

# API Hour!

Des outils à consommer sans modération pour  
augmenter le taux de full-texts dans HAL


Romain Boistel - Frédérique Bordignon  
Journées CasuHAL - 18 juin 2019



École des Ponts  
ParisTech

**casuHAL**  
club utilisateur

# Contexte général



ESPACE  
CHERCHEURS  
RESSOURCES  
& SERVICES

<https://espacechercheurs.enpc.fr>

## RESSOURCES

REVUES &  
EBOOKS

THESES &  
LITT. GRISE

BASES  
BIBLIO

PATRIMOINE

DONNÉES  
DE LA  
RECHERCHE



## SERVICES

ACCES DISTANT

GUIDES

AIDE A LA  
RECHERCHE

INFOS & TUTOS

TCHAT

LE LAB

# Contexte politique

---

- **Mandat** de l'École des Ponts (2017) pour [le partage de la science](#)
- Proposition d'un bonus Open Science au Conseil des labos (mars 2018)
- Décision finale : repérage des chercheurs mauvais élèves et mailing
- **Soutien** de la Direction de la Recherche
- Contexte (HCERES) propice ~~au dépôt~~ à la création de notices
- Nouvelle **campagne** en 2019

# Des outils et des APIs

## Sources des données



DOAJ



## Outils de traitement



Google Sheets

OU



Script en ligne de Philippe Gambette

## Outils pour le mailing



YAMM



École des Ponts  
ParisTech





# Étape 1

Identifier les full-texts qu'on veut récupérer

# Identifier ce qui est déjà en OA dans un corpus

*Ceinture-bretelles...*



# Filtrage, nettoyage

---

Sont considérés en OA tous les articles pour lesquels :

- sur la base du **DOI** :
  - Unpaywall renvoie une réponse positive sur l'article, ou sur la revue dans le DOAJ
  - HAL renvoie une réponse positive sur la présence d'un full-text ou si *LinkExtId* renvoie une réponse sauf si c'est Istex
- sur la base de la **revue** :
  - on trouve le titre ou l'ISSN de la revue dans l'export csv du DOAJ
- sur la base du **titre de l'article** :
  - on trouve s'ils sont en OA dans l'export de la collection ENPC (*fileMain* ou *linkExtId*)

Ultimes vérifications manuelles pour détecter certaines barrières mobiles, certains articles dont le titre existe en 2 langues, les articles qui n'ont pas de DOI etc...

# Fonctionnement d'une API

---

Plusieurs types d'API. Ici on utilise des API REST avec la méthode GET :

- Requête depuis la **barre d'adresse du navigateur** : une URL et des paramètres
- Uniquement pour récupérer des données, pas pour écrire dans une base de données
- Réponse du serveur dans de multiples formats possibles : csv, xml, json, html...
- Une API vient toujours avec une documentation : [HAL](#), [Unpaywall](#)...

[http://site.com/?requete=valeur1&champs\\_demands=valeur2&format\\_reponse=valeur3](http://site.com/?requete=valeur1&champs_demands=valeur2&format_reponse=valeur3)  
&authentication=email\_ou\_cle

Racine de l'URL

Paramètres

Limites fréquentes : nombre de requêtes / heure ; nombre de réponses / requête...

# Focus sur l'API d'Unpaywall

---

Documentation : <https://unpaywall.org/products/api>

- Réponse en JSON
- Champs utilisés par l'extracteur :  
**is\_oa ; journal\_is\_oa ; journal\_is\_in\_doaj ; best\_oa\_location/evidence**
- Autres infos disponibles : URL du PDF, couleur OA, informations bibliographiques...

Extension JSONView

Non-OA selon Unpaywall :

<https://api.unpaywall.org/v2/10.1007/s11401-012-0755-7?email=mail@mail.com>

OA selon Unpaywall :

<https://api.unpaywall.org/v2/10.1007/s40314-013-0076-9?email=mail@mail.com>

# Focus sur l'API de HAL

[https://api.archives-ouvertes.fr/search/?wt=csv&fq=docType\\_s:\(\"ART\"OR\"UNDEFINED\"\)&fq=collCode\\_s:\"ENPC\"&rows=10000&fq=producedDateY\\_i:\[2015 TO 2018\]&fl=halId\\_s,authLastNameFirstName\\_s,producedDateY\\_i,title\\_s,journalIssn\\_s,journalEissn\\_s,doId\\_s,journalTitle\\_s,docType\\_s,fileMain\\_s,labStructName\\_s,citationFull\\_s,linkExtId\\_s,linkExtUrl\\_s](https://api.archives-ouvertes.fr/search/?wt=csv&fq=docType_s:(\)

[Version JSON](#)   [Version XML](#)

<code>https://api.archives-ouvertes.fr/search/</code>	URL de l'API de HAL
<code>?wt=csv</code>	Format de retour csv
<code>&amp;fq=docType_s:(\"ART\"OR\"UNDEFINED\") &amp;fq=collCode_s:\"ENPC\" &amp;fq=producedDateY_i:[2015 TO 2018]</code>	Critères de requêtes <b>articles</b> ou <b>preprints</b> , <b>collection ENPC</b> , <b>2015 à 2018</b>
<code>&amp;rows=10000</code>	Limite de 30 résultats retournés par défaut
<code>&amp;fl=halId_s,fileMain_s,linkExtId_s,linkExtUrl_s,citationFull_s,authLastNameFirstName_s,producedDateY_i,title_s,journalIssn_s,journalEissn_s,doId_s,journalTitle_s,docType_s,labStructName_s</code>	Valeurs retournées <b>identifiant HAL</b> , <b>full-text sur HAL</b> , <b>OA externe</b> , <b>citation bibliographique</b>

# Pratique

## API HAL & API Unpaywall

Rendez-vous ici

pour les ressources nécessaires :

<http://bit.ly/tutocasuhal19>

(lien non pérenne, voir les pages de  
CasuHAL 2019  
pour accéder au document associé)

# Focus sur l'extracteur Unpaywall-HAL

---

- Script [ImportJSON](#) pour collecter proprement les données en JSON dans un **GoogleSheet**
- API d'Unpaywall (oaDOI) pour :
  - détecter s'il existe une version OA de l'article
  - détecter si la revue est dans le DOAJ
- API de HAL pour :
  - détecter les full-texts déjà présents dans HAL
  - collecter à nouveau les résultats d'Unpaywall mais via HAL
  - récupérer les *halId*



Quota de Google !

# Démo de l'extracteur Unpaywall - HAL

<http://bit.ly/ExtracteurUnpaywallHAL>

Faites une copie !

Passez à la pratique !

# Alternative

# Extracteur expérimental de P Gambette



<http://igm.univ-mlv.fr/~gambette/ExtractionHAL/ExtracteurUnpaywall/>

Passez à la pratique !

# Pratique

# Identifier ce qui est déjà en OA dans un corpus

*Ceinture-bretelles...*



# Interroger le DOAJ et sonder le corpus exporté de HAL

---

- Vérifier si la revue est dans le **DOAJ** (ISSN puis Titre)  
RechercheV dans Excel
- Vérifier s'il existe un dépôt dans l'export de **HAL** (DOI puis Titre)  
RechercheV dans Excel  
**Bonus** : Macro de “nettoyage” (retrait de la ponctuation)

# Warnings !



---



- Disparités entre Unpaywall pur et Unpaywall via HAL
- Disparités entre DOAJ et DOAJ selon Unpaywall
- DOIs qui contiennent des () et problèmes de casse
- Doublons dans HAL
- Dépôts hors collection exportée (+ mauvaise ou pas d'affiliation)

# Identifier ce qui est déjà en OA dans un corpus

*Ceinture-bretelles...*



## Étape 2

# Identifier les auteurs et campagne de mailing

# Retrouver ses auteurs

---

Les auteurs ne sont pas toujours dans l'annuaire de l'établissement → vérification avec [OCdHAL](#)

IDArt	Auteurs
Art1	Moisan, Lionel; Moulon, Pierre; Monasse, Pascal

## Corpus de travail

Nom	Prénom	Affiliation
Moulon	Pierre	LIGM
Monasse	Pascal	LIGM
Vandamme	Matthieu	NAVIER
Montel	Nathalie	LATTS

**OCdHAL**

# Retrouver ses auteurs

---

Les auteurs ne sont pas toujours dans l'annuaire de l'établissement → vérification avec [OCdHAL](#)

## 1. Split auteurs

IDArt	Auteurs
Art1	Moisan, Lionel;
	Moulon, Pierre;
	Monasse, Pascal

IDArt	IDAut	Auteurs
Art1	Aut1	Moisan, Lionel
Art1	Aut2	Moulon, Pierre
Art1	Aut3	Monasse, Pascal

Corpus de travail 

Nom	Prénom	Affiliation
Moulon	Pierre	LIGM
Monasse	Pascal	LIGM
Vandamme	Matthieu	NAVIER
Montel	Nathalie	LATTS

**OCdHAL**

# Retrouver ses auteurs

Les auteurs ne sont pas toujours dans l'annuaire de l'établissement → vérification avec [OCdHAL](#)

## 1. Split auteurs

IDArt	Auteurs
Art1	Moisan, Lionel;
	Moulon, Pierre;
	Monasse, Pascal

IDArt	IDAut	Auteurs
Art1	Aut1	Moisan, Lionel
Art1	Aut2	Moulon, Pierre
Art1	Aut3	Monasse, Pascal

## 2. Nettoyage auteurs

IDArt	IDAut	Auteurs	Auteurs clean
Art1	Aut1	Moisan, Lionel	MoisanL
Art1	Aut2	Moulon, Pierre	MoulonP
Art1	Aut3	Monasse, Pascal	MonasseP

Corpus de travail



## 1. Nettoyage auteurs

Nom	Prénom	Affiliation
Moulon	Pierre	LIGM
Monasse	Pascal	LIGM
Vandamme	Matthieu	NAVIER
Montel	Nathalie	LATTS

Nom	Prénom	Auteurs clean	Affiliation
Moulon	Pierre	MoulonP	LIGM
Monasse	Pascal	MonasseP	LIGM
Vandamme	Matthieu	VandammeM	NAVIER
Montel	Nathalie	MontelN	LATTS

OCdHAL



# Retrouver ses auteurs

Les auteurs ne sont pas toujours dans l'annuaire de l'établissement → vérification avec [OCdHAL](#)

## 1. Split auteurs

IDArt	Auteurs
	Moisan, Lionel;
Art1	Moulon, Pierre;
	Monasse, Pascal

IDArt	IDAut	Auteurs
Art1	Aut1	Moisan, Lionel
Art1	Aut2	Moulon, Pierre
Art1	Aut3	Monasse, Pascal

## 2. Nettoyage auteurs

IDArt	IDAut	Auteurs	Auteurs clean
Art1	Aut1	Moisan, Lionel	MoisanL
Art1	Aut2	Moulon, Pierre	MoulonP
Art1	Aut3	Monasse, Pascal	MonasseP

## 3. Correspondance d'affiliations

IDArt	IDAut	Auteurs	Auteurs clean	Affiliation
Art1	Aut1	Moisan, Lionel	MoisanL	
Art1	Aut2	Moulon, Pierre	MoulonP	LIGM
Art1	Aut3	Monasse, Pascal	MonasseP	LIGM


Corpus de travail



## 1. Nettoyage auteurs

Nom	Prénom	Affiliation
Moulon	Pierre	LIGM
Monasse	Pascal	LIGM
Vandamme	Matthieu	NAVIER
Montel	Nathalie	LATTS

Nom	Prénom	Auteurs clean	Affiliation
Moulon	Pierre	MoulonP	LIGM
Monasse	Pascal	MonasseP	LIGM
Vandamme	Matthieu	VandammeM	NAVIER
Montel	Nathalie	MontelN	LATTS



OCdHAL



# Trouver les adresses mails

---

IDArt	IDAut	Auteurs	Auteurs clean	Affiliation
Art1	Aut1	Moisan, Lionel	MoisanL	
Art1	Aut2	Moulon, Pierre	MoulonP	LIGM
Art1	Aut3	Monasse, Pascal	MonasseP	LIGM

## Corpus de travail

Nom	Prénom	Email
Argoul	Pierre	mail1@enpc.fr
Monasse	Pascal	mail2@enpc.fr
Caré	Sabine	mail3@enpc.fr
Château	Camille	mail4@enpc.fr

## Annuaire

# Trouver les adresses mails

---

IDArt	IDAut	Auteurs	Auteurs clean	Affiliation
Art1	Aut1	Moisan, Lionel	MoisanL	
Art1	Aut2	Moulon, Pierre	MoulonP	LIGM
Art1	Aut3	Monasse, Pascal	MonasseP	LIGM

## Corpus de travail

Nom	Prénom	Email
Argoul	Pierre	mail1@enpc.fr
Monasse	Pascal	mail2@enpc.fr
Caré	Sabine	mail3@enpc.fr
Château	Camille	mail4@enpc.fr

## 1. Nettoyage auteurs

Nom	Prénom	Auteurs clean	Email
Argoul	Pierre	ArgoulP	mail1@enpc.fr
Monasse	Pascal	MonasseP	mail2@enpc.fr
Caré	Sabine	CareS	mail3@enpc.fr
Château	Camille	ChateauC	mail4@enpc.fr

Annuaire



# Trouver les adresses mails

## 1. Correspondance d'emails

IDArt	IDAut	Auteurs	Auteurs clean	Affiliation
Art1	Aut1	Moisan, Lionel	MoisanL	
Art1	Aut2	Moulon, Pierre	MoulonP	LIGM
Art1	Aut3	Monasse, Pascal	MonasseP	LIGM

IDArt	IDAut	Auteurs	Auteurs clean	Affiliation	Email
Art1	Aut1	Moisan, Lionel	MoisanL		
Art1	Aut2	Moulon, Pierre	MoulonP	LIGM	
Art1	Aut3	Monasse, Pascal	MonasseP	LIGM	mail2@enpc.fr

Corpus de travail



## 1. Nettoyage auteurs

Nom	Prénom	Email
Argoul	Pierre	mail1@enpc.fr
Monasse	Pascal	mail2@enpc.fr
Caré	Sabine	mail3@enpc.fr
Château	Camille	mail4@enpc.fr

Nom	Prénom	Auteurs clean	Email
Argoul	Pierre	ArgoulP	mail1@enpc.fr
Monasse	Pascal	MonasseP	mail2@enpc.fr
Caré	Sabine	CareS	mail3@enpc.fr
Château	Camille	ChateauC	mail4@enpc.fr



Annuaire



# Campagne de mailing

Bonjour,

Suite à mon message du 10 mai dernier, je vous rappelle que vous pouvez partager le texte intégral pour 5 publication(s) dont vous êtes l'auteur ou le co-auteur. J'ai en effet repéré pour vous celle ou celles qui n'étaient pas encore en Open Access, cliquez ici pour procéder au dépôt dans HAL : [https://public.tableau.com/profile/bibdespnts#/vizhome/PartagePostprint2019/boost?idAut=aut92&linktarget=\\_blank](https://public.tableau.com/profile/bibdespnts#/vizhome/PartagePostprint2019/boost?idAut=aut92&linktarget=_blank)

**!! Cela ne concerne que la version postprint, autrement dit la version finale acceptée, celle qui ne contient pas la charte graphique de l'éditeur, son logo etc... mais dont le contenu est identique à la publication. !!**

Pour information :

En coordination avec la Direction de la Recherche et conformément au [Mandat pour le partage de la science](#) de l'École des Ponts, nous menons une campagne auprès des chercheurs afin de leur demander de partager le texte intégral pour un maximum de leurs publications. Comme l'année dernière, nous espérons que de nombreux dépôts seront faits sur HAL pour augmenter la visibilité de vos travaux et celle de votre laboratoire.

Depuis octobre 2016, la [Loi pour une République Numérique](#) vous protège et vous est très favorable, vous pouvez en effet réduire la durée de l'embargo à 6 mois pour les Sciences, Techniques et Médecine et à 12 mois pour les Sciences Humaines et Sociales.

Si vous rencontrez des difficultés, n'hésitez pas à me solliciter.

## Récupérer les citations complètes :

- API CrossRef


<https://api.crossref.org/works/10.5555/12345678/transform/text/x-bibliography>

- API HAL, valeur de citationFull\_s

## Une seule URL pour toutes les refs :

- Tableau Software
- ou Google Fusion

## Envoi des mails avec YAMM



Vous trouverez ci-dessous la ou les publi(s) dont vous êtes auteur et dont le postprint peut être déposé dans HAL.

**!! Cela ne concerne que la version postprint, autrement dit la version finale acceptée, celle qui ne contient pas la charte graphique de l'éditeur, son logo etc... mais dont le contenu est identique à la publication. !!**

N'hésitez pas à solliciter votre documentaliste référent pour de l'aide, mais lisez aussi les pages dédiées de l'Espace chercheurs :

- la [Loi pour une République Numérique](#)
- comment [appliquer un embargo](#)
- le [mandat de l'École pour le partage de la Science](#)
- comment [récupérer son postprint depuis la plateforme de l'éditeur](#)

Coulombel, N. (2018). Why housing and transport costs should always be considered together: A monocentric analysis of prudential measures in housing access. <i>Transport Policy</i> , 65, 89–105. doi:10.1016/j.tranpol.2017.04.011	
Coulombel, N., Boutueil, V., Liu, L., Vigié, V., & Yin, B. (2018). Substantial rebound effects in urban ridesharing: Simulating travel decisions in Paris, France. <i>Transportation Research Part D: Transport and Environment</i> . doi:10.1016/j.trd.2018.12.006	
Coulombel, N., Dablan, L., Gardrat, M., & Koning, M. (2018). The environmental social cost of urban road freight: Evidence from the Paris region. <i>Transportation Research Part D: Transport and Environment</i> , 63, 514–532. doi:10.1016/j.trd.2018.06.002	
Xiao, Y., Coulombel, N., & Palma, A. de. (2017). The valuation of travel time reliability: does congestion matter? <i>Transportation Research Part B: Methodological</i> , 97, 113–141. doi:10.1016/j.trb.2016.12.003	
Yin, B., Liu, L., Coulombel, N., & Vigié, V. (2018). Appraising the environmental benefits of ride-sharing: The Paris region case study. <i>Journal of Cleaner Production</i> , 177, 888–898. doi:10.1016/j.jclepro.2017.12.186	

# Après le mailing... le déluge !

---

- Suivi des dépôts dans HAL
- Démaquillage
- Assistance, voire dépôts

Bilan de cette *petite* opération

# Bilan chiffré 1 mois après le 1er mail

---


**+79 dépôts**

**Taux d'OA = 65%**

**à comparer aux 41% pour la production française,  
avec une méthodologie différente**

# Mesure de l'effet de la campagne

[Macro Google Sheet de Philippe Gambette](#)



# Bilan non-chiffré

---

- Montée en compétences sur de nombreux outils
- Contact avec les chercheurs (sensibilisation, pédagogie)
  
- ...et tout le plaisir d'avoir partagé ça avec vous !

# Boîte à outils complète...

---

- [Extracteur](#) Unpaywall - HAL (avec GSheets)
- [Extracteur](#) Unpaywall - HAL (en ligne)
- [OcdHAL](#)
  
- [YAMM](#) (outil de mailing)
- [3 macros utilitaires](#)
  - Splitter sur plusieurs lignes l'information d'une cellule qui contient plusieurs valeurs
  - Retirer les caractères de ponctuation des titres
  - Concaténer des noms d'auteurs

# Merci !

Romain Boistel



[romain.boistel@enpc.fr](mailto:romain.boistel@enpc.fr)



[@RomBoistel](https://twitter.com/RomBoistel)

Frédérique Bordignon



[frederique.bordignon@enpc.fr](mailto:frederique.bordignon@enpc.fr)



[@freddie2310](https://twitter.com/freddie2310)



<https://carnetist.hypotheses.org>