

Standardisation de l'utilisation des données du SNDS à des fins de recherche médicale : présentation d'un modèle de données optimisé centré sur le patient

N.Thurin¹, R. Lassalle¹, J. Jové¹, R. Sylvestre¹, J. Dupont¹, C. Lacueille¹, P. Blin¹, N. Moore¹, C. Droz-Perroteau¹

¹ Bordeaux PharmacoEpi, INSERM CIC1401, Université de Bordeaux, Bordeaux, France

Introduction

- > Le SNDS est un outil puissant et incontournable en pharmaco-épidémiologie permettant
 - Une analyse d'impact (bénéfices/risques) des médicaments en conditions réelles,
 - L'évaluation de parcours de soin des patients,
 - Le suivi de l'évolution des maladies et des traitements.

> Le SNDS a une architecture centrée sur la prestation (DCIR) et le séjour (PMSI, Figures 1 et 2)

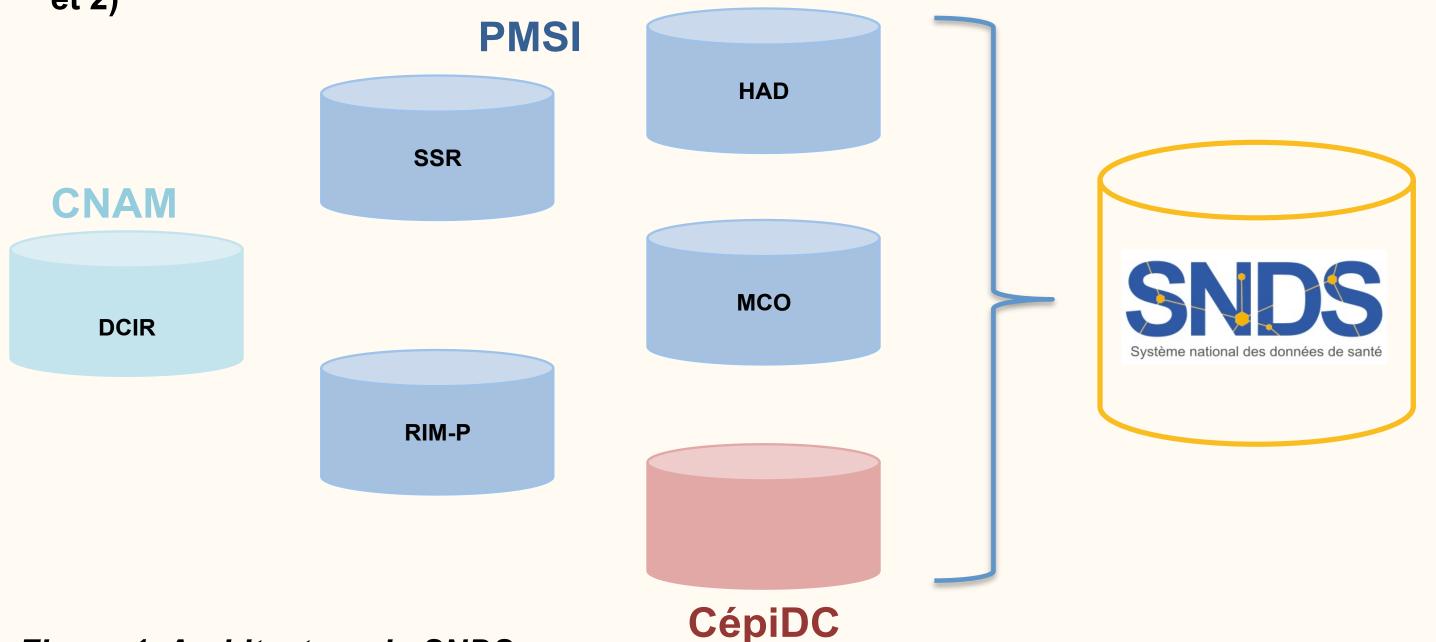


Figure 1. Architecture du SNDS

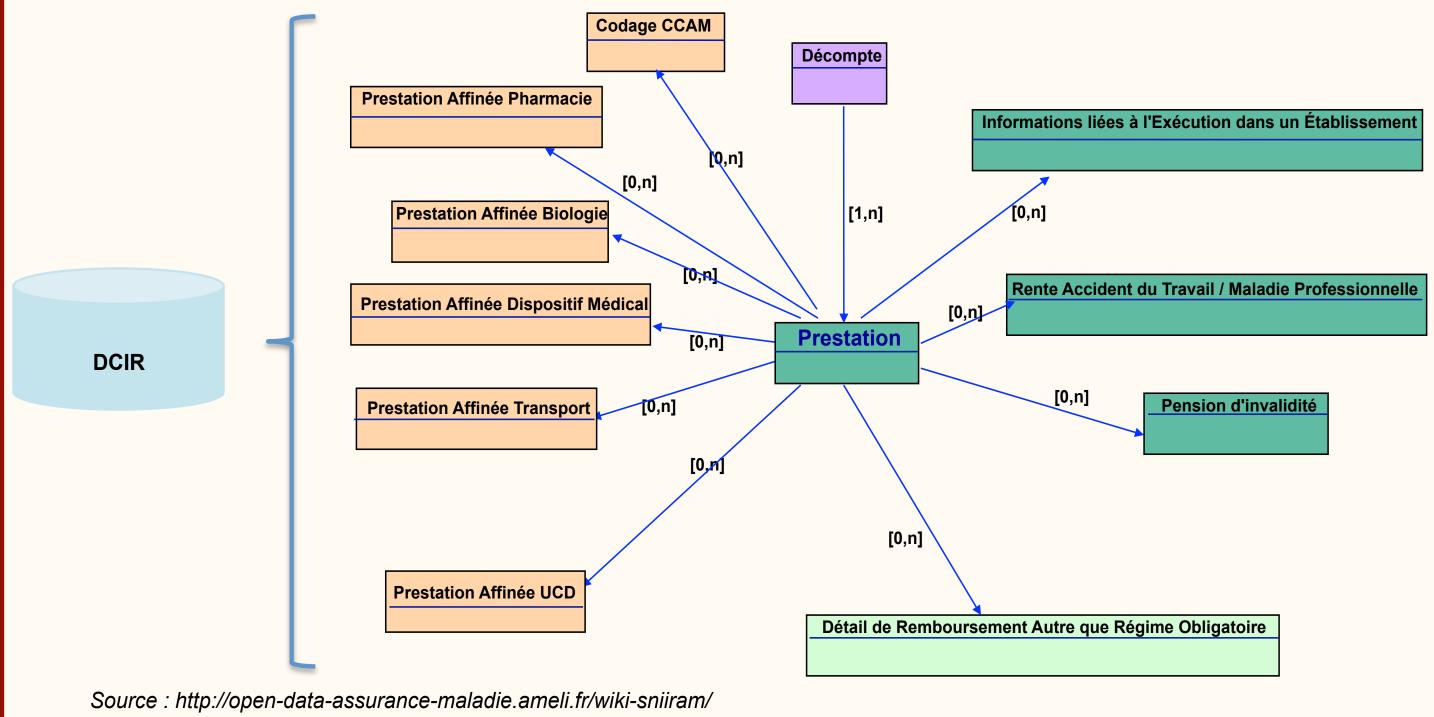


Figure 2. Architecture du DCIR centrée sur la prestation

- > L'architecture du SNDS a pour conséquence de rendre complexe son usage à des fins de recherche (Tableau 1)
 - L'unité statistique est la prestation ou le séjour plutôt que le patient,
 - Le nombre de tables annuelles et de variables est très important et croissant,
 - Cela entraine une certaine « lourdeur » dans les traitements : nombre élevé de clés de jointure, grand volume de données et tables à manipuler, temps machine important.

Univers	Nombre de tables/an ¹		Nombre de variables/an ¹	
	Min	Max	Min	Max
DCIR	12	13	375	394
MCO	19	54	342	859
SSR	14	27	260	519
RIM-P	6	16	92	361
HAD	6	22	114	437
CépiDC ²	_	2	-	61
Total	57	134	1183	2631

¹ 2006 - 2016 ² 2013 - 2015

Tableau 1. Volume annuel de tables et variables au sein du SNDS

Objectifs

Construire, à partir des données du SNDS, un modèle simplifié et optimisé pour conduire des études de pharmaco-épidémiologie centrées autour du patient, avec un nombre de tables et de variables restreint.

Méthodes

- > Définition du modèle de données relationnel par une équipe pluridisciplinaire
- > Rédaction du cahier des charges (ETL « Extract Transform and Load »)
- Sélection des variables pertinentes (exposition médicamenteuse, pathologies, indicateurs de soins...),
- Description des tables,
- Cartographie des variables sources vers le modèle final,
- Création du thésaurus associé.
- Programmation et exécution sur données « test » (SAS®)
- > Validation des programmes et des tables créées

Résultats

Modèle de données final centré autour du patient (Figure 3)

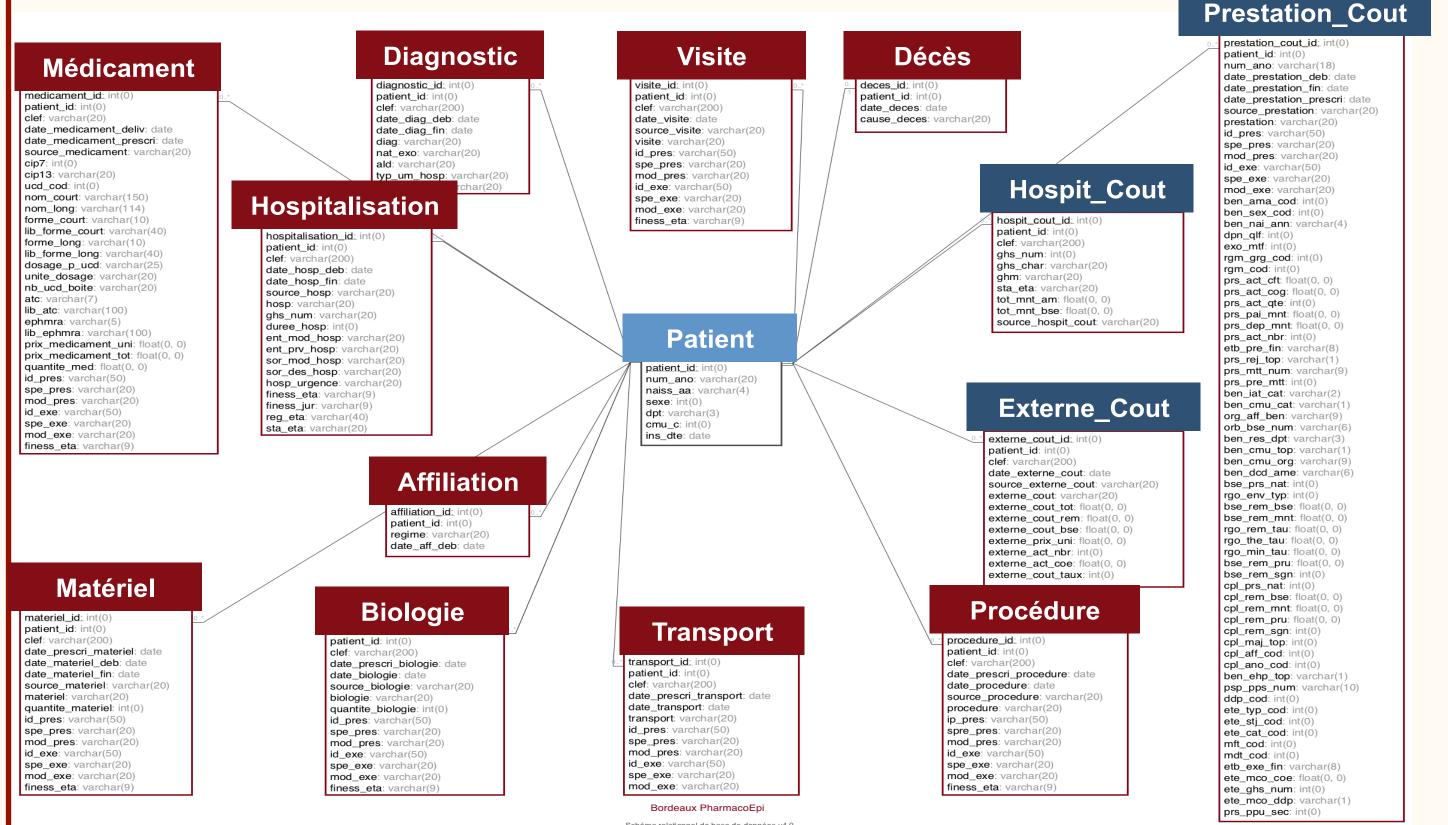


Figure 3. Architecture du SNDS centrée sur le patient

- > Structure des données, exemple de la table « Diagnostic » (Tableau 2)
- Données, provenant de 13 tables/année dans 5 des 6 univers (hors CépiDC), synthétisées en une seule table,
- Clé patient unique, code CIM-10 (diagnostic, ALD) réduit à 1 seule variable

Nom Variable	Libellé Variable	Type Variable	Format	Précision
ID	Identifiant du diagnostic (clé primaire)	number	11.	
PATIENT_ID	Identifiant du patient (clé étrangère)	number	11.	
CLEF	Clef (pour relier avec table HOSPITALISATION, HOSPIT_COUT et autres données hospitalières)	char	\$200.	
DATE_DIAG_DEB	Date de début (séjour hospitalier / mise en ALD ou invalidité ou AT ou MP)	date	8.	
DATE_DIAG_FIN	Date de fin (séjour hospitalier / mise en ALD ou invalidité ou AT ou MP)	date	8.	
DIAG	Code CIM10 Diagnostic hospitalier / ALD / invalidité / AT / MP	char	\$20.	Vocabulaire CIM10
NAT_EXO	Nature d'exonération	char	\$20.	Vocabulaire NAT_EXO
ALD	Code ALD	char	\$20.	Vocabulaire TYP_ALD
TYP_UM_HOSP	Type d'autorisation d'unité médicale	char	\$20.	Vocabulaire TYP_UM
SOURCE_DIAG	Source du diagnostic	char	\$20.	Vocabulaire SOURCE_DIAG

Tableau 2. Exemple de la table « diagnostic »

> Pour chaque table

- Indentification de la source de provenance de chaque donnée,
- Calcul de variables dérivées (passage aux urgences, soins intensifs, CMU-c...),
- Possibilité de relier des données d'un même univers présentes dans différentes tables,
- Ajout dans la table des coûts hospitaliers « Hospit_cout » du montant environné du séjour provenant des Etudes Nationales de Coûts (ENC) annuelles de l'ATIH.
- > Exemple de l'étude CAMERRA : cohorte 2012 N = 913 358 patients, extraction de 10 années de soins (Tableau 3) :

	Modèle initial	Modèle simplifié	Modèle simplifié sans la table "Prestation_cout"
Nombre de tables	973	14	13
Volume des données SAS®	473 Go	389 Go (82%)	52 Go (11%)

Tableau 3. Etude CAMERRA, application du modèle simplifié

- Table « Prestation_cout » encore volumineuse
- Gain de tables et de volume de données SAS®

Concusion

- Cette standardisation de l'utilisation des données du SNDS a permis
 - D'optimiser le travail des statisticiens
 - Standardisation des tables,
 - Diminution de la variabilité inter-programmeurs,
 - Gain notable en terme de temps,
 - Meilleure reproductibilité des résultats et qualité scientifique.
 - D'optimiser l'exploitation des données
 - Utilisation simplifiée d'autres outils (macro SAS® HdPS, packages R…),
 - Simplification de la présentation et explication de la structure des données,
 - Programmes de recherche internationaux multi-pays, multi-bases de données : interconnexion optimisée avec les plateformes existantes (exemples : Aetion, Pharmo, OMOP-OHDSI...).









