ISTEX

Construire et valoriser un corpus spécialisé à partir des ressources Istex

Présentation & démos

2 juin 2022

cnrs Inist Institut de l'information scientifique et technique

URFIST - Toulouse

Sabine Barreaux - Pascale Viot

Documents utiles

https://formation.lodex.fr/

Télécharger ce support et les fichiers utiles au TP

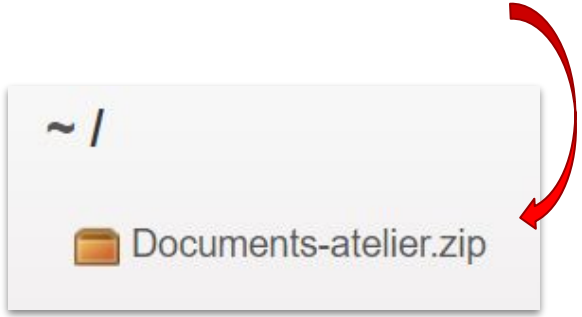

- Support de cours (.pdf)
- *Fichier Mémo*
- *Fichier texte (.txt)*
- *Modèle Lodex (.tar)*
- *Corpus compressé (.zip)*

1. **Enregistrer** le zip contenant les documents de travail : clic droit, puis **“enregistrer le lien** (la cible du lien) **sous”** → Bureau ou dossier créé
2. **Extraire** les fichiers : clic droit, puis **“extraire tout”** → Bureau ou dossier créé

Au programme

Constitution d'un corpus spécialisé à partir des ressources Istex

- Présentation de la base Istex
- Démos
  - Interrogation de la base avec **Istex-démo**
  - Téléchargement des résultats avec **Istex-DL**
  - Exploration du corpus **avec Lodex**
- TP - 1 : Exercices de constitution de corpus à partir d'un cas d'usage

MATIN

Valorisation d'un corpus spécialisé avec les services ISTEX

- TP - 2 : Exercices sur l'exploration du corpus avec **Lodex**
- Exemples de corpus prêts à l'emploi avec **Data.istex**

APRES-MIDI

Accès par le site Istex.fr

- Etablissements, Adhésion…
- Pourquoi Istex?
- Actualité
- La base Istex
- La fouille de textes
- Accès rapide aux services

1.

Présentation d’ISTEX

ISTEX
L'excellence documentaire pour tous

Initiative d'excellence en Information Scientifique et Technique

Construire le socle de la bibliothèque scientifique numérique nationale

ISTEX
L'excellence documentaire pour tous

« Construire le socle de la bibliothèque scientifique numérique nationale. »

- 2011 - 2018 : un projet créé dans le cadre des PIA
  (Programme d'investissement d'avenir)
- Depuis 2019 : un service pour l'ESR
  (Enseignement supérieur et recherche)
- **Depuis le 8 mars 2022 : Istex est inscrit dans la feuille de route nationale des infrastructures de recherche MESRI**
  (Ministère de l'Enseignement supérieur, de la recherche et de l'innovation)

ANR-10-IDEX-0004-02

Istex : quels objectifs ?

- Acquisition massive et centralisée d'archives scientifiques
  - Issue des Licences Nationales
  - Collections rétrospectives multilingues et multidisciplinaires
- Mise à disposition des données
  - Plateforme nationale (Inist)

ISTEX
L'excellence documentaire pour tous

« Construire le socle de la bibliothèque scientifique numérique nationale. »

INVESTISSEMENTS D'AVENIR

https://www.istex.fr

Mode d’accès

- Réservé à l’enseignement supérieur et la recherche
- Accessible par adhésion

356 établissements

Istex

Son contenu en quelques chiffres

25 605 682

C’est le nombre de documents présents dans Istex

32
Collections d’éditeurs

Chiffres du 28/04/2022

9 318
Revues

349 009
Monographies

Les principaux éditeurs scientifiques

Elsevier, Wiley et Springer journals totalisent 69%

6 éditeurs spécialisés en SHS représentent 1.5% (mais disciplines également présentes chez d'autres éditeurs)

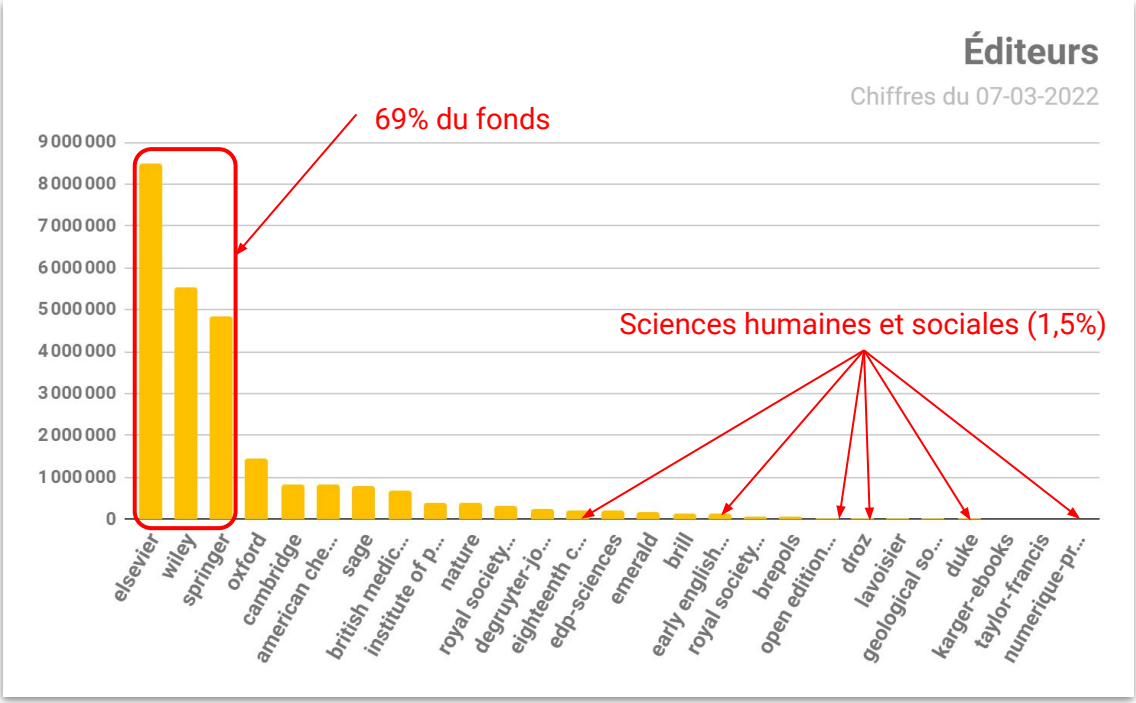

Les plus grandes revues scientifiques

Dans le fonds de plus de **9 000** revues présentes dans Istex :

liste des **20** revues les plus importantes en **nombre de documents**

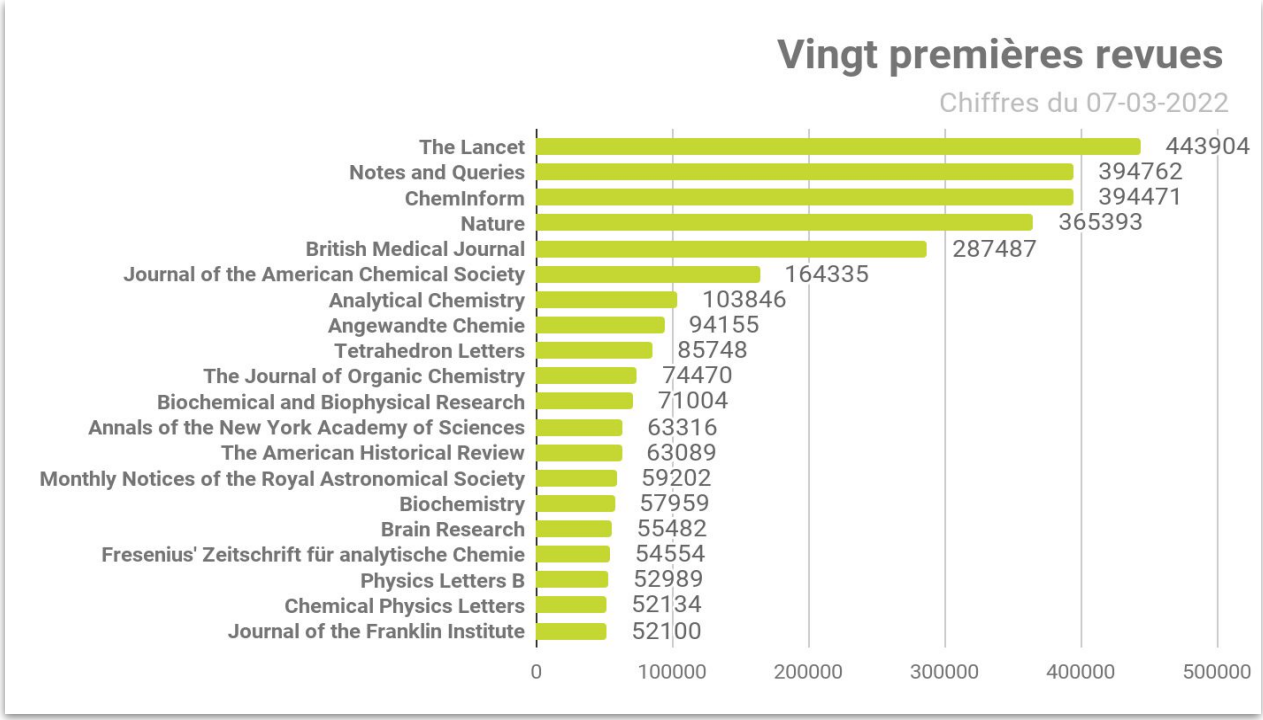

Tous les domaines scientifiques

64 % font partie des **sciences physiques ou de la santé**

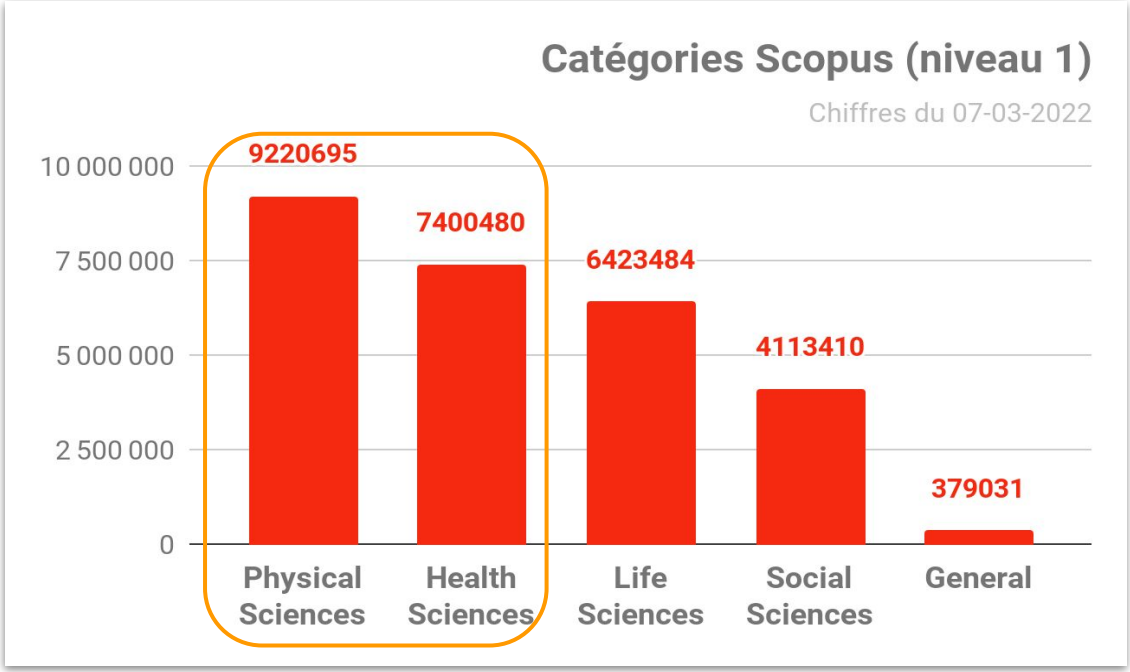

700 ans de publications

Du 15e au 21e siècle

96% des documents publiés entre 1900 et aujourd'hui (2020)

89% des documents publiés depuis 1950

58% des documents publiés sur les 30 dernières années

4% des documents publiés avant 1900

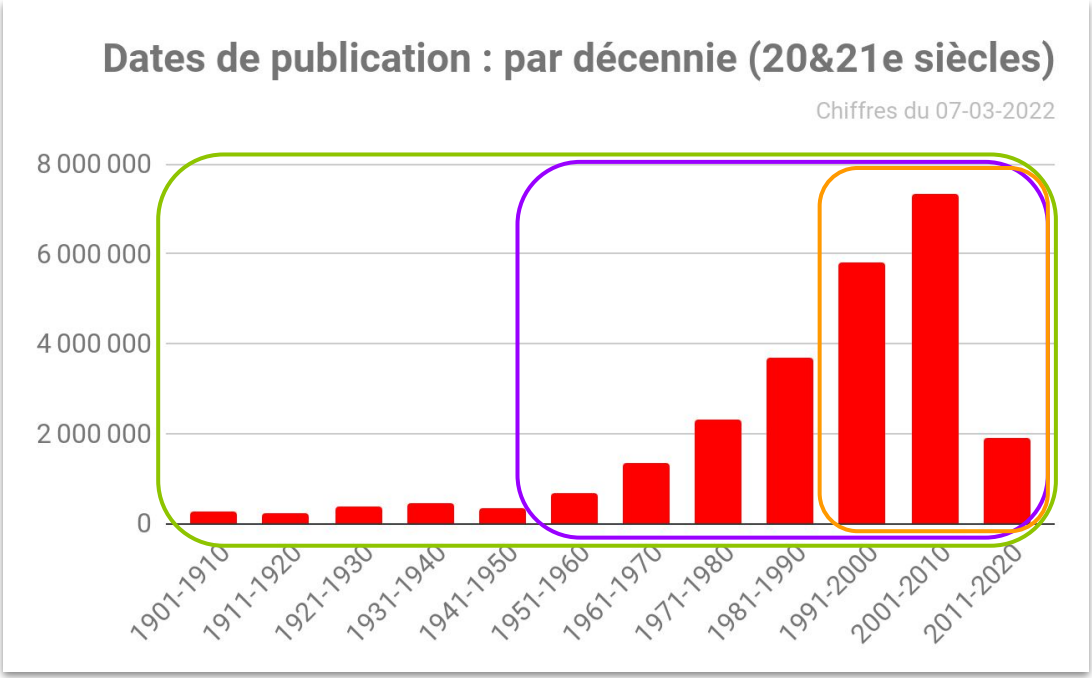

Polyglotte : 52 langues !

Anglais majoritaire

0,3% = 48 autres langues

Information non renseignée par les éditeurs pour près de 1 million de documents !

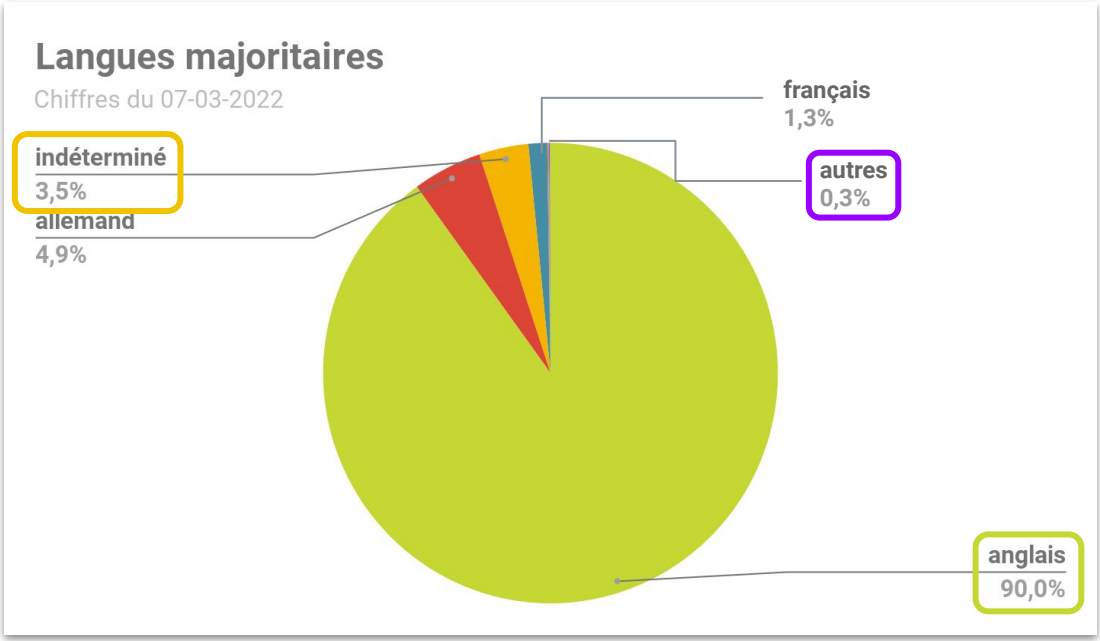

lstex

Pour quel usage ?

2 types d’usage

Usage documentaire

Un document

VS

Usage TDM (Text and data mining)

un corpus de documents

Usage TDM- Pour quoi faire?

Définition :
“directive sur le droit d’auteur”

« Toute technique d'analyse automatisée visant à analyser des textes et des données sous une forme numérique afin d'en dégager des informations, ce qui comprend, à titre non exhaustif, des constantes, des tendances et des corrélations »

(ordonnance du 24 novembre 2021) Source : ouvrirlascience.fr

Le TDM c’est :

- Extraire de l’information pertinente
- Répondre à une question (recherche d’information)
- Analyser de gros volumes de textes
- Détecter des sentiments dans les textes (e-reputation…)
- Construire des résumés automatiques
- Désambiguïser des lieux, des personnes…
- Faire des systèmes des recommandations
- Détecter des « fake news »
- Trier des mails, des textes
- Faire de la bibliométrie
- …

Une plateforme

Enrichissement

1. Usage documentaire

- api.istex.fr
- Bouton
- Google Scholar
- Outils Biblio.

2. Usage TDM

data.istex.fr

dl.istex.fr

corpus.istex.fr

Gargantext, Cortext, Iramuteq ...

Focus sur la chaîne de traitements

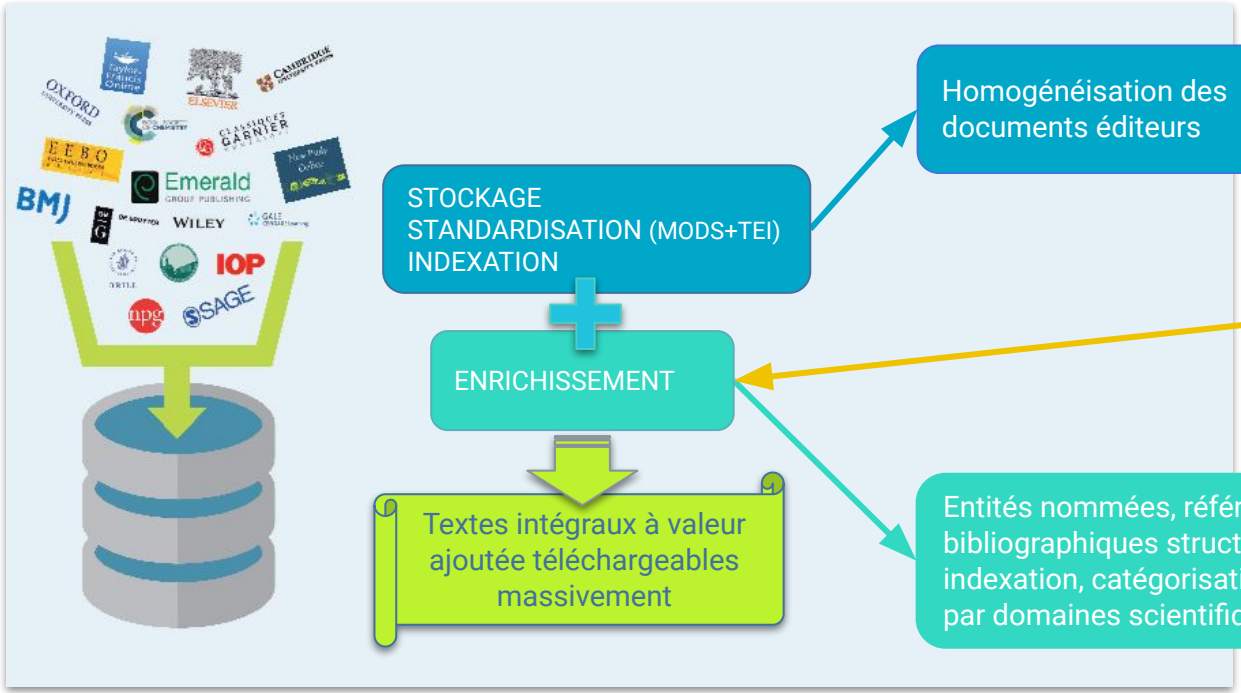

(ré) Océrisation

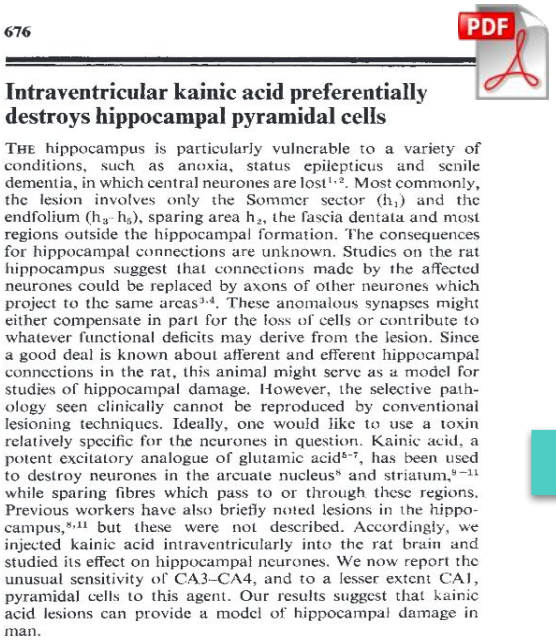

676

Intraventricular kainic acid preferentially destroys hippocampal pyramidal cells

THE hippocampus is particularly vulnerable to a variety of conditions, such as anoxia, status epilepticus and senile dementia, in which central neurones are lost[1,2]. Most commonly, the lesion involves only the Sommer sector (h_1) and the endfolium (h_3–h_5), sparing area h_2, the fascia dentata and most regions outside the hippocampal formation. The consequences for hippocampal connections are unknown. Studies on the rat hippocampus suggest that connections made by the affected neurones could be replaced by axons of other neurones which project to the same areas[3,4]. These anomalous synapses might either compensate in part for the loss of cells or contribute to whatever functional deficits may derive from the lesion. Since a good deal is known about afferent and efferent hippocampal connections in the rat, this animal might serve as a model for studies of hippocampal damage. However, the selective pathology seen clinically cannot be reproduced by conventional lesioning techniques. Ideally, one would like to use a toxin relatively specific for the neurones in question. Kainic acid, a potent excitatory analogue of glutamic acid[5–7], has been used to destroy neurones in the arcuate nucleus[8] and striatum,[9–11] while sparing fibres which pass to or through these regions. Previous workers have also briefly noted lesions in the hippocampus,[8,11] but these were not described. Accordingly, we injected kainic acid intraventricularly into the rat brain and studied its effect on hippocampal neurones. We now report the unusual sensitivity of CA3–CA4, and to a lesser extent CA1, pyramidal cells to this agent. Our results suggest that kainic acid lesions can provide a model of hippocampal damage in man.

OCR

```
676

_ I

Intraventricular kainic acid preferentially
destroys hippocampal pyramidal cells

THE hippocampus is particularly vulnerable to a variety of
conditions, such as anoxia, status epilepticus and senile
dementia, in which central neurones are lostl'z. Most commonly,
the lesion involves only the Sommer sector (h) and the
endfolium (h3wh5), sparing area h,, the fascia dentata and most
regions outside the hippocampal formation. The consequences
for hippocampal connections are unknown. Studies on the rat
hippocampus suggest that connections made by the affected
neurones could be replaced by axons of other neurones which
project to the same areasa'4. These anomalous synapses might
either compensate in part for the loss of cells or contribute to
whatever functional deficits may derive from the lesion. Since
a good deal is known about afferent and efferent hippocampal
connections in the rat, this animal might serve as a model for
studies of hippocampal damage. However, the selective path-
ology seen clinically cannot be reproduced by conventional
lesioning techniques. Ideally, one would like to use a toxin
relatively specific for the neurones in question. Kainic acid, a
potent excitatory analogue of glutamic acid", has been used
to destroy neurones in the arcuate nucleus8 and striatumf"ll
while sparing fibres which pass to or through these regions.
Previous workers have also briefly noted lesions in the hippo-
campusf"11 but these were not described. Accordingly, we
injected kainic acid intraventricularly into the rat brain and
studied its effect on hippocampal neurones. We now report the
unusual sensitivity of CA3—CA4, and to a lesser extent CA1,
pyramidal cells to this agent. Our results suggest that kainic
acid lesions can provide a model of hippocampal damage in
man.
```

Caractérisation des textes

- Score de qualité
- Qualité des PDF
- Nombre de mots
- Présence et type d'enrichissements

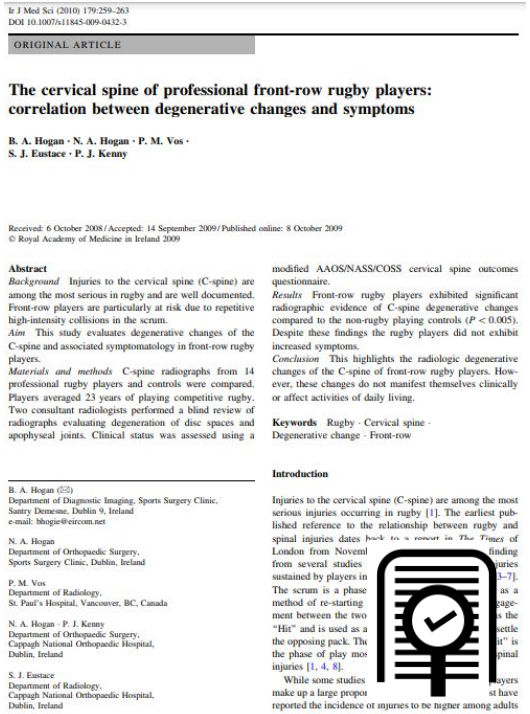

Ir J Med Sci (2010) 179:259–263
DOI 10.1007/s11845-009-0432-3

ORIGINAL ARTICLE

The cervical spine of professional front-row rugby players: correlation between degenerative changes and symptoms

B. A. Hogan · N. A. Hogan · P. M. Vos · S. J. Eustace · P. J. Kenny

Received: 6 October 2008 / Accepted: 14 September 2009 / Published online: 8 October 2009
© Royal Academy of Medicine in Ireland 2009

Abstract
Background Injuries to the cervical spine (C-spine) are among the most serious in rugby and are well documented. Front-row players are particularly at risk due to repetitive high-intensity collisions in the scrum.
Aim This study evaluates degenerative changes of the C-spine and associated symptomatology in front-row rugby players.
Materials and methods C-spine radiographs from 14 professional rugby players and controls were compared. Players averaged 23 years of playing competitive rugby. Two consultant radiologists performed a blind review of radiographs evaluating degeneration of disc spaces and apophyseal joints. Clinical status was assessed using a modified AAOS/NASS/COSS cervical spine outcomes questionnaire.
Results Front-row rugby players exhibited significant radiographic evidence of C-spine degenerative changes compared to the non-rugby playing controls ($P < 0.005$). Despite these findings the rugby players did not exhibit increased symptoms.
Conclusion This highlights the radiologic degenerative changes of the C-spine of front-row rugby players. However, these changes do not manifest themselves clinically or affect activities of daily living.

Keywords Rugby · Cervical spine · Degenerative change · Front-row

B. A. Hogan (✉)
Department of Diagnostic Imaging, Sports Surgery Clinic, Santry Demesne, Dublin 9, Ireland
e-mail: bhogie@eircom.net

N. A. Hogan
Department of Orthopaedic Surgery, Sports Surgery Clinic, Dublin, Ireland

P. M. Vos
Department of Radiology, St. Paul's Hospital, Vancouver, BC, Canada

N. A. Hogan · P. J. Kenny
Department of Orthopaedic Surgery, Cappagh National Orthopaedic Hospital, Dublin, Ireland

S. J. Eustace
Department of Radiology, Cappagh National Orthopaedic Hospital, Dublin, Ireland

Introduction

Injuries to the cervical spine (C-spine) are among the most serious injuries occurring in rugby [1]. The earliest published reference to the relationship between rugby and spinal injuries dates back to a report in *The Times* of London from Novem finding from several studies juries sustained by players in 3–7]. The scrum is a phase as a method of re-starting gage- ment between the two s the "Hit" and is used as a settle the opposing pack. Th it" is the phase of play mos spinal injuries [1, 4, 8].

While some studies layers make up a large propo st have reported the incidence of injuries to be higher among adults

Structuration des PDF

Identifier le titre, le résumé, le corps du texte

GROBID : 49,6 %

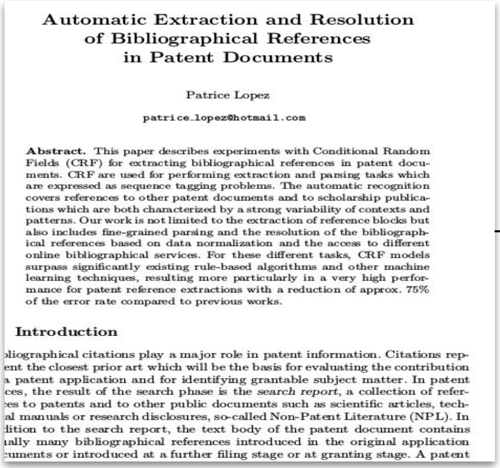

Automatic Extraction and Resolution
of Bibliographical References
in Patent Documents

Patrice Lopez

patrice_lopez@hotmail.com

Abstract. This paper describes experiments with Conditional Random Fields (CRF) for extracting bibliographical references in patent documents. CRF are used for performing extraction and parsing tasks which are expressed as sequence tagging problems. The automatic recognition covers references to other patent documents and to scholarship publications which are both characterized by a strong variability of contexts and patterns. Our work is not limited to the extraction of reference blocks but also includes fine-grained parsing and the resolution of the bibliographical references based on data normalization and the access to different online bibliographical services. For these different tasks, CRF models surpass significantly existing rule-based algorithms and other machine learning techniques, resulting more particularly in a very high performance for patent reference extractions with a reduction of approx. 75% of the error rate compared to previous works.

Introduction

bliographical citations play a major role in patent information. Citations represent the closest prior art which will be the basis for evaluating the contribution a patent application and for identifying grantable subject matter. In patent ces, the result of the search phase is the *search report*, a collection of refer-es to patents and to other public documents such as scientific articles, tech-al manuals or research disclosures, so-called Non-Patent Literature (NPL). In dition to the search report, the text body of the patent document contains ually many bibliographical references introduced in the original application cuments or introduced at a further filing stage or at granting stage. A patent

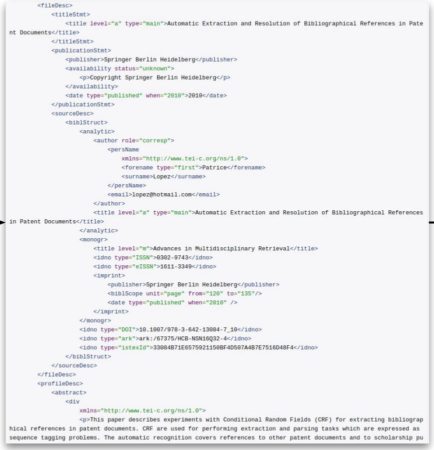


```
<fileDesc>
    <titleStmt>
        <title level="a" type="main">Automatic Extraction and Resolution of Bibliographical References in Pate
nt Documents</title>
    </titleStmt>
    <publicationStmt>
        <publisher>Springer Berlin Heidelberg</publisher>
        <availability status="unknown">
            <p>Copyright Springer Berlin Heidelberg</p>
        </availability>
        <date type="published" when="2010">2010</date>
    </publicationStmt>
    <sourceDesc>
        <biblStruct>
            <analytic>
                <author role="corresp">
                    <persName
                        xmlns="http://www.tei-c.org/ns/1.0">
                        <forename type="first">Patrice</forename>
                        <surname>Lopez</surname>
                    </persName>
                    <email>lopez@hotmail.com</email>
                </author>
                <title level="a" type="main">Automatic Extraction and Resolution of Bibliographical References
in Patent Documents</title>
            </analytic>
            <monogr>
                <title level="m">Advances in Multidisciplinary Retrieval</title>
                <idno type="ISSN">0302-9743</idno>
                <idno type="eISSN">1611-3349</idno>
                <imprint>
                    <publisher>Springer Berlin Heidelberg</publisher>
                    <biblScope unit="page" from="120" to="135"/>
                    <date type="published" when="2010" />
                </imprint>
            </monogr>
            <idno type="DOI">10.1007/978-3-642-13084-7_10</idno>
            <idno type="ark">ark:/67375/HCB-NSN16Q32-4</idno>
            <idno type="istexId">33084B71E6575921150BF4D507A4B7E7516D48F4</idno>
        </biblStruct>
    </sourceDesc>
</fileDesc>
<profileDesc>
    <abstract>
        <div
            xmlns="http://www.tei-c.org/ns/1.0">
            <p>This paper describes experiments with Conditional Random Fields (CRF) for extracting bibliograp
hical references in patent documents. CRF are used for performing extraction and parsing tasks which are expressed as
sequence tagging problems. The automatic recognition covers references to other patent documents and to scholarship pu
```


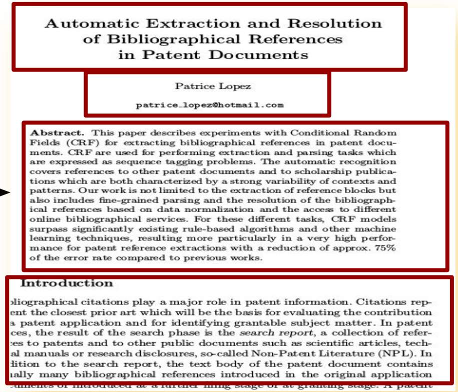

Automatic Extraction and Resolution
of Bibliographical References
in Patent Documents

Patrice Lopez

patrice_lopez@hotmail.com

Abstract. This paper describes experiments with Conditional Random Fields (CRF) for extracting bibliographical references in patent documents. CRF are used for performing extraction and parsing tasks which are expressed as sequence tagging problems. The automatic recognition covers references to other patent documents and to scholarship publications which are both characterized by a strong variability of contexts and patterns. Our work is not limited to the extraction of reference blocks but also includes fine-grained parsing and the resolution of the bibliographical references based on data normalization and the access to different online bibliographical services. For these different tasks, CRF models surpass significantly existing rule-based algorithms and other machine learning techniques, resulting more particularly in a very high performance for patent reference extractions with a reduction of approx. 75% of the error rate compared to previous works.

Introduction

bliographical citations play a major role in patent information. Citations represent the closest prior art which will be the basis for evaluating the contribution a patent application and for identifying grantable subject matter. In patent ces, the result of the search phase is the *search report*, a collection of refer-es to patents and to other public documents such as scientific articles, tech-al manuals or research disclosures, so-called Non-Patent Literature (NPL). In dition to the search report, the text body of the patent document contains ually many bibliographical references introduced in the original application

Extraction des références bib.

Détecter et structurer les références bibliographiques des articles en XML TEI

GROBID : 41,6 %

References

1. Lopez, P., Romary, L.: Multiple retrieval models and regression models for prior art search. In: CLEF 2009 Workshop, Technical Notes, Corfu, Greece (2009)
2. Nakov, P., Schwartz, A., Hearst, M.: Citances: Citation sentences for semantic

```
<biblStruct xml:id="b0" resp="#ISTEX-API" change="#refBibs-istex">
  <analytic>
    <title level="a" type="main">
      Multiple retrieval models and regression models for prior art search
    </title>
    <author>
      <persName>
        <forename type="first">P</forename>
        <surname>Lopez</surname>
      </persName>
    </author>
    <author>
      <persName>
        <forename type="first">L</forename>
        <surname>Romary</surname>
      </persName>
    </author>
  </analytic>
  <monogr>
    <title level="m">CLEF 2009 Workshop</title>
    <meeting>
      <address>
        <addrLine>Corfu, Greece</addrLine>
      </address>
    </meeting>
    <imprint>
      <date type="published" when="2009"/>
    </imprint>
  </monogr>
</biblStruct>
```

Catégorisation des documents

- Par appariement :
  WoS
  Scopus
  Science Metrix
- Par apprentissage automatique :
  Classification Pascal/Francis

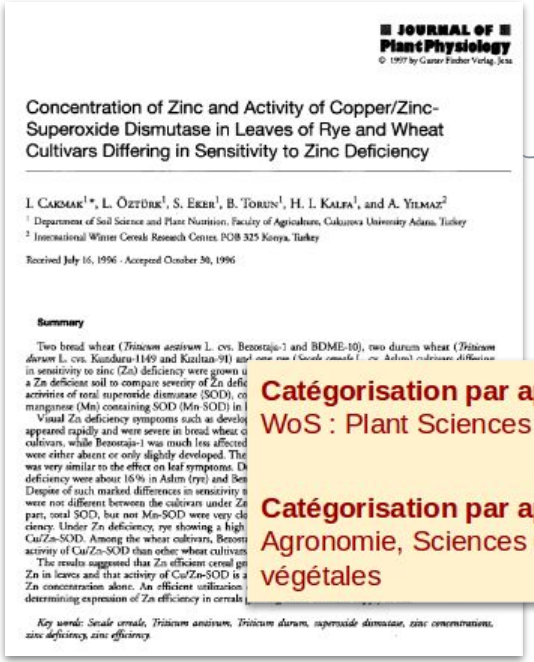
JOURNAL OF Plant Physiology

Concentration of Zinc and Activity of Copper/Zinc-Superoxide Dismutase in Leaves of Rye and Wheat Cultivars Differing in Sensitivity to Zinc Deficiency

I. Cakmak[1]*, L. Öztürk[1], S. Eker[1], B. Torun[1], H. I. Kalfa[1], and A. Yilmaz[2]

[1] Department of Soil Science and Plant Nutrition, Faculty of Agriculture, Cukurova University Adana, Turkey
[2] International Winter Cereals Research Center, POB 325 Konya, Turkey

Received July 16, 1996 · Accepted October 30, 1996

Summary

Two bread wheat (*Triticum aestivum* L. cvs. Bezostaja-1 and BDME-10), two durum wheat (*Triticum durum* L. cvs. Kunduru-1149 and Kiziltan-91) and one rye (Secale cereale L. cv. Aslan) cultivars differing in sensitivity to zinc (Zn) deficiency were grown in a Zn deficient soil to compare severity of Zn defi activities of total superoxide dismutase (SOD), co manganese (Mn) containing SOD (Mn-SOD) in Visual Zn deficiency symptoms such as develo appeared rapidly and were severe in bread wheat c cultivars, while Bezostaja-1 was much less affected were either absent or only slightly developed. The was very similar to the effect on leaf symptoms. D deficiency were about 16% in Aslan (rye) and Be Despite of such marked differences in sensitivity were not different between the cultivars under Zn part, total SOD, but not Mn-SOD were very cle ciency. Under Zn deficiency, rye showing a high Cu/Zn-SOD. Among the wheat cultivars, Bezosta activity of Cu/Zn-SOD than other wheat cultivars The results suggested that Zn efficient cereal ge Zn in leaves and that activity of Cu/Zn-SOD is a Zn concentration alone. An efficient utilization determining expression of Zn efficiency in cereals

Key words: Secale cereale, *Triticum aestivum*, *Triticum durum*, superoxide dismutase, zinc concentrations, zinc deficiency, zinc efficiency.

Catégorisation par appariement
WoS : Plant Sciences

Catégorisation par apprentissage
Agronomie, Sciences du sol et productions végétales

MULTICAT : 76,9 %
Bayésien naïf : 48,2 %

Indexation automatique

Extraire du texte les termes les plus représentatifs du contenu quel que soit le domaine scientifique

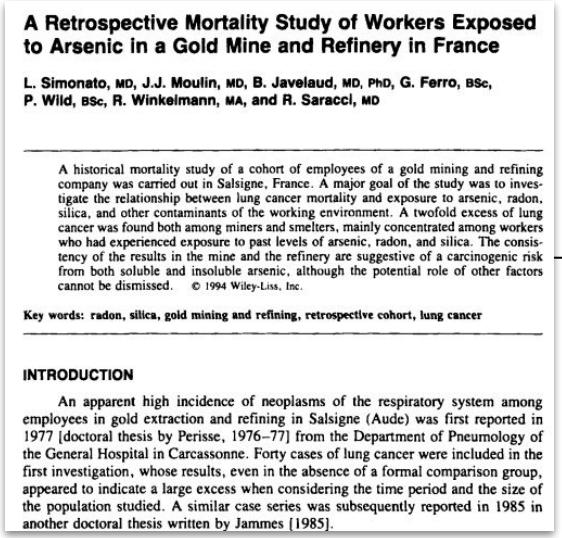

A Retrospective Mortality Study of Workers Exposed to Arsenic in a Gold Mine and Refinery in France

L. Simonato, MD, J.J. Moulin, MD, B. Javelaud, MD, PhD, G. Ferro, BSc, P. Wild, BSc, R. Winkelmann, MA, and R. Saracci, MD

A historical mortality study of a cohort of employees of a gold mining and refining company was carried out in Salsigne, France. A major goal of the study was to investigate the relationship between lung cancer mortality and exposure to arsenic, radon, silica, and other contaminants of the working environment. A twofold excess of lung cancer was found both among miners and smelters, mainly concentrated among workers who had experienced exposure to past levels of arsenic, radon, and silica. The consistency of the results in the mine and the refinery are suggestive of a carcinogenic risk from both soluble and insoluble arsenic, although the potential role of other factors cannot be dismissed. © 1994 Wiley-Liss, Inc.

Key words: radon, silica, gold mining and refining, retrospective cohort, lung cancer

INTRODUCTION

An apparent high incidence of neoplasms of the respiratory system among employees in gold extraction and refining in Salsigne (Aude) was first reported in 1977 [doctoral thesis by Perisse, 1976–77] from the Department of Pneumology of the General Hospital in Carcassonne. Forty cases of lung cancer were included in the first investigation, whose results, even in the absence of a formal comparison group, appeared to indicate a large excess when considering the time period and the size of the population studied. A similar case series was subsequently reported in 1985 in another doctoral thesis written by Jammes [1985].

```
▼<listAnnotation type="rd-teeft">
 ▼<annotationBlock corresp="text" xmls="https//www.tei-c.org/ns/1.0">
  ▼<keywords change="#istex-rd" resp="#istex-rd">
   ▼<term>
     <term>lung cancer</term>
    ▼<fs type="statistics">
     ▼<f name="frequency">
       <numeric value="17"/>
      </f>
     ▼<f name="specificity">
       <numeric value="1"/>
      </f>
     </fs>
    </term>
   ▼<term>
     <term>radon</term>
    ▼<fs type="statistics">
     ▼<f name="frequency">
       <numeric value="14"/>
      </f>
     ▼<f name="specificity">
       <numeric value="0.823529411764706"/>
      </f>
     </fs>
    </term>
```

- Lung Cancer
- Cohort
- Arsenic
- Miner
- Refinery
- Salsigne
- Diesel exhaust
- First exposure

TEEFT : 84,1 %

Détection des entités nommées

9 types d'entités :

- Personnes
- Lieux
- Organisations
- Projets financés
- Organisme financeur
- Hébergeur de ressources
- URL
- Dates
- Citations

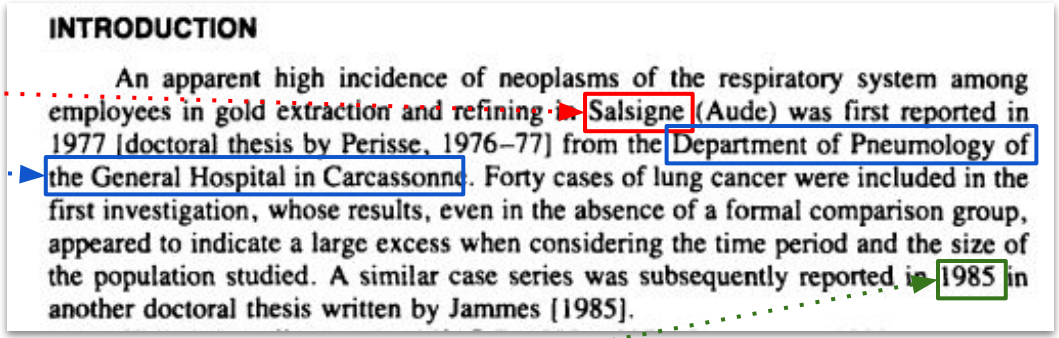

INTRODUCTION

An apparent high incidence of neoplasms of the respiratory system among employees in gold extraction and refining in Salsigne (Aude) was first reported in 1977 [doctoral thesis by Perisse, 1976–77] from the Department of Pneumology of the General Hospital in Carcassonne. Forty cases of lung cancer were included in the first investigation, whose results, even in the absence of a formal comparison group, appeared to indicate a large excess when considering the time period and the size of the population studied. A similar case series was subsequently reported in 1985 in another doctoral thesis written by Jammes [1985].

UNITEX : 67,5 %

Istex

Ses atouts pour le TDM

ISTEX

Des données et des services compatibles pour le TDM

Des données **accessibles**
➽ un seul lieu pour de nombreuses sources

Des données **interopérables**
Formats homogénéisés et données corrigées
➽ **moins de prétraitements**

Des données **enrichies**
Réocérisation / structuration de texte / métadonnées
➽ **des documents retrouvés et analysés plus facilement**

Des millions de textes et de métadonnées **téléchargeables** en 3 clics

Des **connexions** vers des outils / plateformes du monde académique

À venir

Un **cadre juridique** sécurisé par une licence appropriée et déjà négociée

TDM en toute indépendance

Istex

Une évolution constante

Alimentation du fonds

- De nouvelles collections d'éditeurs en prévision
  - E-books, revues, documents patrimoniaux en Sciences humaines et sociales
- Augmentation de la couverture temporelle
  - Elsevier (2002 à 2008, puis 2009 à 2012)
  - EDP Sciences (2019 à 2021)

2.

Constitution d’un corpus spécialisé

À partir d’un cas d’usage

“Je cherche à découvrir l’héritage musical de Beethoven à travers la littérature scientifique”

Méthodologie

- Constituer un corpus de publications sur le compositeur Beethoven

- L'affiner au moyen d'outils propres à Istex en vue d'une exploitation TDM

Stratégie itérative : 3 outils

3 Outils

API Istex

ISTEX

Interrogation
& Exploration

Stratégie itérative : 3 outils

3 Outils

API Istex

ISTEX

Interrogation
& Exploration

ISTEX-DL

Extraction

Stratégie itérative : 3 outils

3 Outils

Lodex

Visualisation
& Exploration

API Istex

ISTEX

Interrogation
& Exploration

Istex-DL

Extraction

Stratégie itérative : 2 phases

Phase 1

Pertinence scientifique

Corpus Ludwig v0

Phase 2

Exploitabilité en TDM

Corpus Ludwig v1

Stratégie

Phase 1 : Pertinence scientifique

2.1

Construction d’une requête

… avec le démonstrateur ISTEX

Le démonstrateur

L’outil

Le démonstrateur

Interface à **vocation pédagogique** branchée sur l'API Istex qui permet de :

- Construire sa requête (en mode simple ou avancé)
- Visualiser et filtrer les résultats

https://demo.istex.fr

Le démonstrateur

Les formats disponibles pour le texte intégral, les métadonnées décrivant le document et les annexes/couvertures

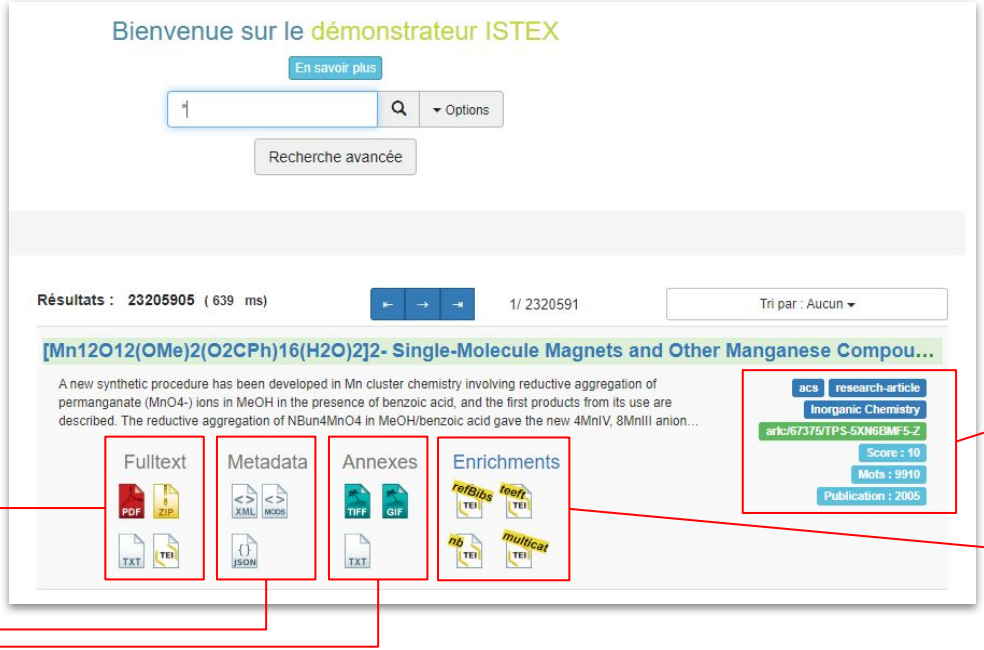

Accès rapide à différentes infos bibliographiques du document

Les différents types d'enrichissements disponibles en TEI

Le démonstrateur

Facettes pré-définies dans l'interface

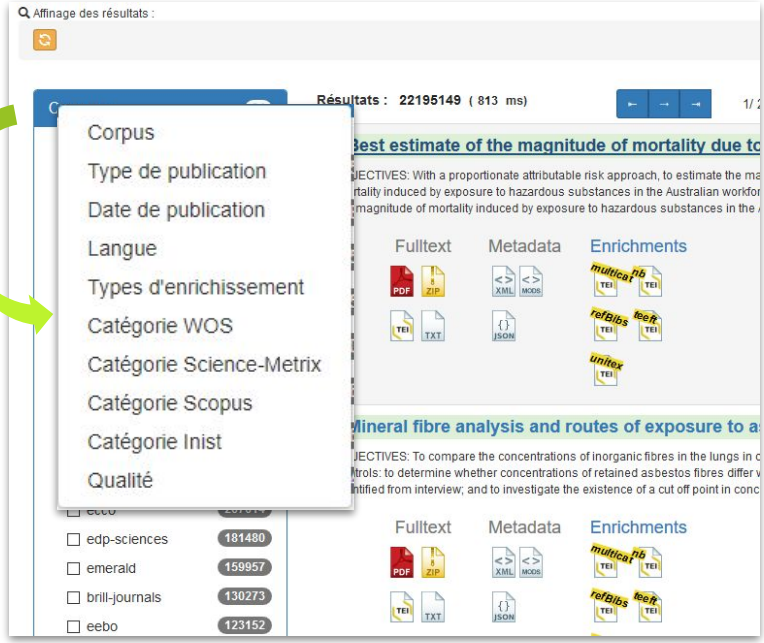

⟶ donne une vision synthétique du corpus

⟶ permet de filtrer les résultats de la requête

⟶ mais possibilités limitées - exploratoire

Le démonstrateur

Le démonstrateur

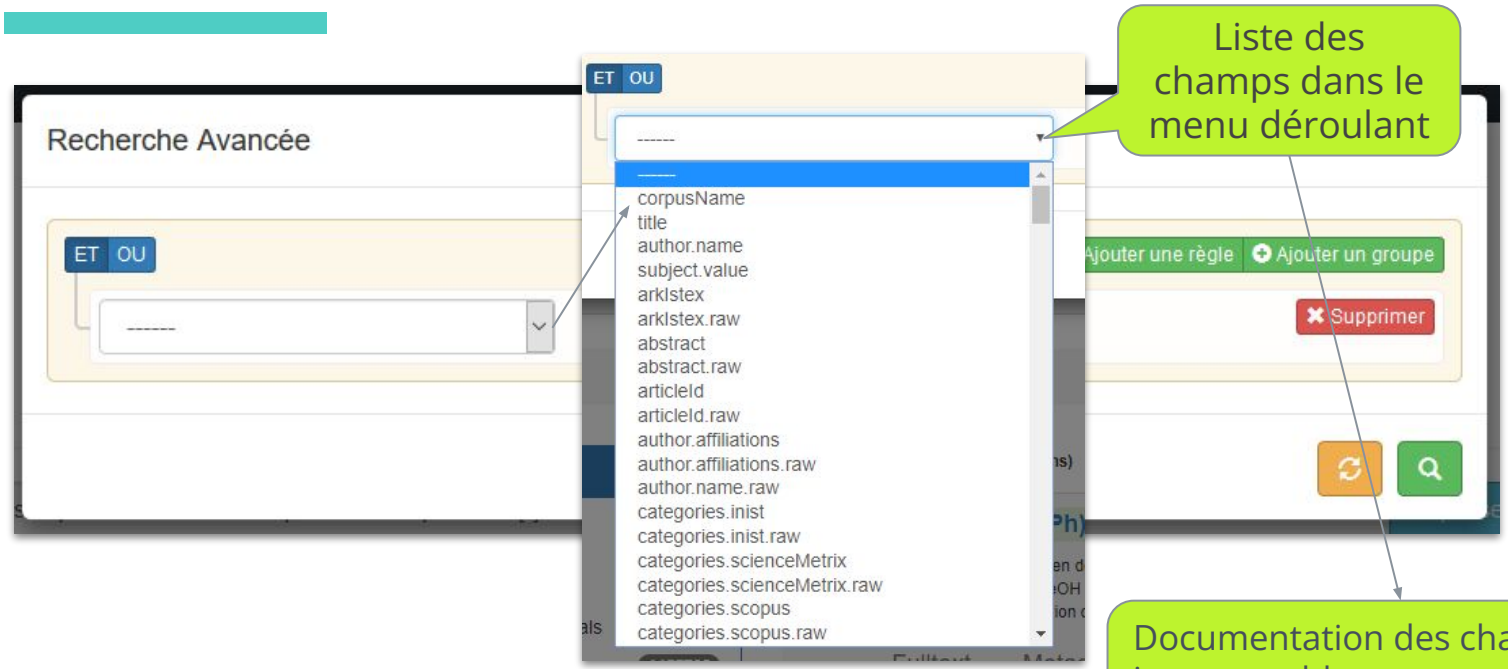

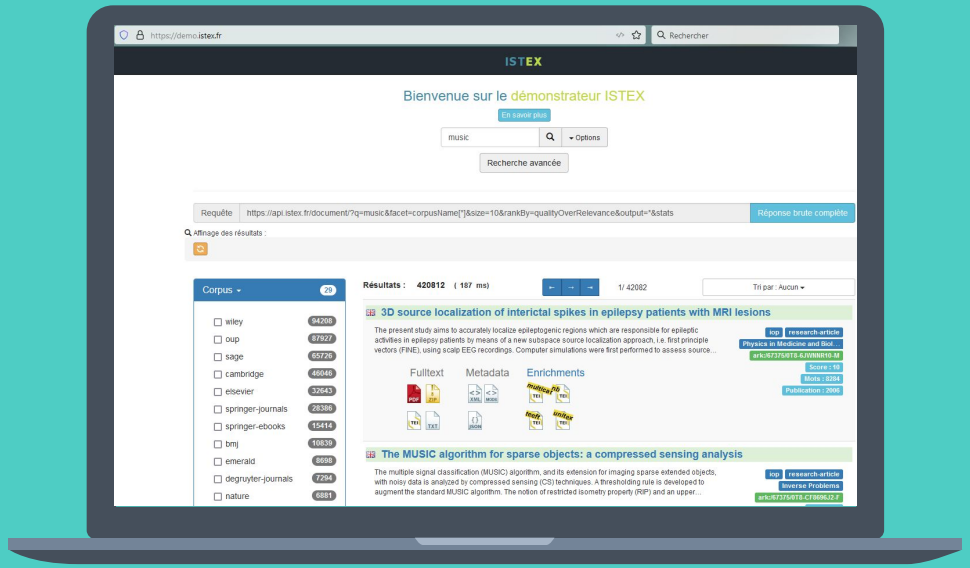

Objectif pédagogique

Écrire une équation, testée pas à pas, utilisant un certain nombre d'opérateurs, d'astuces et de syntaxes, pour délimiter un corpus pertinent et de taille raisonnable

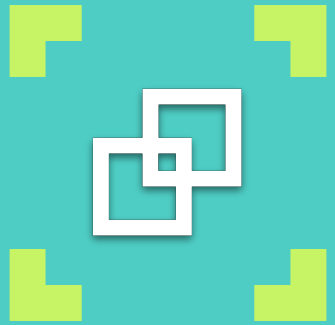

Le démonstrateur

L’équation booléenne

Construire l'équation

CIBLER LA THEMATIQUE

Recherche sur Beethoven

beethoven

Résultats (23-05-2022) : 18 569 docs

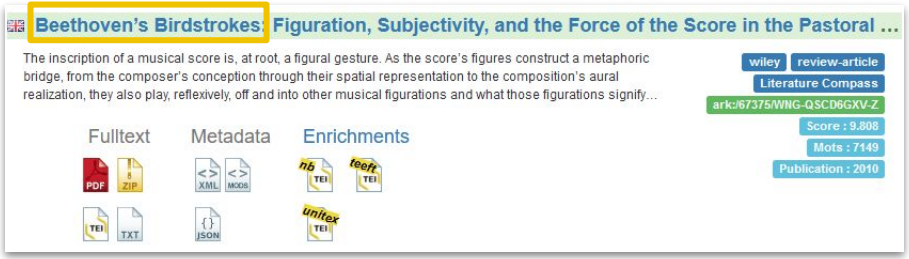

Explication de la requête :

- Le mot est recherché sur tout le document (métadonnées, texte intégral, références bibliographiques, enrichissements)
- Insensibilité à la casse
  - "beethoven" = 18 569 docs
  - "Beethoven" = 18 569 docs

Construire l'équation

CIBLER LA THEMATIQUE

Recherche sur des formes variantes

beethoven*

Résultats (23-05-2022) : 25 365 docs

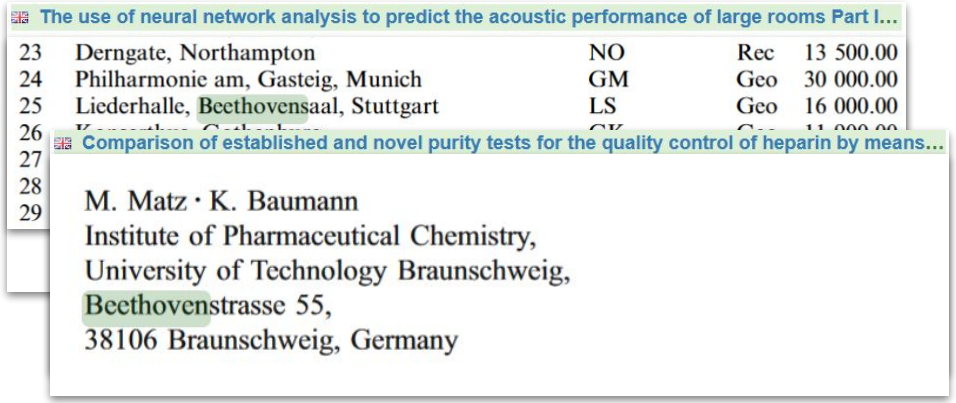

Explication de la requête :

- Utilisation d'une troncature
  - * remplace 0 à n caractère(s)
  - ? remplace 1 caractère

Plus de détails :
troncatures

Construire l'équation

ELIMINER LE BRUIT

Cibler des variantes spécifiques

```
beethoven OR beethoven's
```

Résultats (23-05-2022) : 21 338 docs

Explication de la requête :

- OR cumule les documents associés à chaque terme de recherche
- Si pas d'opérateur utilisé, l'opérateur par défaut OR s'applique
- Les opérateurs doivent s'écrire en MAJUSCULES

Plus de détails :
opérateurs / astuces

Construire l'équation

ELIMINER LE BRUIT

Cibler des variantes spécifiques

```
/beethoven('s)?/
```

Résultats (23-05-2022) : 21 338 docs

Explication de la requête :

- Expression régulière sur Beethoven
  - S'écrit entre délimiteurs / /
  - Aucune majuscule entre les délimiteurs
  - `/beethoven('s)?/` = `beethoven OR beethoven's`

Marque d'appartenance "'s" optionnelle

Plus de détails : expressions régulières

Construire l'équation

ELIMINER LE BRUIT

Cibler des variantes spécifiques

```
/beethoven('s)?/
```

Résultats (23-05-2022) : 21 338 docs

Explication de la requête :

- Expression régulière sur Beethoven
  - S'écrit entre délimiteurs / /
  - Aucune majuscule entre les délimiteurs
  - `/beethoven('s)?/` = `beethoven OR bee`

Marque d'appartenance "'s" optionnelle

Plus de détails : expressions régulières

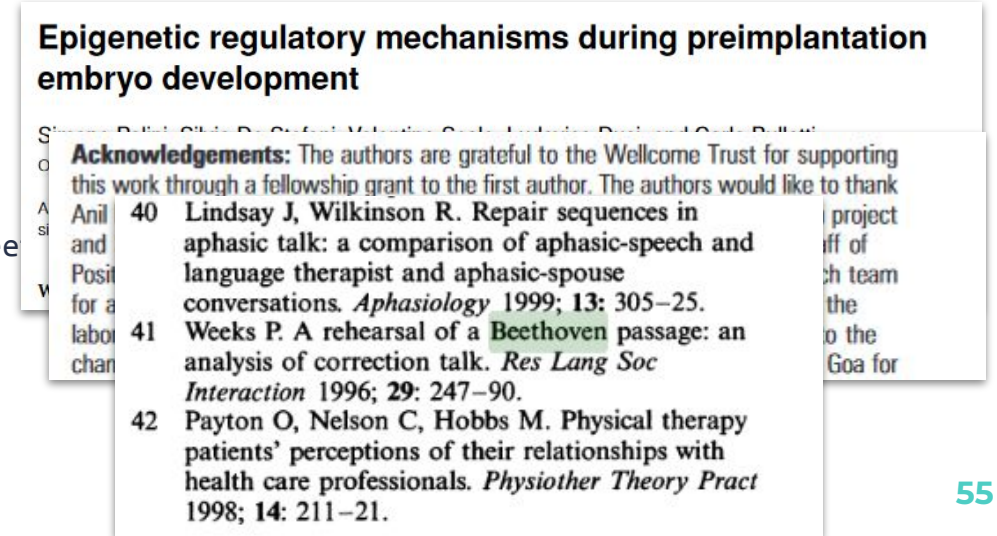

Epigenetic regulatory mechanisms during preimplantation embryo development

Acknowledgements: The authors are grateful to the Wellcome Trust for supporting this work through a fellowship grant to the first author. The authors would like to thank Anil project and ff of Posit h team for a the labo o the chan Goa for

40 Lindsay J, Wilkinson R. Repair sequences in aphasic talk: a comparison of aphasic-speech and language therapist and aphasic-spouse conversations. *Aphasiology* 1999; **13**: 305–25.
41 Weeks P. A rehearsal of a Beethoven passage: an analysis of correction talk. *Res Lang Soc Interaction* 1996; **29**: 247–90.
42 Payton O, Nelson C, Hobbs M. Physical therapy patients' perceptions of their relationships with health care professionals. *Physiother Theory Pract* 1998; **14**: 211–21.

Construire l'équation

ELIMINER LE BRUIT

Cibler l'interrogation sur des champs textuels plus précis

```
title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
```

Résultats (23-05-2022) : 515 docs

Explication de la requête :

- Recherche restreinte sur les champs :
  - titre de l'article : "**title**"
  - résumé : "**abstract**"
  - mots-clés d'auteur : "**subject.value**"
- Les noms de champs sont introduits par **:**
- **Pas de factorisation** des noms de champs. Il faut répéter les termes pour chaque champ interrogé

Plus de détails :
exemples de contenus / recherche sur champs

Construire l'équation

LIMITER LE SILENCE

Interroger sur des données enrichies

```
title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven
OR keywords.teeft:beethoven
```

Résultats (23-05-2022) : 3 023 docs

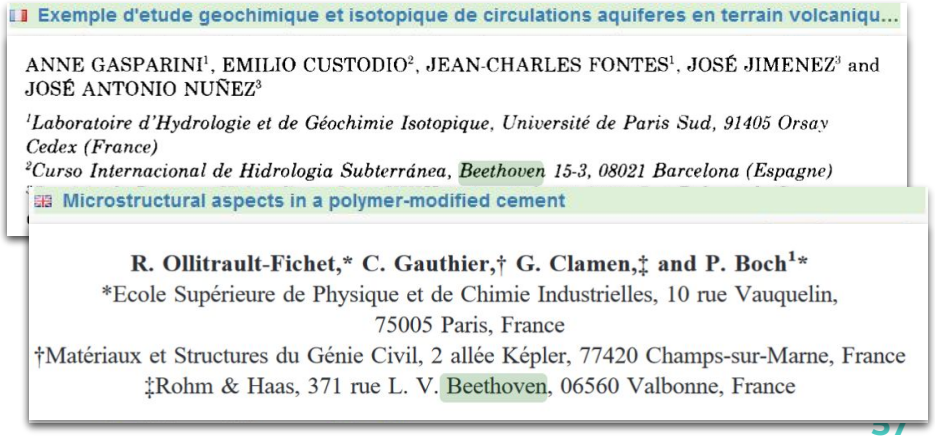
Exemple d'etude geochimique et isotopique de circulations aquiferes en terrain volcaniqu...

ANNE GASPARINI[1], EMILIO CUSTODIO[2], JEAN-CHARLES FONTES[1], JOSÉ JIMENEZ[3] and JOSÉ ANTONIO NUÑEZ[3]

[1]*Laboratoire d'Hydrologie et de Géochimie Isotopique, Université de Paris Sud, 91405 Orsay Cedex (France)*
[2]*Curso Internacional de Hidrologia Subterránea, Beethoven 15-3, 08021 Barcelona (Espagne)*

Microstructural aspects in a polymer-modified cement

R. Ollitrault-Fichet,* C. Gauthier,† G. Clamen,‡ and P. Boch[1]*

*Ecole Supérieure de Physique et de Chimie Industrielles, 10 rue Vauquelin, 75005 Paris, France
†Matériaux et Structures du Génie Civil, 2 allée Képler, 77420 Champs-sur-Marne, France
‡Rohm & Haas, 371 rue L. V. Beethoven, 06560 Valbonne, France

Explication de la requête :

- Recherche sur des champs contenant des enrichissements
  - namedEntities.unitex.persName
  - keywords.teeft

Plus de détails :
Recherche sur enrichissements

Construire l'équation

ELIMINER LE BRUIT

Interroger sur des données enrichies

```
(title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven
OR keywords.teeft:beethoven)
NOT author.affiliations:beethoven*
```

Résultats (23-05-2022) : 3 013 docs

Explication de la requête :

- Ajout de parenthèses pour délimiter la portée du critère suivant
- NOT exclut les documents contenant "beethoven" dans l'affiliation de leur(s) auteur(s)

Plus de détails :
Parenthésage / opérateur d'exclusion

L’équation complète

```
(title:/beethoven('s)?/ OR abstract:/beethoven('s)?/ OR subject.value:/beethoven('s)?/ OR
namedEntities.unitex.persName:beethoven OR keywords.teeft:beethoven)

NOT author.affiliations:beethoven*
```

Résultats (23-05-2022) : 3 013 docs

2.2

Télécharger un corpus...

...avec ISTEX-DL

Istex-DL

L’outil

Istex-DL…
ou Istex-DownLoad

“Télécharger un corpus Istex en quelques clics”

Istex-DL : application

Interface web single page permettant d'**extraire facilement et en masse** un corpus de documents Istex, sous forme compressée, **prêt à l'emploi** pour un **usage en TDM**...avec un **minimum** de connaissances informatiques !

Istex-DL nomade

Une interface "responsive", compatible
avec les mobiles

Lien vers le tutoriel

Istex-DL : accès

https://www.istex.fr/

https://dl.istex.fr/

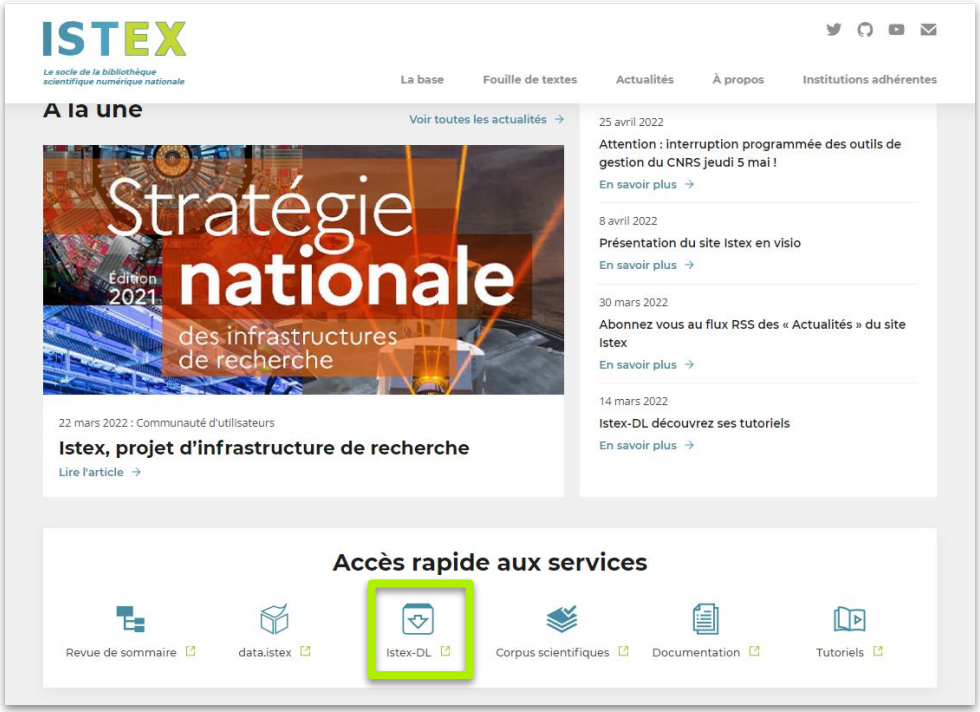

Istex-DL : 3 étapes

1- Définir & délimiter un corpus

2- Choisir les fichiers & formats

3- Lancer l'extraction

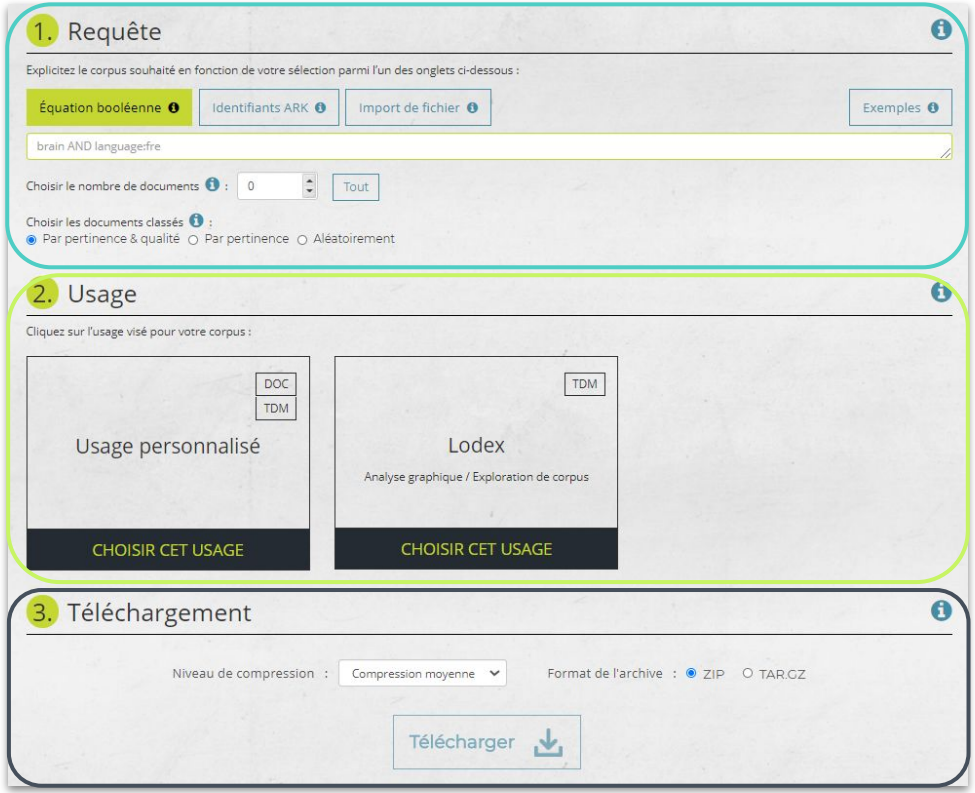

Istex-DL : étape 1

Définir son corpus

3 façons de construire un corpus

1. Requête

Explicitez le corpus souha[illegible]n fonction de votre séle[illegible]n parmi l'un des onglets c[illegible]ssous :

Équation booléenne | Identifiants ARK | Import de fichier | Exemples

brain AND language:fre

Choisir le nombre de documents : 0 Tout

Choisir les documents classés :

Par pertinence & qualité | Par pertinence | Aléatoirement

Aides à disposition

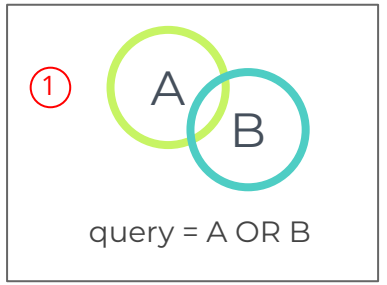

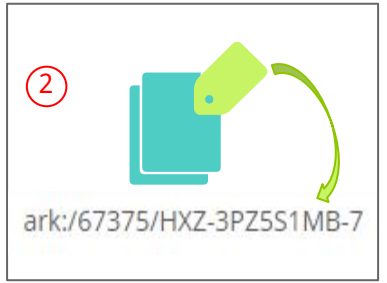

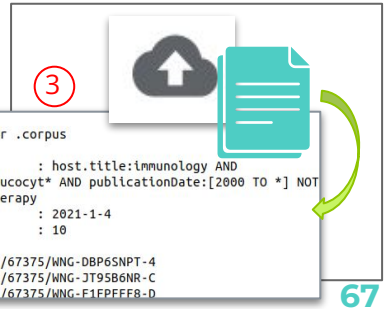

Istex-DL : étape 1

Définir son corpus

Prévisualisation des 6 premiers résultats

Échantillon de résultats

Beethoven's Birdstrokes: Figuration, Subjectivity, and the Force of the Sc... *William Kumbier ;* Literature Compass 2010	BEETHOVEN: MEDICINE, MUSIC, AND MYTHS *T. G. PALFERMAN ;* International Journal of Dermato... 1994	Believing in Beethoven *Daniel K. L. Chua ;* Music Analysis 2000
NEW DIRECTIONS, NEW COLLABORATIONS *Ann Pederson ;* Zygon® 2010	Historical hepatology: Ludwig van Beethoven *PAUL C. ADAMS ;* Journal of Gastroenterology and Hepatol... 1987	RAPID METHOD OF ASSAYING CREATINE KINASE MB *D.I. Melville ; J.P. Mckenna ; J. King ;* The Lancet 1977

International Journal of Dermatology

Rebond vers le texte intégral (accès au PDF par un clic)

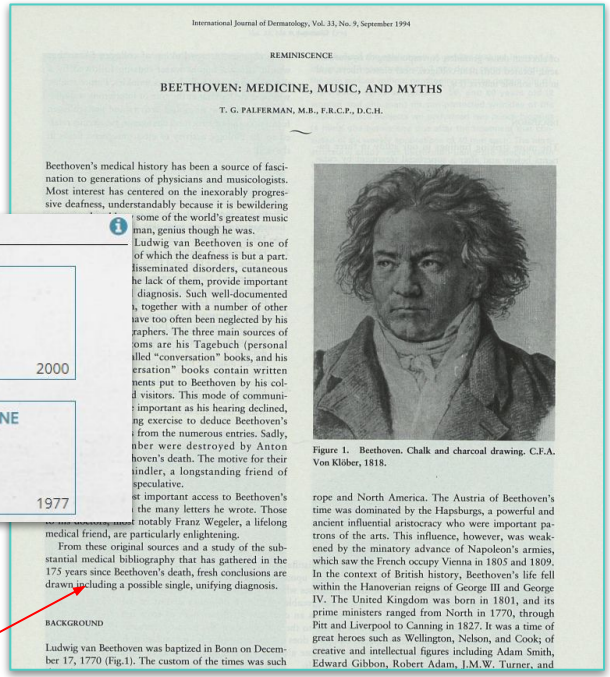

International Journal of Dermatology, Vol. 33, No. 9, September 1994

REMINISCENCE

BEETHOVEN: MEDICINE, MUSIC, AND MYTHS

T. G. PALFERMAN, M.B., F.R.C.P., D.C.H.

Beethoven's medical history has been a source of fascination to generations of physicians and musicologists. Most interest has centered on the inexorably progressive deafness, understandably because it is bewildering

Figure 1. Beethoven. Chalk and charcoal drawing. C.F.A. Von Klöber, 1818.

rope and North America. The Austria of Beethoven's time was dominated by the Hapsburgs, a powerful and ancient influential aristocracy who were important patrons of the arts. This influence, however, was weakened by the minatory advance of Napoleon's armies, which saw the French occupy Vienna in 1805 and 1809. In the context of British history, Beethoven's life fell within the Hanoverian reigns of George III and George IV. The United Kingdom was born in 1801, and its prime ministers ranged from North in 1770, through Pitt and Liverpool to Canning in 1827. It was a time of great heroes such as Wellington, Nelson, and Cook; of creative and intellectual figures including Adam Smith, Edward Gibbon, Robert Adam, J.M.W. Turner, and

BACKGROUND

Ludwig van Beethoven was baptized in Bonn on December 17, 1770 (Fig.1). The custom of the times was such

Istex-DL : étape 1

Délimiter son corpus

Choix du nombre de documents

Choix du mode de tri pour corpus réduit

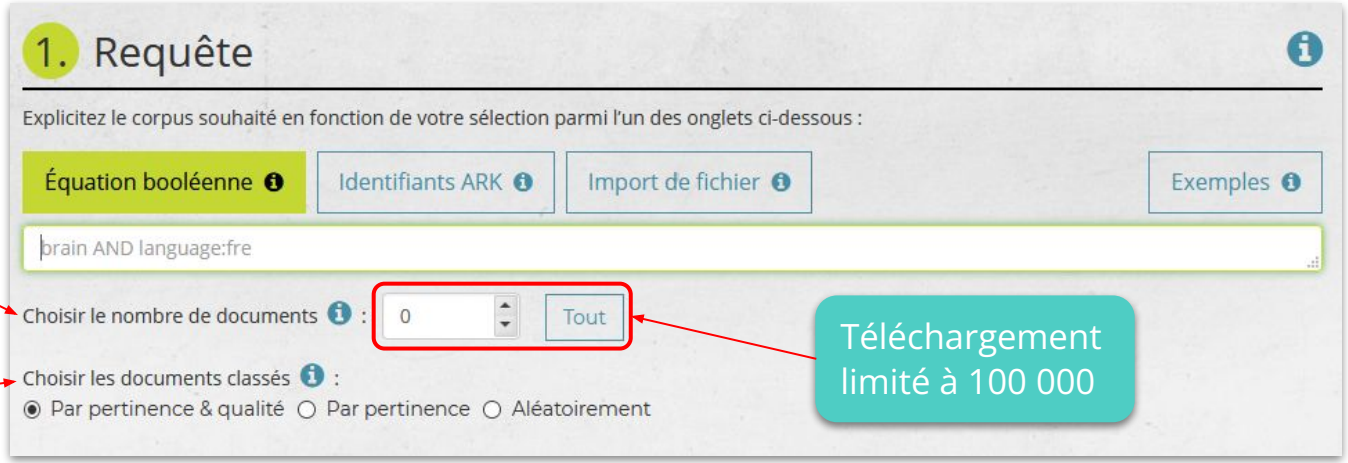

Téléchargement limité à 100 000

Istex-DL : étape 2

Fichiers & formats

Automatique
vs. Manuel

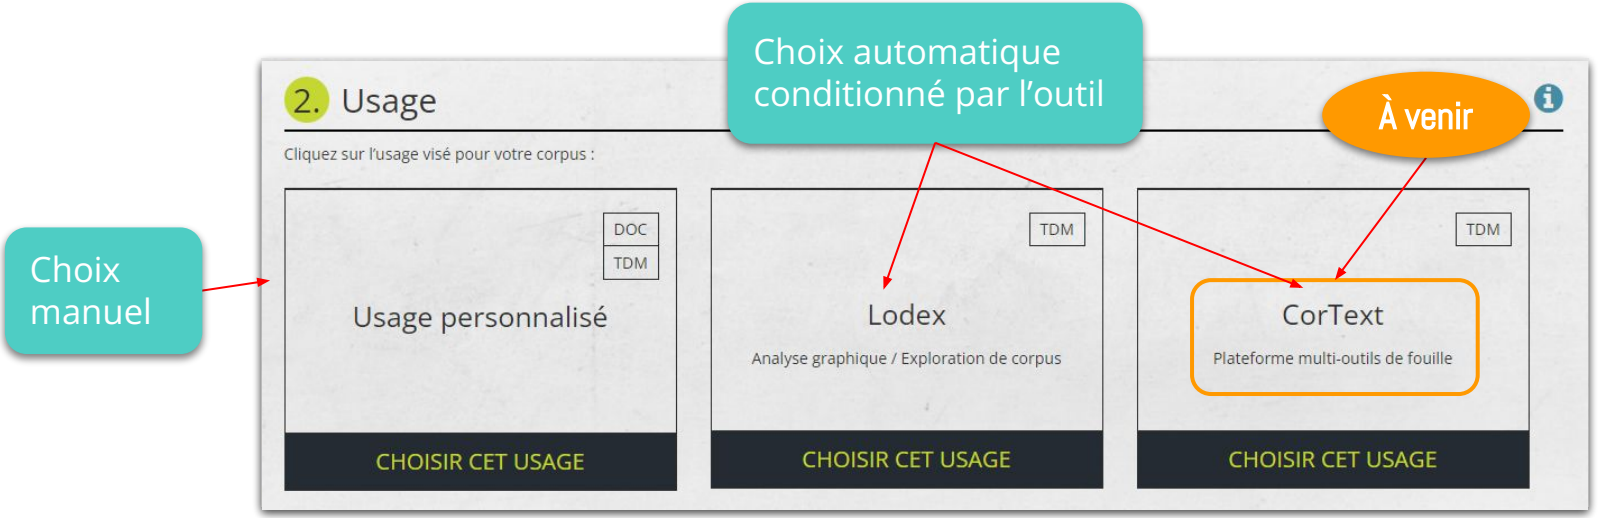

Istex-DL : étape 2

Fichiers & formats

Automatique

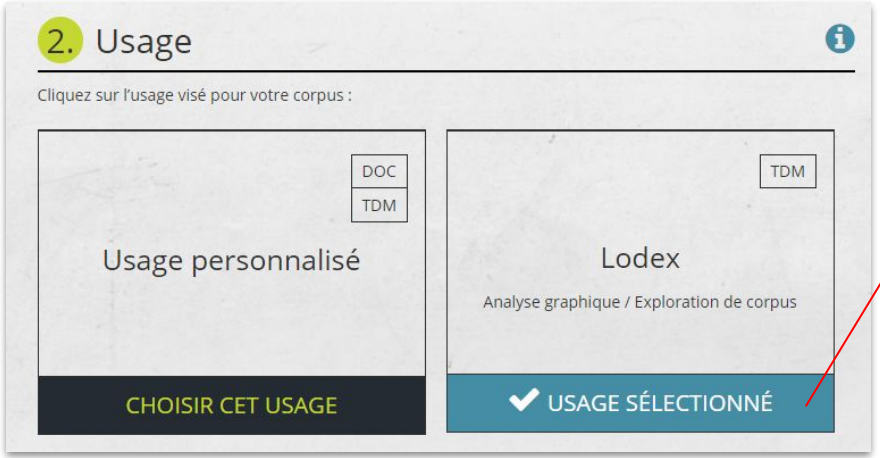

Sélection automatique des fichiers et formats compatibles avec le logiciel LODEX

LODEX

Istex-DL : étape 2

Fichiers & formats

Manuel

Sélection à la carte, en fonction des besoins des utilisateurs

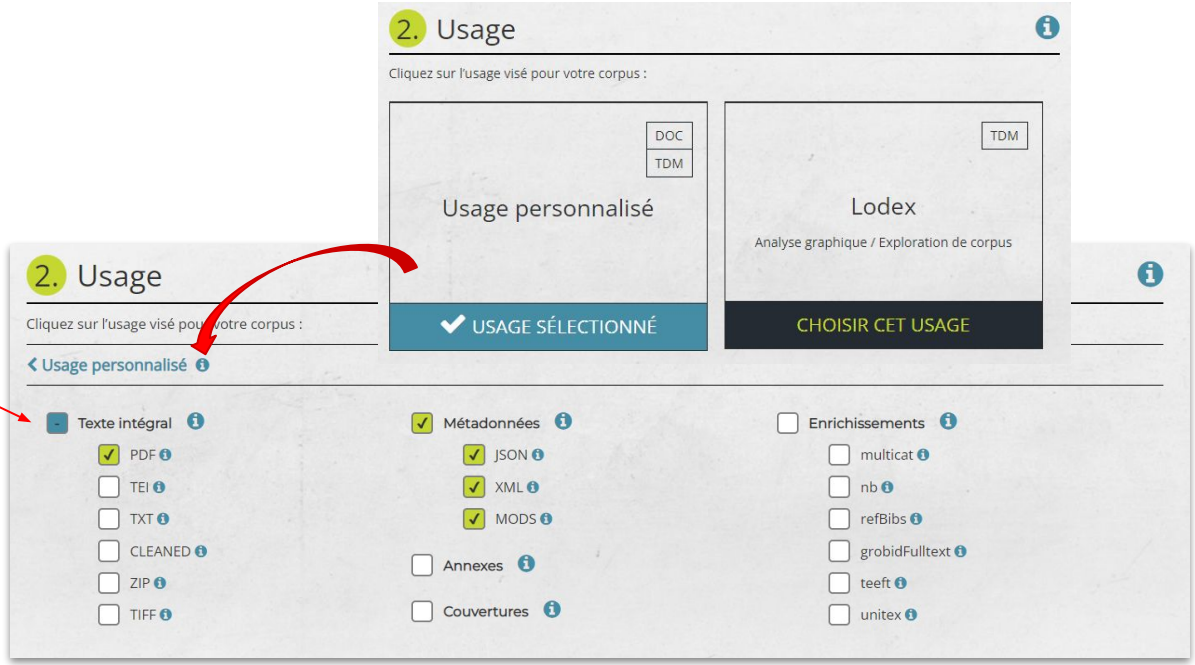

Istex-DL : étape 3

Télécharger

Paramétrer l'extraction

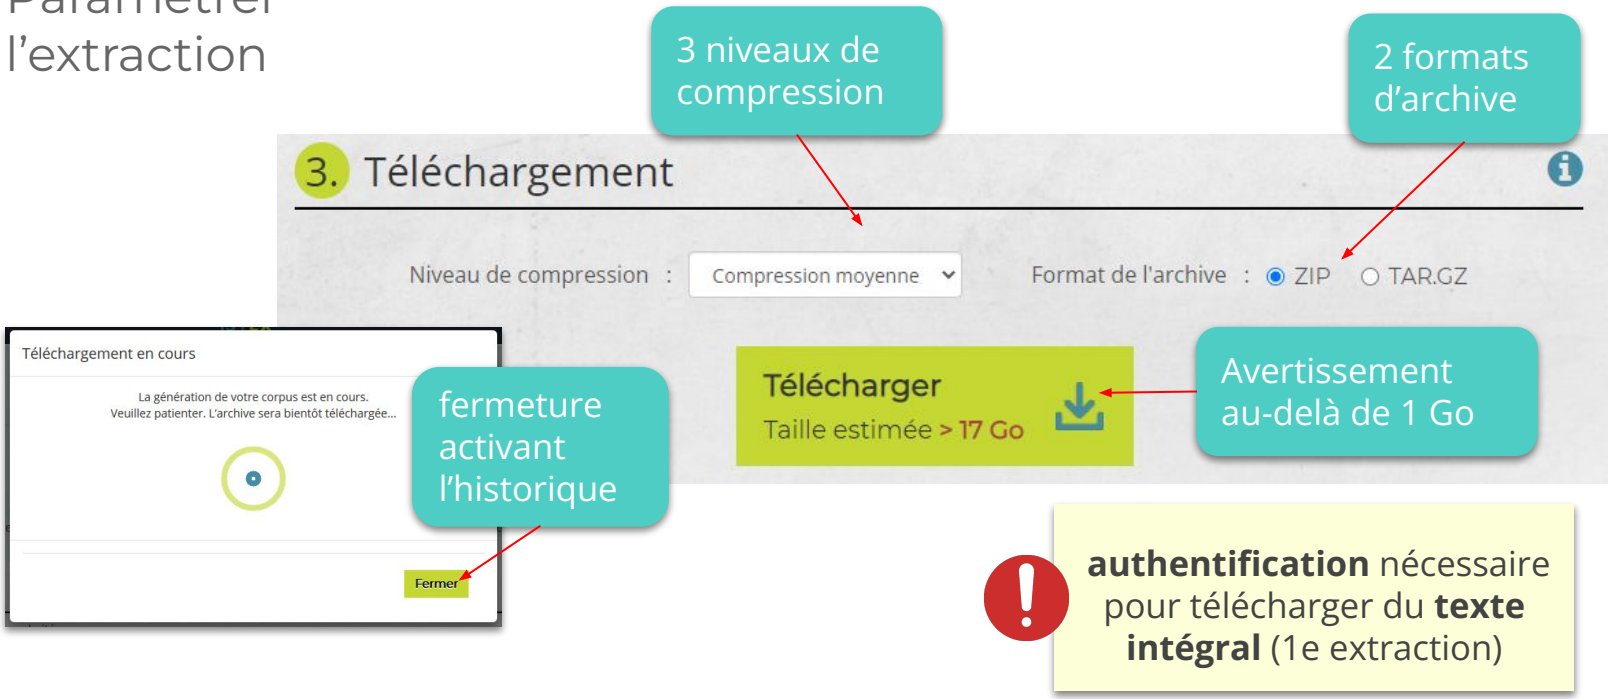

Istex-DL : 4 fonctionnalités

Menu fixe

À disposition en permanence

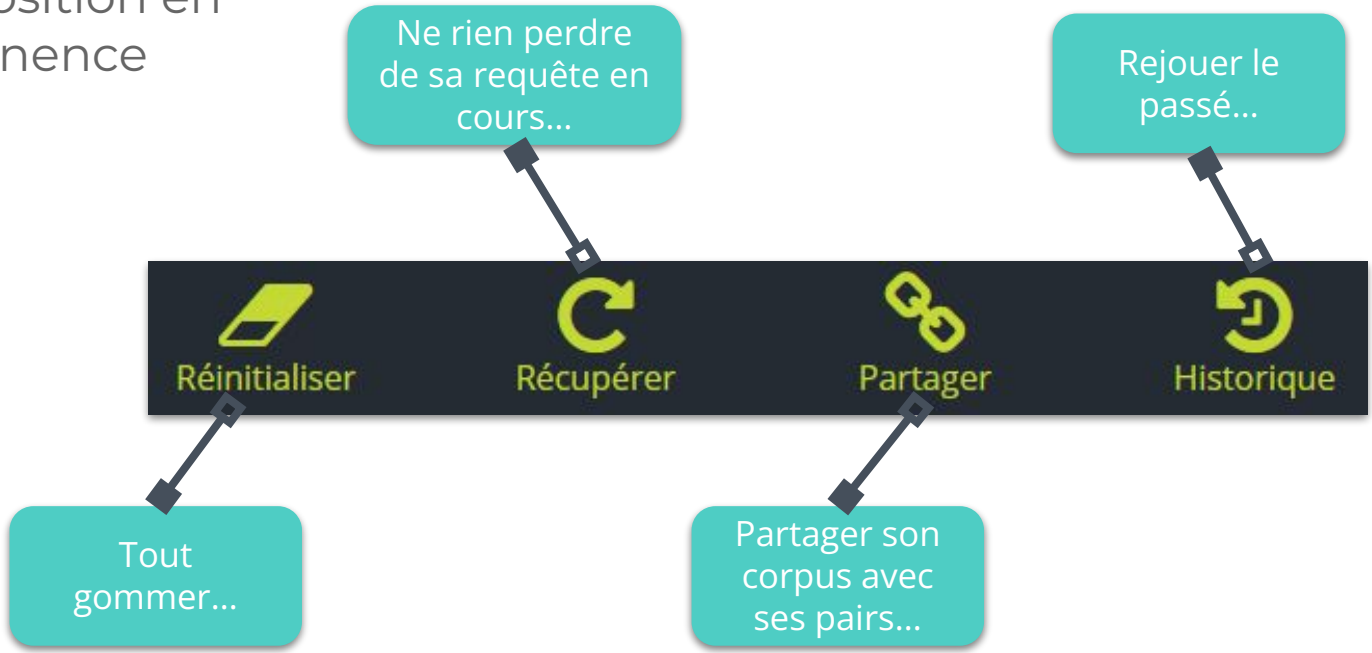

Istex-DL

L’extraction

Istex-DL : cas d’usage

Extraction 1

Extraire le corpus “TDM Beethoven” avec l’ équation définie dans le démonstrateur

Résultats (23-05-2022) : 3 013 docs

```
(title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*
```

2.3

Exploration du corpus

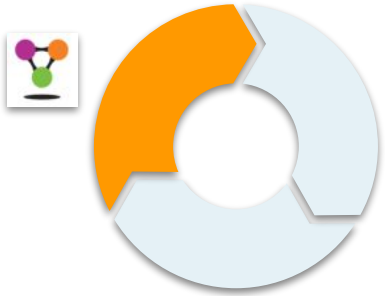

... avec LODEX

Lodex

L’outil

Linked

Open

Data

EXperiment

“Sémantisation

&

Visualisation”

Lodex : application

Application web open-source dédiée aux données structurées

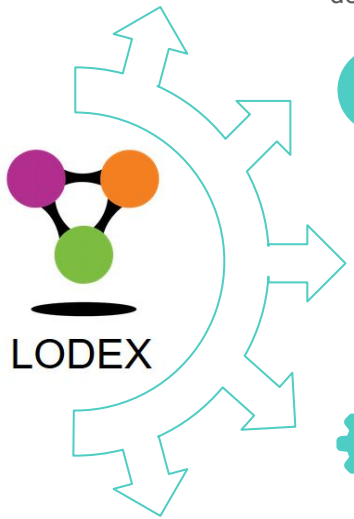

Transformer ses données en site web

à partir de différents formats de données

Explorer ses données enrichies

à l'aide de graphiques, facettes et au travers de données complémentaires

Aligner ses données

avec des données similaires ou connexes

Exporter ses données

en formats classiques ou du web sémantique

Attribuer des identifiants pérennes

ARK

https://github.com/Inist-CNRS/lodex

https://lodex.inist.fr/

Lodex “nomade”

Créés avec Lodex, des sites web "responsives", compatibles avec les mobiles

Lien vers le tutoriel

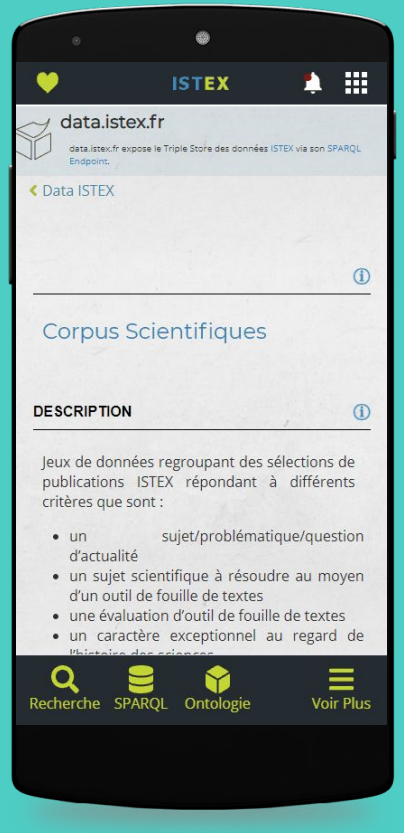

LODEX : principe

Métadonnées

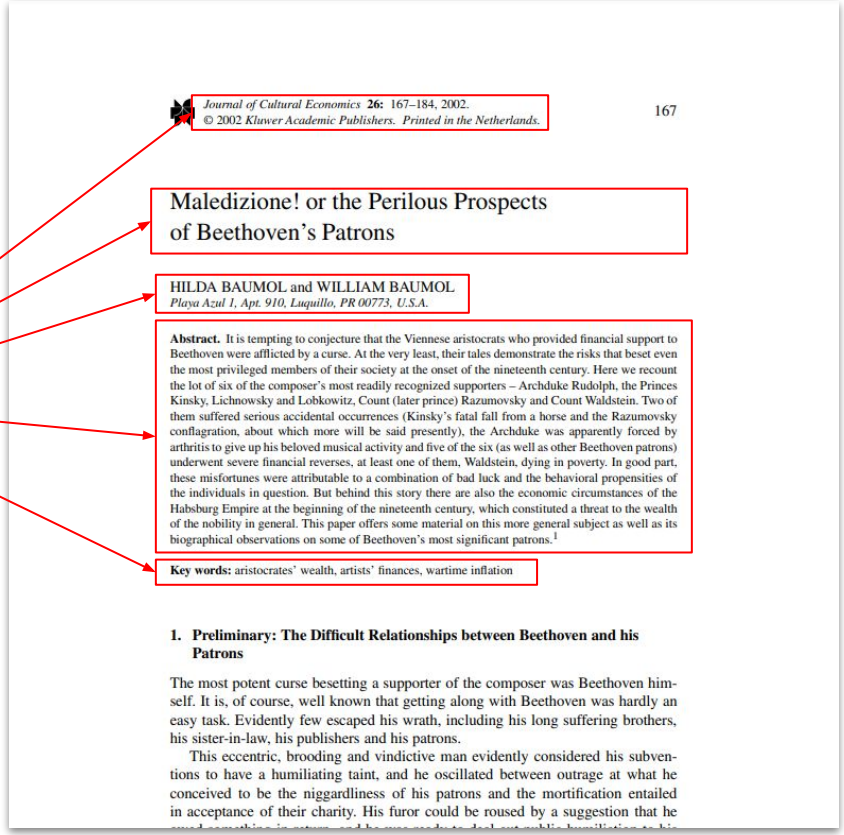

Journal of Cultural Economics **26:** 167–184, 2002.
© 2002 *Kluwer Academic Publishers. Printed in the Netherlands.*

Maledizione! or the Perilous Prospects of Beethoven's Patrons

HILDA BAUMOL and WILLIAM BAUMOL
Playa Azul 1, Apt. 910, Luquillo, PR 00773, U.S.A.

Abstract. It is tempting to conjecture that the Viennese aristocrats who provided financial support to Beethoven were afflicted by a curse. At the very least, their tales demonstrate the risks that beset even the most privileged members of their society at the onset of the nineteenth century. Here we recount the lot of six of the composer's most readily recognized supporters – Archduke Rudolph, the Princes Kinsky, Lichnowsky and Lobkowitz, Count (later prince) Razumovsky and Count Waldstein. Two of them suffered serious accidental occurrences (Kinsky's fatal fall from a horse and the Razumovsky conflagration, about which more will be said presently), the Archduke was apparently forced by arthritis to give up his beloved musical activity and five of the six (as well as other Beethoven patrons) underwent severe financial reverses, at least one of them, Waldstein, dying in poverty. In good part, these misfortunes were attributable to a combination of bad luck and the behavioral propensities of the individuals in question. But behind this story there are also the economic circumstances of the Habsburg Empire at the beginning of the nineteenth century, which constituted a threat to the wealth of the nobility in general. This paper offers some material on this more general subject as well as its biographical observations on some of Beethoven's most significant patrons.[1]

Key words: aristocrates' wealth, artists' finances, wartime inflation

1. Preliminary: The Difficult Relationships between Beethoven and his Patrons

The most potent curse besetting a supporter of the composer was Beethoven himself. It is, of course, well known that getting along with Beethoven was hardly an easy task. Evidently few escaped his wrath, including his long suffering brothers, his sister-in-law, his publishers and his patrons.

This eccentric, brooding and vindictive man evidently considered his subventions to have a humiliating taint, and he oscillated between outrage at what he conceived to be the niggardliness of his patrons and the mortification entailed in acceptance of their charity. His furor could be roused by a suggestion that he

Lodex : principe

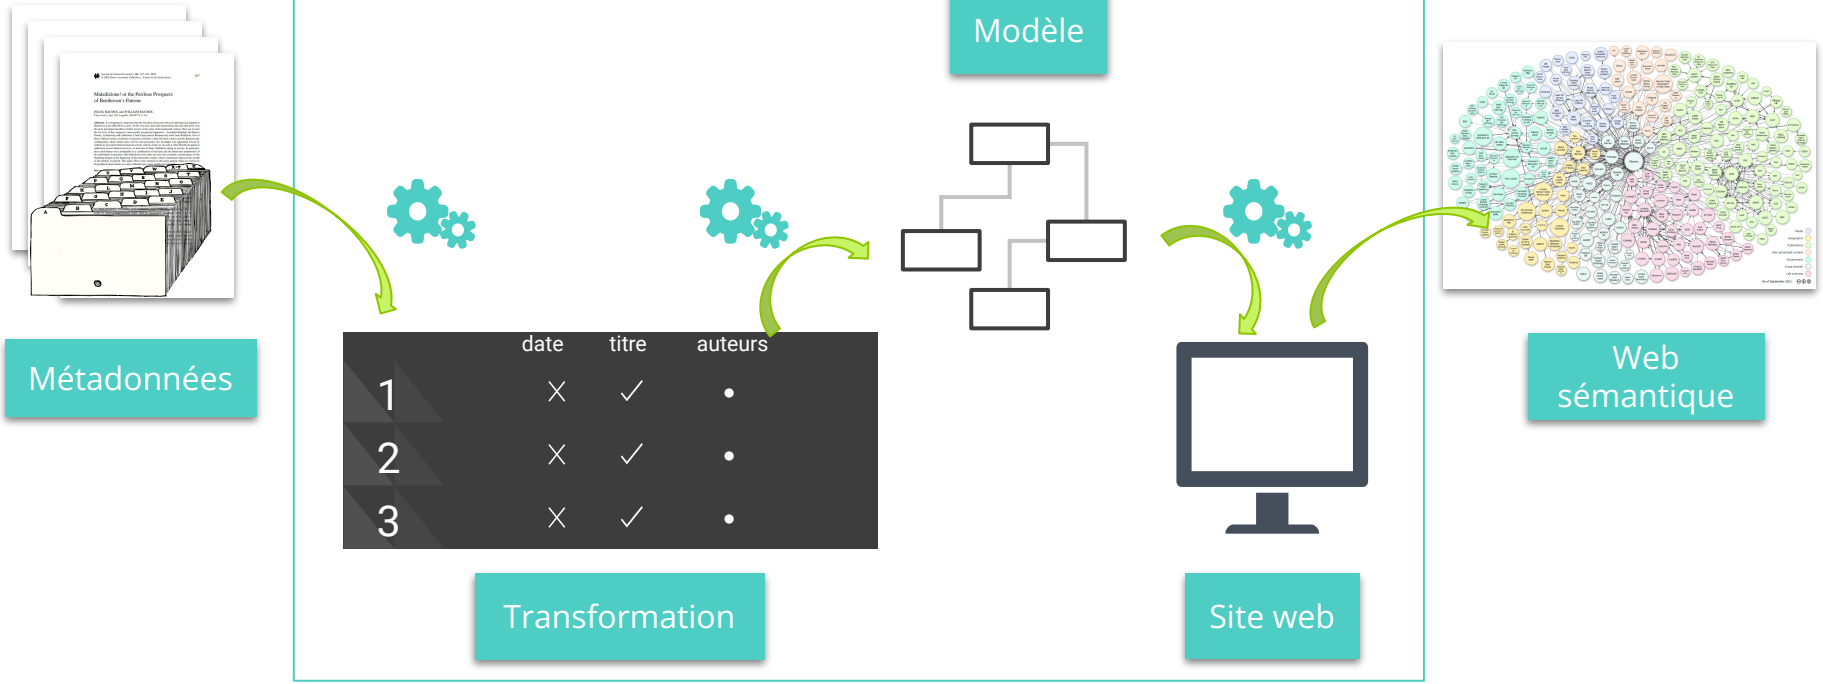

Lodex : import des données

Etape 1

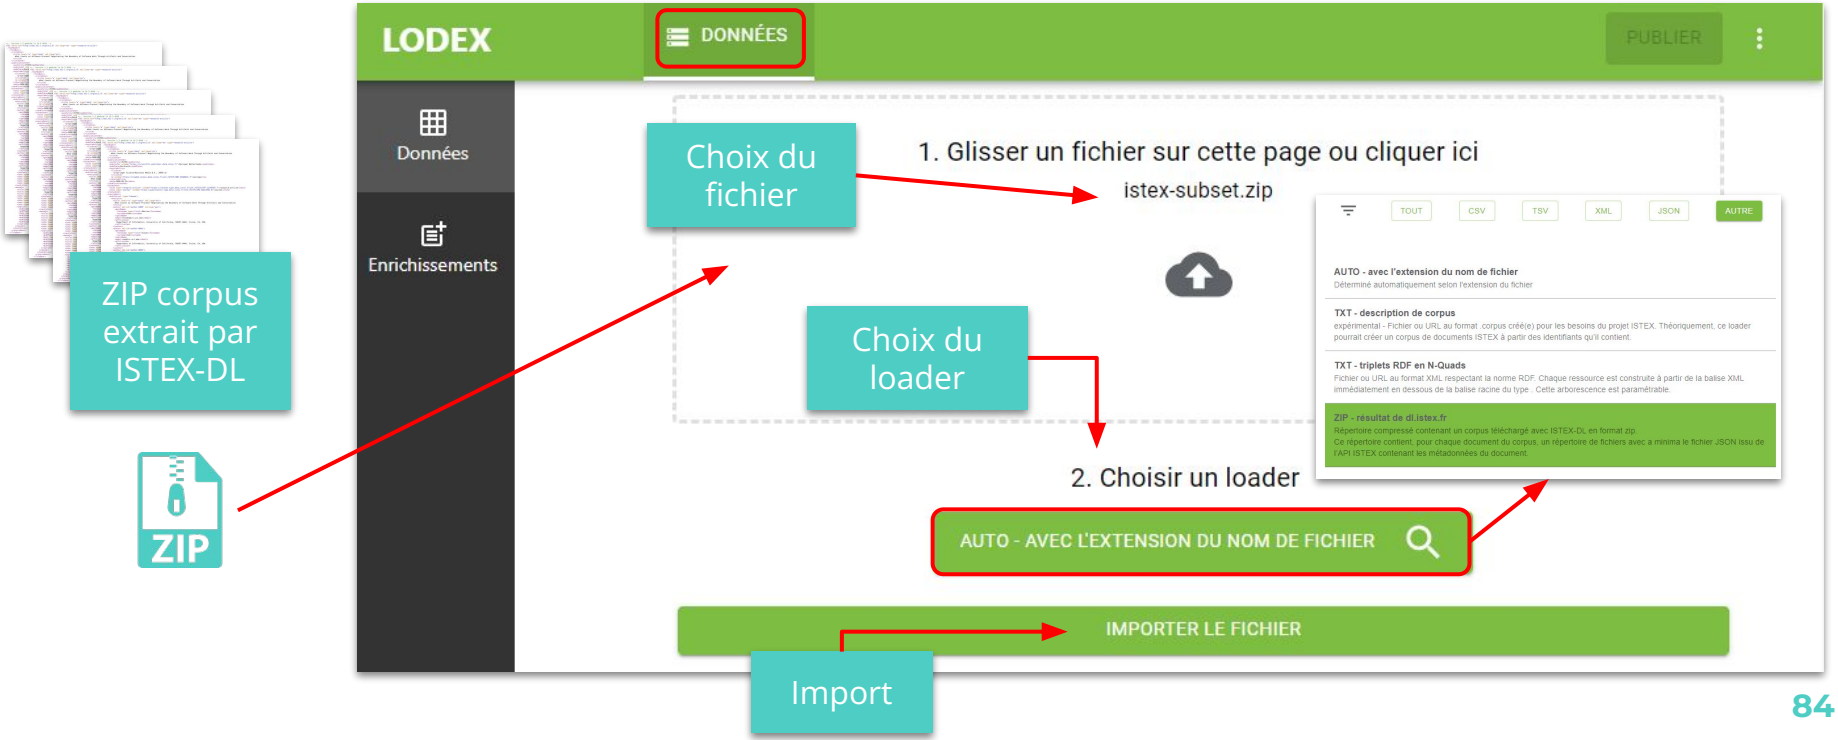

Lodex : import des données

Etape 1

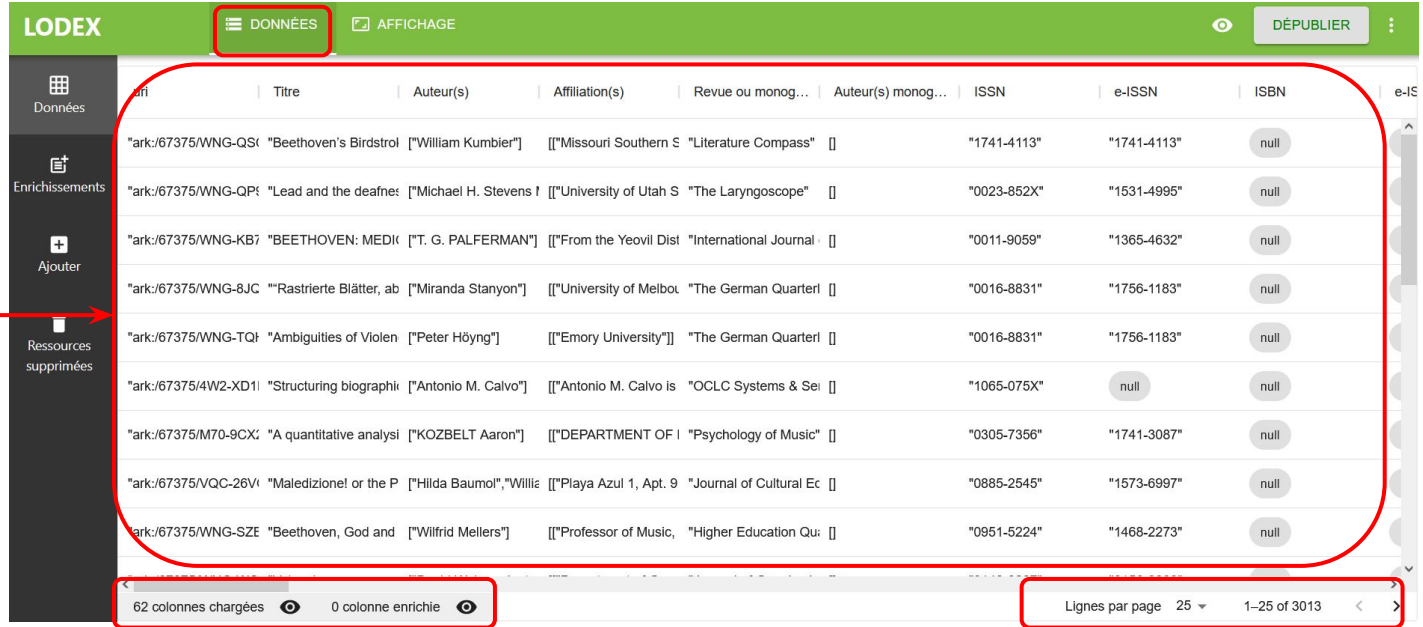

Import des données réussi

Lodex : modélisation

Etape 2

Lodex : modélisation

Etape 2

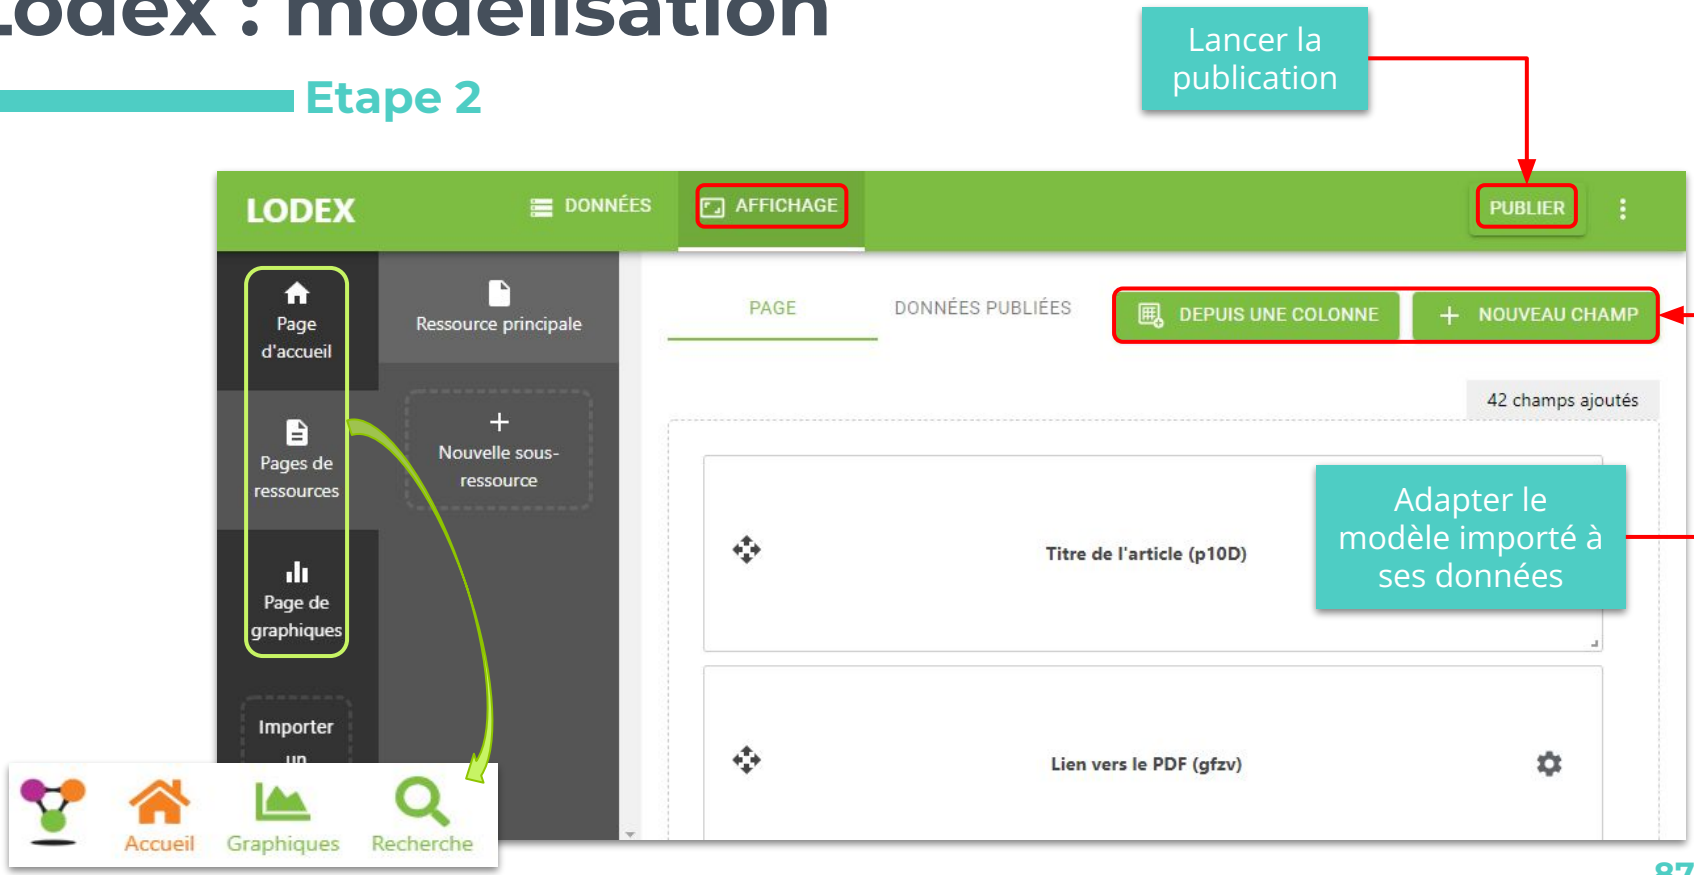

Lodex : modélisation

Etape 2

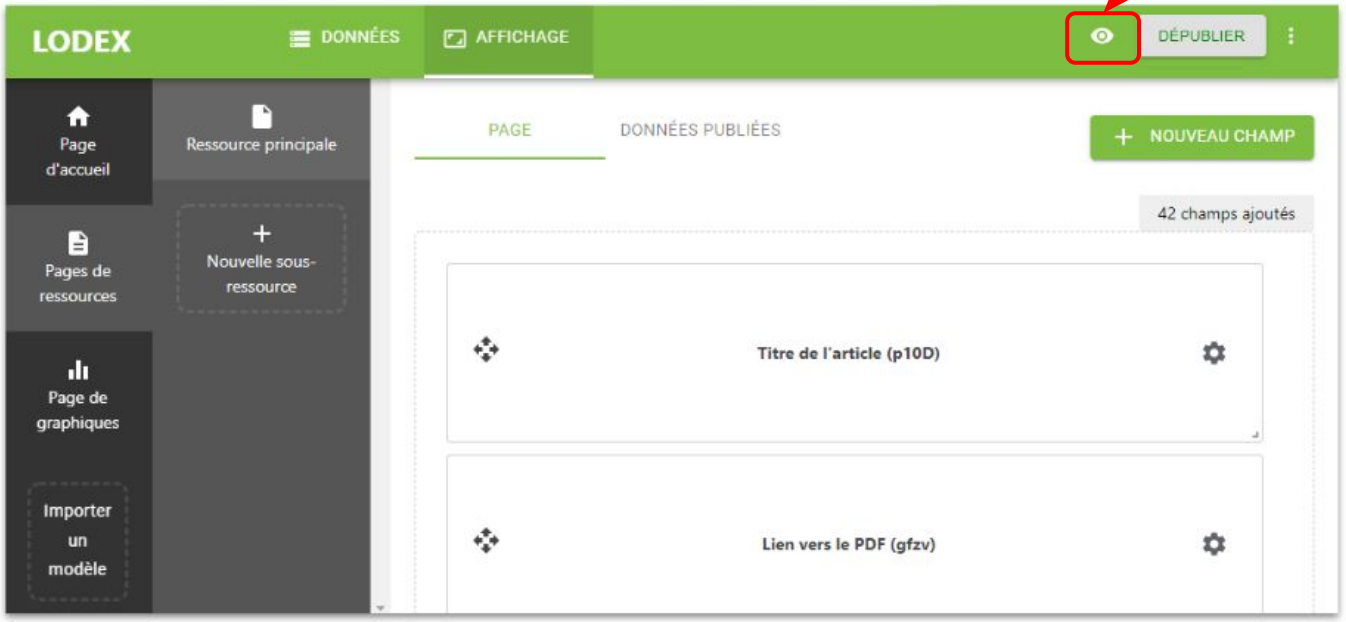

Lodex

L’exploration

Stratégie itérative : 2 phases

Phase 1

Pertinence scientifique

- ***Démonstrateur :***
  - *Construction et affinement requête*
- ***Istex-DL :***
  - *Extraction corpus v0*
- **Lodex:**
  - Mots-clés auteur, termes extraits Teeft & entités nommées Unitex
  - Catégories scientifiques
  - Titres de revues

Lodex : instances

Corpus v0

1. Corpus “TDM Beethoven”

   Version 0

   Corpus de 3013 documents correspondants à l’équation définie dans le démonstrateur

tdm-beethovenv0.formation.lodex.fr

Lodex : exploration phase 1

Résultats

Graphiques “Termes extraits (Teeft)” & “Entités nommées (Unitex)”

- Termes cohérents avec la thématique

Graphique “Mots-clés d’auteur”

- Bruit : toponyme “Beethoven” (géophysique et astrophysique)

Solution

- exclure les mots-clés d’auteur indésirables

Conclusion :

Ajouter le critère

```
NOT subject.value:(Antarctic Astronomy Mercury)
```

Lodex : exploration phase 1

Résultats

Graphiques “Catégories Scientifiques”

- Bruit : multidisciplinarité importante dans les classifications Science-Metrix, Scopus et WoS

Solution

- Soit exclure les catégories hors sujet
- Soit cibler les catégories pertinentes en les combinant dans les différentes classifications

Conclusion :

Ajouter le critère

```
AND
(categories.scienceMetrix:"3-music"
OR categories.scopus:"3-music")
```

Lodex : exploration phase 1

Résultats

Graphique “Titres de revue”

- 477 titres
- 9 titres de musique dans les 16 premières revues (68% des documents)

Solution

- Cibler les titres de revue de musicologie

Conclusion :

Ajouter le critère

```
AND host.title:(musi* opera tempo)
```

Lodex : exploration phase 1

Equation affinée

Affinement

- Cibler les revues de musicologie

```
((title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*)
AND host.title:(musi* opera tempo)
```

Stratégie

Phase 2 : Exploitabilité en TDM

Stratégie itérative : 3 outils

Lodex

Visualisation
& Exploration

API-Istex

ISTEX

Interrogation
& Exploration

Istex-DL

Extraction

Stratégie itérative : 2 phases

Phase 1

Pertinence scientifique

- ***Démonstrateur :***
  - *Construction et affinement requête*
- ***Istex-DL :***
  - *Extraction corpus v0*
- ***Lodex :***
  - *Mots-clés auteur, termes extraits Teeft & entités nommées Unitex*
  - *Catégories scientifiques*
  - *Titres de revues*

Phase 2

Exploitabilité en TDM

- **Démonstrateur :**
  - Nombre mots du PDF
- **Istex-DL :**
  - Extraction corpus v1
- **Lodex :**
  - PDF image
  - Présence résumé & Langue
  - Types de documents & Dates de publication
  - TXT compatible TDM

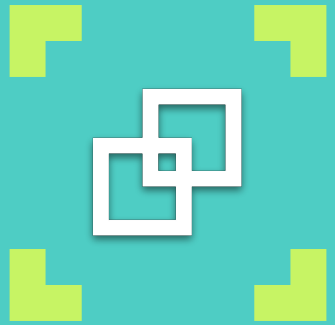

Le démonstrateur

La facette “Qualité”

Démonstrateur : exploration phase 2

Résultats

Facette “Qualité” / Slider “Nombre de mots”

- 2 017 docs : entre 0 et 113 959 mots
- 113 959 mots = 282 pages
- 51 682 mots = 136 pages
- 107 docs (5%) : > 10 000 mots

Solution

- Se limiter aux documents de moins de 10 000 mots

Conclusion :

Selon l’outil et la mémoire vive à disposition, ajouter le critère

```
AND qualityIndicators.pdfWordCount:[* TO 10000]
```

Démonstrateur : exploration phase 2

Equation affinée

Affinement

```
((title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*)
AND host.title:(musi* opera tempo)
AND qualityIndicators.pdfWordCount:[* TO 10000]
```

Istex-DL

L’extraction

Istex-DL : cas d’usage

Extraction 2

Extraire le corpus
“TDM Beethoven”
affiné dans Lodex
et le démonstrateur

Résultats (23-05-2022) : 1910 docs

```
((title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*)
AND host.title:(musi* opera tempo)
AND qualityIndicators.pdfWordCount:[* TO 10000]
```

Lodex

L’exploration

Lodex : instances

Corpus v1

2. Corpus “TDM Beethoven”

Version 1

Corpus de 1910 documents correspondants à l’équation affinée dans LODEX (phase 1), puis dans le démonstrateur

tdm-beethoven-v1.formation.lodex.fr

Lodex : exploration phase 2

Résultats

Graphique PDF Texte

- 13 documents (1%) potentiellement de type PDF “image”

Solution

- Si besoin du format PDF, éliminer les documents qui ne seront pas exploitables
- Si besoin du format TXT, vérifier la présence de formats ré-océrisés

Conclusion :

Selon l’outil et le format à utiliser, ajouter le critère

```
NOT qualityIndicators.pdfText:false
```

Lodex : exploration phase 2

Résultats

Graphique “Présence d’un résumé”

- 79 documents (4 %) avec résumé

Graphique “Langues”

- 1 seule langue (pour le corpus v1)

Solution

- Se limiter aux documents possédant un résumé
- Se limiter à une langue unique

Conclusion :

Selon l’outil, ajouter les critères

```
AND abstract:*
AND language:eng
```

Lodex : exploration phase 2

Résultats

Graphique “Types de documents”

- Types “other” indésirables
- articles contigus & publicités, sources de bruit

Graphique “Dates de publication”

- Articles anciens : articles contigus, sources de bruit

Solution

- Éliminer les types de documents et dates non désirés et/ou problématiques, en utilisant une combinaison de critères

Conclusion :

Ajouter les critères

```
NOT
((genre:other AND title:("quarterly
book-list" "Recordings Received"))
OR (genre:"book-reviews" AND
host.title:"Early Music"))

NOT publicationDate:[1920 TO 1929] AND
host.title:"Music Supervisors' Journal"
```

Lodex : exploration phase 2

Résultats

Graphique “TXT compatible TDM”

- 446 documents (23%) avec format “TXT nettoyé”

Solution

- Se limiter aux documents “nettoyés” pour :
  - cibler les documents pertinents
  - éviter le bruit et les éléments perturbants

Conclusion :

Ajouter le critère

```
AND qualityIndicators.tdmReady:true
+(OR fulltext:/beethoven('s)?/)
```

Lodex : exploration phase 2

Résultats

Graphique “Types de documents”

- Types “other” et “book-reviews”, sources de bruit

Graphique “Dates de publication”

- Articles anciens : articles adjacents, sources de bruit

Solution

- Éliminer les types de documents non désirés, en utilisant si besoin une combinaison de critères
- Cibler le fulltext des documents nettoyés

Conclusion :

Ajouter les critères

```
NOT (genre:other AND title:("quarterly book-list" "Recordings Received"))

AND qualityIndicators.tdmReady:true
+(OR fulltext:/beethoven('s)?/)
```

Lodex : exploration phase 2

Equation affinée

Affinement

- Selon l'outil, ajouter un critère éliminant les PDF image
- Selon l'outil, se limiter aux documents possédant un résumé
- Se limiter à une langue unique
- Éliminer les types de documents non désirés
- Cibler les documents structurés et nettoyés pour éliminer les sources de bruit

```
((title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR fulltext:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*)
AND host.title:(musi* opera tempo)
AND qualityIndicators.pdfWordCount:[* TO 10000]
NOT qualityIndicators.pdfText:false
AND abstract:*
AND language:eng
NOT (genre:other AND title:("quarterly
book-list" "Recordings Received"))
AND qualityIndicators.tdmReady:true
```

2.4

Télécharger le corpus finalisé

...avec ISTEX-DL

Istex-DL : cas d'usage

Extraction 3

Extraire le corpus "TDM Beethoven" finalisé

Résultats (23-05-2022) : 2 029 docs

```
((title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR fulltext:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*)
AND host.title:(musi* opera tempo)
AND qualityIndicators.pdfWordCount:[* TO 10000]
NOT qualityIndicators.pdfText:false
AND language:eng
NOT (genre:other AND title:("quarterly
book-list" "Recordings Received"))
AND qualityIndicators.tdmReady:true
```

Istex-DL : cas d'usage

Extraction 3

Formats adaptés à l'outil de TDM visé

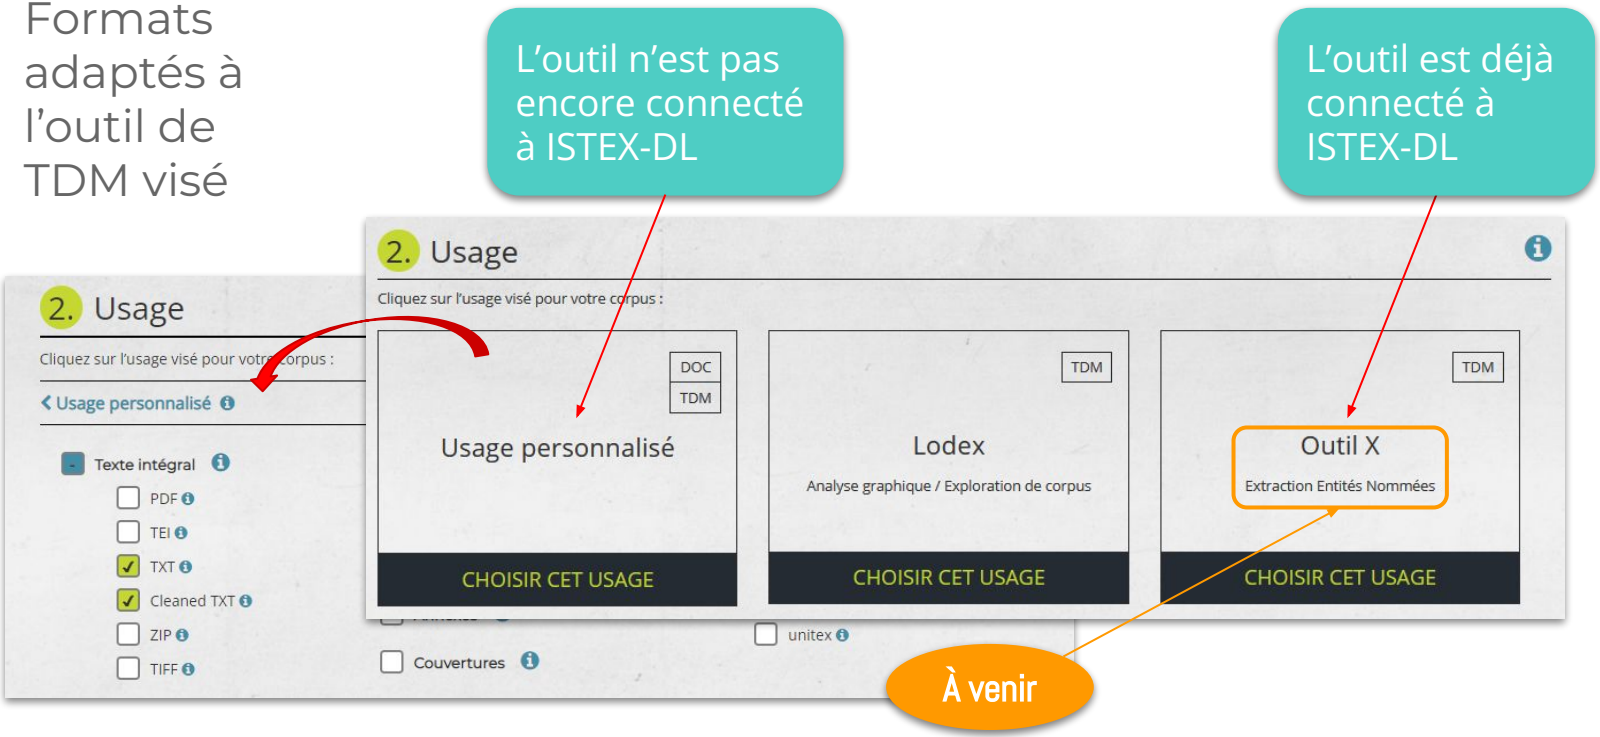

2.5

Partager son corpus

...avec ISTEX-DL

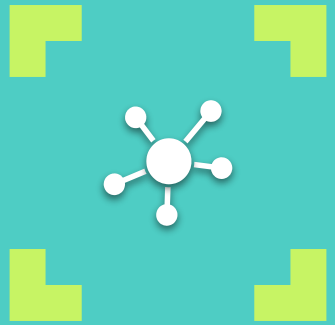

Istex-DL

Partager un corpus actualisé

Istex-DL : partager son corpus

Un corpus actualisé via le bouton “partager” **avant** extraction

Istex-DL : partager son corpus

Un corpus actualisé via le bouton “historique” **après** extraction

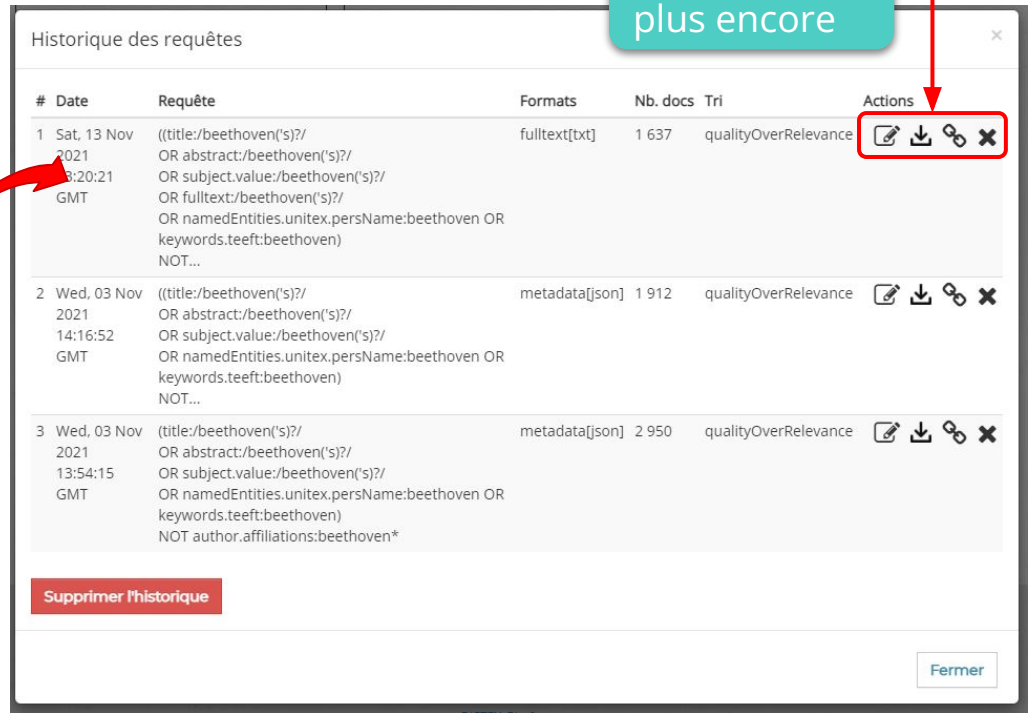

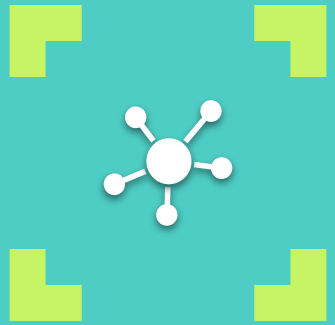

Istex-DL

Partager un corpus à l'identique

Istex-DL : partager son corpus

Un corpus à l'identique via les fichiers **.corpus**

ZIP corpus extrait d'ISTEX-DL

```
#
# Fichier .corpus
#
query        : ((title:/beethoven('s)?/
OR abstract:/beethoven('s)?/
OR subject.value:/beethoven('s)?/
OR fulltext:/beethoven('s)?/
OR namedEntities.unitex.persName:beethoven OR
keywords.teeft:beethoven)
NOT author.affiliations:beethoven*)
AND host.title:(musi* opera tempo)
AND qualityIndicators.pdfWordCount:[* TO 10000]
NOT qualityIndicators.pdfText:false
AND language:eng
NOT (genre:other AND title:("quarterly book-list" "Recordings
Received"))
AND qualityIndicators.tdmReady:true
date         : 2021-11-14
total        : 1637
[ISTEX]
ark ark:/67375/M70-9CX29DZR-V
ark ark:/67375/HXZ-67HRRHPS-3
ark ark:/67375/M70-WNXRTHFX-N
ark ark:/67375/HXZ-JH8KXX4Z-6
ark ark:/67375/HXZ-261385NS-R
ark ark:/67375/M70-VMG3Z3HN-R
ark ark:/67375/M70-HVD46B9M-7
ark ark:/67375/HXZ-2MPFG98H-3
ark ark:/67375/HXZ-FR79KGQX-K
ark ark:/67375/HXZ-0SXPBHW7-T
```

Istex-DL : partager son corpus

Un corpus à l'identique via les fichiers **.corpus**

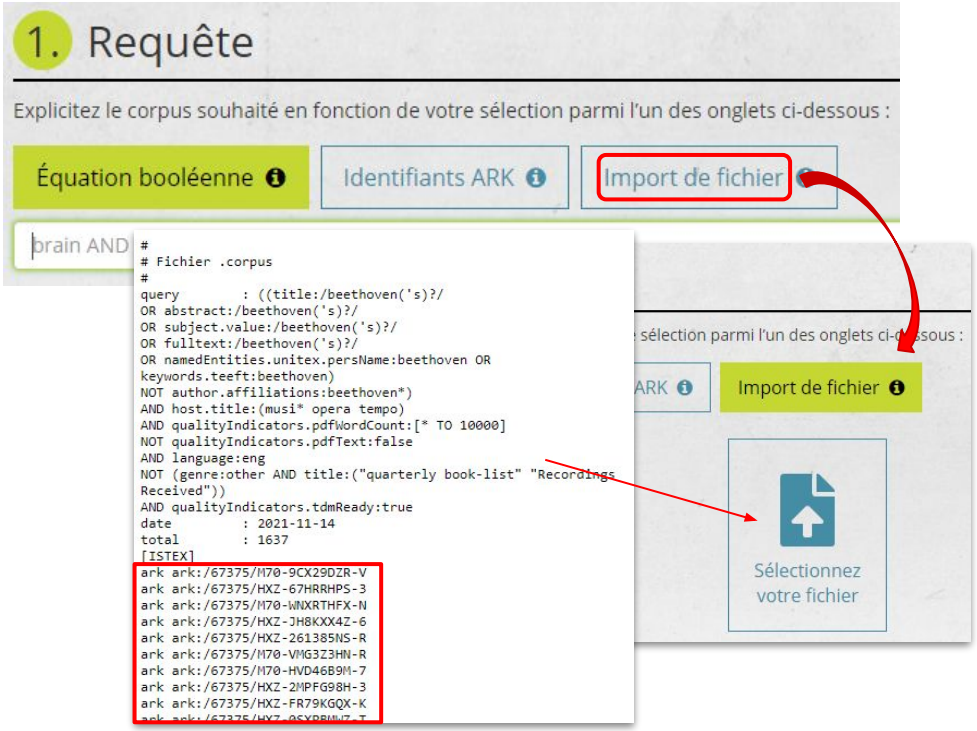

Istex-DL : partager son corpus

Un corpus à l'identique via les identifiants **ARK**

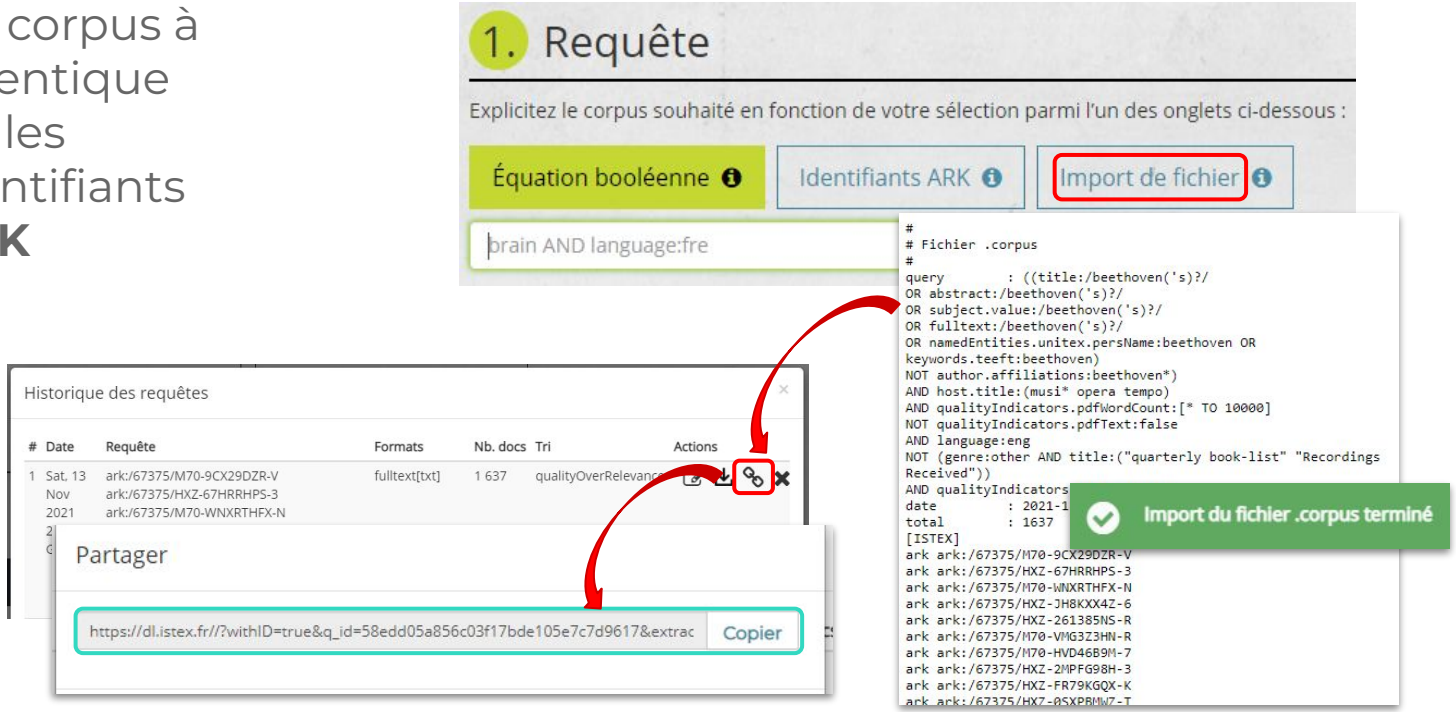

Istex-DL : partager son corpus

Un corpus à l'identique via les identifiants **ARK**

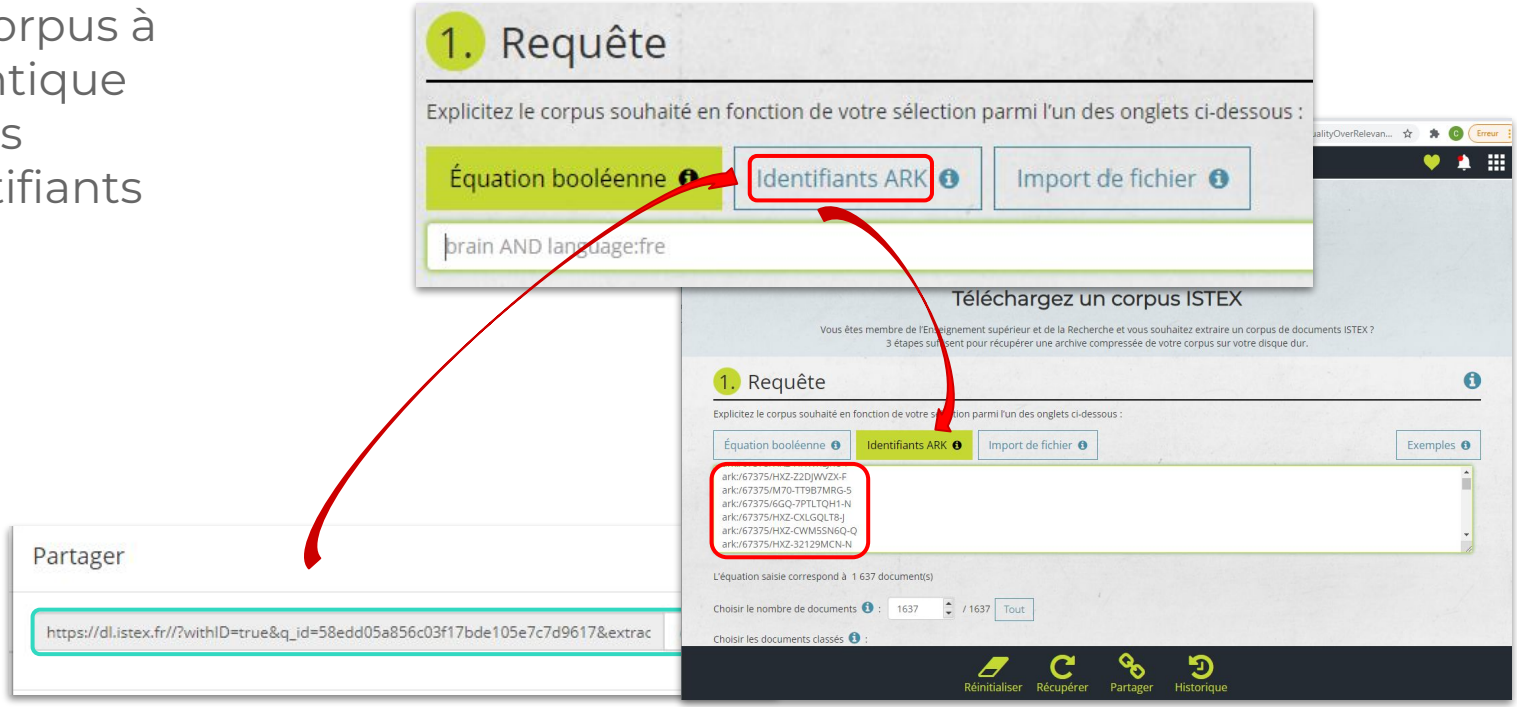

3.

Des corpus prêts à l'emploi

… avec data.istex

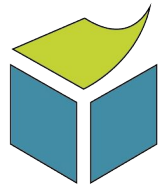

Une autre vision sur les données Istex

DATA.ISTEX

https://www.istex.fr/

https://data.istex.fr/

Des corpus scientifiques

DATA.ISTEX

Des exemples de corpus spécialisés

BEETHOVEN

https://beethoven-collection.corpus.istex.fr

Corpus thématique à visée pédagogique

1864 documents

ENTITÉS NOMMÉES "NOM DE PERSONNE" (UNITEX)

Richard Strauss, Wilhelm Broel, Max Unger, Hugo von Hofmannsthal, Stephen Ley, Willy Hess, Beethoven, Hans von Biilow, Willi Schuh, Mies, Friedrich Munter, M. M. S. Beethoven, Philipp Losch

PUBLICATIONS SIMILAIRES (ENTITÉS NOMMÉES)

NOTE

Représentation des dix publications ayant le plus d'entités nommées de type "nom ... vec cette ressource

TALN 2020 : Vers un corpus optimal pour la fouille de textes : stratégie de constitution de corpus spécialisés à partir d'Istex (C. de Salabert, S. Barreaux)

Des exemples de corpus spécialisés

ANIMALIA 100 https://systematique-animal100.corpus.istex.fr

Corpus enrichi automatiquement

- Annotation **entités nommées scientifiques** (espèces animales)
- Ajout de leur **classification systématique**

100 documents

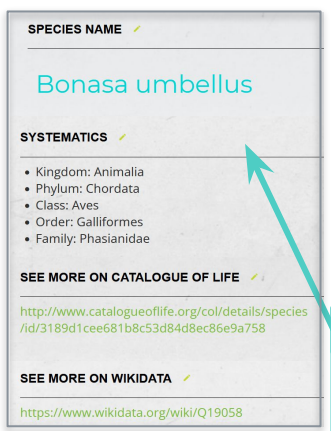

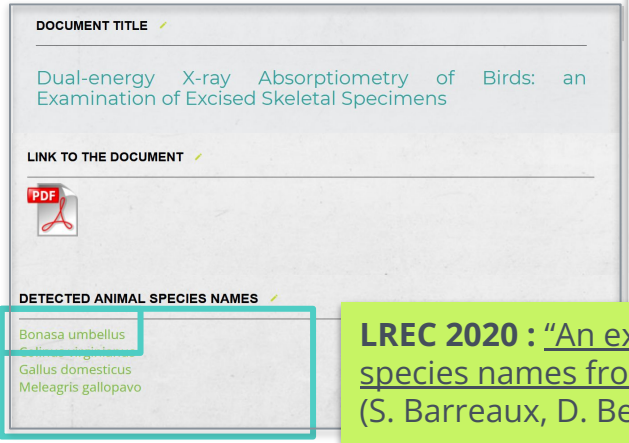

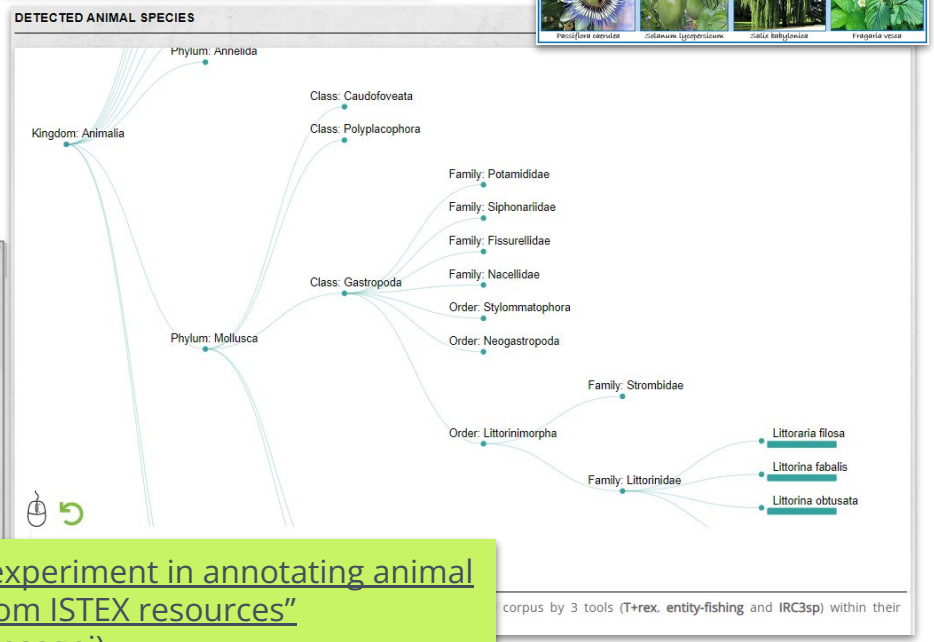

LREC 2020 : "An experiment in annotating animal species names from ISTEX resources"
(S. Barreaux, D. Besagni)

Des exemples de corpus spécialisés

EN-ISTEX

https://gold-enistex.corpus.istex.fr

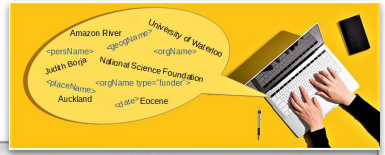

Corpus enrichi manuellement

- Annotation **entités nommées**
- Fiabilité mesurée par un **accord inter-annotateur**

200 documents

APPLICATION

Outil de reconnaissance d'entités nommées dans le texte intégral.

Les fichiers TEI présents sur l'API d'ISTEX étant susceptibles de changements au fil de l'évolution du fonds ISTEX, ils sont donnés ici tels qu'ils étaient au moment du calcul des offsets des entités nommées.

- Le corpus au format XML-TEI est téléchargeable ici
- Les offsets des entités nommées pour chaque document sont téléchargeables ici
- Le guide d'annotation spécifique à ce corpus est téléchargeable ici

Mise à disposition du **guide d'annotation** & de

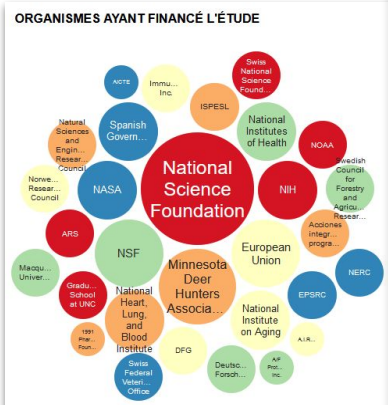

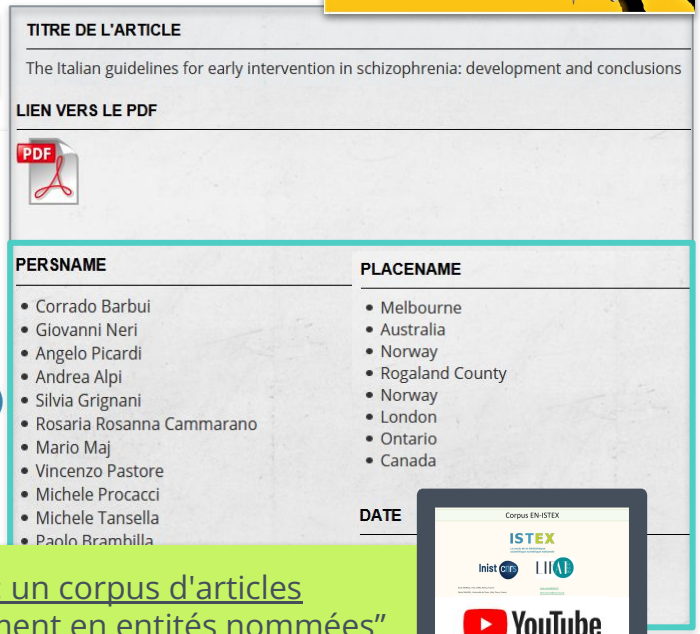

TALN 2021 : "Corpus EN-ISTEX : un corpus d'articles scientifiques annoté manuellement en entités nommées" (E. Morale, D. Maurel, J. Villaneau, J.-Y. Antoine)

Des corpus à télécharger

4.

Outils TDM

https://tmtools-explorer.tdm.inist.fr/

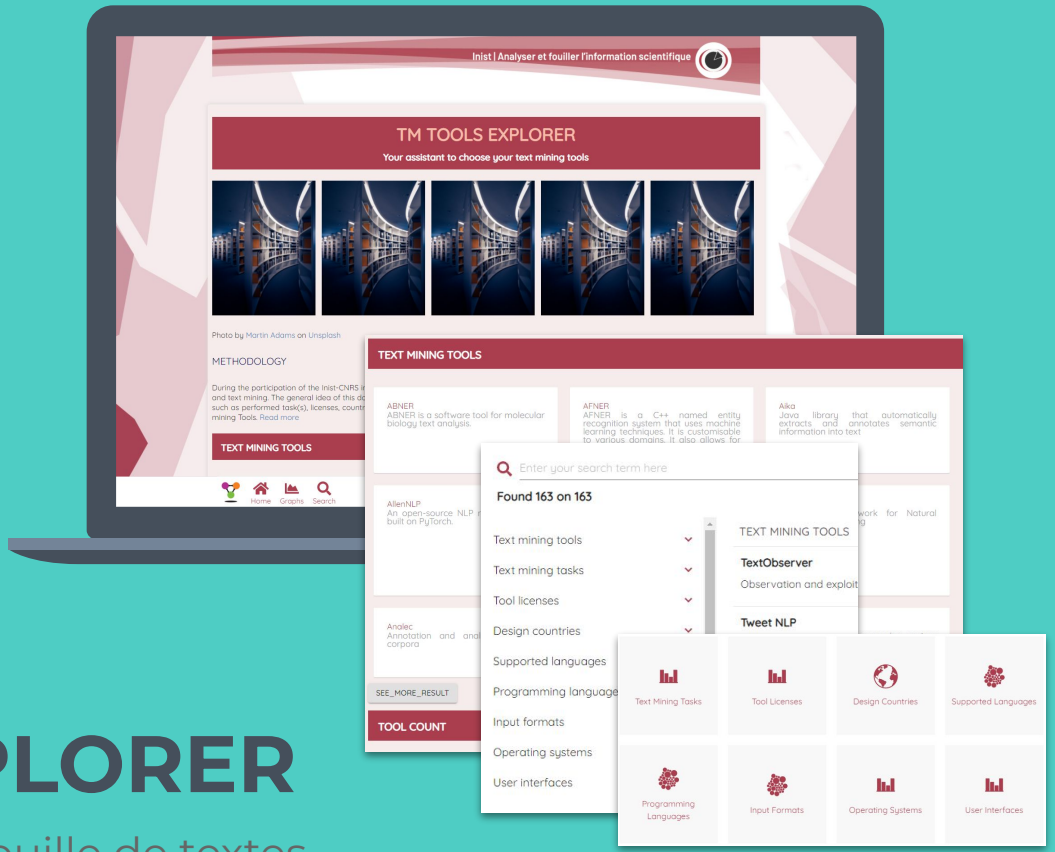

TM TOOLS EXPLORER

Inventaire d'outils libres de fouille de textes

5.

Liens utiles

Adresses & Co

Se connecter :

- ISTEX : **http://www.istex.fr**
- Démonstrateur ISTEX : **http://demo.istex.fr/**
- Application ISTEX-DL : **https://dl.istex.fr/**
- Données ISTEX : **https://data.istex.fr/**
- Infos Lodex : **https://lodex.inist.fr/**
- TM Tools Explorer : **https://tmtools-explorer.tdm.inist.fr/**

S’authentifier :

- Vérifier ses droits d’accès : **https://api.istex.fr/auth**
- Vérifier son accès par fédération d’identité : **https://api.istex.fr/auth?auth=fede**

Documentation & Tutoriels

Se documenter :

- Documentation Usage TDM d'ISTEX : **https://doc.istex.fr/tdm/**
- Documentation API ISTEX : **https://doc.istex.fr/api/**
- Documentation LODEX : **https://user-doc.lodex.inist.fr/**

Se former :

- Tutos API ISTEX & ISTEX-DL : **https://istex-tutorial.data.istex.fr/**
- Tutos LODEX : **https://user-tutorials.lodex.inist.fr/**

Informations & Contact

Se tenir informé :

- Article d'actualité : **https://www.istex.fr/category/actualites/**
- Plateforme Twitter : **@ISTEX_Platform**

Chercher de l'aide / Contribuer à l'amélioration :

- Contact :
  - Via le formulaire : **https://www.istex.fr/contact/**
  - Via la liste : **contact@listes.istex.fr**
- Liste de discussion (publique) : **users@listes.istex.fr**

Merci !

Des questions ?