Groupe de contact FNRS
« Analyse critique et amélioration de la qualité de l'information numérique »

31 janvier 2018

# « La préservation du patrimoine scientifique à l'heure du numérique », par Anthony Leroy

## Introduction

Isabelle Boydens

Smals ICT for society

fnrs LA LIBERTÉ DE CHERCHER

ULB

# Groupe de contact FNRS « Analyse critique et amélioration de la qualité de l'information numérique »

- Qualité des données :
  - *arbitrage* selon les *enjeux* (sociaux, industriels, juridiques, scientifiques, …), sous *contrainte de budget*
  - pas de « *qualité totale* »
  - « *fitness for use* »

- Application de la critique historique aux sources informatiques à des fins opérationnelles :
  - Herméneutique des bases de données empiriques : « *le système d'information se transforme avec l'interprétation du réel observable qu'il permet d'appréhender…* »

- Groupe FNRS, objectifs, réalisations et défis :
  - créé en 1994, pluridisciplinaire
  - associant théorie et pratique, concepteurs et utilisateurs
  - bibliographie en annexe, cours universitaire de Master en « data quality » (5 ECTS) créé à l'ULB

# Du stemma codicum au « data tracking »

**Stemma codicum : "le Lai de l'ombre", poème français du 13ème siècle**

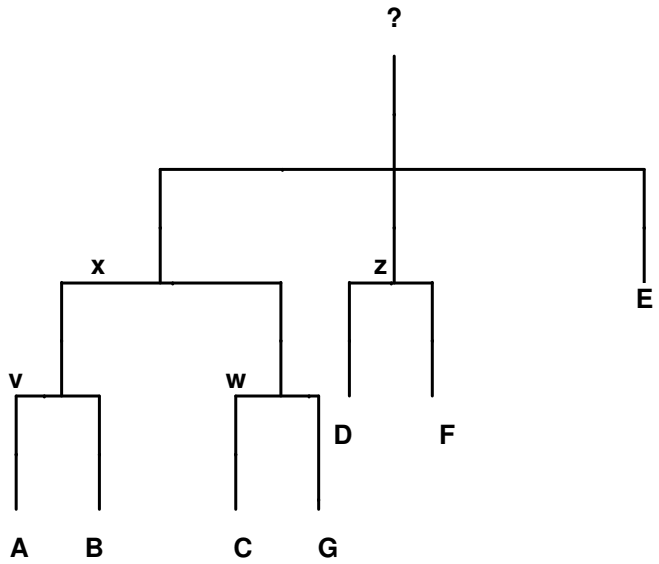


**"Data tracking", AT&T Bell Laboratories, 1992**

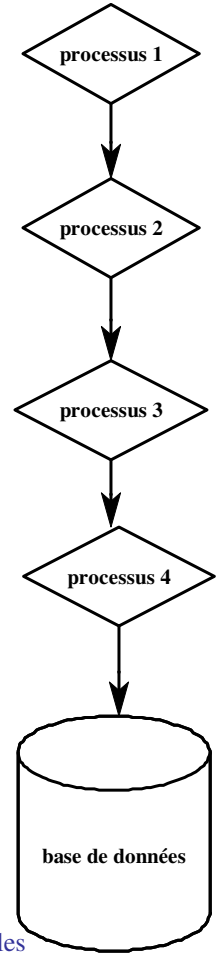

# Enjeux stratégiques lorsque l'information est un instrument d'action sur le réel

Quelques exemples :

- 1442, Laurent Valla démontre que la « *Donation de Constantin* » est un faux antidaté de 4 ou 5 siècles
- Étude du réchauffement climatique (couche d'ozone, 1980)
- Première guerre du Golfe (1990-1991)
- 1999, guerre du Kosovo, bombardement de l'ambassade de Chine à Belgrade
- 2008, interactions entre données et marché financier : Google Finance, Yahoo! Finance
- 2013, secteur administratif (Obamacare)
- 2016, domaine des pipelines, de l'hydrologie, …

# Les « données » ne sont pas « données »

On ne dispose d'aucun référentiel "absolu" en vue de tester la correction d'une vaste base de données empiriques

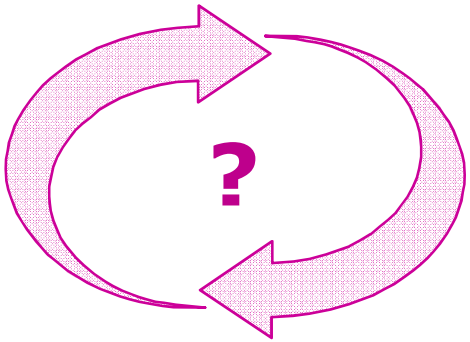

Étude des anomalies à des fins opérationnelles

# Comment les données se construisent-elles progressivement ?

*Cadre d'analyse temporel*

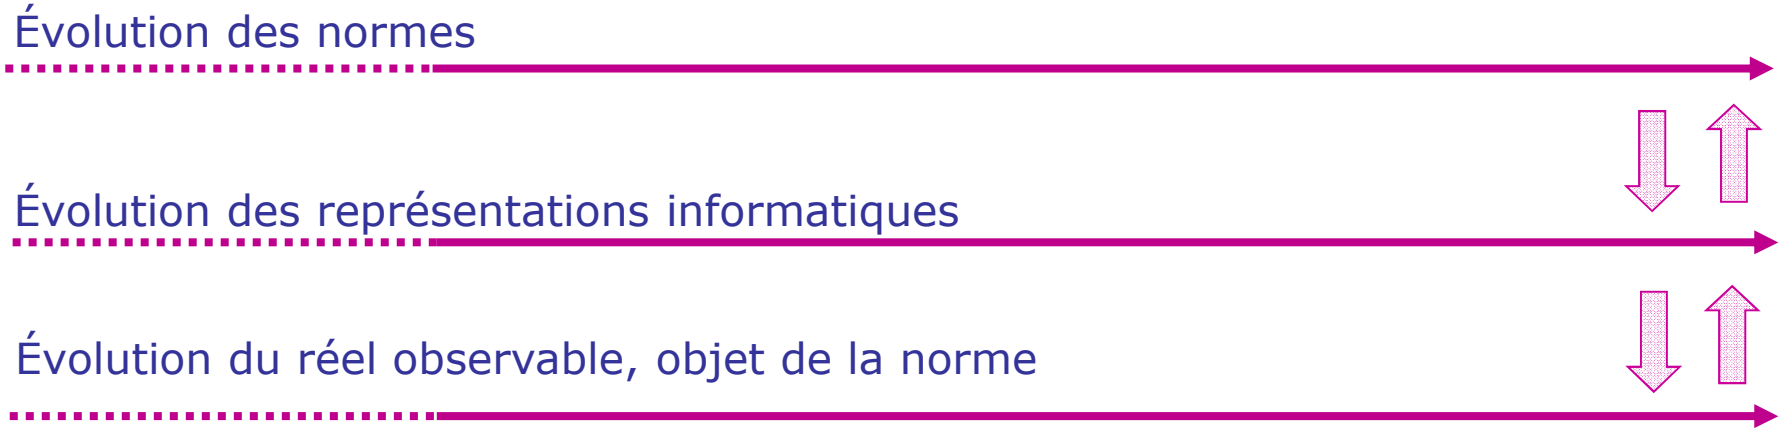


F. Braudel, « *temporalités étagées* » (1949)

N. Elias, « *continuum évolutif* » (1996)

# Evaluer et améliorer la qualité des données : deux approches complémentaires

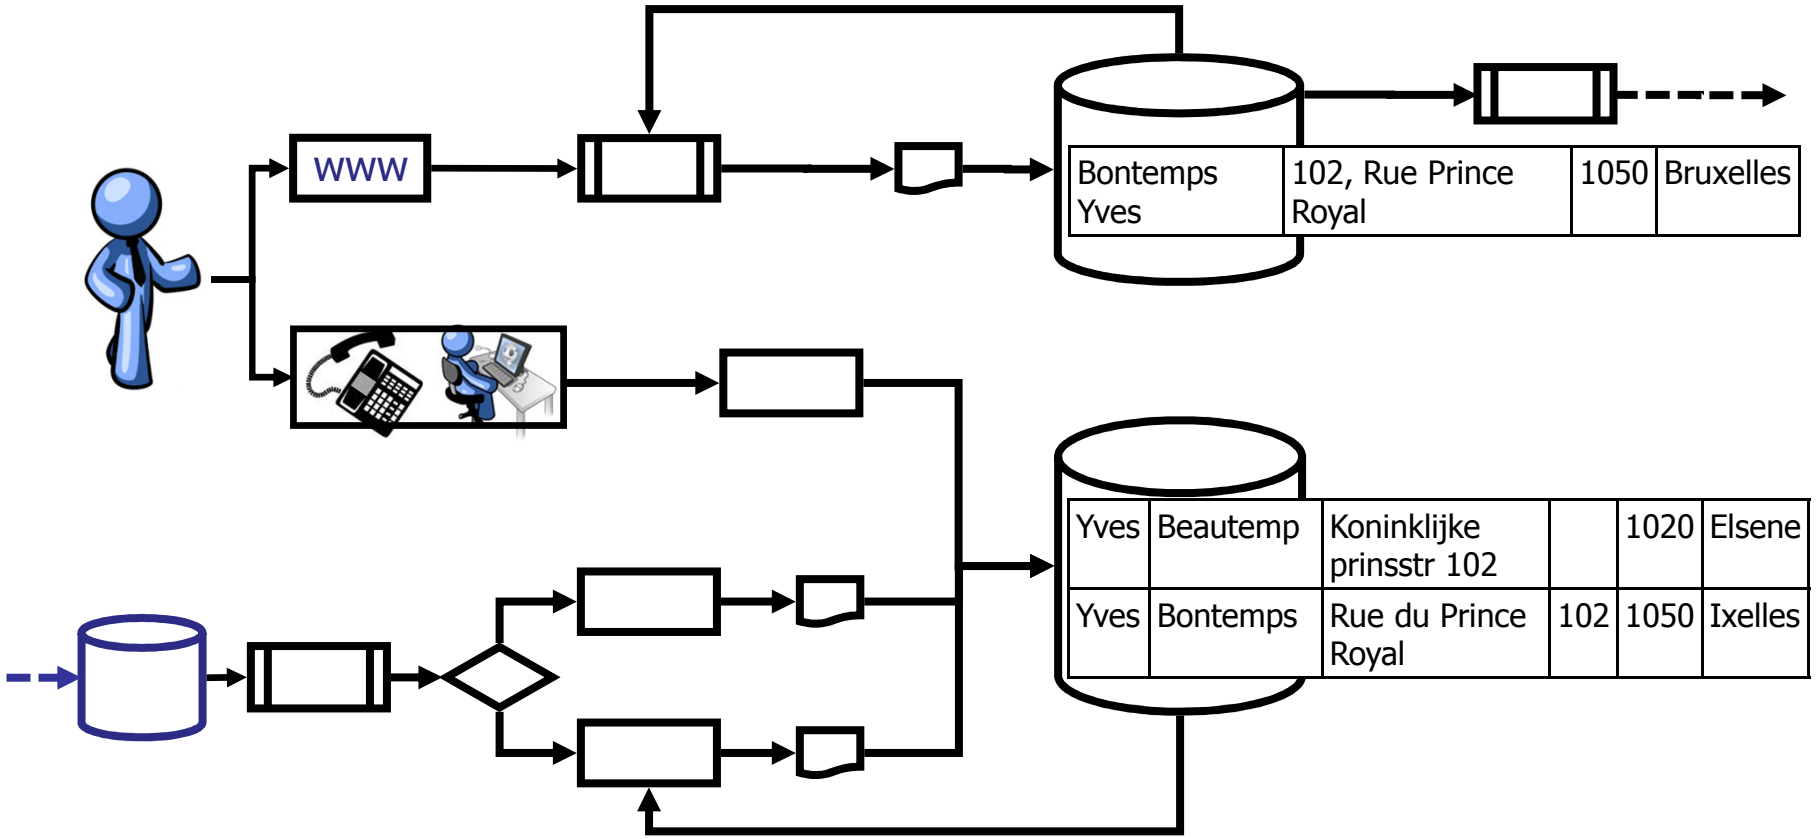


Approches méthodologiques

Approches techniques

# Stratégie opérationnelle : passage d'un « monde clos » à un « monde ouvert sous contrôle »

- Extension du modèle de la base données
- Intégration du traitement des anomalies et historique :
  - Typologie et suivi dans le temps
  - Détection / correction / validation …

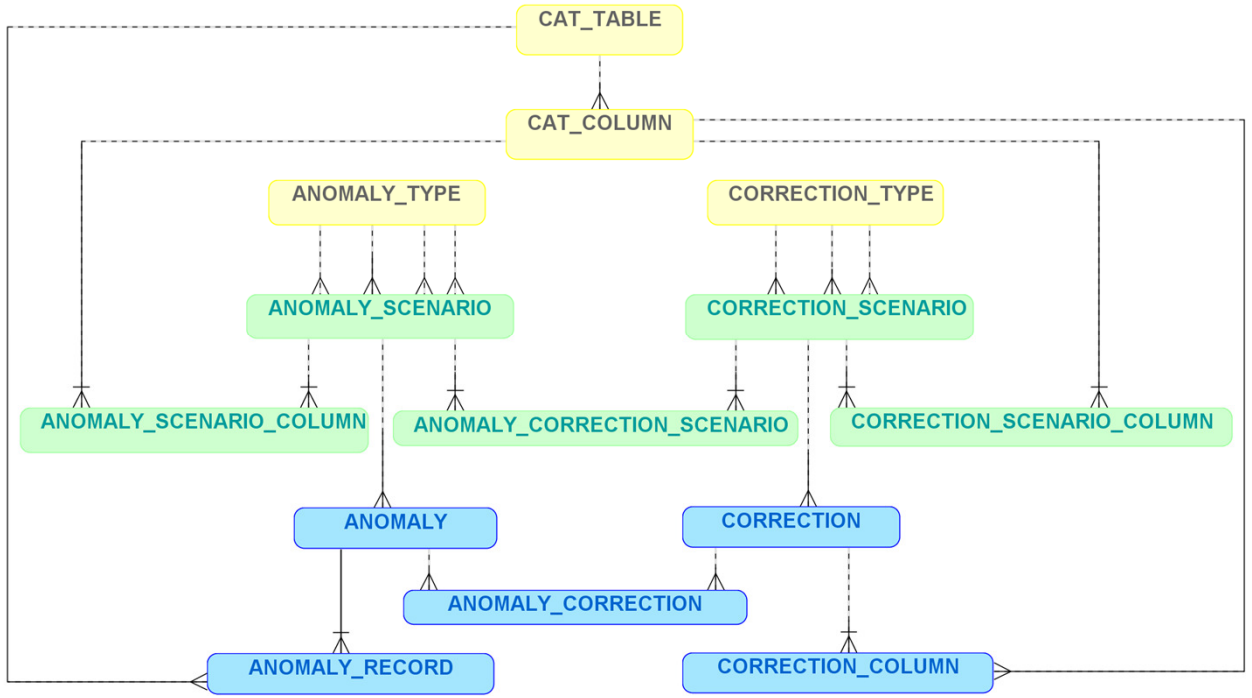

# Stratégies de gestion

- Conception d'indicateurs de qualité :
  - Quantifier le temps et la nature des traitements (monitoring)
  - Identifier les cas d'anomalies fréquemment validées (anomalies « fictives ») et en évaluer les causes structurelles à travers les flux de traitement (obsolescence des contrôles ?)
  - Adapter progressivement les contrôles à l'évolution des réalités et diminuer le nombre d'anomalies fictives

- Exemples d'applications concrètes :
  - DmfA : 65 milliards d'euros annuels de cotisations sociales prélevées
  - Déduction de cotisation pour les "bas salaires" et diminution structurelle du nombre d'anomalies de 50 % (14.000/7.000)
  - Le 2/2/2017: Arrêté Royal imposant l'application d'un "back data tracking" à tous les SSA & prestataires de services en Belgique
  - Applications dans d'autres domaines empiriques : médecine, musées, corpus historiques, secteur bancaire, finances, …

# Thématiques 2014 – 2017 (1)

- **2014**
  - « ***Du stemma codicum au data tracking » : vingt ans de recherche en matière d'évaluation et d'amélioration de la qualité des bases de données*** », par I. Boydens,
  - ***« Email Address Reliability****, » par V. Berten*

*Programme, slides et vidéo : http://mastic.ulb.ac.be/2013/10/reunion-du-groupe-de-contact-fnrs-analyse-critique-et-amelioration-de-la-qualite-de-linformation-numerique/*

- **2015** *: « **Ouverture des données, gouvernance et engagement citoyen: questions de qualité** »*

  - « ***Gouvernance et individus: réflexion sur un couple impossible*** », Par F. de Smet
  - « ***Semantic Information Technology as a provider of tools for a productive and efficient organization of government*** » par Agis Papantoniou

*Programme et slides : http://mastic.ulb.ac.be/2014/10/reunion-du-groupe-de-contact-fnrs-analyse-critique-et-amelioration-de-la-qualite-de-linformation-numerique-2/*

- **2016**
  - « ***Analyzing the evolution history of data-intensive systems in support to software maintenance»,*** par A. Clève

*Programme, slides et vidéo : http://mastic.ulb.ac.be/2016/02/reunion-du-groupe-de-contact-fnrs-analyse-critique-et-amelioration-de-la-qualite-de-linformation-numerique-3/*

# Thématiques 2014 – 2017 (2)

- ***2017***
  - ***« Temps réel, déterminisme et ordonnancement : trois défis majeurs des systèmes embarqués»,*** par J. Goossens

*Programme, slides et vidéo :* http://mastic.ulb.ac.be/2017/02/reunion-du-groupe-de-contact-fnrs-analyse-critique-et-amelioration-de-la-qualite-de-linformation-numerique-4/

# Thématique 2018

- “La préservation du patrimoine scientifique à l’heure du numérique ” par Anthony Leroy

http://mastic.ulb.ac.be/2017/09/reunion-du-groupe-de-contact-fnrs-analyse-critique-et-amelioration-de-la-qualite-de-linformation-numerique-5/

# Anthony Leroy

**Anthony Leroy** est ingénieur civil en électronique et télécommunication, détient un doctorat en microélectronique (ULB) et a été chercheur en électronique pendant près de dix ans en collaboration avec l'industrie.

Il est informaticien au Département des Bibliothèques et de l'Information Scientifique (DBIS) à l'Université libre de Bruxelles depuis 2011.

Anthony est responsable de l'infrastructure technique de numérisation et de préservation numérique des Bibliothèques et coordonne notamment les activités du projet d'archivage pérenne SAFE PLN regroupant 8 partenaires internationaux.

# Programme 2018

- 14h Accueil (S. Van Hooland)
- 14h05 Introduction (I. Boydens)
- 14h15 « La préservation du patrimoine scientifique à l'heure du numérique »  (A. Leroy)
- 15h45 Table ronde (modérateurs : C. Brouwer et S. Van Hooland)
- 16h15 Réception

*Les slides des présentations seront disponibles en ligne sur le site de l'invitation à la fin de la journée d'étude FNRS.*

# Orientation bibliographique (1)


- Bade D., « It's about Time!: Temporal Aspects of Metadata Management in the Work of Isabelle Boydens ». In *Cataloging & Classification Quarterly* (The International Observer), volume 49, n° 4, 2011, pp. 328-338 (Université de Chicago, recension des recherches et publications d'Isabelle Boydens, période 1993-2011).
- Bade D., *Responsible Librarianship, Library policies for unreliable systems*. Library Juice Press, 2007.
- Batini C. et Scannapieco M., éds., *Data and Information Quality. Dimensions, Principles and Techniques*. New York, Springer, 2016.
- Berten V. et Boydens I., *Email Address Reliability*, Section Recherches, Bruxelles, Smals, 2014.
- Berti Equille L. éd., *La qualité et la gouvernance des données au service de la performance des entreprises*. Paris, Hermès, 2012.
- Bizingre J., Paumier J. et Rivère P., *Les référentiels du système d'information*. Paris, Dunod, 2013.
- Bloch L. *Système d'information : obstacles et succès*. Paris : Vuibert, 2005.
- Bontemps Y., Boydens I. et Van Dromme D., *Data Quality : tools.* Deliverable, section recherches, Bruxelles, Smals, 2007.

# Orientation bibliographique (2)


- Boydens I., « Informatique et qualité de l'information. Application de la critique historique à l'étude des informations issues de bases de données ». In *Belgisch Tijdschrift voor Nieuwste Geschiedenis. Revue belge d'histoire contemporaine*, vol. 3-4, 1993, p. 399-439.
- Boydens I., *Informatique, normes et temps*. Bruxelles : Bruylant, 1999. (Prix de la Fondation L. Davin, conféré par l'Académie Royale des sciences, des lettres et des beaux-arts de Belgique, 1999).
- Boydens I., « Les bases de données sont-elles solubles dans le temps? ». In *La Recherche hors série* ("Ordre et désordre"). Hors série n° 9, novembre-décembre 2002, p. 32-34.
- Boydens I., « Déploiement coopératif d'un dictionnaire électronique de données administratives ». In *Revue Document Numérique,* vol. 5, n°3-4, 2001, Paris, Hermès, p. 27-43.
- Boydens I., « La conservation numérique des données de gestion ». In *Revue Document Numérique,* septembre 2004, Paris, Hermès, p. 13-22.
- Boydens I., "Qualité de l'information et administration électronique : enjeux et perspectives". In Assar S. et Boughazala I., éds., Administration électronique. Constats et perspectives. Paris : Lavoisier - Hermès Sciences, 2007, p. 103-120 (chapitre 5).
- Boydens I., "Hiérarchie et anarchie : dépasser l'opposition entre organisation centralisée et distribuée ?" In Hudon M. et El Hadi W. M., éds, Les cahiers du numérique (Numéro thématique « Organisation des connaissances et Web 2.0 »). Paris : Editions Hermès Sciences, 2010, vol. 6, n°3, p. 77-101.

# Orientation bibliographique (3)


- Boydens I., "Strategic Issues Relating to Data Quality for E-government: Learning from an Approach Adopted in Belgium". In Assar S., Boughzala I. et Boydens I., éds., "Practical Studies in E-Government : Best Practices from Around the World", New York, Springer, 2011, p. 113-130 .
- Boydens I. et Van Hooland S., "Hermeneutics applied to the quality of empirical databases". In *Journal of Documentation*, volume 67, issue 2, 2011, p. 279-289.
- Boydens I., Hulstaert A. et Van Dromme D., *Gestion intégrée des anomalies - Evaluer et améliorer la qualité des données*, Delivrable, Section Recherches, Bruxelles, Smals, 2011.
- Boydens I., Mendez E. et Van Hooland S., "Between commodification and sense-making. On the double-sided effect of user-generated metadata within the cultural heritage sector" In Marty P. F. et Kazmer M. M., éds, *Library Trends on "Involving Users in the Co-Construction of Digital Knowledge in Libraries, Archives, and Museums*, Library Trends, John Hopkins University Press, volume 59, n° 4, spring 2011, pp. 707-720.
- Boydens I., « L'océan des données et le canal des normes ». In Carrieu-Costa M.-J., Bryden A. et Couveinhes P. éds, Les Annales des Mines, Série "Responsabilité et Environnement" (numéro thématique : "La normalisation : principes, histoire, évolutions et perspectives"), Paris, n° 67, juillet 2012, pp. 22-29. http://www.ulb.ac.be/cours/iboydens/annales.pdf
- Boydens I., *Open Data et eGovernment*. Research Note, Bruxelles, Smals, n° 33, avril 2014, 23 pp. http://www.smalsresearch.be/download/research_reports/research_note/OpenDataRN.pdf

# Orientation bibliographique (4)


- De Wilde, M. et Verborgh, R., *Using OpenRefine*. Brimingham-Mumbai : Packt Publishing, 2013 (978-1-78328-908-0).
- Elmasri R. et Navathe S. B., *Fundamentals of Database Systems*. Addison Wesley, 2011 (6eme éd.).
- Loshin D., *The Practicioner's Guide to Data Quality Improvment*. Elsevier, Morgan-Kaufmann OMG Press, 2011.
- Madnick S. E. *et al.*., "Overview and Framework for Data and Information Quality Research"*. In Journal of Data and Information Quality*, Vol. 1, No. 1, 2009, p. 2-22.
- McCallum Q. Ethan, Bad Data Handbook, *Mapping the World of Data Problems.* Sebastopol, O'Reilly Media, 2012.
- Analyse critique **:** Boydens I., *"Mapping the World of Data Problems" : la qualité des données vue par la communauté IT*. Bruxelles, Smals, Research Section, post de blog, 03/04/2013. http://www.smalsresearch.be/mapping-the-world-of-data-problems-la-qualite-des-donnees-vue-par-la-communaute-it-geek/
- Olson J., *Data Quality: The Accuracy Dimension*. Elsevier, The Morgan-Kaufmann Series in Database Management, 2003.
- Redman T. C., *Data Quality for the Information Age*. Boston-London : Artech House Publishers, 1996.

# Orientation bibliographique (5)


- Redman T. C., *Data Quality. The Field Guide*. Boston : Digital Press, 2001.
- Rivière P., " Indicateurs de qualité en matière de production de données : quelques éléments de réflexion". In *Courrier des statistiques*, septembre 2005, n°115, p. 35-40.
- Rivière P., *Les référentiels dans un système d'information. Quelques principes*, Paris, Assurance retraite, Direction Qualité, Méthodes et Urbanisation, 2011.
- Shazia S. ed., *Handbook of Data Quality. Research and Practice*. Berlin, Springer, 2013.
- Van Hooland S., "Spectator becomes annotator: possibilities offered by user-generated metadata for image databases". *Paper presented at Immaculate Catalogues: Taxonomy, Metadata and Resource Discovery in the 21st Century*, 13-15 September 2006, University of East Anglia, UK.
- Van Hooland, S., Kaufman, S. et Bontemps, Y., "Answering the call for more accountability: applying data-profiling to museum metadata", *Proceedings of the International conference on Dublin Core and metadata applications, 22- 26 September 2008, Berlin*, Dublin Core Metadata Initiative, Berlin, p. 93-103.
- Van Hooland, S., *Metadata quality in the cultural heritage sector: stakes, problems and solutions*, Thèse de doctorat sous la direction de Boydens I., Département Sciences de l'Information et de la Communication, Université Libre de Bruxelles., 2009.
- Van Hooland S. et Verborgh, R., *Linked data for libraries, archives and museums. How to clean, link and publish your metadata*. Brimingham-Mumbai : Facet Publishing, 2014.
- Volle M., *De l'informatique*. Paris, Economica, 2006.

# Orientation bibliographique (6)

- Quelques ressources en ligne :
  - http://www.ulb.ac.be/cours/iboydens/
  - https://www.smals.be/fr/content/data-quality
  - http://www.smalsresearch.be
  - http://homepages.ulb.ac.be/~svhoolan/
  - http://homepages.ulb.ac.be/~madewild/
  - http://freeyourmetadata.org/
  - http://liliendahl.com/
  - http://iaidq.org/
  - http://www.ocdqblog.com/
  - http://www.dqa.be/
  - http://exqi.asso.fr/

# Orientation bibliographique (7)

## **Mémoires d'Etudiants de fin de Master depuis 2010** (1)

- DUPONT N., « *Les bases de données intra-site utilisant un système d'information géographique en archéologie : évolution et possibilités futures*» (ULB, mémoire de fin d'étude MA en STIC 2010-2011, dir. I. Boydens).

- SALLETS J., « *La problématique des adresses spatiales dans les bases de données administratives*» (ULB, mémoire de fin d'étude MA en STIC 2010-2011, dir. I Boydens). Prix de l'Association Belge de Documentation.

- DUTOIT F., « *La représentation de l'information empirique au sein des bases de données bibliographiques. Cas de l'apparat critique évolutif des œuvres d'attribution incertaine, avec exemplification sur la base d'un corpus de textes médiévaux* » (ULB, mémoire de fin d'étude MA en STIC, dir I. Boydens, année académique 2010-2011).

- Maroye L., « *La nouvelle norme ISO 25964-1 pour les thesaurus multilingues: apports et contraintes. Le cas particulier de TESE*. » (ULB, mémoire de fin d'étude MA en STIC, dir I. Boydens, année académique 2011-2012).

- De Roeck C., « *Analyse de la qualité d'un DataWarehouse au sein d'une institution gouvernementale. Etat de l'art critique, étude de cas, solutions.* » (ULB, mémoire de fin d'étude MA en STIC, dir I. Boydens, année académique 2013-2014).

# Orientation bibliographique (8)

**Mémoires d'Etudiants de fin de Master depuis 2010** (2)

- Meunier V. « *ISO 25964 et introduction de la distinction entre terme et concept : présupposés conceptuels et implications opérationnelles* » (ULB, mémoire de fin d'étude MA en STIC, dir I. Boydens, année académique 2013-2014).

- Paquot F. « *Etat de l'art critique de l'usage des Open Data à des fins journalistiques* ». (mémoire de fin d'étude MA en STIC, dir I. Boydens, année académique 2014-2015).

- Jacobs A., "*Transmitting Information Through the Pipeline Network: Reevaluating the Gas Explosions of San Bruno, Engelhart and Ghislenghien from the Perspective of Organizational, Conceptual or Information Management-Related Elements in the Pipeline Business.*" Bruxelles, ULB, Mémoire Master STIC (dir : I. Boydens), année académique 2015-2016. – Prix ABD-BVD 2017.

- Zombek L., « *La qualité des méta-données dans le domaine environnemental : les bases de données relatives à l'eau. Enjeux, état de l'art critique, étude de cas et recommandations* ». Bruxelles, ULB, Mémoire Master STIC (dir : I. Boydens), année académique 2015-2016.

- De Oliviera Kempf Helena, « *La qualité de l'information au sein des bases de données alimentaires. Etat de l'art des problèmes et solutions et confrontation au cas de l'AFSCA* ». Bruxelles, ULB, Mémoire Master STIC (dir : I. Boydens), année académique 2016-2017.