Antisocial personality disorder
Jan Vandesmals	76011320675	13/01/1976	M	9300	Schizofrenie
Paola Ruffo di Calabria	37091100247	11/09/1937	F	1060	Perfect gezond
Dick Tatuur	50111221385	12/11/1950	M	4000	Megalomanie

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		20/05/1984	M	3211	Antisocial personality disorder
X38DI56		13/01/1976	M	9300	Schizofrenie
X38XD12		11/09/1937	F	1060	Perfect gezond
X38MP68		12/11/1950	M	4000	Megalomanie

Codage mogelijk

Verwijderen Quasi IDs

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		20/05/1984	M	3211	Antisocial personality disorder
X38DI56		13/01/1976	M	9300	Schizofrenie
X38XD12		11/09/1937	F	1060	Perfect gezond
X38MP68		12/11/1950	M	4000	Megalomanie

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		[redacted]	M	3211	Antisocial personality disorder
X38DI56		[redacted]	M	9300	Schizofrenie
X38XD12		[redacted]	F	1060	Perfect gezond
X38MP68		[redacted]	M	4000	Megalomanie

Vervagen

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		20/05/1984	M	3211	Antisocial personality disorder
X38DI56		13/01/1976	M	9300	Schizofrenie
X38XD12		11/09/1937	F	1060	Perfect gezond
X38MP68		12/11/1950	M	4000	Megalomanie

Naam	RRN	Age	Sex	Loc	Problem
X38LS45		32	M	Vl-B	Antisocial personality disorder
X38DI56		39	M	O-Vl	Schizofrenie
X38XD12		77	F	BXL	Perfect gezond
X38MP68		64	M	LUIK	Megalomanie

Ruis toevoegen

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		20/05/1984	M	3211	Antisocial personality disorder
X38DI56		13/01/1976	M	9300	Schizofrenie
X38XD12		11/09/1937	F	1060	Perfect gezond
X38MP68		12/11/1950	M	4000	Megalomanie

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		07/07/1984	M	3211	Antisocial personality disorder
X38DI56		28/12/1975	M	9300	Schizofrenie
X38XD12		29/09/1937	F	1060	Perfect gezond
X38MP68		07/12/1950	M	4000	Megalomanie

Aggregeren

Naam	RRN	DoB	Sex	ZIP	Problem
X38LS45		20/05/1984	M	3211	Antisocial personality disorder
X38DI56		13/01/1976	M	9300	Schizofrenie
X38XD12		11/09/1937	F	1060	Perfect gezond
X38MP68		12/11/1950	M	4000	Megalomanie

DoB	Sex	ZIP	Problem
≥ 1970	…	…	Antisocial personality disorder, Schizofrenie
< 1970	…	…	Megalomanie, Perfect gezond

k-anonymity

SSN	Race	BirthDate	Gender	ZIP	Problem
021-57-1445	black	9/20/1965	male	02141	short of breath
021-77-8034	black	2/14/1965	male	02141	chest pain
107-21-0876	black	10/23/1965	female	02138	painful eye
021-37-1573	black	8/24/1965	female	02138	wheezing
021-54-4229	black	11/7/1964	female	02138	obesity
117-26-3042	black	12/1/1964	female	02138	chest pain
127-91-4819	white	10/23/1964	male	02138	short of breath
270-89-1234	white	3/15/1965	female	02139	hypertension
021-45-7854	white	8/13/1964	male	02139	obesity
021-08-2839	white	5/5/1964	male	02139	fever
117-61-0504	white	2/13/1967	male	02138	vomiting
021-668-9440	white	3/21/1967	male	02138	back pain

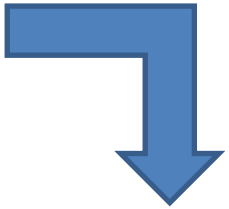

Race	BirthDate	Gender	ZIP	Problem
black	1965	male	02141	short of breath
black	1965	male	02141	chest pain
person	1965	female	0213*	painful eye
person	1965	female	0213*	wheezing
black	1964	female	02138	obesity
black	1964	female	02138	chest pain
white	1964	male	0213*	short of breath
person	1965	female	0213*	hypertension
white	1964	male	0213*	obesity
white	1964	male	0213*	fever
white	1967	male	02138	vomiting
white	1967	male	02138	back pain

Hogere k-waarde =>
meer privacy en
meer verlies van data

Geavanceerdere aanpakken

- l-diversity
- t-closeness

[L02]

Anonimisatietechnieken

De werkelijkheid is iets complexer…

Gefaalde anonimisatie

- 2006: publicatie 20 miljoen geanonimiseerde zoekopdrachten (650.000 users, 3 maand).
- The New York Times achterhaalde identiteit van meerdere gebruikers
- Ontslag CTO, #57 in CNNs "*101 Dumbest Moments in Business*"

- 2007: Publicatie geanonimiseerde records met filmratings 500.000 gebruikers
- Identificatie gebruikers in combinatie met publieke IMDB data
- Voor de rechter door gebruikers

[AV07], (NYT06, CNN07)

Paul Ohm

Broken Promises of Privacy

"De robuuste anonimisatie-veronderstelling is niet fundamenteel foutief, maar wel diep gebrekkig."

"We kunnen niet voorspellen tot welke en tot hoeveel externe informatie de aanvaller toegang heeft"

"Persoonsgegevens zijn een steeds groeiende categorie. Tien jaar terug beschouwde bijna niemand filmbeoordelingen als persoonsgegevens."

"Het aanwasprobleem: Eénmaal een aanvaller twee 'geanonimiseerde' databases aan elkaar gelinkt heeft, kan er makkelijker andere informatie aan gelinkt worden, wat kan helpen bij deanonimisatie."

[O09]

Whitehouse.org

"Anonimisatie van een data record lijkt misschien makkelijk te implementeren. Helaas is het steeds makkelijker om anonimisatie teniet te doen met behulp van de technieken die ontwikkeld worden voor legitieme toepassingen van big data."

"Sommige oudere technologieën, zoals anonimisatietechieken, hebben maar een beperkt toekomstig potentieel, hoewel ze in het verleden wel waardevol waren."

[PCAST14]

In de pers…

datanews TECHNOLOGY BEST PRACTICE BUSINESS

Nieuws van 23 maart 2015

Ik ben bezorgd om security en privacy. En dat is waarom ik mezelf niet langer moet wijsmaken dat ik tot Generation Y behoor.

— Kristof Van der Stadt

Anonimiteit bij big data-analyse een illusie

02/02/15 om 11:19 - Bijgewerkt om 12:46
Bron: Datanews

Big data waar persoonsgegevens uit verwijderd zijn, lijken de privacy te waarborgen. Maar er is maar weinig nodig om persoonlijke gegevens weer aan de persoon te koppelen, blijkt uit onderzoek.

53
KEER GEDEELD

(DN15)

Verenigd Koninkrijk

Uitgebreide documentatie

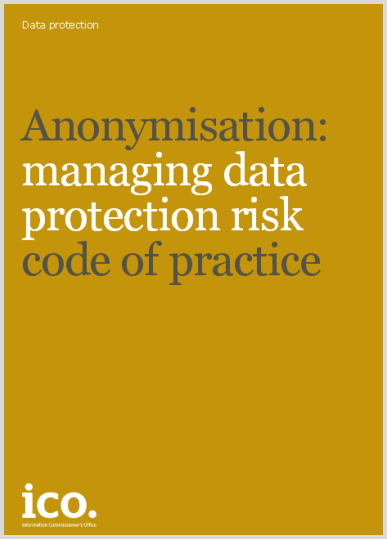

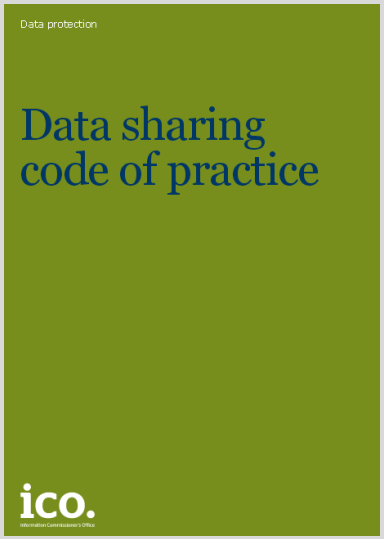

UK Anonymisation Network (UKAN)

"Het is opgezet als een middel om best practices in anonimisatie toe te passen. Het biedt praktisch advies en en informatie."

UKAN
UK ANONYMISATION NETWORK

http://ukanon.net/

[I11, I12, I14], *(UKANON)*

Verenigd Koninkrijk

"Big data is geen spel dat met andere regels gespeeld wordt."

*"Anonimisatie stelt organisaties in staat om **zekerheid** te geven aan de personen over wie het data verzamelde; [zekerheid] dat voor big data analyse geen data gebruikt wordt die hen kan identificeren."*

*"De reeks beschikbare data sets en de kracht van big data analytics maken anonimisatie moeilijker [..] maar **dit betekent niet dat anonimisatie onmogelijk is of dat het geen effectieve tool is**."*

[I14]

Ann Cavoukian

Big Data and Innovation, Setting the Record Straight: De-identification Does work

"Er is een neiging bij een deel van de commentatoren om de bevindingen te overdrijven."

"Er duikt literatuur op die de nauwkeurigheid en legitimiteit van gepubliceerde re-identificatieaanvallen in vraag stelt "

"Organisaties moeten een risicobeoordling doen, die rekening houdt met de huidige state of the art in de-identificatie technieken en re-identificatie aanvallen."

[C14]

DOSSIER ARCHIEF

Google loopt deur plat bij Witte Huis

26-03-15, 07.06u - VK

LEES LATER

President Obama en vicepresident Joe Biden nodigden in 2013 de toplui van Amerika's belangrijkste technologiebedrijven uit. ©GETTY 1

(DM15)

No

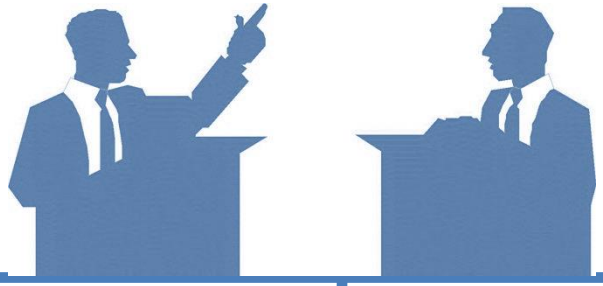

Yes

Wie heeft gelijk?

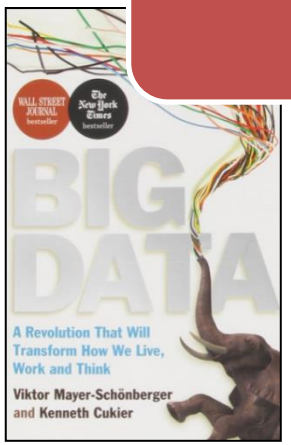

Mayer-Schonberger
Cukier

Populaire pers

Ann Cavoukian

PRINCETON UNIVERSITY

[MSC13,C14,I14,PCAST14], (DN15)

Beperkingen technieken anonimisatie

Onderbouwing

Impliciete: close-world assumption
Aanvaller geen toegang tot externe data

Wat weet aanvaller?
- Data
- Algoritmes
- Vandaag, morgen, overmorgen, …

Toevertrouwen aan derden / publiceren “geanonimiseerde” data kan riskant zijn

Wat weet de aanvaller?

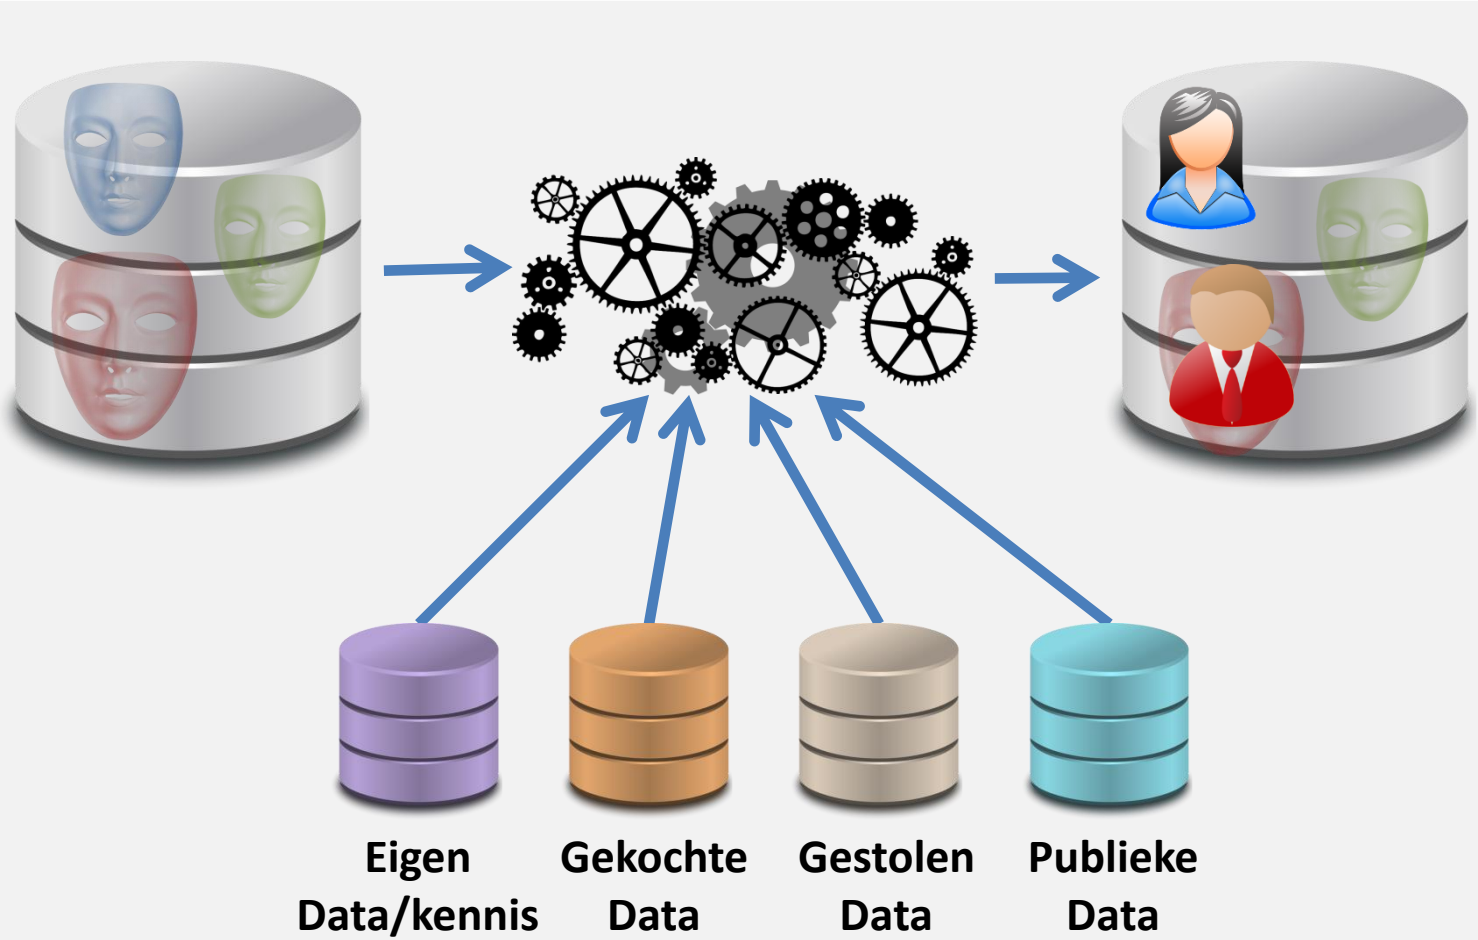

P(Deanonimisatie) ↗

Aanvallen

Large-scale

- Deanonimiseer zo veel mogelijk
- Vb. Hackers

Targetted

- Identificeer gericht specifiek individu
- Vb. Politieke concurrent

Opportunistisch

- Identificeer een gekende (kennis, bekende)
- Vb. Nieuwsgierige buur

[NF14]

Hoogdimensionale data

Eéndimensionale data
Uit te drukken in één getal (Dimensie)
Vb. Postcode, geboortedatum, geslacht, salaris, lengte, BMI, …

Hoogdimensionale data
Enkel uit te drukken met een groot (vaak stijgend) aantal getallen
Vb. location tracking, friendship graph, aankoopgedrag, …

Hoogdimensionale data

Locatie tracking

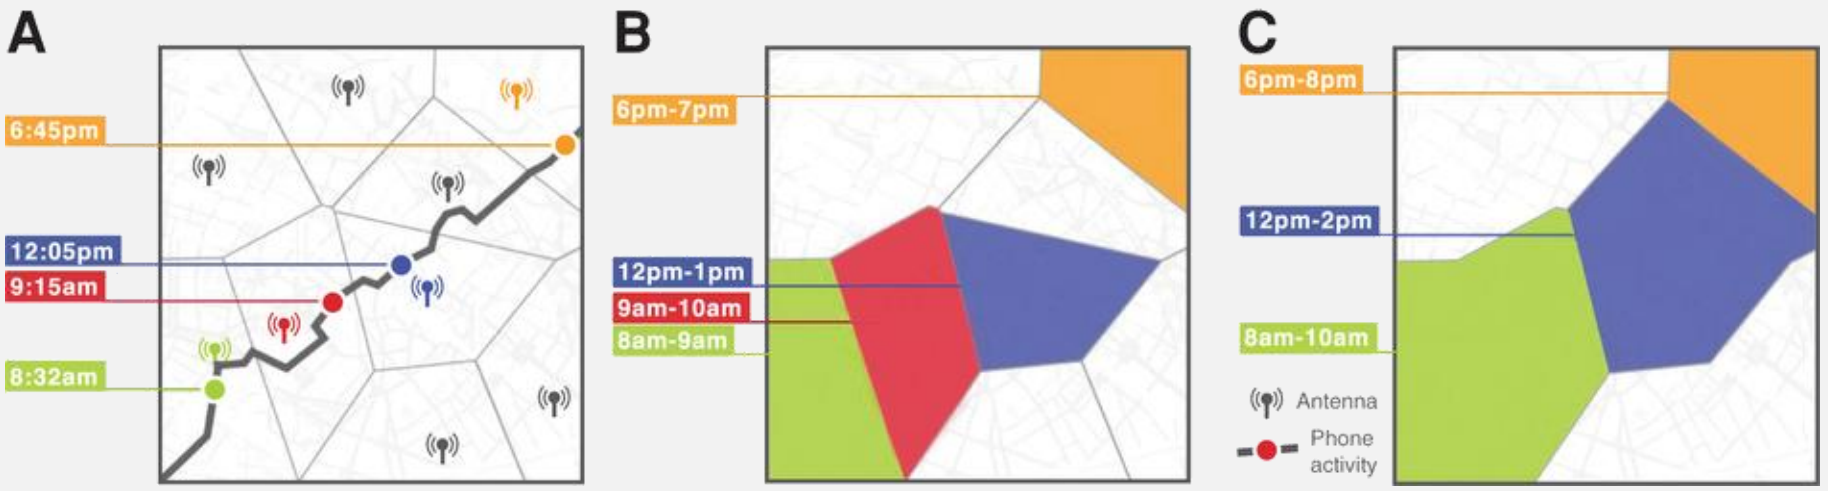

Vervagen data (tijd, locatie) heeft weinig impact op uniekheid [M13]
Maar maakt dat wel veel minder bruikbaar

Aankoopgedrag
4 x locatie-dag: uniek voor 90% kopers
Vrij weinig informatie al uniek

[M13, S15]

Hoogdimensionale data

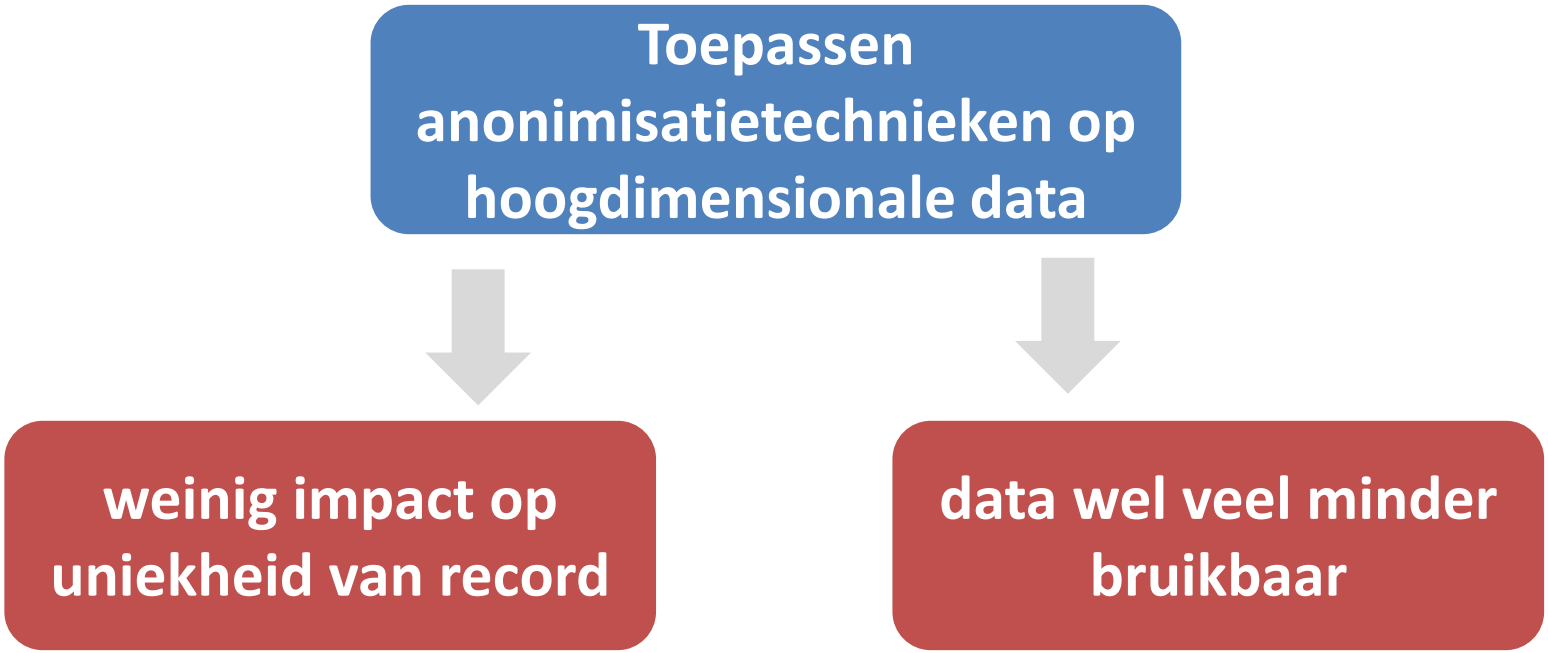

Hoogdimensionale data

Type	Voorbeeld	Dimensies
Sociale netwerken 	Gemiddeld 100 vrienden op facebook	100
Reviews 	Gemiddelde Netflix gebruiker in dataset: 213 ratings	426 (tijd+rating)
Locatie tracking 	Elke 2 uur locatie + tijd	720 per maand
Aankoop-gedrag 	4 keer per maand 20 producten aankopen	160 per maand
Surfgedrag	…	…
Medisch dossier	…	…
Genetische data	…	1.000.000
…	…	…

[NF14]

Uniek

≠

Linkbaar aan individu

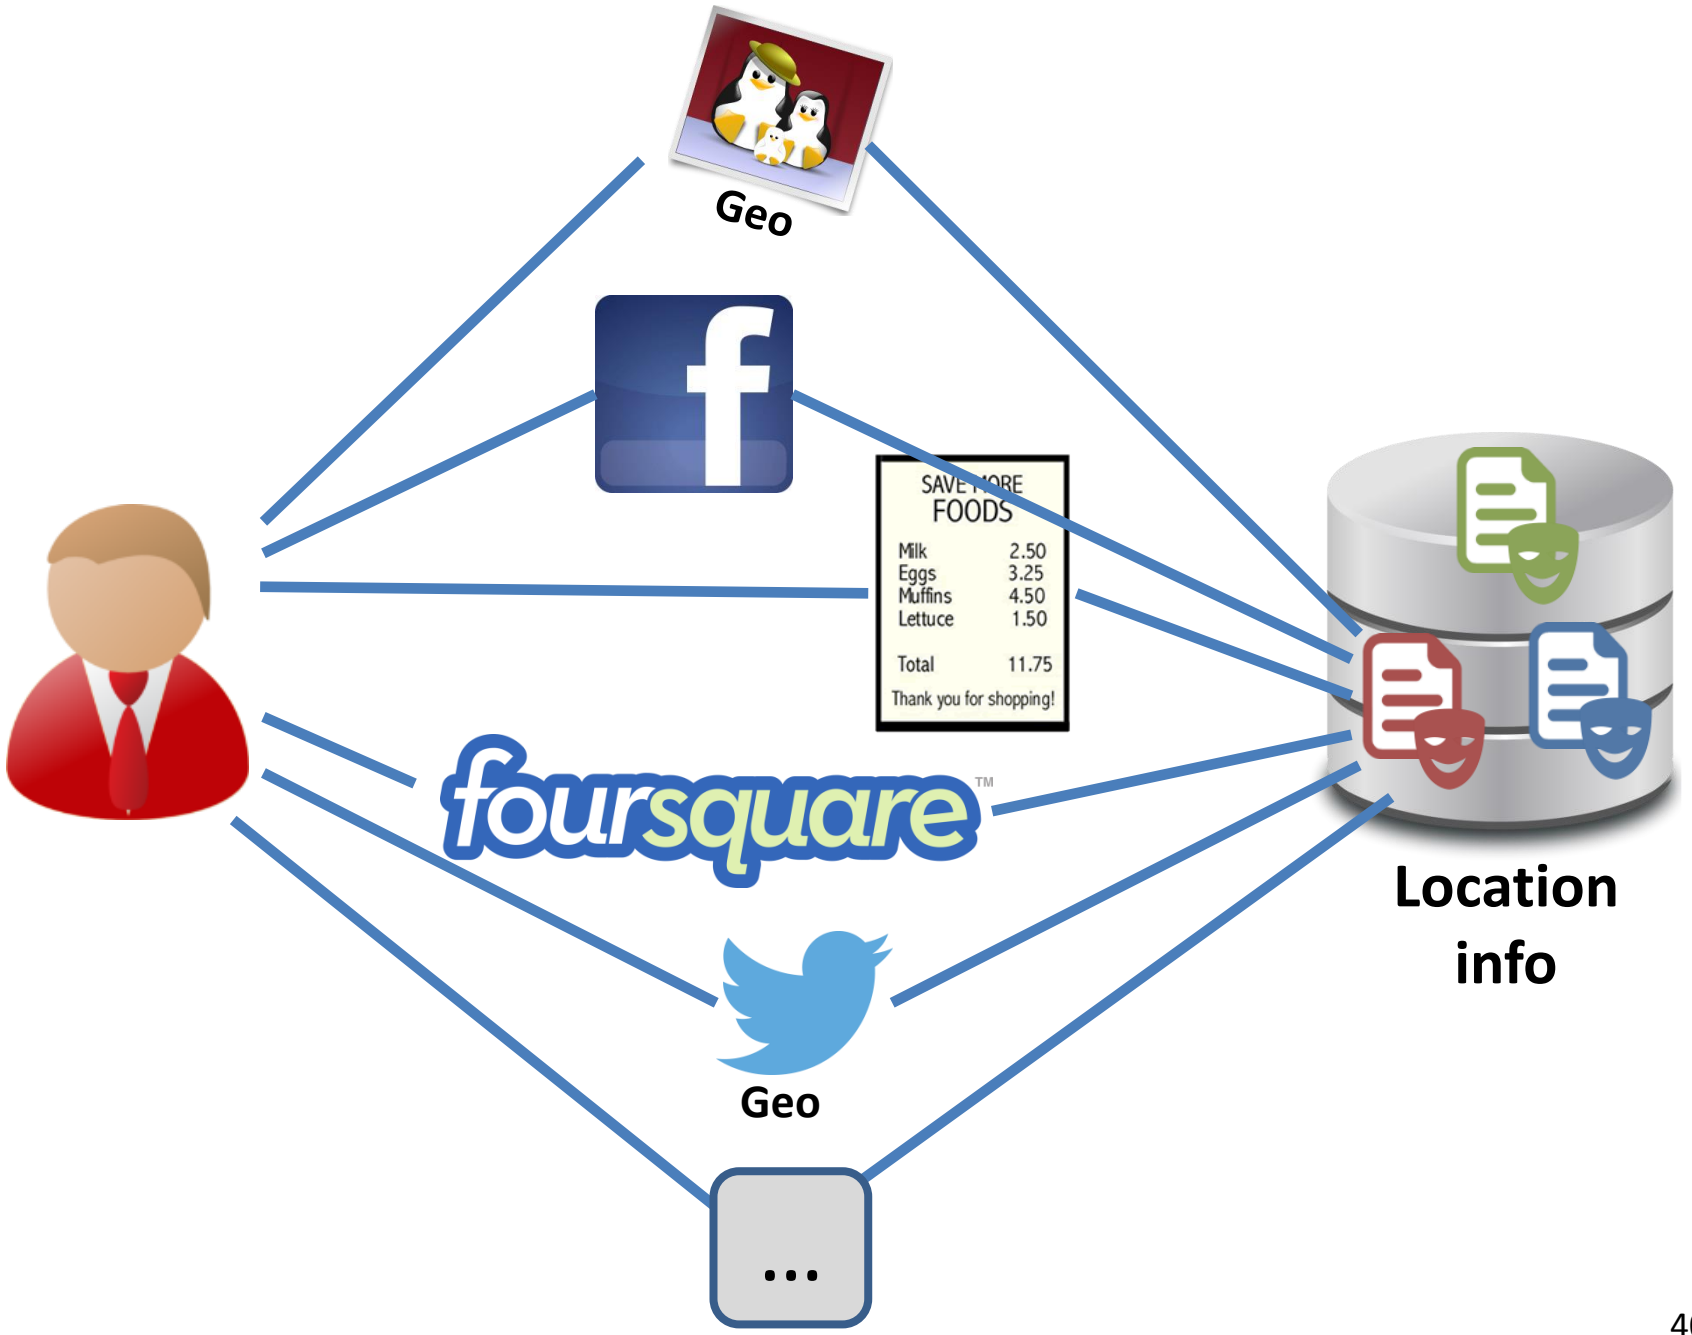
Geo
SAVE MORE
FOODS
Milk 2.50
Eggs 3.25
Muffins 4.50
Lettuce 1.50
Total 11.75
Thank you for shopping!
foursquare
Location info
Geo
...

[S15]

Ann Cavoukian

Big Data and Innovation, Setting the Record Straight: De-identification Does work

"In het geval van hoogdimensionale data kunnen bijkomende regelingen nagestreefd worden, zoals het ter beschikking stellen van de data aan onderzoekers onder strikte voorwaarden."

Slechts één zin in haar tekst…
(waarin ze toegeeft dat deanonimisatietechnieken niet steeds werken)

[C14]

Hoogdimensionale data

De norm in big data

Balans privacy en nut uit evenwicht in anonimisatie-paradigma

We kunnen data niet en juridisch geanonimiseerd maken en tegelijkertijd waardevol houden voor analytics doeleinden

(Wel nog potentieel in meer klassieke context)

Conclusie

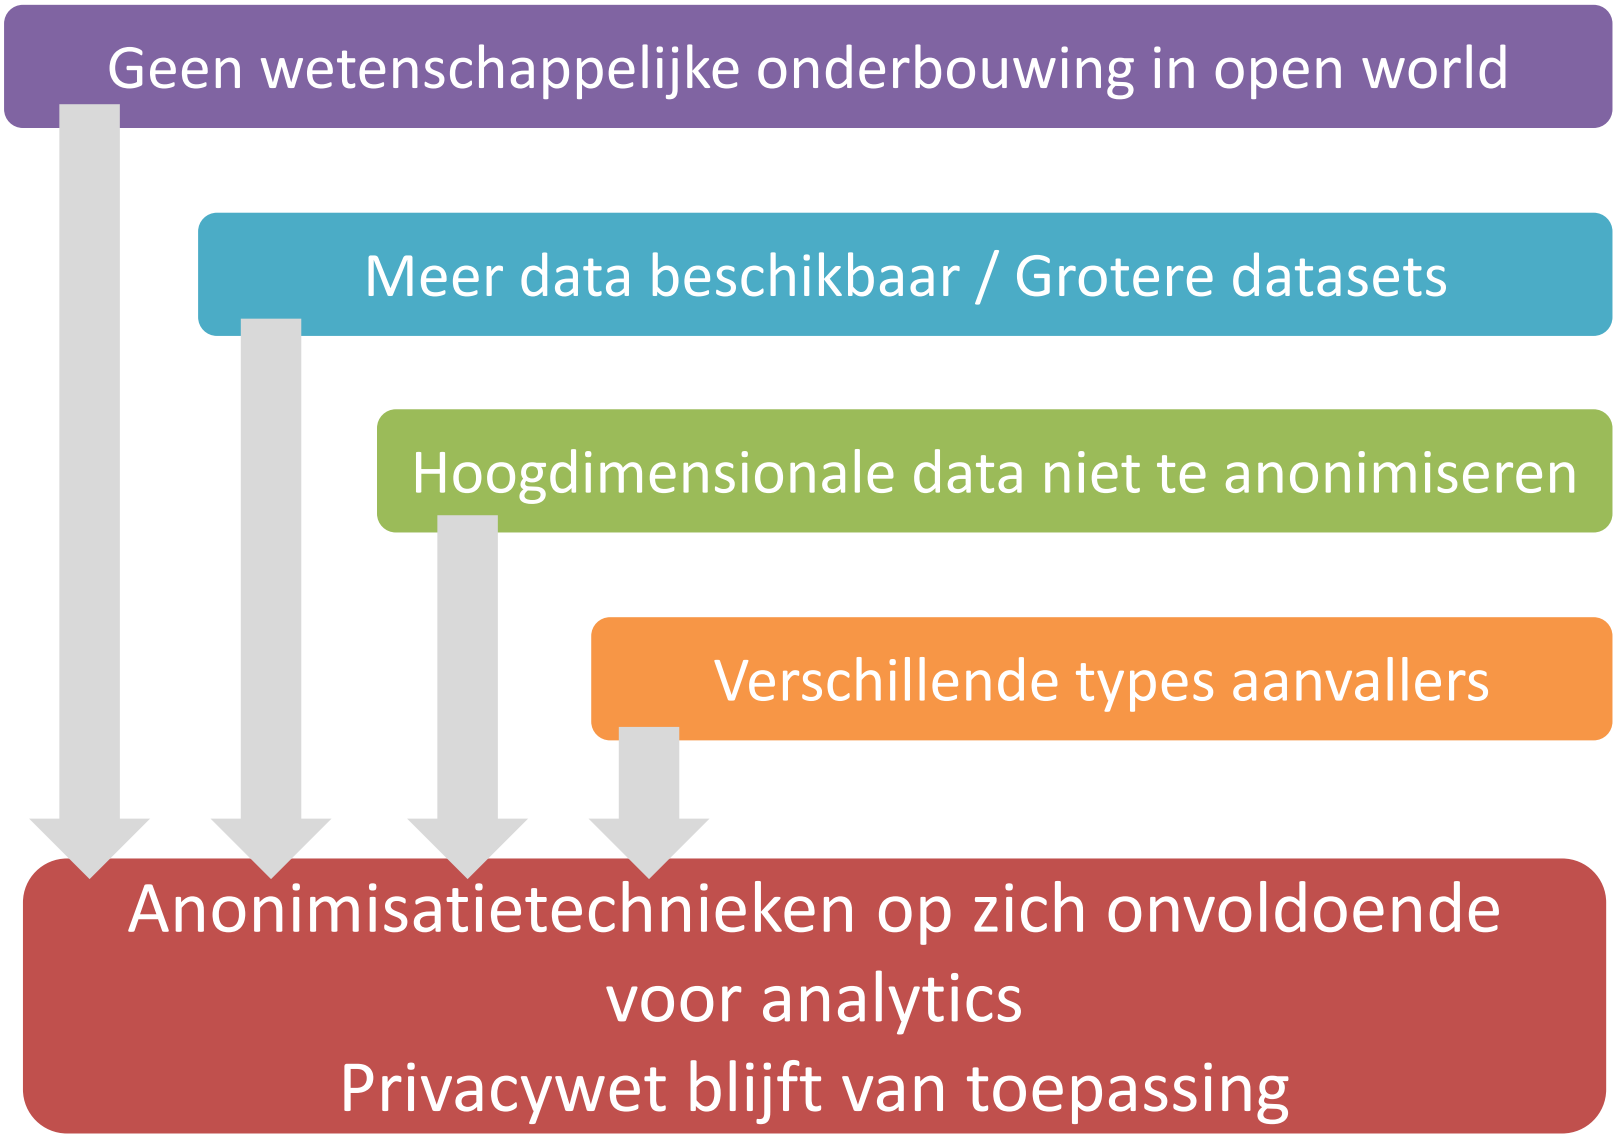

[NF14]

Kruisen van Persoonsgegevens

Een fictief voorbeeld

Een onderzoeksteam wil medische, financiële en demografische persoonsgegevens analyseren van alle burgers die na 1990 geboren zijn, die zelfstandige in bijberoep zijn met een loon van minstens € 50 000.

Deze gegevens worden echter beheerd door verschillende overheidsbedrijven en moeten dus gekruist worden.

Kan technologie steeds persoonsgegevens converteren naar anonieme gegevens die vervolgens geanalyseerd kunnen worden?

Nee ☹

Wat is er technisch mogelijk binnen het wettelijke kader?

AGENDA

Introductie

Technieken Anonimisatie

- Wat
- Beperkingen

Data Archipel

- Concept

- Proof of concept
- Een beetje crypto
- Deanonimisatie
- Sleutelbeheer
- Transparantie
- Small cells

Conclusies

Data Archipel

© Smals Research

Smals
ICT for society

Concept › POC › Crypto › Deanonimisatie › Sleutelbeheer › Transparantie › Small cells

Valida

COSIC, KU Leuve

- Technische validatie
- *"Zit conceptueel mooi in elkaar*


THE WALL STREET JOURNAL.

In Belgium, an Encryption Powerhouse Rises

University of Leuven has become a battleground in the fight between privacy and surveillance

Dept. Computer Science, KU Leuven

- Technische validatie
- *"Zeer interessant"*, *"Zeer actueel probleem"*
- Samenwerking wetenschappelijk artikel

Prof. dr. Patrick Van Eecke (UA, DLA Piper)

- Juridische validatie
- *"Geen showstoppers"*, *"een stap vooruit"*, *"hoogstwaarschijnlijk interesse bij privé"*

Wetenschappelijke Publicatie

Wetenschappelijk artikel
The Data Archipelago - Reconciling privacy and analytics on multi-source PII
i.s.m. dept. computerwet. KU Leuven

?

Conference
16th Privacy Enhancing Technologies Symposium (PETS 2016)

Journal
Proceedings on Privacy Enhancing Technologies

Top crypto and security conferences

Conference	CIF	AR	PR	CR
1. IEEE S&P	3.83	12.2%	9.2%	4.7%
2. Usenix Sec	3.40	16.1%	8.1%	5.2%
3. Eurocrypt	2.92	20.3%	9.9%	4.1%
4. Crypto	2.63	21.1%	12%	4.9%
5. NDSS	2.40	17.1%	20.8%	3.7%
6. ACM CCS	2.36	18.4%	15.6%	8.3%
7. CHES	2.35	25.6%	9.2%	7.7%
8. Asiacrypt	2.25	16.9%	19.1%	8.5%
9. PETS	**2.16**	**22.9%**	**14.1%**	**9.4%**
10. ACSAC	1.94	21.1%	18%	12.4%

CIF = 1 / (AR+PR+CR), where
AR = No. accepted papers / No. of submissions
PR = No. accepted papers / No. of registered participants
CR = No. accepted papers / No. of citations

(JZ)

Kruisen van Persoonsgegevens

Een fictief voorbeeld

*Een **onderzoeksteam** wil medische, financiële en demografische persoonsgegevens analyseren van alle **burgers** die na 1990 geboren zijn, die zelfstandige in bijberoep zijn met een loon van minstens € 50 000.*

*Deze gegevens worden echter beheerd door verschillende **overheidsbedrijven** en moeten dus gekruist worden.*

Wetenschapper
Vlot kruisen data

Burger
Respect privacywetgeving

Overheidsorganisatie
Behoudt controle (want verantwoordelijk)

Allen
minimale impact data breach

Kruisen van Persoonsgegevens

Een fictief voorbeeld

Oefening

Hoe ver kunnen we gaan m.b.v. cryptografie?

Data Archipel

Combineren van

Wetenschapper
Vlot kruisen data

Burger
Respect privacywetgeving

Overheidsorganisatie
Behoudt controle (want verantwoordelijk)

Allen
minimale impact data breach

Digital Data Dystopia

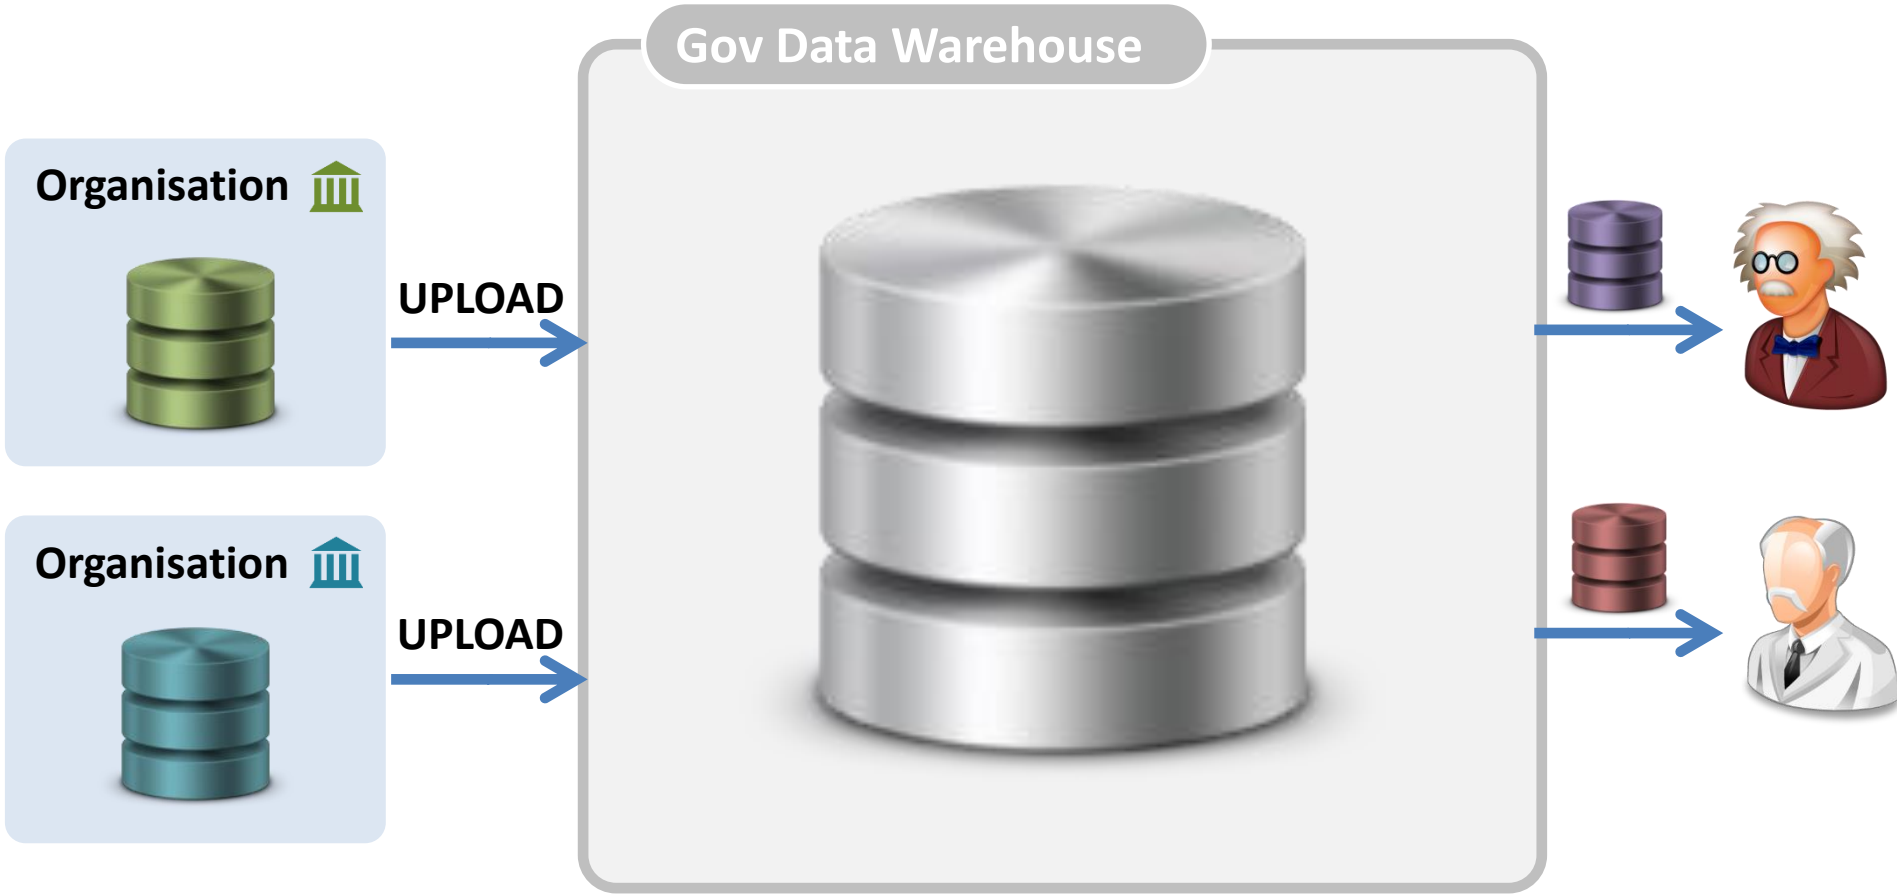

Overheidsorganisatie geen enkele controle

Data breach dramatisch

Privacy risico's

Vlot Kruisen data

Concept

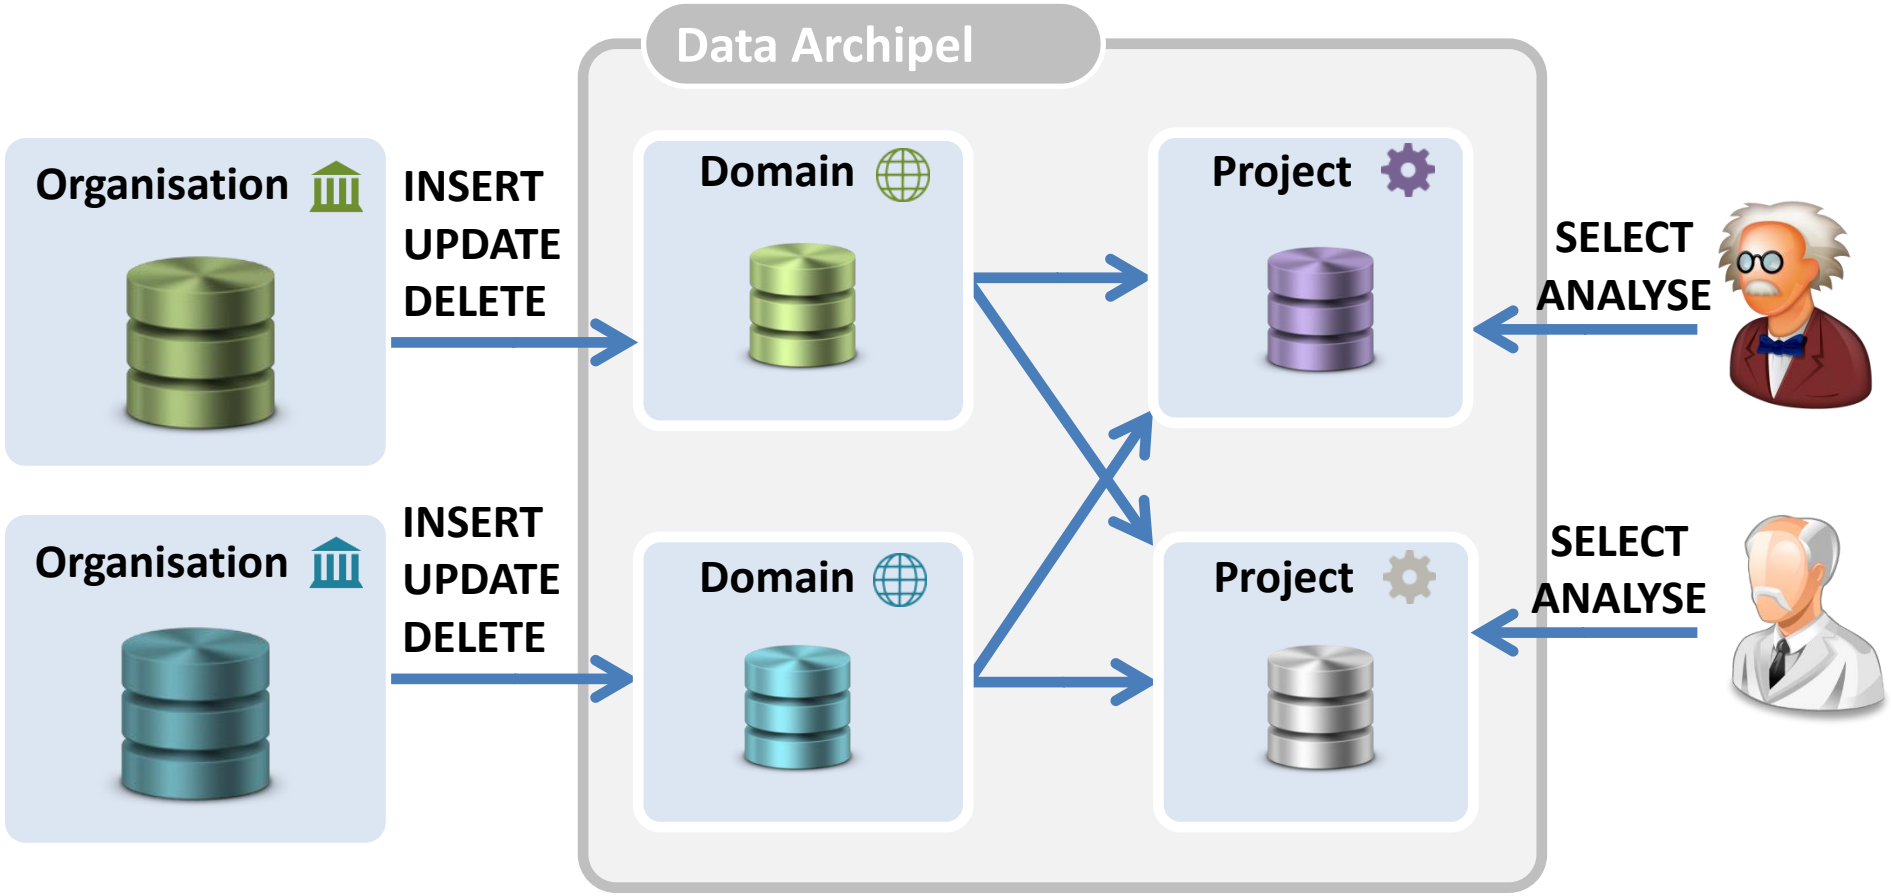

Domain
- Beheerd & gecontroleerd door één organisatie
- Permanent
- Lage performantievereisten

Project
- Ontvang minimaal vereiste data
- Toegangscontrole + monitoring
- Tijdelijk
- Hoog performant

Concept

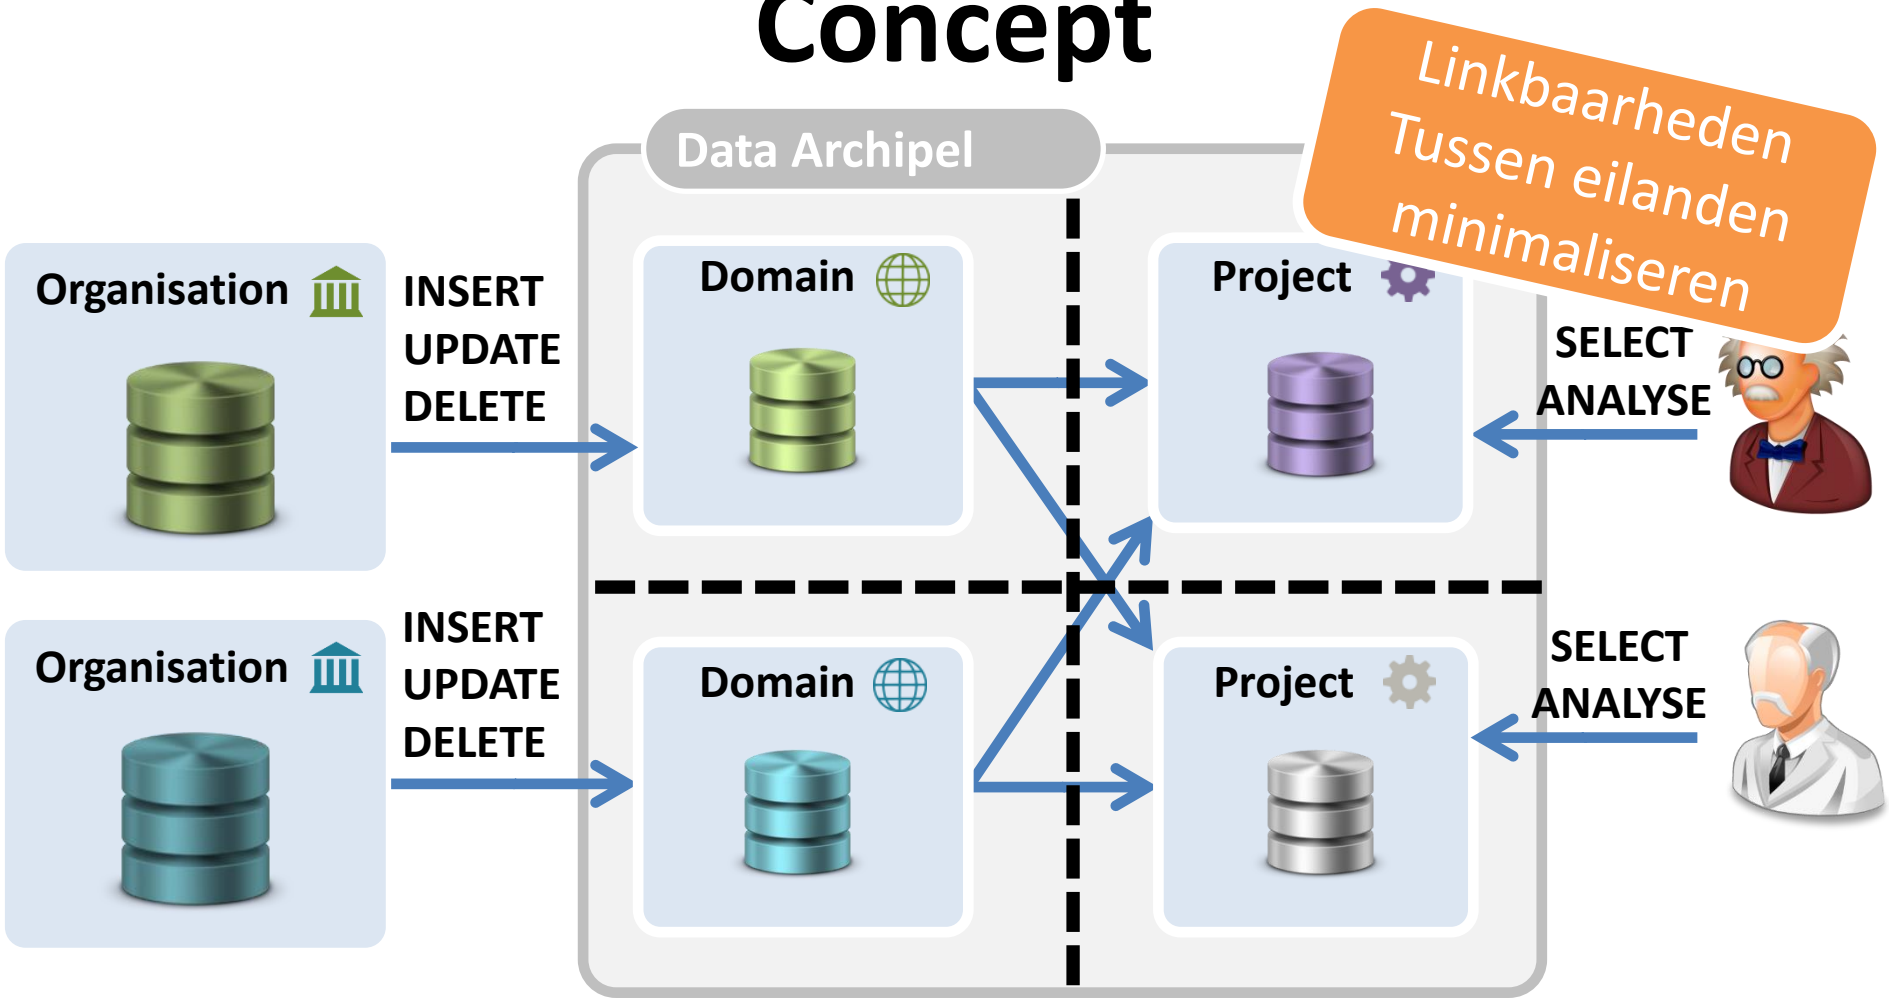

Maximale controle overheidsorganisatie

Kleinere impact bij data breach

Mechanismes Privacy

Vlot kruisen data

Linkbaarheid

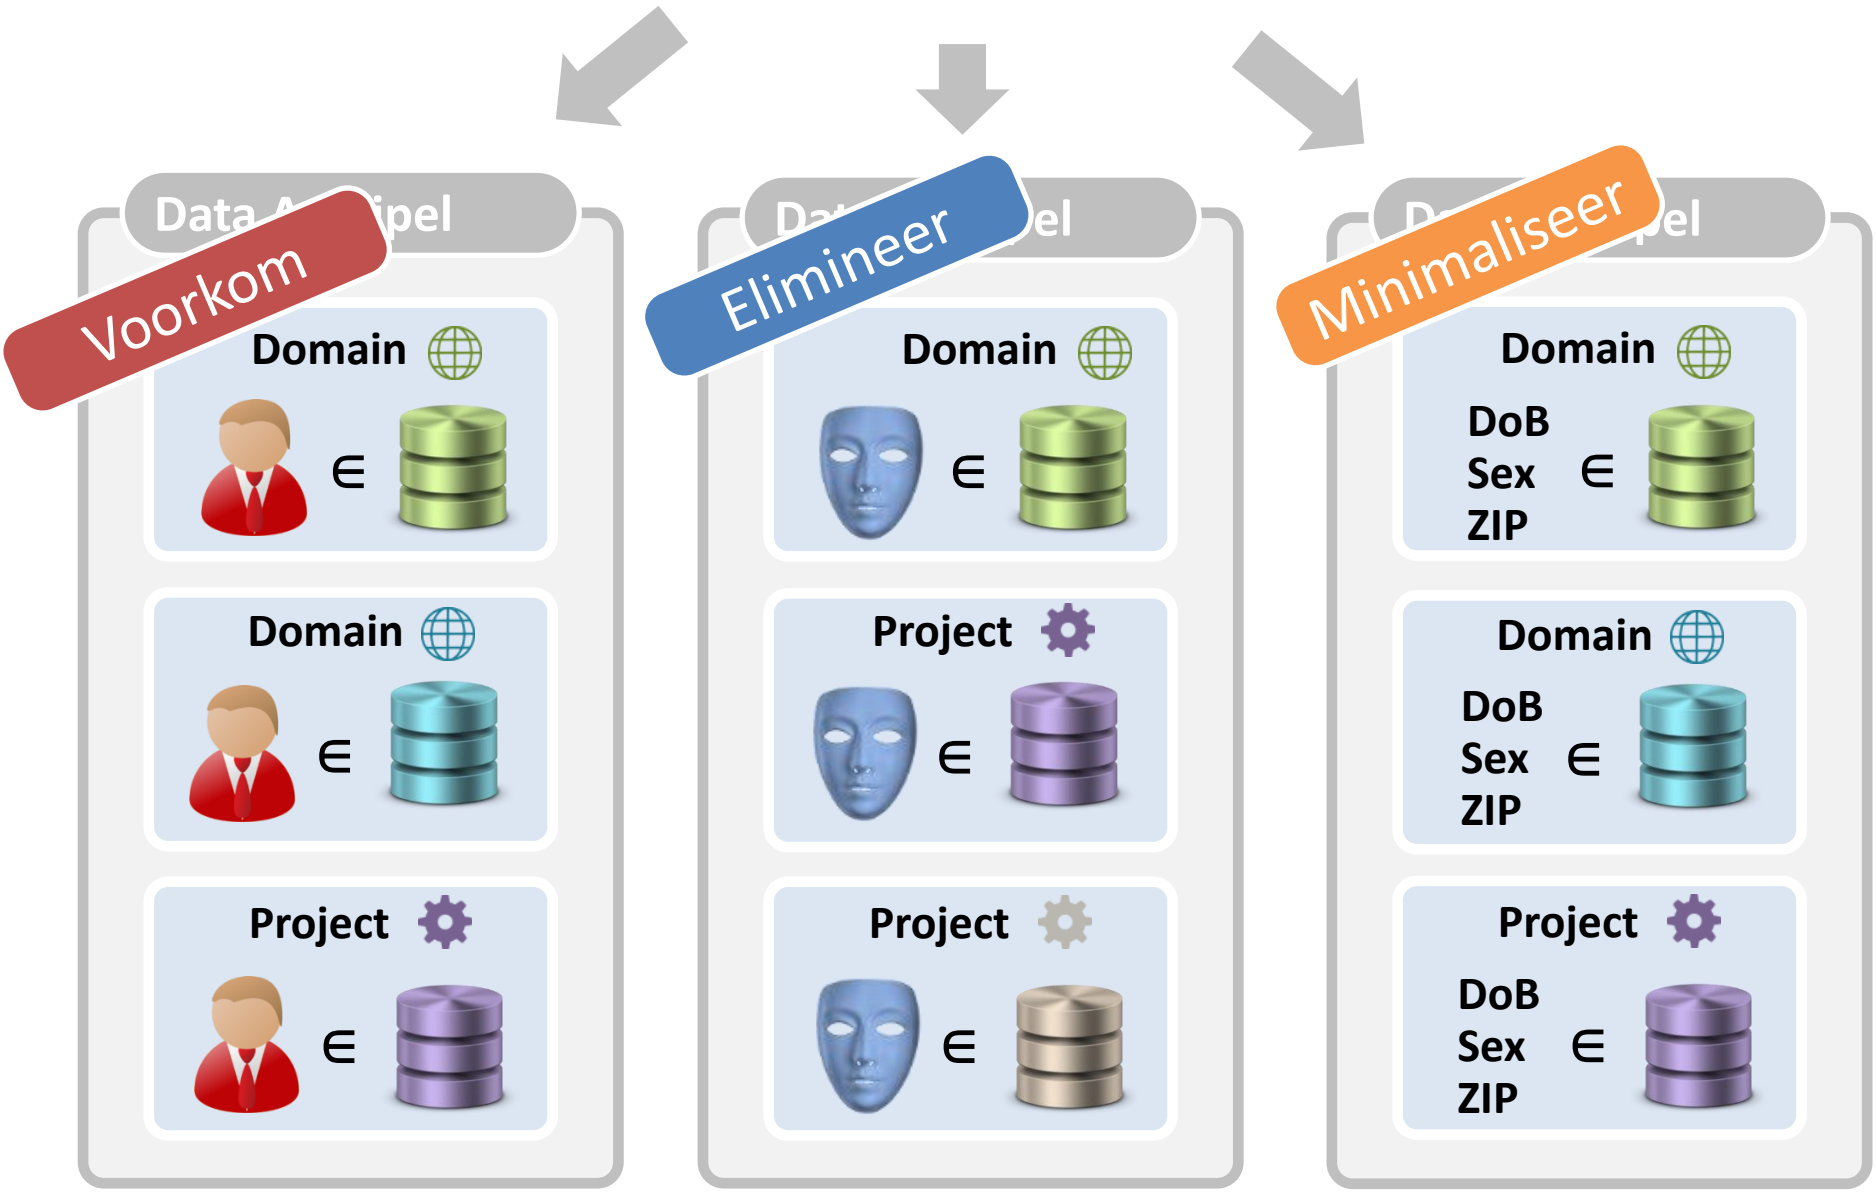

Linkbaarheid

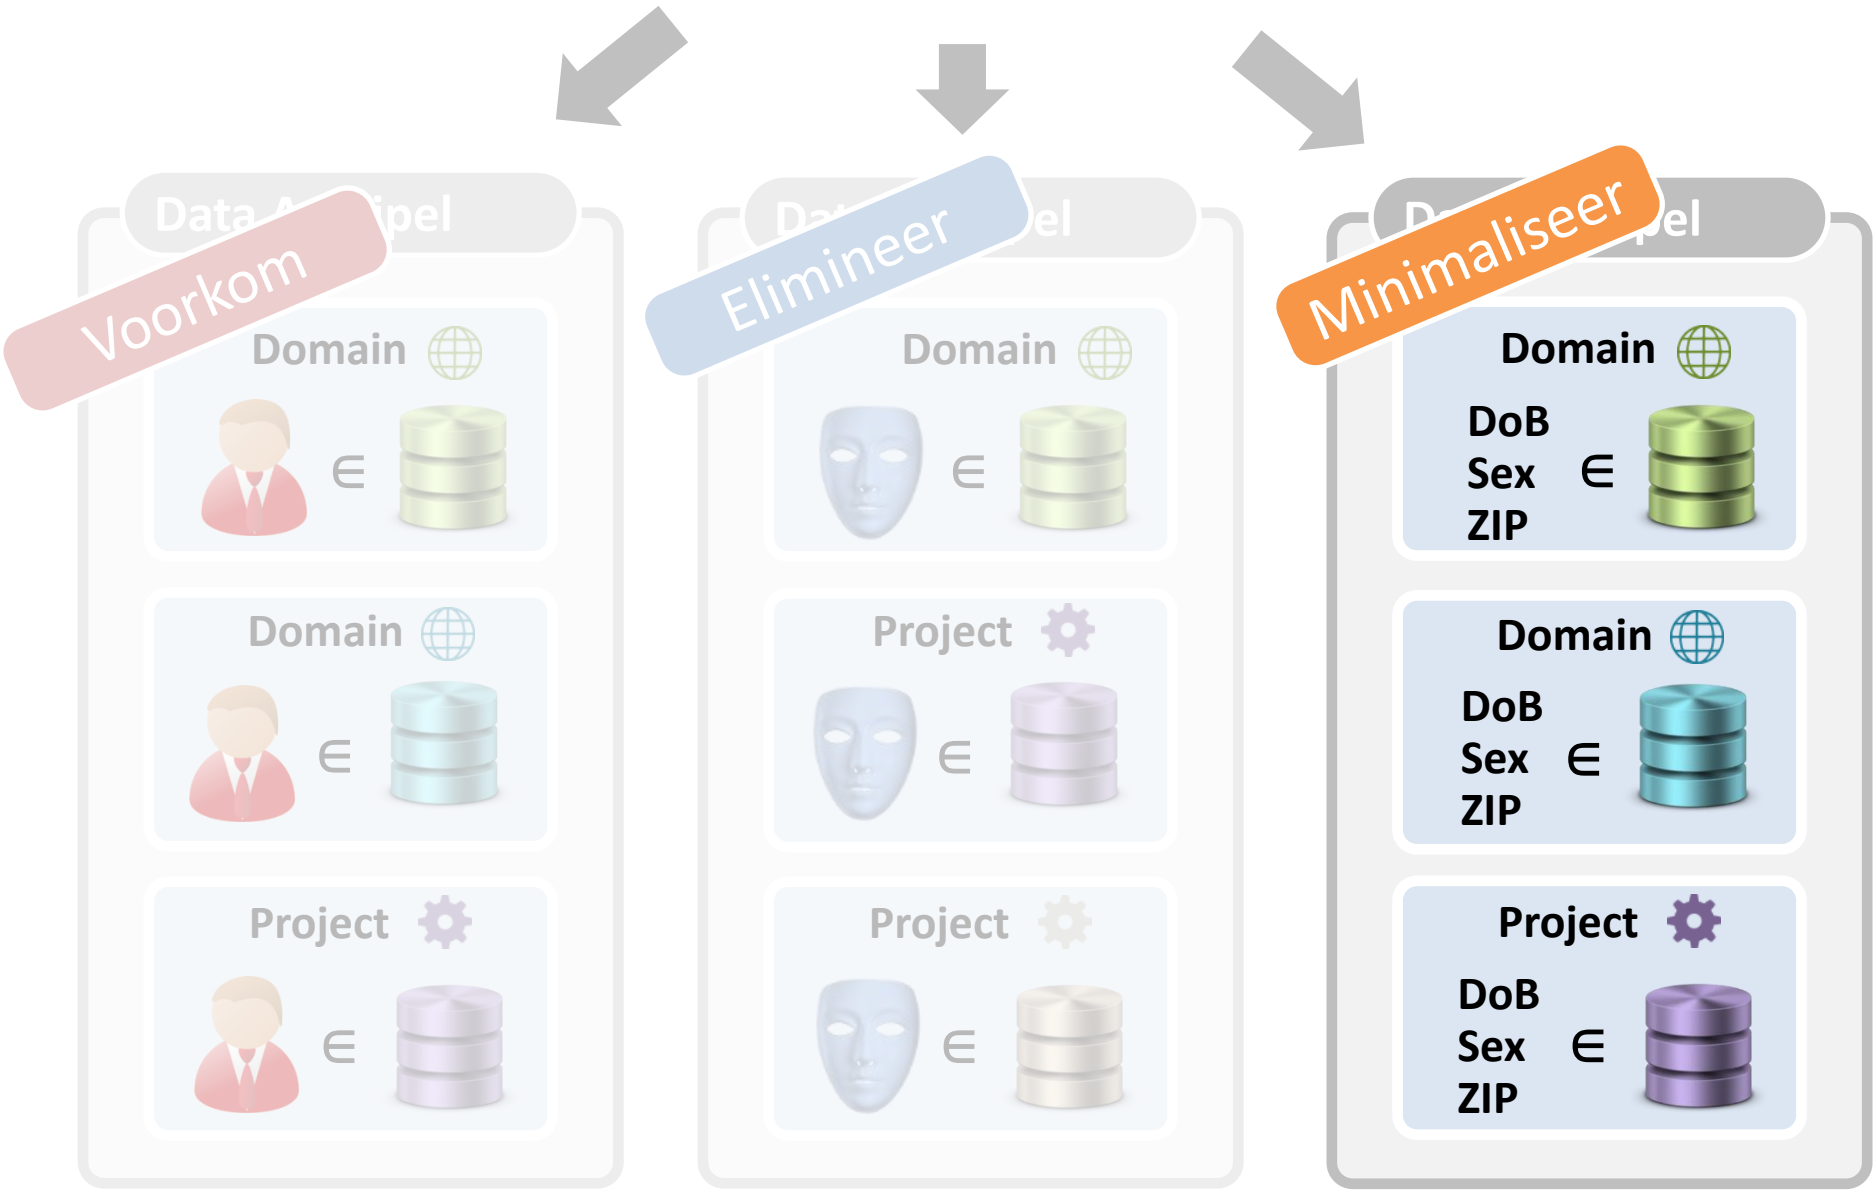

Attribuut-linkbaarheid

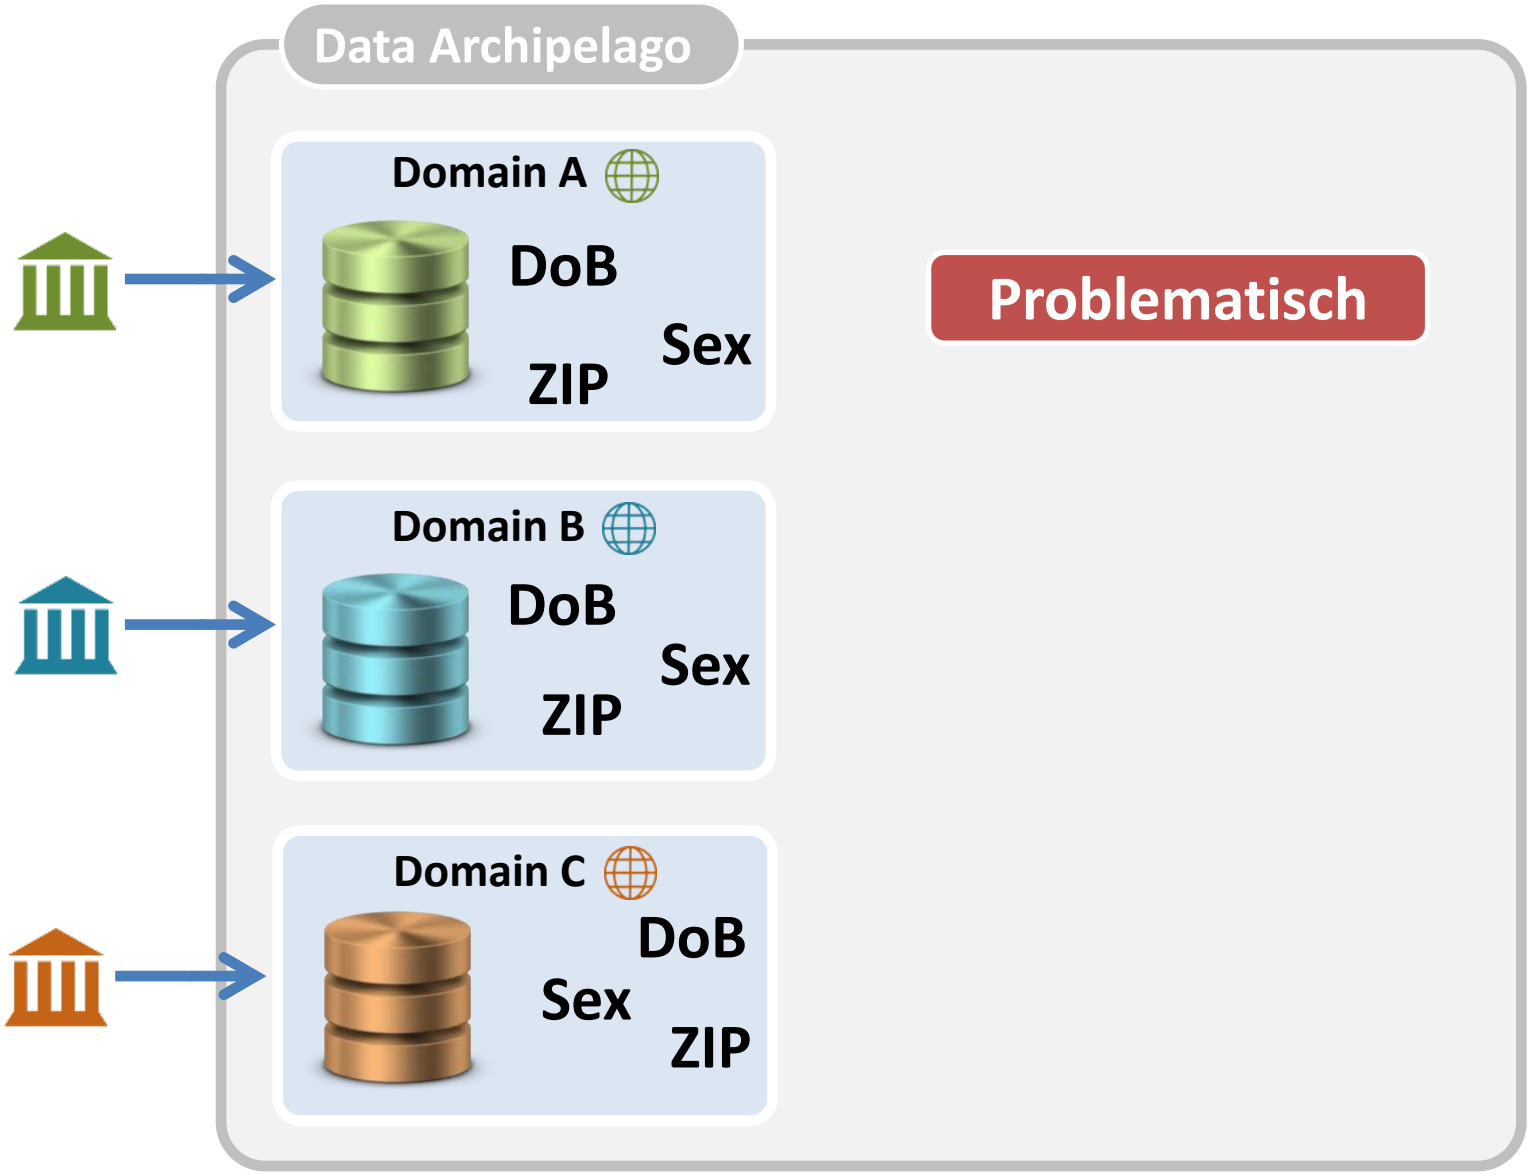

Attribuut-linkbaarheid

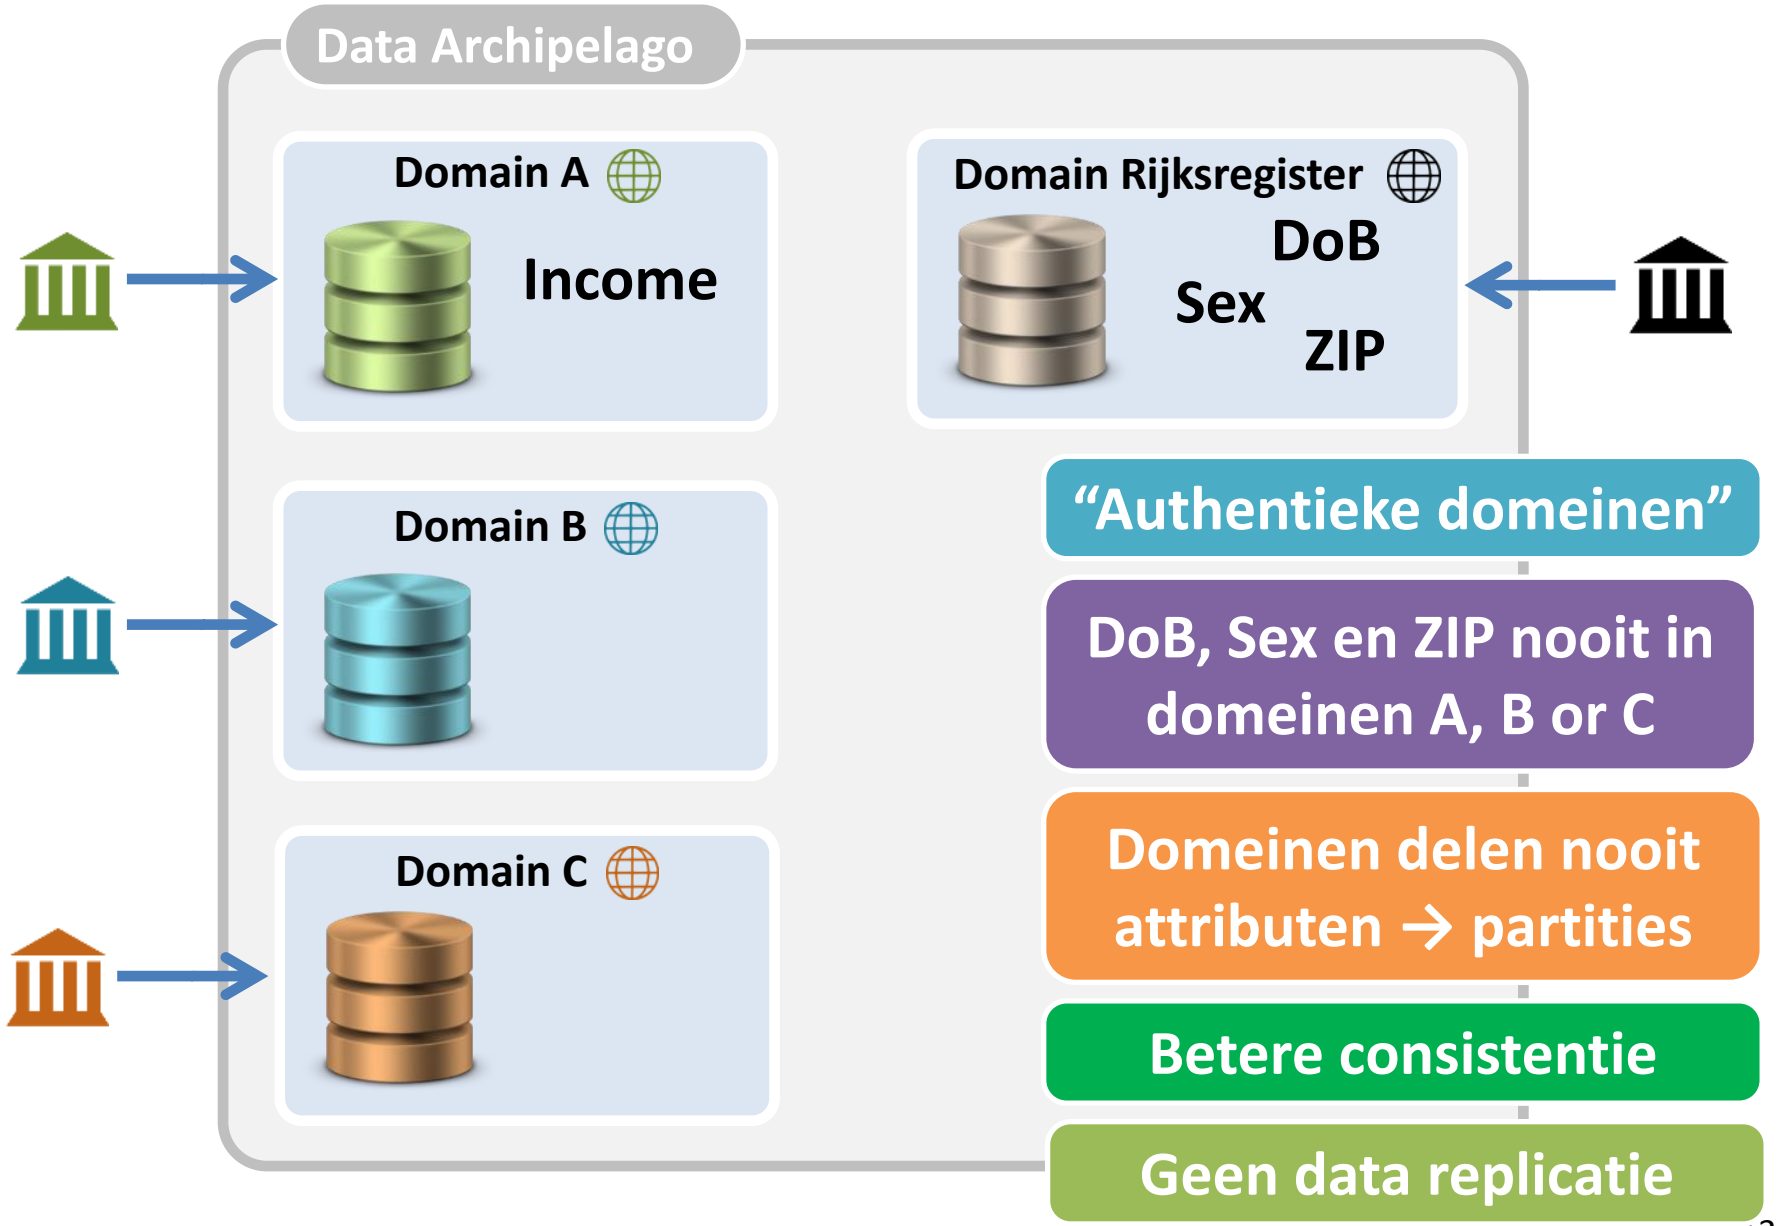

Attribuut-linkbaarheid

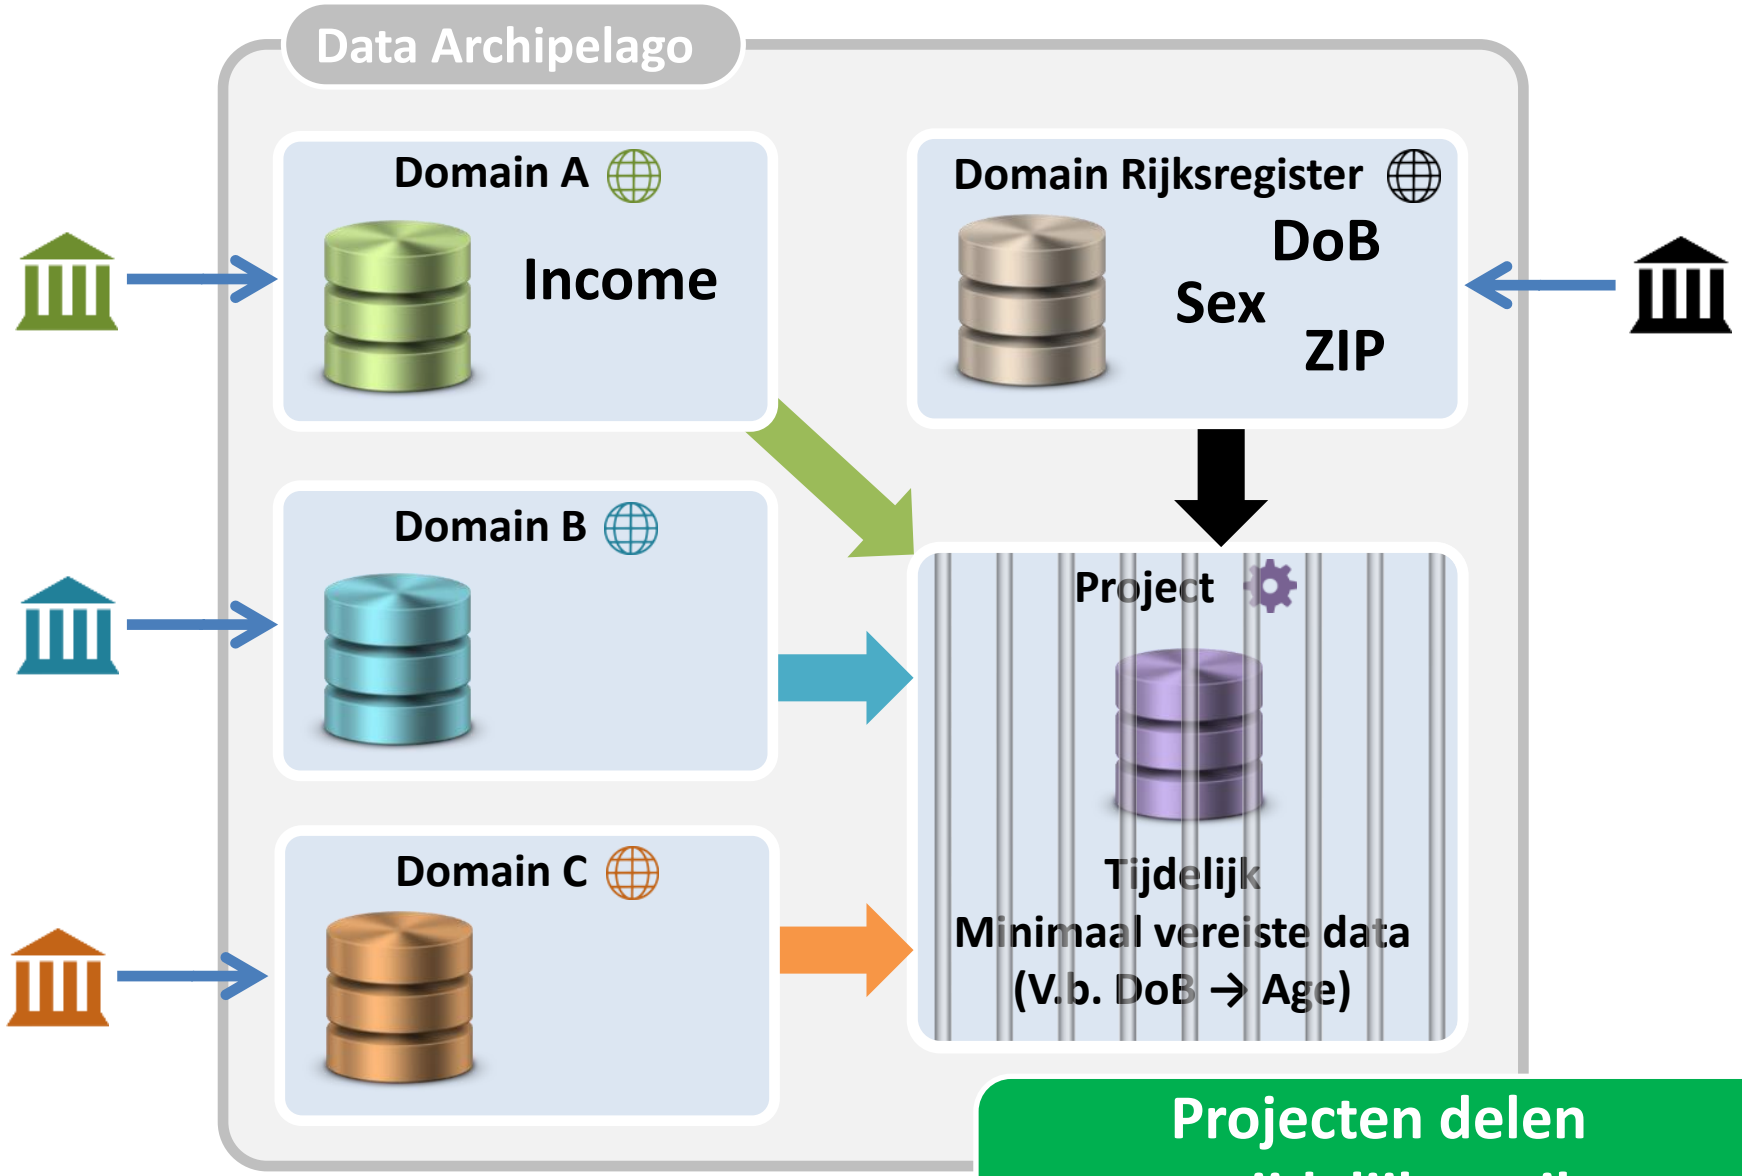

Projecten delen onvermijdelijk attributen

Linkbaarheid

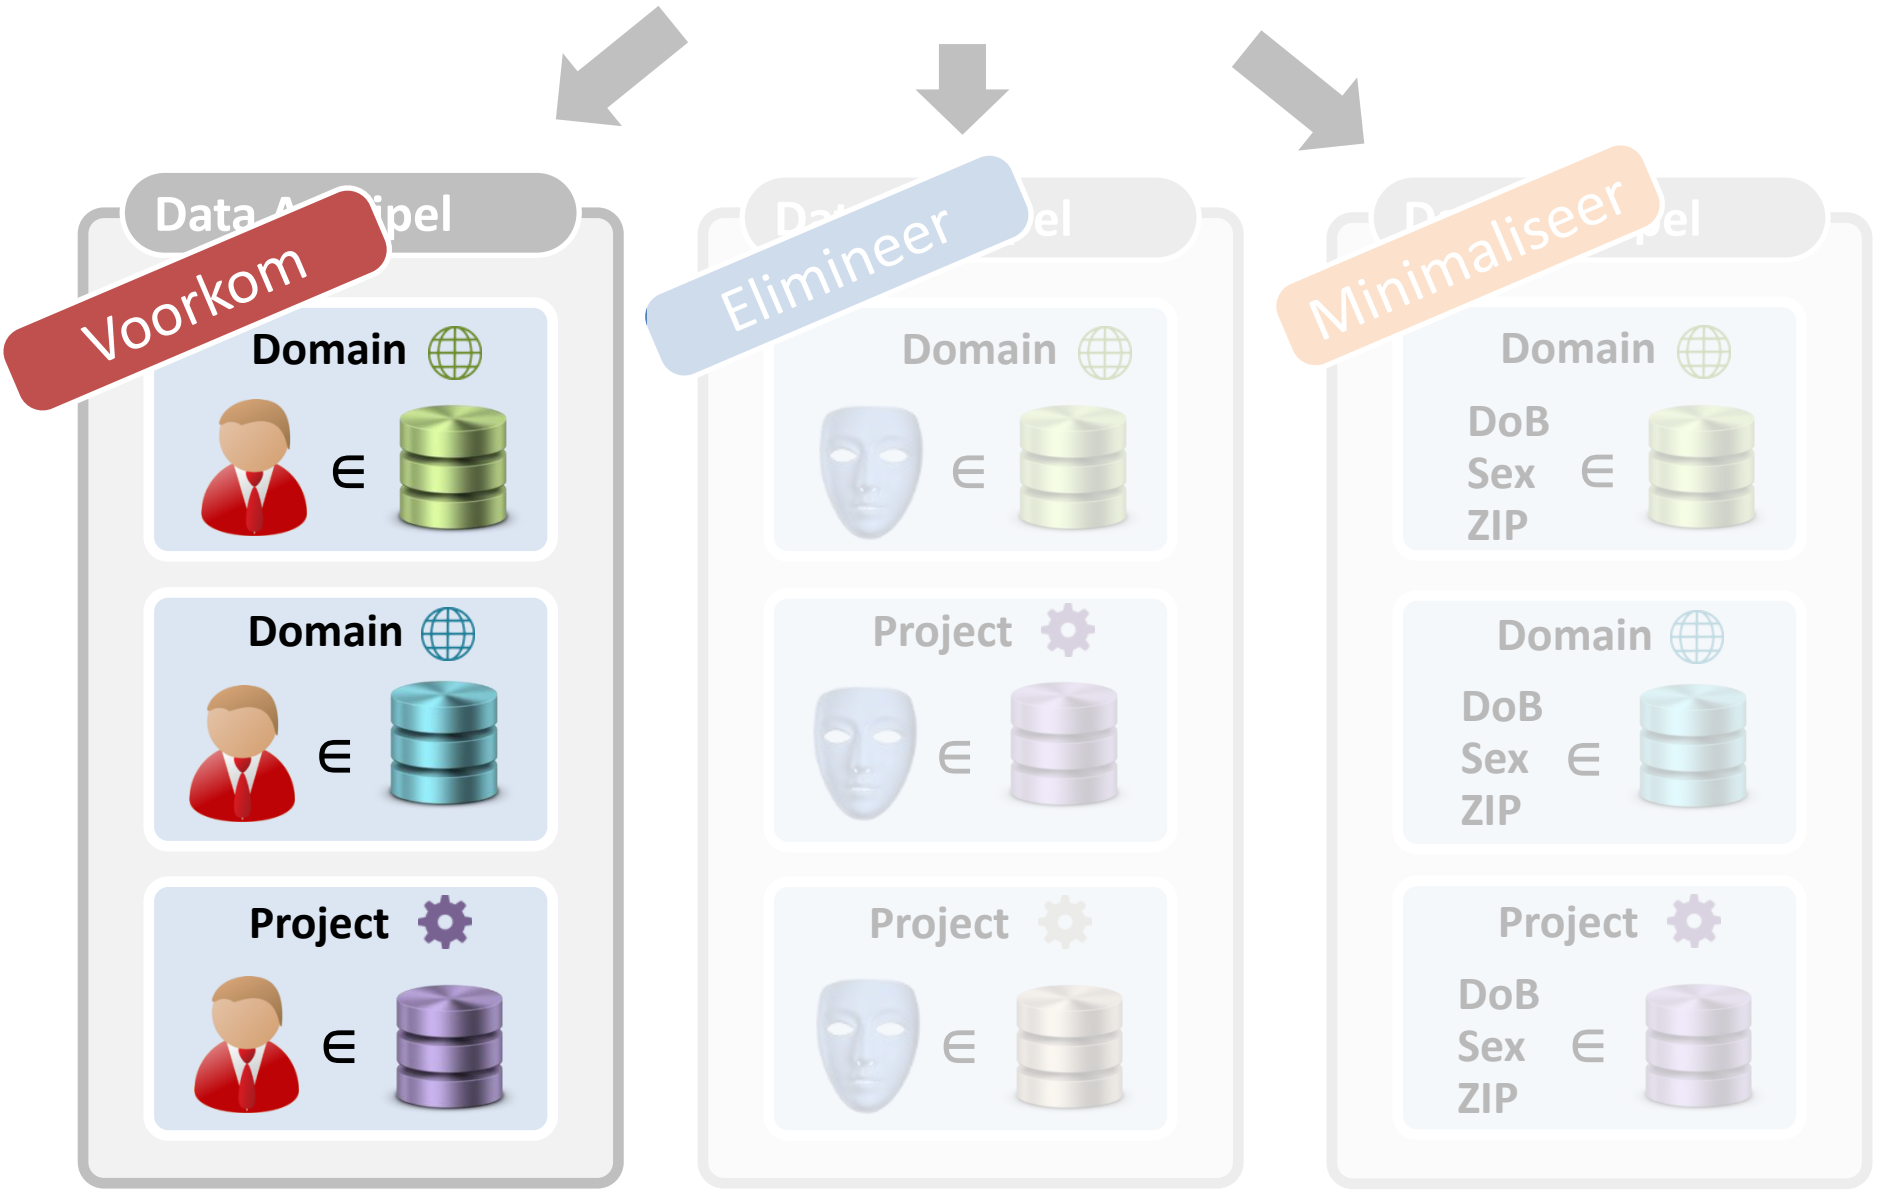

Linkbaarheden met identifiers

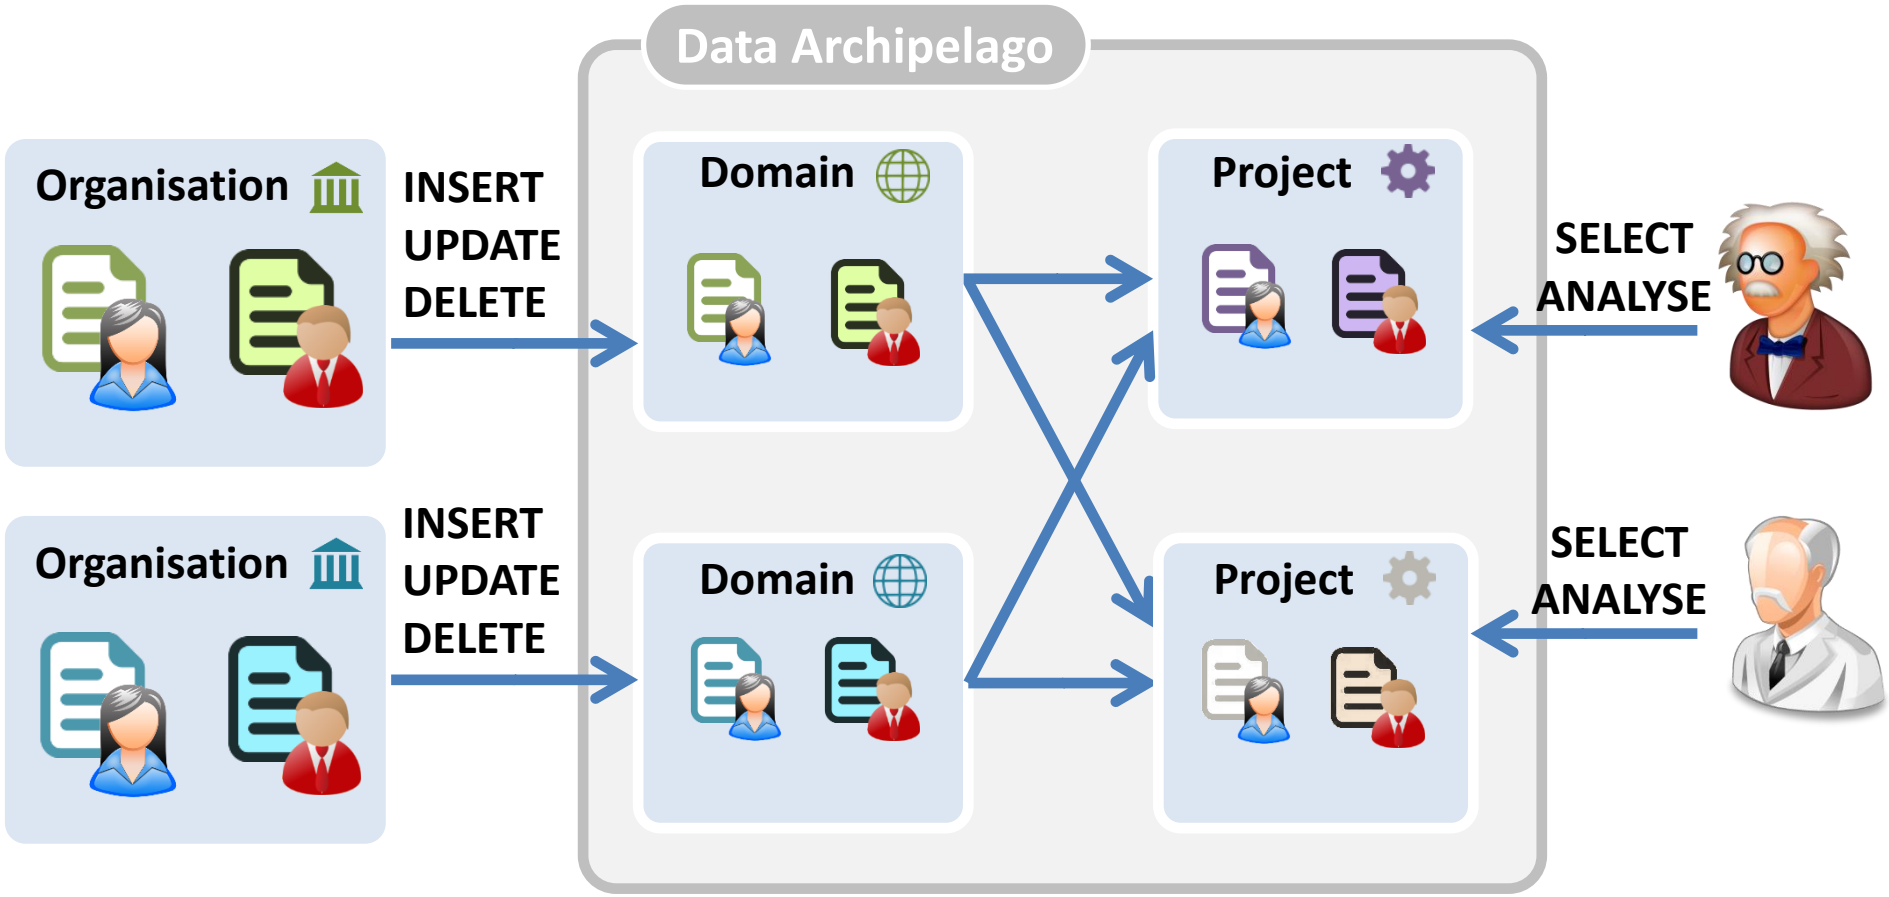

Elk eiland kent de identifier (INSZ-nummer) van burger

We laten niet toe dat identifiers in de data archipel komen

Linkbaarheid

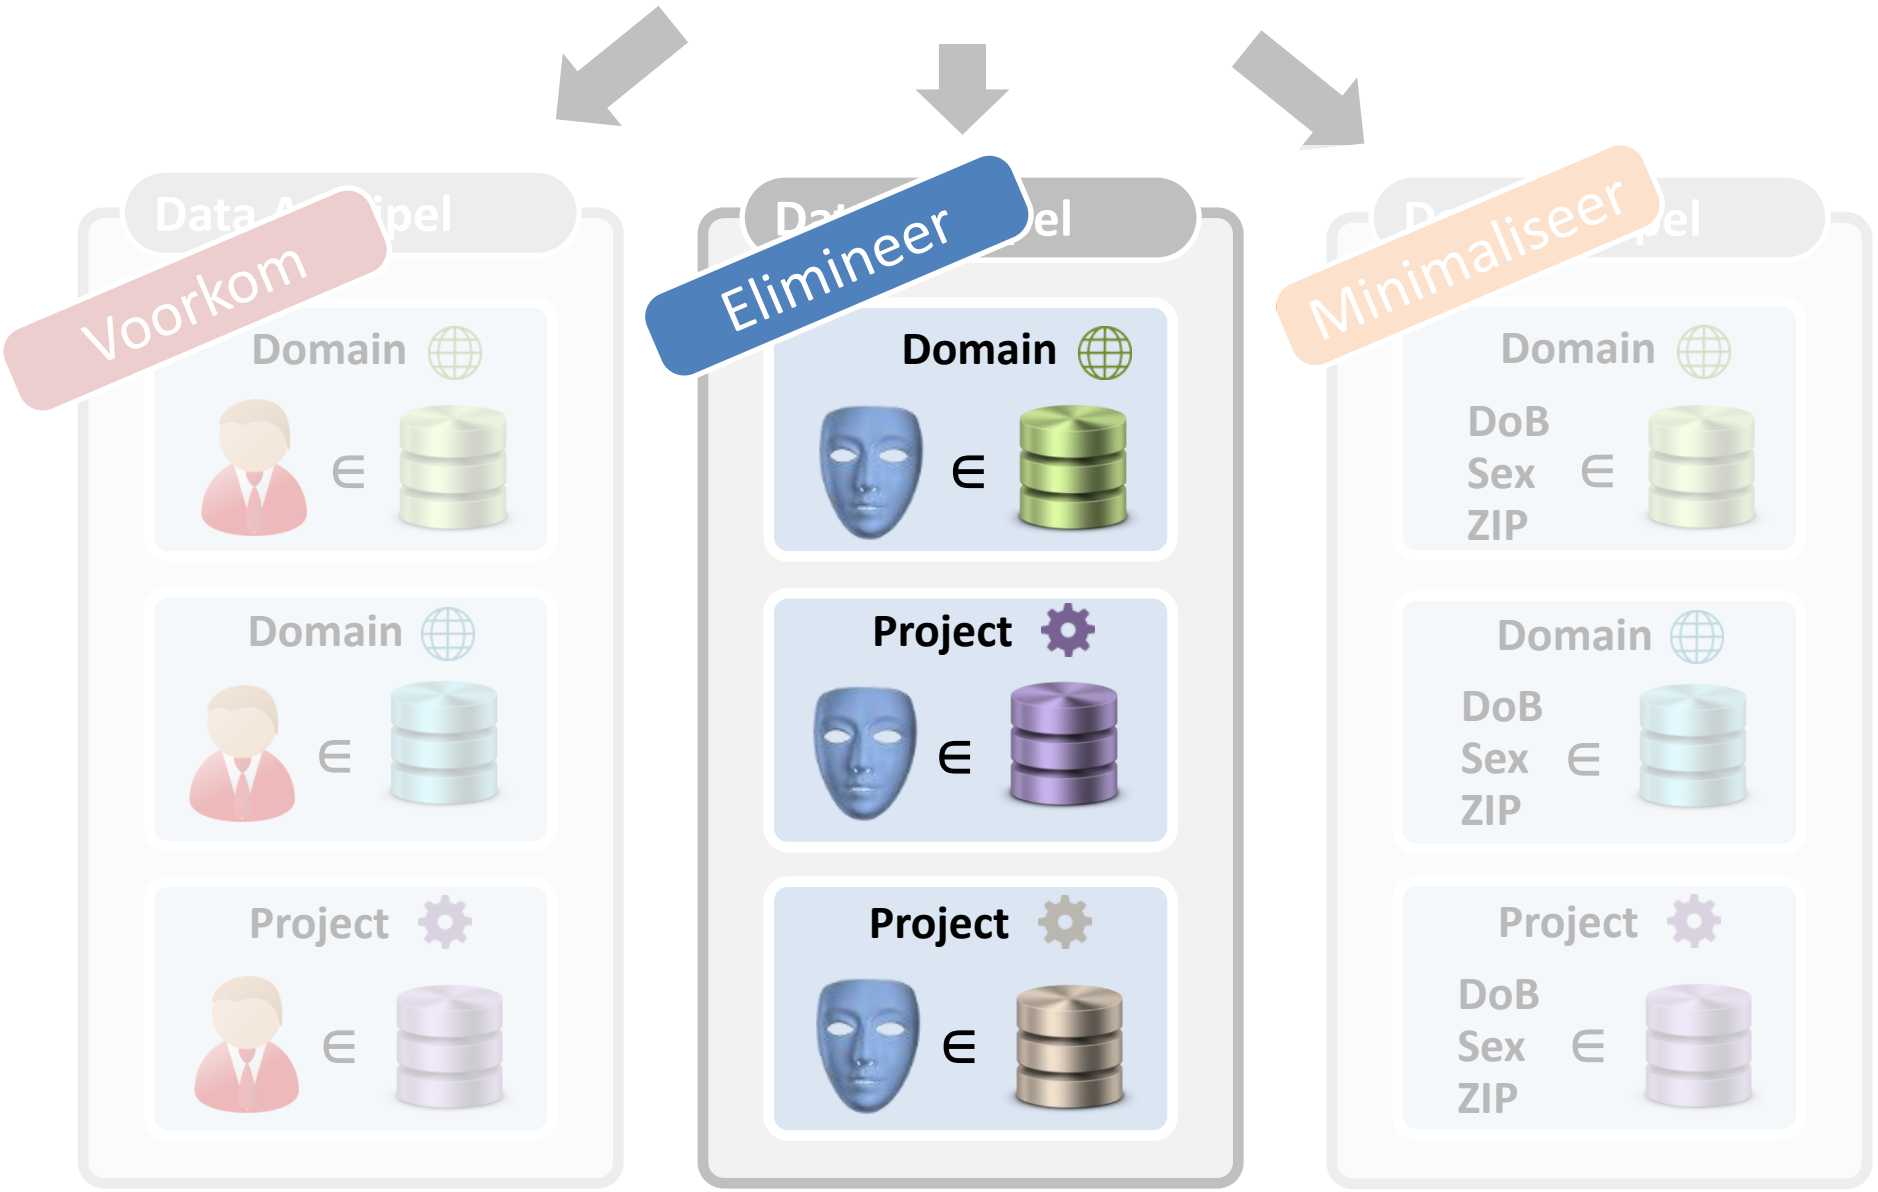

Linkbaarheden met pseudoniemen

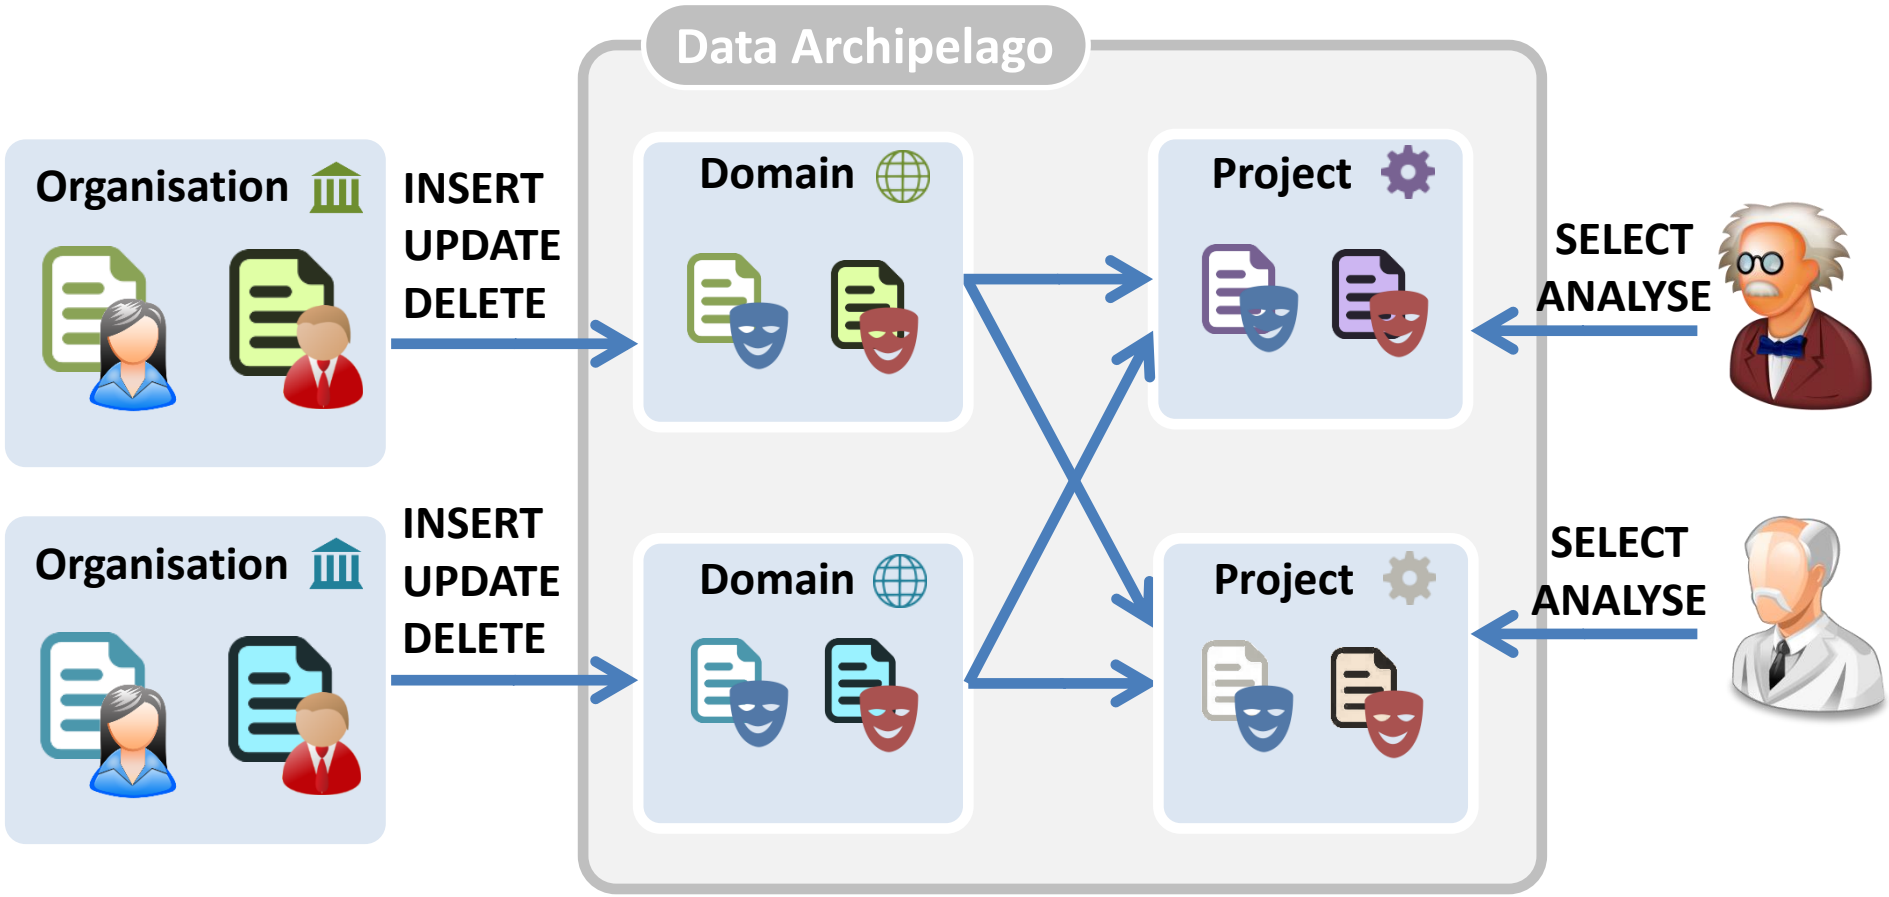

Burger elk eiland gekend onder ander pseudonym
Pseudonymen onlinkbaar

Ideale situatie

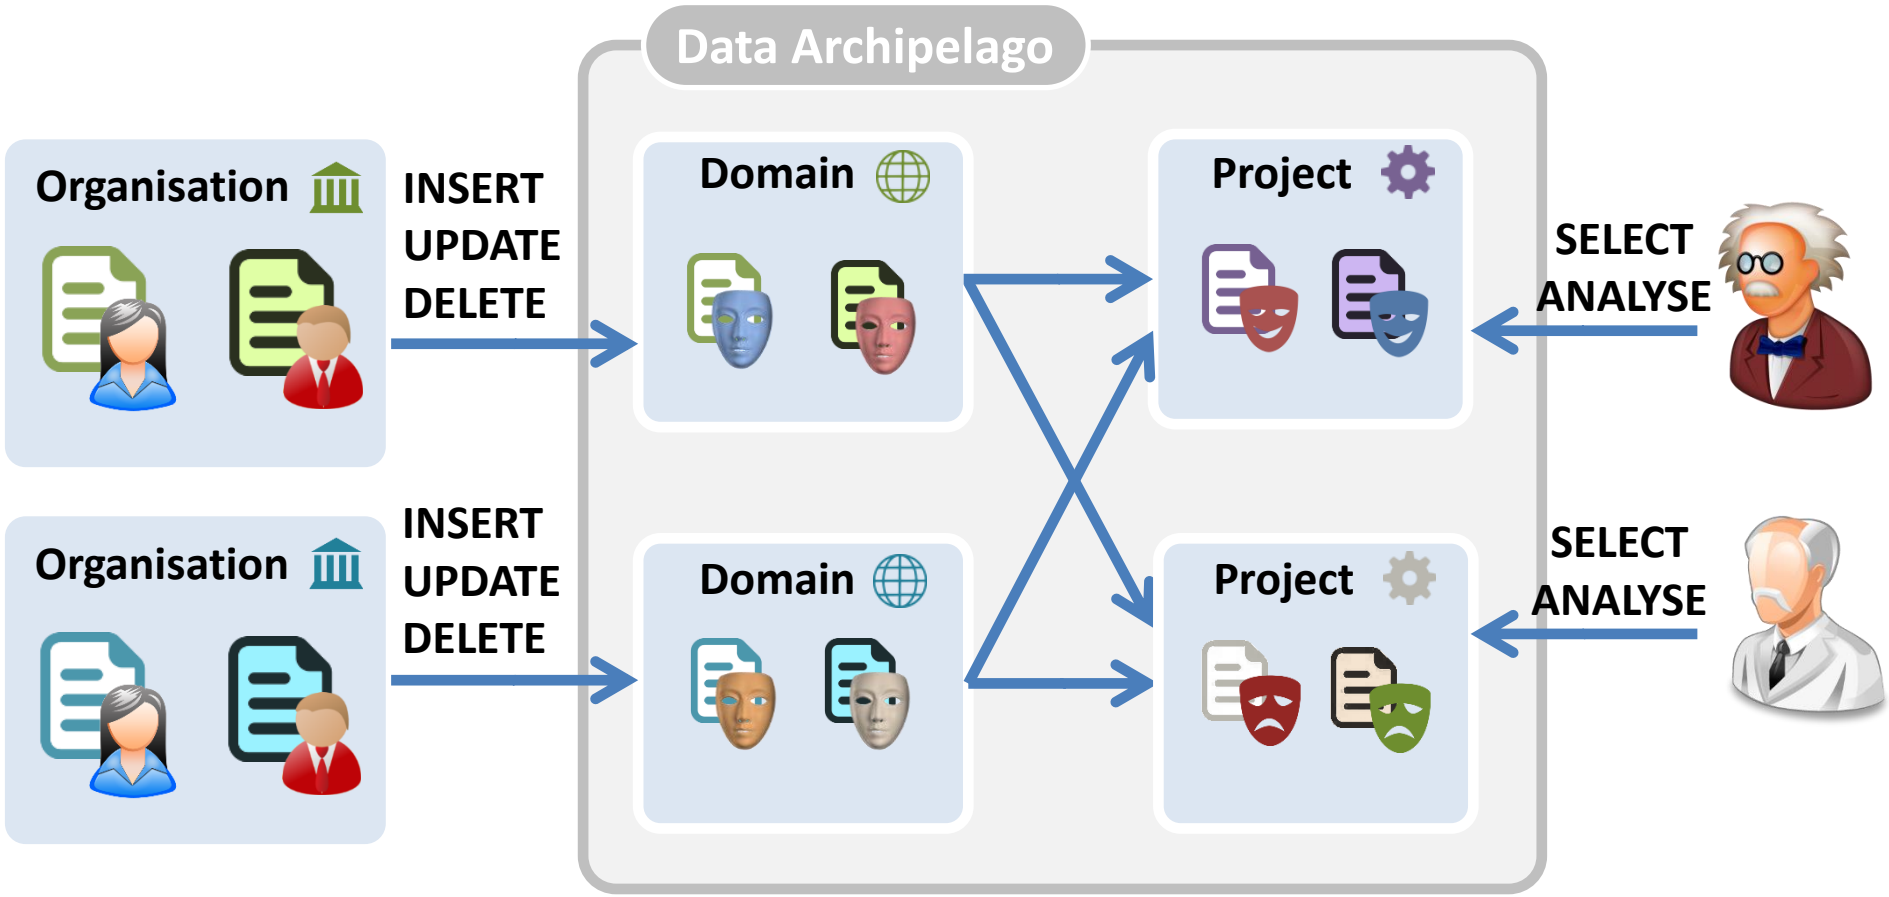

Elke burger heeft apart pseudonym per eiland
Pseudoniemen onlinkbaar aan elkaar en aan identifier

Identifiers & Pseudonymen

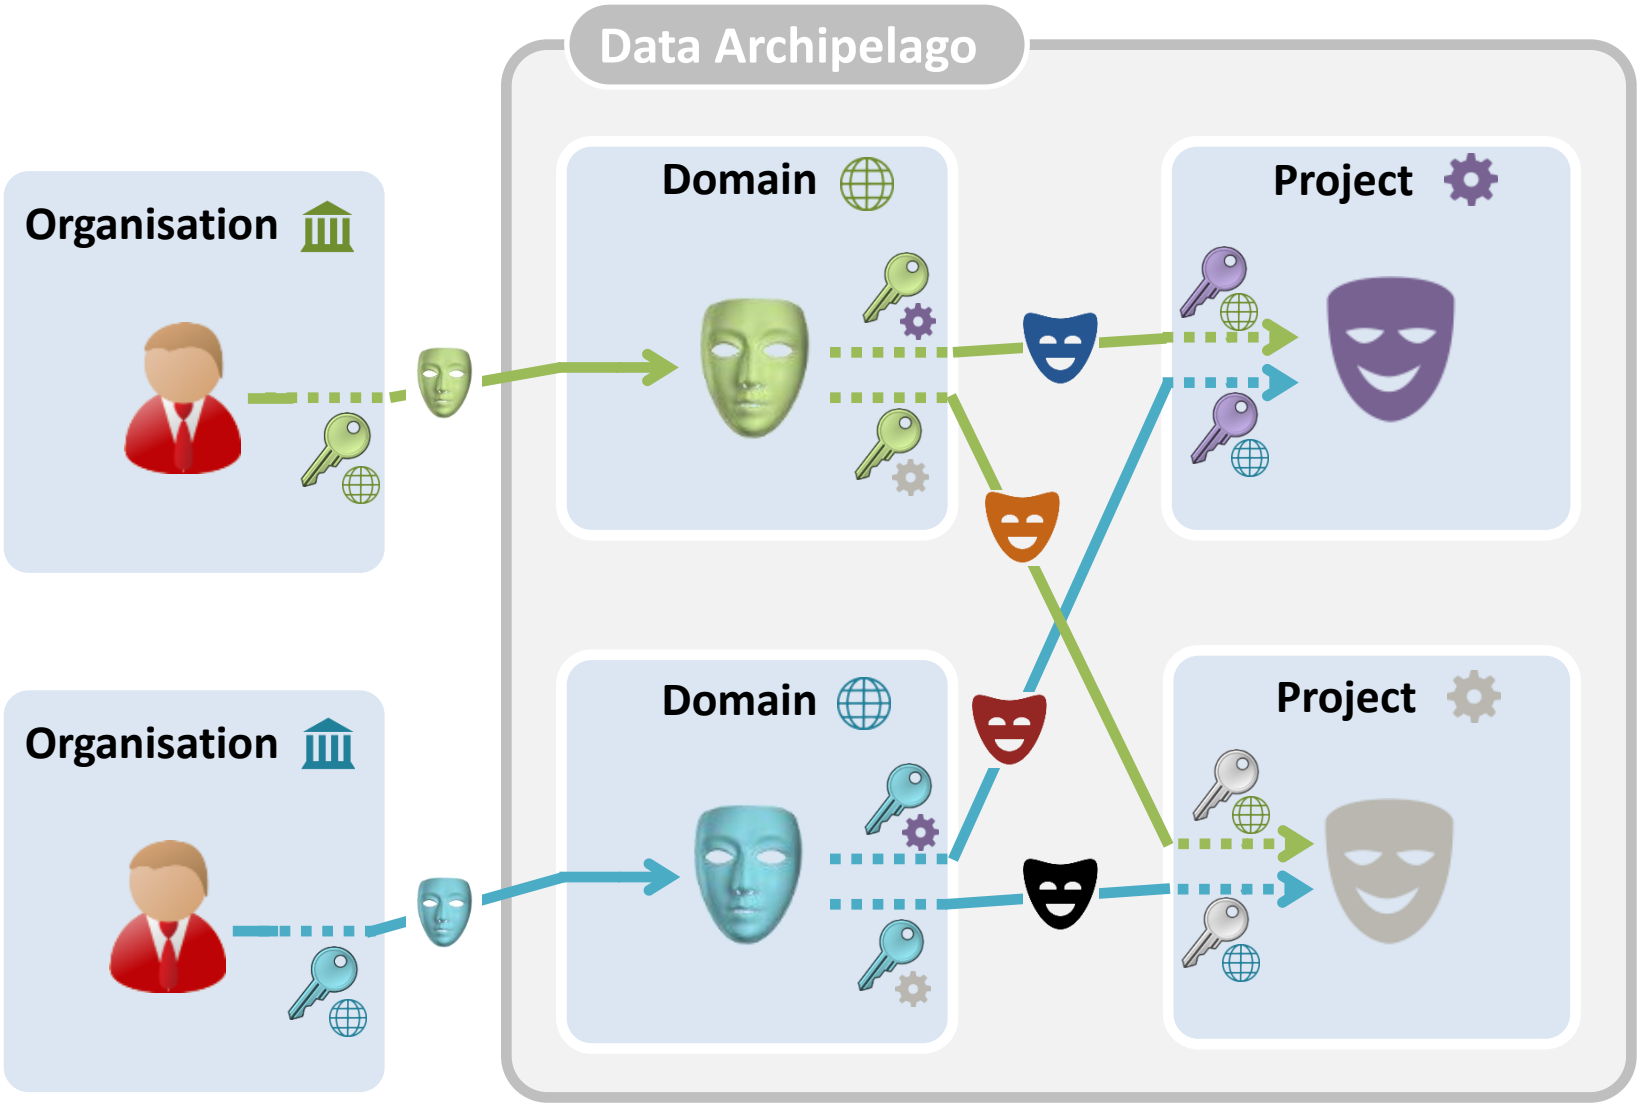

Nieuwe link vereist minstens twee partijen => isolatie

Een project opstarten

Project heeft data nodig over

Domein Rijksregister
Geboortejaar ≥ 1990

Domein A
Zelfstandige in bijberoep

Domein B
Loon > 50.000€/jaar

Stappen

1. Goedkeuring project (machtigingsaanvraag)
2. Het vereiste sleutels worden gegenereerd
3. De vereiste data wordt door project verzameld

Identifiers & Pseudoniemen

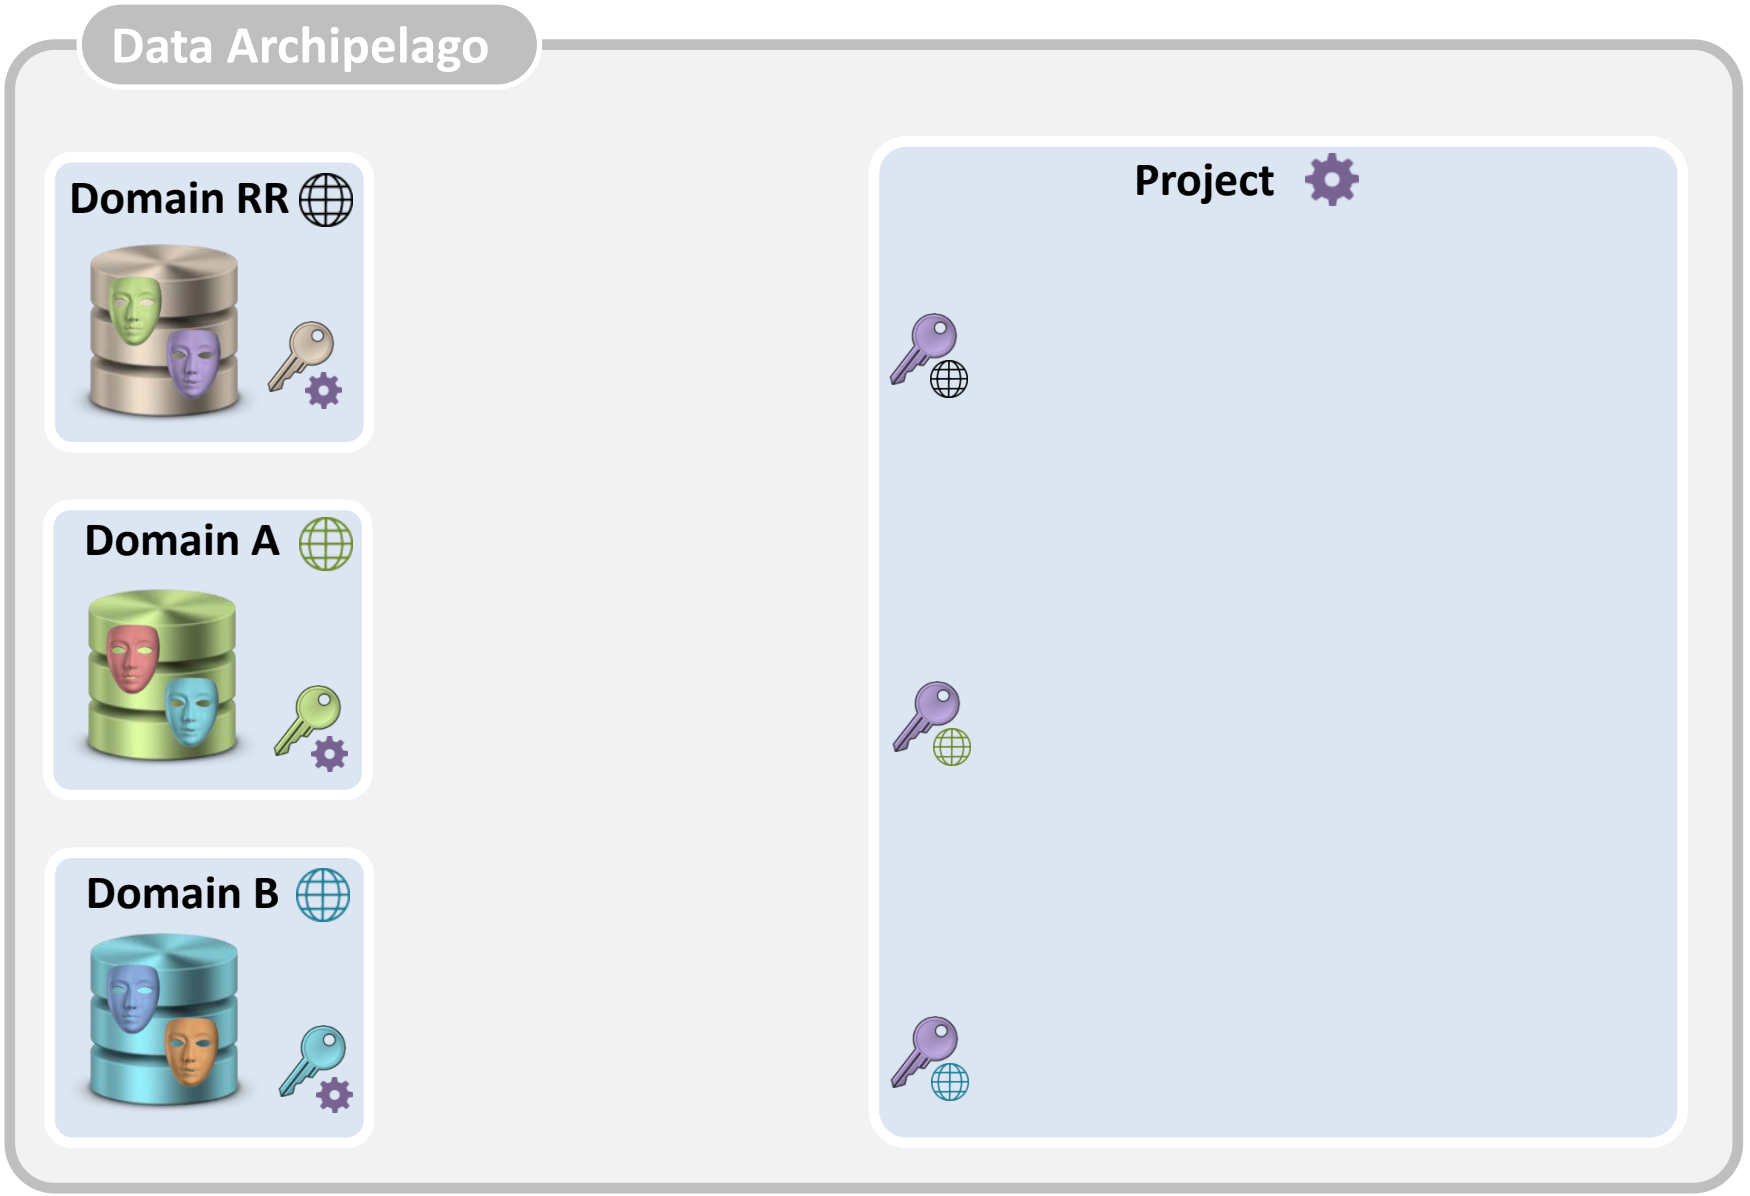

Identifiers & Pseudoniemen

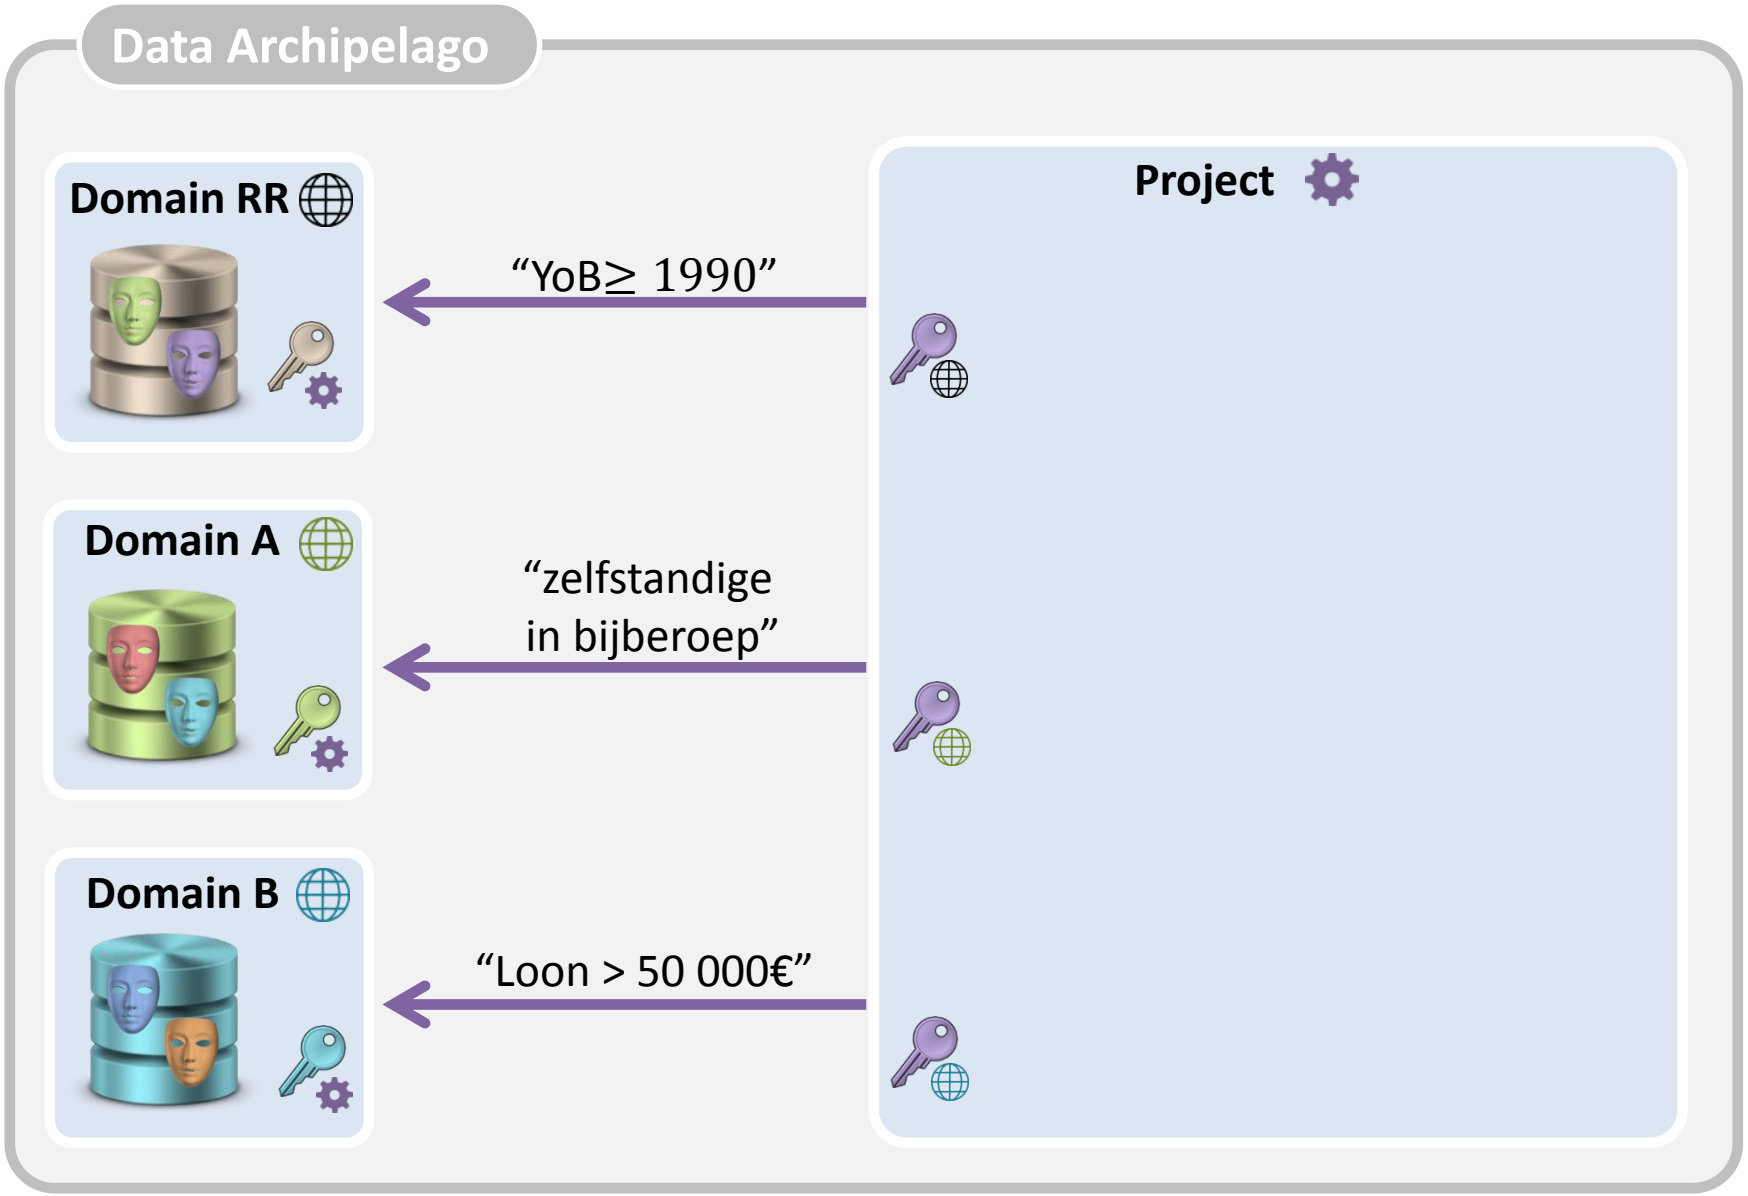

Identifiers & Pseudoniemen

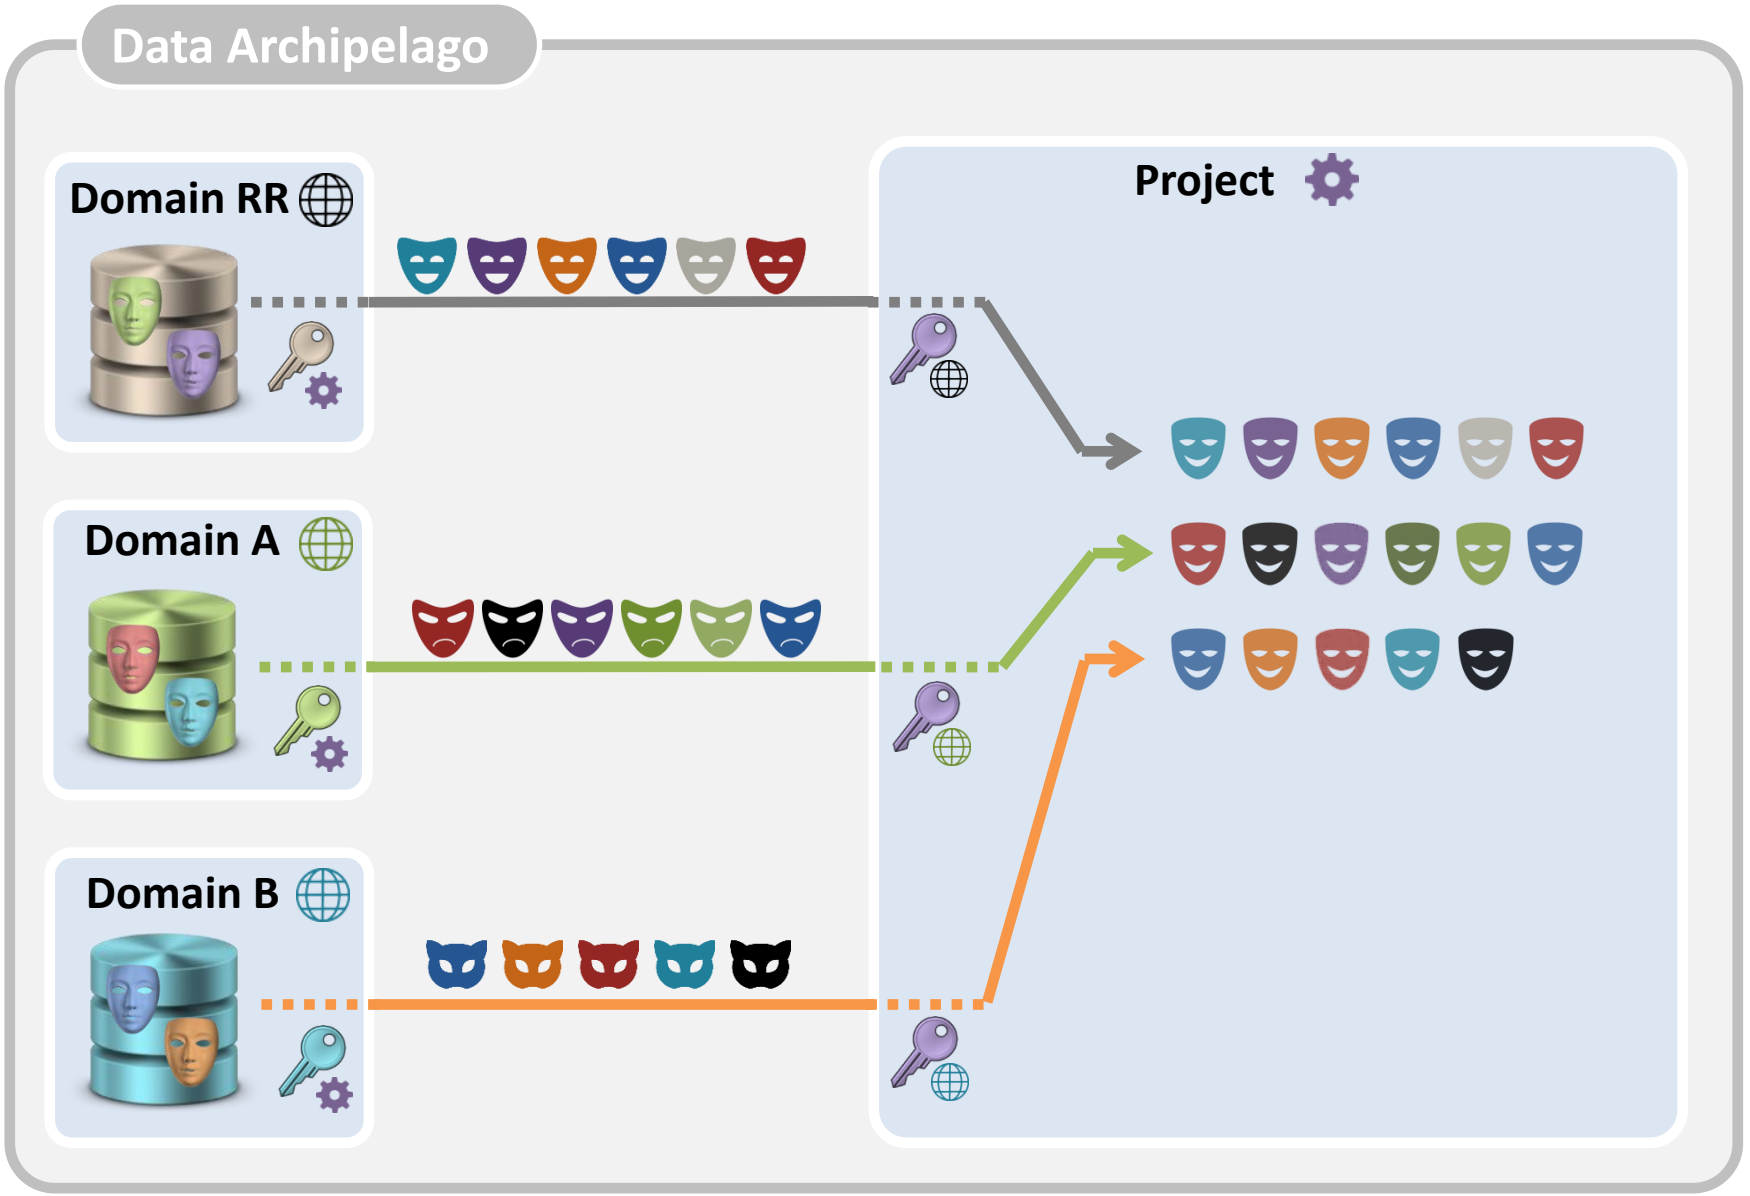

Identifiers & Pseudoniemen

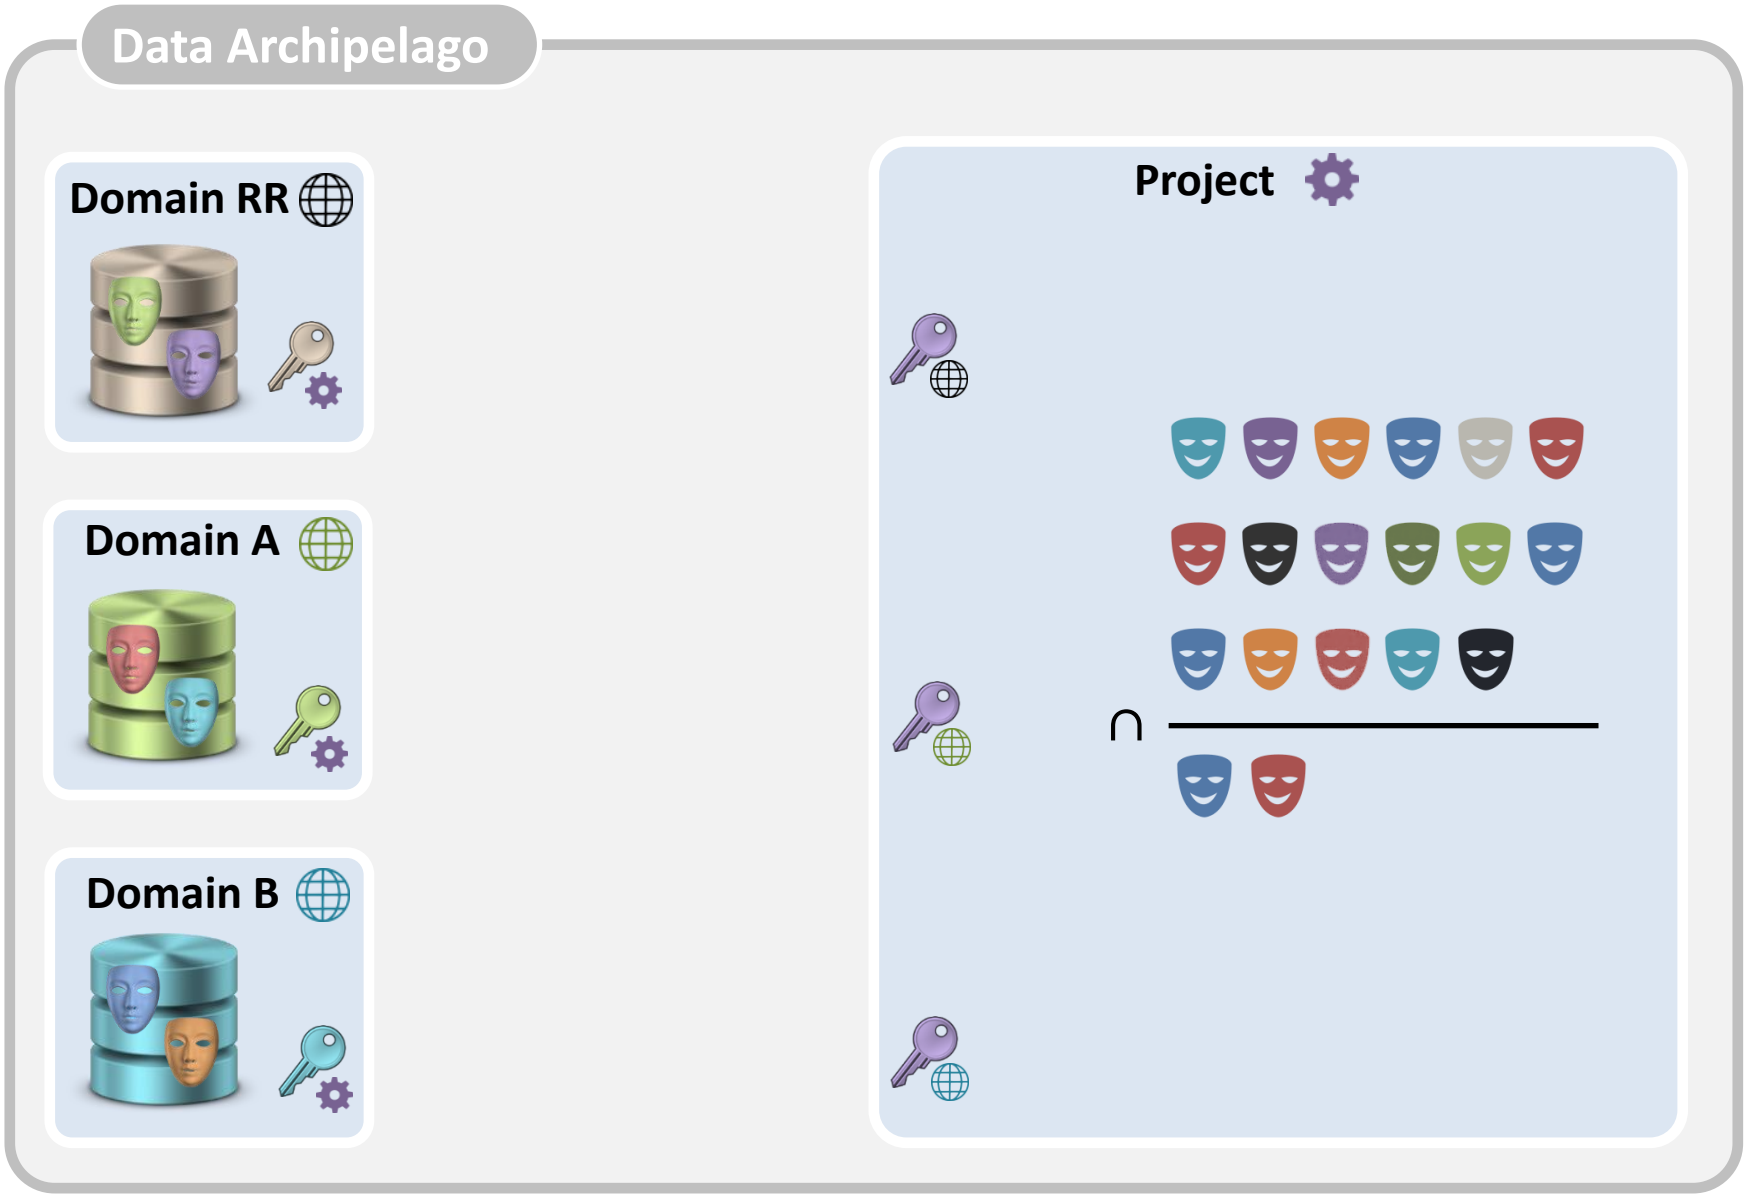

Identifiers & Pseudoniemen

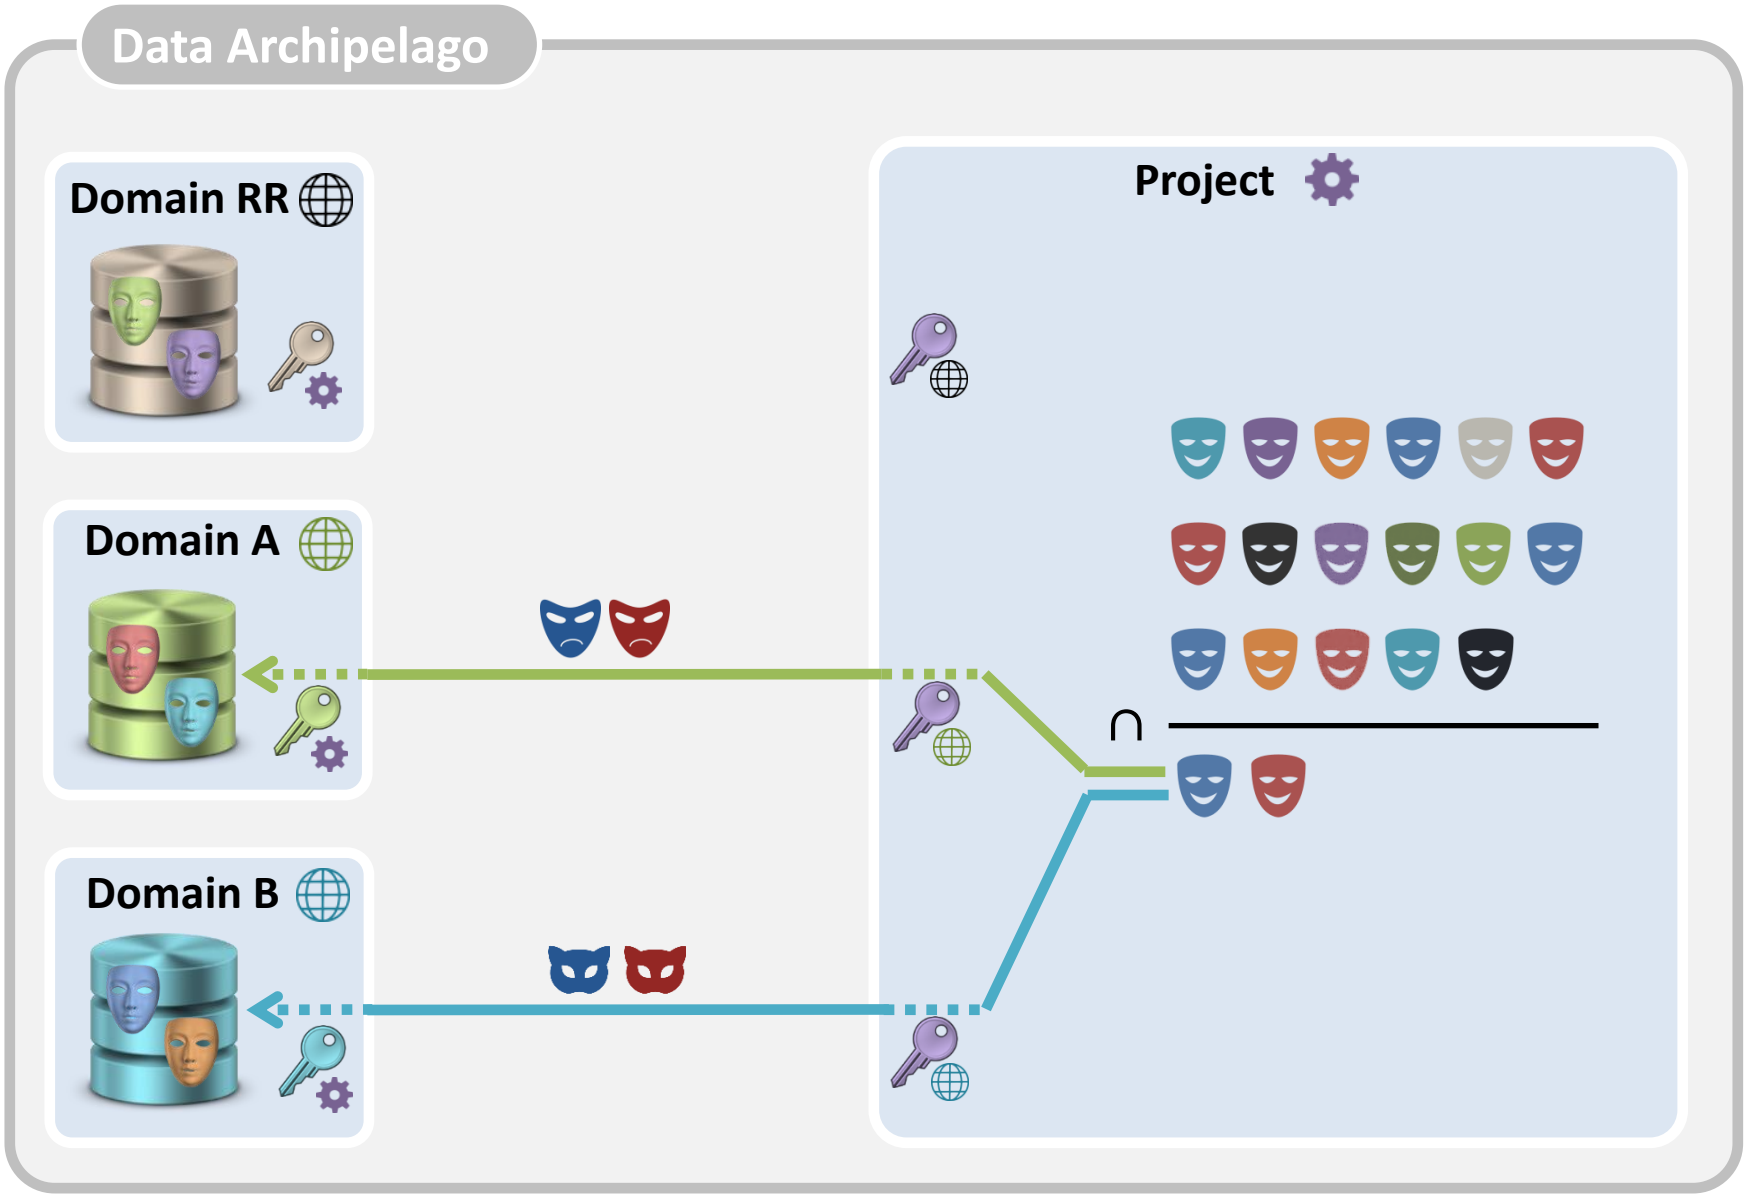

Identifiers & Pseudoniemen

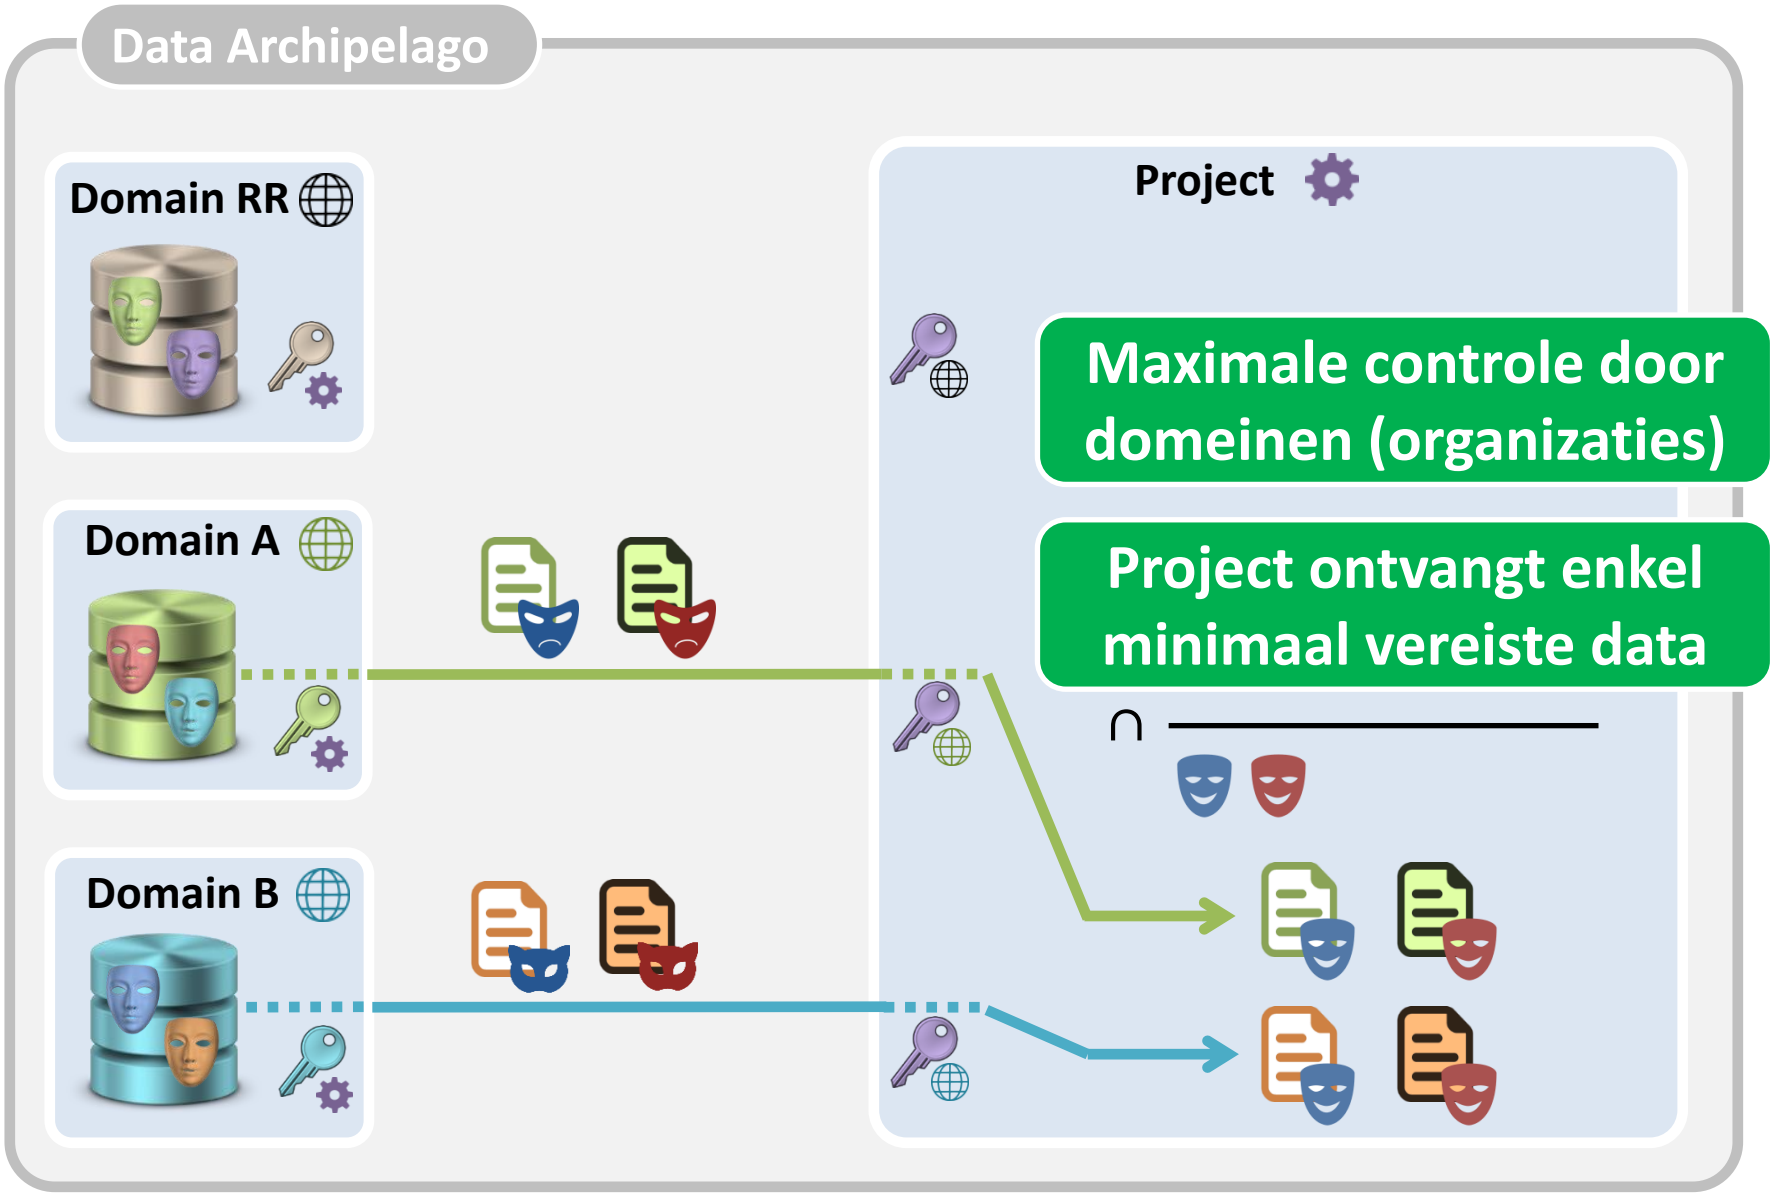

Misbruik


Niemand kan te weten komen dat ik data vraag over meer pseudoniemen
Data Archipelago
Domain RR
Ik leer over en :
YoB ≥ 1990 en wage > 50.000/year
Project
Domain A
Domain B
∩
Zie wetenschappelijk artikel voor details

Linkbaarheid

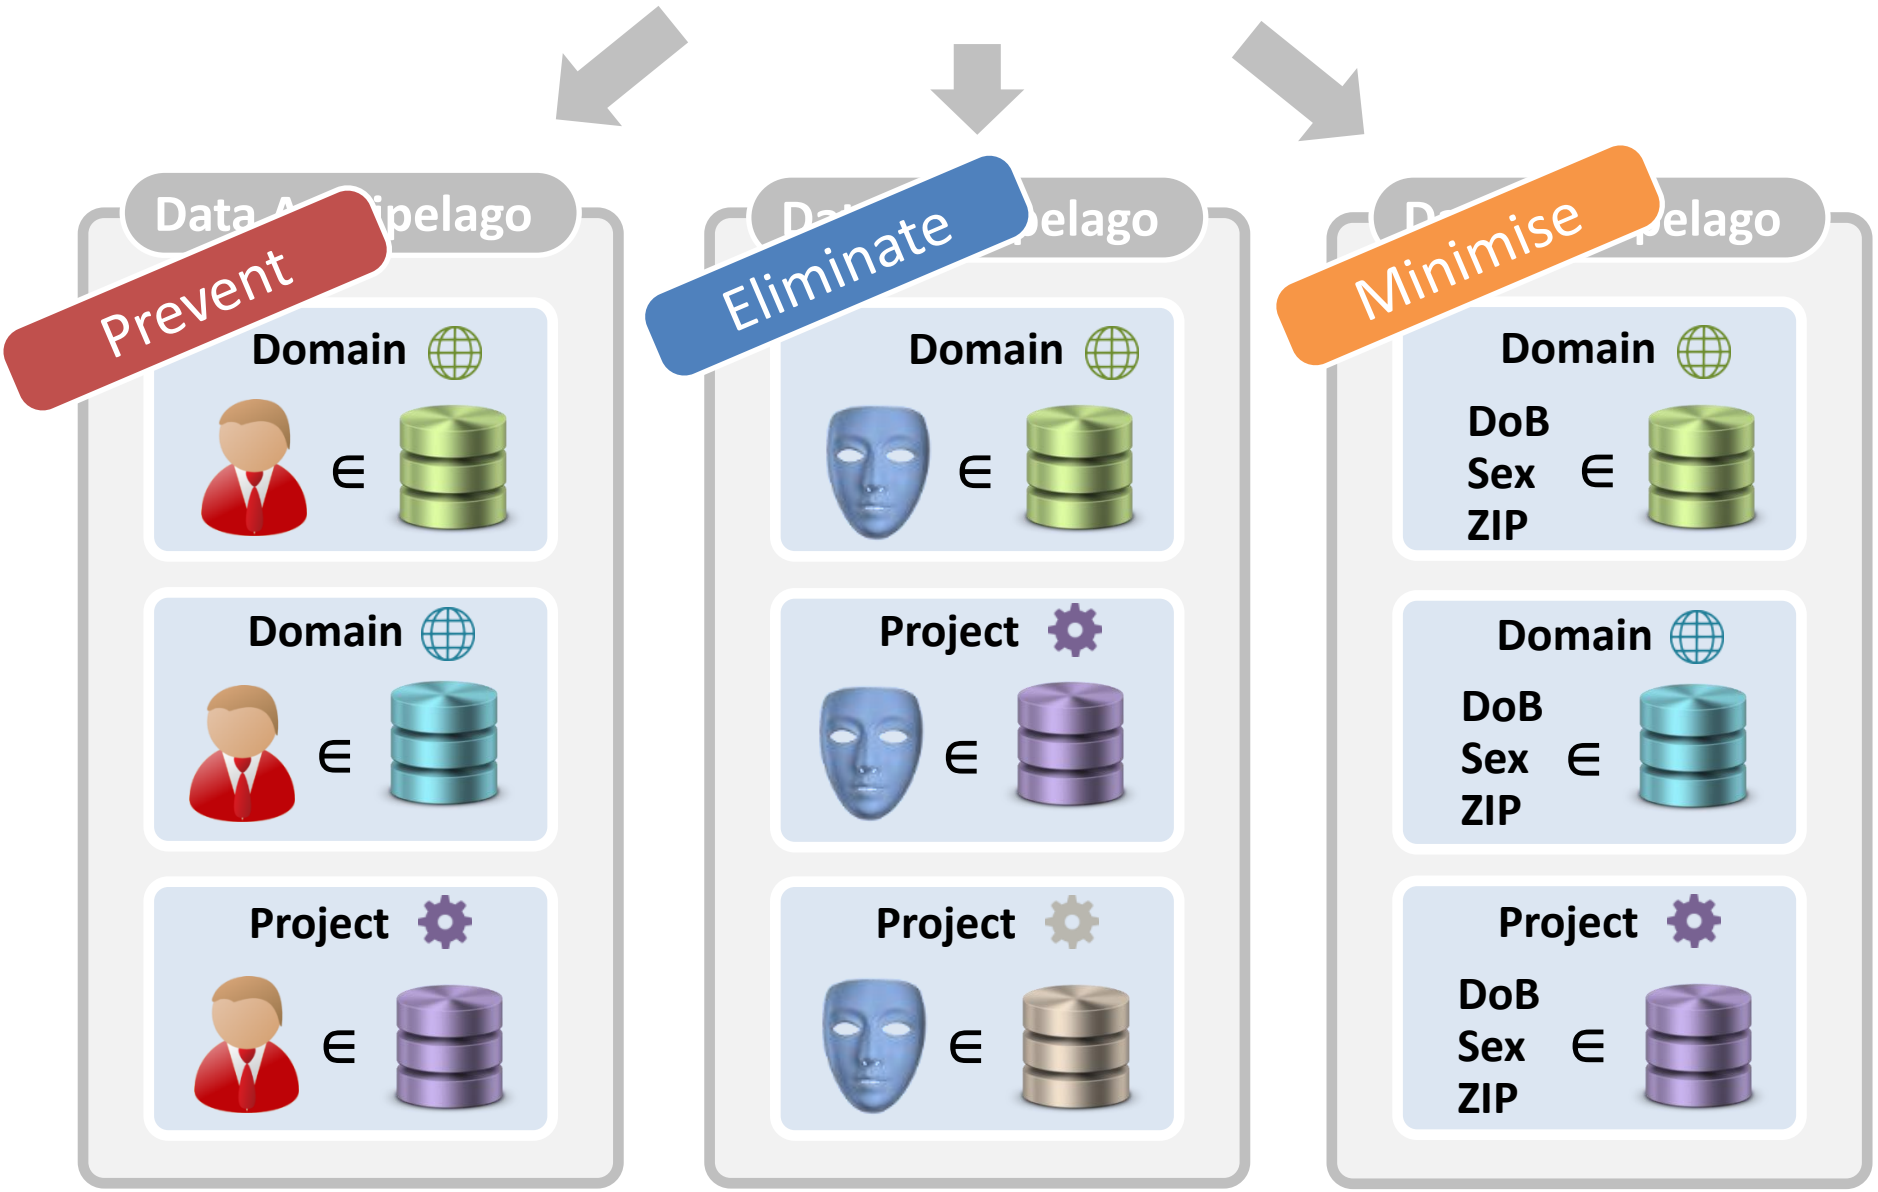

Maximale isolatie

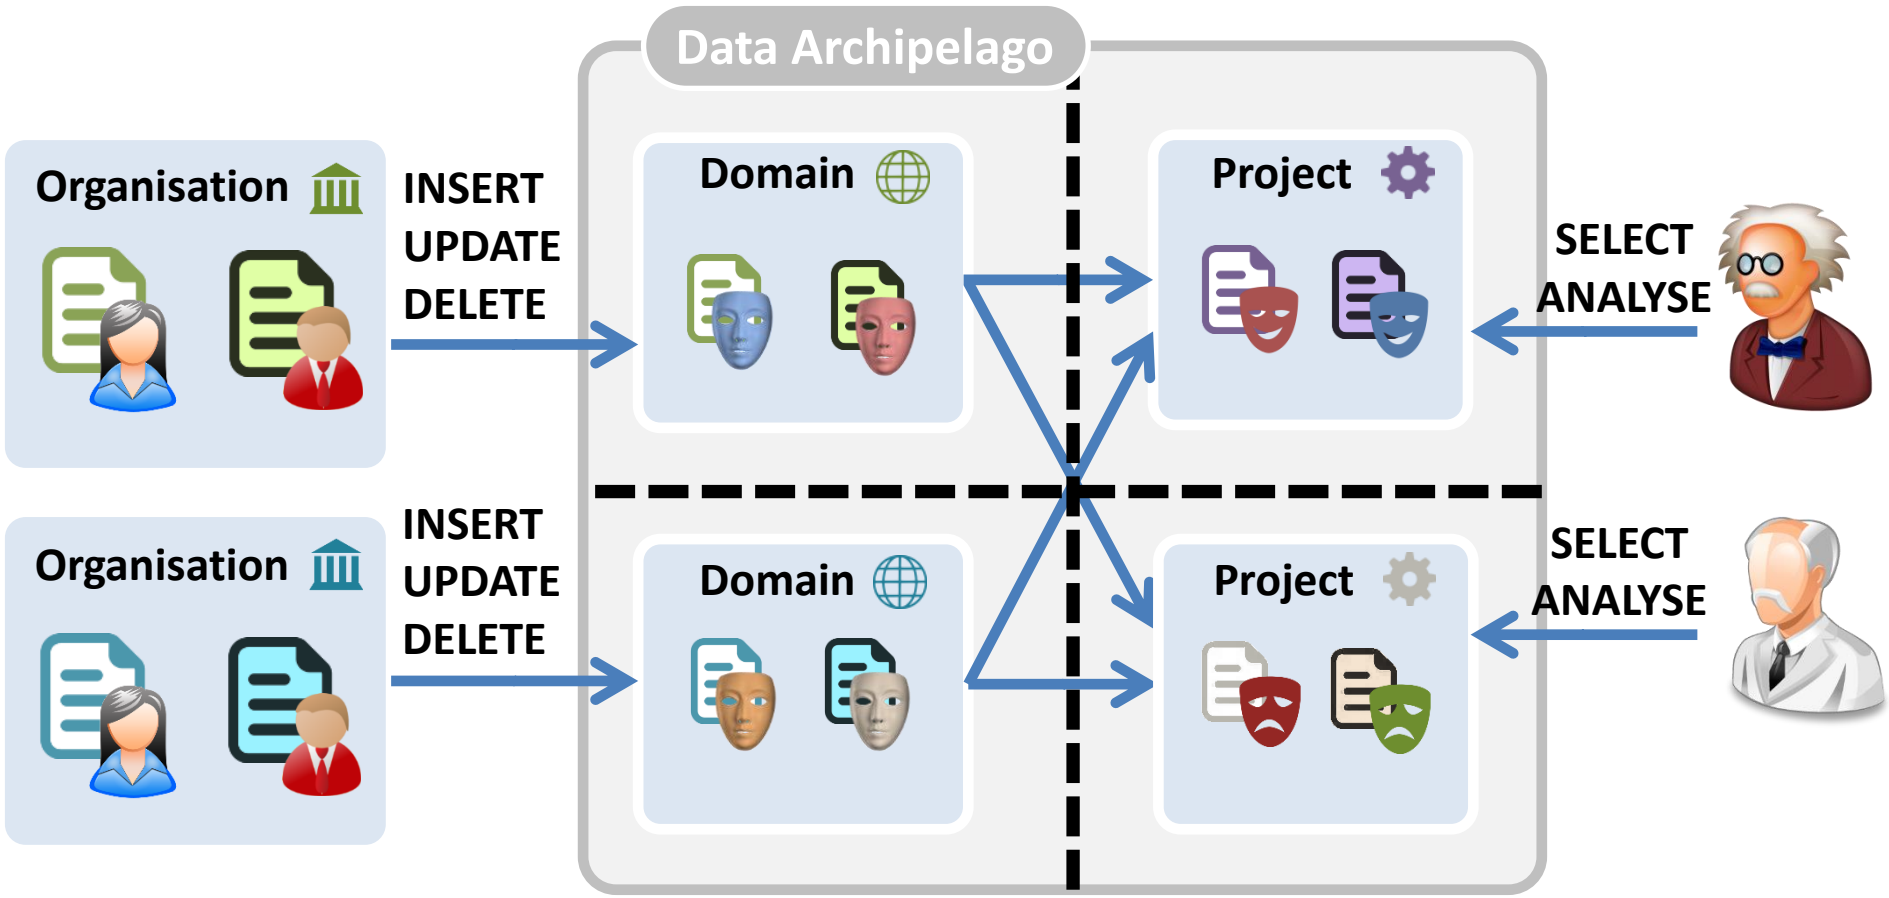

Samengevat

Organisationeel

Organisatie behoudt controle over data

- Beslist welke data naar domain
- Medewerking vereist bij kruisen gegevens in project

Vlot kruisen data

Medewerking betrokken organisaties vereist

Privacy & Data Security

Attribuut linkbaarheid geminimaliseerd

Moeilijker voor aanvaller

Pseudoniem linkbaarheid geëlimineerd

Tenzij crypto sleutels gekend

Pauze

AGENDA

Introductie

Technieken Anonimisatie

- Wat
- Beperkingen

→ Data Archipel

- Concept

- Proof of concept
- Een beetje crypto
- Deanonimisatie
- Sleutelbeheer
- Transparantie
- Small cells

Conclusies

Privacywet

Anonieme gegevens
Onidentificeerbaar

Persoonsgegevens
Identificeerbaar/
Geïdentificeerd

Privacywet niet van toepassing

- Finaliteit
- Proportionaliteit
- Transparantie
- Information security practices
- Recht toegang & correctie
- Expliciete toelating
- Data kwaliteit

Waarschijnlijkheid op identificatie

Kruisen van Persoonsgegevens

Een fictief voorbeeld

Een onderzoeksteam wil medische, financiële en demografische persoonsgegevens analyseren van alle burgers die na 1990 geboren zijn, die zelfstandige in bijberoep zijn met een loon van minstens € 50 000.

Deze gegevens worden echter beheerd door verschillende overheidsbedrijven en moeten dus gekruist worden.

Kan technologie steeds persoonsgegevens converteren naar anonieme gegevens die vervolgens geanalyseerd kunnen worden?

Nee ☹

Wat is er technisch mogelijk binnen het wettelijke kader?

Recap – Data Archipel

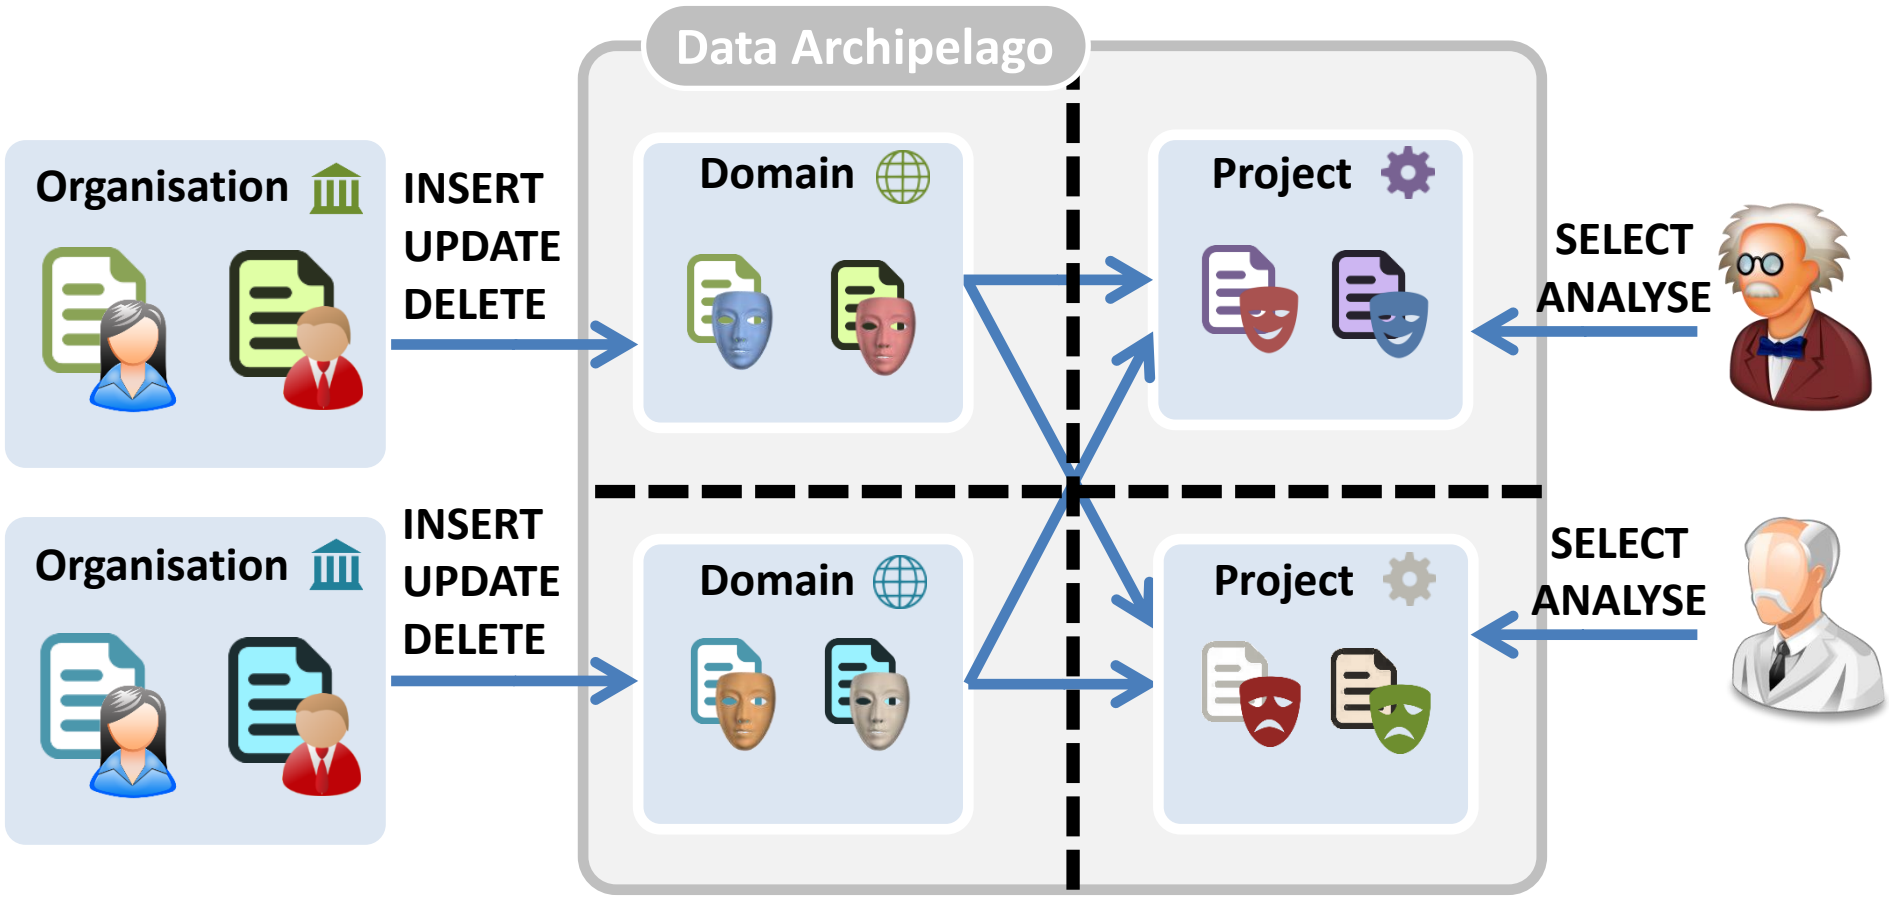

Recap – Data Archipel

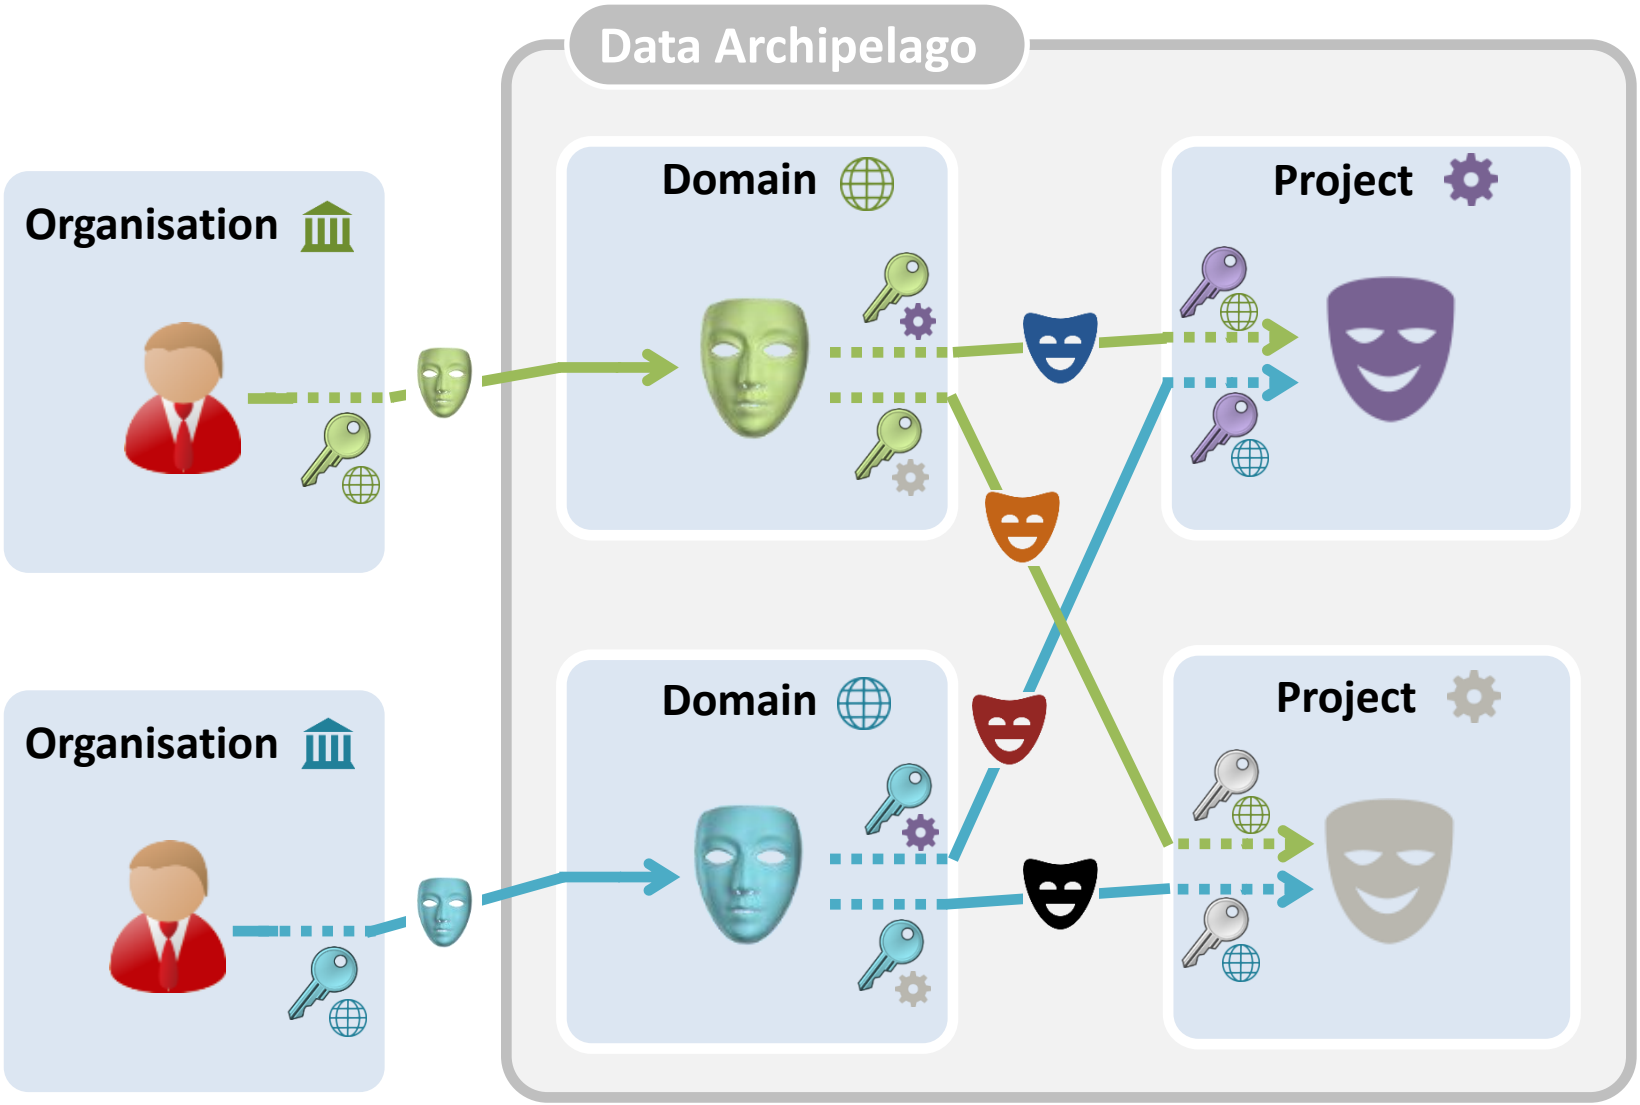

Kruisen van Persoonsgegevens

Een fictief voorbeeld

*Een **onderzoeksteam** wil medische, financiële en demografische persoonsgegevens analyseren van alle **burgers** die na 1990 geboren zijn, die zelfstandige in bijberoep zijn met een loon van minstens € 50 000.*

*Deze gegevens worden echter beheerd door verschillende **overheidsbedrijven** en moeten dus gekruist worden.*

Wetenschapper
Vlot kruisen data

Burger
Respect privacywetgeving

Overheidsorganisatie
Behoudt controle (want verantwoordelijk)

Allen
minimale impact data breach

Proof of concept

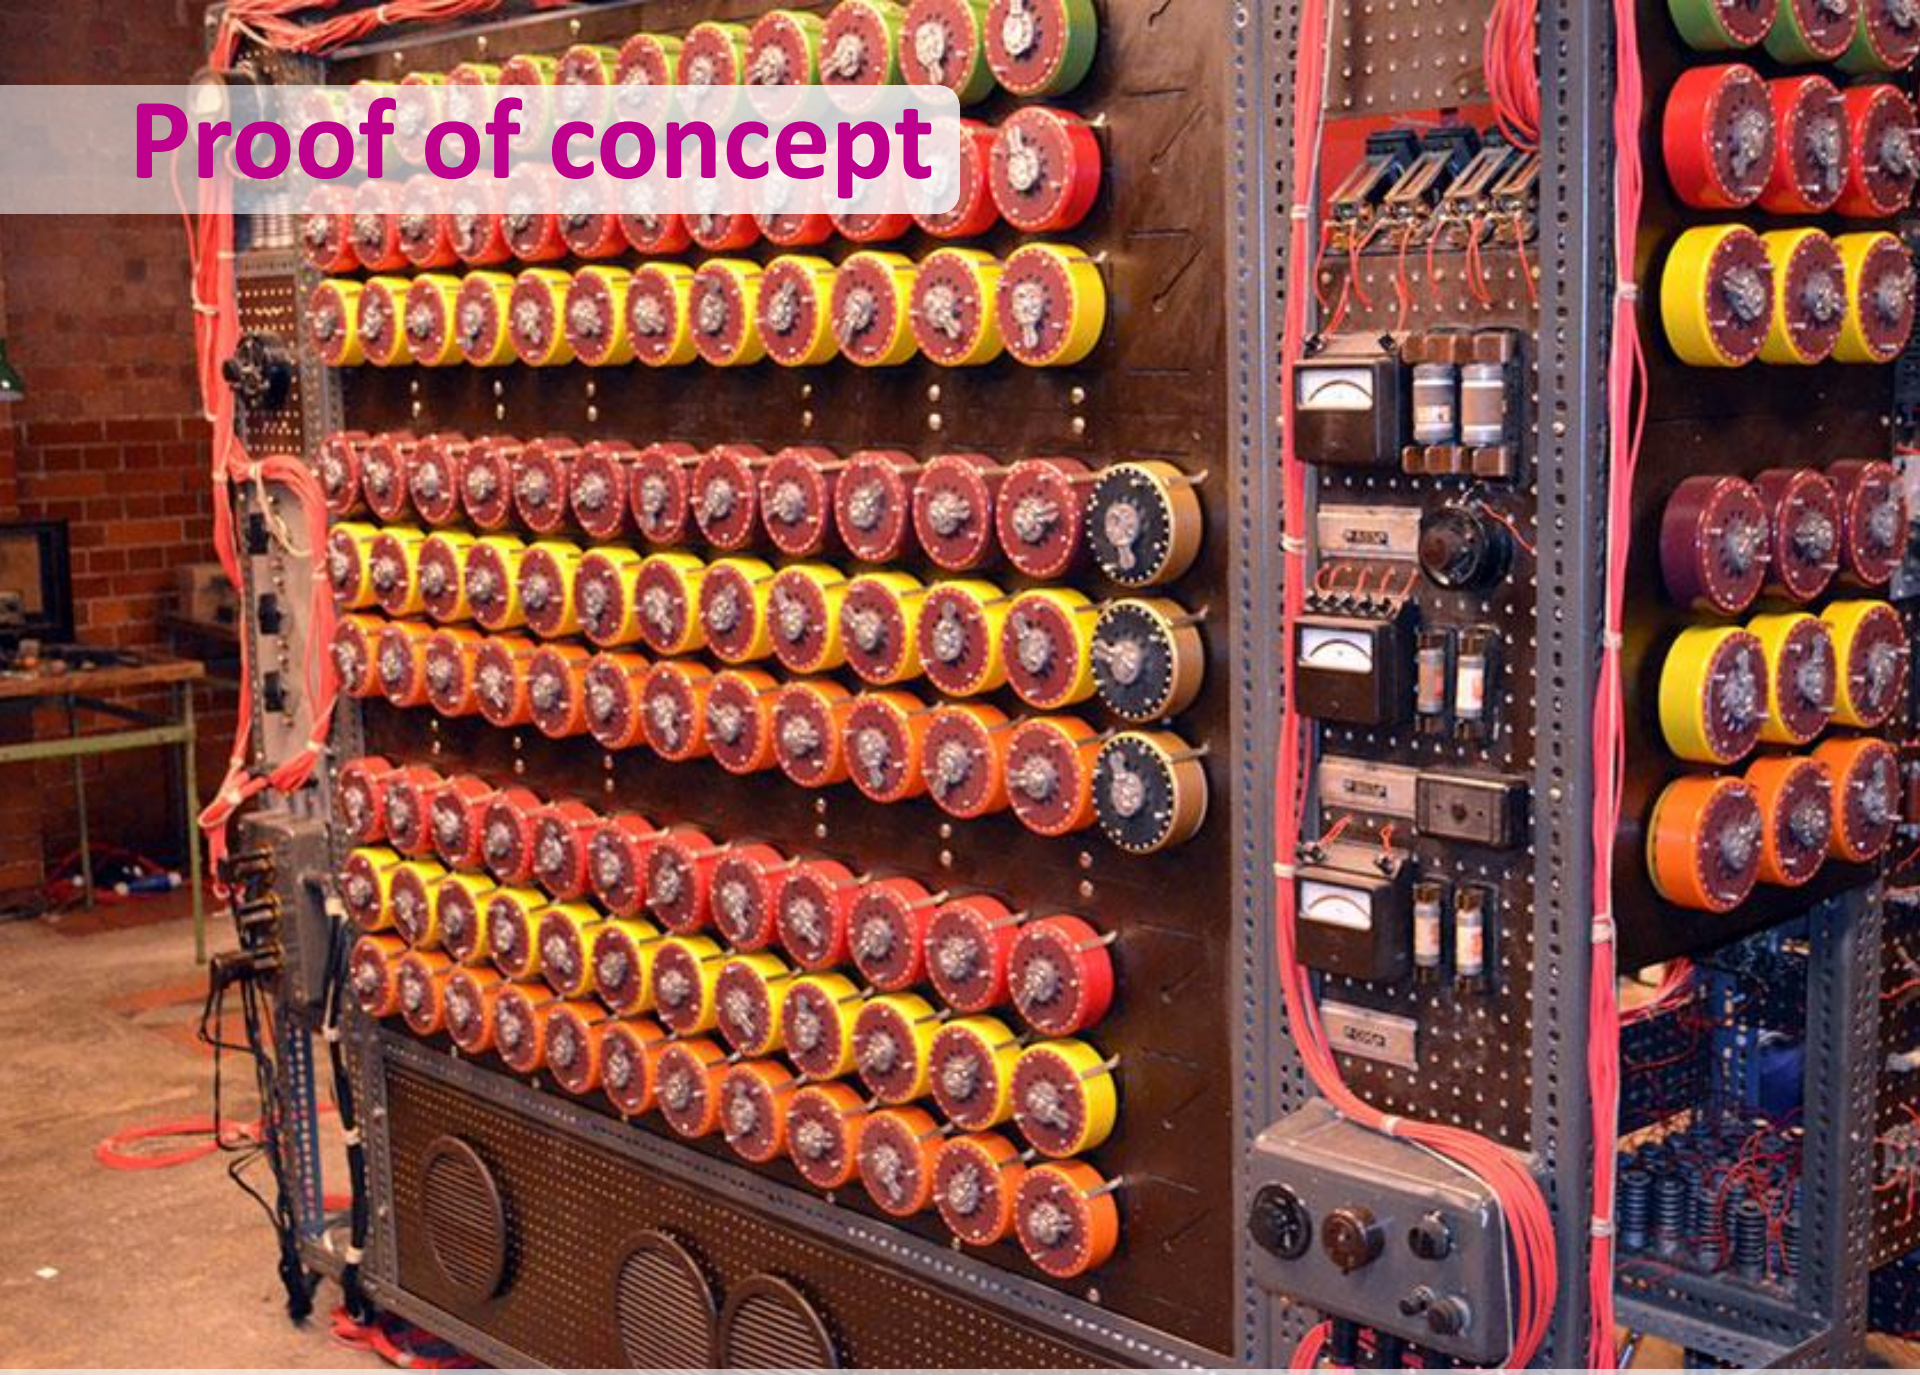

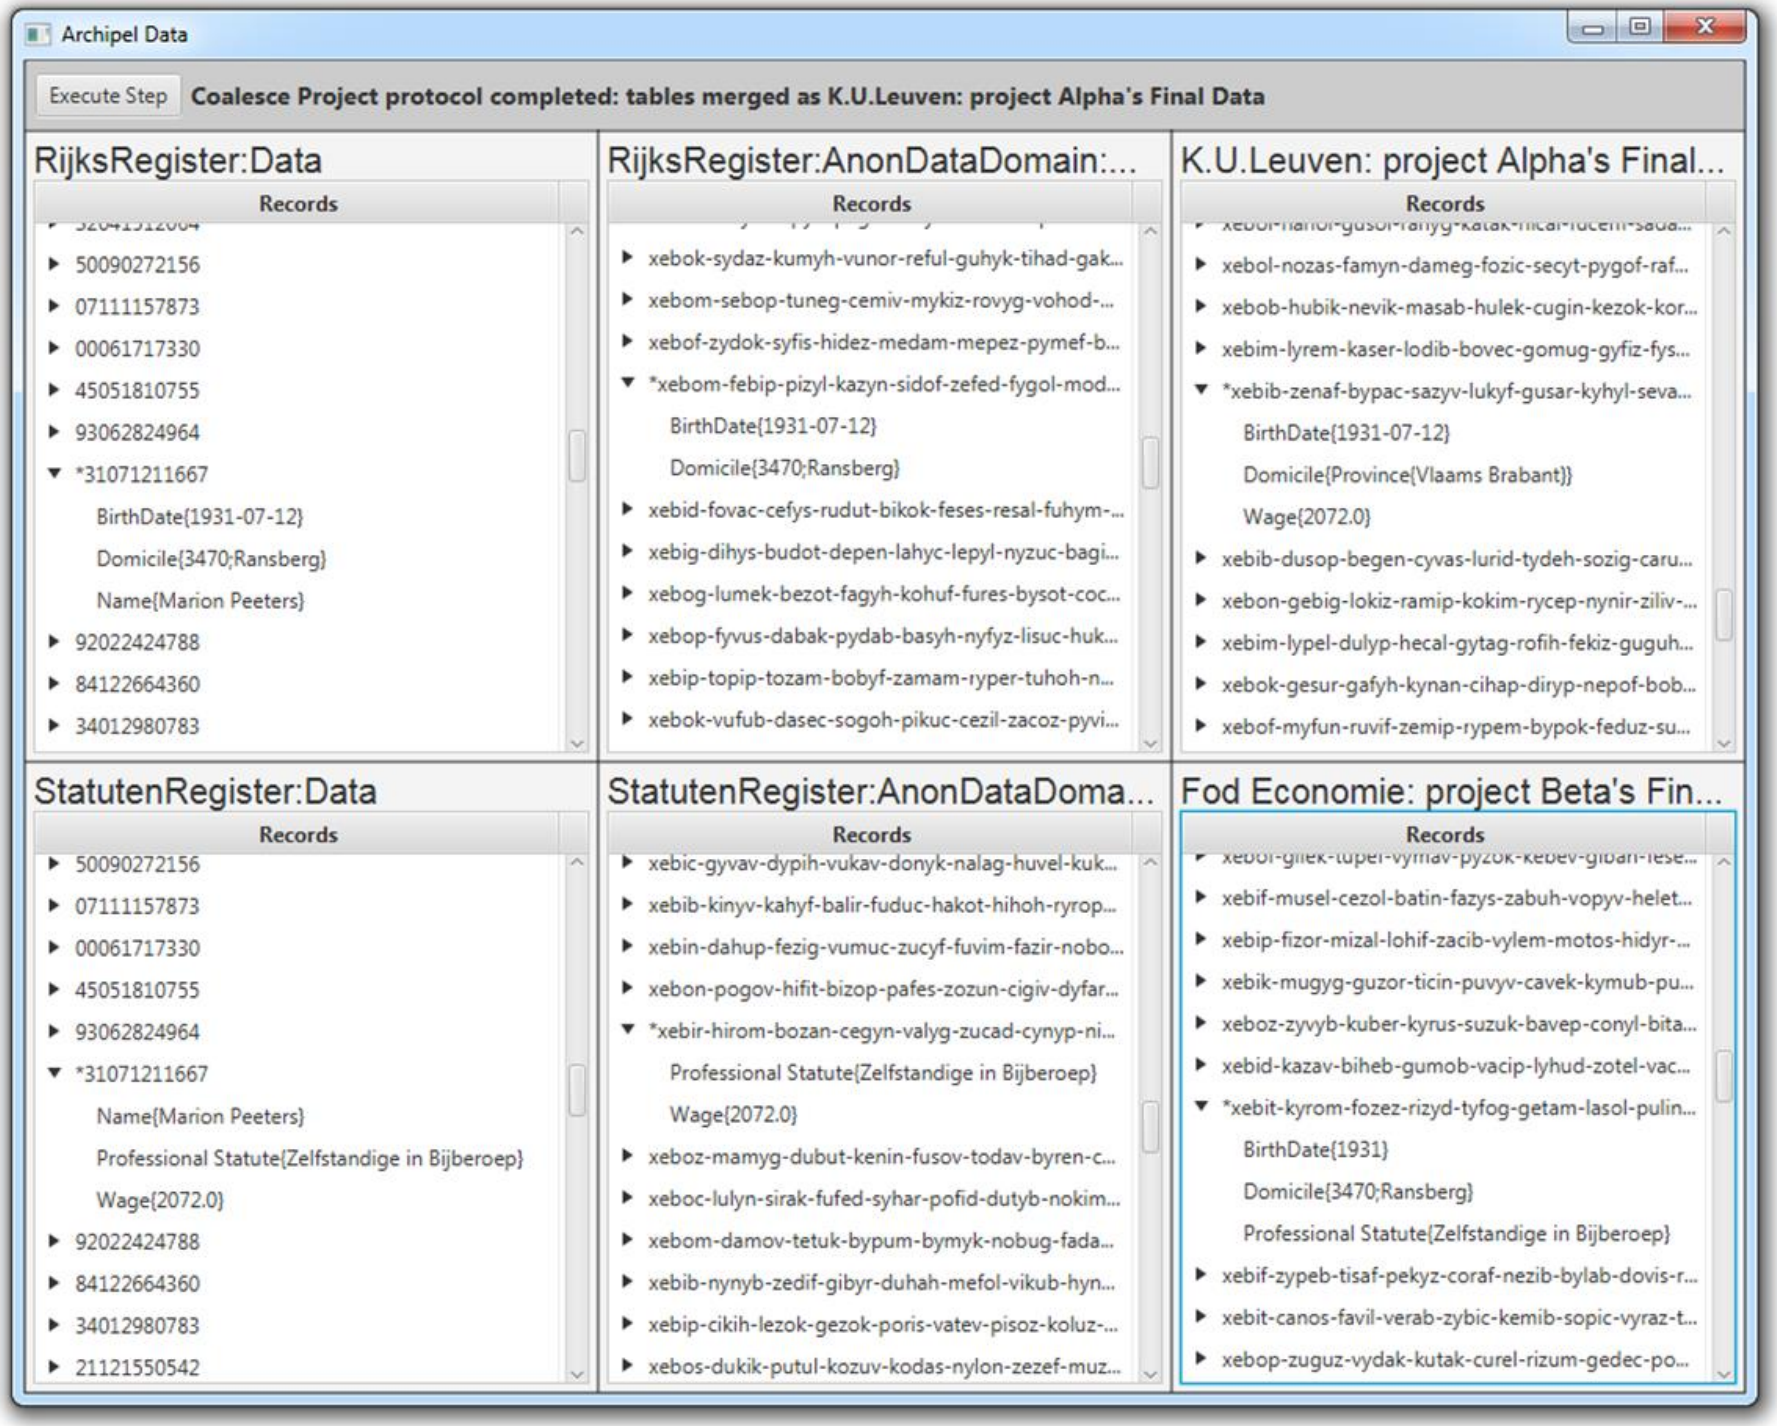
Archipel Data
Execute Step
Coalesce Project protocol completed: tables merged as K.U.Leuven: project Alpha's Final Data
RijksRegister:Data
Records
50090272156
07111157873
00061717330
45051810755
93062824964
*31071211667
BirthDate{1931-07-12}
Domicile{3470;Ransberg}
Name{Marion Peeters}
92022424788
84122664360
34012980783
RijksRegister:AnonDataDomain:...
Records
xebok-sydaz-kumyh-vunor-reful-guhyk-tihad-gak...
xebom-sebop-tuneg-cemiv-mykiz-rovyg-vohod-...
xebof-zydok-syfis-hidez-medam-mepez-pymef-b...
*xebom-febip-pizyl-kazyn-sidof-zefed-fygol-mod...
BirthDate{1931-07-12}
Domicile{3470;Ransberg}
xebid-fovac-cefys-rudut-bikok-feses-resal-fuhym-...
xebig-dihys-budot-depen-lahyc-lepyl-nyzuc-bagi...
xebog-lumek-bezot-fagyh-kohuf-fures-bysot-coc...
xebop-fyvus-dabak-pydab-basyh-nyfyz-lisuc-huk...
xebip-topip-tozam-bobyf-zamam-ryper-tuhoh-n...
xebok-vufub-dasec-sogoh-pikuc-cezil-zacoz-pyvi...
K.U.Leuven: project Alpha's Final...
Records
xebol-nozas-famyn-dameg-fozic-secyt-pygof-raf...
xebob-hubik-nevik-masab-hulek-cugin-kezok-kor...
xebim-lyrem-kaser-lodib-bovec-gomug-gyfiz-fys...
*xebib-zenaf-bypac-sazyv-lukyf-gusar-kyhyl-seva...
BirthDate{1931-07-12}
Domicile{Province{Vlaams Brabant}}
Wage{2072.0}
xebib-dusop-begen-cyvas-lurid-tydeh-sozig-caru...
xebon-gebig-lokiz-ramip-kokim-rycep-nynir-ziliv-...
xebim-lypel-dulyp-hecal-gytag-rofih-fekiz-guguh...
xebok-gesur-gafyh-kynan-cihap-diryp-nepof-bob...
xebof-myfun-ruvif-zemip-rypem-bypok-feduz-su...
StatutenRegister:Data
Records
50090272156
07111157873
00061717330
45051810755
93062824964
*31071211667
Name{Marion Peeters}
Professional Statute{Zelfstandige in Bijberoep}
Wage{2072.0}
92022424788
84122664360
34012980783
21121550542
StatutenRegister:AnonDataDoma...
Records
xebic-gyvav-dypih-vukav-donyk-nalag-huvel-kuk...
xebib-kinyv-kahyf-balir-fuduc-hakot-hihoh-ryrop...
xebin-dahup-fezig-vumuc-zucyf-fuvim-fazir-nobo...
xebon-pogov-hifit-bizop-pafes-zozun-cigiv-dyfar...
*xebir-hirom-bozan-cegyn-valyg-zucad-cynyp-ni...
Professional Statute{Zelfstandige in Bijberoep}
Wage{2072.0}
xeboz-mamyg-dubut-kenin-fusov-todav-byren-c...
xeboc-lulyn-sirak-fufed-syhar-pofid-dutyb-nokim...
xebom-damov-tetuk-bypum-bymyk-nobug-fada...
xebib-nynyb-zedif-gibyr-duhah-mefol-vikub-hyn...
xebip-cikih-lezok-gezok-poris-vatev-pisoz-koluz-...
xebos-dukik-putul-kozuv-kodas-nylon-zezef-muz...
Fod Economie: project Beta's Fin...
Records
xebif-musel-cezol-batin-fazys-zabuh-vopyv-helet...
xebip-fizor-mizal-lohif-zacib-vylem-motos-hidyr-...
xebik-mugyg-guzor-ticin-puvyv-cavek-kymub-pu...
xeboz-zyvyb-kuber-kyrus-suzuk-bavep-conyl-bita...
xebid-kazav-biheb-gumob-vacip-lyhud-zotel-vac...
*xebit-kyrom-fozez-rizyd-tyfog-getam-lasol-pulin...
BirthDate{1931}
Domicile{3470;Ransberg}
Professional Statute{Zelfstandige in Bijberoep}
xebif-zypeb-tisaf-pekyz-coraf-nezib-bylab-dovis-r...
xebit-canos-favil-verab-zybic-kemib-sopic-vyraz-t...
xebop-zuguz-vydak-kutak-curel-rizum-gedec-po...

Proof-of-Concept

Het theoretisch model werkt ook in de praktijk

Performance pseudonym conversion

PC Windows 7 Enterprise (64bit) op één 2,66Ghz Intel i5 core

RSA		
Key size	One operation	Ops / hour
1536 bit	58ms	62070
2048 bit	135ms	26700
3072 bit	440ms	8180

EC		
Key size	One operation	Ops / hour
192 bit	0,4ms	9 million
224 bit	0,6ms	6 million
256 bit	0,7-0,8ms	4-5 million

Een beetje cryptografie

Smals
ICT for society

Concept › POC › **Crypto** › Deanonimisatie › Sleutelbeheer › Transparantie › Small cells

Elliptische Krommen (EC)

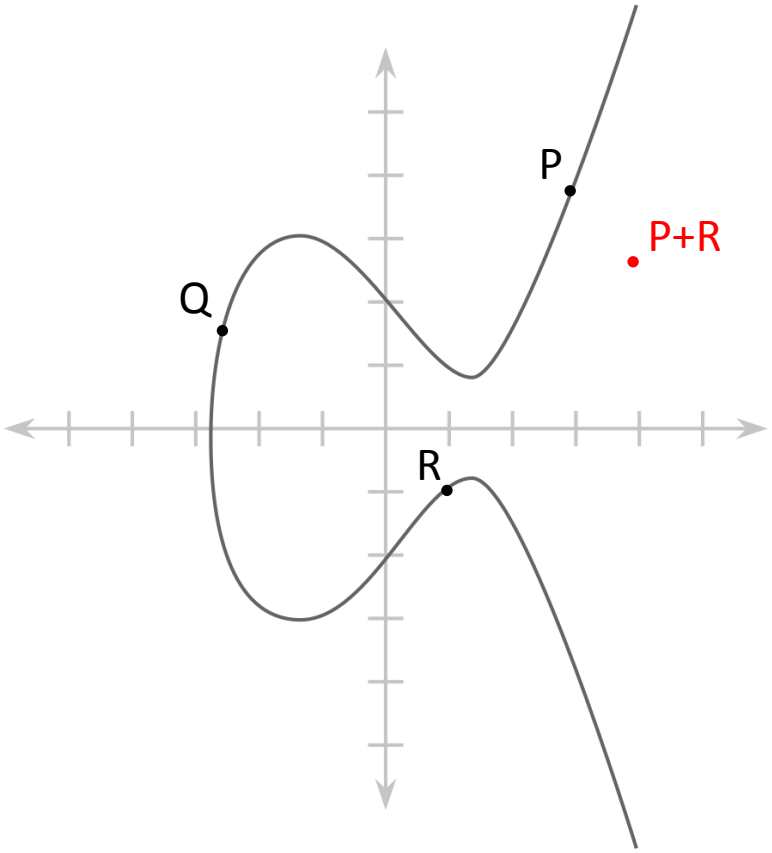

$$P = (x_P, y_P)$$
$$Q = (x_Q, y_Q)$$
$$R = (x_R, y_R)$$

De curve is een groep
We willen een bewerking (+) zodat telkens $P + R \in$ curve

Wat werk niet:
$P + R = (x_P + x_R, y_P + y_R)$

Geschiedenis

- Voorgesteld in 1985 door Koblitz & Miller
- Wijdverspreid sinds 2004 – 2005
- Graduele shift van RSA naar EC (want efficiënter)

[M15a, M15b]

Elliptische Krommen (EC)

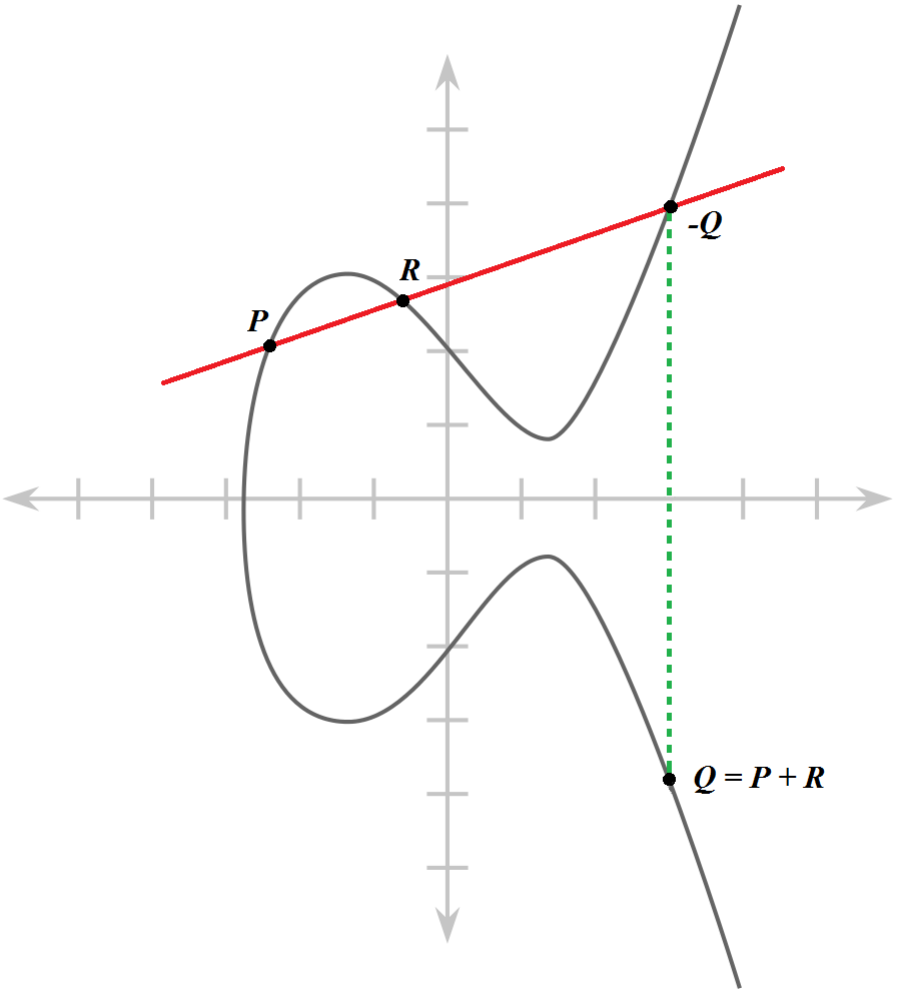

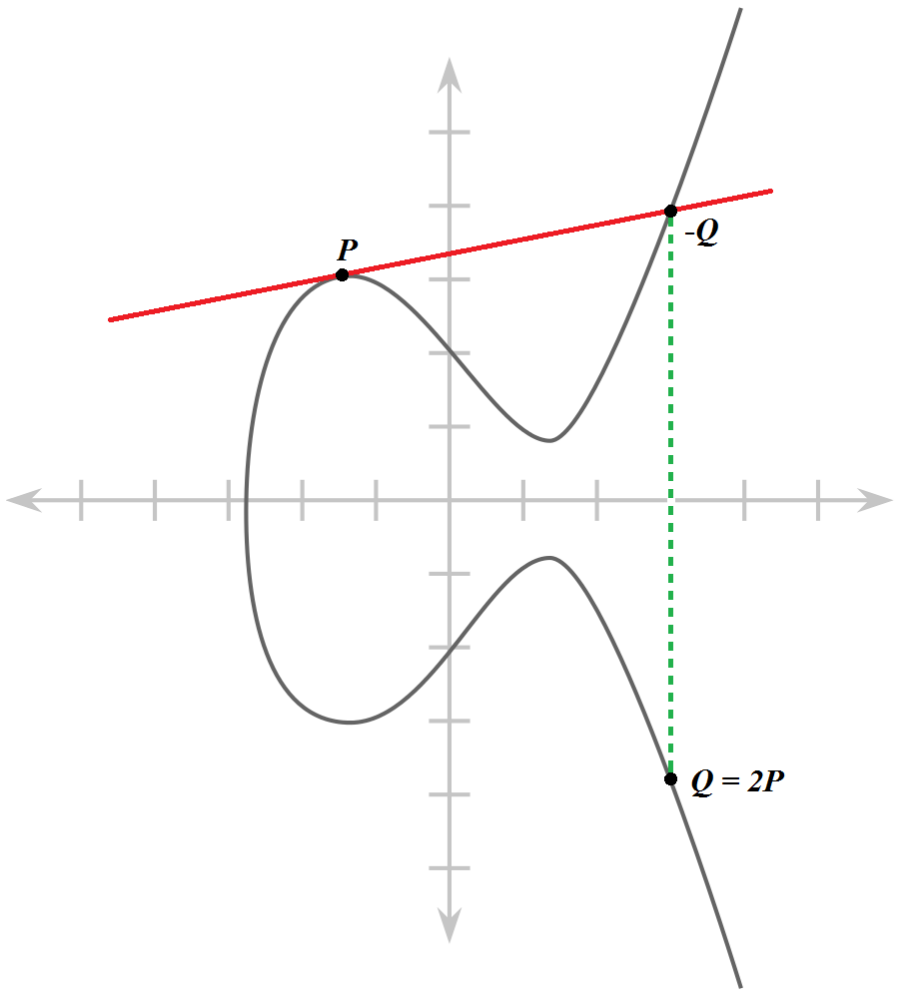

Elliptische Krommen (EC)

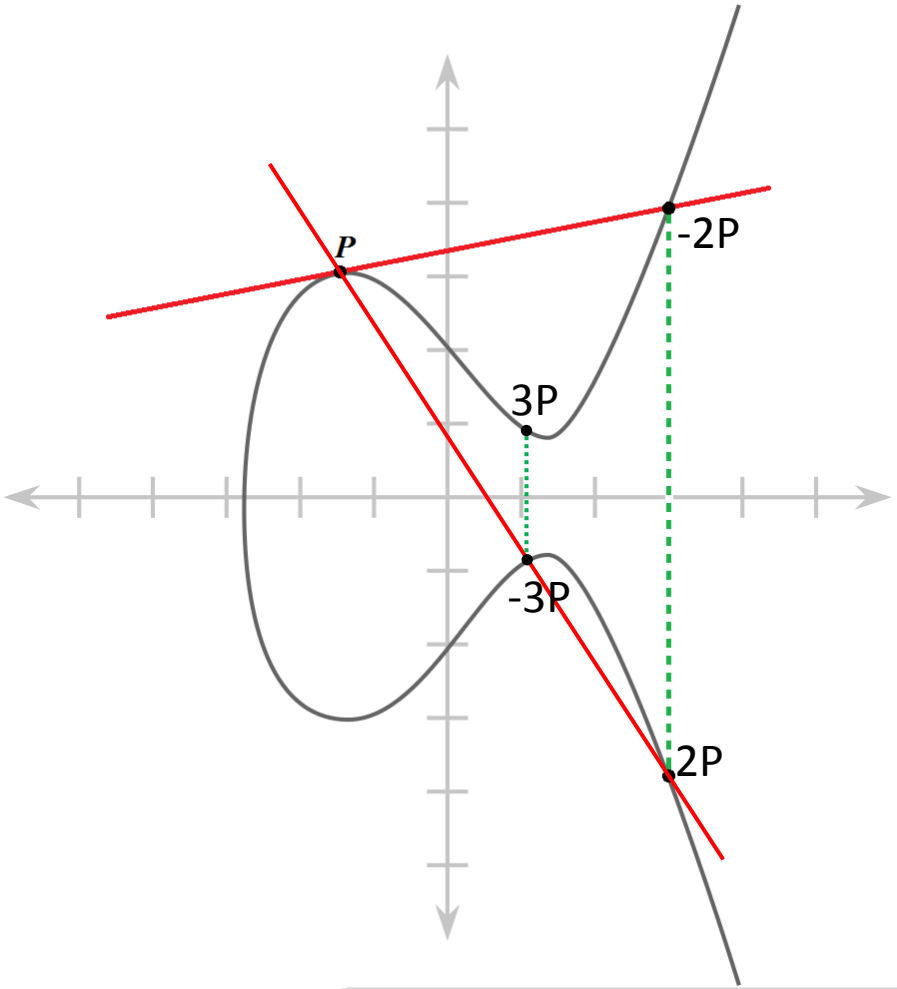

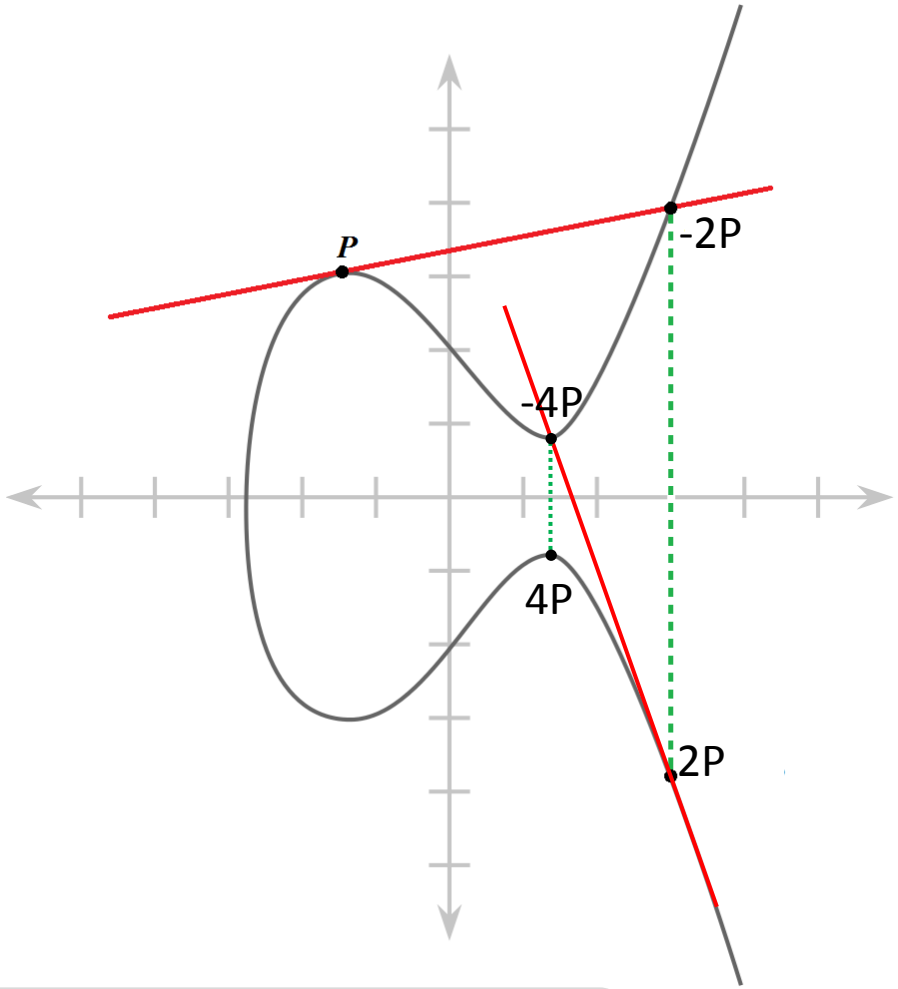

Easy: $Q \leftarrow n \cdot P = \underbrace{P + P + \cdots + P}_{n\ times}$ $\quad n \in \mathbb{Z}$

Hard: $n \leftarrow P, Q$

Central Idea

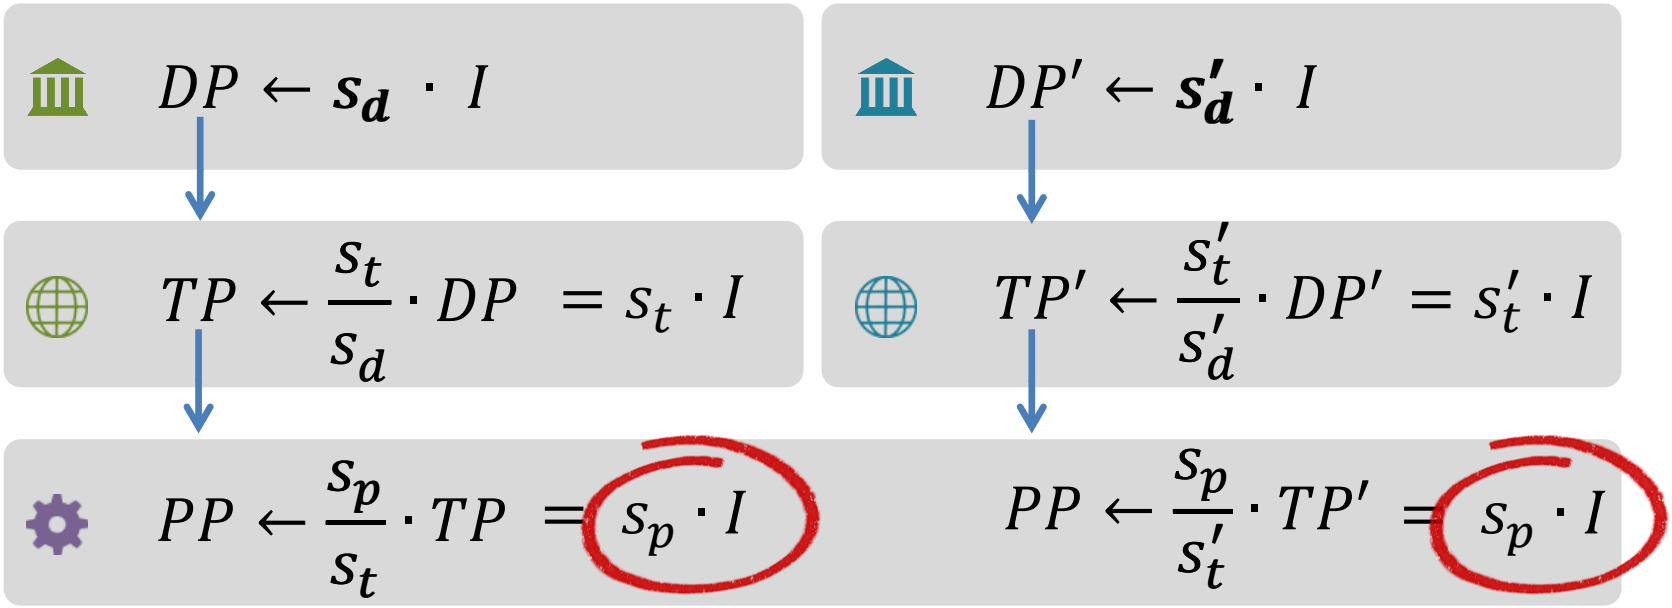

Easy: $Q \leftarrow n \cdot P = \underbrace{P + P + \cdots + P}_{n \text{ times}}$ $n \in \mathbb{Z}$

Hard: $n \leftarrow P, Q$

Smals
ICT for society

Deanonimisatie

Fraudebestrijding

Onderzoeker moet in staat zijn verdacht gedrag te detecteren

Onderzoeker mag betrokken burger niet kunnen identificeren

Enkel een specifieke autoriteit mag een pseudoniem kunnen linken aan burger

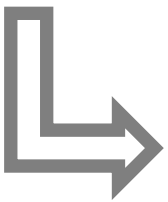

Geïntegreerde & flexibele oplossing

Org. deanonimiseert

1

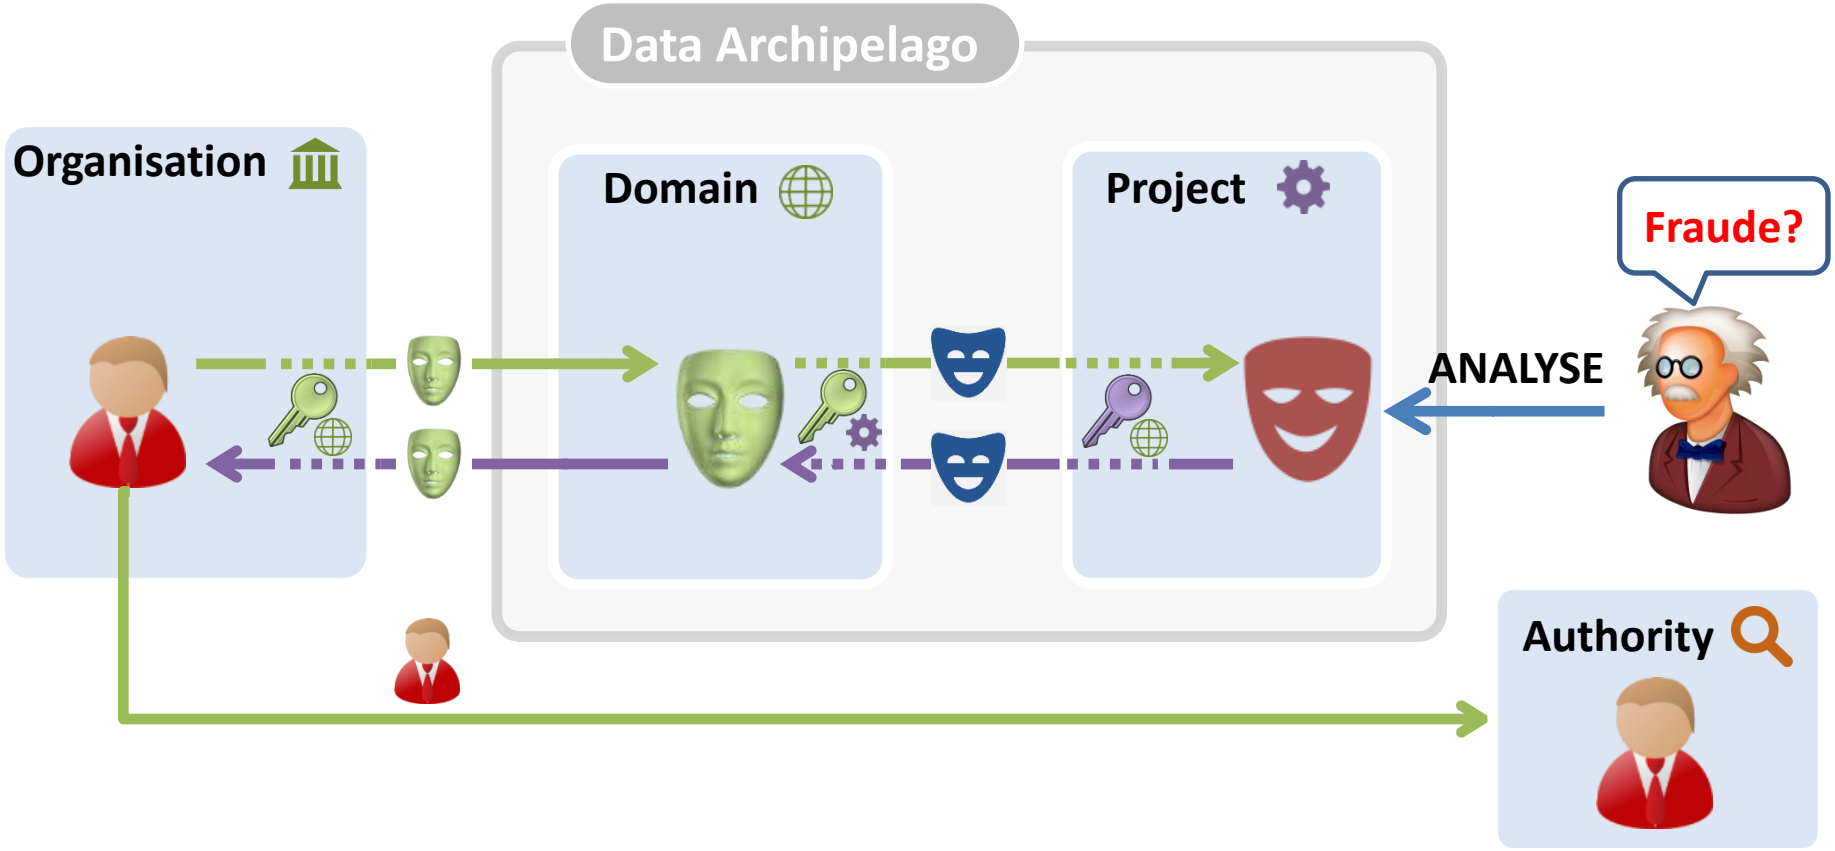

Betrokken organisatie leert de identiteit van de burger en neemt verdere stappen

Geen org. betrokken

2

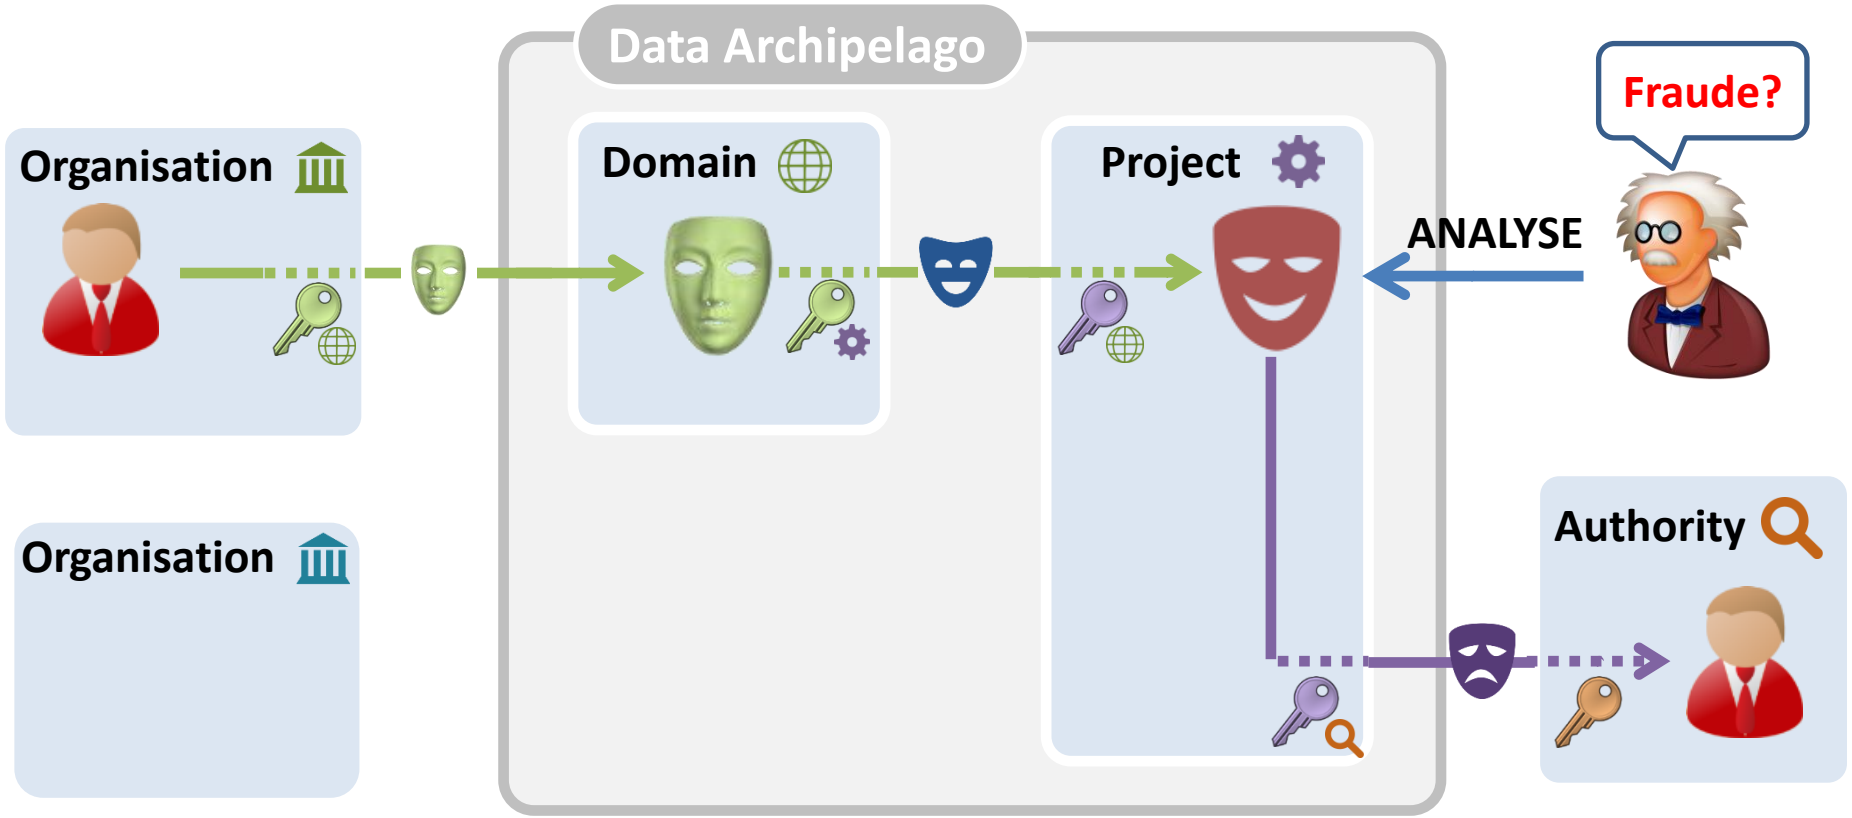

Deanonimisatie gebeurt zonder medeweten van betrokken organisaties
Autoriteit neemt verdere stappen

Eén org. keurt goed, maar leert identiteit burger niet

3

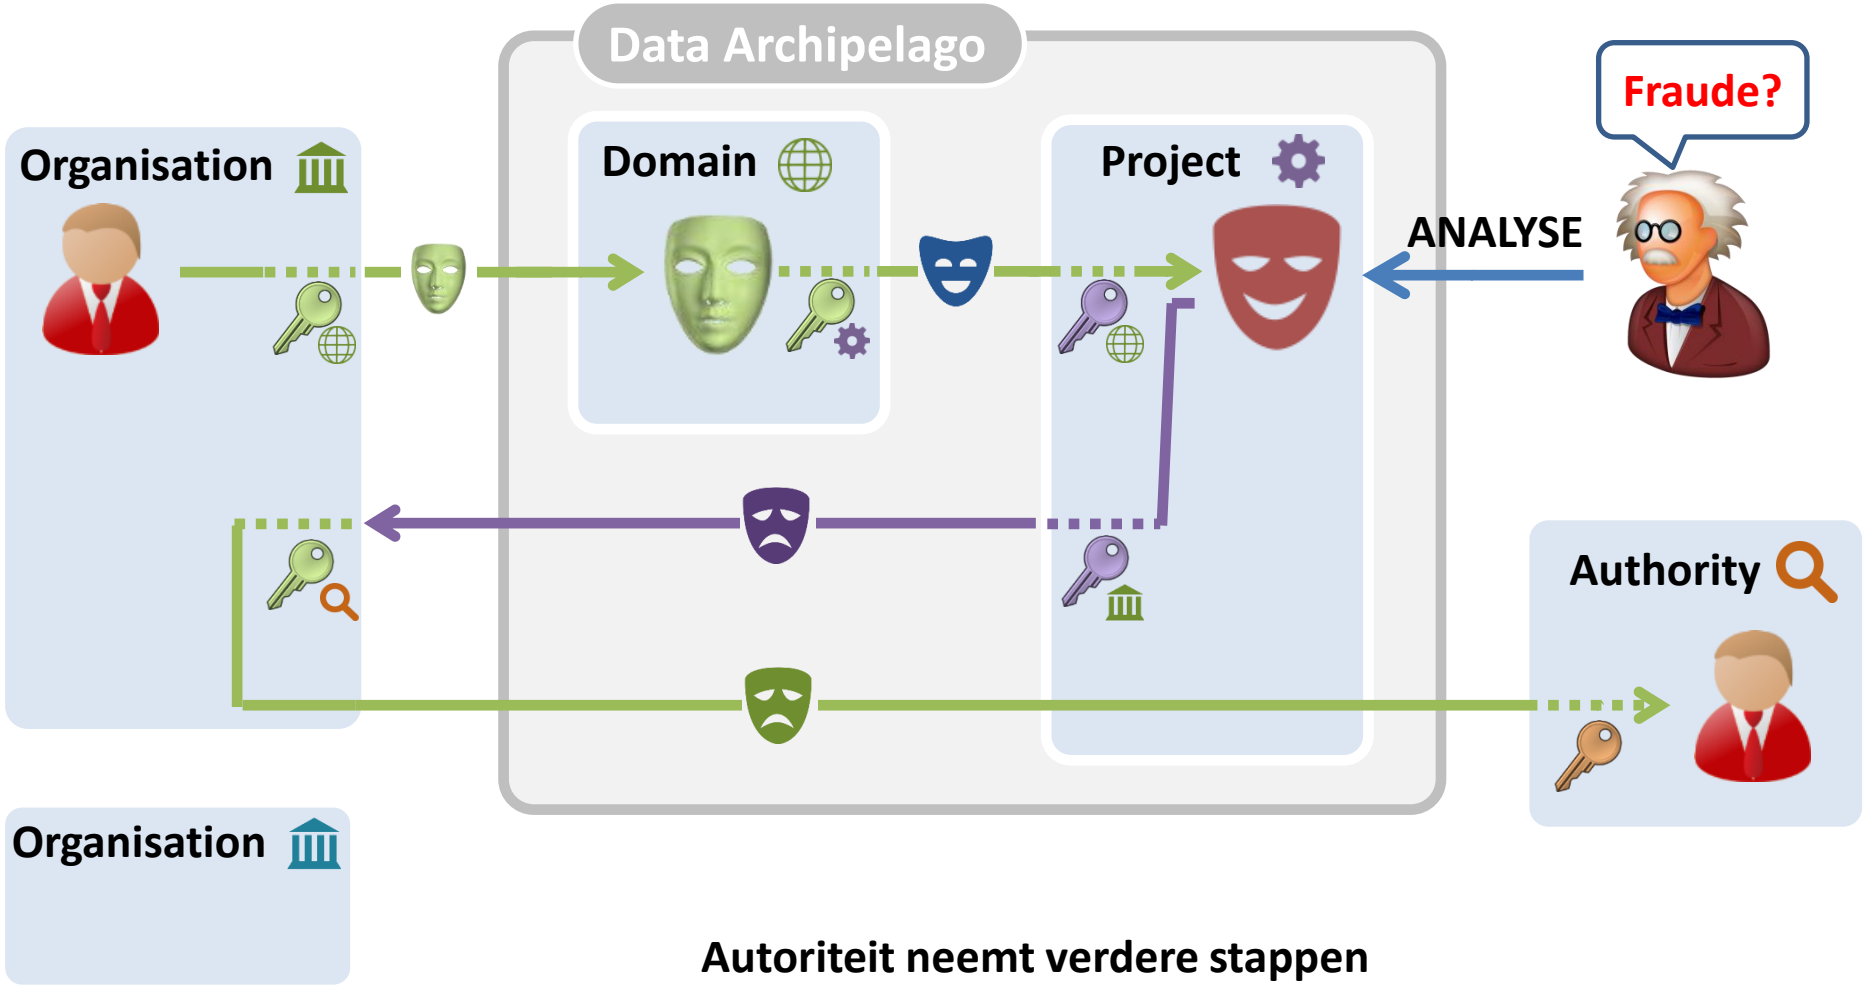

Autoriteit neemt verdere stappen
Betrokken organisaties leren de identiteit betrokken burger niet
Eén betrokken organisatie keurt de deanonimisatie goed

Meerdere orgs. keuren goed zonder identiteit te leren

4

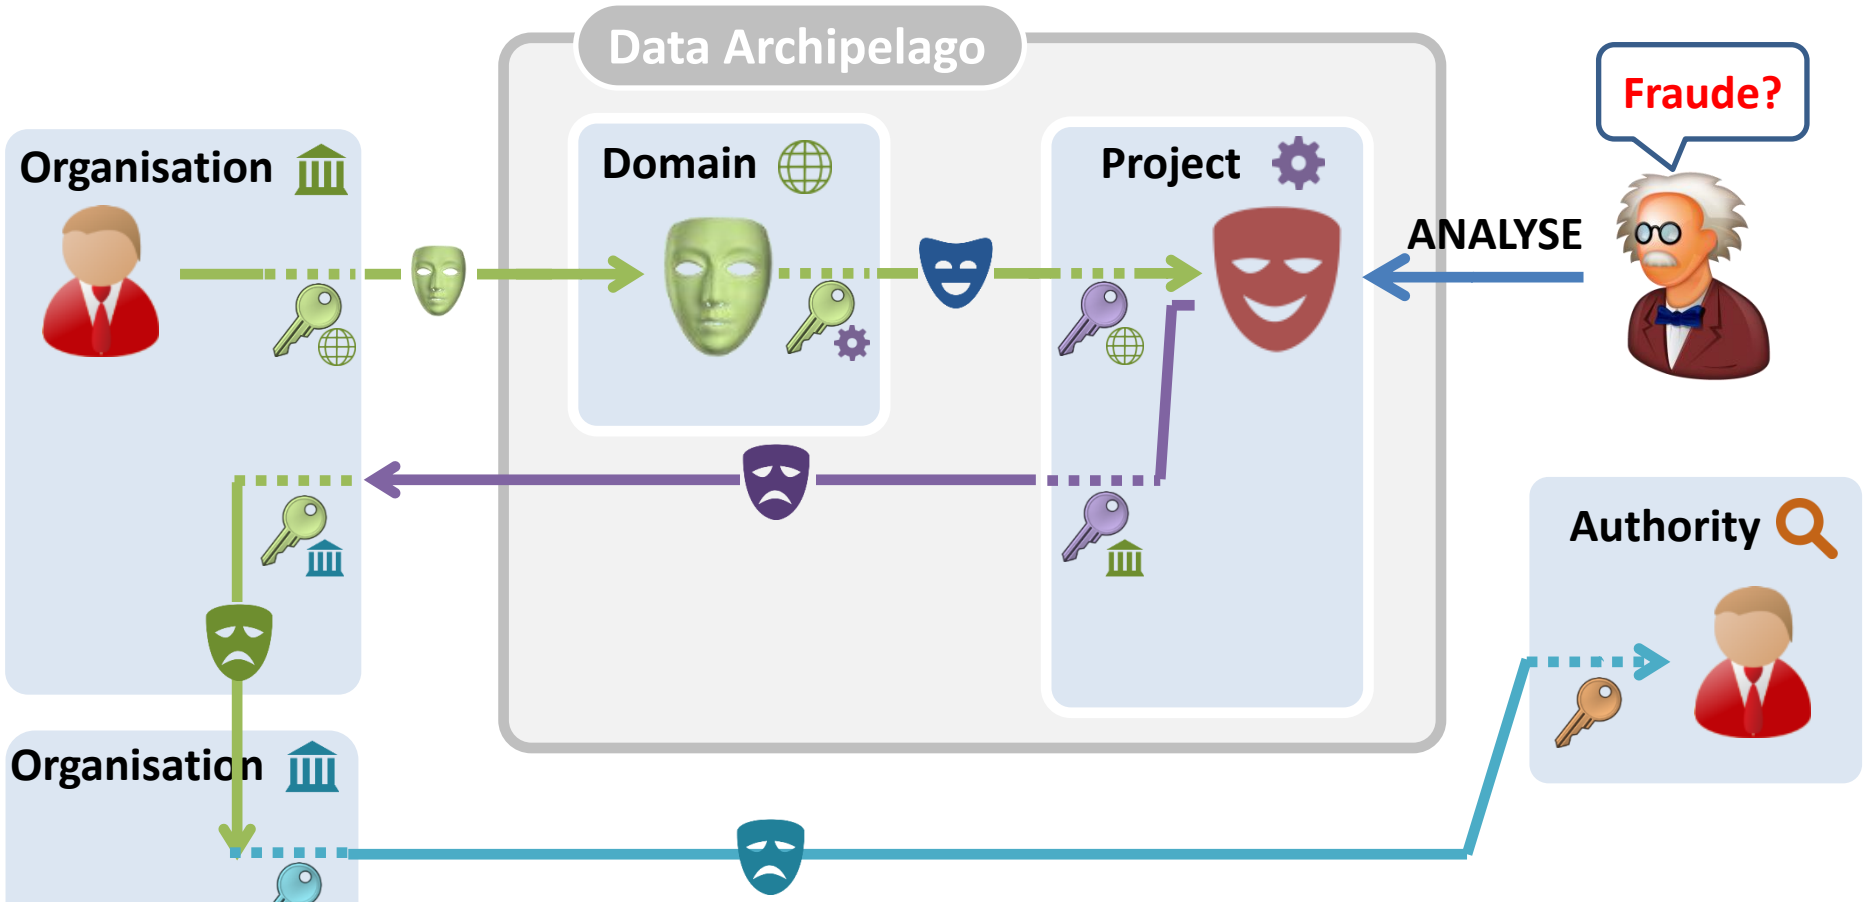

Autoriteit neemt verdere stappen
Betrokken organisaties leren de identiteit van de burger niet
Meerdere betrokken organisaties keuren deanonimisatie goed

Variaties

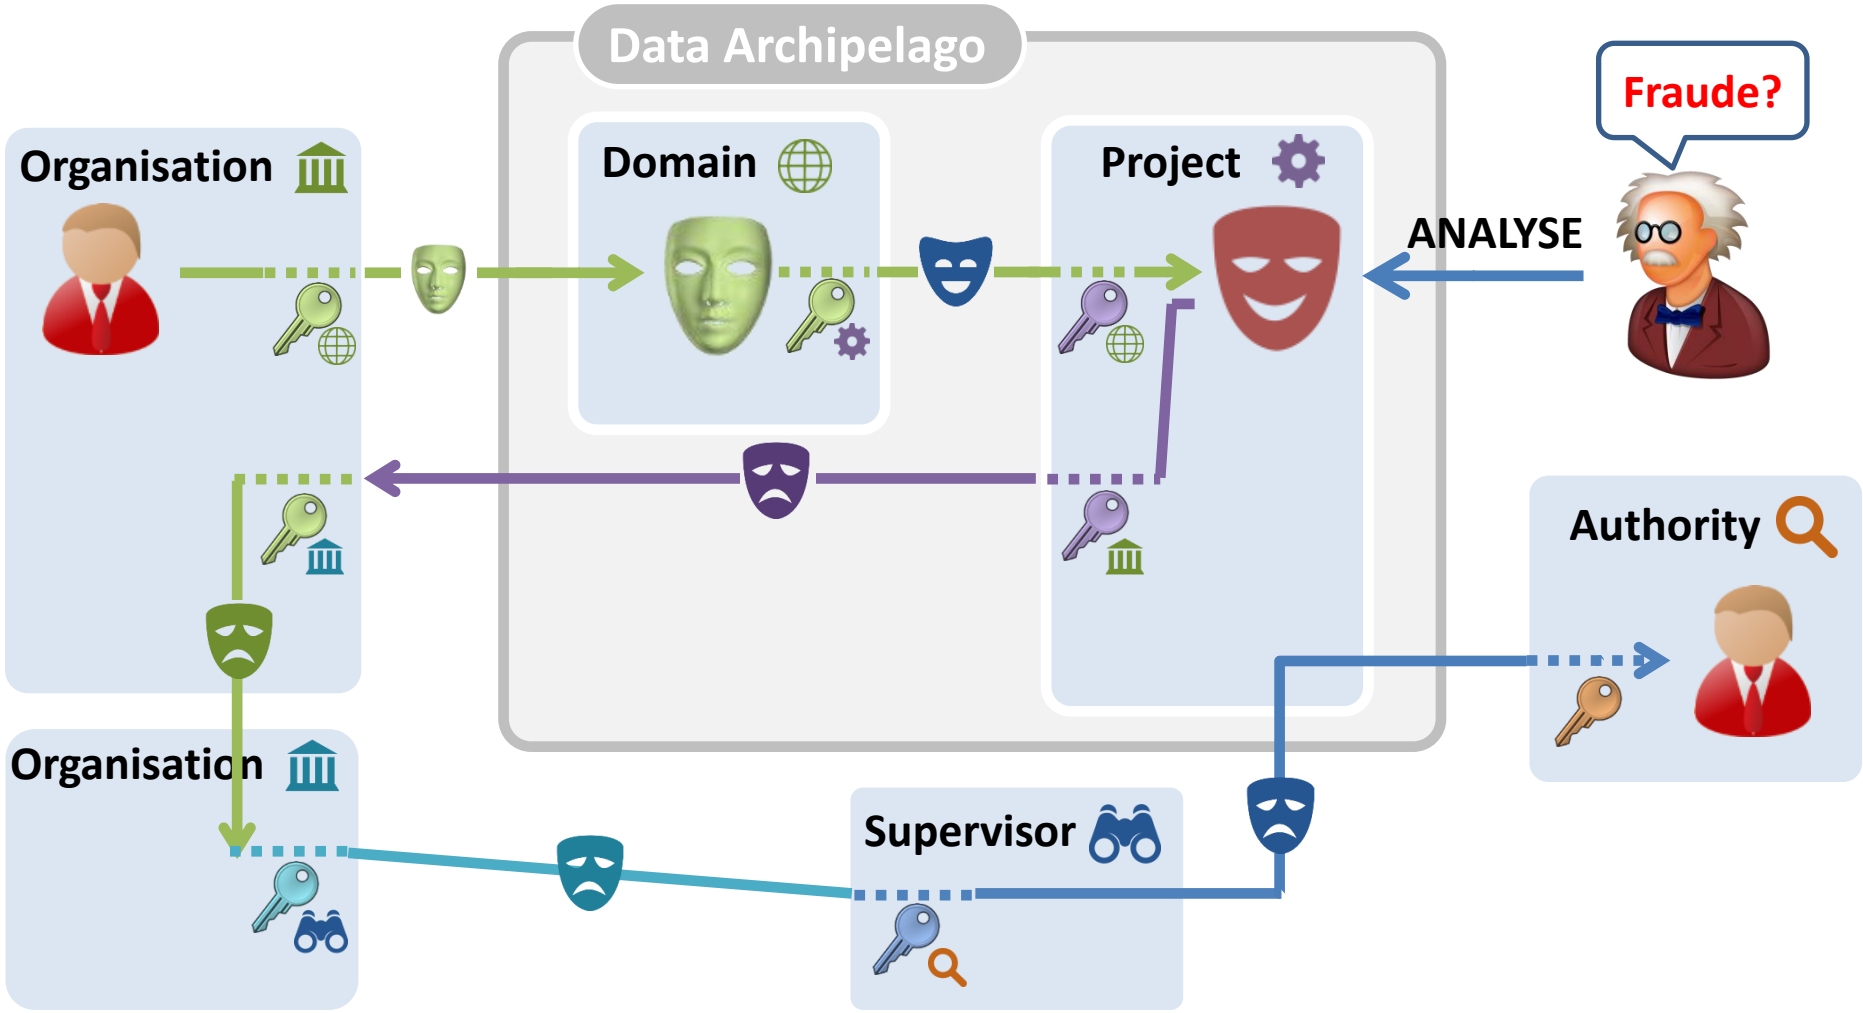
Data Archipelago
Organisation
Domain
Project
Fraude?
ANALYSE
Authority
Organisation
Supervisor

Samenvatting

Flexibele & efficiënte deanonimisatie

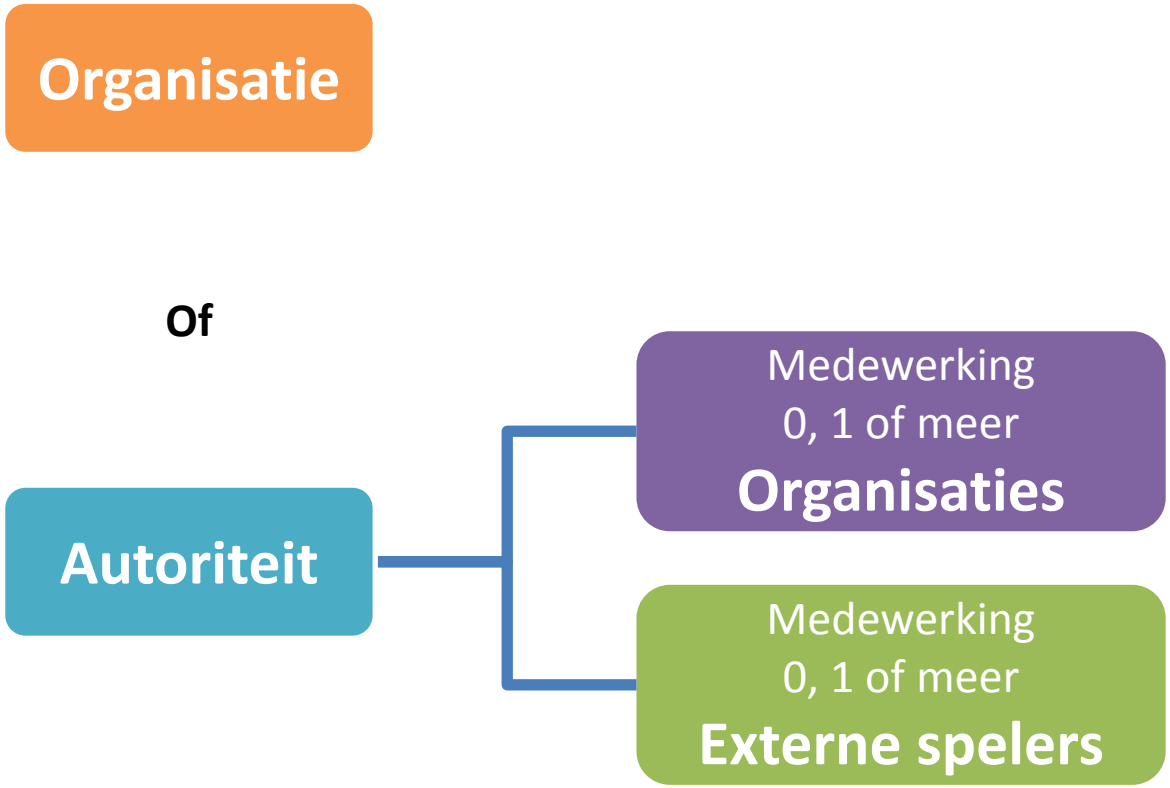

Sleutelbeheer

Key Properties

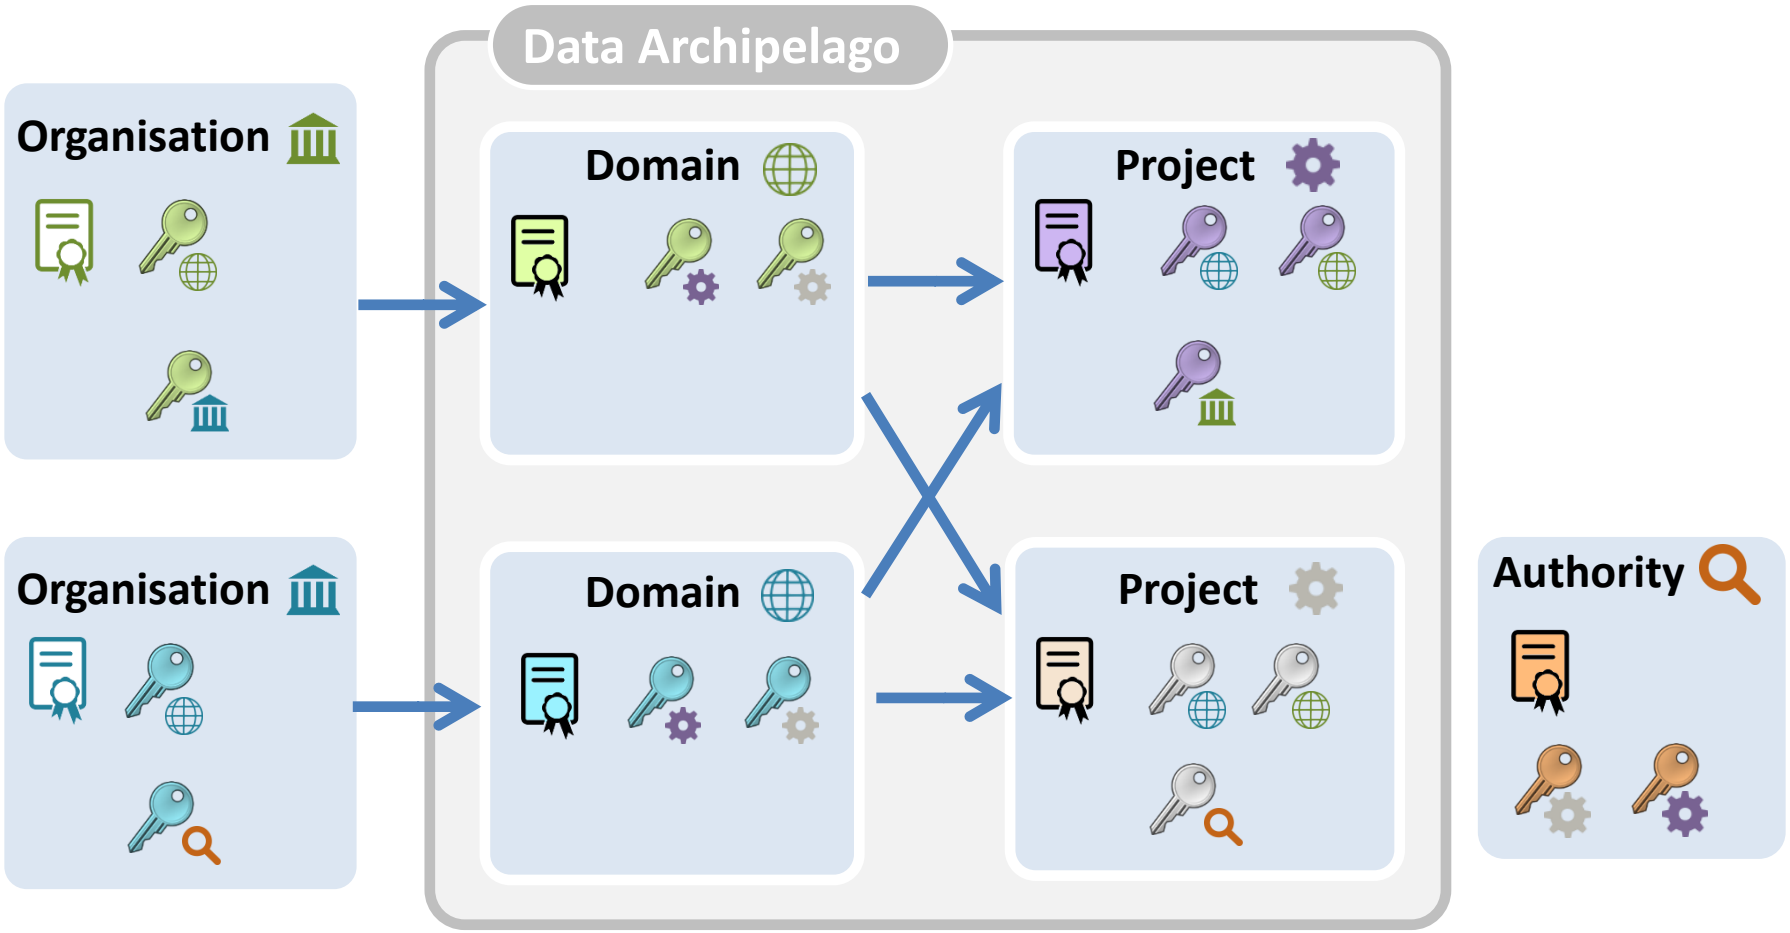

Sleutels

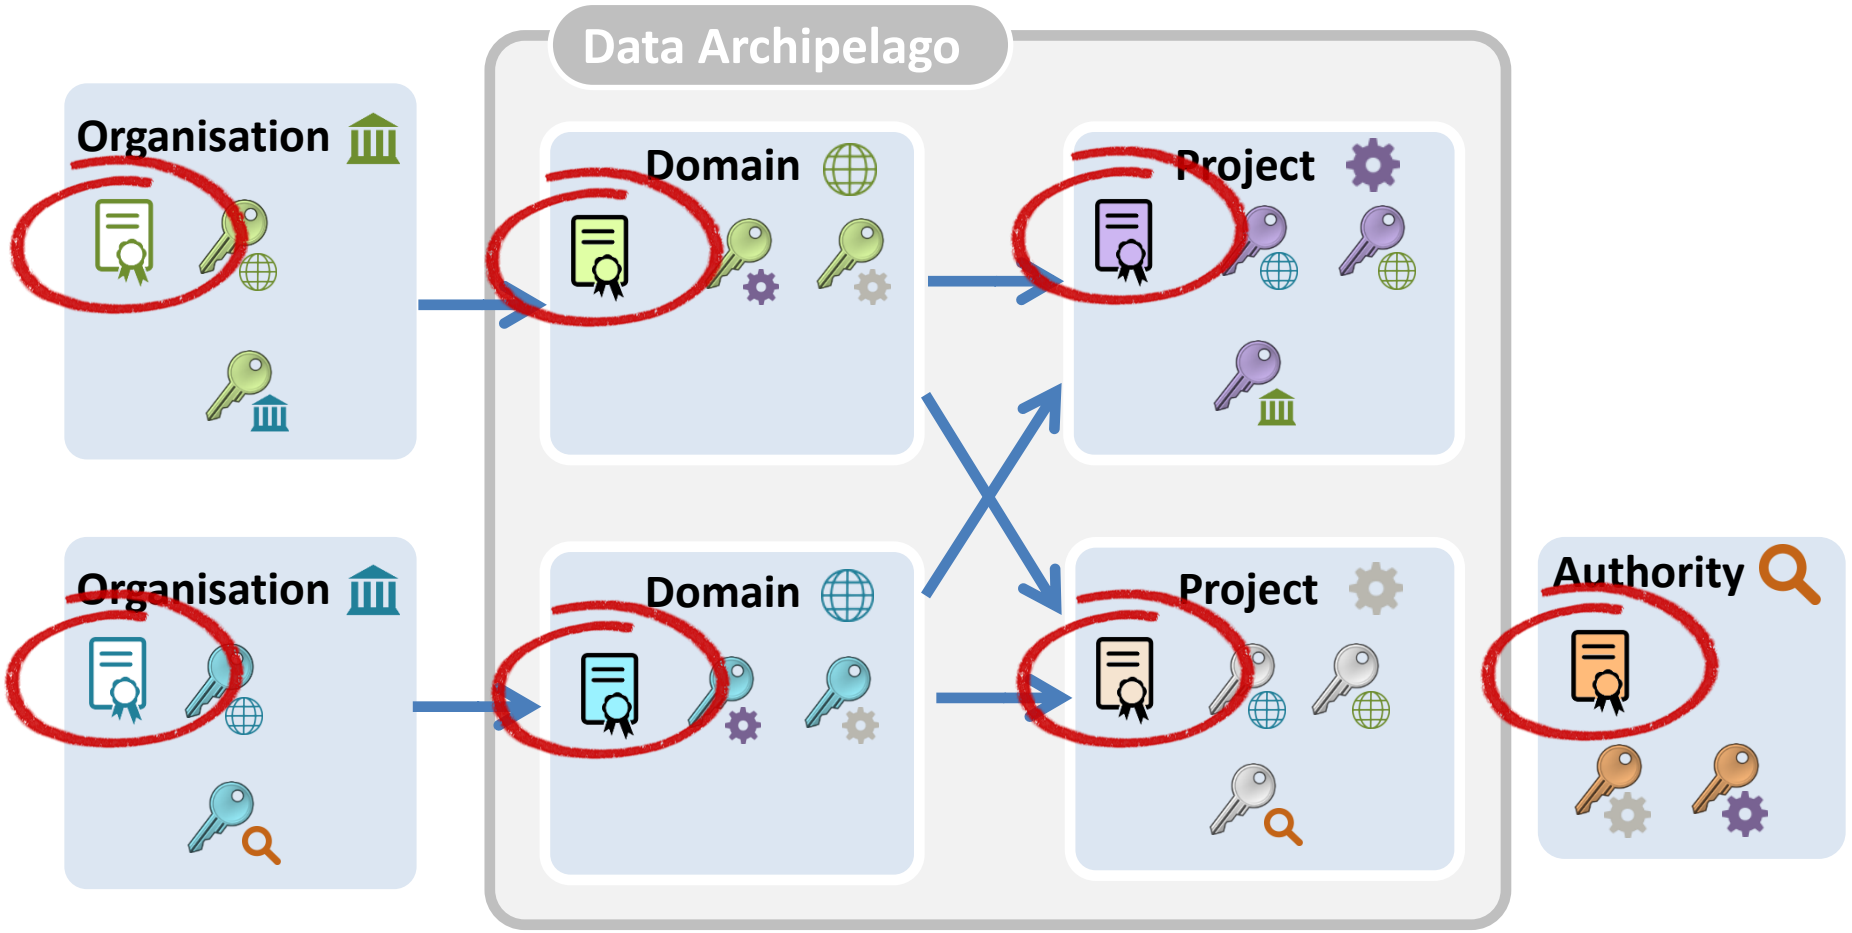
Data Archipelago
Organisation
Organisation
Domain
Domain
Project
Project
Authority

Sleutels

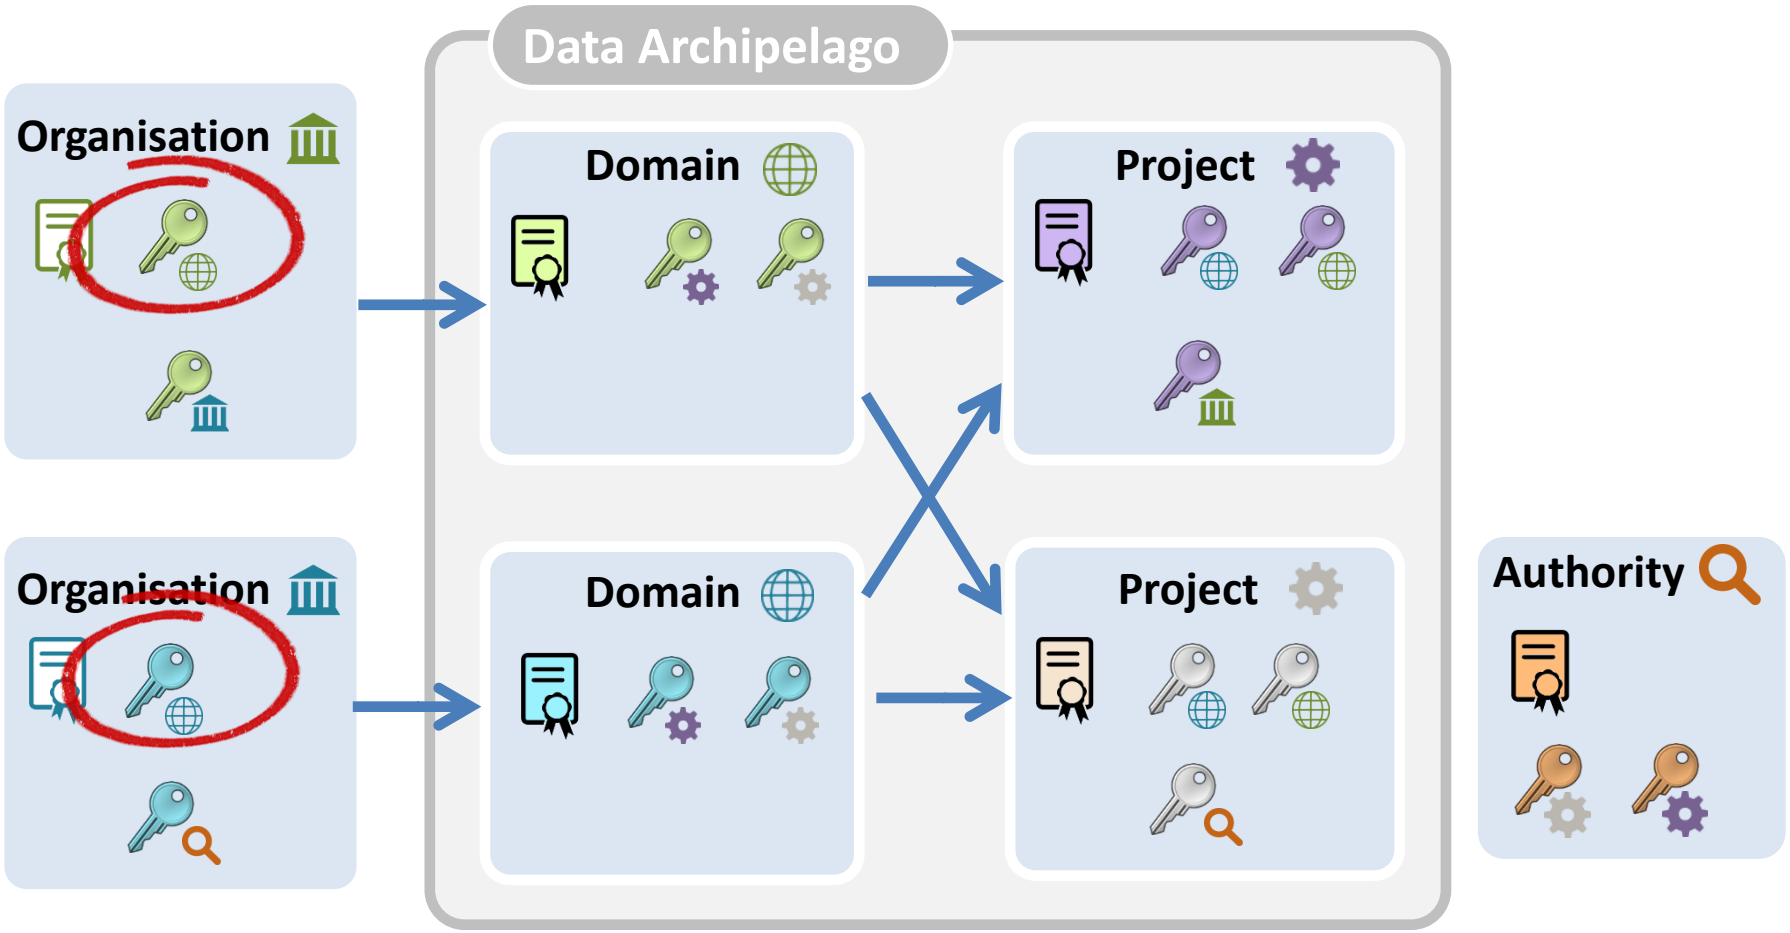
Data Archipelago
Organisation
Organisation
Domain
Domain
Project
Project
Authority

Sleutels

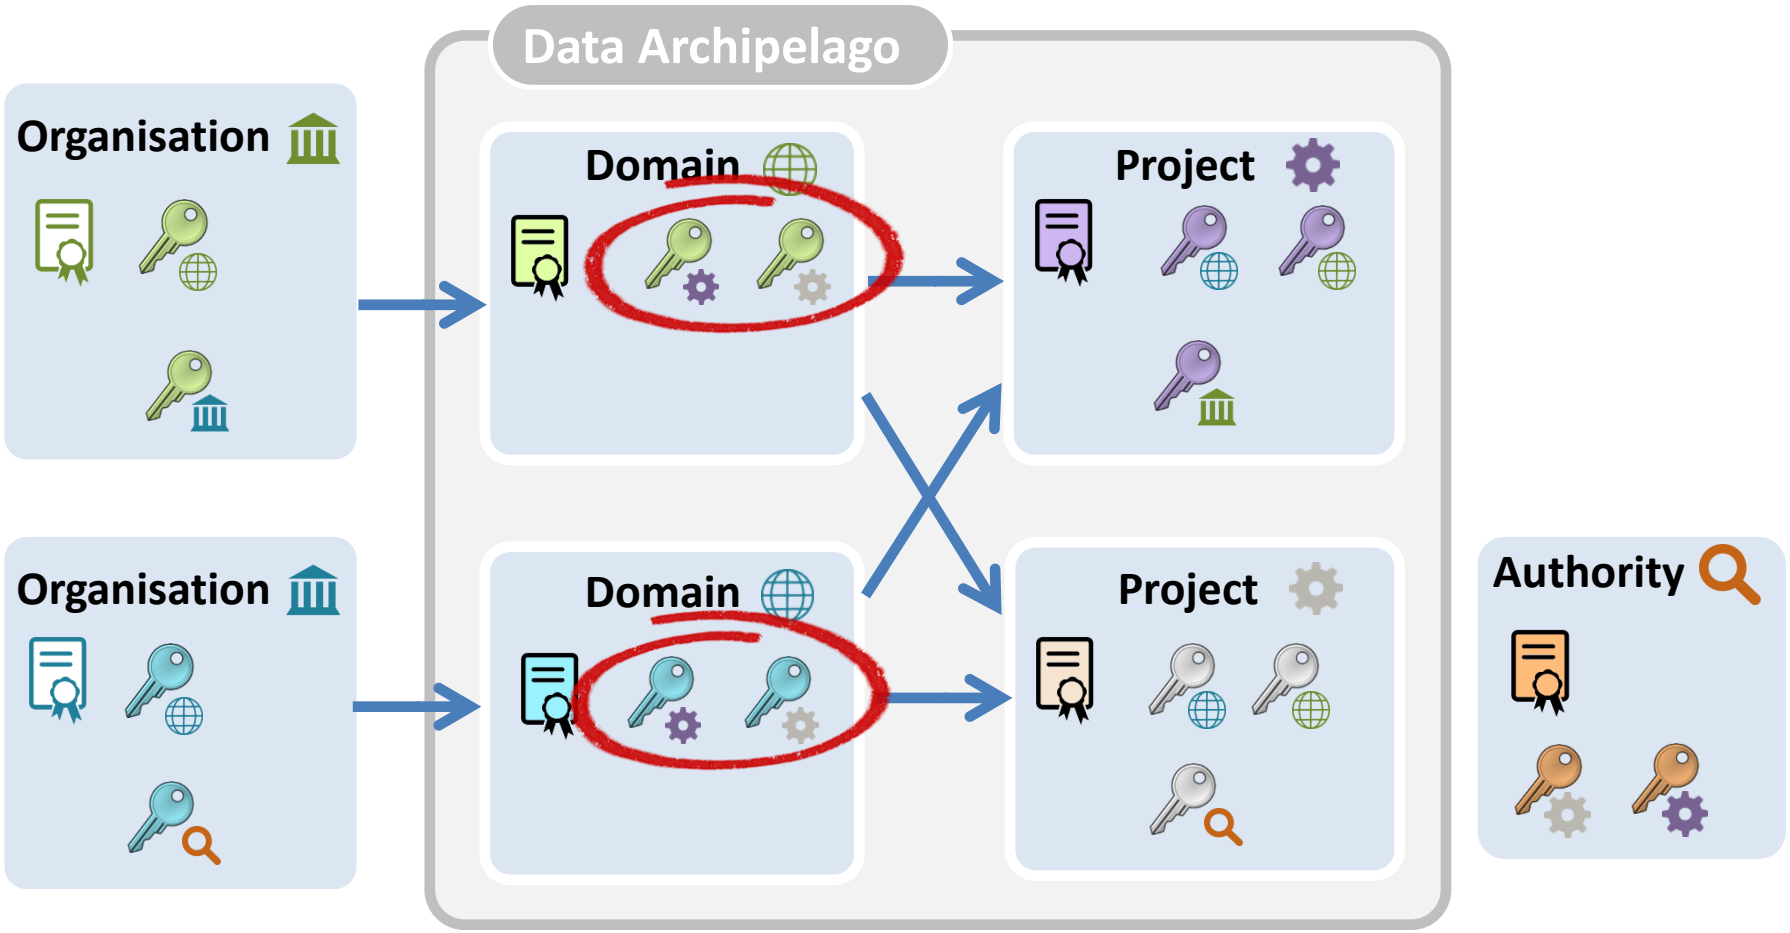
Data Archipelago
Organisation
Organisation
Domain
Domain
Project
Project
Authority

Sleutels

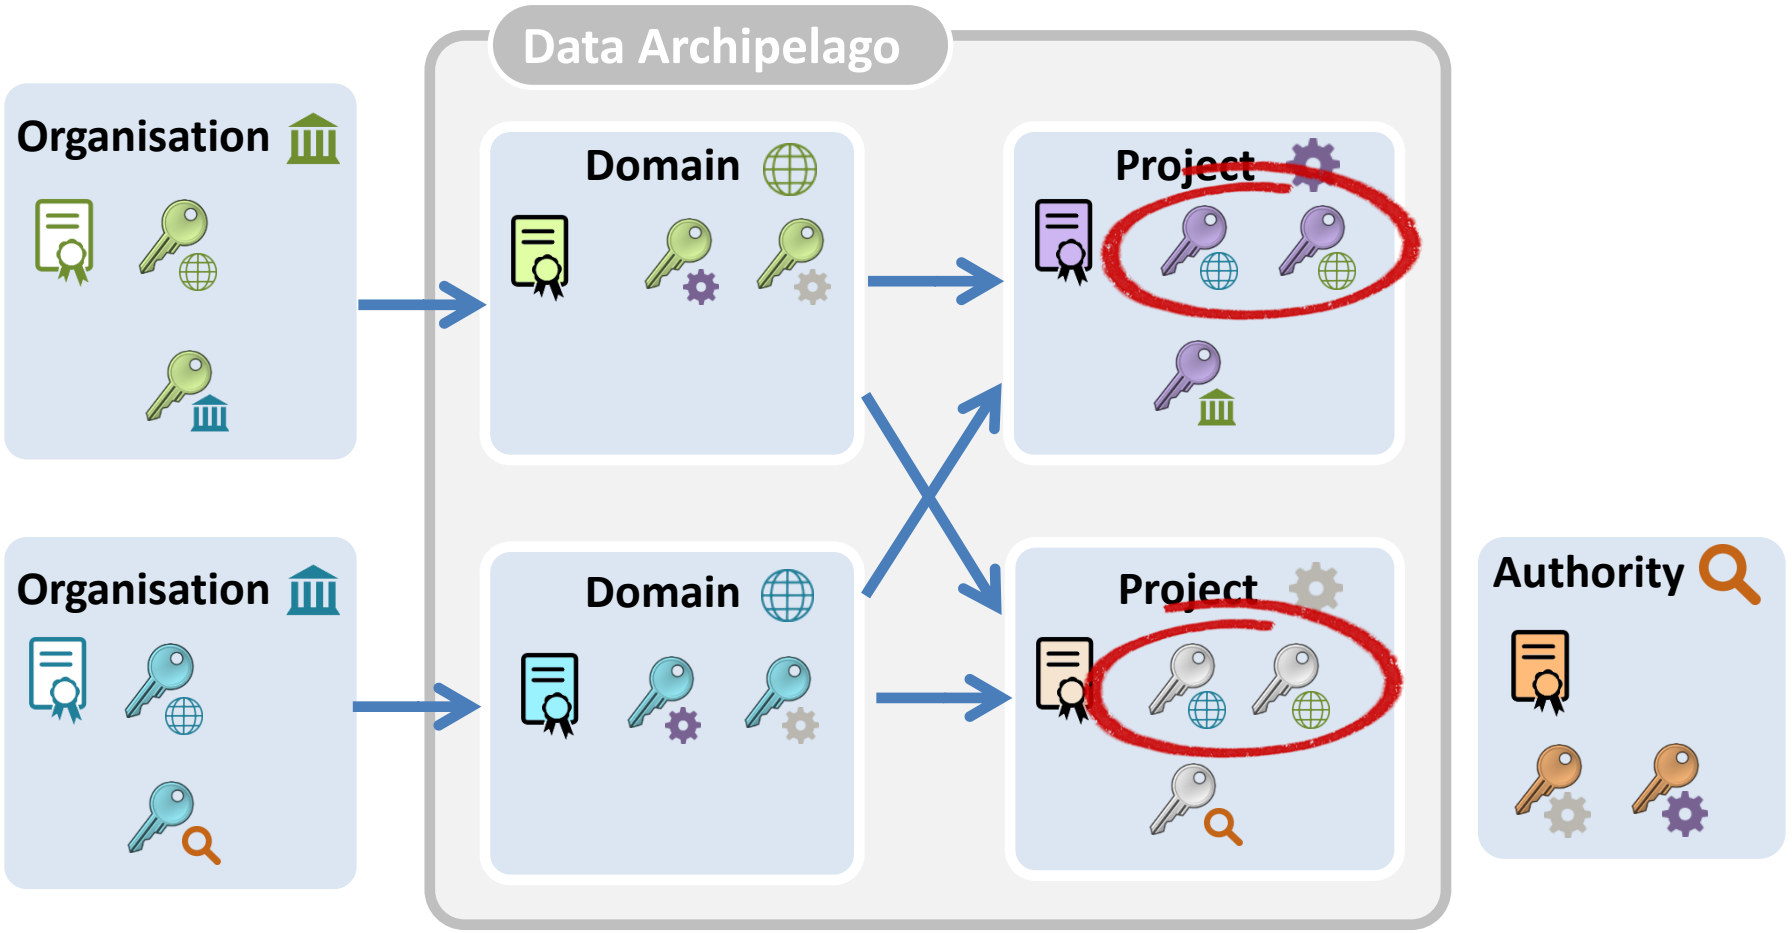

Kan soms al snel verwijderd worden

Sleutels

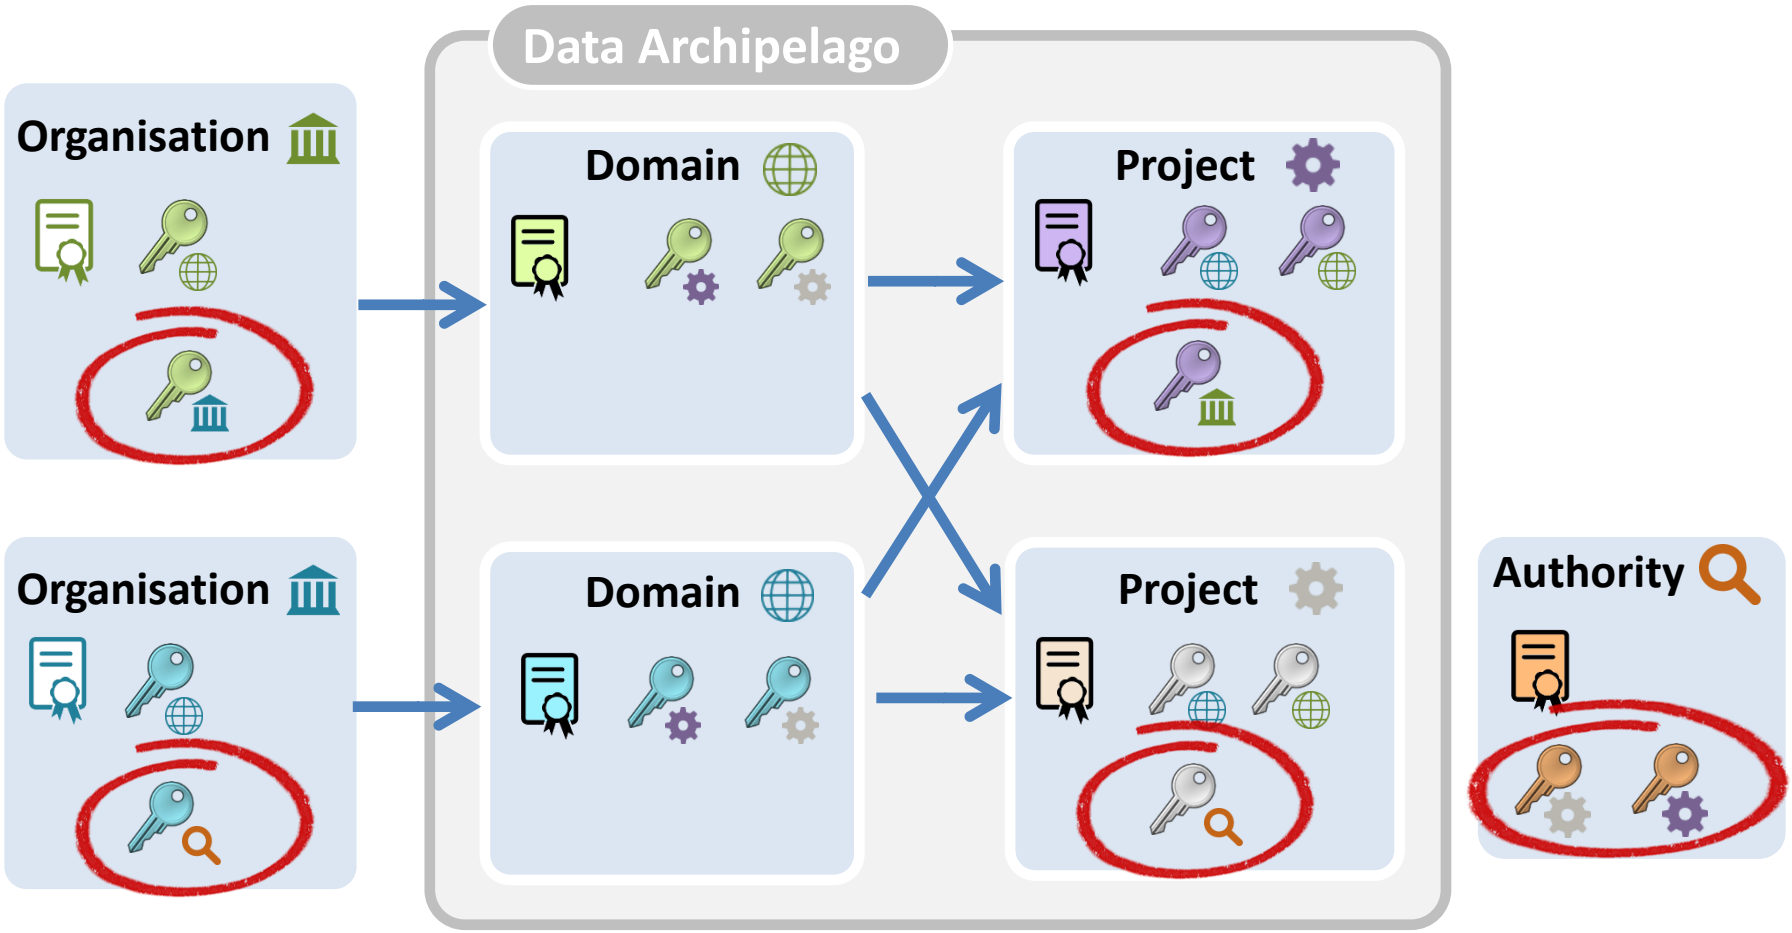

Opslag sleutels?

Sleutellengte?

Sleutelgeneratie?

Opslag sleutels

Software-based

- V.b. PKCS#12
- Password given to very slow function

Hardware-based (HSM)

Network attached

Server embedded

Portable / USB

Cryptografische operaties in HSM → sleutel verlaat HSM nooit

Aanbevolen sleutellengte

Verschillende aanbevelingen, waaronder:

NIST

Date	AES	RSA	EC
2010	80	1024	160
2011 - 2030	112	2048	224
> 2030	128	3072	256
>>> 2030	256	15360	512

Lenstra

Date	AES	RSA	EC
2018	80	1329	160
2042	96	2124	192
2066	112	3154	224
2090	128	4440	256
2282	256	26268	512

http://www.keylength.com

Sleutelgeneratie 1

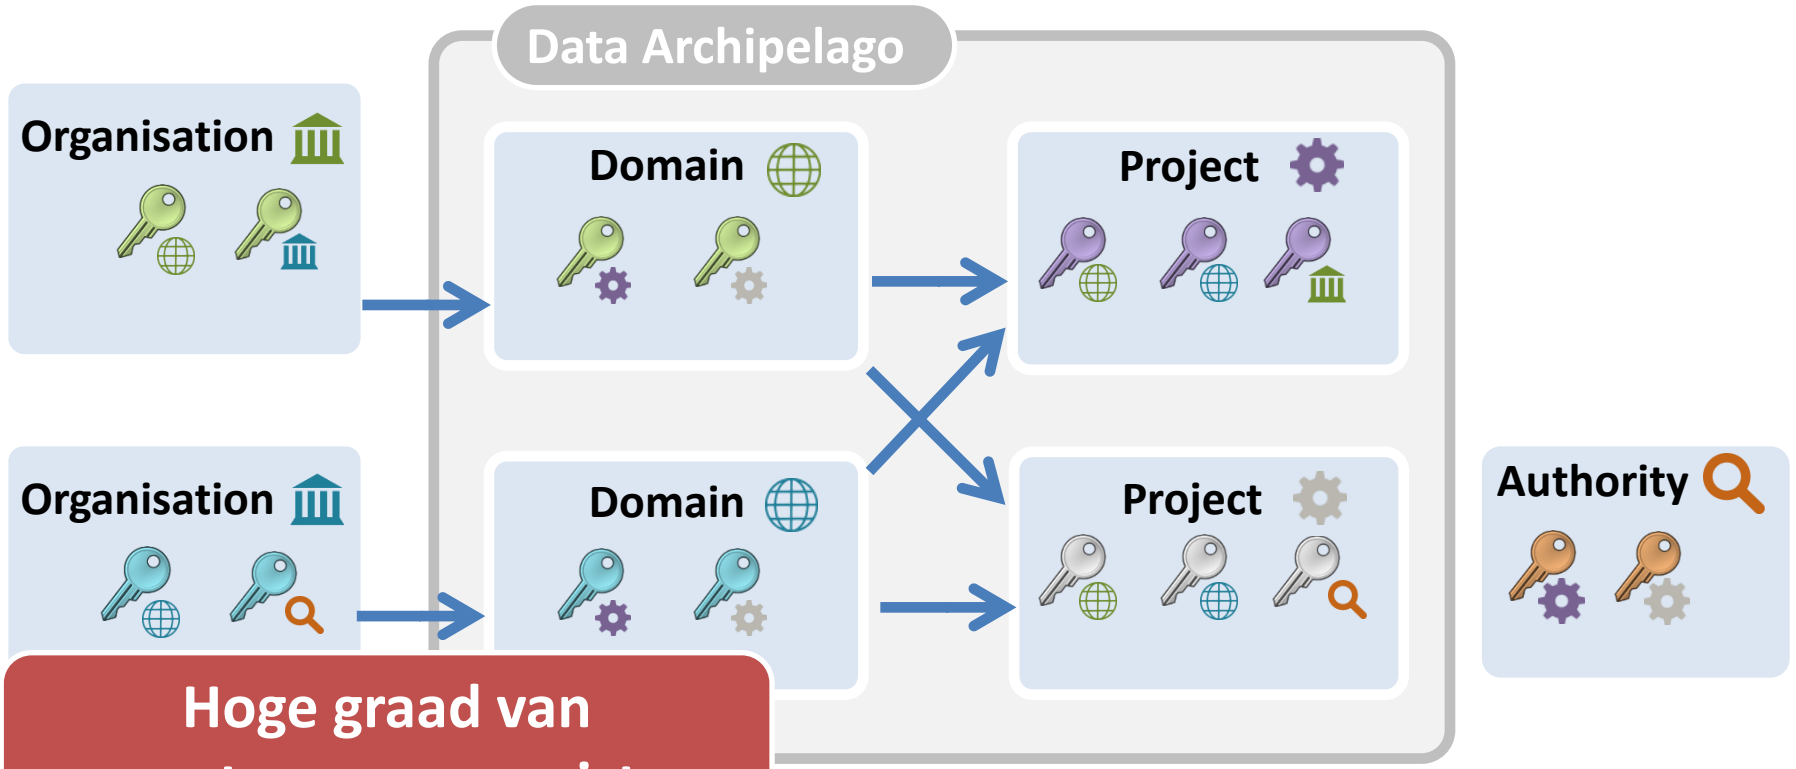

Hoge graad van vertrouwen vereist

Centrale trusted dealer kent alle sleutels

Alle sleutels afleidbaar uit één enkel master secret

Sleutelgeneratie 2

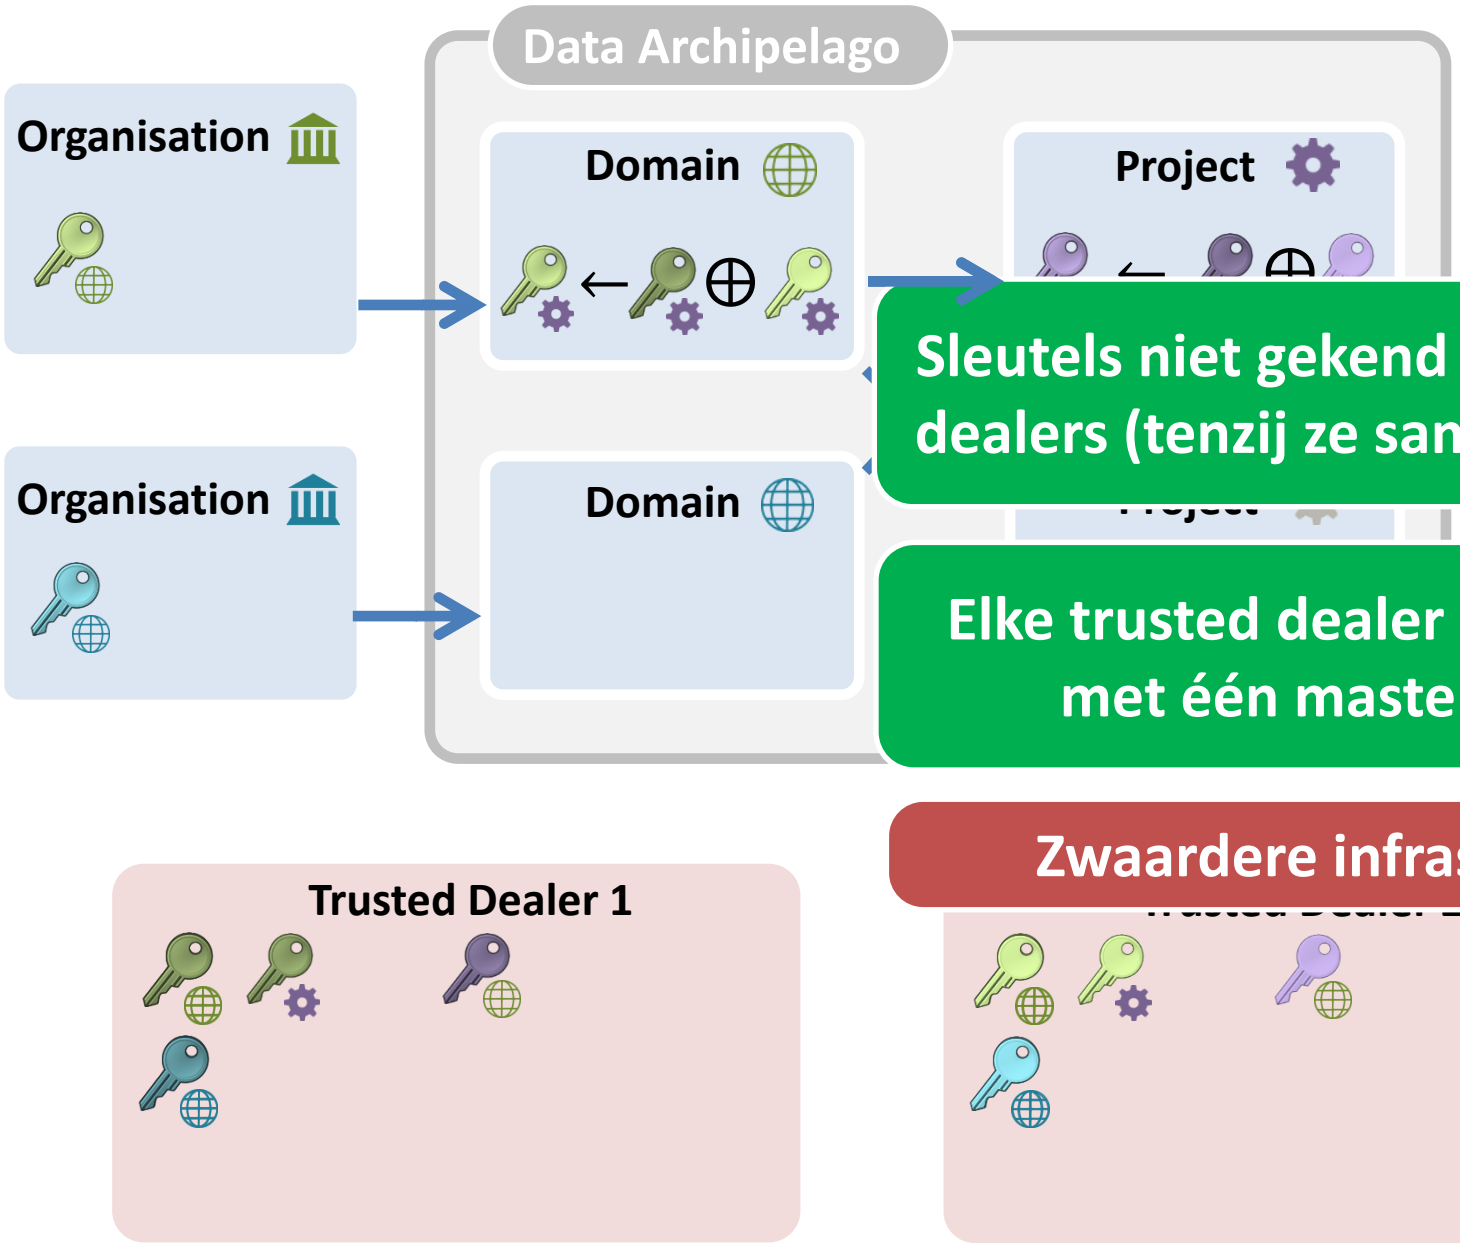

Sleutelgeneratie 3

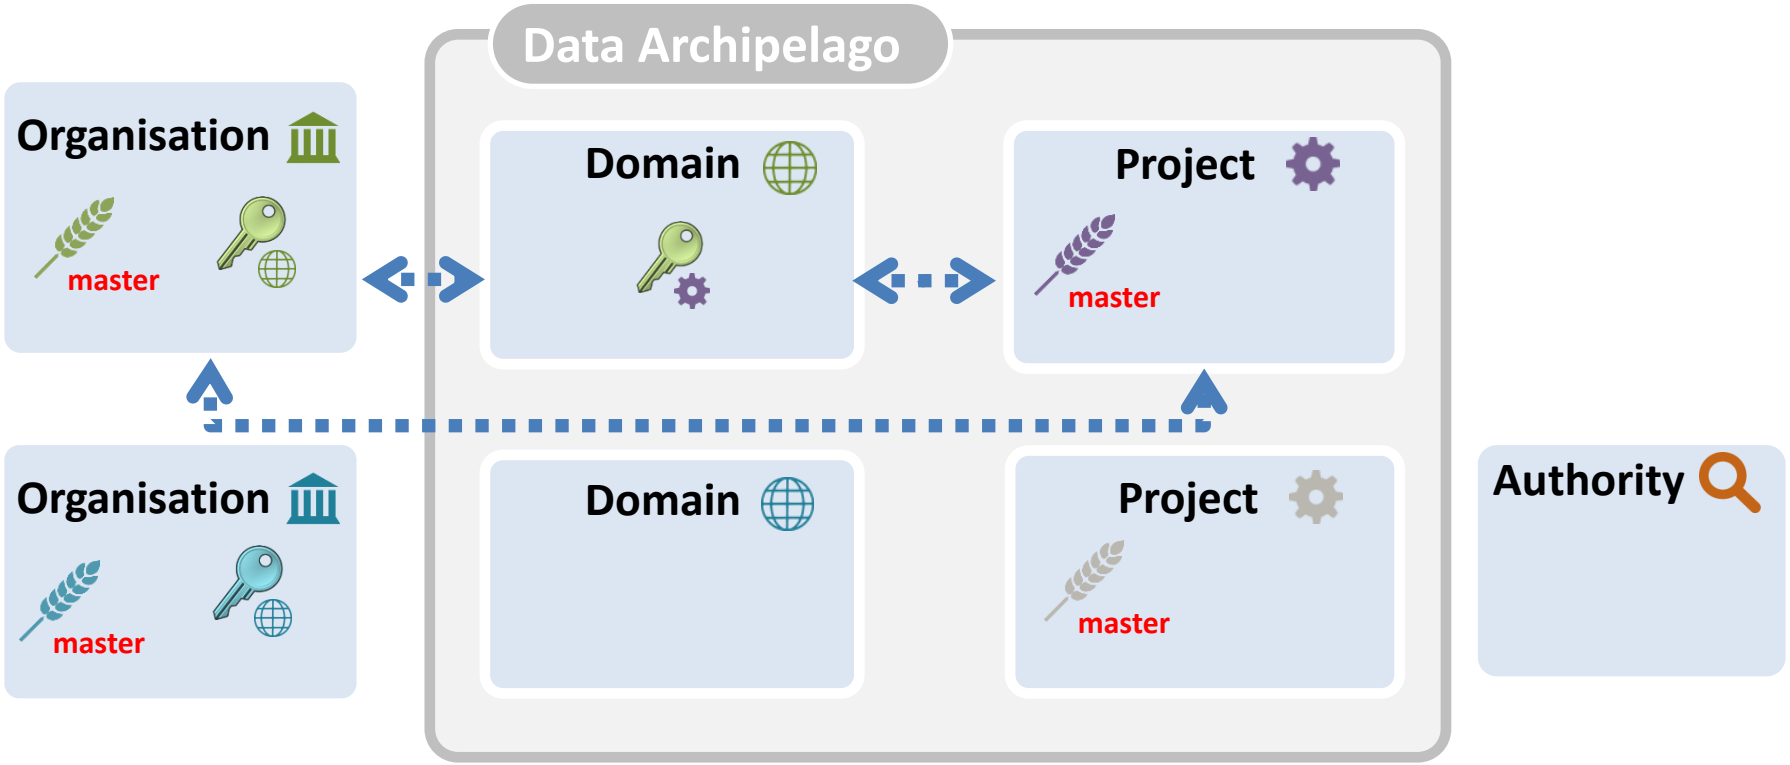

Domein leert niets buiten nieuwe sleutel
Geen informatie gelekt over master secrets

Sleutelgeneratie 3

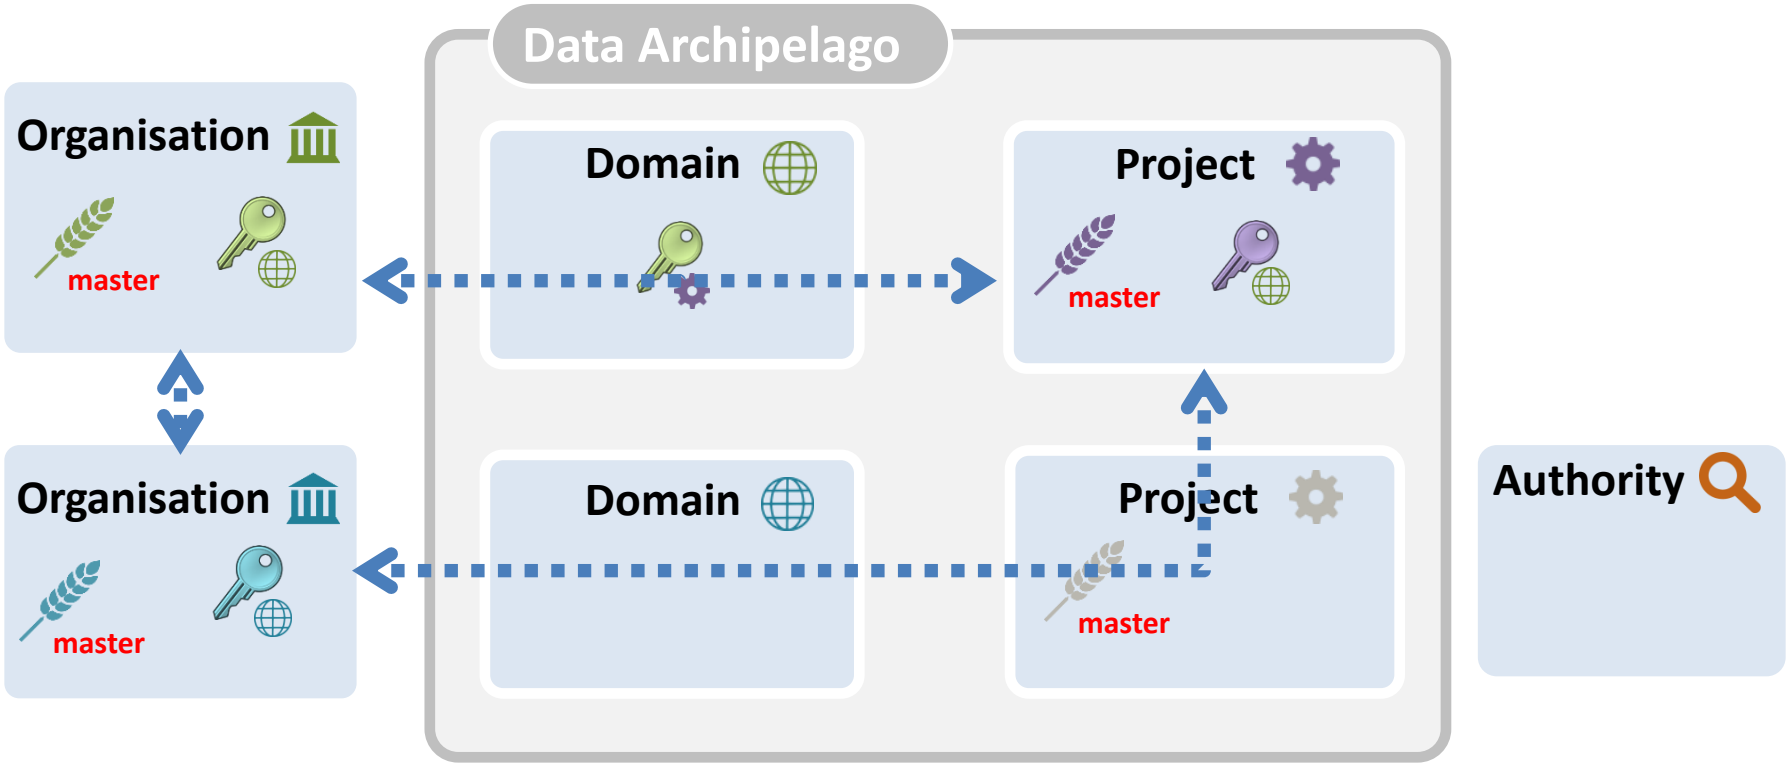

Project leert niets buiten nieuwe sleutel
Geen informatie gelekt over master secrets

Multi-Party Multiplication

Sterk vereenvoudigd!

Dave

$r = getRandom()$

$s = \frac{t_3}{r}$

$= s_{Alice} * s_{Bob} * s_{Charlie}$

r

Alice

s_{Alice}

$t_1 = r * s_{Alice}$

t_1

Bob

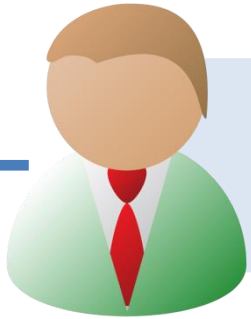

s_{Bob}

$t_2 = t_1 * s_{Bob}$

$= r * s_{Alice} * s_{Bob}$

t_2

Charlie

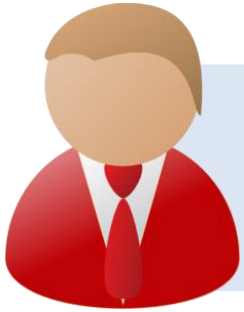

$s_{Charlie}$

$t_3 = t_2 * s_{Charlie}$

$= r * s_{Alice} * s_{Bob} * s_{Charlie}$

t_3

Dave leert $s = s_{Alice} * s_{Bob} * s_{Charlie}$ maar niets anders

Generatie sleutels - Vergelijking

	Eén trusted dealer	Meerdere trusted dealers	Geen trusted dealer
Vertrouwen per entiteit	**Hoog**	**Medium**	**Laag**
Extra partijen	**1**	**>1**	**0**
Impact lekken geheim	**Hoog**	**Medium**	**Laag**
Kans lekken geheim	**Laag**	**Medium**	**Hoog**
Sleutel recupereerbaar	**Ja**	**Ja**	**Ja**

Flexibele sleutelgeneratie en -distributie

Samenvatting

Elke entiteit slaat sleutels op

Levensduur sleutels varieert

Veilige opslag vereist

Voldoende lange sleutels

Flexibele sleutelgeneratie

Transparantie

Transparantie voor de burger

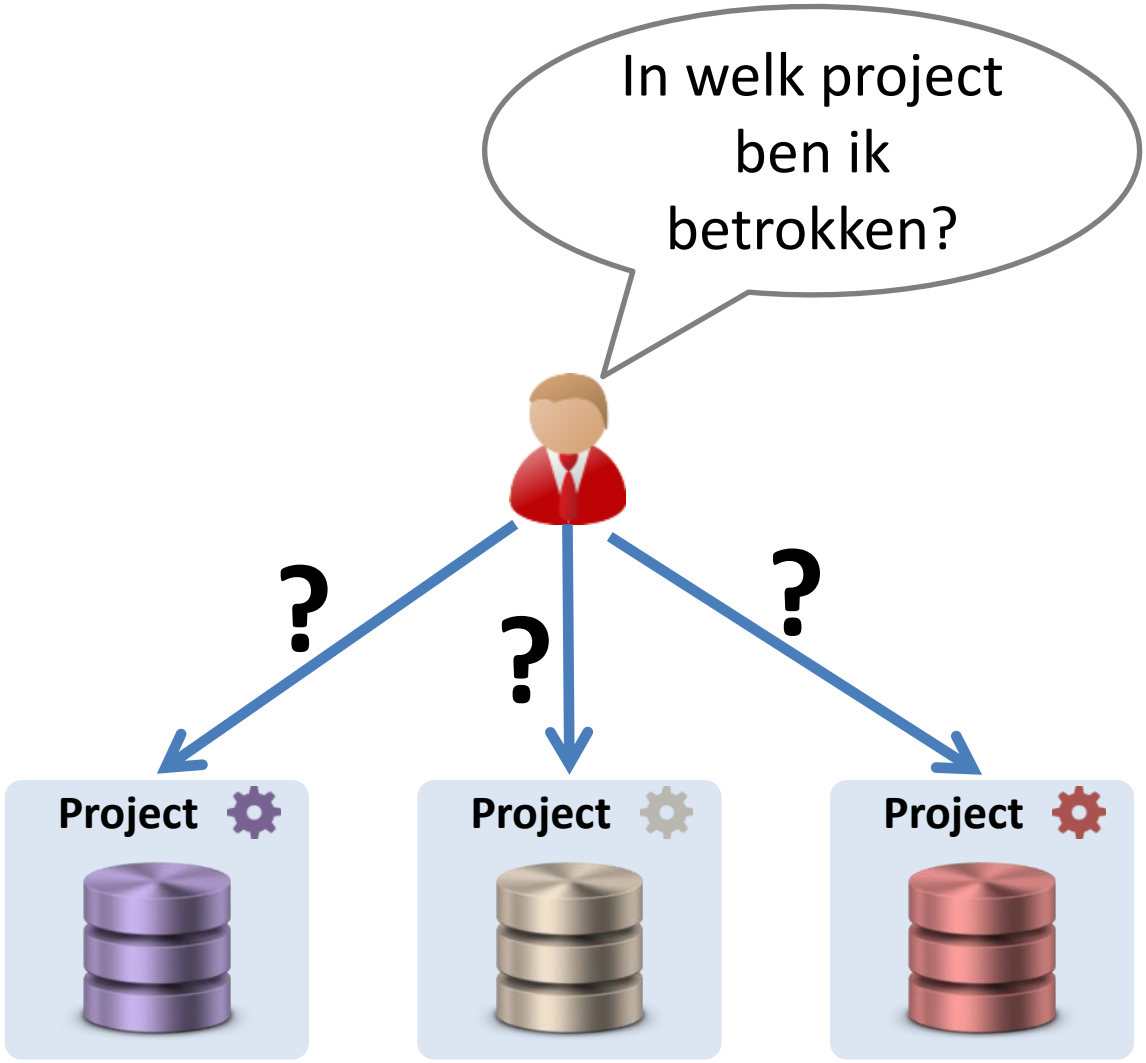

parantie voor de b

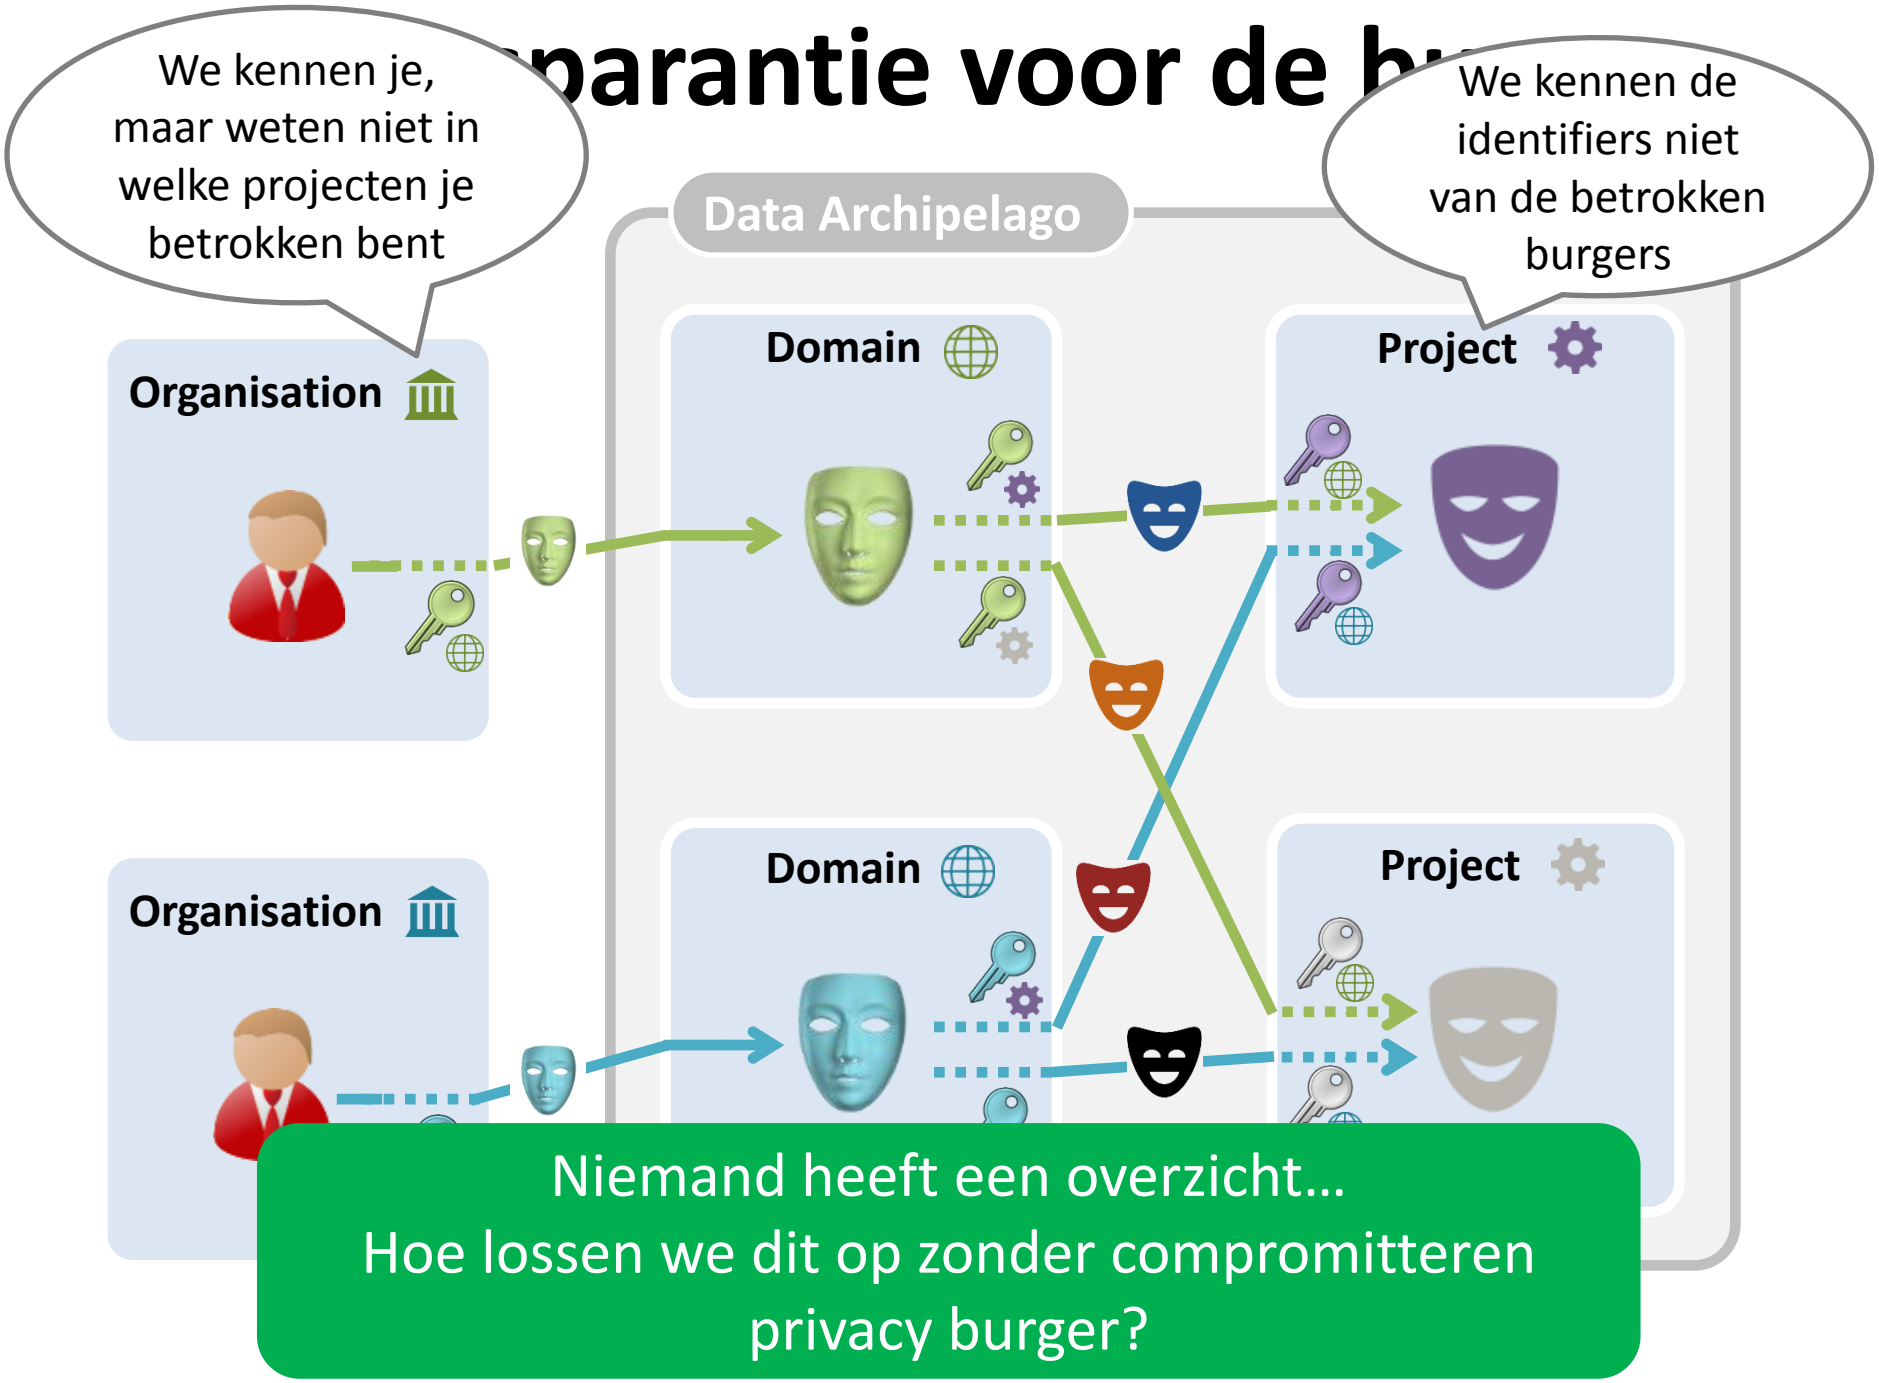

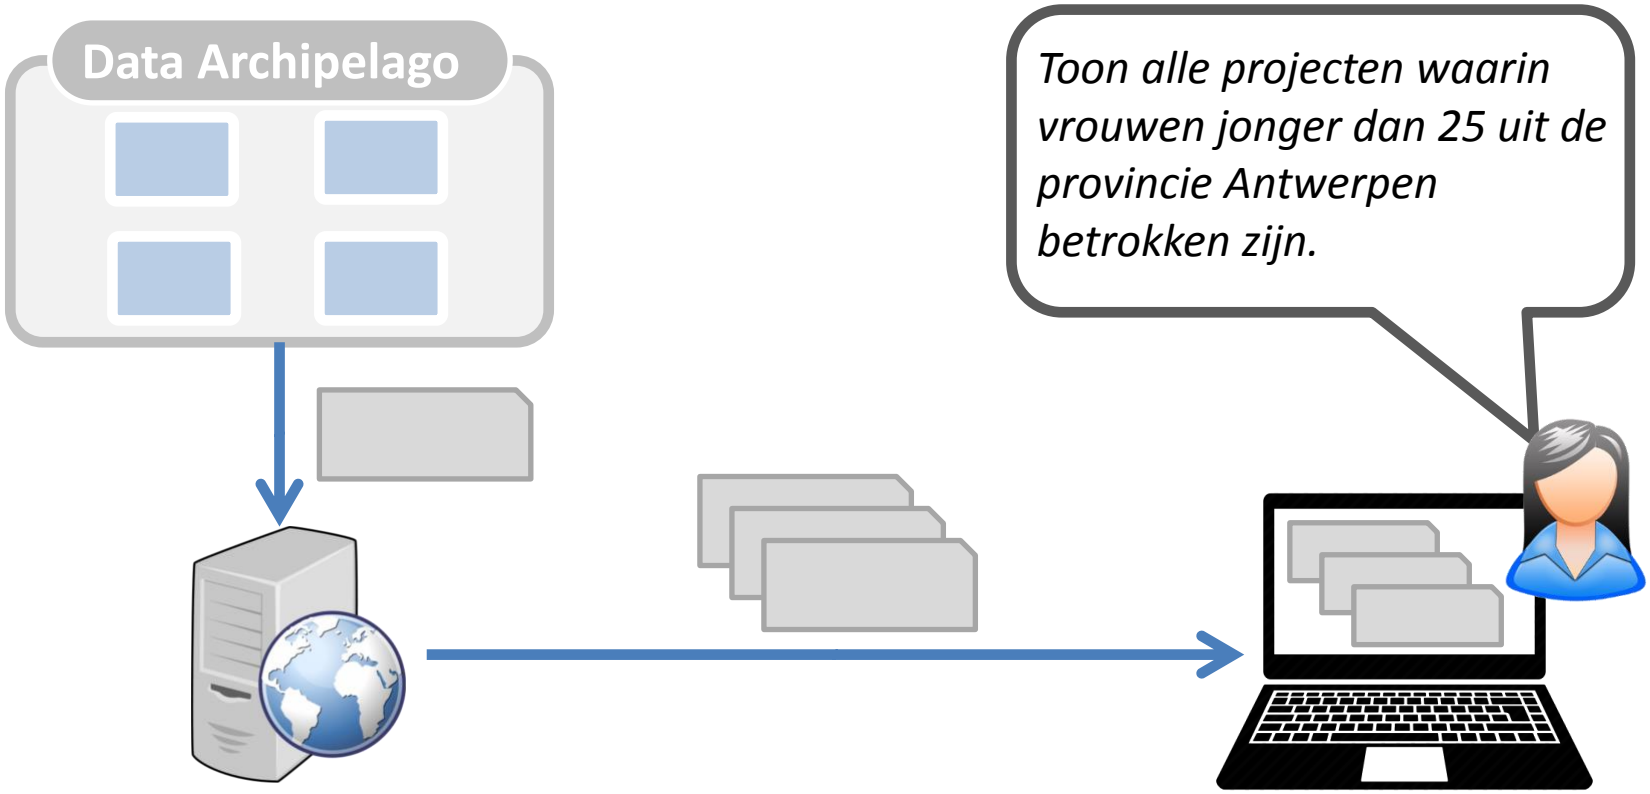

Aanvrager:	KU Leuven
Doelstelling:	Onderzoek naar jonge zelfstandigen in bijberoep in k…
Duur:	01/06/206 tot 31/12/2016
Selectie:	YoB ≥ 1990 & wage > 50.000 & status=zelfst. in bijb.
Attributen:	Opleiding, gezinsinkomen, gemeente, werkgever, …

Burger leert in welke projecten hij betrokken is.
Overheden weten dit niet.

Small Cells

Smals
ICT for society

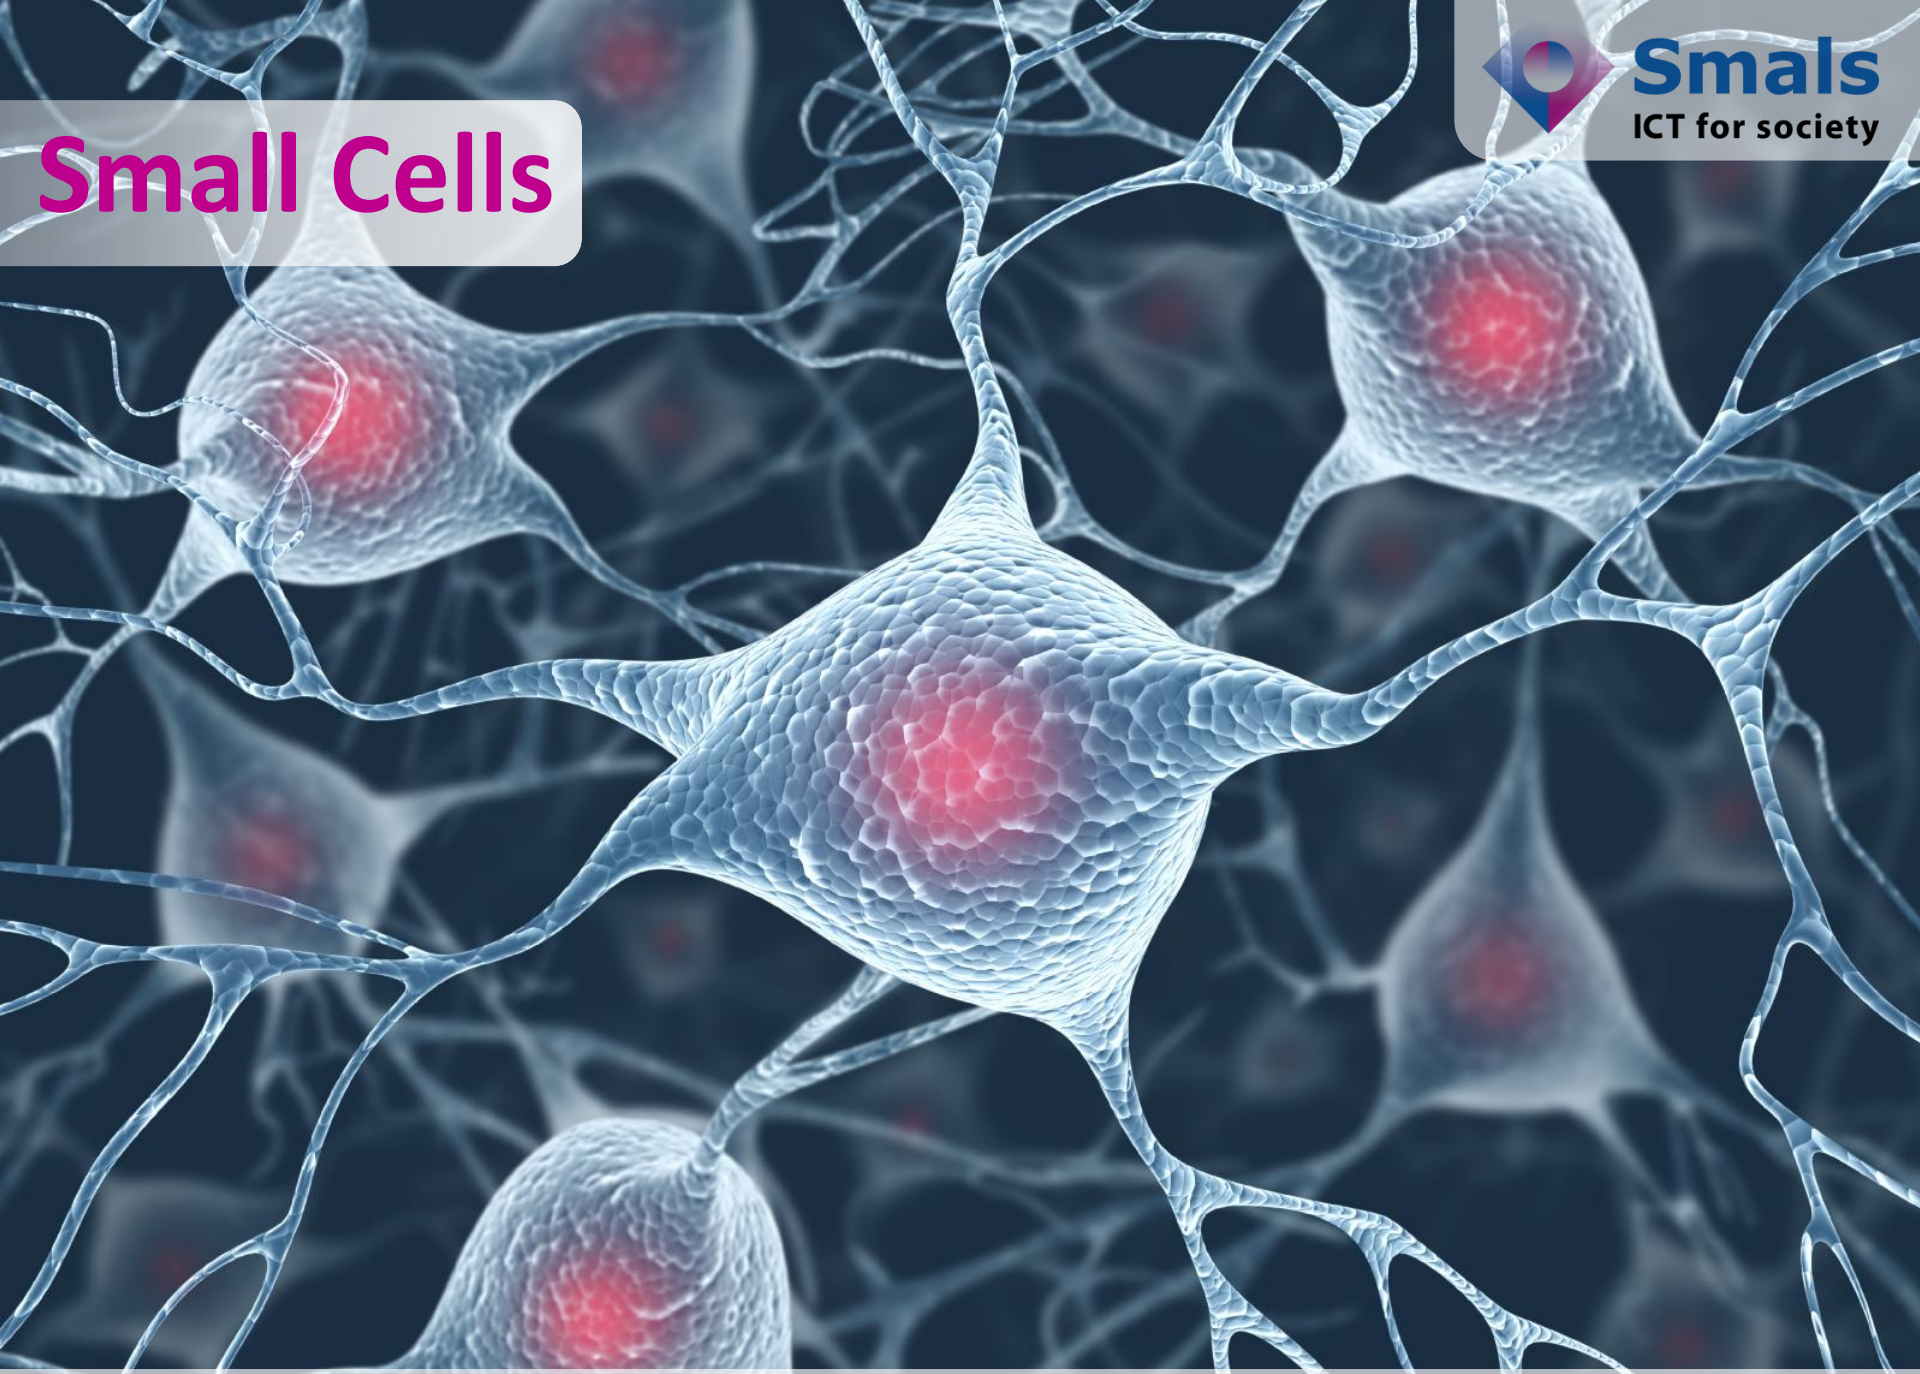

Small Cells

Zelfs na toepassen anonimisatietechnieken kan veelal record terug gelinkt worden aan één fysieke persoon (=small cell)

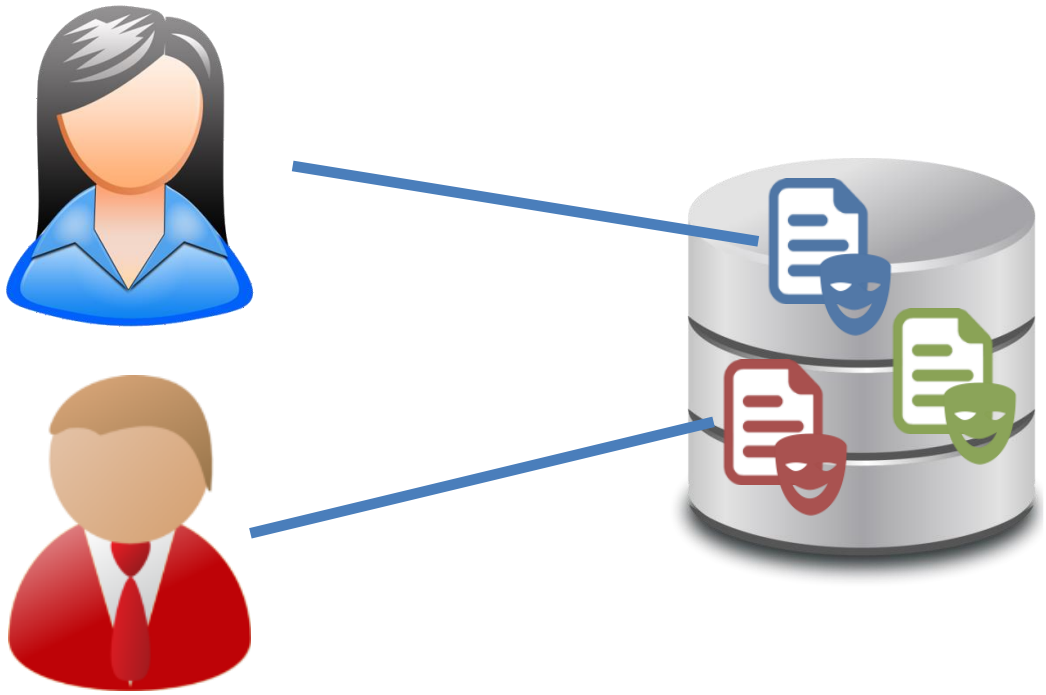

Doorsturen van “geanonimiseerde” gegevens naar onderzoeker houdt dus risico’s in

Paradigmashift

Haal de data naar de berekeningen

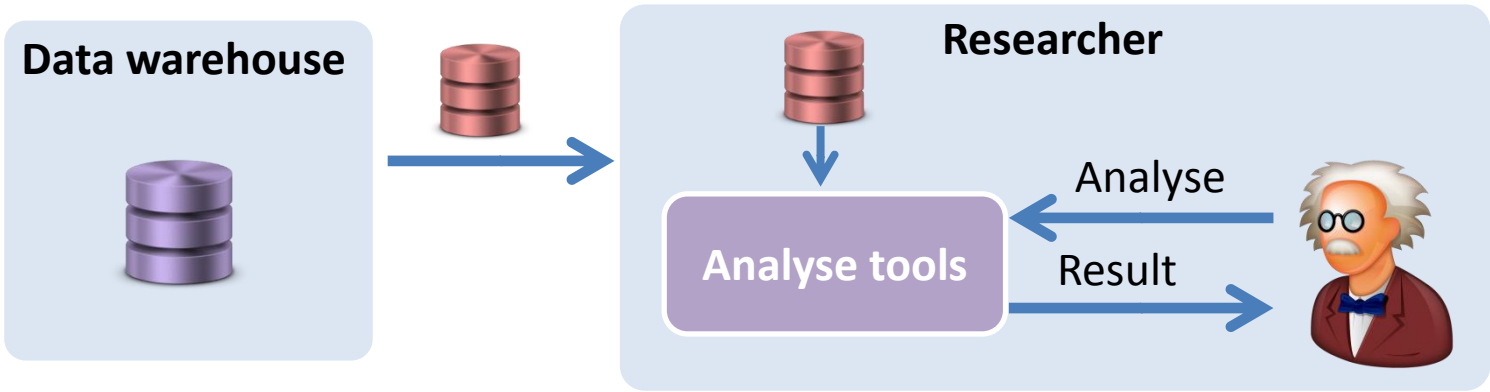

Hoog risico

Haal de berekeningen naar de data

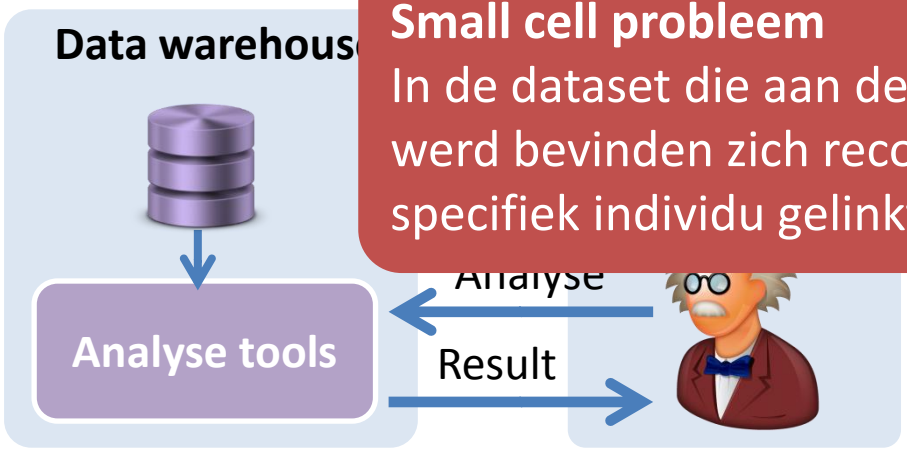

Small cell probleem
In de dataset die aan de onderzoeker gegeven werd bevinden zich records die maar aan één specifiek individu gelinkt kunnen worden.

erzoekers

Ondersteund door # vendors

Omgaan met Small Cells

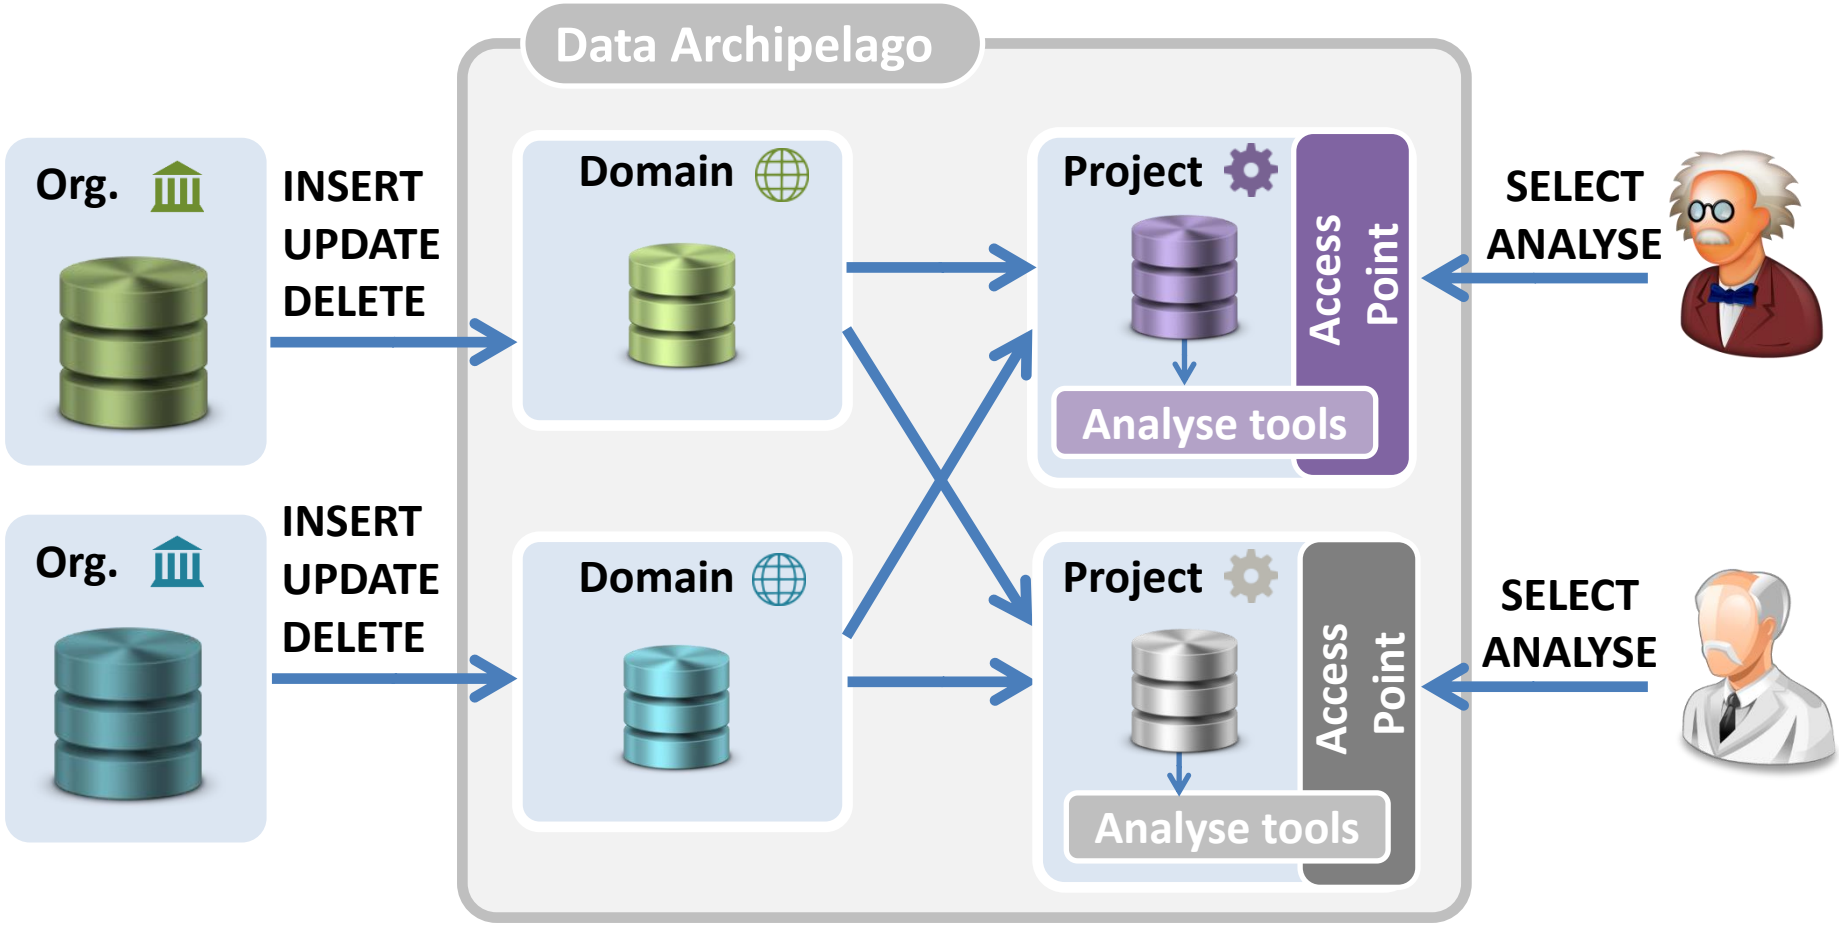

Fine-grained access control

Logging & Monitoring

Policies

Differential privacy

Differential Privacy

"Veronderstel dat je op elk moment een query kan doen op een database zodat je het gemiddelde inkomen in een wijk kent. Als je weet dat meneer Jansens naar een andere wijk verhuist en je voert de query vlak voor en vlak na zijn vertrek uit, kun je zijn loon berekenen"

Privacy garanties voor data subjecten bij recurrente statistische queries

Wiskundig onderbouwd

Vrij nieuw principe

Onderzoeker kiest zelf hoeveel statistische query's hij uitvoert.

1x Hoge nauwkeurigheid

2x Lagere gemiddelde nauwkeurigheid

3x nog lagere gemiddelde nauwkeurigheid

…

Differential Privacy

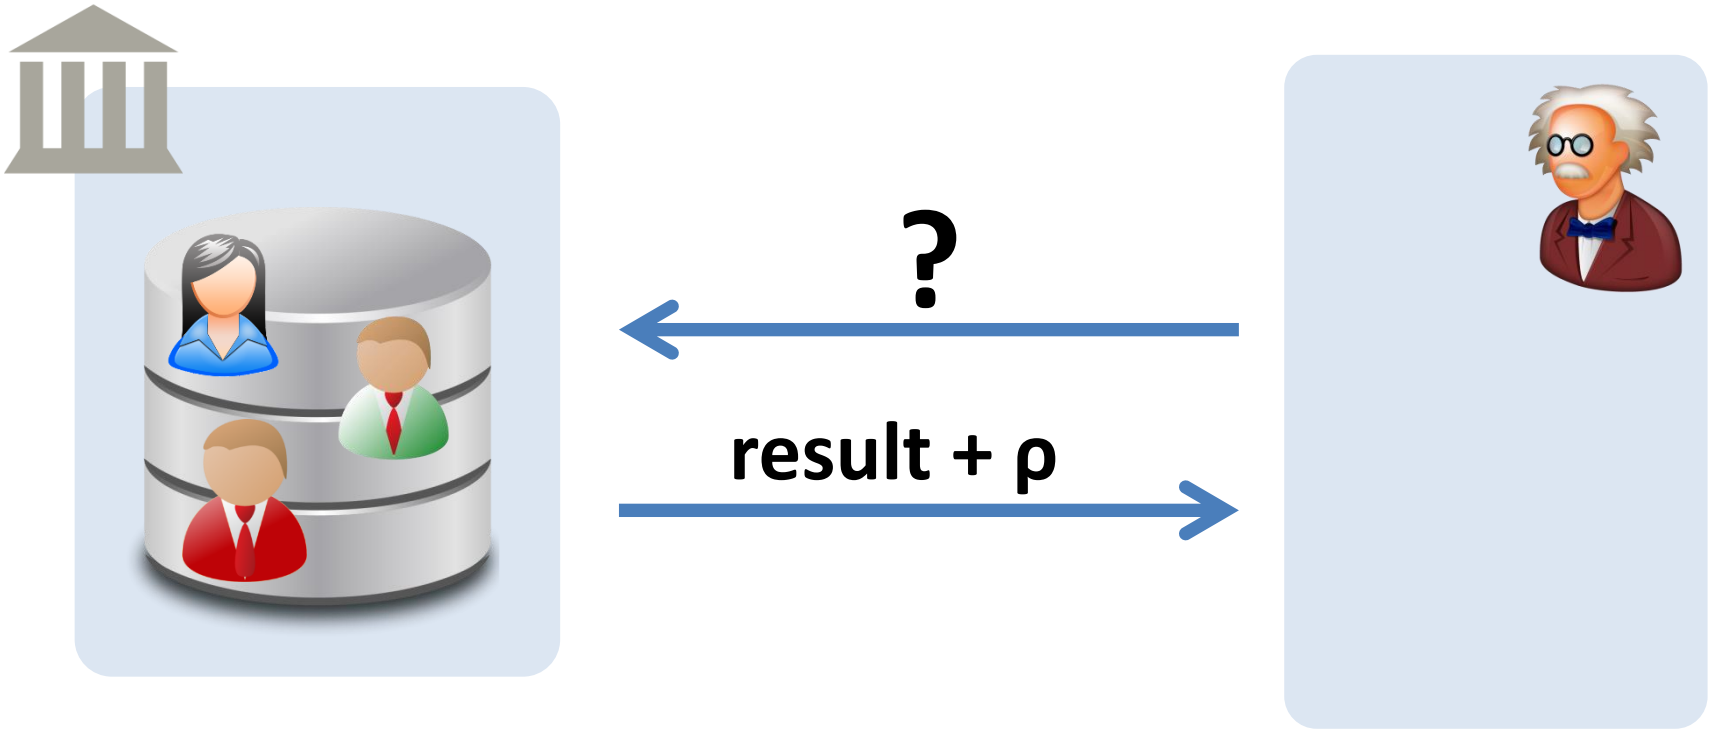

Door nemen gemiddelde resultaat zelfde query kunnen we ρ grotendeels wegfilteren…

Een privacy budget verhindert dit.

[T14]

Differential Privacy

Query 1
Veel ruis, dus minder exact
$\varepsilon = \varepsilon - 1$

Query 2
Weinig ruis, dus vrij exact
$\varepsilon = \varepsilon - 6$

Query 3
Ruis tussenin, exactheid ook
$\varepsilon = \varepsilon - 3$

Geen verdere queries meer mogelijk

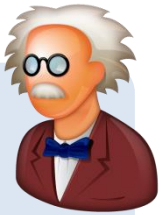

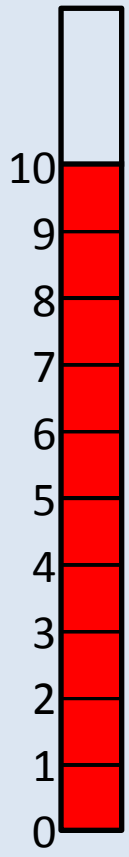

Privacy budget ε

Omgaan met Small Cells

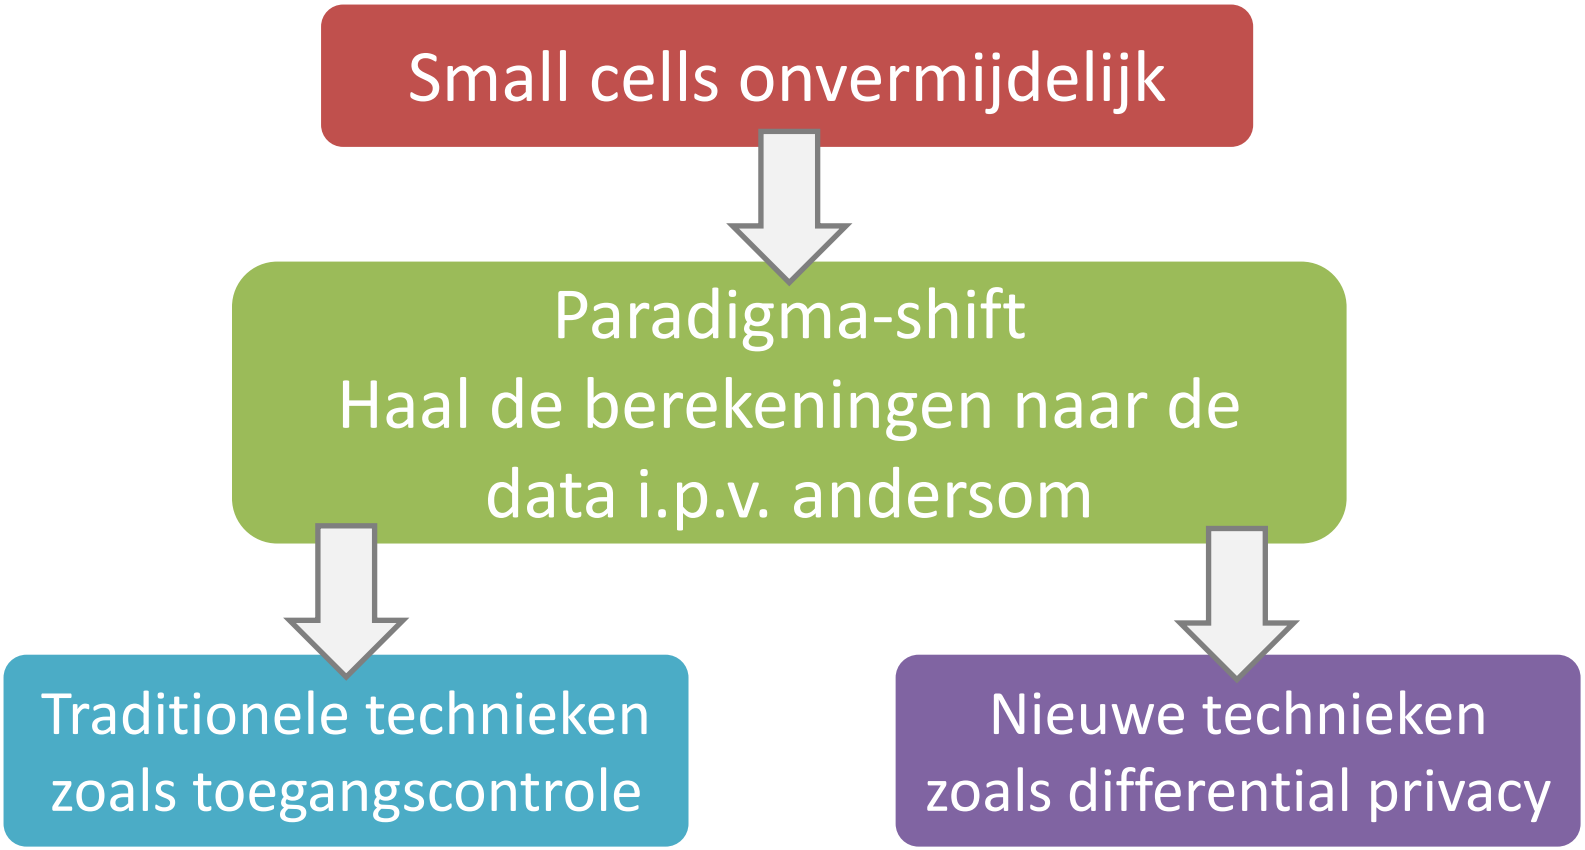

Verder onderzoek vereist!

AGENDA

Introductie

Technieken Anonimisatie

- Wat
- Beperkingen

Data Archipel

- Concept

- Proof of concept
- Een beetje crypto
- Deanonimisatie
- Sleutelbeheer
- Transparantie
- Small cells

Conclusies

Conclusie & toekomst

Kruisen van Persoonsgegevens

Een fictief voorbeeld

*Een **onderzoeksteam** wil medische, financiële en demografische persoonsgegevens analyseren van alle **burgers** die na 1990 geboren zijn, die zelfstandige in bijberoep zijn met een loon van minstens € 50 000.*

*Deze gegevens worden echter beheerd door verschillende **overheidsbedrijven** en moeten dus gekruist worden.*

Wetenschapper
Vlot kruisen data

Burger
Respect privacywetgeving

Overheidsorganisatie
Behoudt controle (want verantwoordelijk)

Allen
minimale impact data breach

Toegevoegde waarde

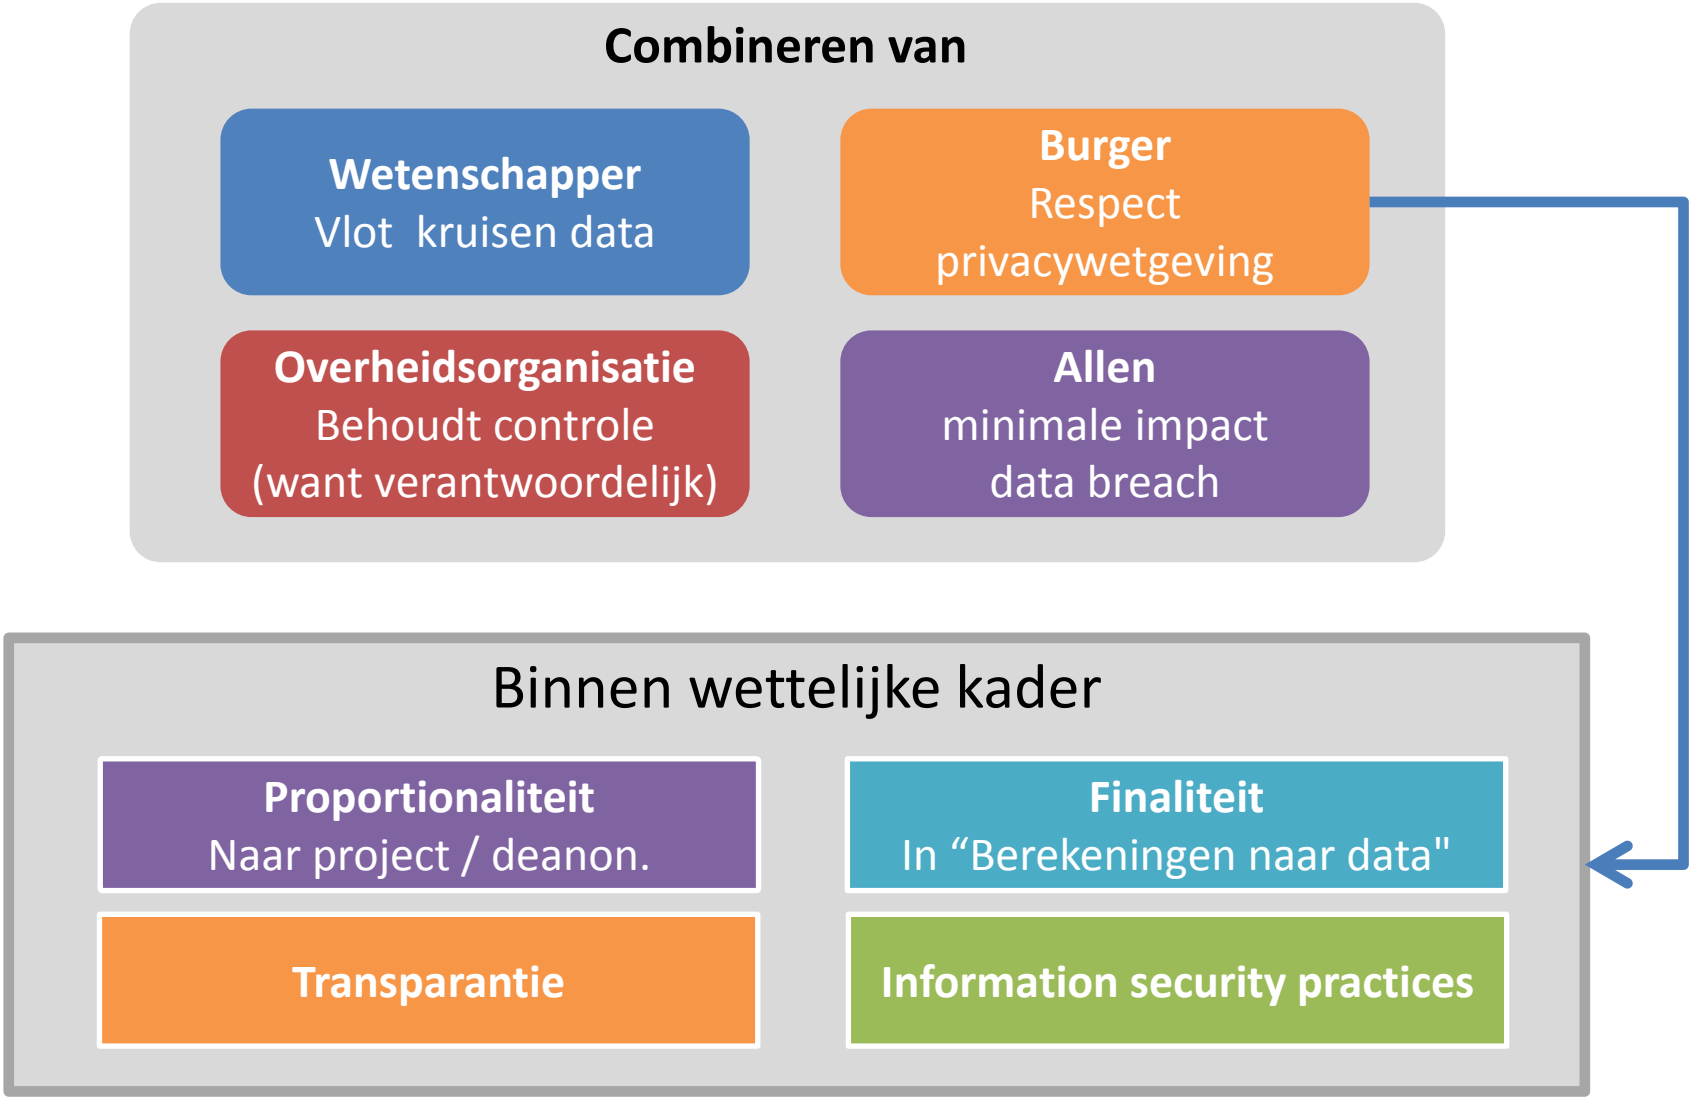

Stap vooruit t.o.v. huidige werkwijze

Flexibiliteit

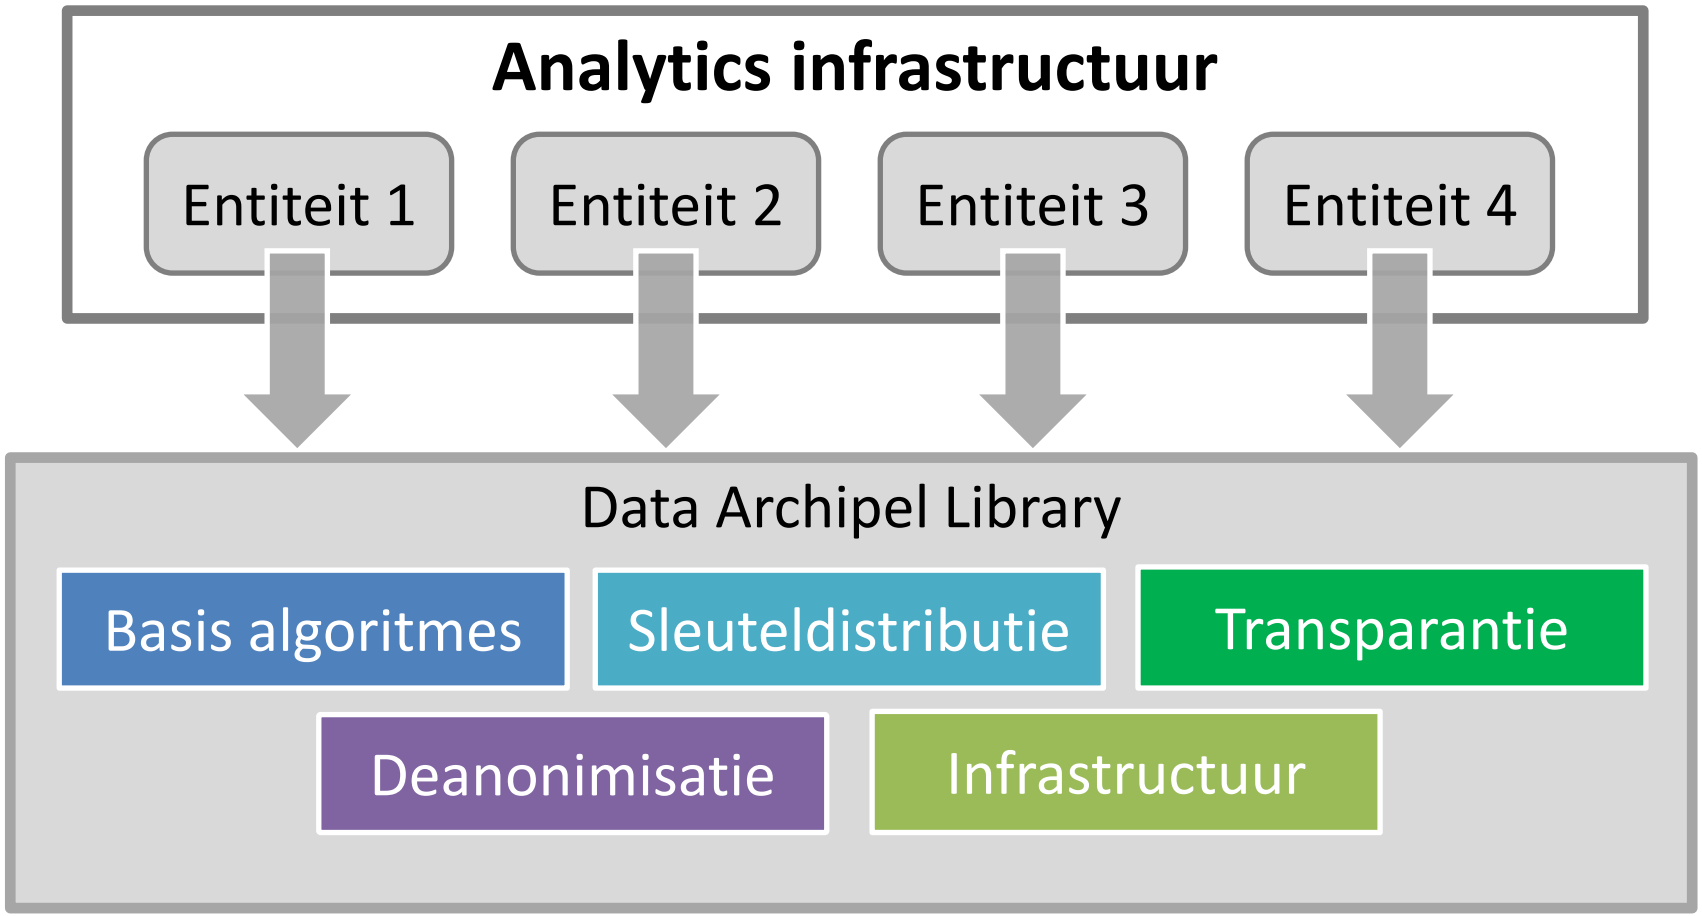

GEEN monolithisch systeem

Gedistribueerde Infrastructuur

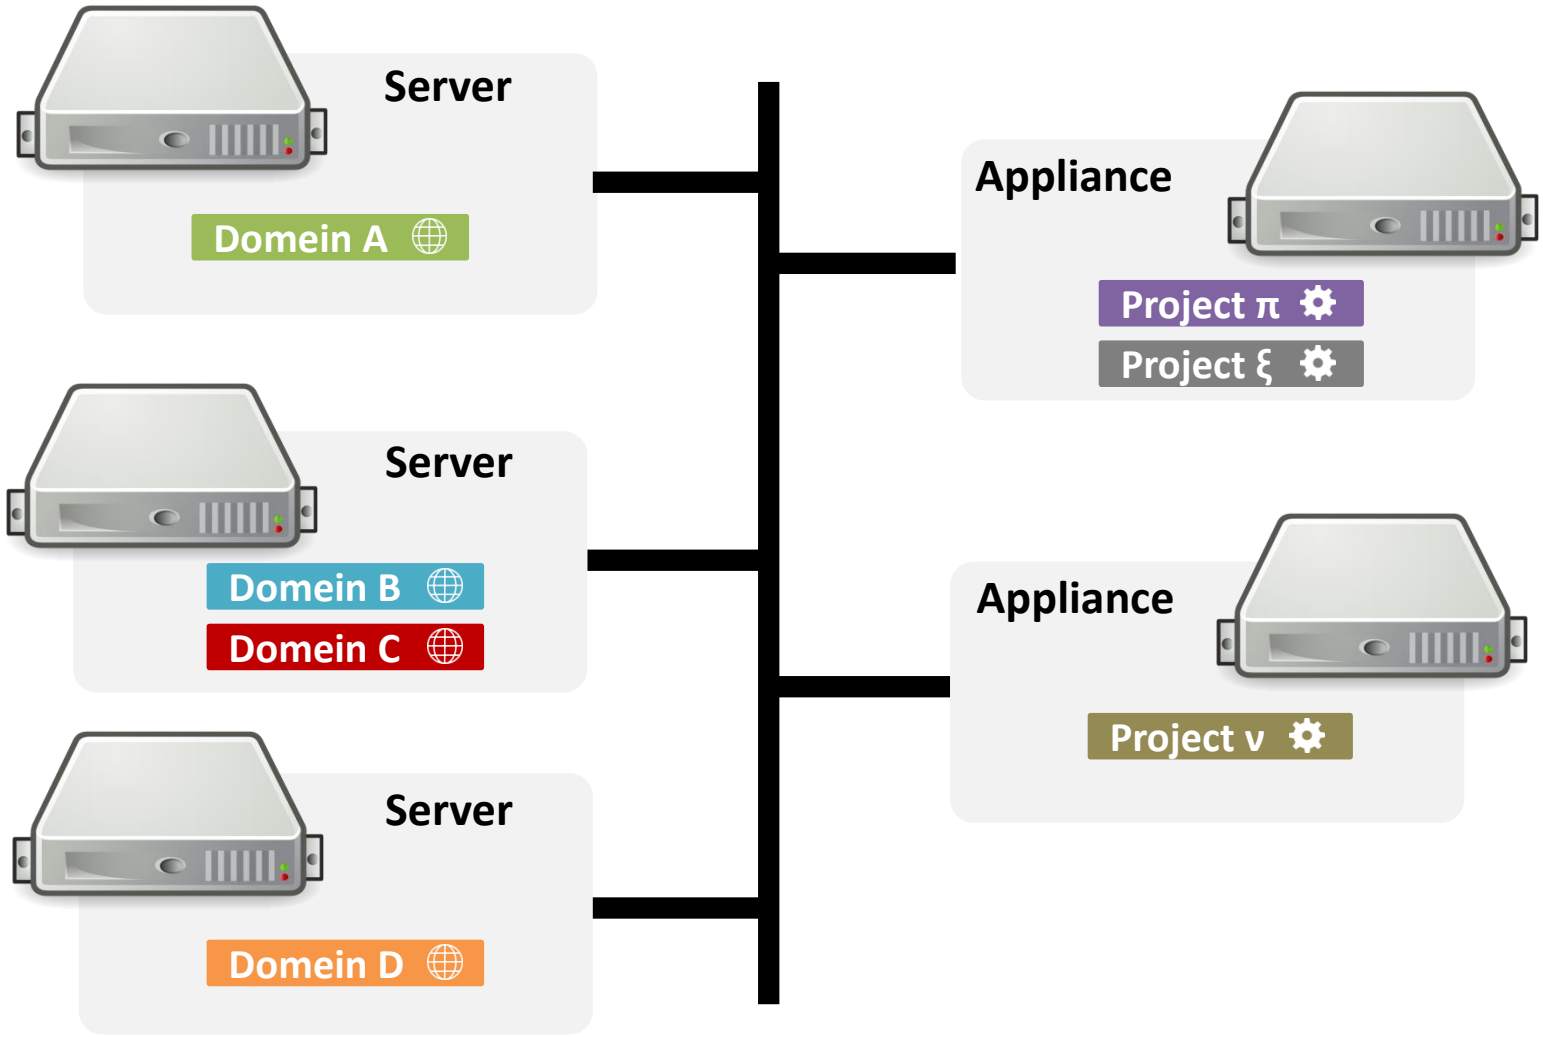

Horizontaal schaalbaar

Vereisten servers < appliances

[opt] zelfde DC → performantie

[opt] Instelling beheert server

Validatie

Juridische validatie

- Prof. dr. Van Eecke, UA & DLA Piper

Technische Validatie

- COSIC, KU Leuven (recent in WSJ)
- Departement computerwetenschappen, KU Leuven
- Internationale experts (PETS programme committee)

Functionele validatie

- Proof-of-concept
- Concrete case: **We need you!**

(WSJ, PETS)

Uitdagingen & Beperkingen

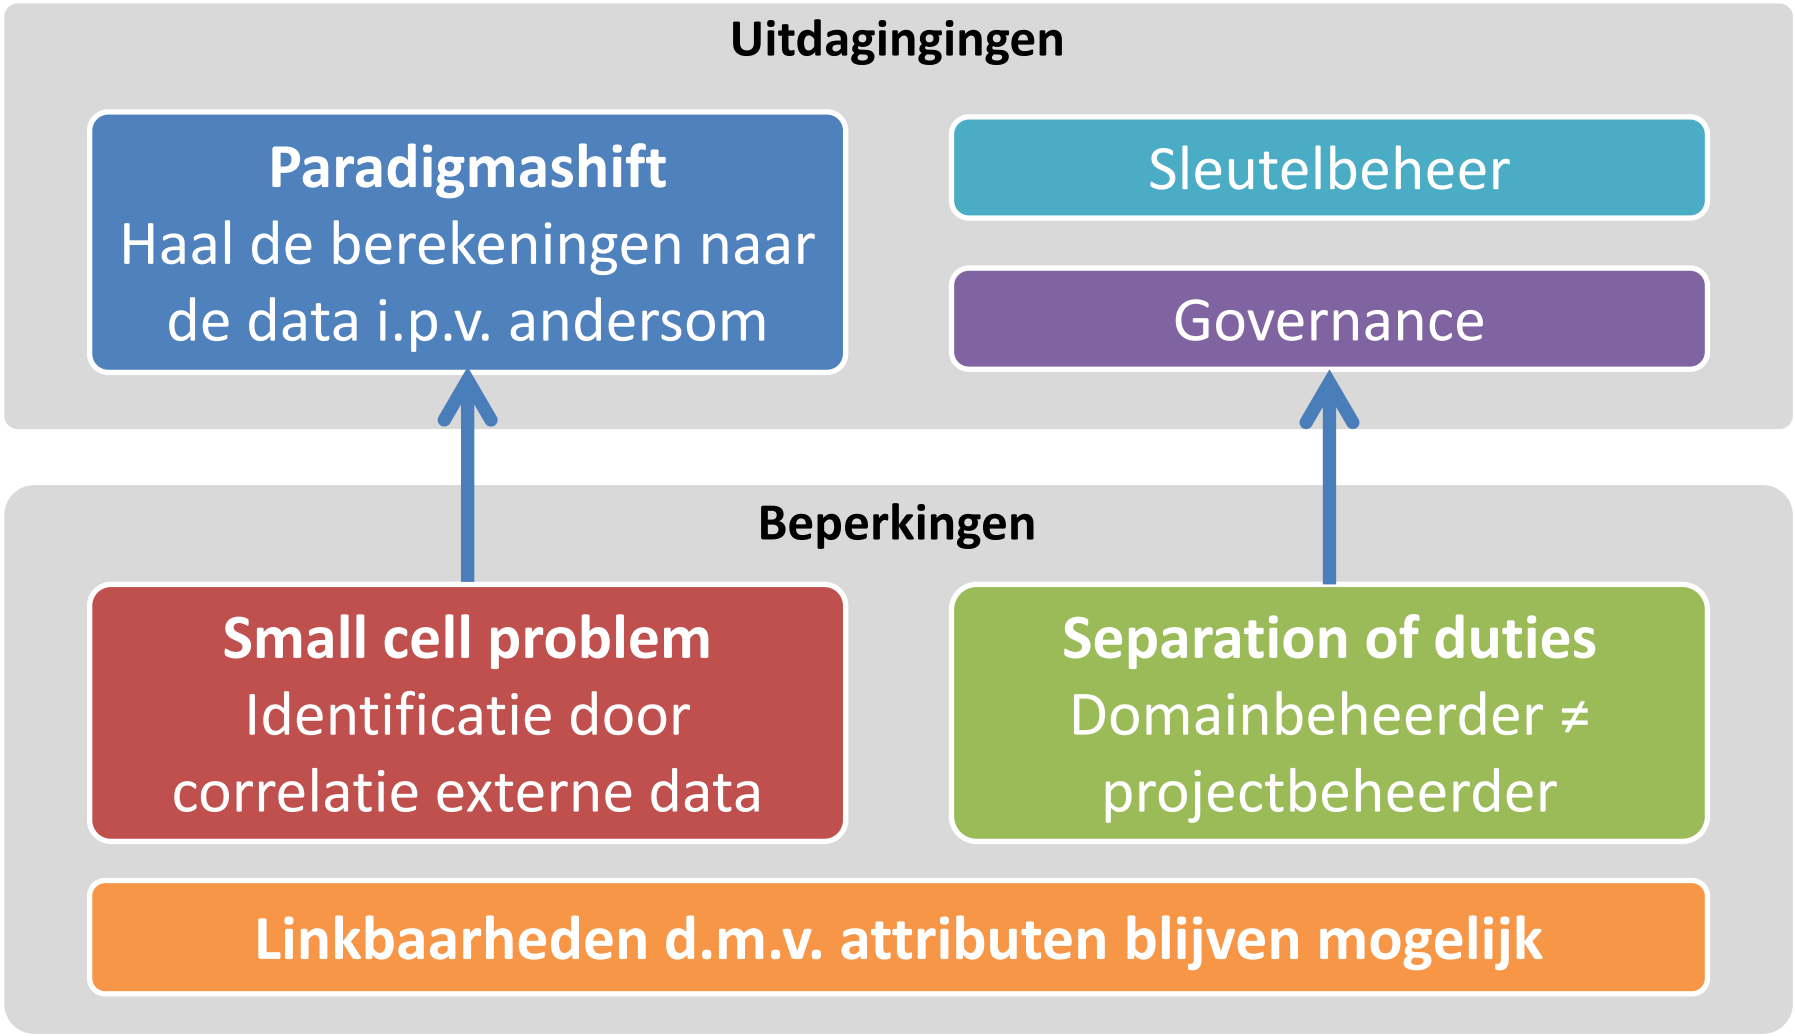

Voldoende interesse → verder onderzoek

Toekomst (voorwaardelijk)

Uitbreiden & toepassen POC

Uptake (delen van) concept door vendors

Ontwikkelen visie sector
In welke richting wat betreft data managment bij analytics?

Realisatie
Eventueel met privé

Verder onderzoek

Tijd

Publicaties

Blogpost Anonimisatie

Big data & krakend ijs onder anonimisatie

Mei 2015

Presentatie

Privacy vs. Analytics

Maart 2016

Wetenschappelijk artikel

Data Archipelago - Reconciling privacy and analytics on multi-source PII

2016

Toegankelijk rapport

Data Archipel – Analytics op gekruiste persoonsgegevens

Maart 2016

www.smalsresearch.be

Crypto@gov.be

Les Crypto is een extreem krachtige, veelzijdige tool die veel verder gaat dan traditionele encryptie, veilige verbindingen en digitale handtekeningen.

Maar onbekend = onbemind (ook in overheidscontext…)

- Data archipel
- Elliptische krommen
- Format preserving encryption
- Bitcoin / Blockchain
- Homomorphic encryption
- Anonymous credentials
- Quantum computing
- . . .

Bij voldoende interesse: Infosessie - Crypto Awareness

Kristof Verslype

02 787 53 76

Kristof.verslype@smals.be

@KristofVerslype

Smals

www.smals.be

@Smals_ICT

www.smalsresearch.be

@SmalsResearch

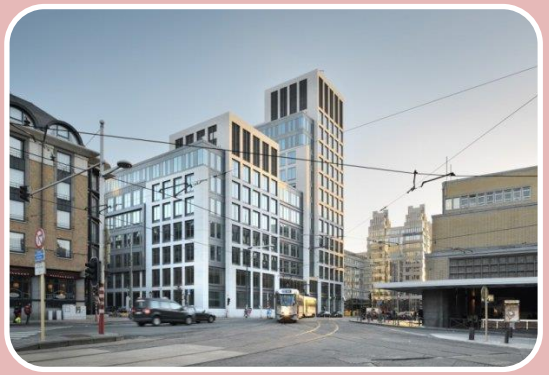

Referenties

- [AV07] Arvind Narayanan, Vitaly Shmatikov. ***How To Break Anonymity of the Netflix Prize Dataset.*** Cornell University Library. 22 november 2007. http://arxiv.org/abs/cs/0610105
- [B92] ***Wet van 8 december 1992 tot bescherming van de persoonlijke levensfeer ten opzichte van de verwerking van persoonsgegevens***. 1999. http://www.e-privacy.be/privacywet.pdf
- [C14] Ann Cavoukian. ***Big Data and Innovation, Setting the Record Straight: De-identification Does Work***. Canada. 16 juni 2014 http://www2.itif.org/2014-big-data-deidentification.pdf
- [I11] Information Commissioner's Office (ICO). ***Data sharing code of practice.*** Mei 2011. https://ico.org.uk/media/for.../1068/data_sharing_code_of_practice.pdf
- [I12] Information Commissioner's Office (ICO). ***Anonymisation: managing data protection risk code of practice.*** November 2012. https://ico.org.uk/media/1061/anonymisation-code.pdf
- [I14] Information Commissioner's Office (ICO). ***Big data and data protection*****.** 28 juli 2014. https://ico.org.uk/media/for-organisations/documents/1541/big-data-and-data-protection.pdf
- [KB01] ***Koninklijk besluit ter uitvoering van de wet van 8 december 1992 tot bescherming van de persoonlijke levenssfeer ten opzichte van de verwerking van persoonsgegevens.*** 13 februari 2001. http://www.privacycommission.be/sites/privacycommission/files/documents/CONS_kb_uitvoering_privacywet_13_02_2001.pdf
- [L01] Latanya Sweeney . k-Anonymity: A model for protecting privacy. Mei 2001. https://epic.org/privacy/reidentification/Sweeney_Article.pdf

Referenties (Ctd)

- [M13] Yves-Alexandre de Montjoye, César A. Hidalgo, Michel Verleysen & Vincent D. Blondel. ***Unique in the Crowd: The privacy bounds of human mobility***. 25 maart 2013. Scientific Reports 3, Article number: 1376. http://www.nature.com/srep/2013/130325/srep01376/fig_tab/srep01376_F1.html
- [M15a] Tania Martin, Smals research. ***Elliptic Curve Cryptography for dummies 1: introduction***. 25 februari 2015. https://www.smalsresearch.be/elliptic-curve-cryptography-tutoriel1/
- [M15b] Tania Martin, Smals Research. ***Elliptic Curve Cryptography for dummies 2: en pratique pour la cryptographie***. 12 Augustus 2015 https://www.smalsresearch.be/elliptic-curve-cryptography-tutoriel2/
- [MSC13] Viktor Mayer-Schonberger., Kenneth Cukier. ***Big Data: A Revolution That Will Transform How We Live, Work and Think***. 10 oktober 2013. http://arxiv.org/abs/1304.7605
- [NF14] Arvind Narayanan, Edward W. Felten. ***No silver bullet: De-identification still doesn't work***. 9 juli 2014. Princeton University. http://randomwalker.info/publications/no-silver-bullet-de-identification.pdf
- [O09] Paul Ohm. ***Broken Promises of Privacy: Responding to the surprising failure of anonymisation***. UCLA Law Review, Vol. 57, p. 1701, 2010; U of Colorado Law Legal Studies Research Paper No. 9-12. 13 augustus 2009 http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1450006
- [PCAST14] President's Council of Advisors on Science and Technology (PCAST). ***Big Data and Privacy: A Technological Perspective***. Mei 2014. http://www.whitehouse.gov/sites/default/files/microsites/ostp/PCAST/pcast_big_data_and_privacy_-_may_2014.pdf

Referenties (Ctd)

- [S15] Science. ***Credit card study blows holes in anonymity***. 30 januari 2015 http://www.sciencemagazinedigital.org/sciencemagazine/30_january_2015?folio=468#pg16
- [T14] Anthony Tockar. ***Differential Privacy: The Basics***. Neustar Research. 8 september 2014. http://research.neustar.biz/2014/09/08/differential-privacy-the-basics/
- [WP01] Article 29 Data Protection Working Party. ***Opinion 05/2014 on Anonymisation Techniques***. 10 april 2014 http://ec.europa.eu/justice/data-protection/article-29/documentation/opinion-recommendation/files/2014/wp216_en.pdf

Websites / Artikels

- (CNN07) CNN Money. ***101 Dumbest Moments in Business***. 2007 http://money.cnn.com/galleries/2007/biz2/0701/gallery.101dumbest_2007/
- (DN15) DataNews. ***Anonimiteit bij big data-analyse een illusie***. 2 februari 2015. http://datanews.knack.be/ict/nieuws/anonimiteit-bij-big-data-analyse-een-illusie/article-normal-529977.html
- ***(UKANON) UK Anonimisation Network*.** http://ukanon.net/
- (DM15) De Morgen. ***Google loopt deur plat bij Witte Huis***. 26 maart 2015. http://www.demorgen.be/economie/google-loopt-deur-plat-bij-witte-huis-a2265407/
- (NYT06) Michael Barbaro, Tom Zeller. **A Face Is Exposed for AOL Searcher No. 4417749.** 9 augustus 2006, New York Times.
- (ZD15) ZDNet. These companies lost your data in 2015's biggest hacks, breaches. 13 januari 2016. http://www.zdnet.com/pictures/worst-largest-security-data-breaches-2015/13/
- (OPM) Wikipedia. ***Office of Personnel Management data breach***. https://en.wikipedia.org/wiki/Office_of_Personnel_Management_data_breach/
- (PETS) Privacy Enhancing Technologies Symposium. https://www.petsymposium.org/
- (WSJ) Wall Street Journal. ***In Belgium, an Encryption Powerhouse Rises***. 10 December 2015 http://www.wsj.com/articles/in-belgium-an-encryption-powerhouse-rises-1449791014
- (JZ) Jianying Zhou. ***Top Crypto and Security Conferences Ranking (2015)***. http://icsd.i2r.a-star.edu.sg/staff/jianying/conference-ranking.html