

Investigating Leaked Sensitive Information in Version Control Systems with the Kraulhorizon Framework

Felix Wilkening, Lars Stiemert, Matthias Schopp, Daniela Pöhn, Wolfgang Hommel



**Forschungsinstitut
Cyber Defence**

Universität der Bundeswehr München

<https://www.unibw.de/code>
felix.wilkening@unibw.de

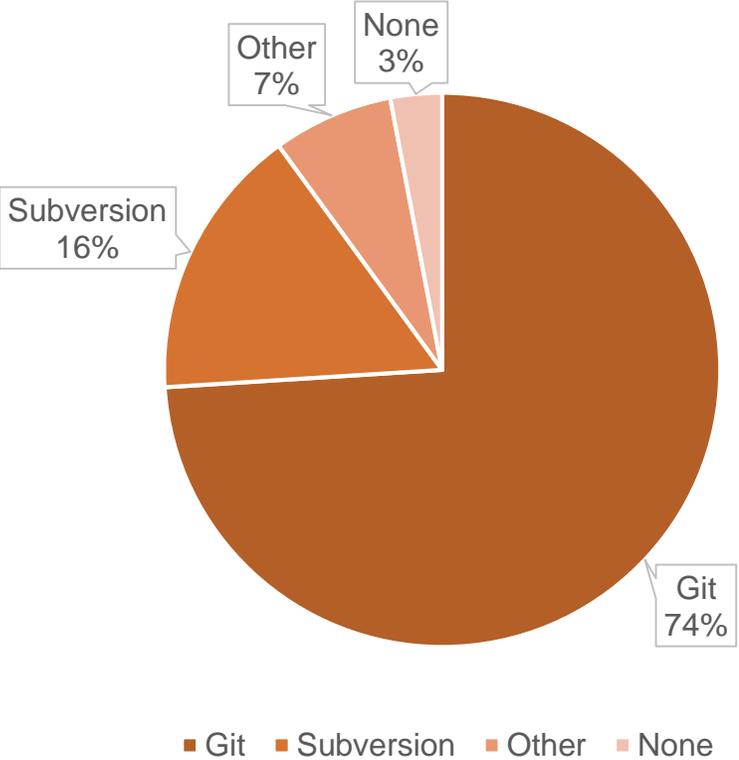
Agenda

- Einführung und Motivation
- Anforderungen
- Konzeptionierung
- Evaluation
- Zusammenfassung und Ausblick

Einführung und Motivation

"Which source code management platform does your team use for your main project?"

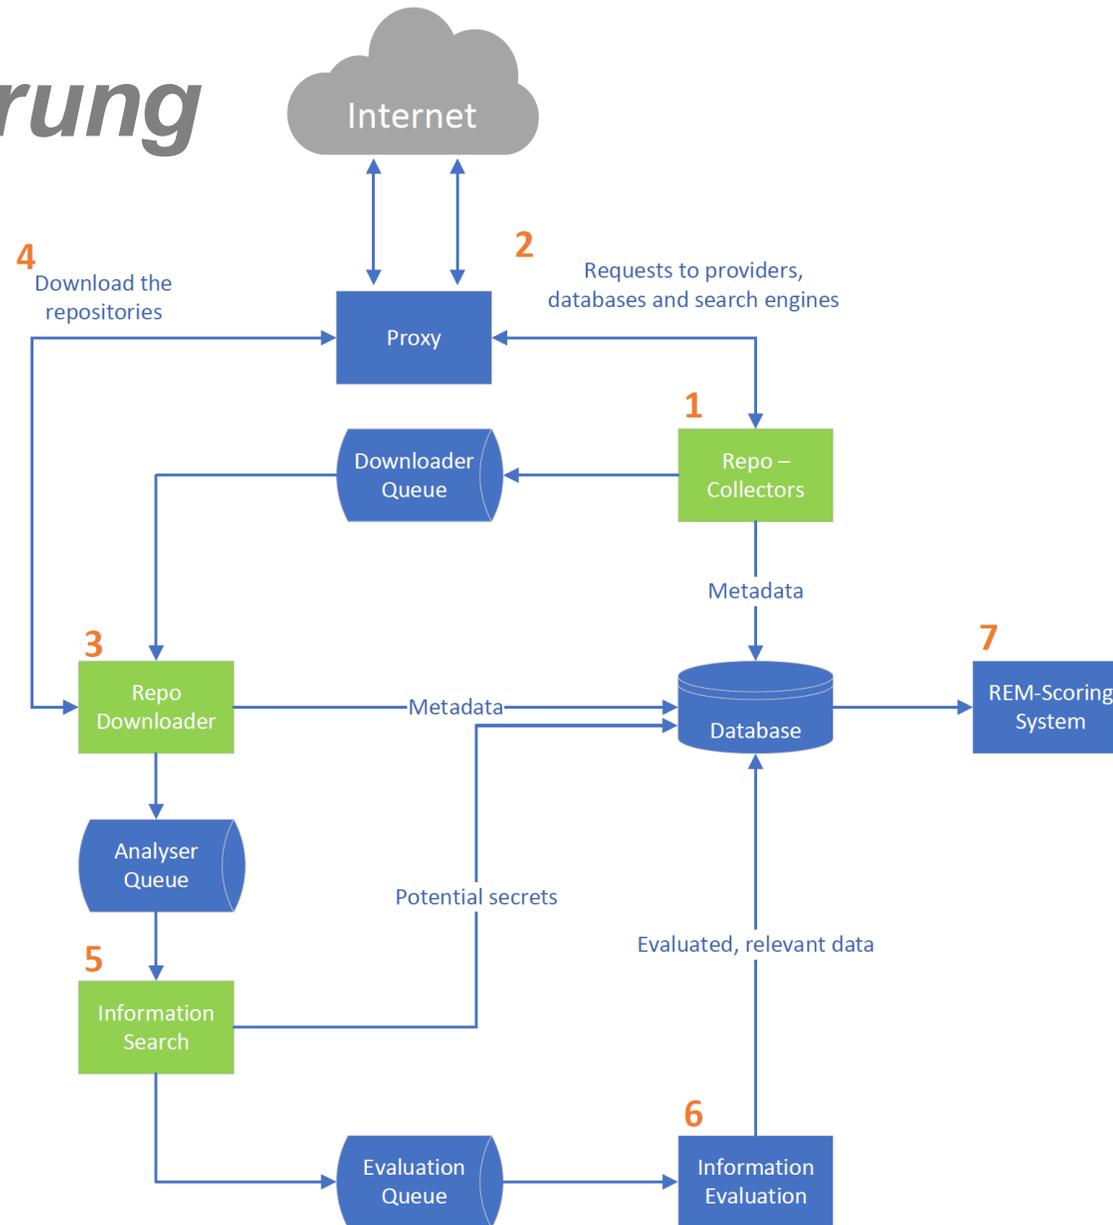
JVM-Report 2018



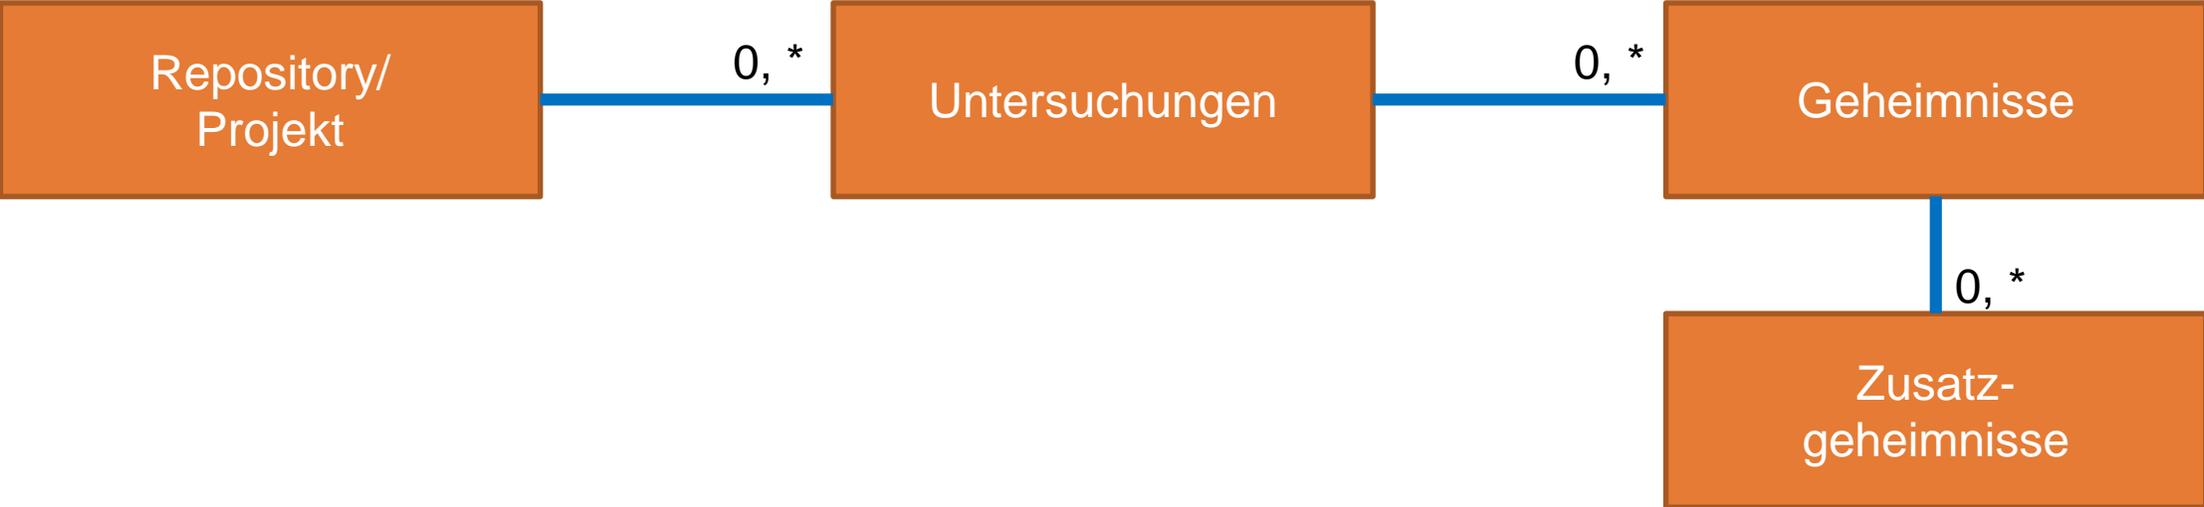
Anforderungen

- Automatische Suche nach Repositories
- Automatisches Herunterladen der Daten
- Analyse und Beurteilung der Daten
- Verschleierung der eigenen Identität
- Skalierbarkeit
- Modularität

Konzeptionierung



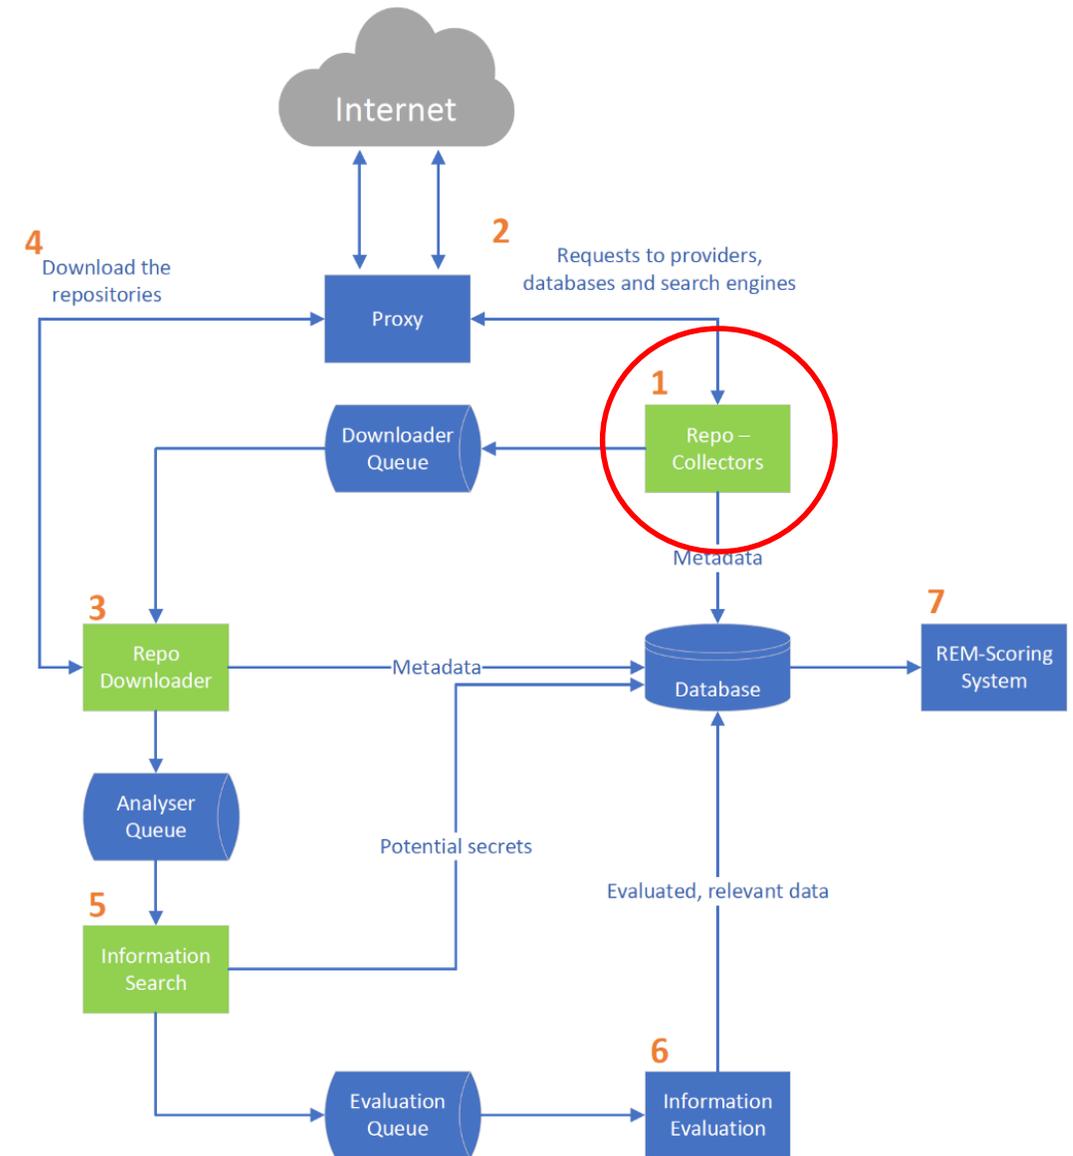
Konzeptionierung



Konzeptionierung

Repo-Kollektoren:

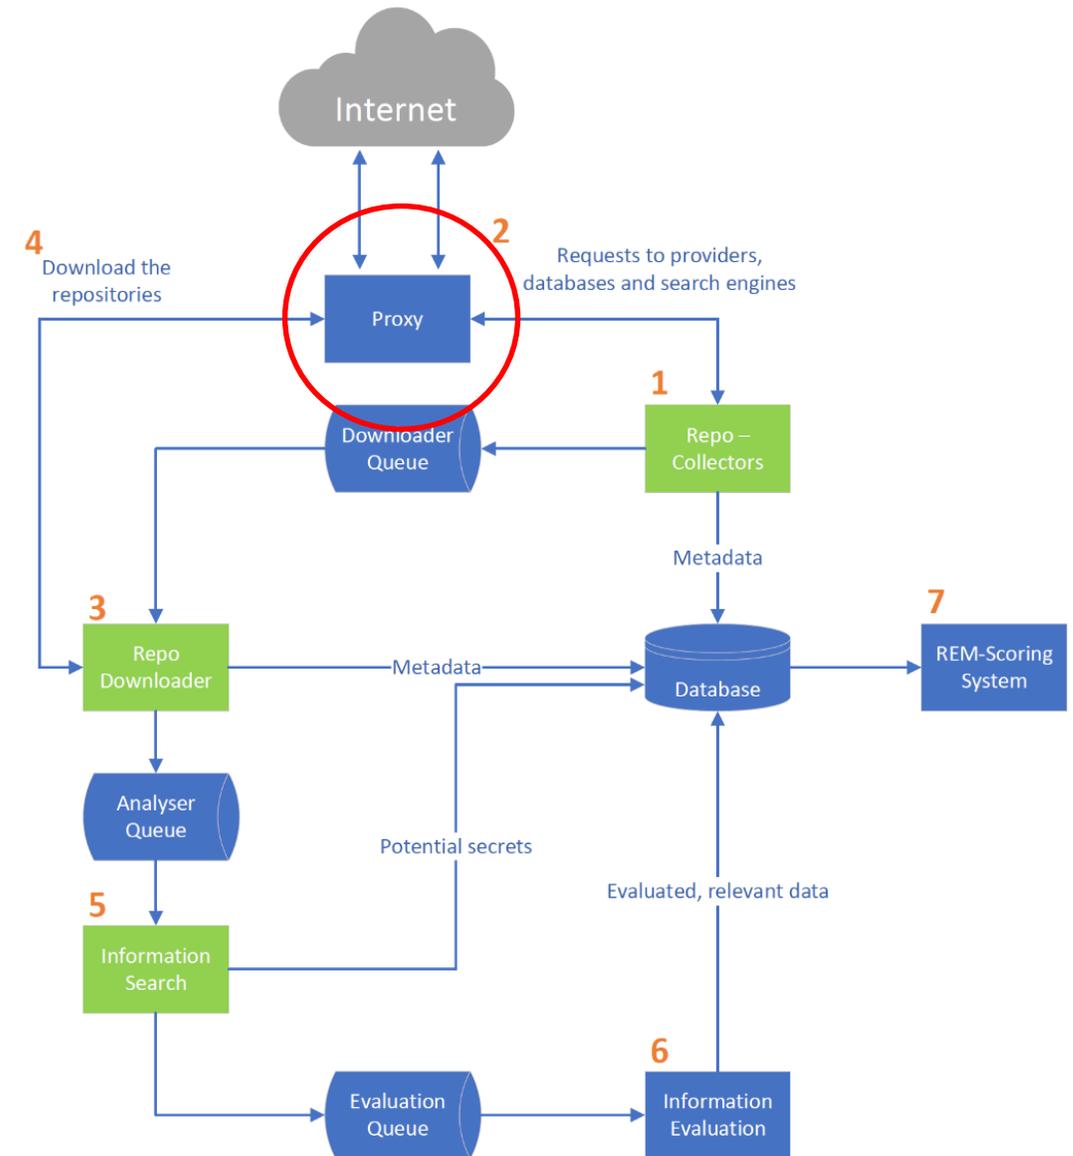
- Sammeln Repositories für spätere Untersuchungen
- Verschiedene Implementierungen für unterschiedliche Ziele



Konzeptionierung

Proxy:

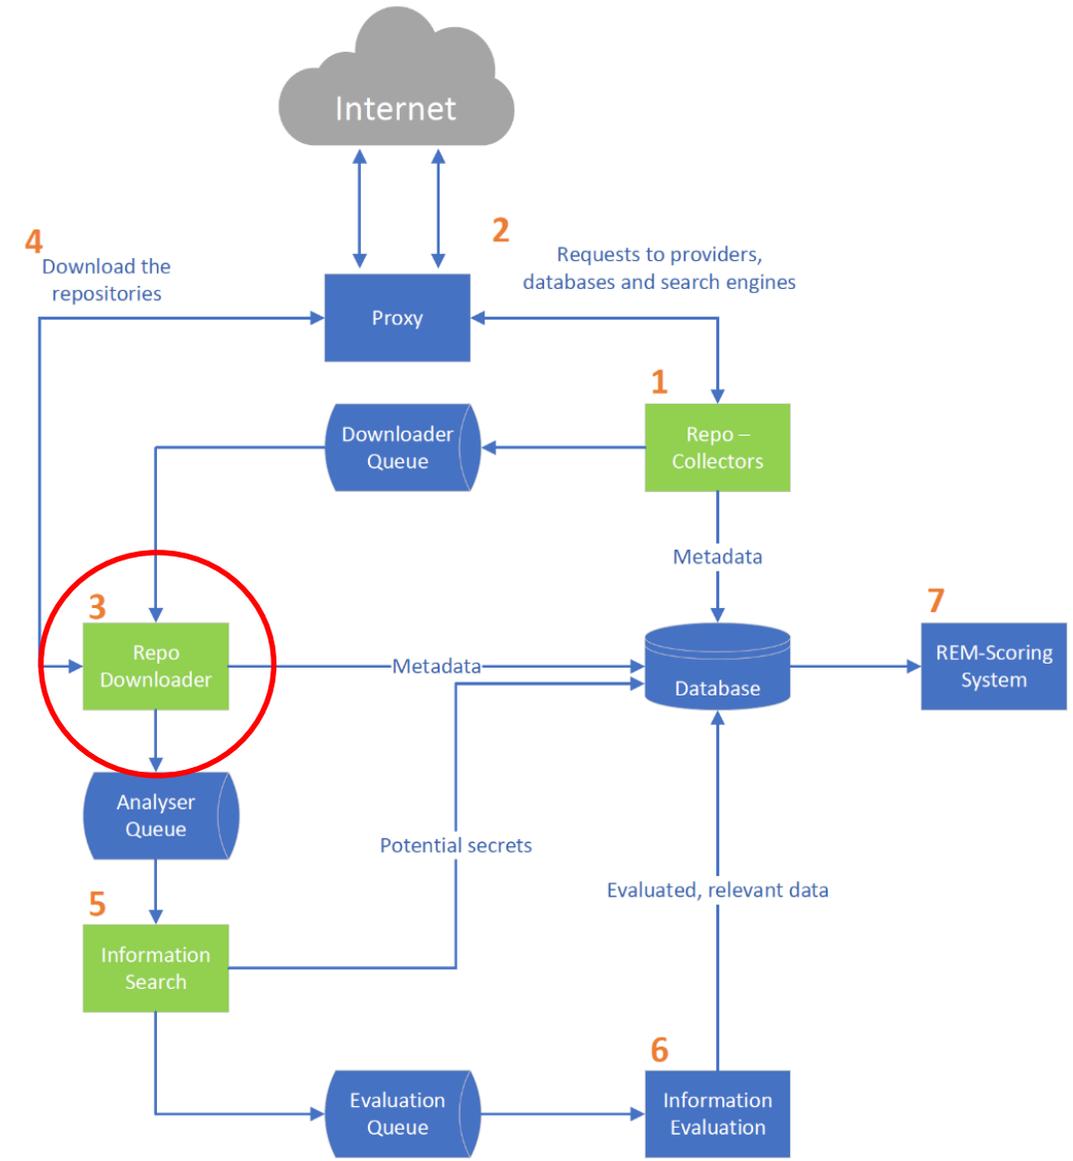
- Verschleiert die eigene Identität
- Zugang zu internen Systemen



Konzeptionierung

Repo-Downloader:

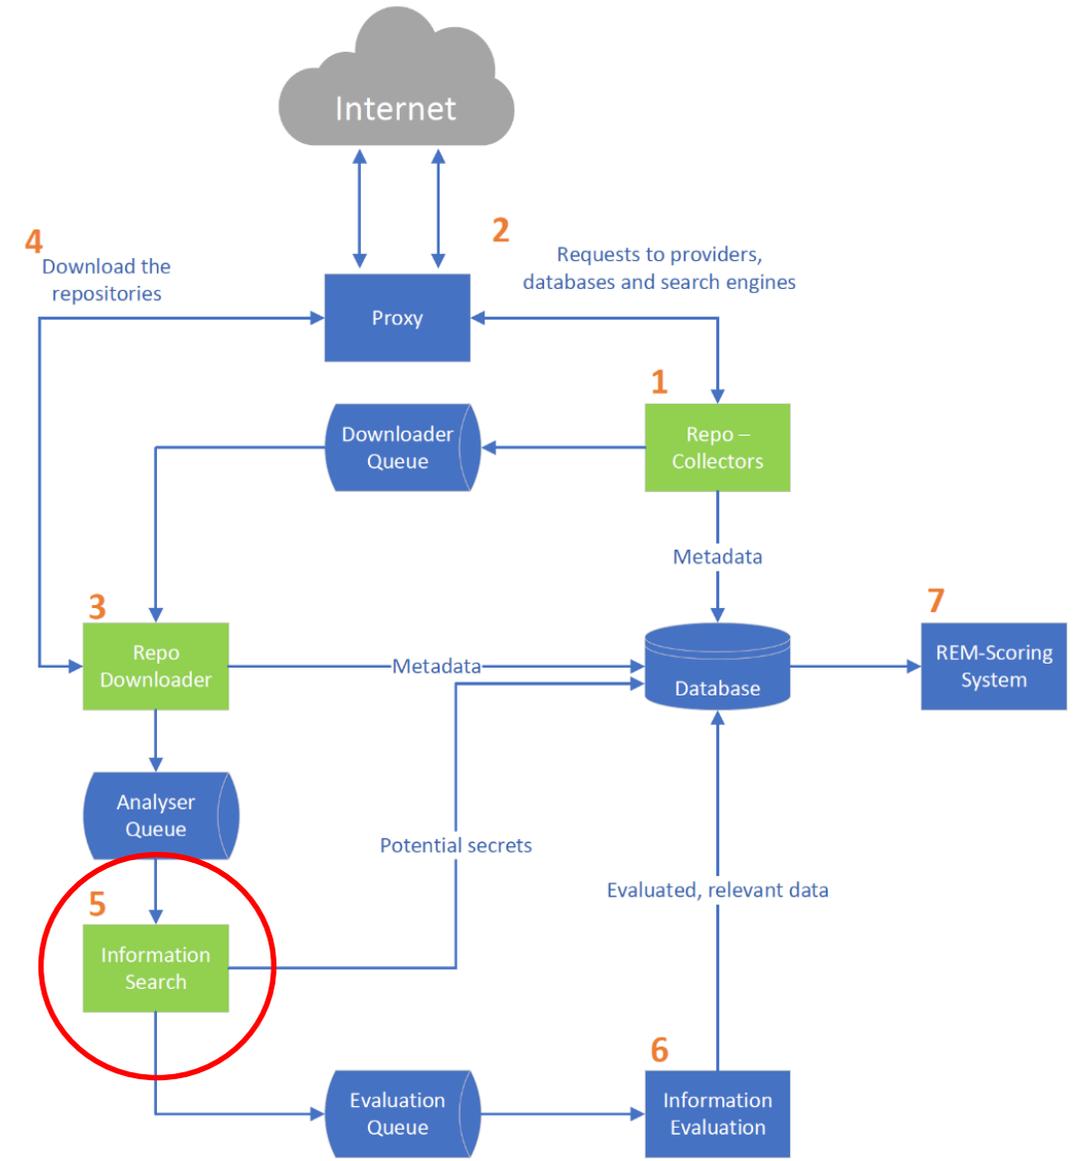
- Lädt Repositories herunter und speichert die Metadaten ab



Konzeptionierung

Information Search:

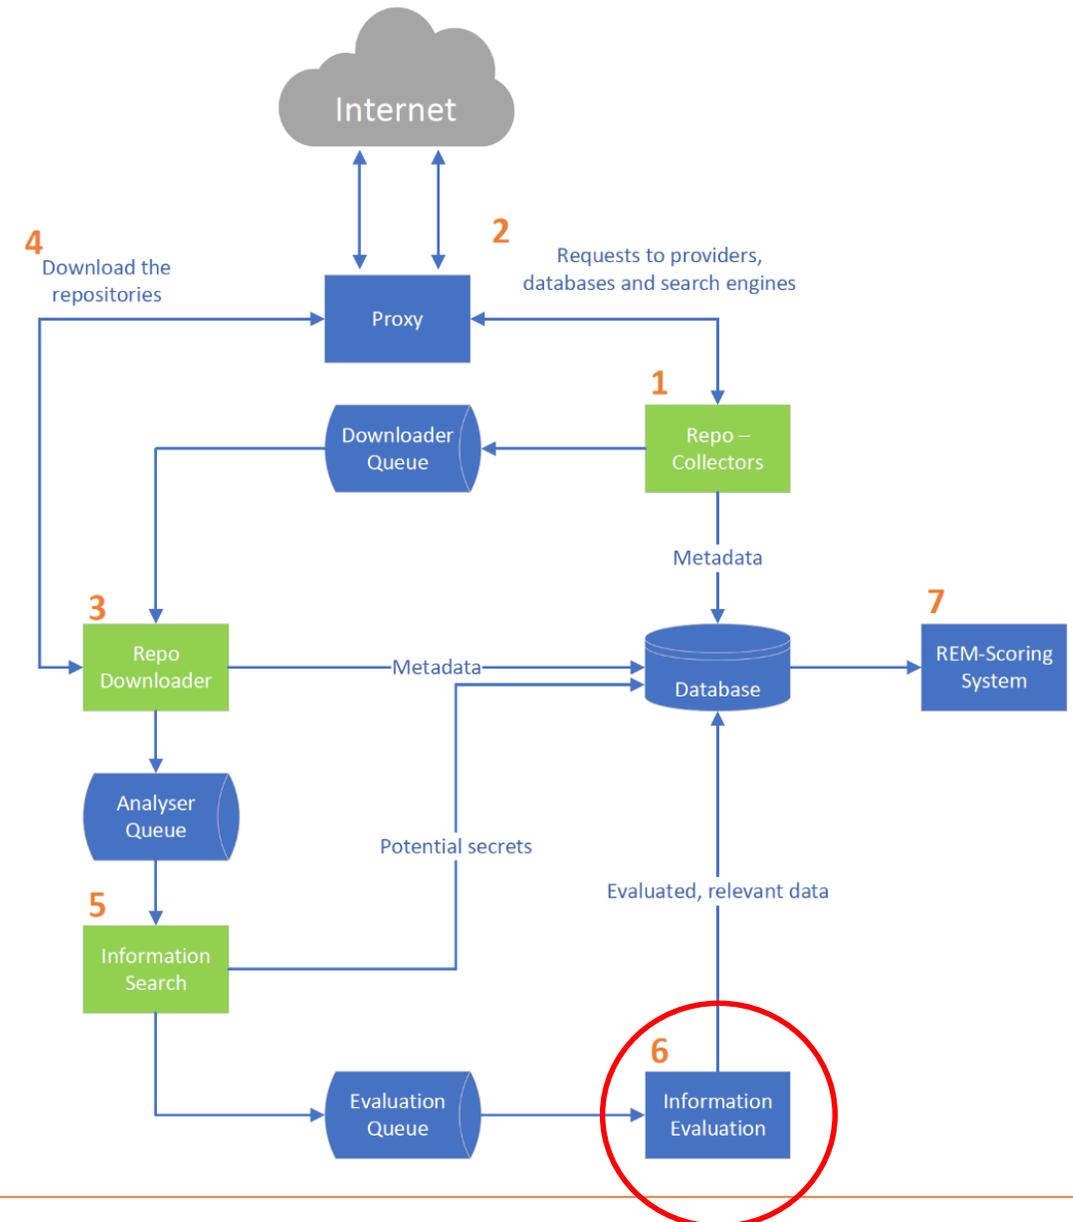
- Analysiert Repositories mittels Regex auf potentielle Geheimnisse



Konzeptionierung

Information Evaluation:

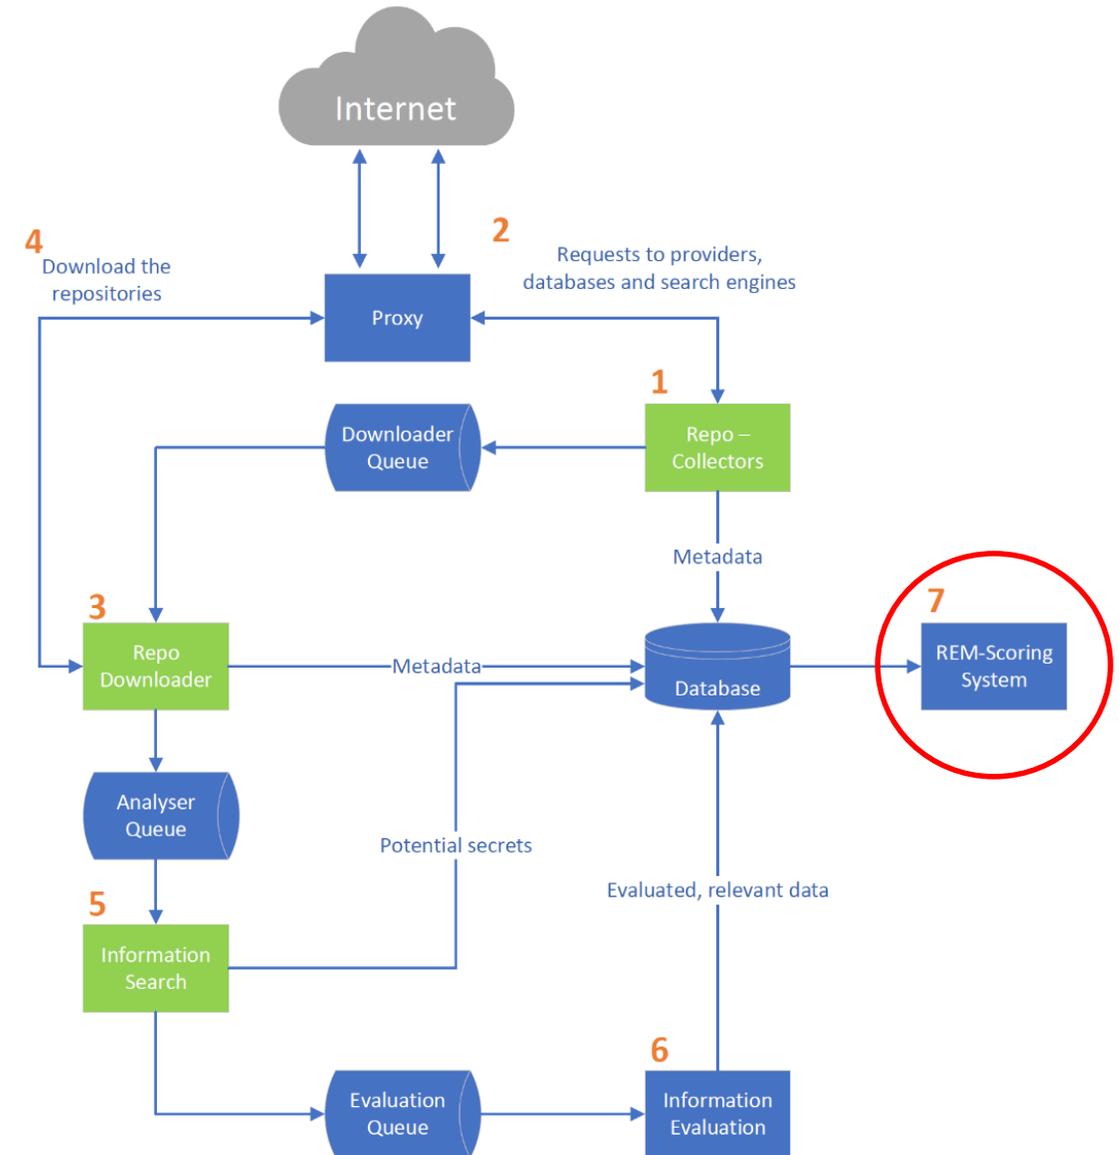
- Analysiert die gefundenen Geheimnisse
- Word-Filter
- Entropy-Filter
- Pattern-Filter



Konzeptionierung

REM-Scoring System:

- *Bewertung der Repositories mittels der Bewertungsvorschrift*



Konzeptionierung

Domain	Platform/API	Key Type	Single-factor or Multi-factor	Primary Risks			
				Monetary Loss	Privacy	Data Integrity	Message Abuse
Social Media	Twitter	Access Token	M		X	X	X
	Facebook	Access Token	S		X	X	X
	YouTube ^u	API Key	S	X	X		
		OAuth ID	M		X	X	X
	Picatic	API Key	S		X	X	X
Finance	Stripe	Standard API Key	S	X		X	
		Restricted API Key	S				
	Square	Access Token	S	X		X	
		OAuth Secret	S				
	PayPal Braintree	Access Token	S	X		X	
Amazon MWS	Auth Token	M	X	X	X	X	
Communications	Gmail	(same as YouTube) ^u	(same as YouTube) ^u		X	X	X
	Twilio	API Key	S		X	X	X
	MailGun	API Key	S		X	X	X
	MailChimp	API Key	S		X	X	X
Storage	Google Drive	(same as YouTube) ^u	(same as YouTube) ^u		X	X	
IaaS	Amazon AWS	Access Key ID	S	X	X	X	
	Google Cloud Platform	(same as YouTube) ^u	(same as YouTube) ^u	X	X	X	
Private Keys	RSA	Cryptographic key	M	X	X	X	X
	EC	Cryptographic key	M	X	X	X	X
	PGP	Cryptographic key	M	X	X	X	X
	General	Cryptographic key	M	X	X	X	X

Aus Meli et. al – „How Bad Can It Get?“

Konzeptionierung

$$ISS = 1 - ((1 - Geldverlust) \cdot (1 - Privacy) \cdot (1 - Integritaet) \cdot (1 - Falschmeldungen)) \quad (5.1)$$

$$Auswirkungen = 5 \cdot ISS \quad (5.2)$$

$$Grundwert = 4 \cdot Typ \cdot Multifaktor \quad (5.3)$$

$$Kennwert = 0(\text{wenn } Auswirkungen = 0) \quad (5.4)$$

$$Kennwert = Round(\text{Minimum}(Veraltet \cdot (Grundwert + Auswirkungen), 10)) \quad (5.5)$$

$$\text{Gesamtkennwert} = \min\left(\sum_{s=0}^n \text{Kennwert}_s, 20\right)$$

Konzeptionierung

Domain	Platform/API	Key Type	Single-factor or Multi-factor	Primary Risks			
				Monetary Loss	Privacy	Data Integrity	Message Abuse
Social Media	Twitter	Access Token	M		X	X	X
	Facebook	Access Token	S		X	X	X
	YouTube ^u	API Key	S	X	X		
		OAuth ID	M		X	X	X
	Picatic	API Key	S		X	X	X
Finance	Stripe	Standard API Key	S	X		X	
		Restricted API Key	S				
	Square	Access Token	S	X		X	
		OAuth Secret	S				
	PayPal Braintree	Access Token	S	X		X	
Amazon MWS	Auth Token	M	X	X	X	X	
Communications	Gmail	(same as YouTube) ^u	(same as YouTube) ^u		X	X	X
	Twilio	API Key	S		X	X	X
	MailGun	API Key	S		X	X	X
	MailChimp	API Key	S		X	X	X
Storage	Google Drive	(same as YouTube) ^u	(same as YouTube) ^u		X	X	
IaaS	Amazon AWS	Access Key ID	S	X	X	X	
	Google Cloud Platform	(same as YouTube) ^u	(same as YouTube) ^u	X	X	X	
Private Keys	RSA	Cryptographic key	M	X	X	X	X
	EC	Cryptographic key	M	X	X	X	X
	PGP	Cryptographic key	M	X	X	X	X
	General	Cryptographic key	M	X	X	X	X

Aus Meli et. al – „How Bad Can It Get?“

Konzeptionierung

Eigenschaft	Metrik-Wert	Symbol	Wert	Definition
Geldverlust (Gv) Privacy (Pr)	Keiner	K	0	Wenn die entsprechende Eigenschaft ungefährdet ist.
Integrität (I) Falschmeldungen (Fm)	Hoch	H	0.4	Wenn durch Missbrauch der Datei die entsprechende Eigenschaft gefährdet ist.
Multifaktor (Mf)	Unsicher	U	1	Es handelt sich um ein allein stehendes Geheimnis, oder ein Multifaktorgeheimnis, bei welchem alle Geheimnisse bekannt sind.
	Sicher	S	0.2	Bei einem Multifaktorgeheimnis sind nicht alle Geheimnisse bekannt und die Daten können nicht ausgenutzt werden.
Typ (Ty)	Zugangsdaten	Z	1	Standartwert für alle Datentypen, die keine kryptografischen Schlüssel sind.
	Kryptodaten	K	1.5	Wenn es sich um kryptografische Daten, wie z. B. Schlüssel handelt.
Veraltet (Ve)	Gültig	G	1	Standartwert für alle gefundenen sensiblen Daten.
	Veraltet	V	0	Der Wert ist nachweislich veraltet oder ungültig. Dies tritt ein, wenn z. B. ein Zugangstoken oder Schlüssel abgelaufen ist.

Konzeptionierung

Beispielrechnung für einen Amazon MWS-Token
(inklusive Zusatzgeheimnis)

$$0.8704 = 1 - ((1 - 0.4) \cdot (1 - 0.4) \cdot (1 - 0.4) \cdot (1 - 0.4))$$

$$4.352 = 5 \cdot 0.8704$$

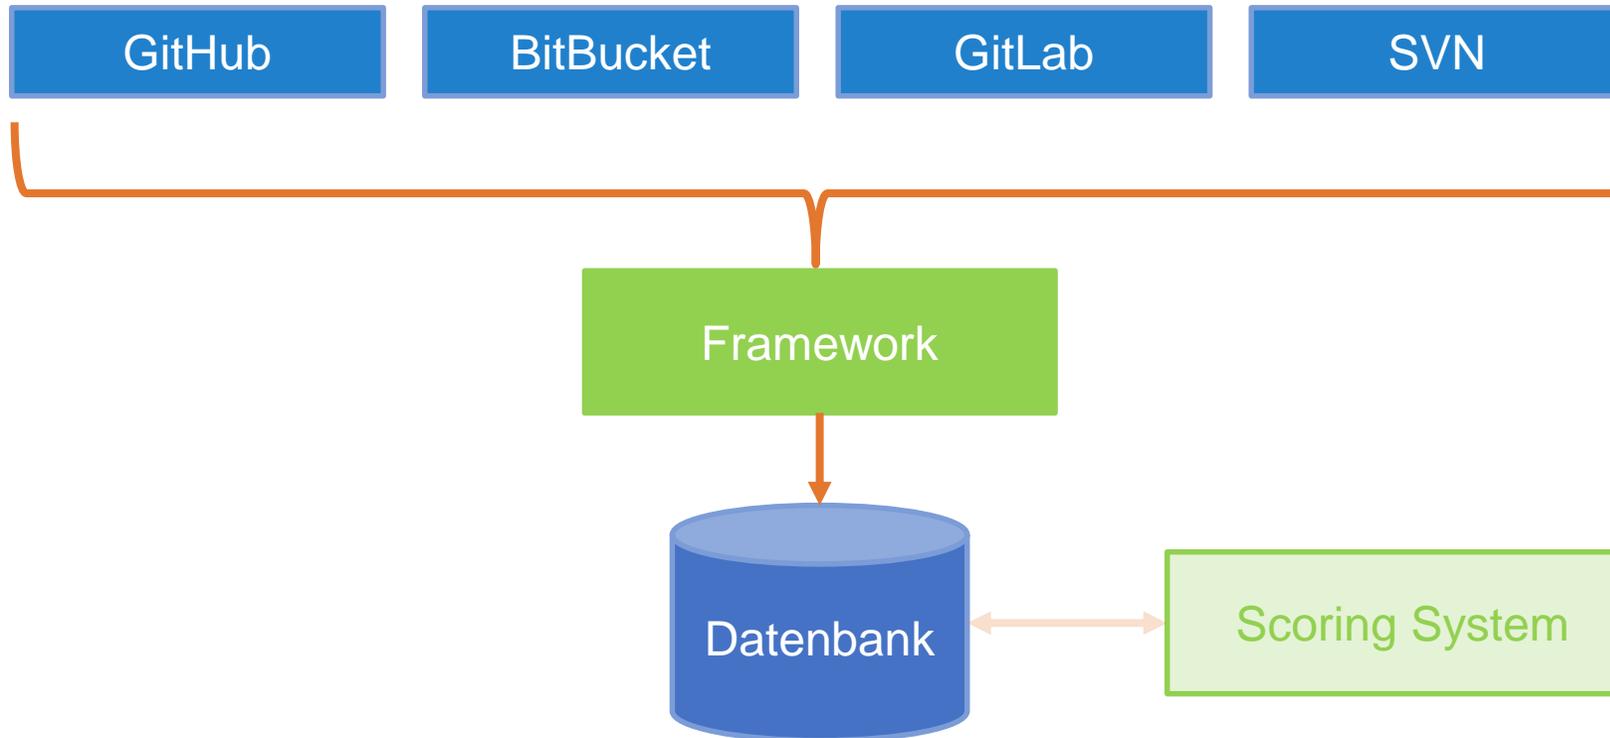
$$4 = 4 \cdot 1 \cdot 1$$

$$8.4 = \text{Round}(\text{Minimum}(1 \cdot (4 + 4.352), 10))$$

REMr1.0 = {GV:H/Pr:H/I:H/Fm:H/Mf:U/Ty:Z/Ve:G}

Evaluation

Erster Test: Präparierte Daten von verschiedenen SVN und Git-Repositories herunterladen und analysieren



Evaluation

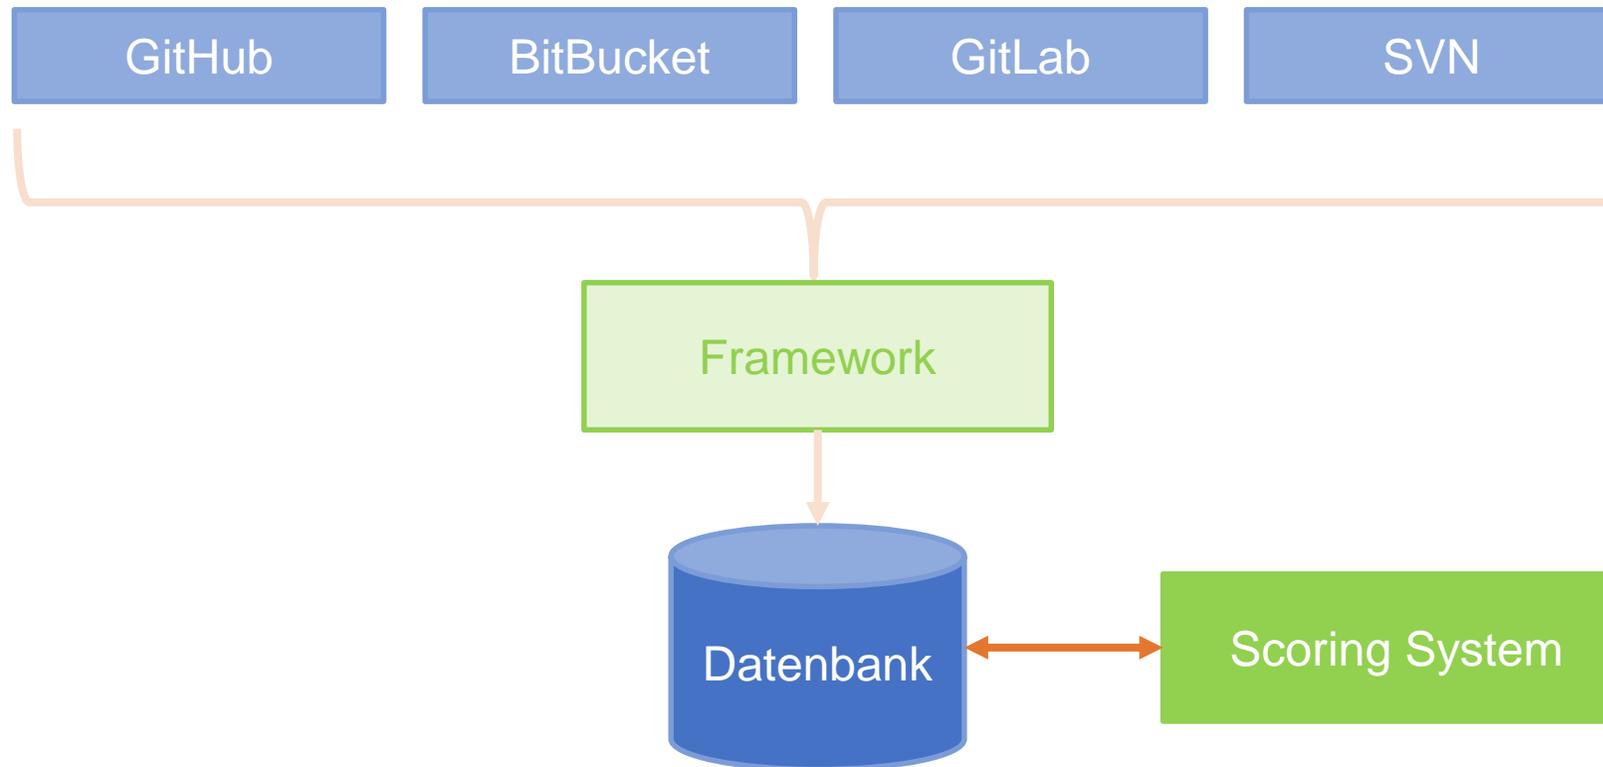
Erster Test: Präparierte Daten von verschiedenen SVN und Git-Repositories herunterladen und analysieren

Resultate:

- Verschiedene Provider können angefragt werden*
- Daten werden lokal gespeichert*
- Bei Git-Repositories werden alle gestreuten Geheimnisse erkannt,*
- Bei SVN lediglich die letzte Revision*
- Doppelte Erkennungen durch Regex sind möglich*

Evaluation

Zweiter Test: Auswerten der Repositories mittels des Scoring Systems



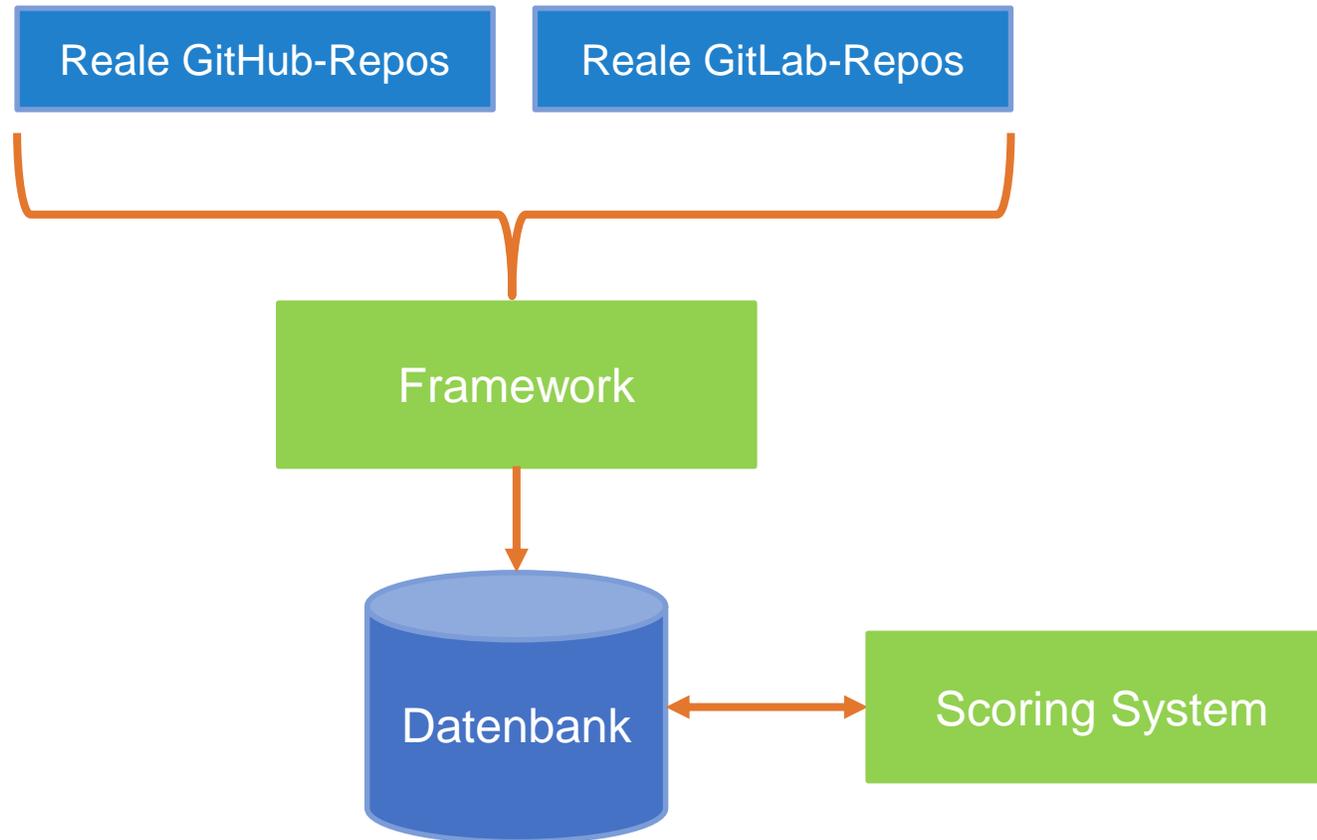
Evaluation

Zweiter Test: Auswerten der Repositories mittels des Scoring Systems

```
{
  "_id" : ObjectId("60edf7419d363d75c1d3ea76"),
  "repo_storage_id" : ObjectId("60edf73b13dd88222b33fa23"),
  "type" : "Git",
  "date_time" : "13-07-2021 22:27:44",
  "size" : 3683,
  "duration_download" : 0.8720064440003625,
  "filepath" : "/home/worker/Repositories/gitlab.com/justm4ster1t/uselessstuff4testing/13-07-2021 22:27:44",
  "found_secrets" : [
    ObjectId("60edf7413e152c513dc32334"),
    ObjectId("60edf7413e152c513dc32335"),
    ObjectId("60edf7413e152c513dc32336")
  ],
  "duration_file_analyser" : 0.08544835199973022,
  "score" : 13.1,
  "score_vector" : "REMV1.0{Gv:H/Pr:H/I:H/Fm:H/MF:H/Ty:Z/Ve:G}{Gv:H/Pr:H/I:H/Fm:H/MF:K/Ty:Z/Ve:G}"
}
{
  "_id" : ObjectId("60edf74332fbc704c10f765e"),
  "repo_storage_id" : ObjectId("60edf73b13dd88222b33fa23"),
  "type" : "Git",
  "date_time" : "13-07-2021 22:27:46",
  "size" : 4781,
  "duration_download" : 1.4344857480000428,
  "filepath" : "/home/worker/Repositories/Bitbucket/W1Fe1483984@bitbucket.org/W1Fe1483984/uselessstuff4demo/13-07-2021 22:27:46",
  "found_secrets" : [
    ObjectId("60edf7445aa7b619b1bbfef7"),
    ObjectId("60edf7445aa7b619b1bbfef8")
  ],
  "duration_file_analyser" : 0.0883312020005178,
  "score" : 9.4,
  "score_vector" : "REMV1.0{Gv:H/Pr:H/I:H/Fm:H/MF:K/Ty:Z/Ve:G}{Gv:H/Pr:H/I:H/Fm:H/MF:K/Ty:Z/Ve:G}"
}
```

Evaluation

Dritter und vierter Test: Auswerten von GitHub und GitLab Repositories



Evaluation

Dritter Test: Auswerten von GitLab Repositories

Resultate:

- *12.500 GitLab Repositories erfasst*
- *9.039 Repositories heruntergeladen*
- *4.717 Repositories analysiert*
- *Keine Funde von sensiblen Informationen*

Evaluation

Vierter Test: Auswerten von GitHub Repositories. 1.000 Repositories jeweils via Git und SVN.

Resultate:

- 991 heruntergeladene Repositories*
- 734 analysiert*
- Git: 22 gefundene private RSA-Schlüssel in 15 Repositories*

Zusammenfassung und Ausblick

- *Framework für die Untersuchung verschiedener Versionsverwaltungssysteme*
- *Bewertungssystem für geleakte Informationen*
- *Nachweis der Funktionsfähigkeit des Prototypen an realen Repositories*

- *Weitere Verbesserungen*
- *Umfassendere Studie mit Realdaten*

Fragen?

<https://www.unibw.de/code>
felix.wilkening@unibw.de

Bildquellen

Bitcoin (Folie 3 – Einführung und Motivation)

<https://pixabay.com/de/vectors/bitcoin-digitale-w%C3%A4hrung-4130299>

(Zugriff am 30.01.2022 16:15)