

Webarchivierung an der Französischen Nationalbibliothek

Bert Wendland

Bibliothèque nationale de France

bert.wendland@bnf.fr

Wer ich bin / wer wir sind

- > Bert Wendland
 - > crawl engineer in der IT-Abteilung der BnF
- > gemeinsame Arbeitsgruppe
 - > Legal-Deposit-Abteilung, Service „Dépôt légal numérique (DLnum)“
 - > 1 Service-Leiter
 - > 2 Bibliothekare
 - > 2 Dokumentare
 - > IT-Abteilung
 - > 1 Projektkoordinatorin
 - > 1 Software-Entwickler
 - > 2 Crawl-Ingenieure
- > ein Komitee von 80 Bibliothekaren aus den Fachabteilungen

Kontext

Die BnF und Web-Archivierung
als Teil ihres Sammelauftrags

Die BnF

- > Bibliothèque *nationale* de France
- > ca. 30 Millionen Bücher, Periodika und anderes
 - > 10 Mio. am neuen Standort
 - > jährlich 60.000 neue Medien
 - > ca. 550 TB Daten im Web-Archiv
 - > jährlich 100 TB neue Daten
- > zwei Standorte
 - > alter Standort « Richelieu » im Pariser Zentrum
 - > neuer Standort « François-Mitterrand » seit 1996
- > zwei Ebenen am neuen Standort
 - > Studienbibliothek (« Haut-de-jardin »): Freihandbestand
 - > Forschungsbibliothek (« Rez-de-jardin »): Zugriff zum Gesamtbestand, einschließlich Web-Archiv



Frankreich und die Pflichtexemplare

- 1368 königliche Manuskriptsammlung von Karl V. im Louvre
- 1537 Franz I.: Pflichtabgabe – alle Herausgeber müssen ein Exemplar ihrer Produktion der königlichen Bibliothek überlassen
- 1648 Pflichtabgabe erweitert auf Karten und Pläne
- 1793 Musikpartituren
- 1925 Fotos und Schallplatten
- 1975 Videoaufnahmen
- 1992 CD-ROMs und elektronische Ausgaben
- 2002 Websites (experimental)
- 2006 Websites (produktiv)



Erweiterung des DADVSI am 1. August 2006


- > « Droit d'auteur et droits voisins dans la société de l'information »
Französisches Urheberrechtsgesetz
- > Umfang (Artikel 39)
« Sont également soumis au dépôt légal les signes, signaux, écrits, images, sons ou messages de toute nature faisant l'objet d'une communication au public par voie électronique. »
- > Bedingungen (Artikel 41 II)
« Les organismes dépositaires procèdent à la collecte des signes, signaux, écrits, images sons ou messages de toute nature mis à la disposition du public ou de catégories de public, ... Ils peuvent procéder eux-mêmes à cette collecte selon des procédures automatiques ou en déterminer les modalités en accord avec ces personnes. »
- > Zuständigkeiten (Artikel 50)
INA (Institut national de l'audiovisuel) für Websites von Radio und TV
BnF für alles andere
- > Webharvests ohne besondere Erlaubnis, aber Zugriff zum Archiv beschränkt auf Lesesäle
- > Ziel: nicht das ganze frz. Internet, auch nicht „das Beste vom Web“, sondern einen repräsentativen Querschnitt zu einem bestimmten Datum

Konzept

Wie wir das französische
Web speichern

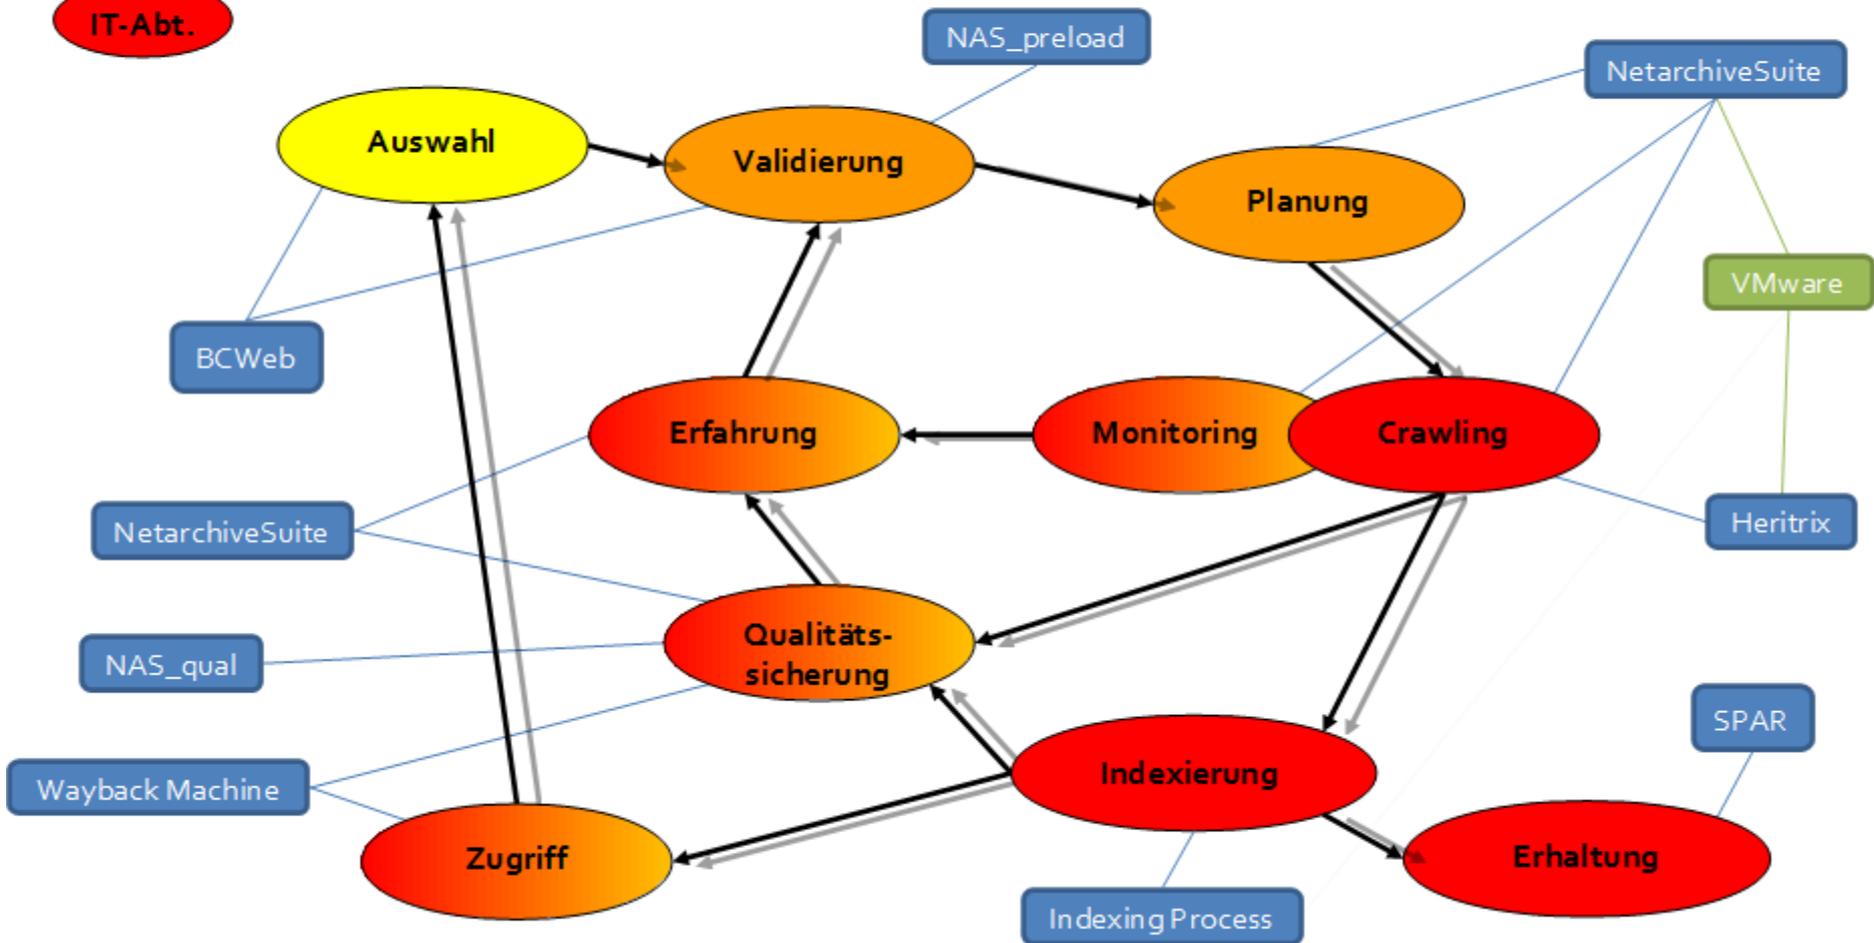
Partnerschaft BnF – Internet Archive

- > fünf Jahre zwischen 2004 und 2008
 - > danach weitere Zusammenarbeit im Rahmen des IIPC (International Internet Preservation Consortium)
- > Daten
 - > 5 broad crawls und 2 focused crawls im Auftrag der BnF
 - > Extraktion von historischen Alexa-Daten zu .fr rückwirkend bis 1996
- > Technologie
 - > Heritrix
 - > Wayback Machine
 - > 5 Petaboxen
- > Know-how
 - > Installation der Petaboxen durch Ingenieure des IA
 - > Anwesenheit eines crawl engineers einen Tag pro Woche für 6 Monate



Produktionszyklus

- Bib.
- DLnum
- IT-Abt.



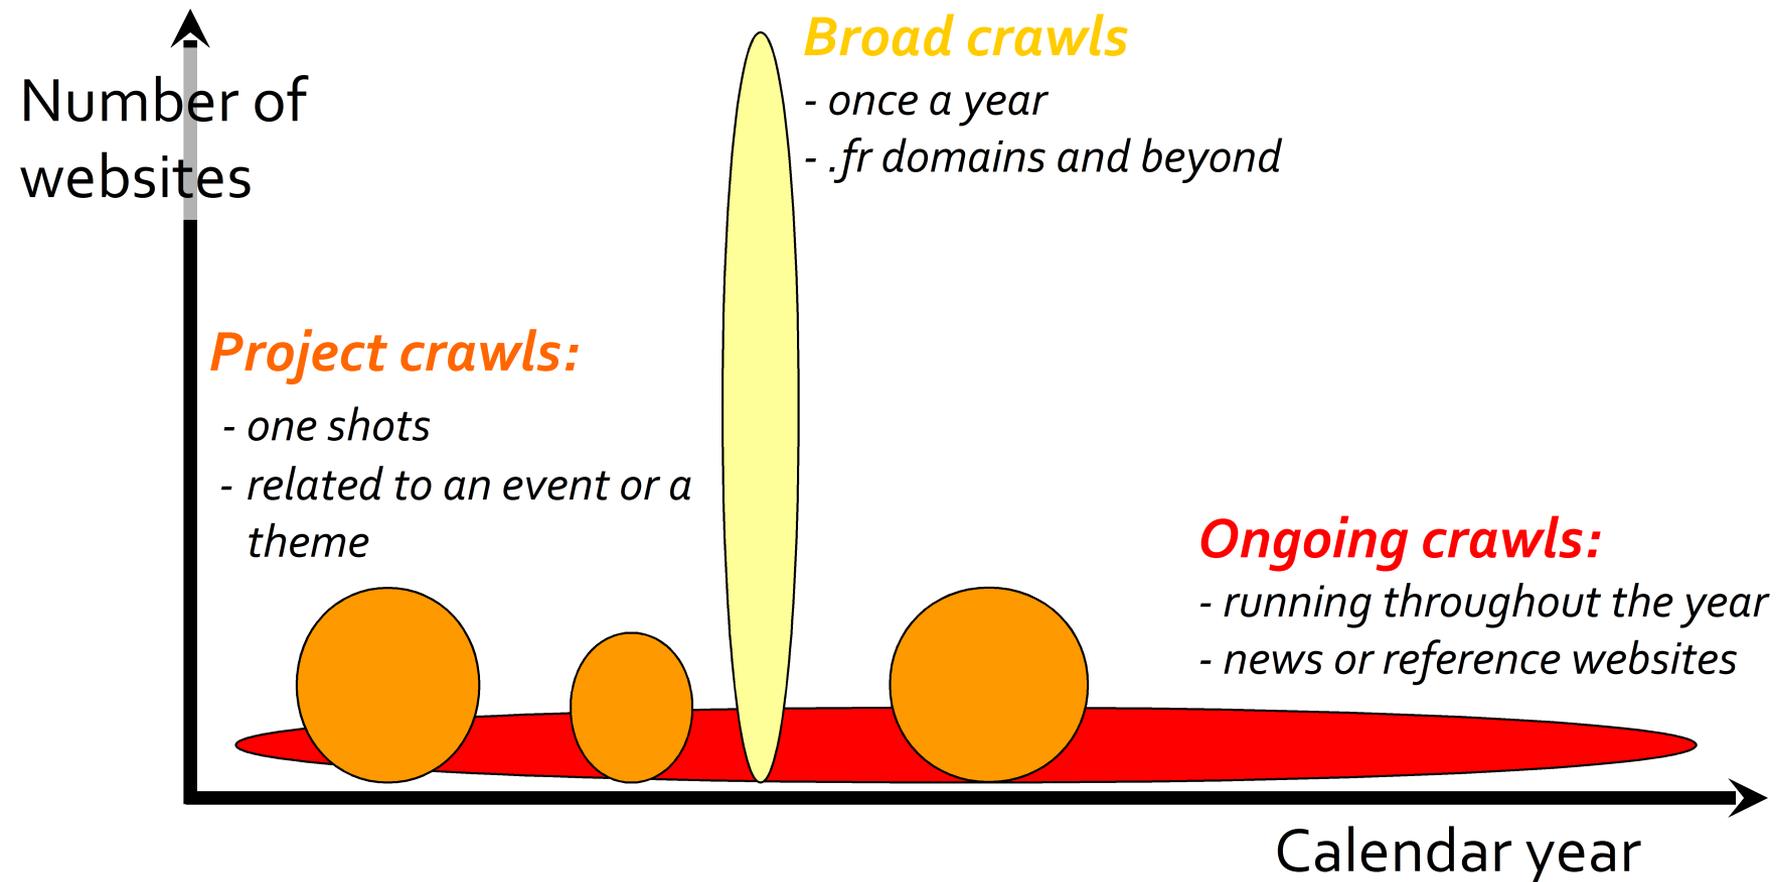
Herausforderungen

- > Was ist das *französische Web*?
 - > nicht nur .fr/.re/.nc, auch .com und .org
- > einige Daten schwierig zu harvesten
 - > Streaming, Datenbanken, Videos, JavaScript
 - > dynamische Webseiten
 - > Paßwort-geschützte Inhalte
 - > Erfolge durch komplexe Konfigurationen, u.a.
 - > Dailymotion
 - > Online-Ausgaben im Abonnentenbereich von Zeitungen

Datenakquisition

Unser gemischtes Modell
des Web harvesting

BnF "mixed model" of harvesting



Broad crawl

Aggregation verschiedener Quellen

- > 2013:
 - > 2,7 Mio. domains in .fr und .re, geliefert von AFNIC (*Association française pour le nommage Internet en coopération* – französische Registrierungsorganisation)
 - > 3500 domains in .nc, geliefert von OPT-NC (*Office des postes et télécommunications de Nouvelle-Calédonie* – Registrierungsorganisation von Neukaledonien)
 - > 1,6 Mio. domains, geliefert von OVH (privater frz. Internetdienstleister)
 - > 3,2 Mio. domains aus der Produktions-Datenbank
 - > 11000 domains durch URL-Selektion von Bibliothekaren der BnF
 - > 7800 domains aus anderen Geschäftsgängen der Bibliothek, die URLs als Teil der Metadaten enthalten: Verlagsdeklarationen für Bücher und Periodika, der Katalog der BnF, Identifikation neuer Periodika durch Bibliothekare, Online-Publizierung ehemaliger Print-Periodika, ...
- > nach Deduplikation eine Liste von 4,0 Mio. eindeutigen domains

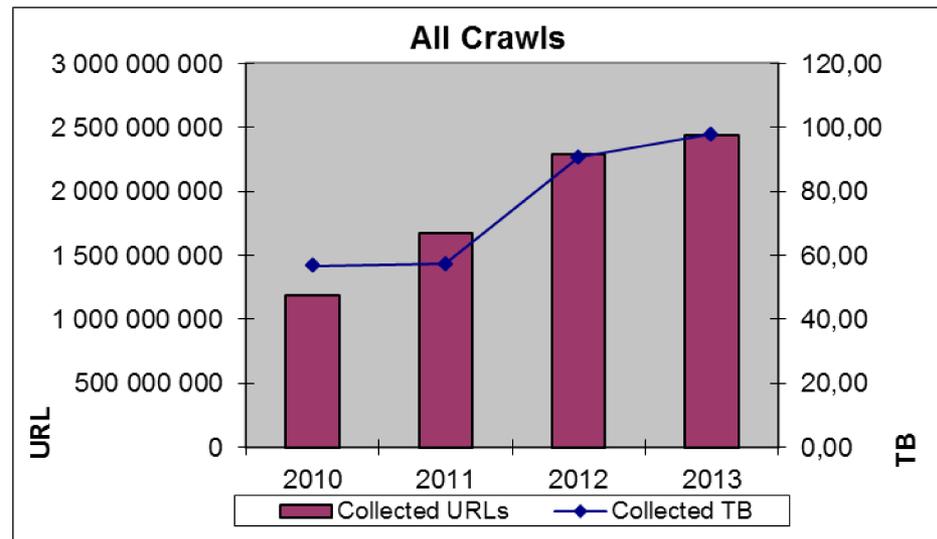
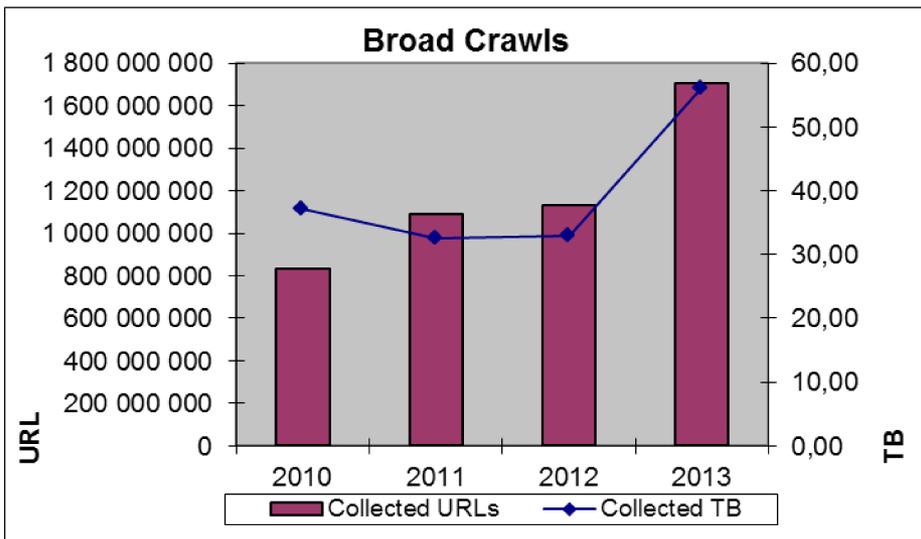
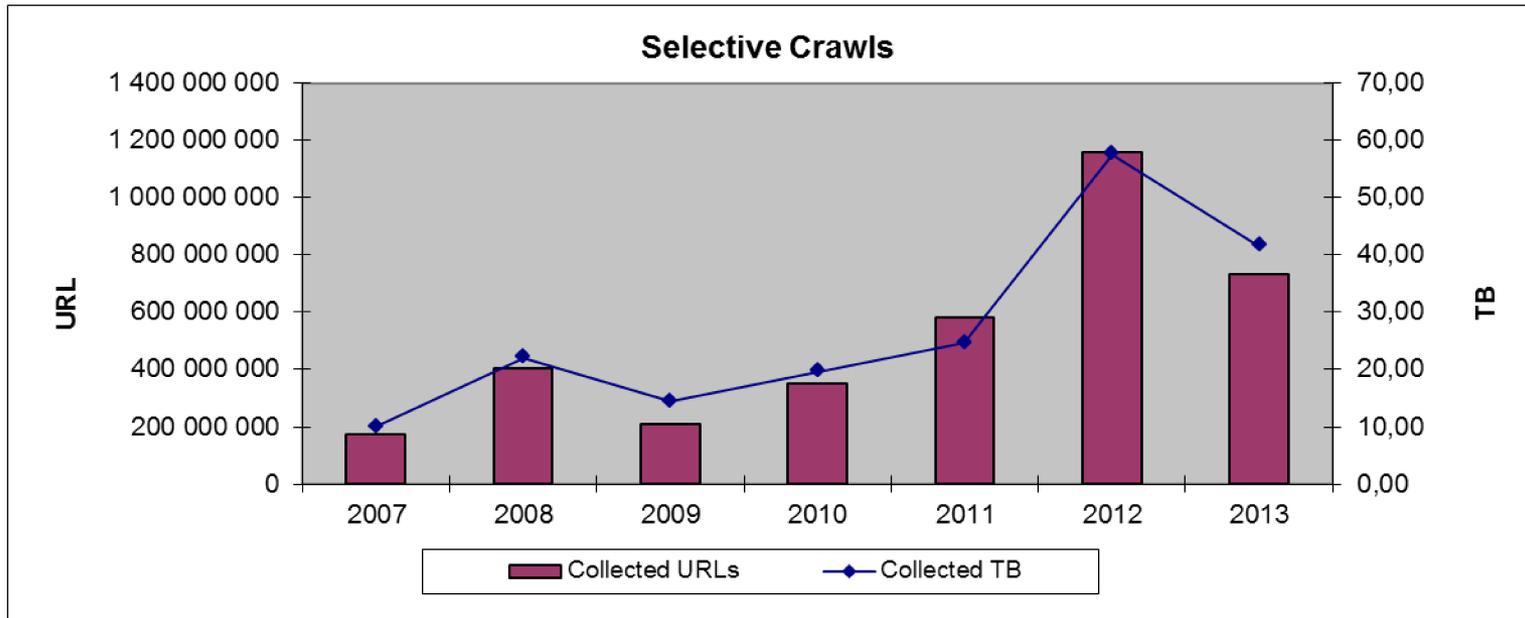
Der broad crawl 2013 in Zahlen

- Start-Domains: 4.014.595
 - max. URLs pro domain: 2300
 - Dauer: 10 Wochen
 - parallele Crawler-Instanzen: 50
 - threads pro crawler: 200
 - gespeicherte URLs: 1.703.800.806
 - ARC-Files (à ca. 100 MB): 551.177
 - Datenvolumen (komprimiert): 56,2 TB
-
- TLDs: 299, davon 43,6 % .fr, 39,9 % .com, ..., 0,8 % .de
 - URLs pro domain: 49,8 % < 10, 45,5 % 10..2300, 4,7 % > 2300
 - Statuscodes: 80,4 % 2XX, 11,4 % 4XX

Datenvolumen

- > Neun broad crawls seit 2004
- > einige Zehntausend focus-crawled websites seit 2002
- > 1996-2005 Internet Archive, seit 2006 BnF
- > Gesamtgröße
 - > 25 Milliarden URLs
 - > 550 Terabyte

Datenvolumen



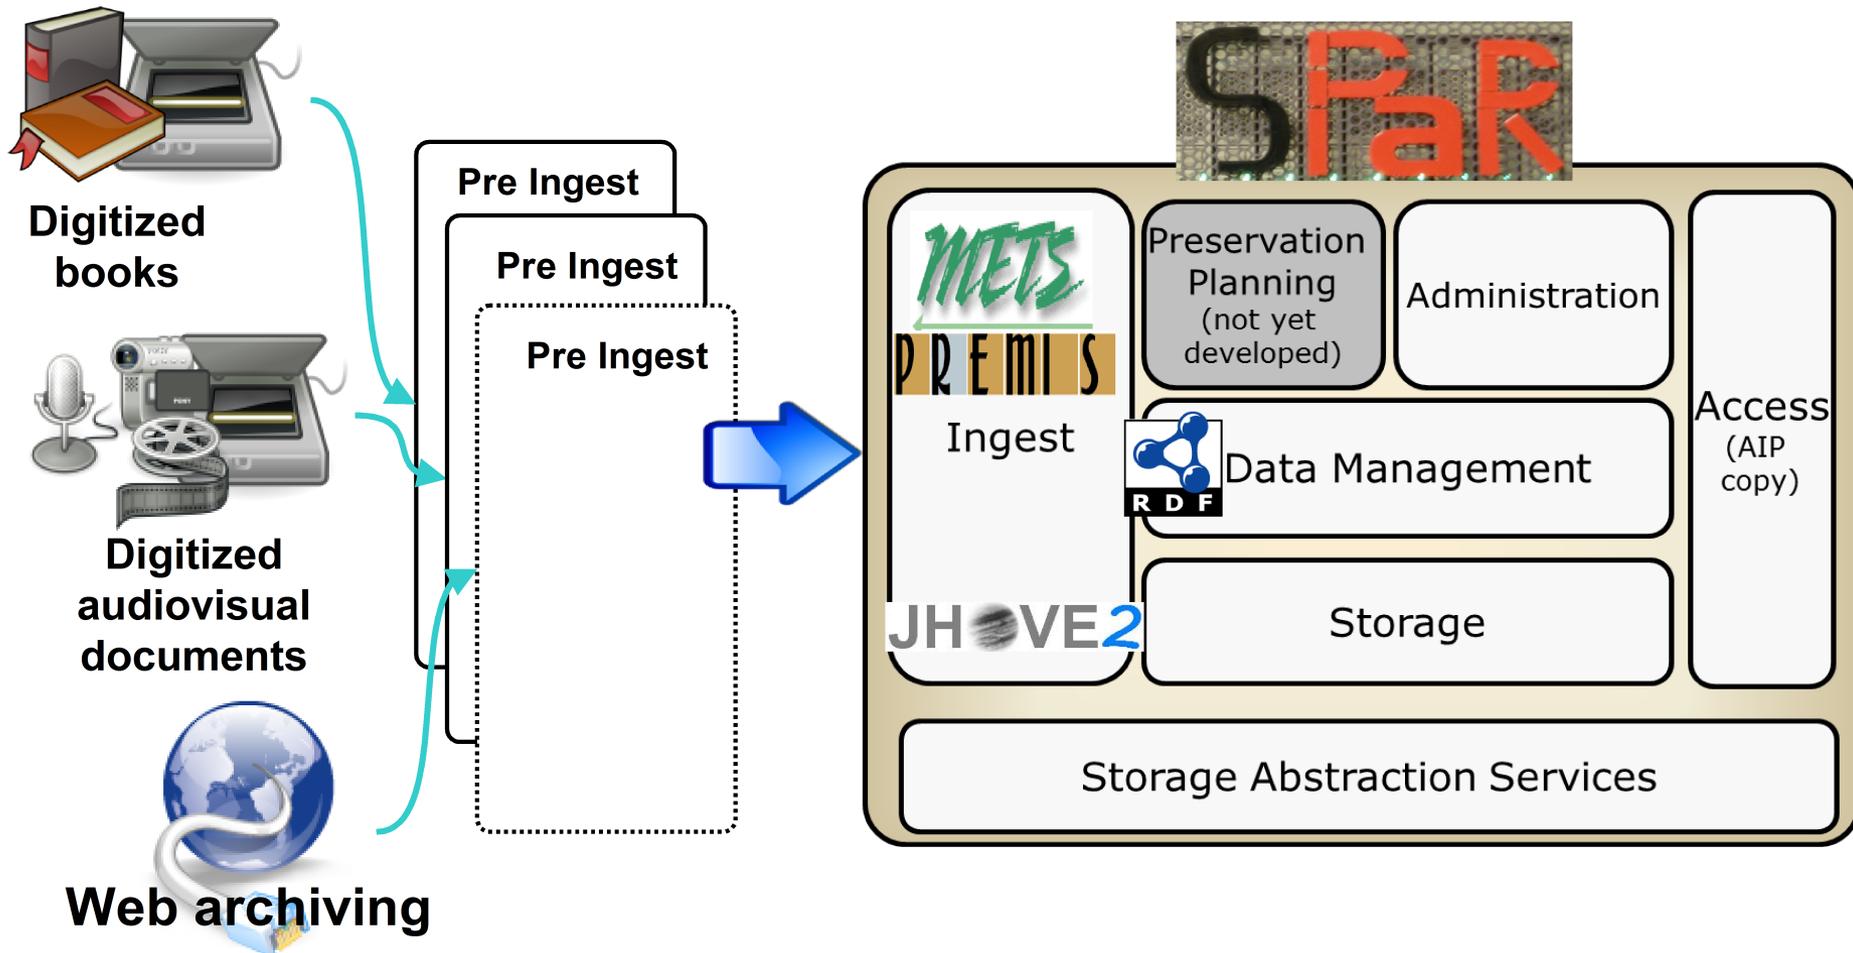
Archivierung und Zugriff

Wie wir die Daten erhalten
und die Nutzer darauf zugreifen

SPAR

Systeme de Pr6servation et d'Archive R6parti

Langzeitarchivierungssystem f6ur digitale Objekte, konform dem OAIS-Standard (Open Archival Information System), ISO 14721



SPAR

Das digitale Langzeitarchiv der BnF



Nutzerzugang zum Archiv

- > angepaßte Version der open-source Wayback Machine
- > drei Zugangswege:
 - > URL-Suche
 - > experimentelle Volltext-Suche über NutchWAX
 - > im Moment für 10% des Archivs
 - > parcours guidés (geführte Touren)
 - > Auswahl aus dem Archiv, redaktionell aufbereitet durch Bibliothekare der BnF und externe Partner
 - > nutzerfreundliches Interface zur Erschließung des Archivinhalts
 - > Sichtbarkeit der thematischen harvests



Outils : Recherche par URL | Recherche par mot | Parcours guidés |

Les archives sont constituées de sites internet du domaine français archivés de 1996 à aujourd'hui.

à propos des archives de l'internet...



Recherche par URL

Retrouver un site, une page, un fichier en indiquant son adresse internet (exemple : <http://www.ihpt.cnrs.fr>).

Remonter le temps Recherche avancée

Option

Limiter la recherche à cette année :



Recherche par mot

Retrouver ces mots dans la partie indexée des archives (environ 5%, documents archivés en nov-déc 2006 et 2007).

Rechercher Recherche avancée

Possibles :

- une expression : "Louis XIV"
- un mot sur un site : site:www.francegenweb.org Bretagne



Parcours guidés

Tous les parcours ...

Découvrir le contenu des archives et se familiariser avec les outils de recherche et de consultation.

Presse et actualité

Le web est un vecteur majeur de diffusion de l'information : les sites de presse et d'actualité font par conséquent l'objet d'un traitement spécifique par le dépôt légal de l'internet. Ses archives proposent un accès particulier aux contenus gratuits ou réservés aux abonnés, mis en ligne par les principaux sites nationaux et régionaux. Les collections les plus anciennes permettent d'étudier la naissance du web d'information, tandis que les plus récentes, à partir de 2010, donnent accès à une centaine de titres capturés quotidiennement.



Carnets de voyage : le monde au bout des doigts

Les carnets de voyage, forme ancienne sur papier, peuvent être aussi divers que les voyages qu'ils racontent. L'internet prolonge les pratiques existantes et apporte de nouvelles



accueil | aide



Archives de l'internet



Outils : Recherche par URL | Recherche par mot | Parcours guidés |

Retrouver ce site ou cette page :

[Remonter le temps](#)

Option

Limiter à :

- -



Recherche par URL

5.842 résultats

pour : <http://www.lemonde.fr>

du 1 jan. 1996 au 25 juin 2014

[ouvrir tout](#) | [fermer tout](#)

2014 425 résultats ▶

2013 1.784 résultats ▶

2012 1.679 résultats ▶

2011 1.173 résultats ▶

2010 369 résultats ▶

2009 59 résultats ▼

| jan. | fév. | mar. | avr. | mai | juin | jui. | août | sep. | oct. | nov. | déc. |
|------|------|------|------|-----|------|------|------|------|------|------|------|
| 26 | 2 | 2 | 7 | 4 | 2 | | | 24 | 3 | | 14 |
| 27 | 5 | 4 | 9 | 6 | 3 | | | 25 | 5 | | |
| | 9 | 5 | 14 | 7 | 8 | | | 30 | | | |
| | 17 | 7 | 21 | | 9 | | | | | | |
| | 18 | 9 | 23 | | | | | | | | |
| | 24 | | 26 | | | | | | | | |
| | 25 | | | | | | | | | | |
| | 26 | | | | | | | | | | |

2008 67 résultats ▶

2007 206 résultats ▶

2006 13 résultats ▶

TYPE
html
/EN*
11-
html"
head
30-
type"
meta
Mac
r Mac
_org"
world
uter,
wide,
vide,
chno-
-Lee,
ding,
DOM,
tree,
meta
wide
local
one, a
work
a W3C
gh the
lines
of the
ers of
y the
ntai-
USA,
infor-
arte-
Japan,
wide"
to be
Tech

Page archivée le : 26 Janvier 2009 à 18:27 GMT
 Permalien :
<http://archivesinternet.bnf.fr/2009012/>

Capture 354 sur 5.842

Recherche rapide :

 OK
[accueil](#) | [recherche initiale](#)

Actualités

Le Monde.fr

Mise à jour à 19h23 - Paris

Le Monde.fr | le web avec **YAHOO!** Recherche sur Le Monde.fr

Recevez les newsletters gratuites

Abonnez-vous au journal

Le Monde : 16€/mois

ACTUALITÉS PERSPECTIVES PRATIQUE ANNONCES **LE DESK** **LE KIOSQUE** NEWSLETTERS MULTIMÉDIA RÉFÉRENCES **S'abonner au Monde.fr - 6€ / mois**

International Planète Europe Politique Société Carnet Economie Médias Sports Technologies Culture L'économie en crise La guerre de Gaza



Tempête : l'état de catastrophe naturelle pourrait être déclaré mardi

6

De son côté la Commission européenne s'est dite prête à actionner le Fonds de solidarité européen.

"La mobilisation est générale pour les assurances françaises"
La France à l'âge du feu



Les "désobéisseurs pédagogiques" interpellent Darcos

Cent-cinquante professeurs demandent au ministre le retrait du dispositif d'aide personnalisée aux élèves en difficultés.

Sri Lanka : vers la fin d'une guerre de trente ans ?

LES DÉPÊCHES Toutes les dépêches

- 19:10 Jérôme Kerviel devrait être jugé en 2010, sans ses supérieurs Reuters
- 19:01 Le musée d'Auschwitz veut créer un fonds de 100 M EUR pour préserver le site AFP
- 18:45 Journalistes et avocat tués en Russie: il faut une "véritable enquête" (Unesco) AFP
- 18:44 France Télévisions candidat aux droits de la Coupe de la Ligue (Bilalian) AFP

EDITION ABONNÉS : 70 fils de dépêches thématisés

VOS RÉACTIONS

“ C'est l'arroseur arrosé !!! TF1, qui avait si bien théorisé la fin de la pub (pour son plus grand profit) dans un livre blanc sur mesure pour le président, réclame à cors...

Alex sur La fin de la publicité sur les chaînes publiques ne profite pas à TF1 ni à M6 53

TEMPÊTE

A découvrir

Météo **Bourse**

"Le Monde" fait peau neuve
 Aujourd'hui, découvrez la nouvelle maquette du quotidien "Le Monde" en kiosque ou avec le Journal Electronique.
 En savoir plus

Les blogs invités

- ▶ **Abalo le Coréen**
LES "EXPERTS" : CROATIE
- ▶ **Pour Gaëtan Gorce, s'opposer c'est négocier...**
PUZZLE SOCIALISTE
- ▶ **"Je suis plutôt inquiet pour 2011 et 2012"...**
ENGRENAGES
- ▶ **Nouvel an chinois**
L'ACTU EN PATATES
- ▶ **United States of Tara - Moi, elle, lui et elle**
LE MONDE DES SÉRIES



Outils : Recherche par URL | Recherche par mot | Parcours guidés |

Les archives sont constituées de sites internet du domaine français archivés de 1996 à aujourd'hui.

à propos des archives de l'internet...



Recherche par URL

Retrouver un site, une page, un fichier en indiquant son adresse internet (exemple : <http://www.ihpt.cnrs.fr>).

Remonter le temps

Recherche avancée

Option

limiter la recherche à cette année :



Recherche par mot

Retrouver ces mots dans la partie indexée des archives (environ 5%, documents archivés en nov-déc 2006 et 2007).

Rechercher

Recherche avancée

Possibles :

- une expression : "Louis XIV"
- un mot sur un site : site:www.francegenweb.org Bretagne



Parcours guidés

Tous les parcours ...

Découvrir le contenu des archives et se familiariser avec les outils de recherche et de consultation.

Presse et actualité

Le web est un vecteur majeur de diffusion de l'information : les sites de presse et d'actualité font par conséquent l'objet d'un traitement spécifique par le dépôt légal de l'internet. Ses archives proposent un accès particulier aux contenus gratuits ou réservés aux abonnés, mis en ligne par les principaux sites nationaux et régionaux. Les collections les plus anciennes permettent d'étudier la naissance du web d'information, tandis que les plus récentes, à partir de 2010, donnent accès à une centaine de titres capturés quotidiennement.



Carnets de voyage : le monde au bout des doigts

Les carnets de voyage, forme ancienne sur papier, peuvent être aussi divers que les voyages qu'ils racontent. L'internet prolonge les pratiques existantes et apporte de nouvelles



Archives de l'Internet



Outils : Recherche par URL | Recherche par mot | Parcours guidés |

Retrouver les occurrences de ces mots :

Possibles :

- une expression : "Louis XIV"
- un mot sur un site : site:www.francegenweb.org Bretagne

Recherche par mot

13318089 résultats

pour : "le monde"

résultats 1 à 10 - par page

Bonjour tout le monde ! - eureka

<http://albin.unblog.fr/2006/11/08/bonjour-tout-le-monde/>

... Bonjour tout **le monde** ! - eureka eureka Bienvenue sur mon blog Accueil A propos Que tout **le monde** y trouve quelque chose navigation Bonjour tout **le monde** ! 8 novembre, 2006 Posté par albin dans : Non classé , [trackback](#) Bienvenue sur Unblog.fr . Ceci est votre premier article. Editez ... commentaires, identifiez vous et affichez les commentaires de votre blog, et vous pourrez l'effacer. Ce formulaire est protégé contre **le** ...

Archive du 29/11/2006 à 01:08 | autres dates

html - 19 Ko

Commentaires sur Bonjour tout le monde !

<http://accesmodeintime.unblog.fr/2006/09/08/bonjour-tout-le-monde/feed/>

... Commentaires sur Bonjour tout **le monde** ! <http://accesmodeintime.unblog.fr/2006/09/08/bonjour-tout-le-monde/> Bienvenue sur **le** blog harmonie intime entre adultes consentants dont la devise est " un(e) pour tous & tous pour un(e) " interdit ... 01:12:02 +0000 <http://wordpress.org/?v=MU> par : Admin <http://accesmodeintime.unblog.fr/2006/09/08/bonjour-tout-le-monde/#comment-1> Fri, 08 Sep 2006 12:09:43 +0000 <http://accesmodeintime.unblog.fr/2006/09/08/bonjour-tout-le-monde/> ...

Archive du 29/11/2006 à 02:11 | autres dates

xml - 1 Ko

Broc collection - Le monde du reduit et de la collection

http://boutique.broc-collections.fr/epages/ce_fr.sf/secrdZCvGMcgOc/?ViewAction=ViewContactForm&ObjectPath=/Shops/155816

... Broc collection - **Le monde** du reduit et de la collection Broc collection **Le monde** du reduit et de la collection Page d'accueil Coordonnées Nous contacter Conditions générales de vente Informations client Politique de ... Adresse e-mail * Sujet * Message * * champs requis Panier 12 Produits 176,30 € Colissimo 6,50 € Montant total 182,80 € Afficher **le**

Archive du 18/10/2007 à 15:20 | autres dates

html - 11 Ko

Forum le monde de la magie blanche

<http://96334.aceboard.fr/recherche.php?login=96334>

... Forum **le monde** de la magie blanche FORUM , Forum Discussion , Forum Gratuit , Nom de domaine , Nom de domaine gratuit , Redirection gratuite , Administrateurs : lune ... en ligne : 1 inconnu visite **le** forum Inscription | Profil | Messages Privés | Recherche | Online | Aide | Créer un blog gratuit Recherche sur



Outils : Recherche par URL | Recherche par mot | Parcours guidés |

- Tous les parcours
- Presse et actualité
- Carnets de voyage : le monde au bout des doigts
- L'administration en ligne : le web au service des citoyens
- Images amateurs, amateurs d'images
- La révolution tunisienne à travers le web
- Le web vert : les politiques du développement durable
- Le web militant
- (S') écrire en ligne : journaux personnels et littéraires
- Cliquer, voter : l'internet électoral



Parcours guidés

Mis à jour le 15/06/2012

Tous les parcours

Les parcours guidés permettent de découvrir le contenu des archives et se familiariser avec les outils de recherche et de consultation.

Presse et actualité

Créé le 21/11/2013

Le web est un vecteur majeur de diffusion de l'information : les sites de presse et d'actualité font par conséquent l'objet d'un traitement spécifique par le dépôt légal de l'internet. Ses archives proposent un accès particulier aux contenus gratuits ou réservés aux abonnés, mis en ligne par les principaux sites nationaux et régionaux. Les collections les plus anciennes permettent d'étudier la naissance du web d'information, tandis que les plus récentes, à partir de 2010, donnent accès à une centaine de titres capturés quotidiennement.



Carnets de voyage : le monde au bout des doigts

Créé le 24/06/2014

Les carnets de voyage, forme ancienne sur papier, peuvent être aussi divers que les voyages qu'ils racontent. L'internet prolonge les pratiques existantes et apporte de nouvelles possibilités : visibilité accrue, immédiateté et interaction, variété de médias. Tout en insistant sur les carnets novateurs, ce parcours guidé propose un échantillon qui se veut représentatif et montre comment les voyageurs se sont approprié le web pour renouveler le genre.





Tous les parcours

Presse et actualité

Carnets de voyage : le monde au bout des doigts

L'administration en ligne : le web au service des citoyens

Images amateurs, amateurs d'images

La révolution tunisienne à travers le web

Le web vert : les politiques du développement durable

Le web militant

(S') écrire en ligne : journaux personnels et littéraires

Cliquer, voter : l'internet électoral



Parcours guidé

Carnets de voyage : le monde au bout des doigts

Avec qui voyager ?

Avant de raconter son voyage, il faut l'organiser : décider d'une destination, d'un mode de transport, préparer ou improviser son itinéraire et son mode de vie une fois sur place, mais aussi proposer à une autre « personne » de participer au voyage... ou pas.

Parmi les sites ou blogs sélectionnés sur le web, il faut distinguer les blogueurs qui partent à plusieurs : en famille, en couple comme des jeunes mariés ou avec une classe d'élèves. Certains blogueurs partent seuls accompagnés d'un objet insolite ou de leur animal « favori ». Et puis, il y a les solitaires !

L'aventure Caraïbes en catamaran

Blog d'une famille (les parents et leurs deux filles de 10 et 12 ans) qui voyage en catamaran *le Delphis* sur les eaux des Caraïbes, durant 1 an. Le blog montre leur vie de famille avec de nombreuses photos et commentaires.

<http://delphis2.uniterre.com>

► Archive du 13 juin 2013 à 12:33 | autres dates



Voyage au Burundi

Joelle, l'ainée de 4 enfants raconte dans son blog, le voyage de ses parents, frères et soeurs au Burundi, pendant 3 semaines en 2007. Ce blog a permis de partager la découverte de ce pays méconnu des touristes.

<http://burundi-decouverte.skyrock.com>

► Archive du 13 juin 2013 à 12:33 | autres dates



Thèmes de ce parcours

- Pourquoi voyager ?
- Avec qui voyager ?
- Comment voyager ?
- Le quotidien du voyage
- Aux quatre coins du monde
- Le tour du monde
- Raconter son voyage
- Autour du carnet de voyage

Consultation
des Archives
de l'Internet





Danke für die Aufmerksamkeit

Fragen?