



# A Human-in-the-Loop Approach for Information Extraction from Privacy Policies under Data Scarcity

Michael Gebauer, Faraz Maschhur, Nicola Leschke, Elias Grünewald, and Frank Pallas

Information Systems Engineering  
TU Berlin

**Opinion | THE PRIVACY PROJECT**

# We Read 150 Privacy Policies. They Were an Incomprehensible Disaster.

By Kevin Litman-Navarro

In the background here are several privacy policies from major tech and media platforms. Like most privacy policies, they're verbose and full of legal jargon — and opaquely establish companies' justifications for collecting and selling your data. The data market has become the engine of the internet, and these privacy policies we agree to but don't fully understand help fuel it.

<https://www.nytimes.com/interactive/2019/06/12/opinion/facebook-google-privacy-policies.html>



<https://www.designboom.com/readers/dima-yarovinsky-visualizes-facebook-instagram-snapchat-terms-of-service-05-07-2018/>

Hinweis zu ausgelegten Bearbeitungen: Bestimmte Drittanbieter und Unternehmen der PayPal-Gruppe benötigen Bearbeitungen für PayPal (Standard) S.A. (L) et Cie, S.A. (PayPal), damit PayPal Ihre Dienstleistungen anbieten kann. Wir geben möglicherweise Daten an diese Personen weiter, darunter personalisierte Empfehlungen von den praktischsten verfügbaren geschäftlichen Angeboten und Erstattungen zu Ihren Transaktionen. Diese Drittanbieter haben Ihren Sitz an verschiedenen Orten in den Europäischen Union (insbesondere Frankreich, Deutschland, Irland, Spanien, Italien, Belgien, Portugal, Italien, Polen, Spanien, Schweden, Dänemark) und dem Vereinigten Königreich sowie in Taiwan, Japan, Südkorea, den Philippinen und den Vereinigten Staaten. Gemäß dem Luxemburger Gesetz über den Finanzsektor haben wir Ihre Daten geteilt, um die für solche Abrechnungen erforderlichen Daten zu bereitstellen.

Kategorie	Name der Partei und Geschäftszweck (in Klammern)	Zweck	Offengelegte Daten
1. Zahlungsdienstleister	Banken Bank Plc (GB), HSBC Bank Plc (GB), Standard Bank Services LLP (GB), Bank of America N.A. (USA), (USA), BA Continuum India (Private Limited (India)), Citicor Financial Services (USA), (Philippine) Citicor Bank (USA), (USA), BNP Paribas (Frankreich), (Frankreich) Citicor Bank (USA), (USA), American Express (USA), National Instruments Bank Plc (GB), Citigroup Limited (USA), Barclays Bank Limited (Australien), ANZ National Bank Limited (Neuseeland), Transaction Network Services UK Limited (GB)	Zahlungsvorbereitung, Abwicklung und Bearbeitung	Name, Adresse, E-Mail-Adresse, Telefonnummer, Angaben zu Zahlungsgeschäften des Nutzers und Angaben zu Zahlungstransaktionen, Zahlungstransaktionsnummern.
	BNP Paribas (Frankreich)	Zahlungsvorbereitung, Betragsprüfung und Aufbuchung für Transaktionen von PayPal-Nutzern, wenn dies mit einem Handel (es sei denn, der den Nutzer dazu über den	Name, E-Mail-Adresse, Telefonnummer, Adresse, IP-Adresse, Geräteidentifikator, PayPal-Kontennummer, Ermittlungen zu den Finanzierungsaktivitäten des Nutzers und Angaben zu Zahlungstransaktionen.
Abgleich von	Abgleich von	Name, Adresse, E-Mail-Adresse, Telefonnummer, Angaben zu den Finanzierungsaktivitäten des Nutzers und Angaben zu Zahlungstransaktionen.	Name, Adresse, E-Mail-Adresse, Telefonnummer, Angaben zu den Finanzierungsaktivitäten des Nutzers und Angaben zu Zahlungstransaktionen.
	BNP Paribas (Frankreich)	Name, Transaktionsnummern und -betrag, Transaktion und Bankverbindung des Nutzers.	Name, Transaktionsnummern und -betrag, Transaktion und Bankverbindung des Nutzers.
Anmeldung	Abgleich von	Abgleich von	Abgleich von
	BNP Paribas (Frankreich)	Abgleich von	Abgleich von

### Welche Arten von Informationen erfassen wir?

Zur Bereitstellung der Facebook-Produkte müssen wir Informationen über dich verarbeiten. Die Arten der von uns erfassten Informationen hängen davon ab, wie du unsere Produkte nutzt. Du kannst erfahren, wie du auf von uns erfasste Informationen zugreifen bzw. sie löschen kannst, indem du die Facebook-Einstellungen bzw. die Instagram-Einstellungen besuchst.

#### Von dir und anderen gesammelte und bereitgestellte Daten.

- Von dir bereitgestellte Informationen und Inhalte. Wir erfassen die Inhalte, Kommunikationen und sonstigen Informationen, die du bereitstellst, wenn du unsere Produkte nutzt, dazu gehören auch deine Registrierungen für ein Konto, die Erstellen oder Teilen von Inhalten sowie der Nachrichtenaustausch (wie die Kommunikation mit anderen). Dies kann Informationen über die von dir bereitgestellten Inhalte oder Inhalte, die in ihnen enthalten sind (wie Metadaten) umfassen, wie z. B. den Aufnahmezeitpunkt eines Fotos oder das Datum, an dem eine Datei erstellt wurde. Es kann auch die umfassen, was du durch von uns bereitgestellte Funktionen, wie z. B. unsere Kamera, siehst, damit wir dir empfehlenswerte Medien und Filter, die dir gefallen könnten, vorschlagen oder dir Tipps für die Verwendung des Hochformats geben können. Unsere Systeme verarbeiten von dir bereitgestellte Inhalte und Mitteilungen automatisch, um den Kontext und die in ihnen enthaltenen Details für die unten beschriebenen Zwecke zu analysieren. Erläutere mehr darüber, wie du kontrollieren kannst, wer die Dinge sehen kann, die du siehst.
- Daten mit besonderem Schutz. Du kannst in deinen Facebook-Profilen oder unter „Lebensereignisse“ Informationen über deine religiösen Ansichten, deine politischen Einstellungen oder deine Gesundheit (wie, an wen du „intereponierst“), das allgemeine Datum und andere Informationen (wie etwa Nationalität oder ethnische Herkunft, weltanschauliche Überzeugungen oder eine Gewerkschaftsangehörigkeit) unterlegen nach EU-Recht einem besonderen Schutz.
- Netzwerke und Verbindungen. Wir erfassen Informationen über die Personen, Seiten, Konten, Beiträge und Gruppen, mit denen du interagierst, um zu verstehen, wie du mit anderen interagierst.



Controller: Green Company AG  
 Data Protection Officer: Jane Super  
 Data Disclosed (#): 1  
 Automated Decision Making: In use  
 Third country Transfers: DE, FR, ES

[Learn more](#)



Browser-Plugins

Visualising Data-Sharing-Networks

TYPE OF DATA COLLECTED	ORIGINAL DATA PRACTICES	DATA SHARING
Contact: name, mailing address, phone number, or private mailbox	ID: user ID may be used for the purpose of continuing advertising	Offers: offers and/or substitute offers for the same primary purposes
Computer or Internet browser data: cookies, system, or device ID	Public display: the public may see, or other users may see, the data may have seen	Contracts: third party contractors may use the data for the same primary purposes
Interactive: interaction, behavior or search history	User control: user allowed to access or delete information or purchase history	Third parties: third parties not subject to same data practices
Financial: financial status or other credit information, or purchase history	User control: user allowed to access or delete information or purchase history	
Content: content of personal communications, shared documents or media	User control: user allowed to access or delete information or purchase history	

Privacy Icons

Grünwald et al. (2023). „Enabling Versatile Privacy Interfaces Using Machine-Readable Transparency Information“. In Privacy Symposium 2023

# Indispensable: machine-readable representation

## Transparency Information Language & Toolkit

Welche Arten von Informationen erfassen wir?

Zur Bereitstellung der Facebook-Produkte müssen wir Informationen über dich verarbeiten. Die Art und Weise, wie wir diese Informationen erfassen, hängt davon ab, wie du unsere Produkte nutzt. Du kannst bestimmen, was du auf uns preisgeben möchtest, indem du die Nachschaltflächen, indem du die Facebook-Einstellungen oder die datenschutzrechtlichen Einstellungen einstellst.

Von dir und anderen geteilte und bereitgestellte Dinge

- Von dir bereitgestellte Informationen und Inhalte, wie zum Beispiel die Inhalte, Kommunikationen und sonstigen Informationen, die du bereitstellst, wenn du unsere Produkte nutzt, das gezeichnete Foto bei der Registrierung für ein Konto, das Erstellen oder Teilen von Inhalten sowie die Nachrichtenaktivität bei den Interaktionen mit anderen. Dies kann Informationen über die von dir bereitgestellten Inhalte oder Inhalte, die in einem anderen Kontext (z. B. in einem anderen Profil) veröffentlicht werden, oder die Aufnahme von Bildern oder Videos, die du durch eine oder mehrere unserer Produkte bereitstellst, wie z. B. durch eine von dir bereitgestellte Funktion, wie z. B. unsere Kamera, dafür, dass wir dir bereitgestellte Medien und Fotos, die du geteilt hast, vorschlagen oder dir Tipps für die Verwendung des Produkts geben können. Unsere Systeme verarbeiten oder für bereitgestellte Inhalte und Kommunikationen automatisch, um den Kontext und die in ihnen enthaltenen Details für die gezielte beschriebenen Zwecke zu analysieren. Erfahre mehr darüber, wie die Datennutzung funktioniert, was die Dinge sind, die du sagst.
- Daten mit besonderen Schutz: Du kannst in deinem Facebook-Profil Details oder unter „Informations“ Informationen über deine registrierte Adresse, deine persönliche Identifizierung oder deine Identifizierung bei „Anmelden“ fest angeben. Diese sind andere Informationen über eine Individualität oder ethische Herkunft, weltanschauliche Überzeugungen oder eine Identifizierung (einschließlich) Informationen, die du bereitstellst einen besonderen Schutz.
- Netzwerke und Verbindungen: Wir erfassen Informationen über die Personen, Stellen, Konten, Plattformen und Gruppen, mit denen du verbunden bist, und darüber, wie du mit ihnen zusammen interagierst.



```

15  "controller": {
      "name": "Green Company AG",
      "division": "Product line e-mobility",
      "address": "Wolfsburger Ring 2, 38440 Berlin",
      "country": "DE",
      "representative": {
        "name": "Jane Super",
        "email": "contact@greencompany.de",
        "phone": "0049 151 1234 5678"
      }
    },
20  "dataProtectionOfficer": {
      "name": "Jane Super",
      "address": "Wolfsburger Ring 2, 38440 Berlin",
      "country": "DE",
      "email": "contact@greencompany.de",
      "phone": "0049 151 1234 5678"
    },
25  "dataDisclosed": {
      "_id": "f1424f86-ca0f-4f0c-9438-43ec00509931",
      "category": "E-mail address",
      "purpose": [
35  ]
    }
  }

```



Controller: Green Company AG  
 Data Protection Officer: Jane Super  
 Data Disclosed (#): 1  
 Automated Decision Making: **In use**  
 Third country Transfers:

[Learn more](#)

Browser-Plugins



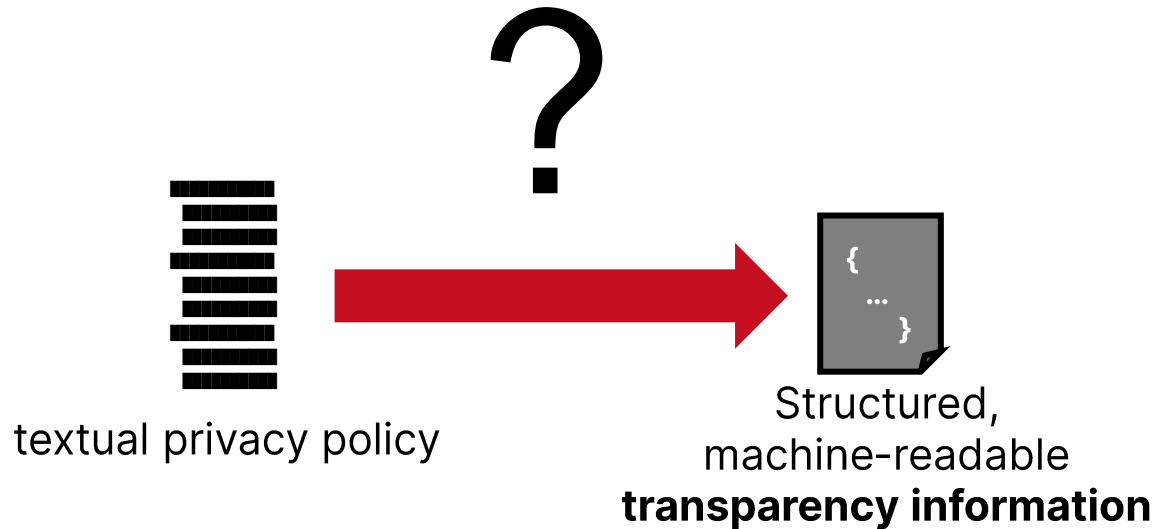
Visualising Data-Sharing-Networks

TYPE OF DATA COLLECTED	GENERAL DATA PRACTICES	DATA SHARING

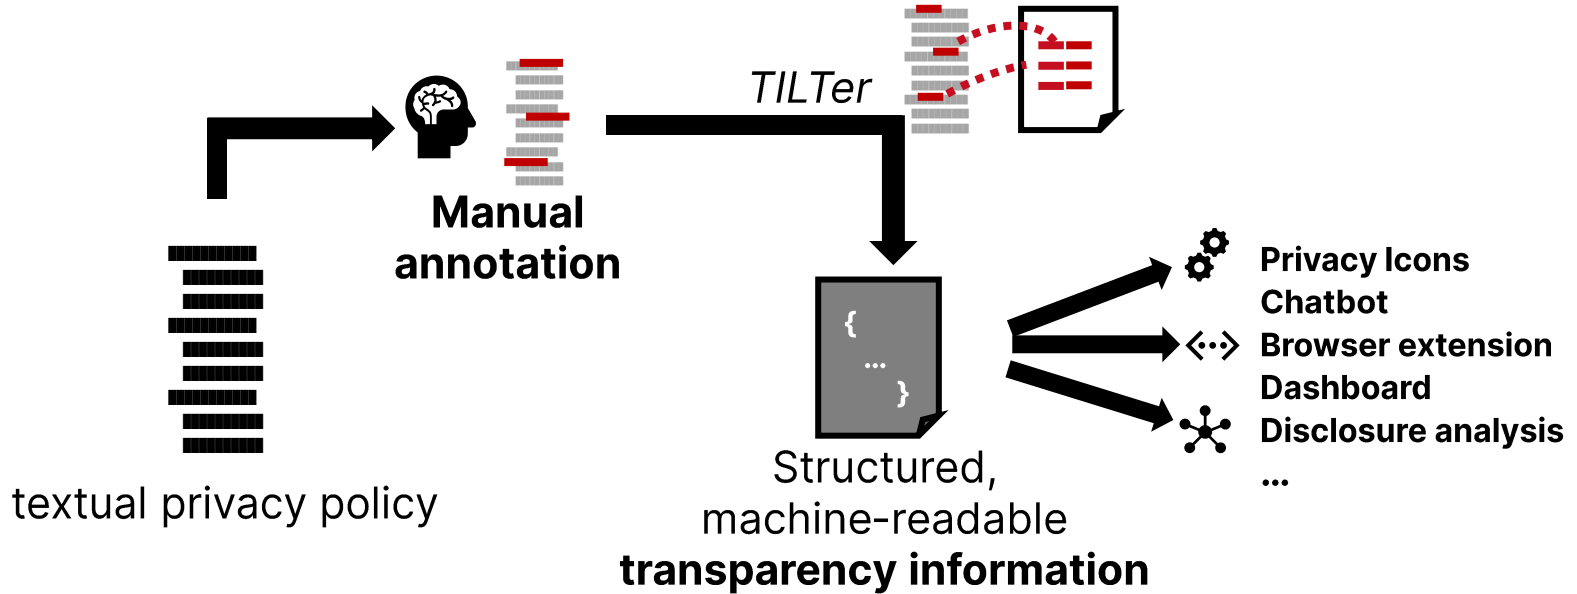
Privacy Icons

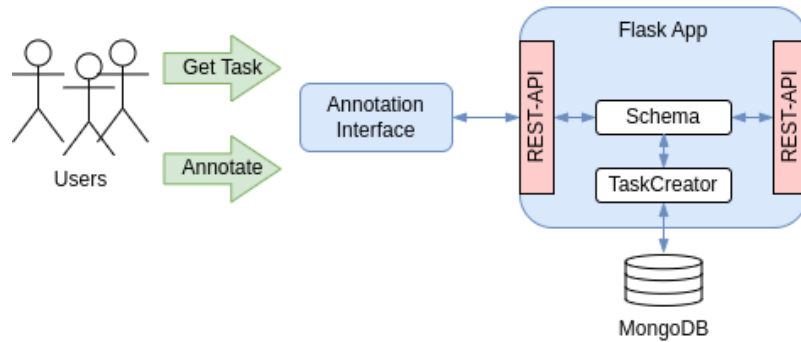
Grünwald and Pallas (2021). „TILT: A GDPR-Aligned Transparency Information Language and Toolkit for Practical Privacy Engineering“. In ACM FAccT 2021.

# How to get TILT?



# General Approach





# Annotation Interface

Hierarchically structured **labels** for:

- Tokens, e.g.
  - DPO (name, e-mail, address, ...)
  - categories
  - purpose
- Sentences, e.g.
  - data subject rights
  - automated decision making
  - changes

Multiple **tasks** per policy:

- Identify labels for a specific hierarchical level

→ still, very tedious work!

## Task "Tesco"

[← task overview](#) [TILT Representation](#)

> Label Descriptions

Undo Redo Reset

Controller - Company Name<sup>1</sup> | Data Protection Officer - E-mail<sup>1</sup> | Data Disclosed - Category<sup>1</sup>

Third Country Transfers - Target Country<sup>1</sup> | Access and Data Portability<sup>1</sup> | Sources<sup>1</sup> | Right to Information<sup>1</sup>

Right to Deletion<sup>1</sup> | Right to Data Portability<sup>1</sup> | Right to Withdraw Consent<sup>1</sup> | Right to Complain<sup>1</sup>

Automated Decision Making - Logic<sup>1</sup> | Changes of Purpose<sup>1</sup>

Privacy and cookies policy  
Last Updated: 23 May 2018

Version 1.1

At Tesco, we're working hard to serve shoppers a little better every day. Looking after the personal data you share with us is a hugely important part of this. We want you to be confident that your data is safe and secure with us, and understand how we use it to offer you a better and more personalised shopping experience.

What this Policy covers  
The data controller is [Tesco Ireland Limited](#) ([Controller - Company Name](#)) (referred to in this policy as "we" or "us").

## Results

Nothing selected

Regions (4) [Sort](#)

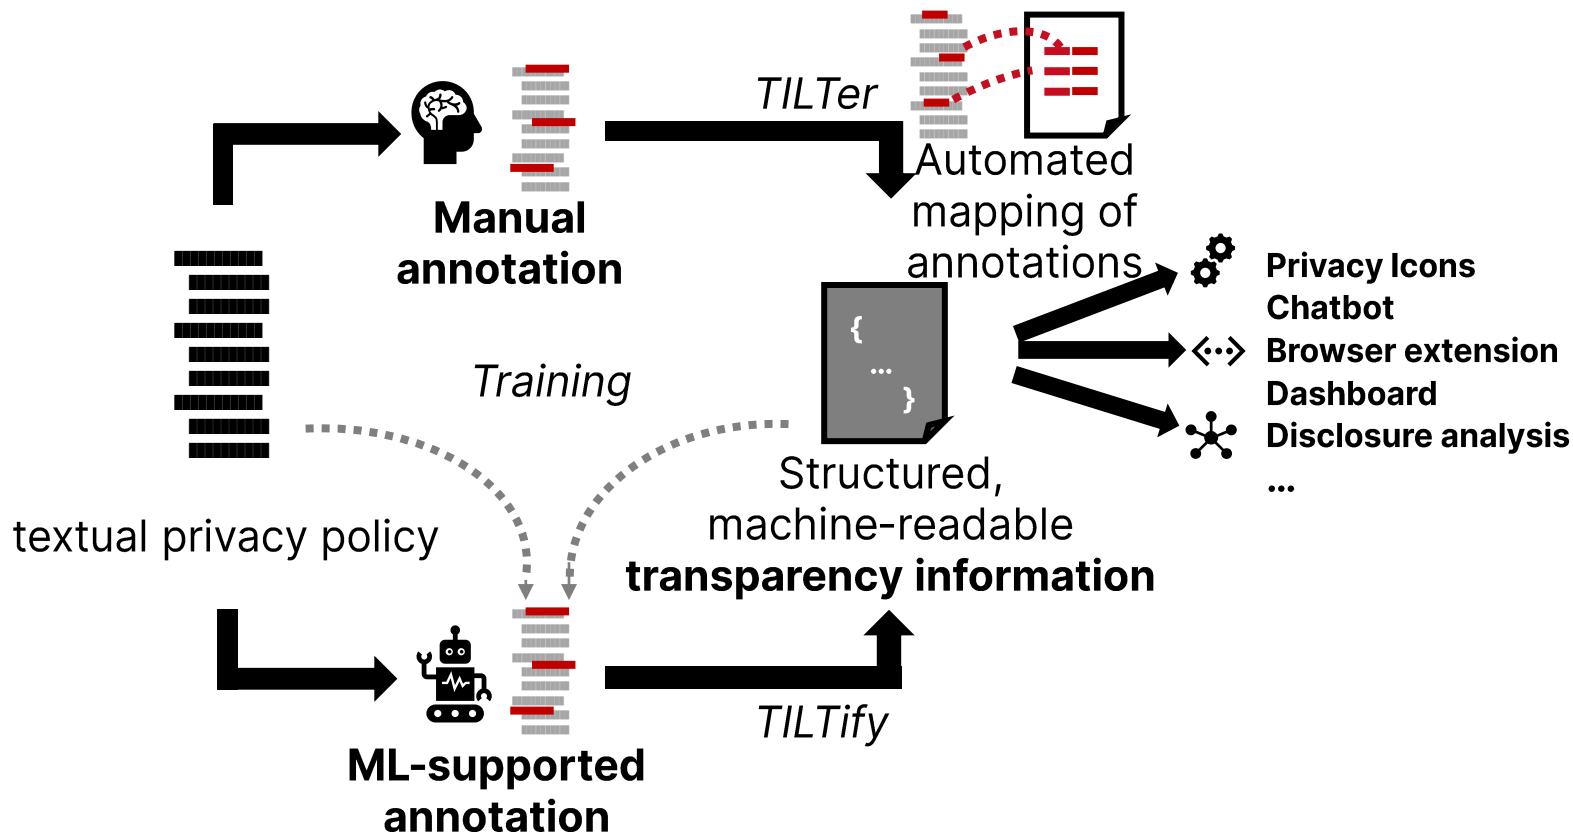
- Tesco Ireland Limited
- Your personal details, including yo...
- Information relating to your membe...
- dataprotection@tesco.com

Relations (0)

No Relations added yet



# NLP Coming to the Rescue!



# ML-supported Annotation of Privacy Policies

OPP-115 data set (Wilson et al. 2016)

- Polisis (Harkous et al. 2018)
- TLDR (Alabduljabbar et al. 2021)
- ✓ reliable classification (F1: 0.83/0.91)
- ✓ improving navigability
- × data scarcity
- × creating detailed and accurate machine-readable representations

# Refining the Classification Task

## Annotations for:

- Tokens, e.g.
  - DPO
  - categories
  - purpose
- Sentences, e.g.
  - data subject rights
  - automated decision making
  - changes

“We therefore would like to inform you about data privacy for websites under \*.tu.berlin.”

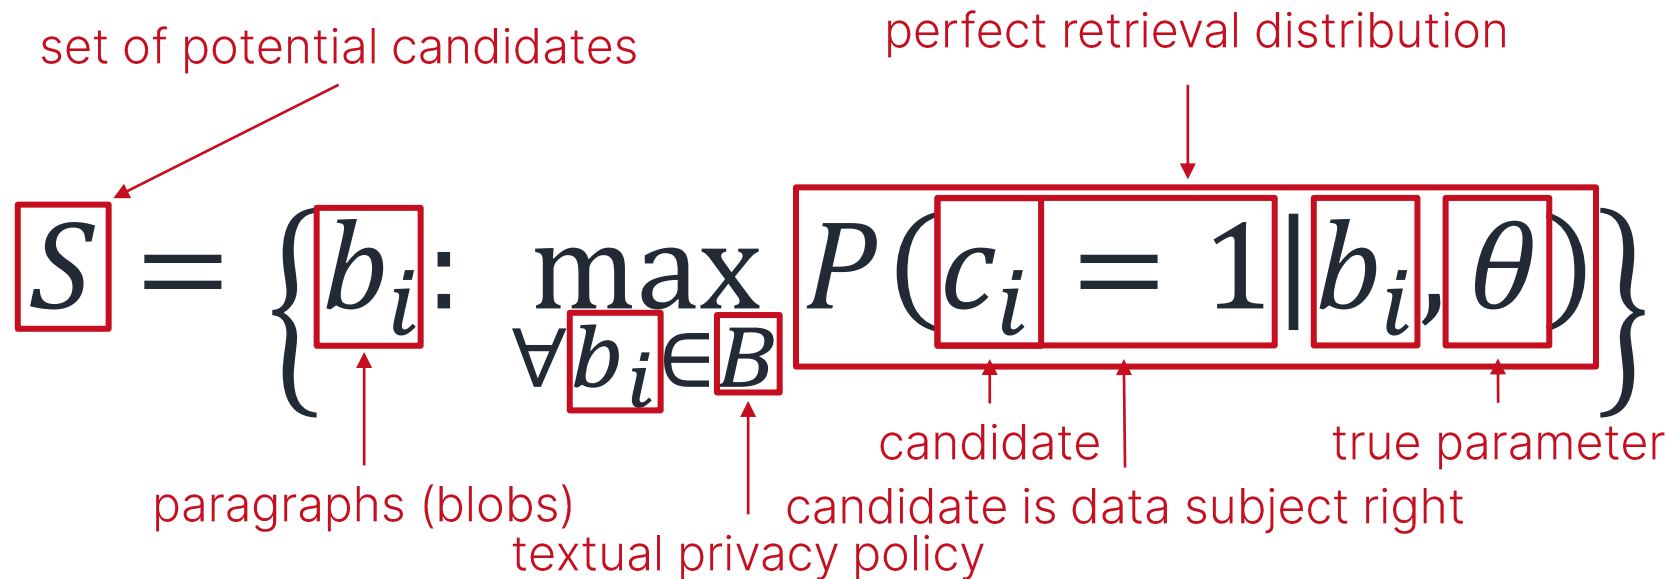
“You can obtain information about the data we have stored about you free of charge at any time without having to give a reason.”

“You also have the right to object at any time to the processing of personal data concerning you that is carried out on the basis of Article 6 paragraph 1 lit. e and f EU-GDPR.”

<https://www.tu.berlin/en/data-protection>



# Sentence-based Information Retrieval



# Sentence-based Information Retrieval

perfect retrieval distribution



$$S = \left\{ b_i : \max_{\forall b_i \in B} P(c_i = 1 | b_i, \theta) \right\}$$

$$\hat{f}(b_i, \hat{\theta})$$

extraction model

# Extraction Model

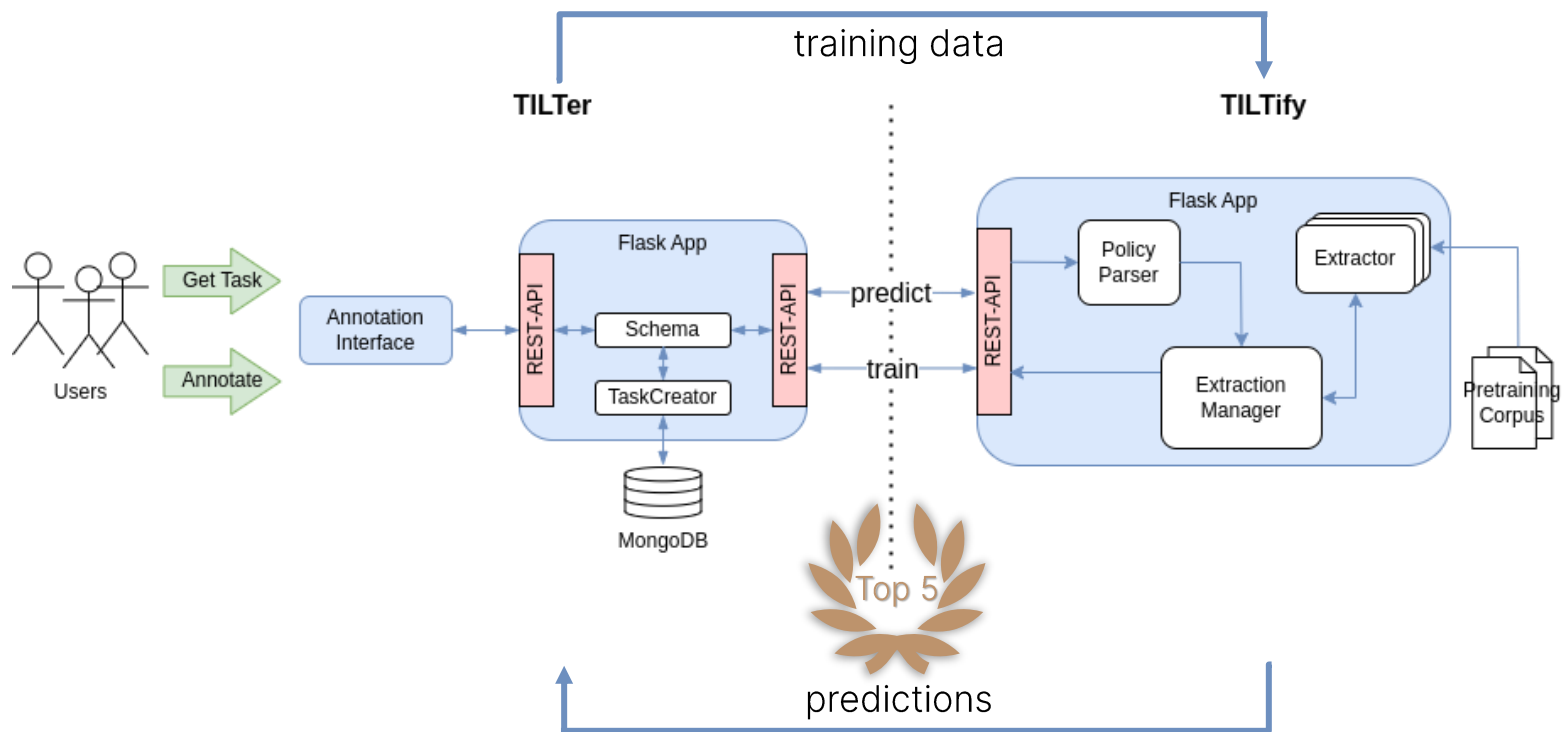


Static Word Embeddings  
& Naive Bayes

BinaryBERT

SentenceBERT

# Human-in-the-Loop



# Task "Tesco"

[← task overview](#) [🔗 TILT representation](#)

> Label Descriptions

▼ Predictions

Label	Prediction	
Right to Deletion	There are several situations when you can have us delete your personal data, this includes (but is not limited to)	>
Right to Deletion	if you believe we hold inaccurate or missing information, please let us know and we will correct it.	>
Right to Complain	We'd like the chance to resolve any complaints you have, however you also have the right to complain to the ROI data protection regulator (the DPC) about how we have used your personal data. Their website is <a href="https://www.dataprotection.ie/docs/Contact-us/b/11.html">https://www.dataprotection.ie/docs/Contact-us/b/11.html</a>	>
Right to Complain	If you have any questions about how we collect, store and use personal data please contact us.	>

↶ Undo   ↷ Redo   ↺ Reset

⚙️ ⌵

Controller - Company Name<sup>[2]</sup>
Data Protection Officer - E-mail<sup>[2]</sup>
Data Disclosed - Category<sup>[2]</sup>
Third Country Transfers - Target Country<sup>[4]</sup>
Access and Data Portability<sup>[3]</sup>
Sources<sup>[6]</sup>
Right to Information<sup>[7]</sup>
Right to Deletion<sup>[8]</sup>
Right to Data Portability<sup>[9]</sup>
Right to Withdraw Consent<sup>[2]</sup>
Right to Complain<sup>[8]</sup>
Automated Decision Making - Logic<sup>[4]</sup>
Changes of Purpose<sup>[4]</sup>

Privacy and cookies policy  
Last Updated: 23 May 2018

Version 1.1

At Tesco, we're working hard to serve shoppers a little better every day. Looking after the personal data you share with us is a hugely important part of this. We want you to be confident that your data is safe and secure with us, and understand how we use it to offer you a better and more personalised shopping experience.

What this Policy covers  
The data controller is **Tesco Ireland Limited** Controller - Company Name (referred to in this policy as "we" or "us").

## Results

Nothing selected

Regions (4) ⌵ Sort

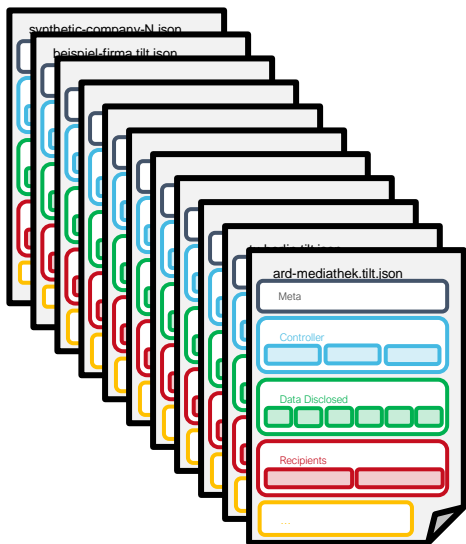
- 1 ⚠️ Tesco Ireland Limited
- 2 ⚠️ Your personal details, including yo...
- 3 ⚠️ Information relating to your membe...
- 4 ⚠️ dataprotectionroi@tesco.com

Relations (0) ⌵


No Relations added yet



# Evaluation Dataset




60 annotated policies

 German language

 data scarcity

 differing amounts of data subject rights

 data imbalance:  
>16600 paragraphs  
<450 containing data subject rights

[https://github.com/DaSKITA/tiltify/tree/main/data/annotated\\_policies](https://github.com/DaSKITA/tiltify/tree/main/data/annotated_policies)

# Evaluation Models

	Static Word Embeddings & Naive Bayes	BinaryBERT	SentenceBERT
Right to Information	0.18	0.0	0.93
Right to Deletion	0.0	0.0	0.86
Right to Data Portability	0.0	0.0	0.86
Right to Complain	0.29	0.15	0.93
Right to Withdraw Consent	0.0	0.08	0.90

F1 Score (for 5-rank, if not stated otherwise)

## Take-aways

We tackled problem of retrieving machine-readable transparency information from privacy policies under the constraint of data scarcity.



Adopted from  
<https://datascientest.com/de/bert>  
 and <https://tinyurl.com/2bhe3brk>

S-BERT - in conjunction with k-rank approaches - is extremely promising to simplify the annotation of privacy policies, even with few training data.



# A Human-in-the-Loop Approach for Information Extraction from Privacy Policies under Data Scarcity

Nicola Leschke

 [nl@ise.tu-berlin.de](mailto:nl@ise.tu-berlin.de)

 [tu.berlin/ise/nl](http://tu.berlin/ise/nl)

 Nicola Leschke

## DaSKITA

[tu.berlin/ise/daskita](http://tu.berlin/ise/daskita)

Gefördert durch:

 Bundesministerium für Umwelt, Naturschutz, nukleare Sicherheit und Verbraucherschutz

  
Projekträger Bundesanstalt für Landwirtschaft und Ernährung

aufgrund eines Beschlusses des Deutschen Bundestages