

Journée ICO – 05/12/2025

Antony Dalmiere

Master cybersécurité

Master psychologie

Thèse CNRS

Encadrants

Vincent Nicomette

Guillaume Auriol

Pascal Marchand

Contexte

23%

taux de réussite de phishing peu ciblé

Bakhshi, T., Papadaki, M., & Furnell, S. (2009). Social engineering : Assessing vulnerabilities in practice. *Information Management & Computer Security*, 17(1), 53-63.
<https://doi.org/10.1108/09685220910944768>

La théorie



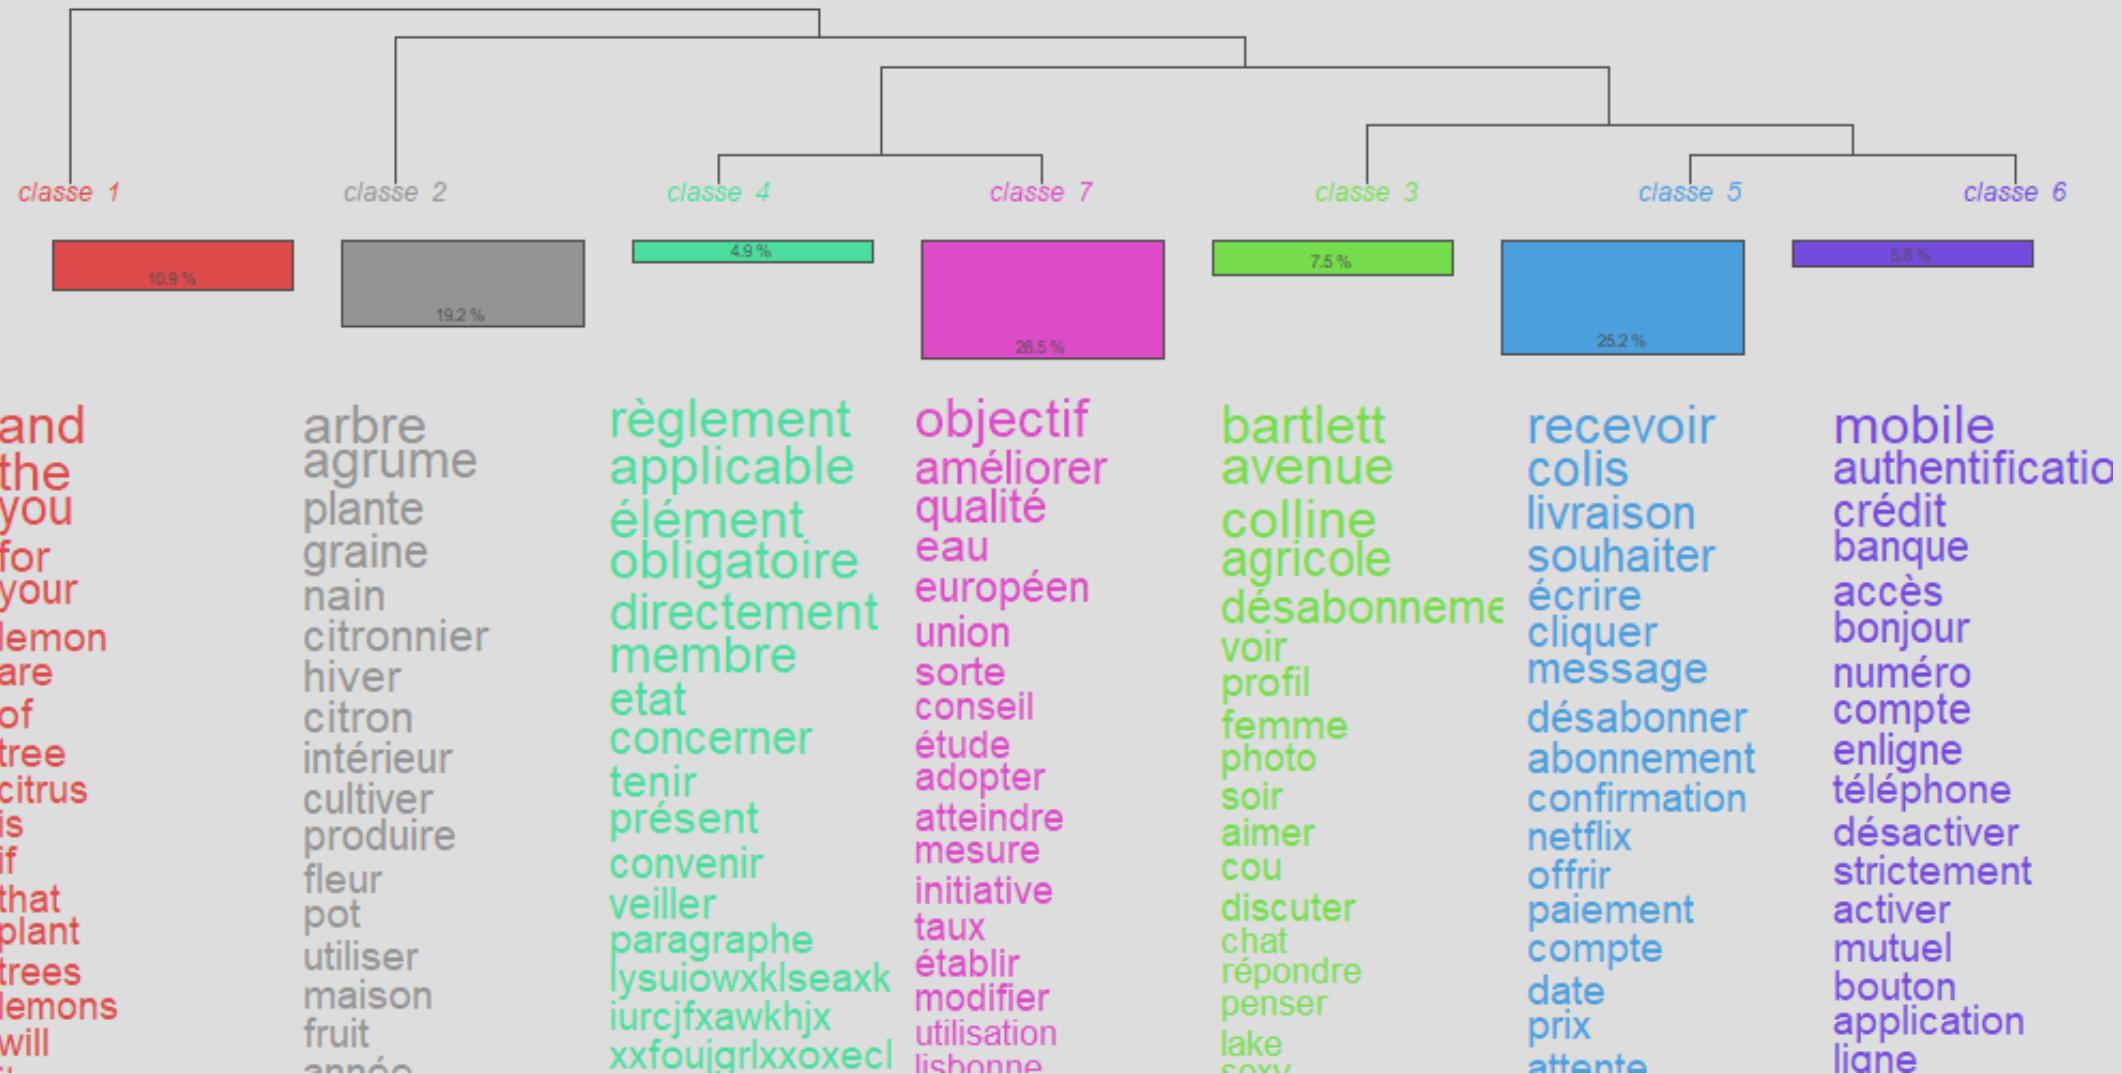


DÉTECTION PAR IA DES TECHNIQUES DE MANIPULATION PSYCHOLOGIQUE



LE GANG DES AGRUMES

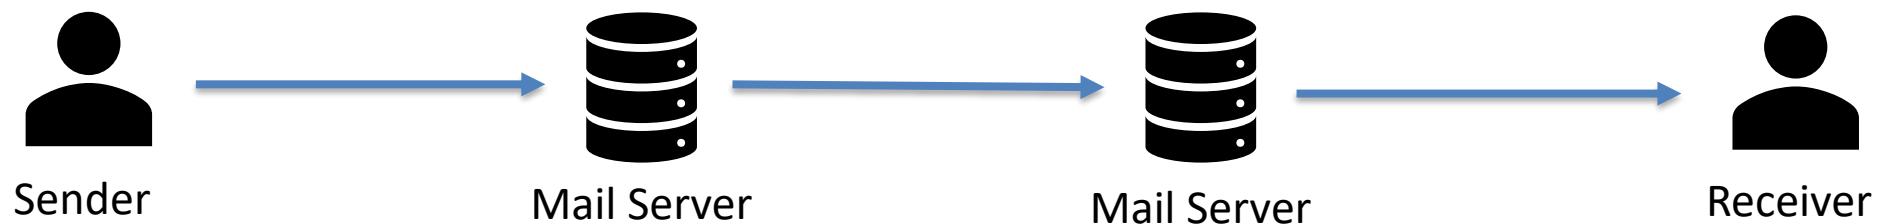
Le gang des agrumes



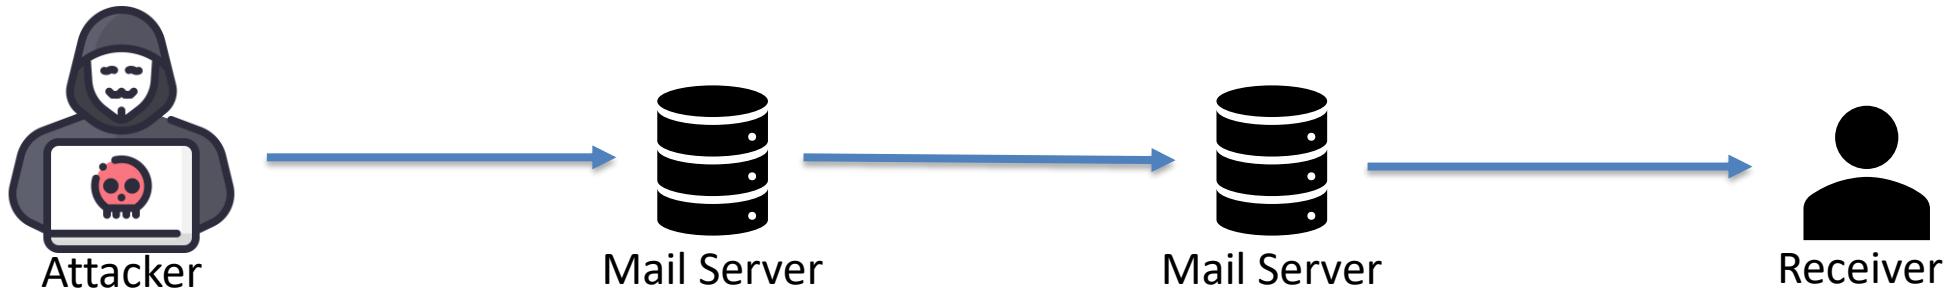
Le gang des agrumes



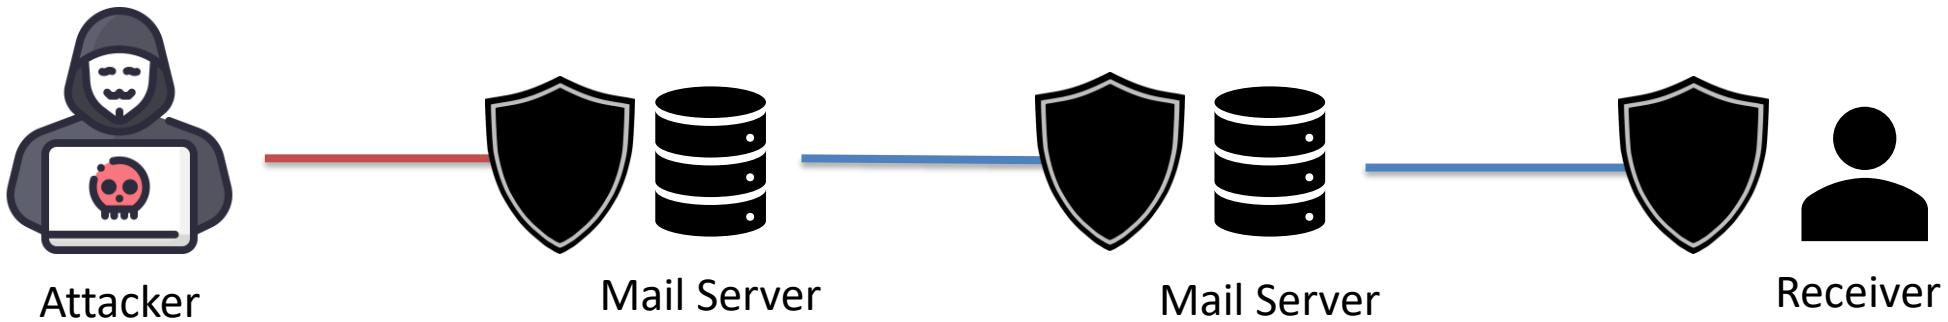
Comment ça arrive dans la boîte mail ?



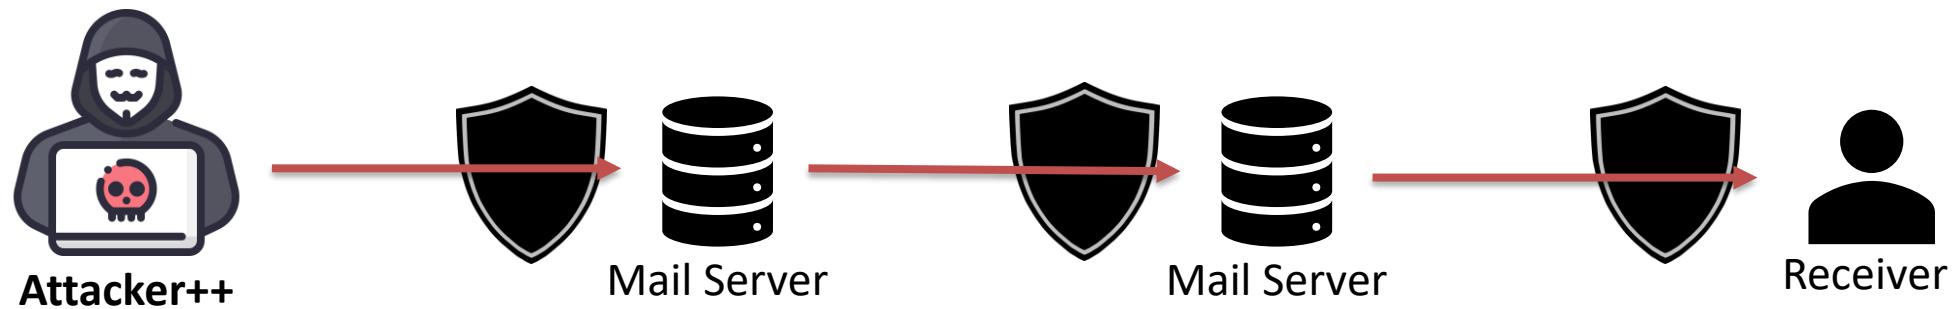
Comment ça arrive dans la boîte mail ?



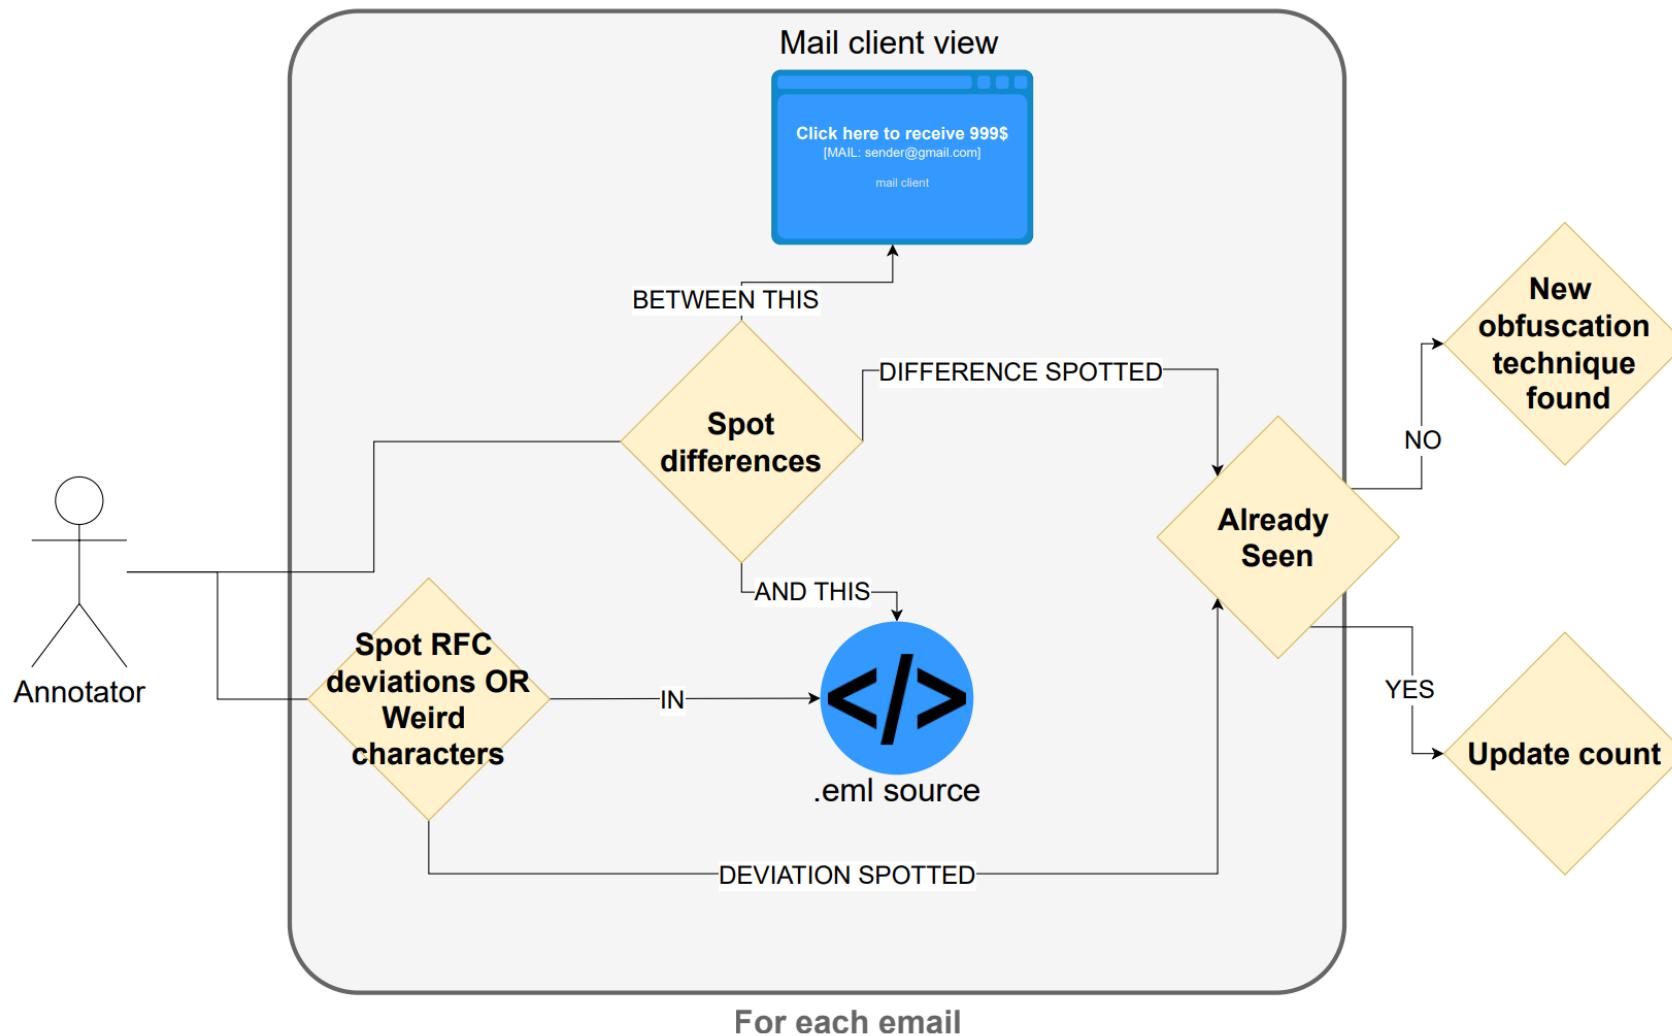
Comment ça arrive dans la boîte mail ?



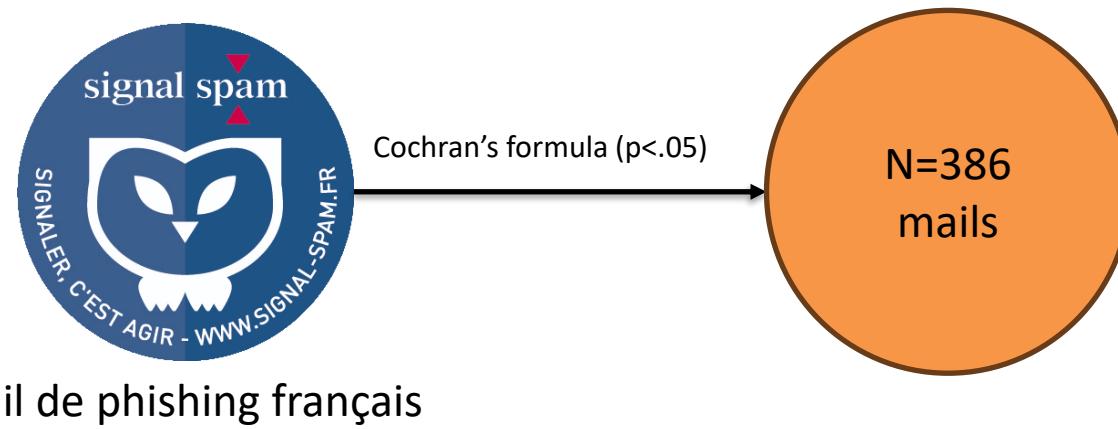
Comment ça arrive dans la boîte mail ?



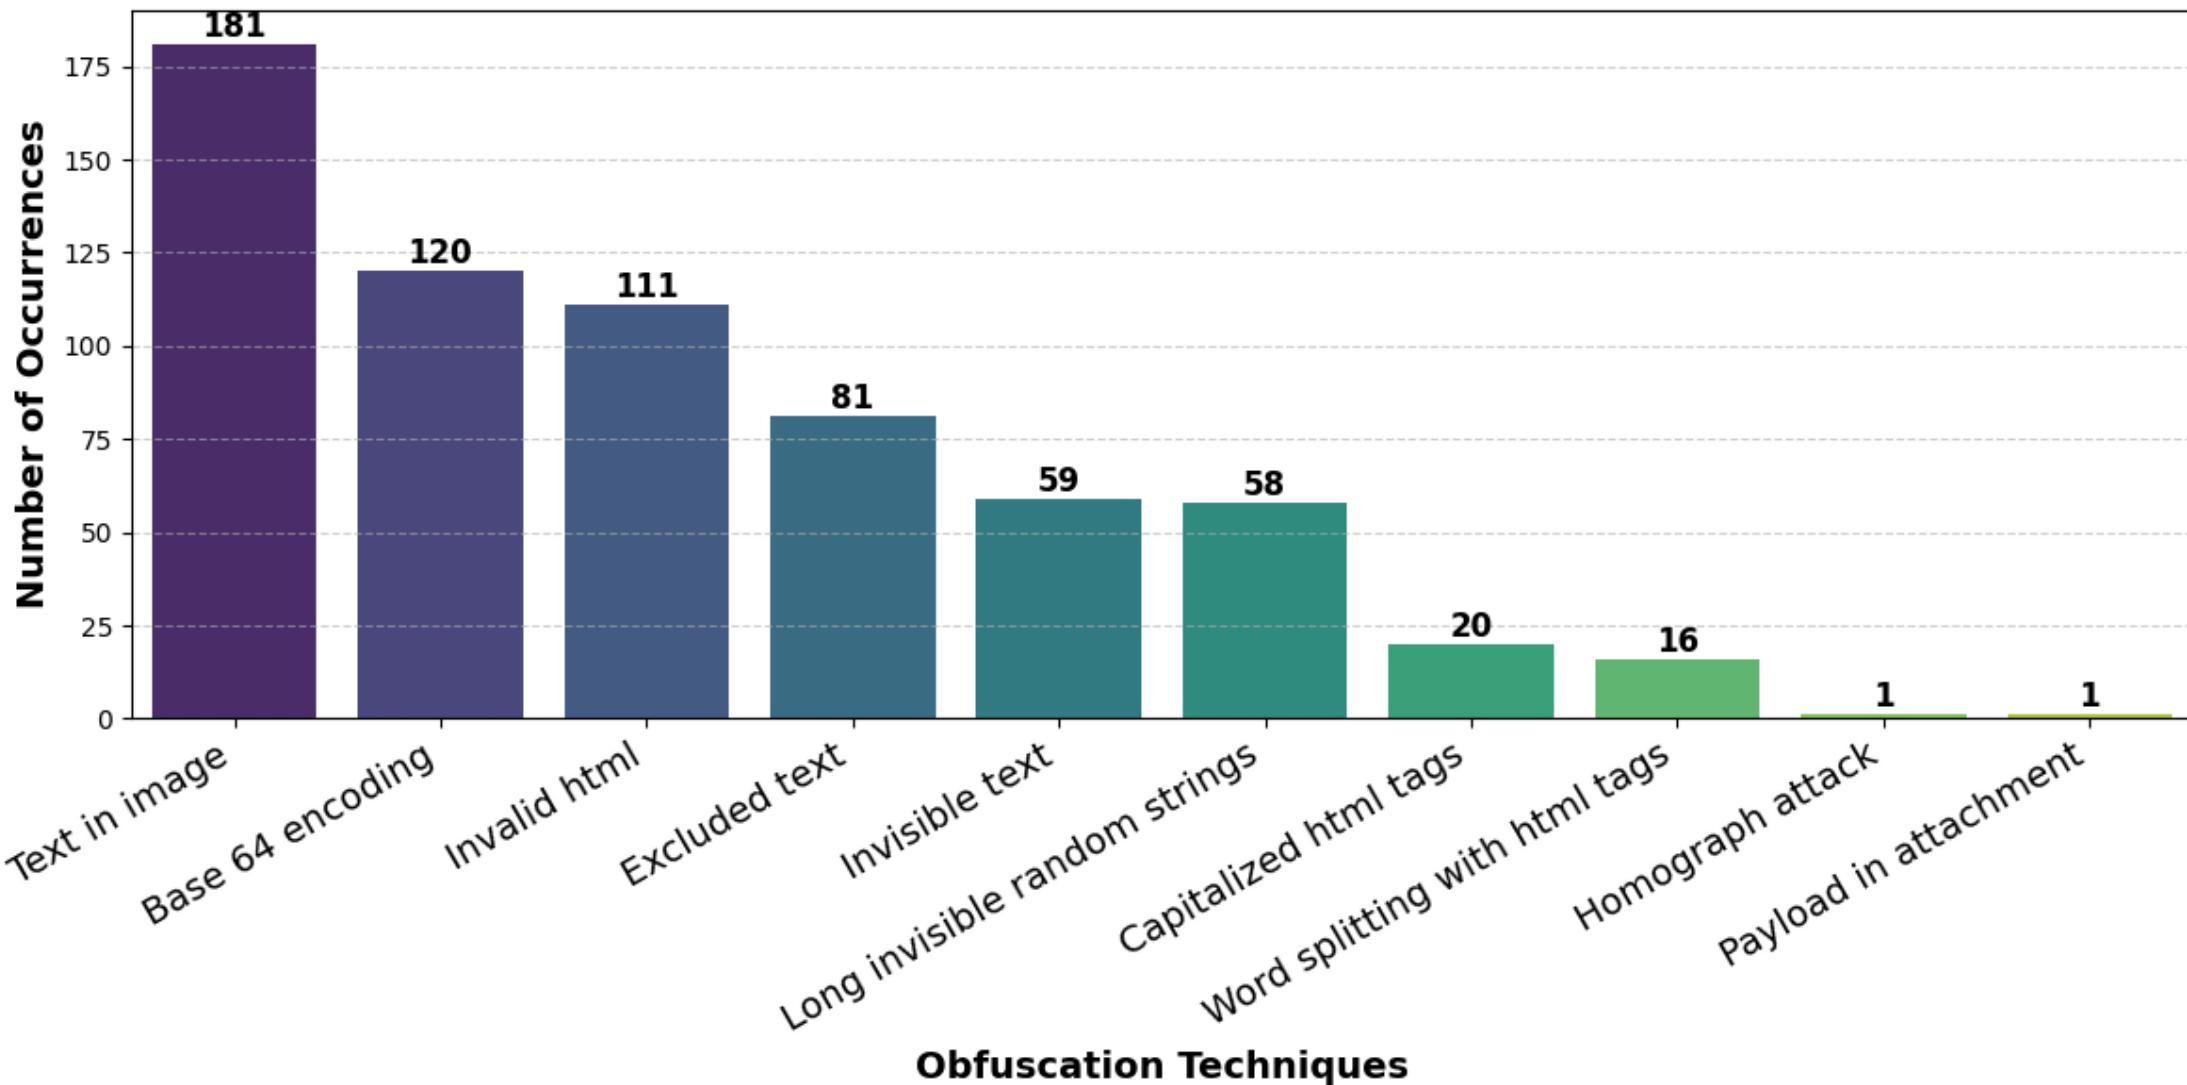
Notre méthode pour le savoir



Dataset



Les techniques d'obfuscation



Technique #1 Text in image



```

```

Vu par les filtres



Dear ESORICS 2025 participant,

The final program is now available at
<https://esorics2025.sciencesconf.org>

An electronic (PDF) version of the conference handbook,
including sessions, guidelines and some other practicalities,
is available at the link below:

Vu par des humains

Technique #5 Invisible Text



```
<html>
  <body>
    Dear ESORICS 2025 participant,  
  

    The final program is now available at  

https://esorics2025.sciencesconf.org  

    [...]  
  

    <p style="font-size:0px; font-color:white">  

      Hemoglobin is an iron-containing,  

      tetrameric protein in red blood cells  

      that binds oxygen in the lungs and  

      delivers it to body tissues.  

    </p>
  </body>
</html>
```



Dear ESORICS 2025 participant,

The final program is now available at
<https://esorics2025.sciencesconf.org>

An electronic (PDF) version of the conference handbook,
including sessions, guidelines and some other practicalities,
is available at the link below:

Vu par les filtres

Vu par des humains

COMMENT CES TECHNIQUES D'OBfuscation SE COMBINENT-ELLES

Combinaison des techniques d'obfuscation

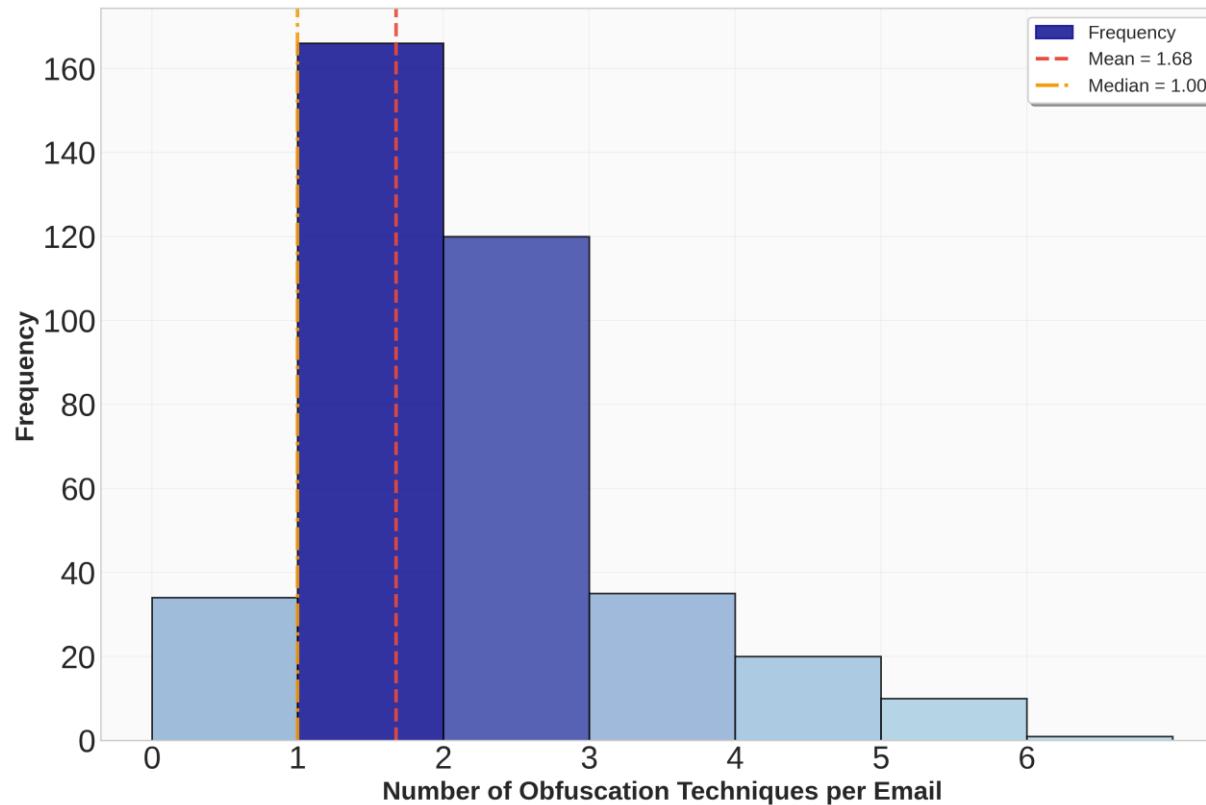
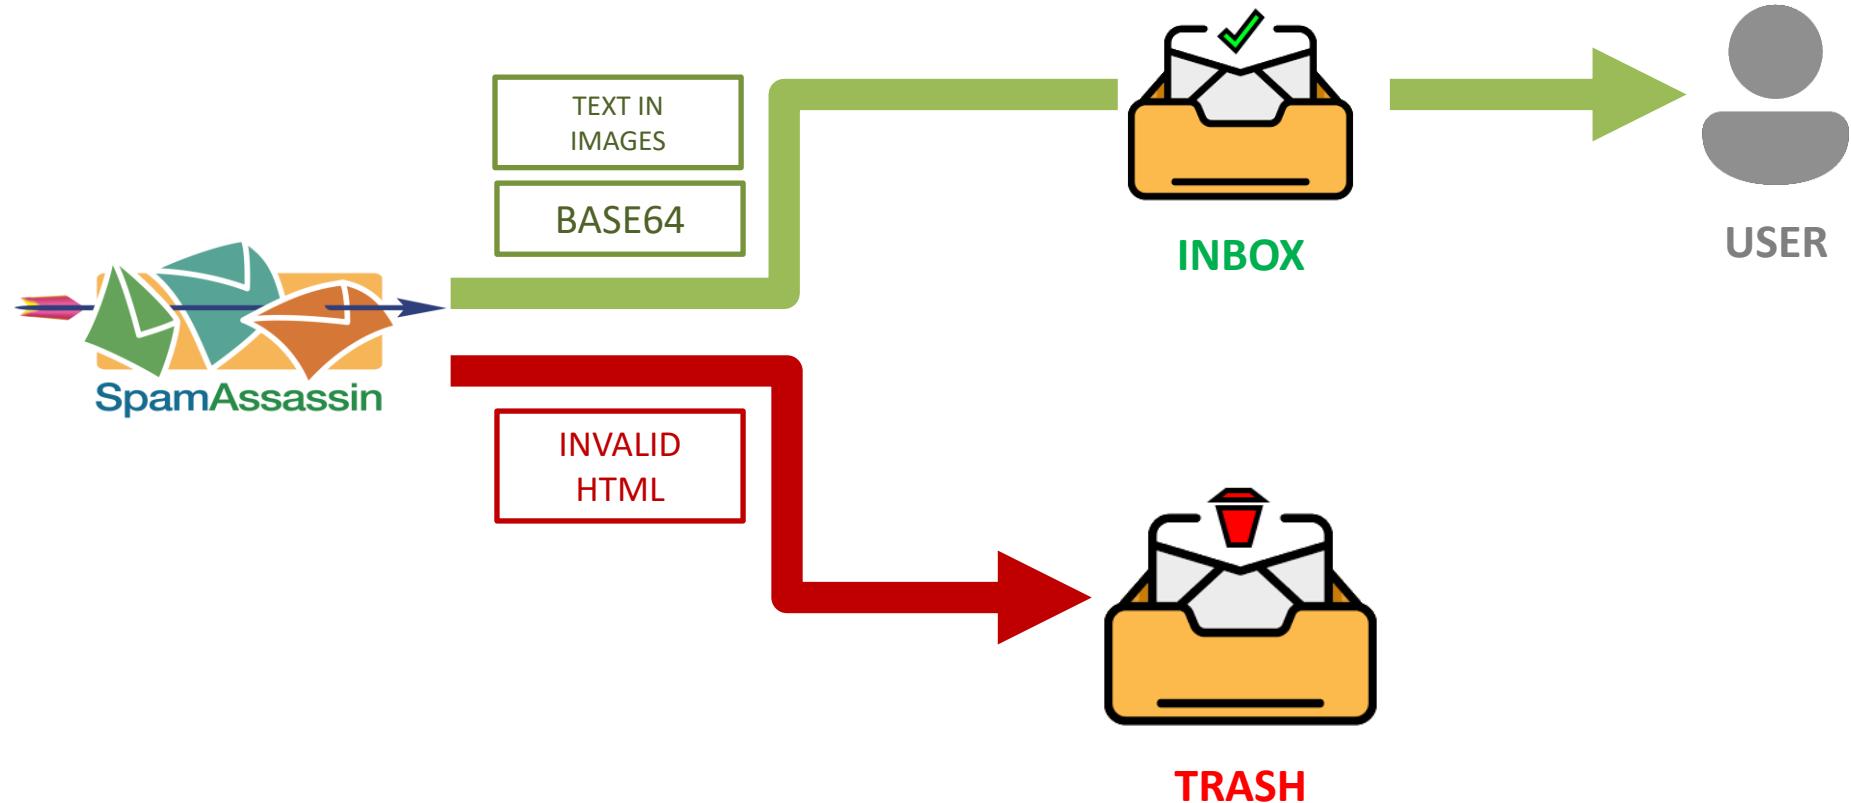
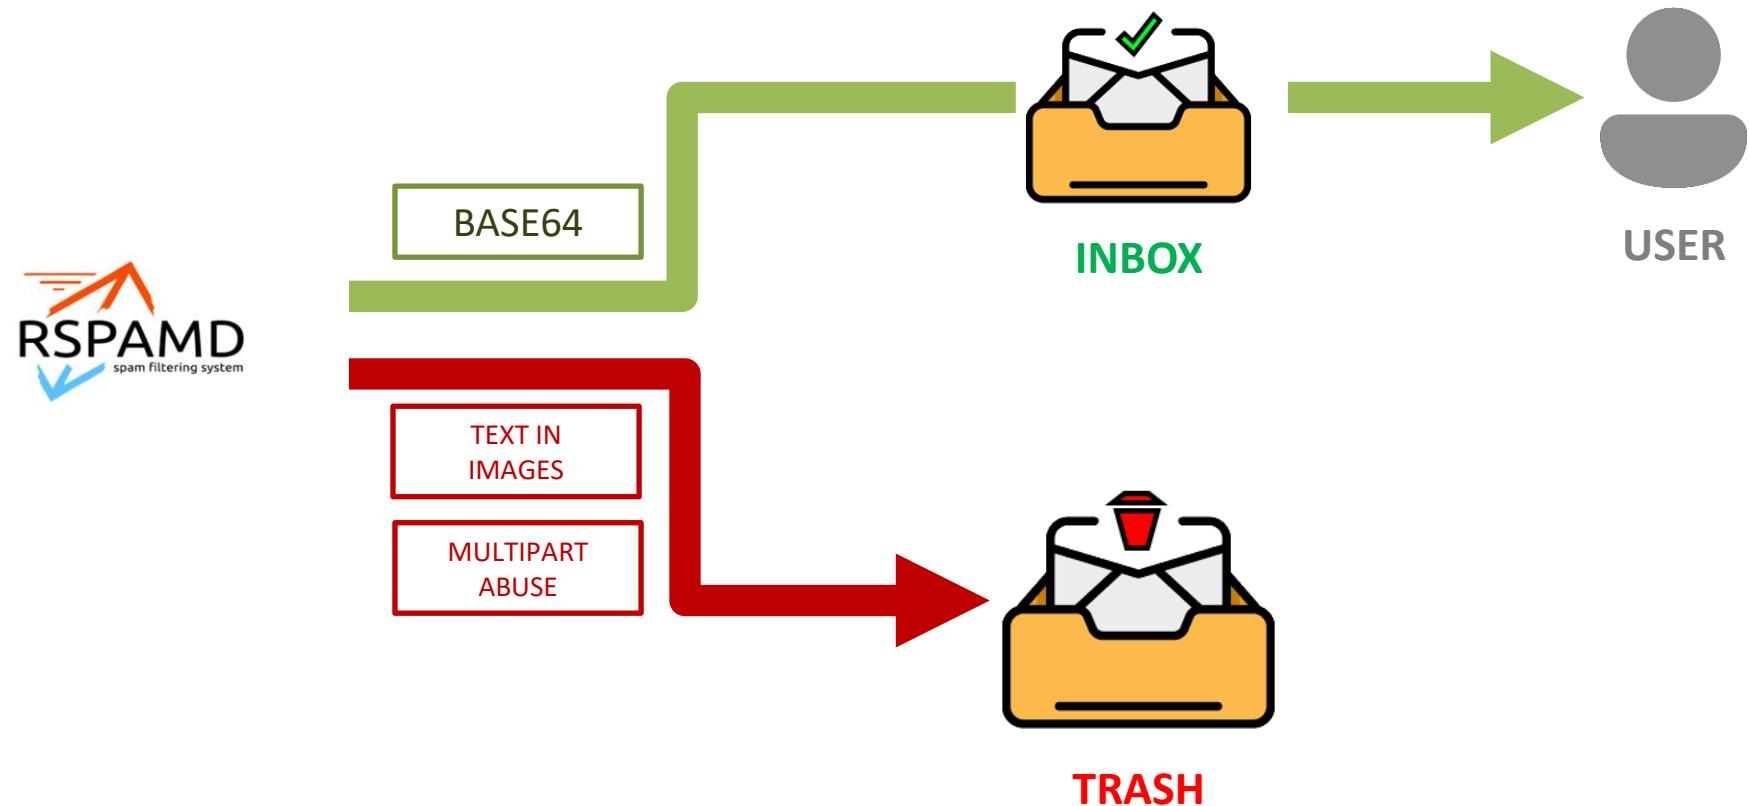


Fig. 2. Normalized co-occurrence matrix of obfuscation techniques

Efficacité contre les antispams



Efficacité contre les antispams



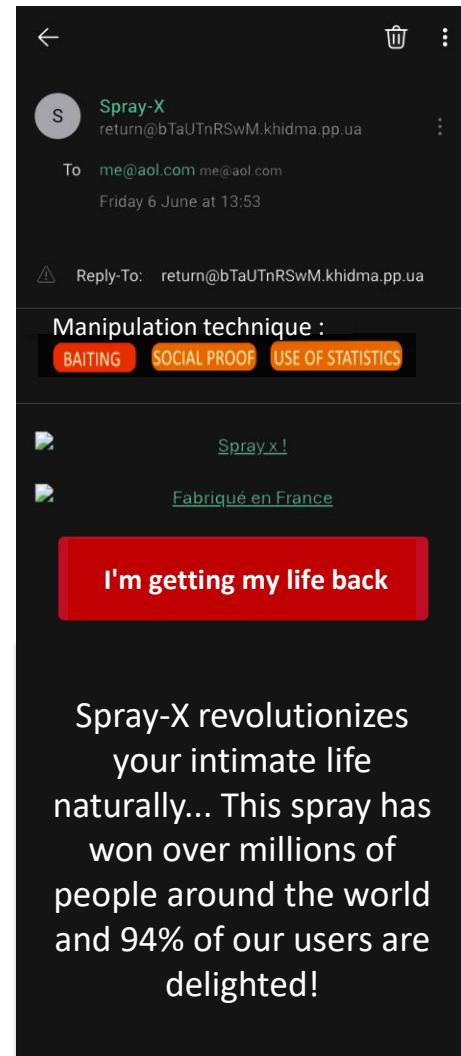
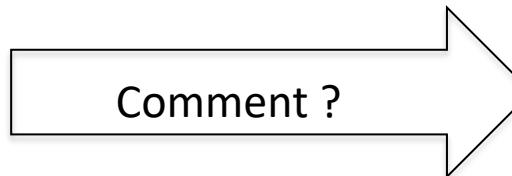
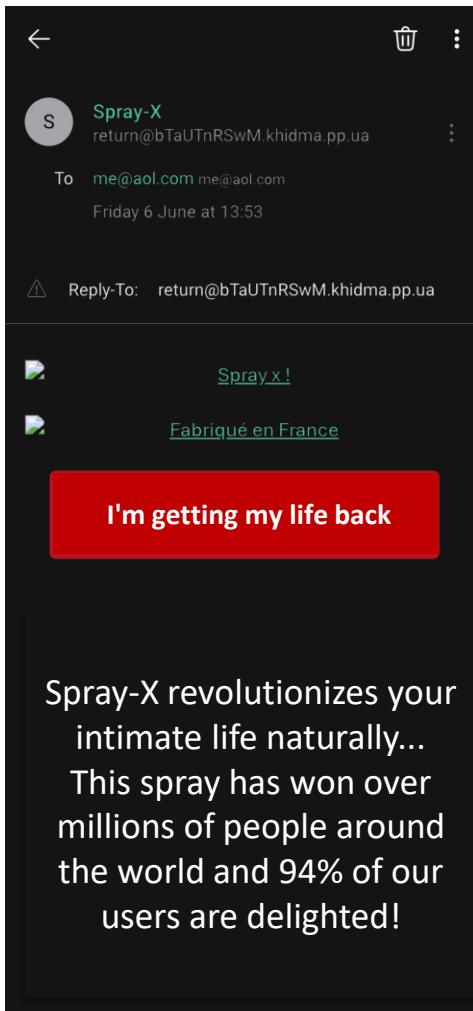
Qu'avons-nous appris ?

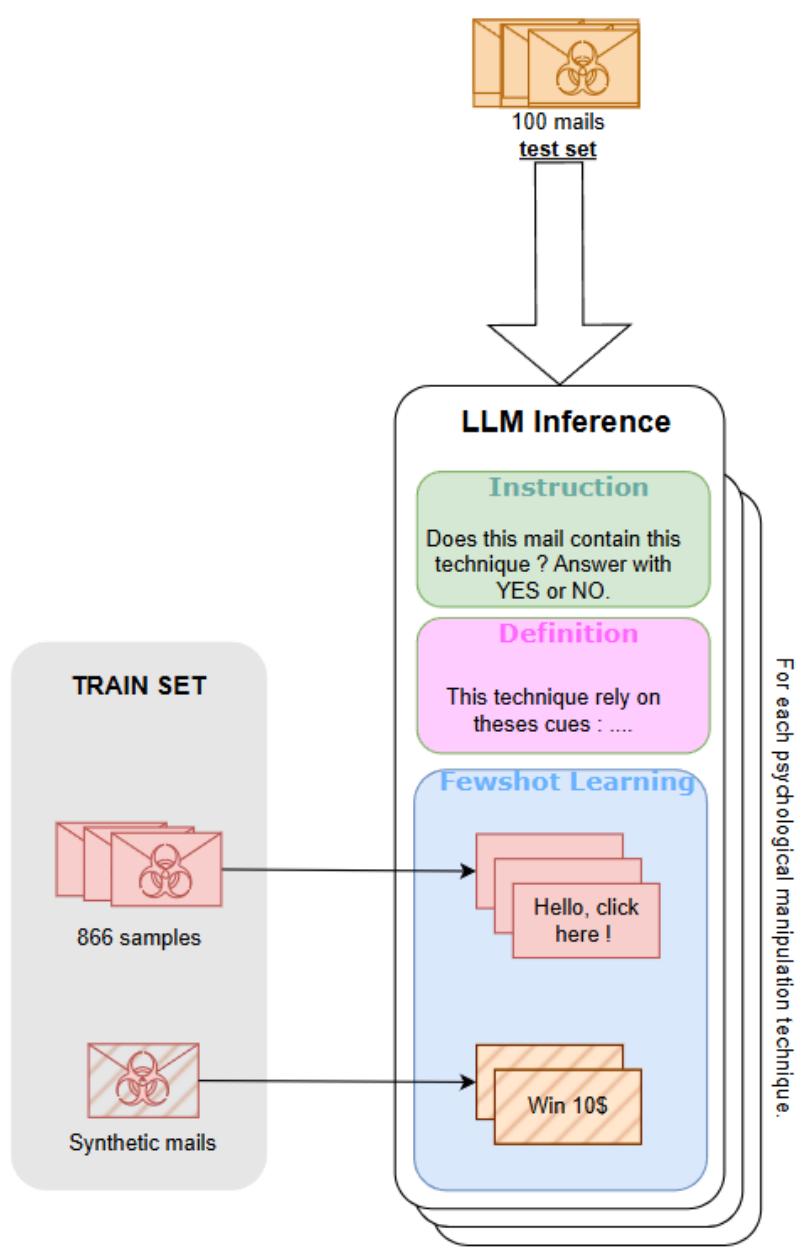
Base64 est efficace contre les antispams testés.

Les techniques d'obfuscation peuvent être contre-productives et augmenter le score de spam.

DÉTECTION PAR IA DES TECHNIQUES DE MANIPULATION PSYCHOLOGIQUE

Cas d'application





IN-CONTEXT LEARNING

Capacité des LLM à apprendre une nouvelle compétence simplement en la décrivant dans le prompt.

SYNTHETIC DATA

Utilisation d'une IA pour créer les données nécessaires à une autre IA. (Dans notre cas)

Une approche très simple

ChatGPT ▾

↑ Partager ⋮

Is this email contain the XXX manipulation technique. Answer with YES or NO.
XXX is when you do

Here are samples of mail containing this technique :

###

Hello,

[Click here](#)

...

####

Please, I miss u

###

....

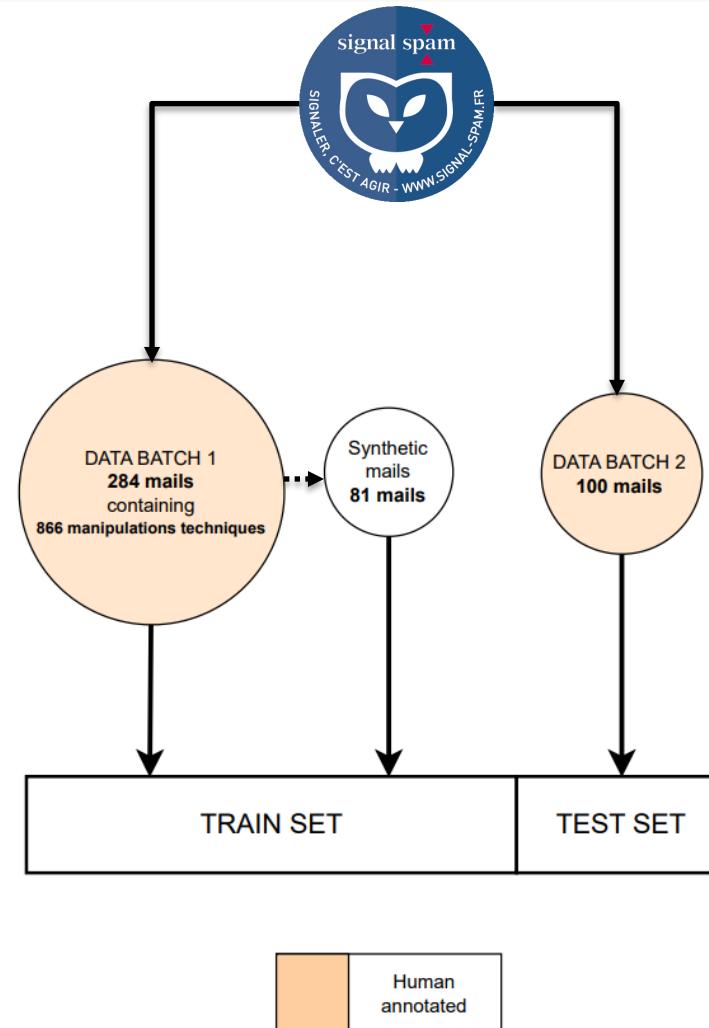
###

YES

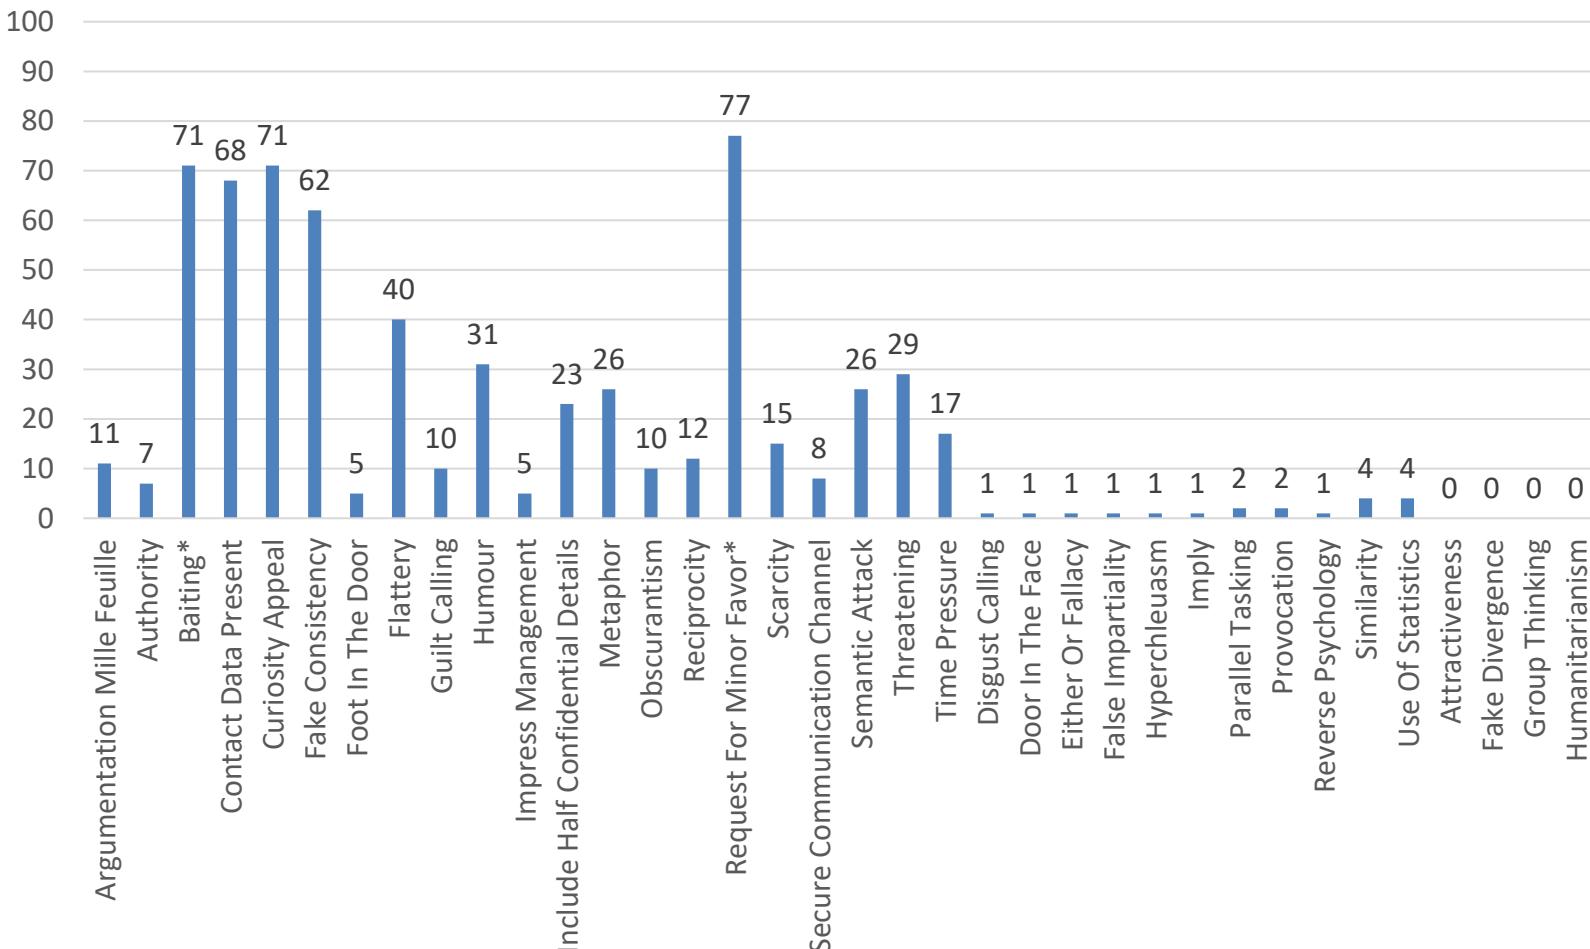


Thèse interdisciplinaire en sciences cognitives et cybersécurité

Dataset

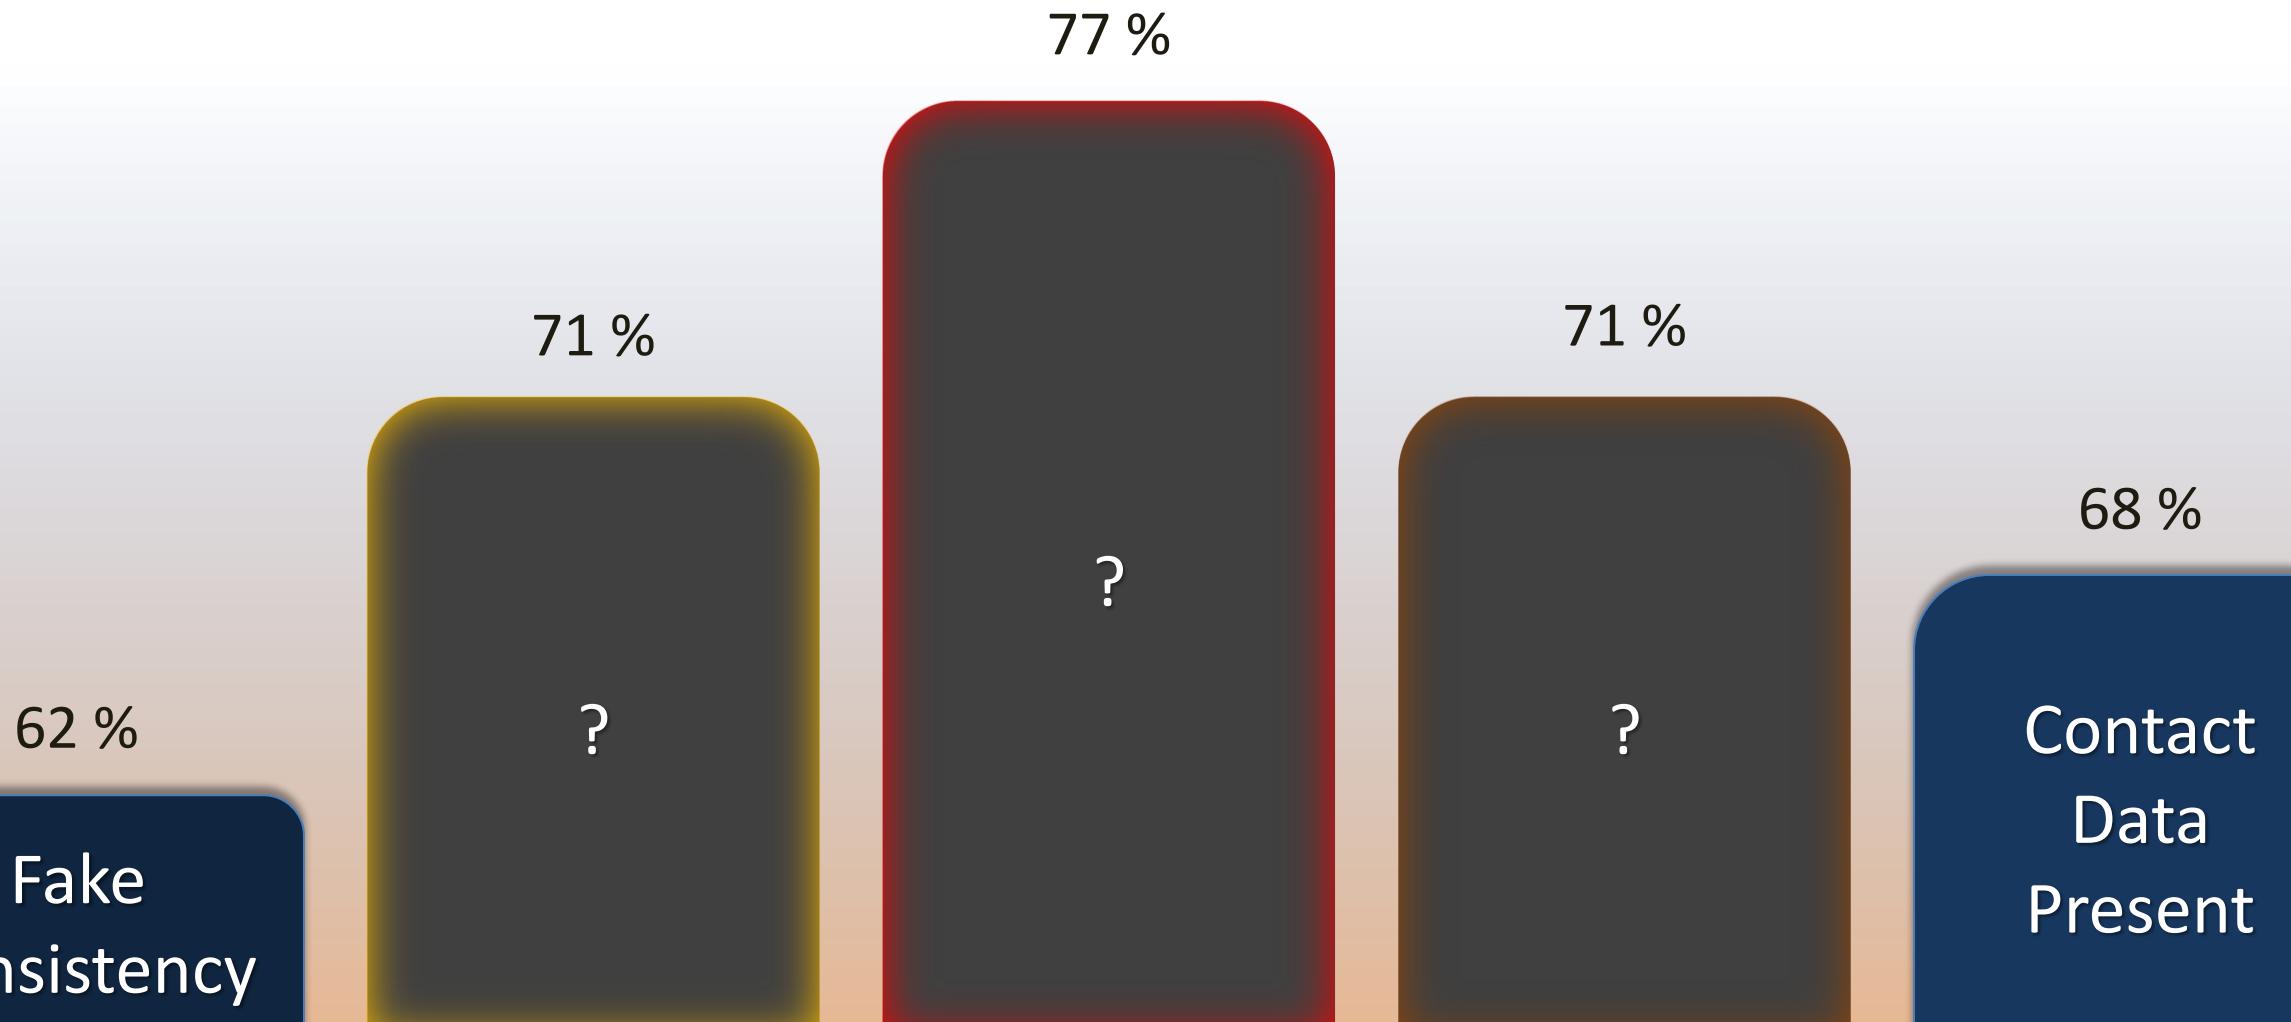


Utilisation de techniques de manipulation



% of use of manipulation techniques in the wild.

Utilisation de techniques de manipulation



TOP 3 : Curiosité

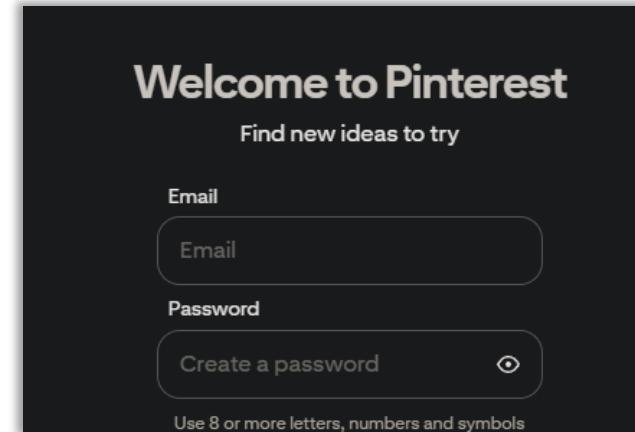


Click here to know more.

secret.pdf

You will never believe it.

Social Engineering
Marketing



TOP 2 : Appatage



Win 20000\$

A hot single near you

Get a free Iphone

Social Engineering
Marketing

Uber One
€5.99/mo or €59.99/yr

- €0 Delivery Fee on eligible orders*
- Up to 50% off service fees on eligible orders*
- Up to 10% on eligible rides**
- Cancel without fees or penalties

Save €14 every month
Savings calculated based on average savings from members in France over the month of July 2022.

Apple
Up To 25% OFF
on Apple brand products
[SHOP NOW](#)



: Demande mineure

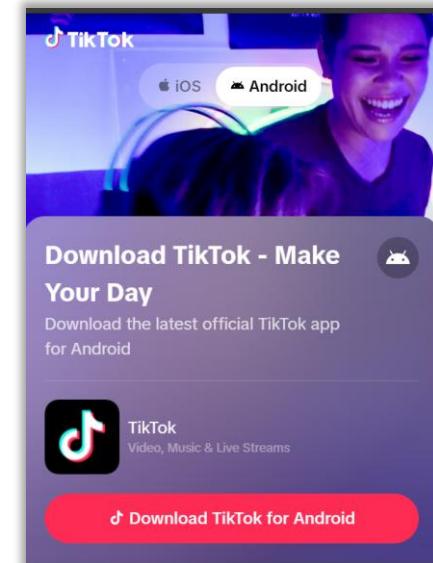
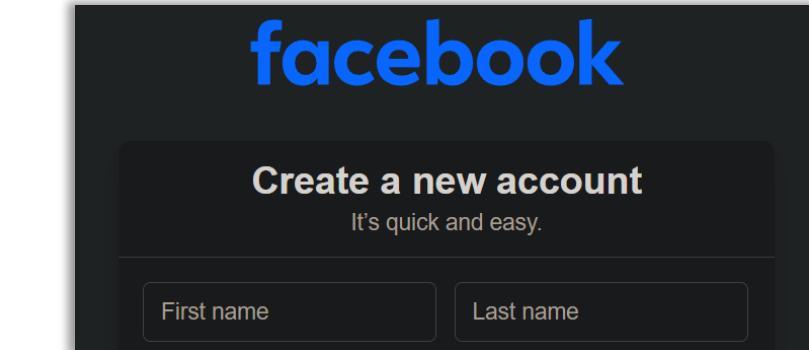


We just need your name

You are one click away from being rich

You just have to reply to this mail

Social Engineering Marketing



Qu'avons-nous appris ?

Les « vieux scams » sont toujours à la mode.

Les étapes cognitives ciblées en priorité sont la motivation à évaluer et la capacité à évaluer.

COMMENT CES TECHNIQUES DE MANIPULATIONS SE COMBINENT-ELLES

Co-occurrence matrix

	Request For Minor Favor	Baiting	Contact Data Present	Curiosity Appeal	Fake Consistency	Flattery	Humour	Threatening	Metaphor	Semantic Attack	Include Half Confidential Details	Time Pressure	Scarcity	Guilt Calling	Reciprocity	Argumentation Mille Feuille	Obscurantism	Secure Communication Channel	Authority	Foot In The Door	Impress Management
Request For Minor Favor		0,65	0,59	0,62	0,51	0,40	0,31	0,18	0,26	0,18	0,18	0,12	0,10	0,09	0,09	0,09	0,08	0,06	0,05	0,03	0,05
Baiting	0,65		0,58	0,56	0,51	0,40	0,29	0,14	0,25	0,11	0,13	0,10	0,11	0,08	0,10	0,09	0,05	0,05	0,02	0,04	0,04
Contact Data Present	0,59	0,58		0,50	0,48	0,37	0,28	0,21	0,24	0,15	0,14	0,13	0,09	0,07	0,05	0,07	0,05	0,06	0,04	0,04	0,05
Curiosity Appeal	0,62	0,56	0,50		0,49	0,36	0,29	0,13	0,21	0,15	0,17	0,10	0,08	0,10	0,05	0,06	0,05	0,05	0,04	0,01	0,04
Fake Consistency	0,51	0,51	0,48	0,49		0,31	0,23	0,17	0,21	0,15	0,15	0,14	0,10	0,10	0,04	0,04	0,02	0,06	0,04	0,03	0,04
Flattery	0,40	0,40	0,37	0,36	0,31		0,27	0,02	0,21	0,00	0,01	0,01	0,02	0,03	0,00	0,02	0,00	0,01	0,01	0,00	0,01
Humour	0,31	0,29	0,28	0,29	0,23	0,27		0,03	0,17	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,01	0,00	0,03	0,00	0,01
Threatening	0,18	0,14	0,21	0,13	0,17	0,02	0,03		0,02	0,17	0,13	0,13	0,11	0,05	0,06	0,05	0,05	0,05	0,07	0,04	0,01
Metaphor	0,26	0,25	0,24	0,21	0,21	0,21	0,17	0,02		0,00	0,01	0,01	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,00	0,02
Semantic Attack	0,18	0,11	0,15	0,15	0,15	0,00	0,01	0,17	0,00		0,14	0,13	0,09	0,03	0,05	0,03	0,06	0,03	0,05	0,03	0,02
Include Half Confidential Details	0,18	0,13	0,14	0,17	0,15	0,01	0,01	0,13	0,01	0,14		0,12	0,10	0,08	0,06	0,02	0,03	0,04	0,02	0,01	0,01
Time Pressure	0,12	0,10	0,13	0,10	0,14	0,01	0,01	0,13	0,01	0,13	0,12		0,09	0,05	0,03	0,02	0,02	0,04	0,02	0,02	0,00
Scarcity	0,10	0,11	0,09	0,08	0,10	0,02	0,01	0,11	0,01	0,09	0,10	0,09		0,04	0,06	0,02	0,02	0,02	0,02	0,02	0,00
Guilt Calling	0,09	0,08	0,07	0,10	0,10	0,03	0,01	0,05	0,00	0,03	0,08	0,05	0,04		0,01	0,02	0,00	0,02	0,00	0,00	0,01
Reciprocity	0,09	0,10	0,05	0,05	0,04	0,00	0,00	0,06	0,01	0,05	0,06	0,03	0,06	0,01		0,02	0,03	0,02	0,00	0,02	0,01
Argumentation Mille Feuille	0,09	0,09	0,07	0,06	0,04	0,02	0,00	0,05	0,00	0,03	0,02	0,02	0,02	0,02	0,02		0,03	0,02	0,01	0,01	0,00
Obscurantism	0,08	0,05	0,05	0,05	0,02	0,00	0,01	0,05	0,01	0,06	0,03	0,02	0,02	0,00	0,03		0,02	0,03	0,02	0,00	0,02
Secure Communication Channel	0,06	0,05	0,06	0,05	0,06	0,01	0,00	0,05	0,01	0,03	0,04	0,04	0,02	0,02	0,02	0,02		0,01	0,01	0,00	0,00
Authority	0,05	0,02	0,04	0,04	0,04	0,01	0,03	0,07	0,01	0,05	0,02	0,02	0,02	0,00	0,00	0,01	0,03	0,01		0,01	0,01
Foot In The Door	0,03	0,04	0,04	0,01	0,03	0,00	0,00	0,04	0,00	0,03	0,01	0,02	0,02	0,00	0,02	0,01	0,02	0,01	0,01		0,00
Impress Management	0,05	0,04	0,05	0,04	0,04	0,01	0,01	0,01	0,02	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00		0,00

Contact Data + Request For Minor Favor

Curiosity Appeal + Contact Data

Baiting+ Request For Minor Favor

Co-occurrence matrix

Request For Minor Favor	0.65	0.59	0.62	0.51	0.40	0.31	0.18	0.26	0.18	0.18	0.12	0.10	0.09	0.09	0.09	0.08	0.06	0.05	0.03	0.05
Baiting	0.65	0.58	0.56	0.51	0.40	0.29	0.14	0.25	0.11	0.13	0.10	0.11	0.08	0.10	0.09	0.05	0.05	0.02	0.04	0.04
Contact Data Present	0.59	0.58	0.50	0.48	0.37	0.28	0.21	0.24	0.15	0.14	0.13	0.09	0.07	0.05	0.07	0.05	0.06	0.04	0.04	0.05
Curiosity Appeal	0.62	0.56	0.50	0.49	0.36	0.29	0.13	0.21	0.15	0.17	0.10	0.08	0.10	0.05	0.06	0.05	0.05	0.04	0.01	0.04
Fake Consistency	0.51	0.51	0.48	0.49	0.31	0.23	0.17	0.21	0.15	0.15	0.14	0.10	0.10	0.04	0.04	0.02	0.06	0.04	0.03	0.04
Flattery	0.40	0.40	0.37	0.36	0.31	0.27	0.02	0.21	0.00	0.01	0.01	0.02	0.03	0.00	0.02	0.00	0.01	0.01	0.00	0.01
Humour	0.31	0.29	0.28	0.29	0.23	0.27	0.03	0.17	0.01	0.01	0.01	0.01	0.01	0.00	0.00	0.01	0.00	0.03	0.00	0.01
Threatening	0.18	0.14	0.21	0.13	0.17	0.02	0.03	0.02	0.17	0.13	0.13	0.11	0.05	0.06	0.05	0.05	0.05	0.07	0.04	0.01
Metaphor	0.26	0.25	0.24	0.21	0.21	0.21	0.17	0.02	0.00	0.01	0.01	0.01	0.00	0.01	0.00	0.01	0.01	0.01	0.00	0.02
Semantic Attack	0.18	0.11	0.15	0.15	0.00	0.01	0.17	0.00	0.14	0.13	0.09	0.03	0.05	0.03	0.06	0.03	0.05	0.03	0.02	0.02
Include Half Confidential Details	0.18	0.13	0.14	0.17	0.15	0.01	0.01	0.13	0.01	0.14	0.12	0.10	0.08	0.06	0.02	0.03	0.04	0.02	0.01	0.01
Time Pressure	0.12	0.10	0.13	0.10	0.14	0.01	0.01	0.13	0.01	0.13	0.12	0.09	0.05	0.03	0.02	0.02	0.04	0.02	0.02	0.00
Scarcity	0.10	0.11	0.09	0.08	0.10	0.02	0.01	0.11	0.01	0.09	0.10	0.09	0.04	0.06	0.02	0.02	0.02	0.02	0.02	0.00
Guilt Calling	0.09	0.08	0.07	0.10	0.10	0.03	0.01	0.05	0.00	0.03	0.08	0.05	0.04	0.01	0.02	0.00	0.02	0.00	0.00	0.01
Reciprocity	0.09	0.10	0.05	0.05	0.04	0.00	0.00	0.06	0.01	0.05	0.06	0.03	0.06	0.01	0.02	0.03	0.02	0.00	0.02	0.01
Argumentation Mille Feuille	0.09	0.09	0.07	0.06	0.04	0.02	0.00	0.05	0.00	0.03	0.02	0.02	0.02	0.02	0.03	0.02	0.01	0.01	0.00	0.00
Obscurantism	0.08	0.05	0.05	0.05	0.02	0.00	0.01	0.05	0.01	0.06	0.03	0.02	0.02	0.00	0.03	0.02	0.03	0.02	0.00	0.00
Secure Communication Channel	0.06	0.05	0.06	0.05	0.06	0.01	0.00	0.05	0.01	0.03	0.04	0.04	0.02	0.02	0.02	0.02	0.01	0.01	0.00	0.00
Authority	0.05	0.02	0.04	0.04	0.04	0.01	0.03	0.07	0.01	0.05	0.02	0.02	0.02	0.00	0.01	0.03	0.01	0.01	0.01	0.01
Foot In The Door	0.03	0.04	0.04	0.01	0.03	0.00	0.00	0.04	0.00	0.03	0.01	0.02	0.02	0.00	0.02	0.01	0.02	0.01	0.01	0.00
Impress Management	0.05	0.04	0.05	0.04	0.04	0.01	0.01	0.01	0.02	0.02	0.01	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.00	0.00

Contact Data Request For Minor Favor Curiosity Appeal Baiting

You will never guess what happened to him.

John,
+33 137118419
7 Rue de Paris, France

Please just answer me.

Judith,
+33 137118419
7 Rue de Paris, France

Save 80% on your insurance just by clicking here.

Co-occurrence matrix

	Baiting	Contact Data Present	Curiosity Appeal	Fake Consistency	Flattery	Humour	Threatening	Semantic Attack	Include Half Confidential Details	Time Pressure	Scarcity	Guilt Calling	Reciprocity	Argumentation Mille Feuille	Obscurantism	Secure Communication Channel	Authority	Foot In The Door	Impress Management	
Request For Minor Favor	0.65	0.59	0.62	0.51	0.40	0.31	0.18	0.26	0.18	0.18	0.12	0.10	0.09	0.09	0.09	0.08	0.06	0.05	0.03	0.05
Baiting	0.65	0.58	0.56	0.51	0.40	0.29	0.14	0.25	0.11	0.13	0.10	0.11	0.08	0.10	0.09	0.05	0.05	0.02	0.04	0.04
Contact Data Present	0.59	0.58	0.50	0.48	0.37	0.28	0.21	0.24	0.15	0.14	0.13	0.09	0.07	0.05	0.07	0.05	0.06	0.04	0.04	0.05
Curiosity Appeal	0.62	0.56	0.50	0.49	0.36	0.29	0.13	0.21	0.15	0.17	0.10	0.08	0.10	0.05	0.06	0.05	0.05	0.04	0.01	0.04
Fake Consistency	0.51	0.51	0.48	0.49	0.31	0.23	0.17	0.21	0.15	0.15	0.14	0.10	0.10	0.04	0.04	0.02	0.06	0.04	0.03	0.04
Flattery	0.40	0.40	0.37	0.36	0.31	0.27	0.02	0.21	0.00	0.01	0.01	0.02	0.03	0.00	0.02	0.00	0.01	0.01	0.00	0.01
Humour	0.31	0.29	0.28	0.29	0.23	0.27	0.03	0.17	0.01	0.01	0.01	0.01	0.01	0.00	0.00	0.01	0.00	0.03	0.00	0.01
Threatening	0.18	0.14	0.21	0.13	0.17	0.02	0.03	0.02	0.17	0.13	0.13	0.11	0.05	0.06	0.05	0.05	0.05	0.07	0.04	0.01
Metaphor	0.26	0.25	0.24	0.21	0.21	0.17	0.02	0.00	0.00	0.01	0.01	0.01	0.00	0.01	0.00	0.01	0.01	0.01	0.00	0.02
Semantic Attack	0.18	0.11	0.15	0.15	0.00	0.01	0.17	0.00	0.14	0.13	0.09	0.03	0.05	0.03	0.06	0.03	0.05	0.03	0.02	0.00
Include Half Confidential Details	0.18	0.13	0.14	0.17	0.15	0.01	0.01	0.13	0.01	0.14	0.12	0.10	0.08	0.06	0.02	0.03	0.04	0.02	0.01	0.01
Time Pressure	0.12	0.10	0.13	0.10	0.14	0.01	0.01	0.13	0.01	0.13	0.12	0.09	0.05	0.03	0.02	0.02	0.04	0.02	0.02	0.00
Scarcity	0.10	0.11	0.09	0.08	0.10	0.02	0.01	0.11	0.01	0.09	0.10	0.09	0.04	0.06	0.02	0.02	0.02	0.02	0.02	0.00
Guilt Calling	0.09	0.08	0.07	0.10	0.10	0.03	0.01	0.05	0.00	0.03	0.08	0.05	0.04	0.01	0.02	0.00	0.02	0.00	0.00	0.01
Reciprocity	0.09	0.10	0.05	0.05	0.04	0.00	0.00	0.06	0.01	0.05	0.06	0.03	0.06	0.01	0.02	0.03	0.02	0.00	0.02	0.01
Argumentation Mille Feuille	0.09	0.09	0.07	0.06	0.04	0.02	0.00	0.05	0.00	0.03	0.02	0.02	0.02	0.02	0.03	0.02	0.01	0.01	0.00	0.00
Obscurantism	0.08	0.05	0.05	0.05	0.02	0.00	0.01	0.05	0.01	0.06	0.03	0.02	0.02	0.00	0.03	0.02	0.03	0.02	0.00	0.00
Secure Communication Channel	0.06	0.05	0.06	0.05	0.06	0.01	0.00	0.05	0.01	0.03	0.04	0.04	0.02	0.02	0.02	0.02	0.01	0.01	0.00	0.00
Authority	0.05	0.02	0.04	0.04	0.04	0.01	0.03	0.07	0.01	0.05	0.02	0.02	0.02	0.00	0.00	0.01	0.03	0.01	0.01	0.01
Foot In The Door	0.03	0.04	0.04	0.01	0.03	0.00	0.00	0.04	0.00	0.03	0.01	0.02	0.02	0.00	0.02	0.01	0.02	0.01	0.01	0.00
Impress Management	0.05	0.04	0.05	0.04	0.04	0.01	0.01	0.01	0.02	0.02	0.01	0.00	0.01	0.01	0.00	0.00	0.01	0.00	0.00	0.00

Contact Data Request For Minor Favor Curiosity Appeal Baiting

You will never guess what happened to him.

John,

+33 137118419

7 Rue de Paris, France

Please just answer me.

Judith,

+33 137118419

7 Rue de Paris, France

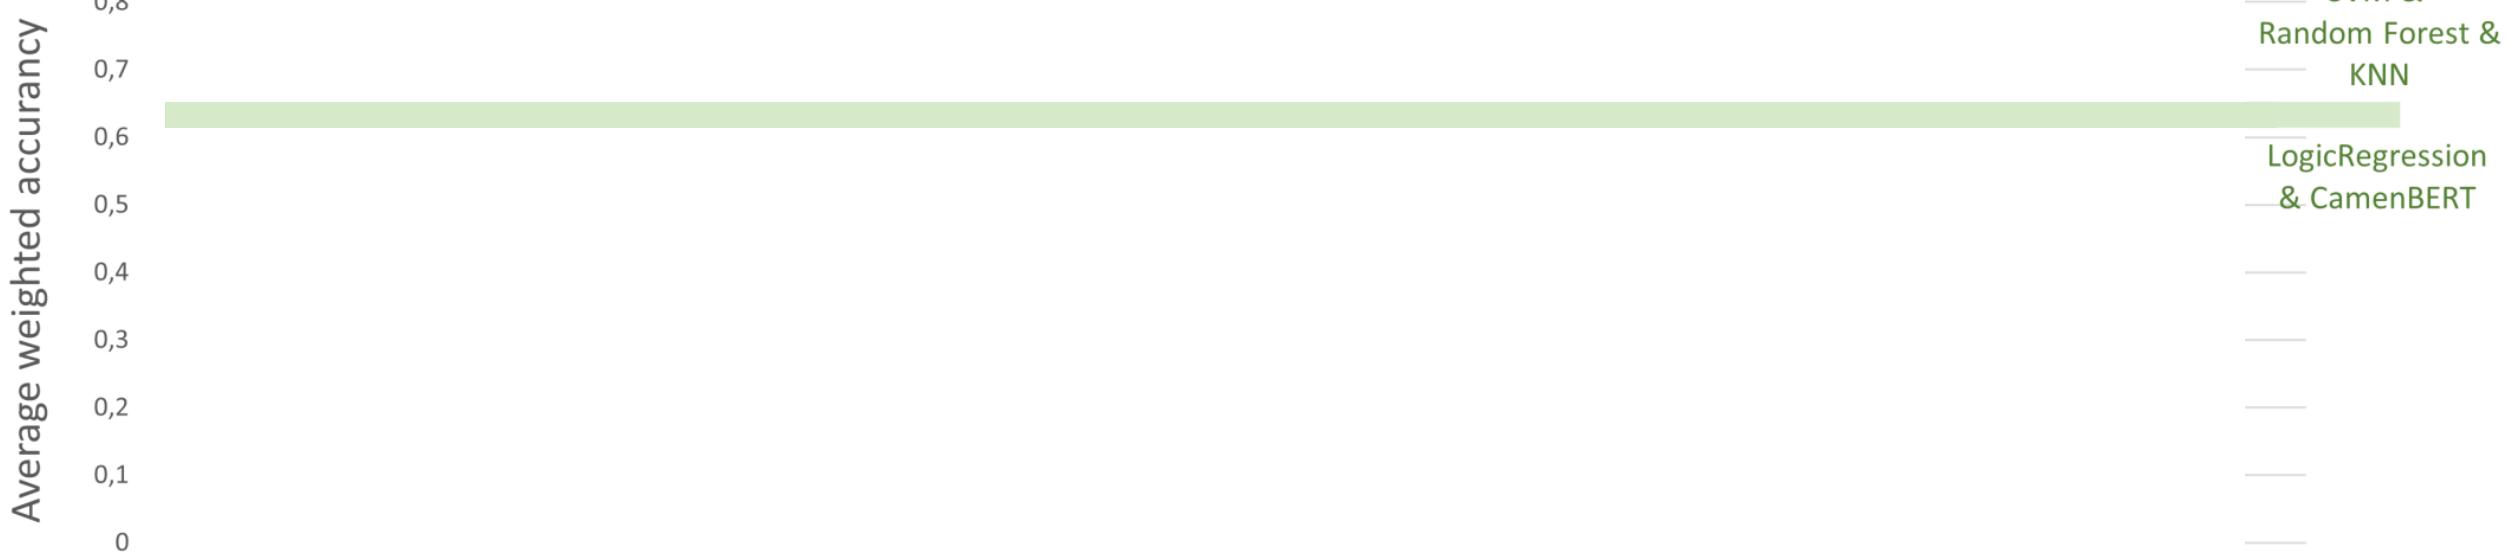
Save 80% on your insurance just by clicking [here](#).

BENCHMARK

Résultat

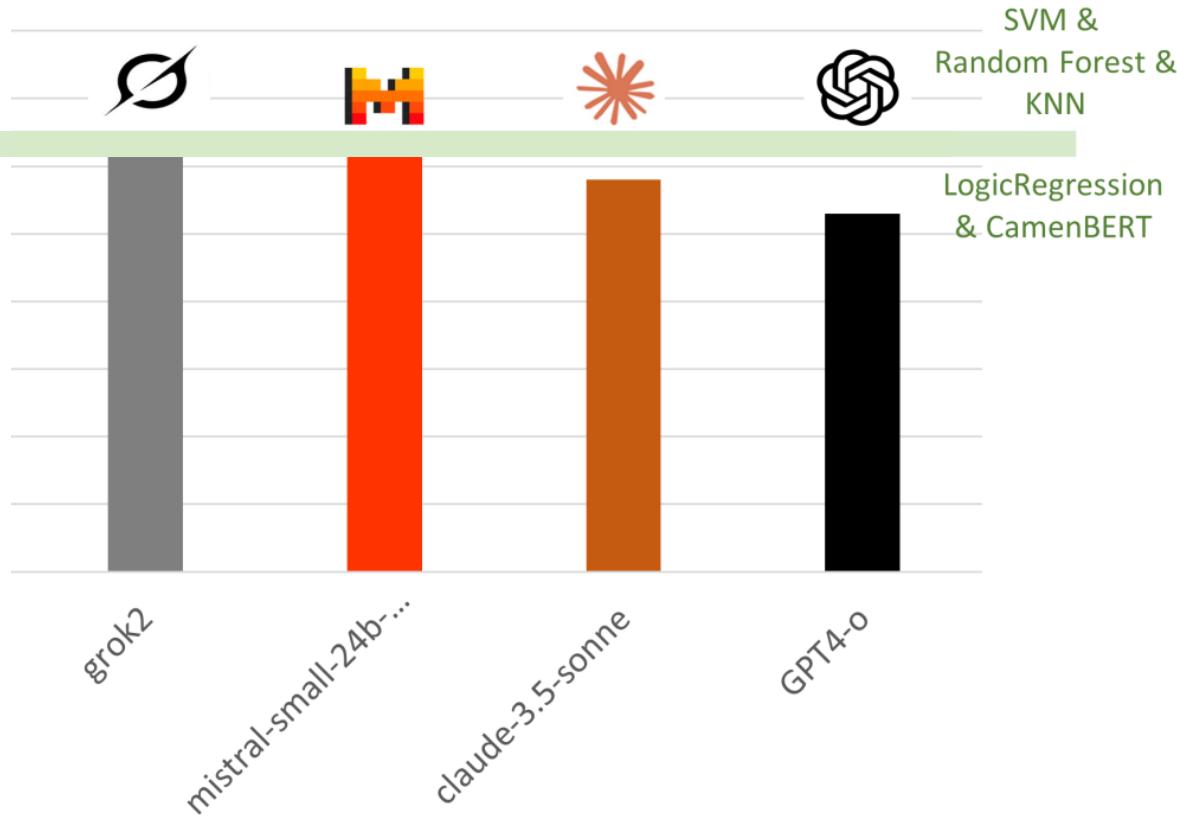
Technique	TP	TN	FP	FN	Acc	Rec	Prec	F1
<i>Highly representative techniques</i>								
Argumentation Mille Feuille	4	53	36	7	0.57	0.36	0.10	0.16
Authority	5	71	22	2	0.76	0.71	0.19	0.29
Baiting*	53	26	2	18	0.79	0.74	0.96	0.83
Contact Data Present	48	21	11	20	0.69	0.71	0.81	0.76
Curiosity Appeal	64	11	18	7	0.75	0.90	0.78	0.84
Fake Consistency	46	28	10	16	0.74	0.74	0.82	0.78
Foot In The Door	4	78	17	1	0.82	0.80	0.19	0.31
Flattery	37	54	6	3	0.91	0.93	0.86	0.89
Guilt Calling	1	90	0	9	0.91	0.10	1.00	0.18
Humour	28	52	17	3	0.80	0.90	0.62	0.74
Impress Management	2	54	41	3	0.56	0.40	0.05	0.08
Include Half Confidential Details	14	68	9	9	0.82	0.61	0.61	0.61
Metaphor	26	32	42	0	0.58	1.00	0.38	0.55
Obscurantism	3	70	20	7	0.73	0.30	0.13	0.18
Reciprocity	5	87	1	7	0.92	0.42	0.83	0.56
Request For Minor Favor*	60	13	9	17	0.73	0.77	0.87	0.82
Scarcity	13	56	29	2	0.69	0.87	0.31	0.46
Secure Communication Channel	5	80	12	3	0.85	0.62	0.29	0.40
Semantic Attack	14	59	15	12	0.73	0.54	0.48	0.51
Threatening	12	70	1	17	0.82	0.41	0.92	0.57
Time Pressure	13	67	16	4	0.80	0.76	0.45	0.57

Benchmark

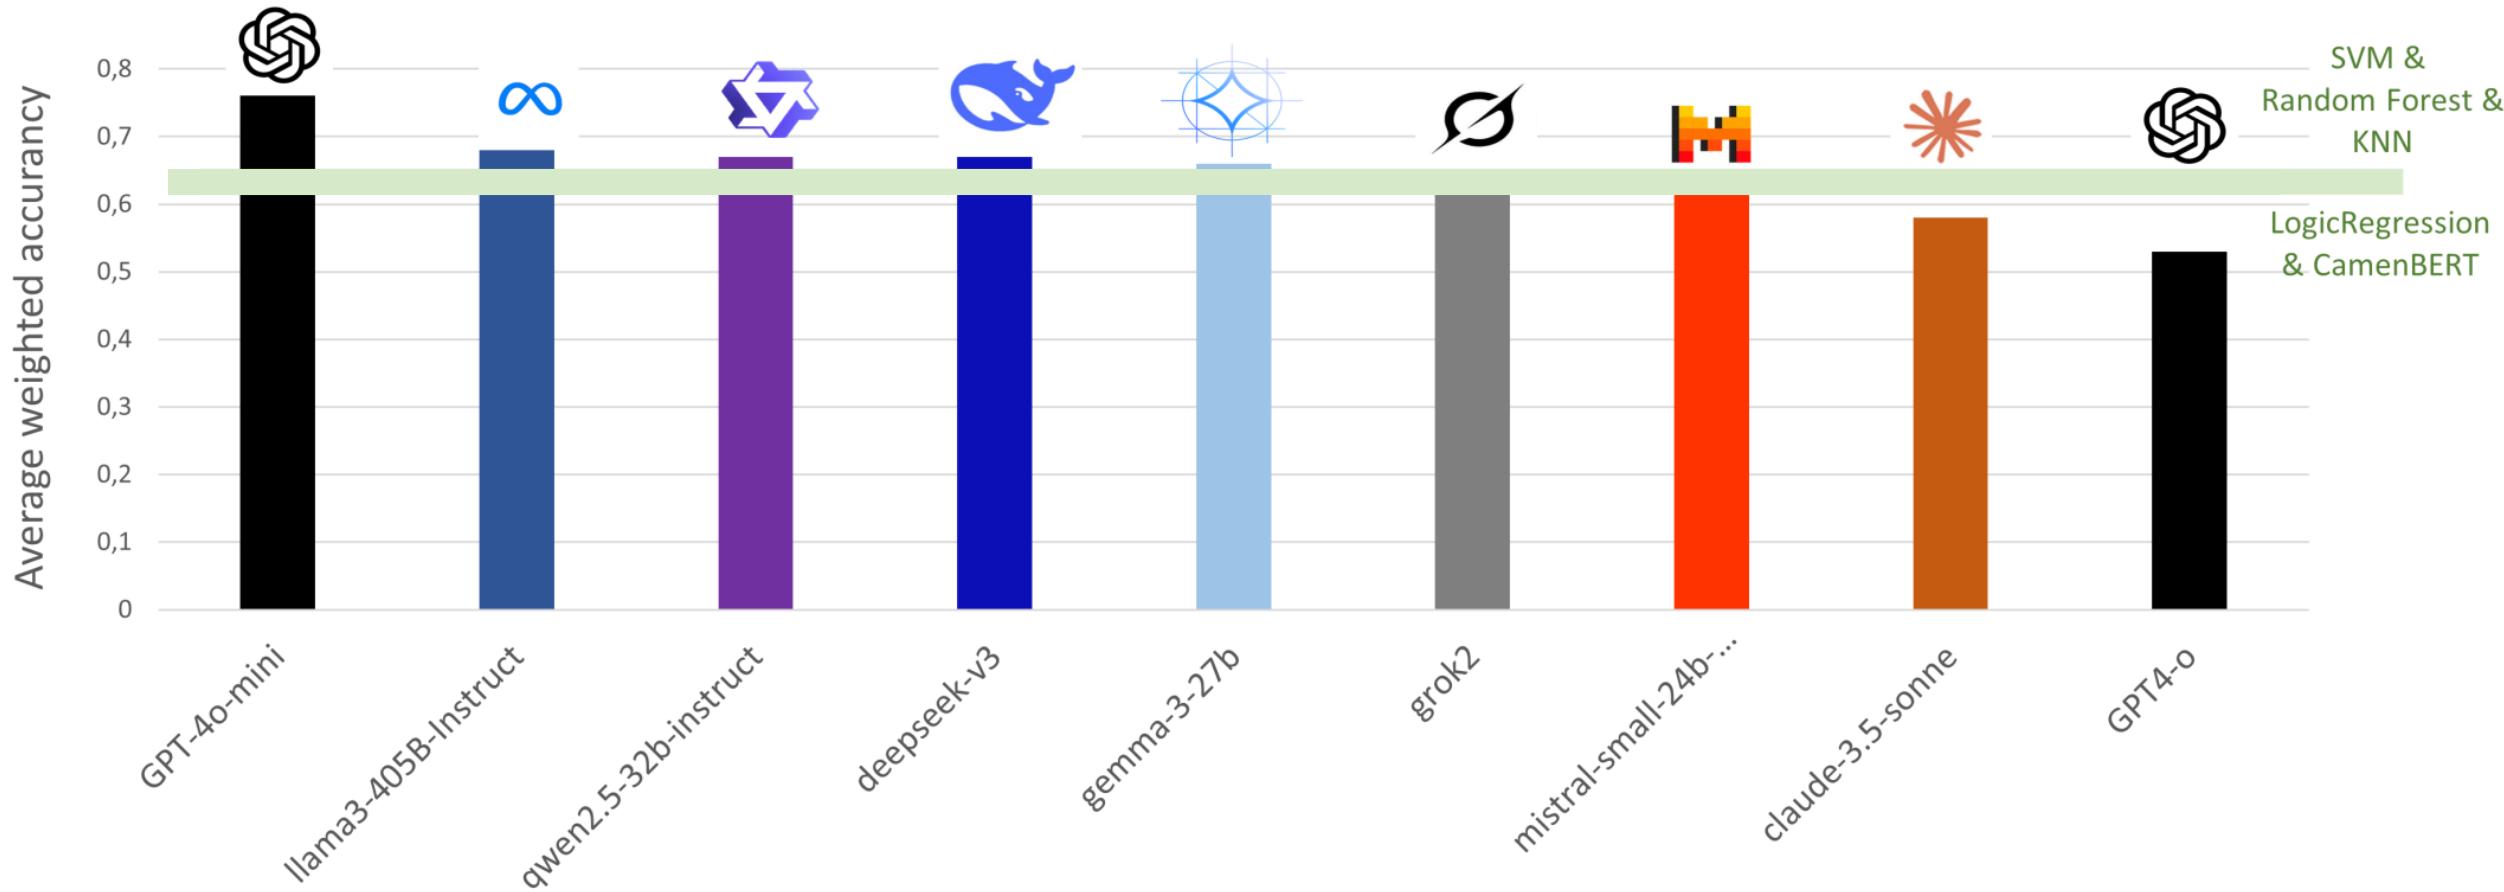


Benchmark

Average weighted accuracy

0,8
0,7
0,6
0,5
0,4
0,3
0,2
0,1
0

Benchmark



Qu'avons-nous appris ?

Les LLM sont de très bons candidats pour détecter des patterns de langages aussi complexes.

Bonne marge de progression.

Data semble être le bottleneck principal.

MERCI

antony.dalmiere@cnrs.fr