Ethique du numérique, données personnelles et données d'intérêt générale. Préparation à l'agrégation d'Informatique

Roberto Di Cosmo

Ethique du numérique, données personnelles et données d'intérêt générale

Préparation à l'agrégation d'Informatique

Roberto Di Cosmo
Inria et Université de Paris

17 Avril 2023

Software Heritage

THE GREAT LIBRARY OF SOURCE CODE

Outline

Courte biographie: Roberto Di Cosmo

Computer Science professor in Paris, now working at INRIA

- *30+ years* of research (Theor. CS, Programming, Software Engineering, Erdos #: 3)
- *20+ years* of Free and Open Source Software
- *10+ years* building and directing structures for the common good

1999 *DemoLinux* – first live GNU/Linux distro

2007 *Free Software Thematic Group*
150 members 40 projects 200Me

2008 *Mancoosi project* www.mancoosi.org

2010 *IRILL* www.irill.org

2015 *Software Heritage* at INRIA

2018 *National Committee for Open Science*, France

2021 *EOSC Task Force on Infrastructures for Software*, European Union

Standard disclaimer: IANAL (I am not a lawyer)

Objectifs du cours

Elargir vos perspectives…

L'Informatique est une science dont les applications ont un impact sur toute notre société.

… à travers le programme officiel …

- Points clés du RGPD.
- Notions de Données d'Intérêt Général (DIG).
- Points clés de la loi n° 2016-1321 du 7 octobre 2016 pour une République numérique.
- Enjeux d'éthique du numérique et valeurs sous-jacentes.

… pour mieux vous préparer

Vous avez la responsabilité de former des nouvelles générations plus conscientes des enjeux du numérique.

Outline

Les technologies informatiques

Les bases de la révolution informatique:

- processeurs,
- systèmes de stockage des données,
- réseaux,
- algorithmes et logiciels,
- …

Cela évolue à une vitesse sans précédent.

Loi de Moore (in memoriam, 24/3/2023, voir entrée sur Wikipedia)

"Le nombre de transistors double tous les deux ans" Gordon Moore, 1965

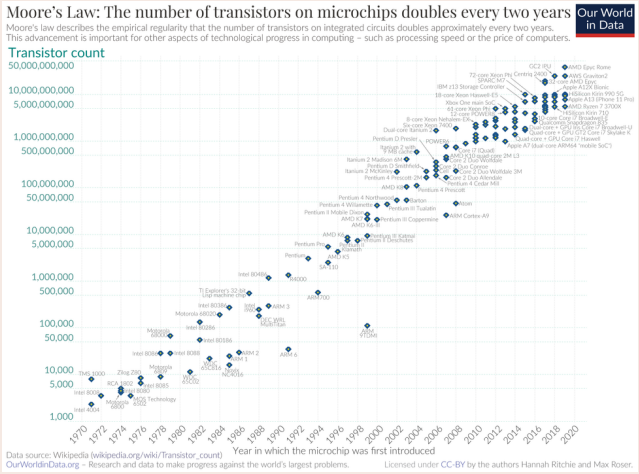

Capacité de stockage, vitesse du réseau

Taille des disques

Année	2.5in	3.5in
1997	3Gb	10Gb
2007	250Gb	1000Gb
2023	8000Gb	22000Gb

Et on peut avoir des SSD!

Débit du réseau

Année	Rx	Tx
1998	256 kb/s	128 kb/s
2007	28000 kb/s	1000 kb/s (*)
2021	1000000 kb/s	100000 kb/s

(*) Exception importante!

Trois à quatre ordres de grandeur en 25 ans…

… et sur toutes les dimensions!

Une évolution sans précedents, avec un grand impact sur la société

Cela pose des défis éthiques majeurs auxquels on était peu préparés

Outline

Adoption massive

Utilisateurs d'Internet

de 2.6M en 1990 à 3+ milliards en 2016 (voir https://ourworldindata.org/internet)

Abonnements mobiles

de 34M en 1993 à 8 milliards en 2019 (voir https://www.statista.com/statistics/262950/global-mobile-subscriptions-since-1993/)

- et depuis 2007 (iPhone), abonnement mobile == accès internet

Informatique sans fil, partout, de(?)centralisée

Téléphones mobiles

- ordinateurs sans fil, mobiles, connectés
- réseau massif de senseurs
- financé par les utilisateurs

Cloud

- compute/storage/network à la demande
- data centers massifs
- opérés par des corporations multinationales

Essor de la collaboration et du partage…

Expansion massive du logiciel libre

- SourceForge (1999), BitBucket (2008), GitHub (2008), GitLab (2014), etc. etc.

Réseaux peer to peer

- Napster (1999), BitTorrent (2001), etc.

Dévéloppement collaboratif des connaissances

- Wikipedia (depuis 2001)
- OpenStreeMap (depuis 2004)

A propos du logiciel

Cadre legislatif du logiciel

- "oeuvre de l'esprit", couverte par le droit d'auteur (article L112-2 du CPI)
  - droit moral
  - droit patrimonial
- la (re)utilisation se fait sur la base d'un contrat, qui peut prendre la forme d'une *licence logicielle*
- des particularités meriteraient une étude approfondie (e.g.: voir cette analyse d'un cas concret)

A propos du logiciel libre

Le logiciel libre …

- logiciel dont la licence autorise sans restrictions
  - *l'utilisation*
  - la *modification* (implique l'accès aux sources et aux outils)
  - la *redistribution*
  - la *redistribution* des versions modifiées
- ces droits peuvent s'accompagner d'obligations (de citation, de préservation de la licence, etc.)
- cela meriterait une étude approfondie, voir par exemple
  - Canevet et Pellegrini, Droit des Logiciels
  - Di Cosmo, Notes du cours sur les logiciels libres

… est un des moteurs de la revolution numérique

- au coeur de pratiquement tous les systèmes logiciels modernes
- réduction massive du coût de développement de nouveaux systèmes informatiques

… mais aussi de l'hyperconnectivité …

L'échange *prime* sur la possession

- moteurs de recherche
- sites web
- information en ligne
- social networks

Test

Combien de jours pouvez-vous résister/exister sans réseau?

À propos de la connectivité (1/2)

Evolution d'Internet

de épiphénomène technologique de la guerre froide (DARPA, TCP/IP, 1970): assurer la communication fiable même en cas de guerre nucléaire … …à moteur du changement des modes de communication, avec des problématiques multiples

Supranationalité (connexion entre machines dans différents pays)

- quel droit applicable?
  - MegaUpload, PirateBay
  - GAFAM vs éditeurs
  - …
- qui pilote les décisions techniques?
  - ICANN et ISOC
  - …

À propos de la connectivité (2/2)

Neutralité des réseaux

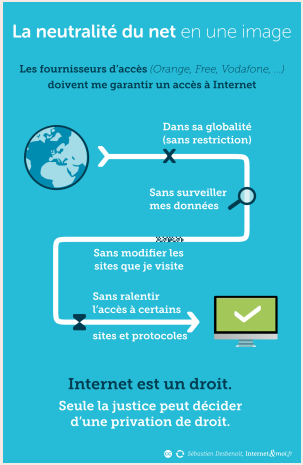

C'était le cas à l'origine de l'Internet, mais la technique n'impose rien.

Il s'agit d' un choix *sociétal*, et peut varier selon les pays et dans le temps

- grand firewall de Chine
- debat reglementaire aux US, et ses évolutions
- zero rating

et de la collecte massive d'informations…

par l'état (dématérialisation des données publiques), par exemple:

- dossier médical partagé
- dossier fiscal
- casier judiciaire
- cadastre

par des acteurs privés, par exemple:

- préférences de consommation (cartes de fidélité)
- préférences culturelles (cinéma, VOD, moteur de recherche)
- préférences politiques (réseaux sociaux, moteur de recherche)
- réseau de connaissances (téléphone, réseaux sociaux, courriel, banques)
- textes, photos, vidéos (téléphone, réseaux sociaux, moteur de recherche)

avec notre collaboration active

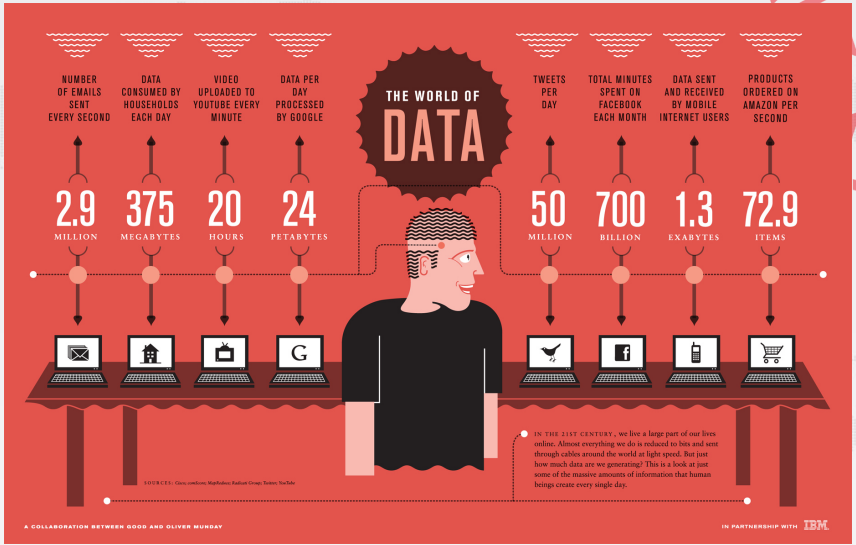
THE WORLD OF
DATA
NUMBER OF EMAILS SENT EVERY SECOND
2.9 MILLION
DATA CONSUMED BY HOUSEHOLDS EACH DAY
375 MEGABYTES
VIDEO UPLOADED TO YOUTUBE EVERY MINUTE
20 HOURS
DATA PER DAY PROCESSED BY GOOGLE
24 PETABYTES
TWEETS PER DAY
50 MILLION
TOTAL MINUTES SPENT ON FACEBOOK EACH MONTH
700 BILLION
DATA SENT AND RECEIVED BY MOBILE INTERNET USERS
1.3 EXABYTES
PRODUCTS ORDERED ON AMAZON PER SECOND
72.9 ITEMS
IN THE 21ST CENTURY, we live a large part of our lives online. Almost everything we do is reduced to bits and sent through cables around the world at light speed. But just how much data are we generating? This is a look at just some of the massive amounts of information that human beings create every single day.
SOURCES: Cisco; comScore; MapReduce; Radiant Group; Twitter; YouTube
A COLLABORATION BETWEEN GOOD AND OLIVER MUNDAY
IN PARTNERSHIP WITH IBM

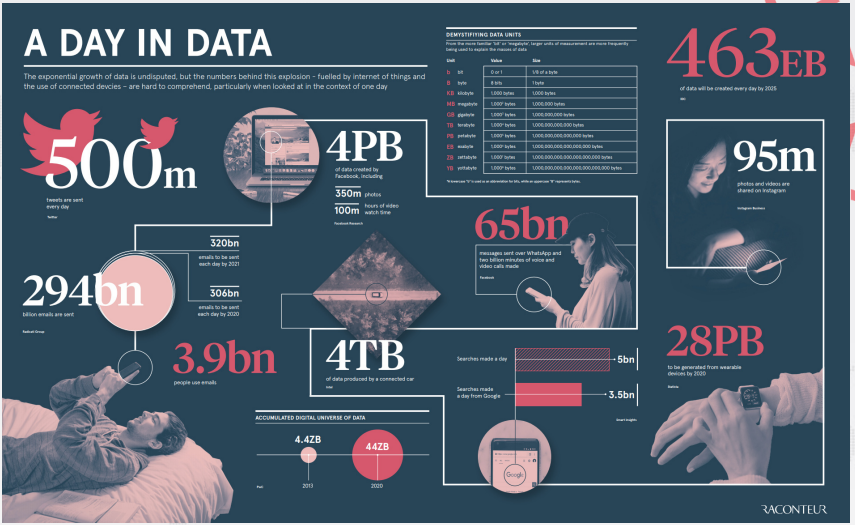

Credits: VisualCapitalist 2019

… qui a été longtemps peu ou pas encadrée: quelques exemples

Cession de droits à Facebook (par simple click), version 2013

For content that is covered by intellectual property rights, like photos and videos (IP content), you specifically give us the following permission, subject to your privacy and application settings: you grant us a non-exclusive, transferable, sub-licensable, royalty-free, worldwide license to *use* any IP content that you post on or in connection with Facebook (IP License). This IP License ends when you delete your IP content or your account *unless* your content has been shared with others, and they have not deleted it.

Clearview

Reconnaissance faciale basée sur plusieurs milliards d'images obtenues sur le Web et les réseaux sociaux

WhatsApp

Collecte de (meta)données personnelles (voir un résumé du débat)

Tout cela ensemble n'est pas anodin

Les ingrédients

- dématérialisation
- dans des infrastructures *centralisées*
- mises en réseau
- avec des moyens de calcul énormes

Les résultats

il y en a des positifs et des négatifs

Machine Learning

Avec données massives, calcul et avancées algorithmiques on peut avoir

des outils qui font rever…

- traduction automatique (DeepL)
- detection automatique de cancers
- generation automatique de documents, textes (LLM, ChatGPT, Bard, LLaMa etc.)
- assistants personnels
- …

… ou faire peur

- SciGen: faux papiers de recherche (déjà en 2005!)
- générateurs de *fake news* pour les *troll farms*
- *décisions automatiques biaisées* sur la santé, l'emploi ou la liberté des personnes (voir quelques exemples)
- …

Statistiques/Big Data

Avec des données massives, on peut

- suivre/prévoir l'avancée d'une grippe ou une épidemie e.g. Google Flu Trends (2008-2015)
- fournir des prévisions de trafic (Google Maps, Waze, etc.) ou de fréquentation de sites (possiblement utiles en temps de COVID, voir un autre exemple chez Google)

Mais aussi

- savoir avant vous si vous attendez un enfant:
  "I had a talk with my daughter. It turns out there's been some activities in my house I haven't been completely aware of" Un client de Target, en 2012.
- cibler précisement des utilisateurs pour les manipuler (e.g. Cambridge Analytica)

Les tuyaux ont leur importance

Traçage des échanges

- NSA (Snowden)
  - recording of conversations, conversion to searchable text (AI)
  - metadata collection (who talks to whom)

Technologies plus ou moins invasives

- traces GSM
- Deep packet inspection

nous ne sommes pas innocents dans tout cela

Outline

Enjeux éthiques

Ces exemples montrent le besoin d'une éthique de l'Informatique:

- ce qui est techniquement possible n'est pas forcément à faire
- un logiciel qui prend des décisions peut impliquer des questions éthiques

Principes

Des principes de bases ont été dévéloppés par différentes communautés, et notamment:

- code éthique de l'ACM: https://www.acm.org/code-of-ethics
- principes d'Asilomar : https://futureoflife.org/ai-principles

Comités

En France, un comité pilote d'éthique du numérique (CNPEN) a été créé au sein du Comité National d'Éthique.

Voir aussi: la note sur logiciels libres et décisions algorithmiques (LLW Barcelona, 2018)

Une culture qui n'est pas encore acquise

Un exemple recent: recherche en sécurité

- soumission de patchs "hypocrites" au noyau Linux au IEEE Symposium on Security and Privacy 2021
- reaction des dévéloppeurs Linux Avril 2021
  - "you are not welcome here"
- le rapport de comité de programme de S&P Mai 2021
  - violation de deux principes clé
    - Informed Consent / Autonomy
    - Beneficence / Balancing risks and benefits
  - mise en place d'un comité d'éthique

Move fast, break things?

La question du TDM

- DIRECTIVE (EU) 2019/790, 17 April 2019 on copyright and related rights
- Article 3: Text and data mining for the purposes of scientific research
- Article 4: Exception or limitation for text and data mining

Essor des LLM

- GitHub CoPilot (OpenAI Codex)
- training dataset = ?
- class action aux Etats Unis

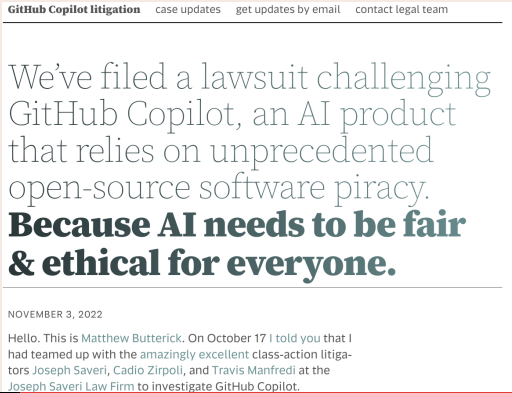

GitHub Copilot litigation case updates get updates by email contact legal team

We've filed a lawsuit challenging GitHub Copilot, an AI product that relies on unprecedented open-source software piracy.

Because AI needs to be fair & ethical for everyone.

NOVEMBER 3, 2022

Hello. This is Matthew Butterick. On October 17 I told you that I had teamed up with the amazingly excellent class-action litigators Joseph Saveri, Cadio Zirpoli, and Travis Manfredi at the Joseph Saveri Law Firm to investigate GitHub Copilot.

Outline

Enjeux legaux

Suite aux dérives multiples et aux vides juridiques constatés, le legislateur est intervenu.
On s'intéressera ici en particululier aux enjeux suivants:

Données personnelles

- données liées aux personnes physiques
- encadrées par le RGPD (régulation européenne de 2016) et la Loi Lemaire (2016)

Données administratives et publiques

- encadrées par la Loi Lemaire (voir aussi le rapport Trojette, 2013)

Données d'intérêt générale (Loi Lemaire, rapport Bothorel)

- données produites par des entités publiques ou par délégation des pouvoirs publics (Loi Lemaire)
- données produites ou déténues par des acteurs privés, mais dont l'usage peut être nécéssaire pour des fins d'intérêt général (rapport Bothorel 23 décembre 2020)

Outline

Le règlement général sur la protection des données (RGPD)

Objectifs du Règlement (UE) 2016/679, en vigeur depuis le 25 Mai 2018

- "protection des personnes physiques à l'égard du traitement des données à caractère personnel"
- "protection des données à caractère personnel"
- "règles relatives à la libre circulation de ces données"

Structure

- 11 chapitres, 99 articles
- définit les "données à caractère personnel"
- fixe les droits des personnes, et les obligations de qui traite leur données
- fixe le cadre des autorités de contrôle

Nous allos explorer les notions clé dans une présentation préparée par Anne Combe, la Data Protection Officer d'Inria.

Les autorités de contrôle

La Commission Nationale Informatique et Liberté (CNIL)

- créé par la Loi n° 78-17 du 6 janvier 1978 (Loi Informatique et Liberté)
- avis systèmatique sur les nouvelles lois (Art. 8, 4.a)
- contrôle du respet du cadre legal des traitements touchant à des données à caractère personnel
  - automatisés
  - non automatisés mais aménant à constituer un fichier
- pouvoir de sanction (Art. 20 à 23)

à noter

- il n'y a plus de déclaration préalable de fichiers à la CNIL

Une remarque sur l'anonymisation

Est-ce facile d'anonymiser *vraiement* les données personnelles?

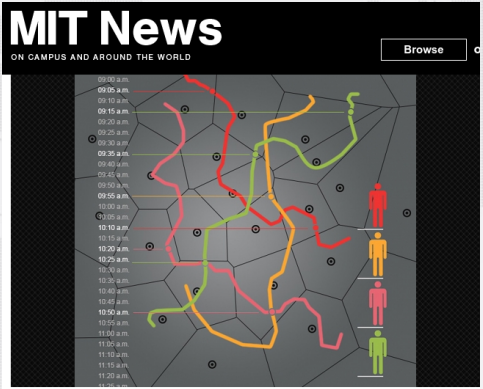

"you are identified by just 4 points, over a year"

Scientific Reports, 2013

La notion de *compliance*

Outline

La loi Lemaire

Répères

- loi n° 2016-1321 du 7 octobre 2016 pour une République numérique
- aussi connue comme "Loi Lemaire", de la Ministre Axelle Lemaire qui l'a portée
- voir le résumé dans le dossier de presse officiel

Structure

- Titre I: circulation des données et des savoirs (39 articles)
- Titre II: protection des droits dans la société numérique (29 articles)
- Titre III: accès au numérique (41 articles)

Eléments clé (séléction)

Transparence des algorithmes

Forts enjeux sociétaux (voir APB, Parcoursup, IA, etc.)

- De l'administration (Article 4)
- Des opérateurs économiques (Titre II)

Données Personnelles

- Protection des données personnelles (Titre II)
- Droit à la récuperation et à la portabilité de données (Titre II)

Internet (Titres II et III)

- neutralité
- très haut débit
- maintien de la connexion

Eléments clé (séléction)

Données publiques et d'intérêt général: ouverture par défaut (Titre I)

- documents administratifs (y compris les codes sources! Article 2)
- données d'intérêt générale (activités liées aux pouvoirs publiques)
  - cadastre
  - jugements
  - informations issues de la gestion d'un service public délégué (élécticité, gaz, ...)
- information scientifique: promotion de l'accès ouvert (Article 30)
- MOOCs

Outline

Une notion en dévénir

En Europe: Open Data Directive 2019 (art. 14): "high value dataset" qui doivent être

- *(a) available free of charge, subject to paragraphs 3, 4 and 5;*
- *(b) machine readable;*
- *(c) provided via APIs; and*
- *(d) provided as a bulk download, where relevant.*

il s'agit essentiellement de *données produites par des entités publiques*

En France, Rapport Bothorel, Décembre 2020 Section 5, données d'Intérêt Générale

- Données d'Intérêt Générale comme "donnée d'un acteur privé" dont la mise à disposition peut se justifier par un "motif d'intérêt général"
- Deux cas identifiés
  - Les données provenant du secteur privé mises à disposition des acteurs publics (B2G).
  - L'échange de données entre acteurs privés (B2B).

Pas de cadre normatif de référence pour le moment

Quelques exemples depuis les USA

Agences fédérales

Une oeuvre produite par (des employés de) une agence fédérale n'est pas couverte par le droit d'auteur (section 105 du Copyright Act), et est donc dans le domaine public.
Grâce à cela on a accès à:

- le code source de l'Apollo 11
- le CIA world factbook
- les données de l'USGS

Municipalités

Ouverture des données comme stratégie pour un meilleur service

- Trimet (~ RATP de Portland, OR, USA) fournit des APIs ouvertes aux dévéloppeurs depuis plus de dix ans, ce qui a conduit à des dizaines d'applications tierces spécialisées

Outline

Un apercu rapide

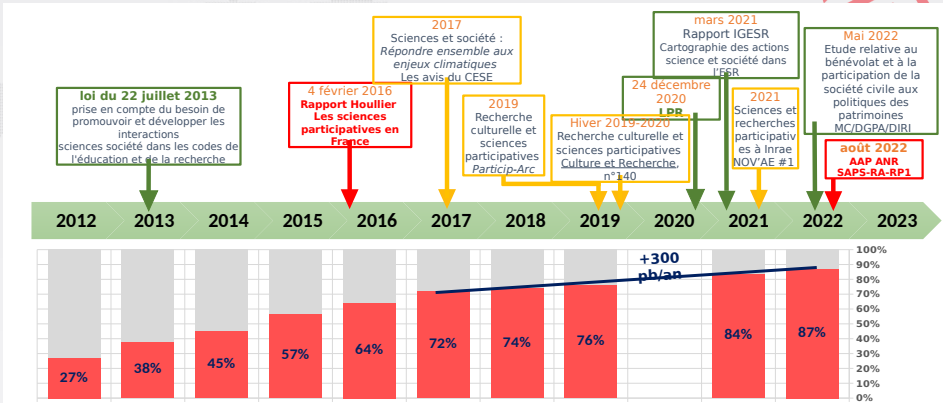

Taux d'équipement - smartphone

ARCEP - Enquête sur la diffusion des technologies de l'information et de la communication dans la société française en 2022
https://www.arcep.fr/cartes-et-donnees/nos-publications-chiffrees/barometre-du-numerique/le-barometre-du-numerique.html

Outline

Conclusion

Perte de l'innocence

l'Informatique *n'est plus* une science exempte d'impact sociétal:

- logiciel et algorithmes font partie du tissus constitutif de nos sociétés
- évolution massive des capacités de calcul, échange et stockage
- dématérialisation des données (en particulier personnelles)
- explosion du domaine d'application des décisions automatiques

Reflection sur l'éthique: ce qui est techniquement possible n'est pas forcément à faire

"move fast, break things" n'est plus un credo acceptable, meme pour les VC

Un cadre législatif qui se structure (et évolue!)

droit du logiciel (non traité dans ce cours); traitement des données personnelles; données publiques et d'intérêt générale; traitements algorithmiques

Ressources

Textes de loi et régléments

- Loi n° 78-17 du 6 janvier 1978 (Loi "informatique et liberté", actualisée en 2021)
- RGPD (règlement général sur la protection des données), 2016
- Loi pour une république numérique (Loi Lemaire), 2016
- Open Data Directive, 2019

Rapports

- rapport Trojette, 2013
- rapport Bothorel, 2020

Codes d'éthique

- code éthique de l'ACM
- principes d'Asilomar por l'IA

Organismes

- Commission nationale informatique et liberté (CNIL)
- Comité national d'éthique