

Raisonner sur les données médico-administratives pour reconstruire et analyser les parcours de soins


T. Guyet, Inria-IRISA/LACODAM



E. Oger, UR1/EA-7449 REPERES - CHU Rennes



Consortium PEPS



Contexte

- Plateforme ANSM - Consortium PEPS – Pharmaco-Epidemiologie des produits de Santé (Financement ANSM)

- CHU Rennes / CHRU Brest
- IRISA/Inria
 - Équipes de recherche en informatique : LACODAM, DRUID
 - Axe transversal Biologie – Santé
- REPERES (UR1/EHESP)
- IRT B-Com
- Inserm Equipe ESTHER/CESP Villejuif

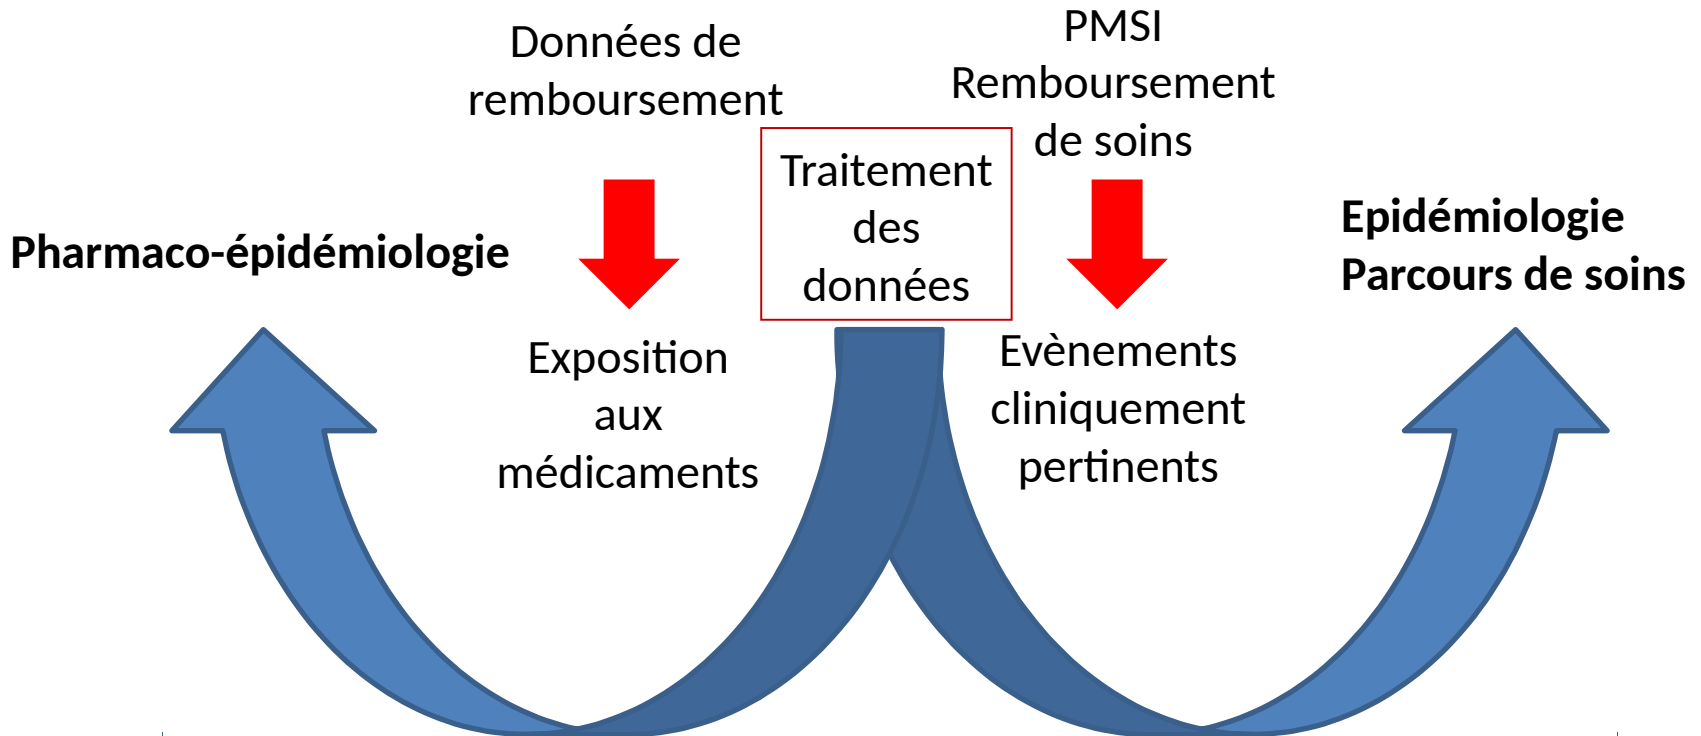


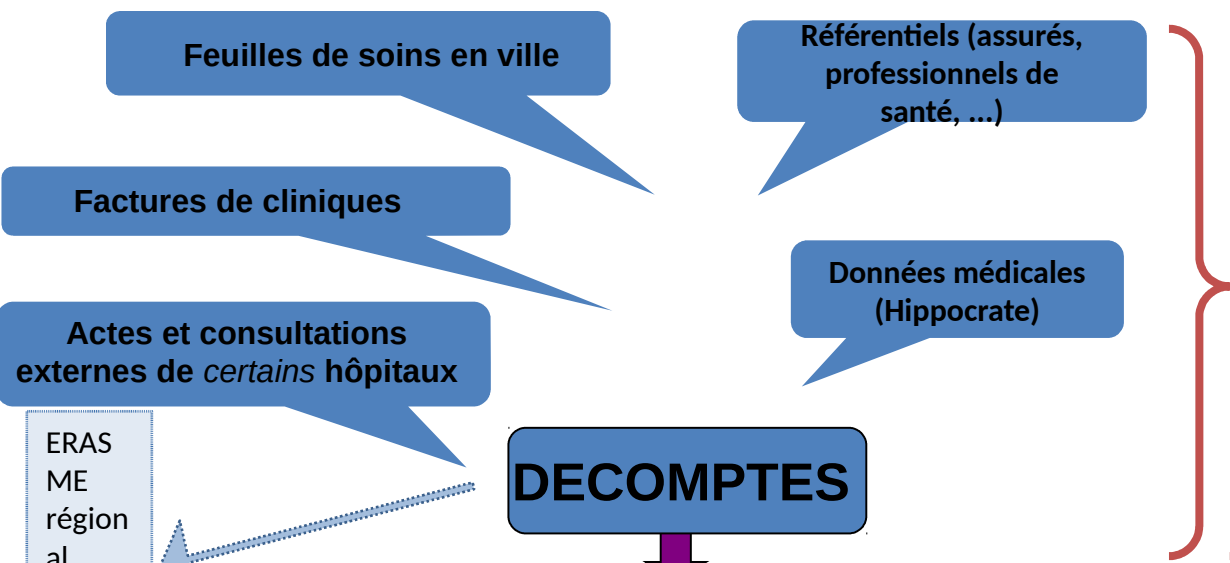
- Consortium multi-disciplinaire avec un programme de R&D sur les outils
- **Objectif : Exploiter les données du SNDS pour répondre à des questions de pharmaco-épidémiologie**

Exemple : Etude GENEPI (E. Polard et al.): “évaluer l’association entre la substitution Princeps-Génériques et les hospitalisations pour épilepsie”



Utilisation des données du SNDS

Système National Information Inter-Régime Assurance Maladie





Bases de données locales nominatives (remboursement, retour possible au dossier)
 Données collectées par l'ensemble des organismes gérant un régime de base d'assurance maladie (RG, RA, RSI, autres)

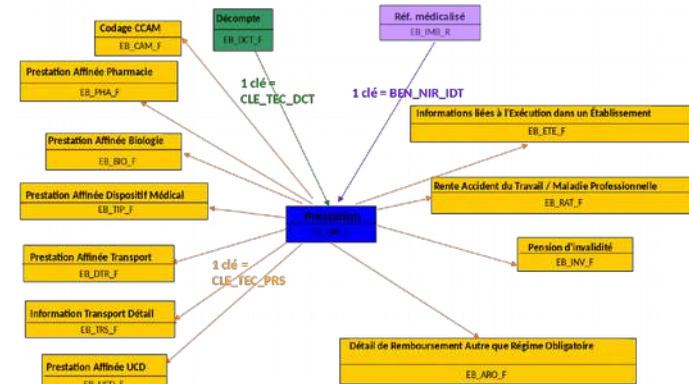



Bases de données nationales pseudonymisées bénéficiaires

| | | | |
|---|--|---|--|
| <p>Suivi des dépenses (DAMIR + Requêtes préétablies)</p> <p>Biologie Pharmacie</p> <p>Médicaments délivrés à l'hôpital (UCD)</p> <p>Données de cadrage (bénéficiaires, PS...)</p> <p>Données agrégées</p> | <p>Offre de Soins Libérale (ODS + Requêtes préétablies + Outil Commission)</p> <p>Tableaux du SUIR CCAM</p> <p>Établissements Privés (SIREP)</p> <p>Dispositifs Médicaux (DF)</p> <p>Référentiel Établissements (BER)</p> <p>Données agrégées Bénéficiaires Données Individuelles PS et Individuelles Établissements</p> | <p>Échantillon généraliste de bénéficiaires au 1/97^{ème} (EGB)</p> <p>référentiel bénéficiaires référentiel médical consommations de soins en ville séjours hospitaliers (PMSI)</p> <p>Données Individuelles Anonymisées Bénéficiaires, Données Individuelles PS et Individuelles Établissements</p> | <p>Datamart de Consommation Inter-régimes (DCR)</p> <p>référentiel consommations référentiel médical consommations de soins en ville séjours hospitaliers (PMSI)</p> <p>Données Individuelles référéntielles Bénéficiaires, Données Individuelles PS et Individuelles Établissements</p> |
|---|--|---|--|

Données médico-administratives et pharmaco-épidémiologie

- Sources de données médico-administratives
 - Données SNDS – SNIIRAM
 - Données hospitalières
 - Au coeur du Health Data Hub
- Avantages/Inconvénients du SNDS
 - + Données numériques disponibles sans délai de collecte
 - + Population large
 - + Taux de couverture de la population
 - + Données structurées
 - + Données historisées
 - + Possibilité de chaînage avec des données de cohortes, données de capteurs, etc
 - Des informations partielles
 - Information médicale limitée
 - **Fossé sémantique entre la donnée et l'information recherchée**






Question de l'étude
Association entre la
substitution Princeps-
Génériques et les
hospitalisations pour
épilepsie ??



Quels patients choisis ?



Question de l'étude
Association entre la substitution Princeps-Génériques et les hospitalisations pour épilepsie ??



Quels événements utiliser pour décrire le **parcours de soins** ?

Comment le **formaliser**, les **représenter** ?



Quelle question poser ?

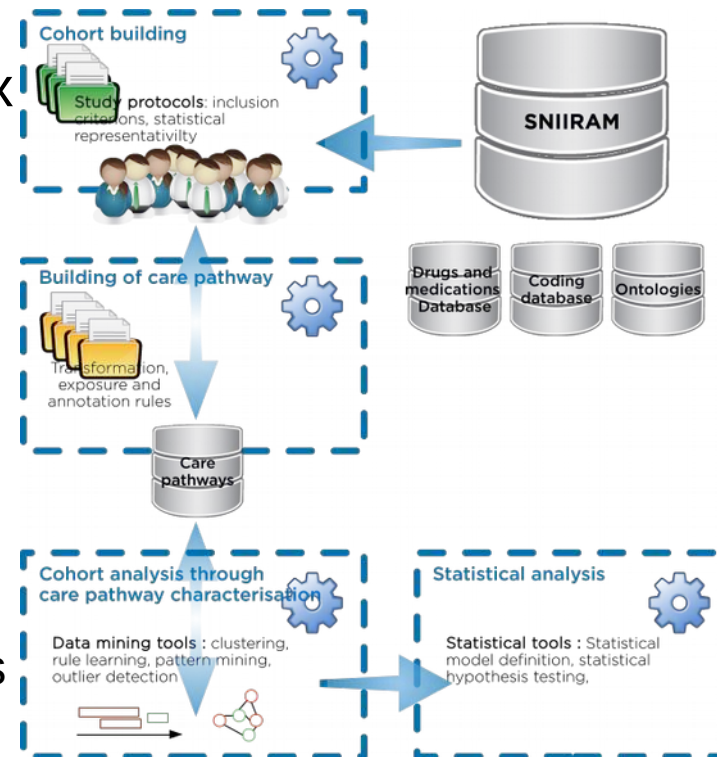
Comment **traduire la question** ?

Quelles questions peuvent être **efficacement posées** ?



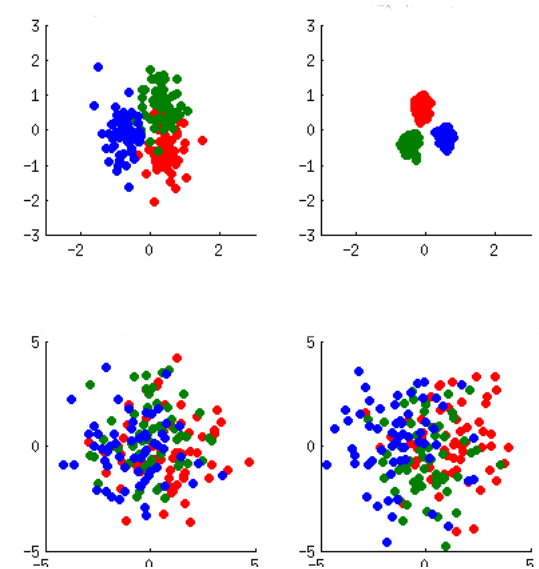
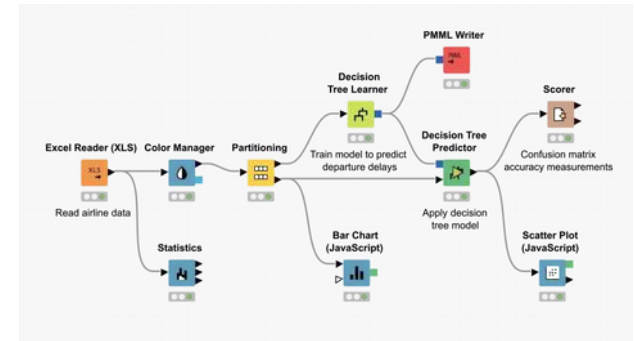
Données médico-administratives et études épidémiologiques

- Sources de données médico-administratives
 - Données SNDS – SNIIRAM
 - Données hospitalières
- *Épidémiologie numérique* : Alternative aux études épidémiologiques classiques
 - Les étapes de l'étude épidémiologique deviennent des étapes d'une analyse de données
 - Sélection de patients
 - Identification d'événements d'intérêts
 - Analyse des liens entre événements d'intérêts
 - Notion centrale de « **parcours de soins** »
 - Une étude est une succession de traitements numériques sur des parcours de soins :
data science workflow



Data science workflows / data wrangling

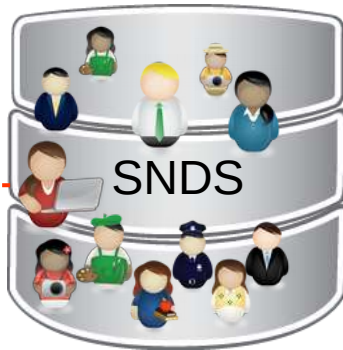
- Pourquoi les méthodes d'apprentissage automatique fonctionnent ?
 - Effort considérable d'annotation des données
 - Beaucoup de la résolution de la tâche d'apprentissage se trouve dans **la préparation des données**
- Généralisation du principe d'une ACP : **un bon espace de représentation des données facilite le travail des algorithmes d'apprentissage**
- La partie la plus importante du workflow est la phase en amont de la tâche d'apprentissage automatique : **data wrangling**
 - Elle comble en partie le problème du fossé sémantique
 - Qu'en est-il pour les données du SNDS ?



Fossé sémantique

Champs sémantique
administratif

Quels
patients
choisis
?



Quels événements
utiliser pour décrire le
parcours de soins ?

Champs sémantique
médical



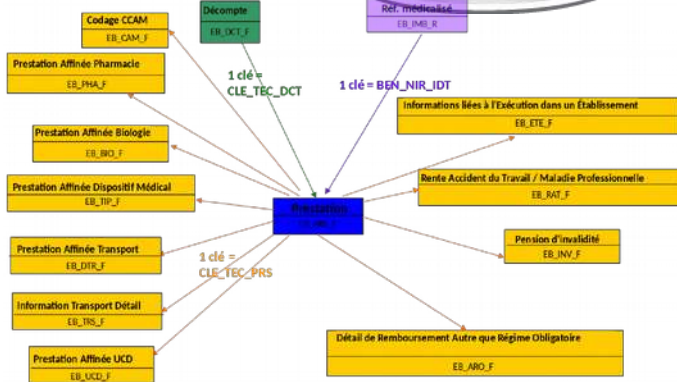

Question de l'étude
Association entre la
substitution Princeps-
Génériques et les
hospitalisations pour
épilepsie ??



Quelle "question"
poser ?

Fossé sémantique

Champs sémantique administratif



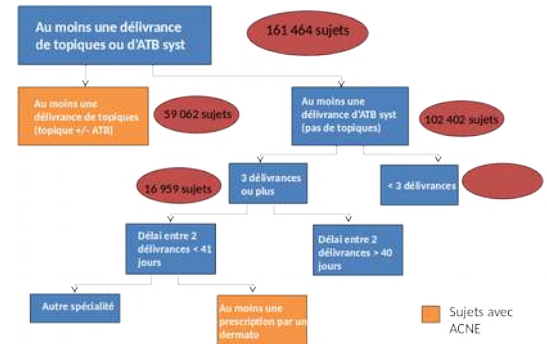
Champs sémantique médical



Question de l'étude
Association entre la substitution Princeps-Génériques et les hospitalisations pour épilepsie ??

```
SELECT
  EXE_S01_DTD, PHA_PRS_IDE, PFS_PRS_NUM, PFS_EXE_NUM,
  PSE_SPE_COD, PSP_SPE_COD, PSE_ACT_NAT, PSP_ACT_NAT
FROM
  ER_PRS_F as prs,
  ER_PHA_F as pha
WHERE
  (prs.FLX_D15_DTD = pha.FLX_D15_DTD) AND (prs.FLX_TRT_DTD = pha.FLX_TRT_DTD) AND
  (prs.FLX_DMT_TYP = pha.FLX_DMT_TYP) AND (prs.FLX_DMT_NUM = pha.FLX_DMT_NUM) AND
  (prs.FLX_DMT_ORD = pha.FLX_DMT_ORD) AND (prs.ORG_CLE_NUM = pha.ORG_CLE_NUM) AND
  (prs.DCT_ORD_NUM = pha.DCT_ORD_NUM) AND (prs.DCT_ORD_NUM = pha.ORG_CLE_NUM) AND
  (prs.REM_TYP_AFF = pha.REM_TYP_AFF) AND (prs.PRS_ORD_NUM = pha.PRS_ORD_NUM) AND
  (BEN_NIR_PSA = '123456789')
ORDER BY
  EXE_S01_DTD,
  PHA_PRS_IDE;
```

Requête SQL

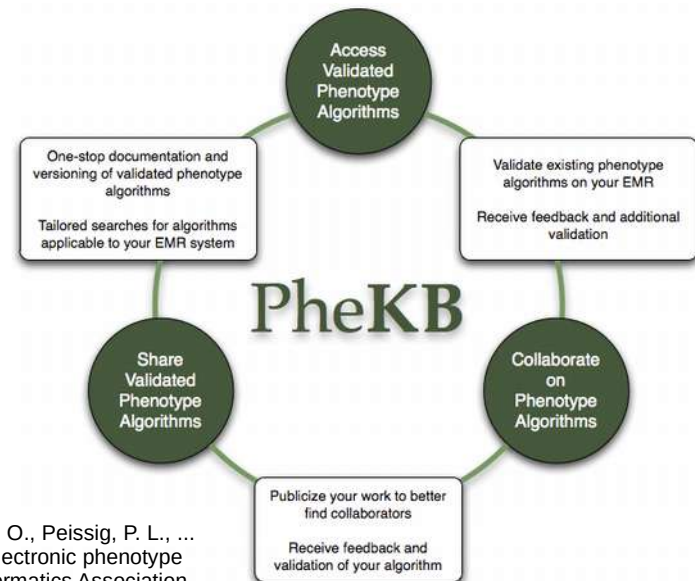


Fossé sémantique – illustrations pratiques

- Enrichir à l'aide d'**information phénotypique**
 - Données disponibles : des prescriptions de soins
 - Information médicale pertinente : le patient est atteint de telle maladie ou de tel syndrome (sur telle période)
 - Enjeux de précision des algorithmes d'identification

ReDSiam

Réseau pour mieux utiliser les Données
du Système national des données de santé



Kirby, J. C., Speltz, P., Rasmussen, L. V., Basford, M., Gottesman, O., Peissig, P. L., ... & Ellis, S. B. (2016). PheKB: a catalog and workflow for creating electronic phenotype algorithms for transportability. *Journal of the American Medical Informatics Association*, 23(6), 1046-1052.

Fossé sémantique – illustrations pratiques

- Enrichir à l'aide d'information phénotypique
 - Données disponibles : des prescriptions de soins
 - Information médicale pertinente : le patient est atteint de telle maladie ou de tel syndrome (sur telle période)
 - Enjeux de précision des algorithmes d'identification
- Reconstruction des **expositions aux médicaments**
 - Données disponibles : **délivrances** de **boîtes de médicament**
 - Information médicale pertinente : **exposition** à **une molécule** (avec une **dose journalière**)
 - Quelques difficultés :
 - Multitude de **boites** pour une même **molécule**, et pour la même **posologie**
 - Posologie prescrite inconnue
 - Anticipation ou masquage de délivrances

Problématique et approche

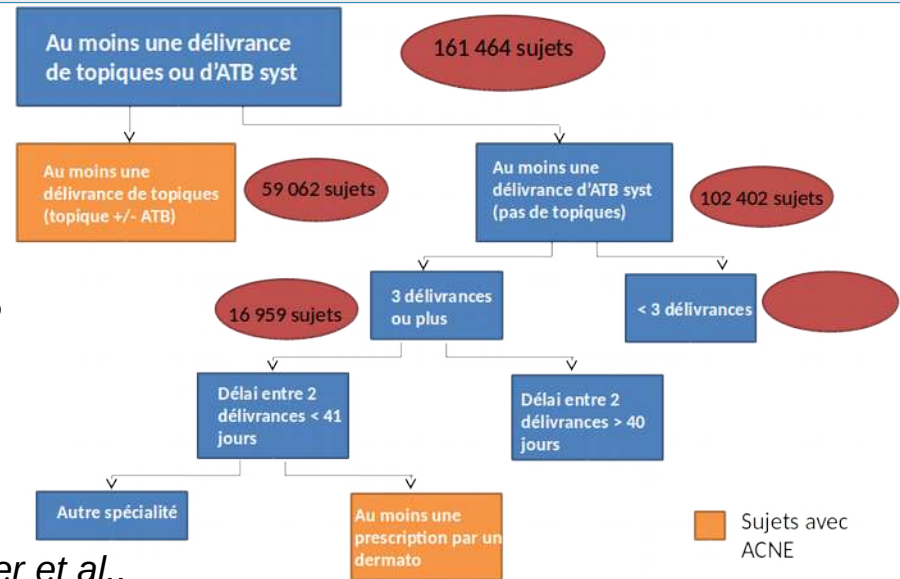
- Proposer des **outils pour faciliter l'enrichissement des données du SNDS** vers de données exploitables par des méthodes d'analyse de données pour en tirer des informations médicales
- Notre approche
 - Modélisation de « parcours de soins » : conserver la richesse de temporelle et descriptive du SNDS
 - Exploiter des connaissances du domaine : intégrer des connaissances formalisées (taxonomies ATC, CIM10, CCAM, ...)
 - Approche générique : fournir un cadre pour la conception d'outils répondant à un grand nombre d'études
- Notre proposition
 - Langage de requête hybride dédié aux études de pharmaco-épidémiologies

Langage de requête dédié

- Langage SQL

```
SELECT
EXE_SOI_DTD, PHA_PRS_IDE, PFS_PRE_NUM, PFS_EXE_NUM,
PSE_SPE_COD, PSP_SPE_COD, PSE_ACT_NAT, PSP_ACT_NAT
FROM
ER_PRS_F as prs,
ER_PHA_F as pha
WHERE
(prs.FLX_DIS_DTD = pha.FLX_DIS_DTD) AND (prs.FLX_TRT_DTD = pha.FLX_TRT_DTD) AND
(prs.FLX_EMT_TYP = pha.FLX_EMT_TYP) AND (prs.FLX_EMT_NUM = pha.FLX_EMT_NUM) AND
(prs.FLX_EMT_ORD = pha.FLX_EMT_ORD) AND (prs.ORG_CLE_NUM = pha.ORG_CLE_NUM) AND
(prs.DCT_ORD_NUM = pha.DCT_ORD_NUM) AND (prs.PRS_ORD_NUM = pha.PRS_ORD_NUM) AND
(prs.REM_TYP_AFF = pha.REM_TYP_AFF) AND
(BEN_NIR_PSA = '123456789')
ORDER BY
EXE_SOI_DTD,
PHA_PRS_IDE;
```

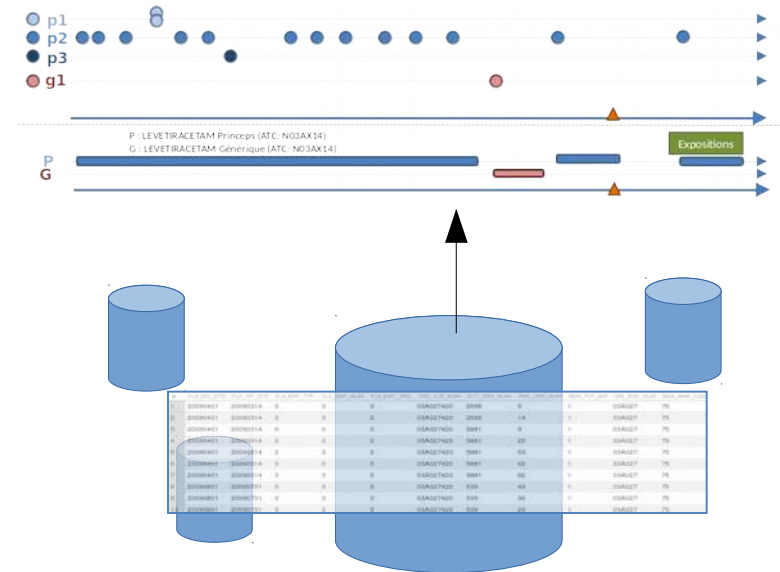
- « Langage » dédié pour la réalisation de la préparation des données de pharmaco-epidemiologie



ISOPSY, E. Oger et al.,
REPERES

Modèle de parcours de soins

- Modèle de données orienté parcours de soins
 - Collection de patients
 - Pour chaque patient
 - Ensemble d'évènements datés et attribués
 - Caractéristiques propre à un patient (eg. Statut ALD, Sexe, date de naissance)
- Modèle de données très générique et flexible
- Représentation formelle en logique du premier ordre
 - RDF
 - Datalog



```
sex(m). by(1980). zipcode(25700).  
seq(0,0, drug(c01da02,1)).  
seq(10,10, drug(r01ad52,3)).  
seq(31,31, drug(c07aa07,1)).  
seq(8,8, act(hnca006)).  
seq(35,39, hosp(k350)).
```


Éléments d'une étude de pharmaco-épidémiologie

- Algèbre d'opérations « élémentaires » sur des « parcours de soins »

- Sélection de patients sur un critère $\sigma_{\varphi}(D)$

- eg. sélection des **patients épileptiques**

- Projection d'événements sur un critère attributaires $\pi_{\varphi}(D)$

- eg. sélection des **antiépileptiques**

- Sélection d'événements sur critère temporels $\tau_{\varphi}(D)$

- eg. événements **avant une hospitalisation**


- Induction d'événements $\iota_{\varphi}(D)$

- eg. **exposition à un antiépileptique**

- Labellisation d'un patient sur un critère

- eg. patients avec switches

$$\lambda(\iota_{\varphi}(\tau_{\varphi}(\pi_{\varphi}(\sigma_{\varphi}(D))))))$$



Éléments d'une étude de pharmaco-épidémiologie

- Algèbre d'opérations « élémentaires » sur des « parcours de soins »

- Sélection de patients sur un critère $\sigma_{\varphi}(D)$

- eg. sélection des **patients épileptiques**

- Projection d'événements sur un critère attributaires $\pi_{\varphi}(D)$

- eg. sélection des **antiépileptiques**

- Sélection d'événements sur critère temporels $\tau_{\varphi}(D)$

- eg. événements **avant une hospitalisation**


- Induction d'événements $\iota_{\varphi}(D)$

- eg. **exposition à un antiépileptique**

- Labellisation d'un patient sur un critère

- eg. patients avec switches

$$\lambda(\iota_{\varphi}(\tau_{\varphi}(\pi_{\varphi}(\sigma_{\varphi}(D))))))$$



Éléments d'une étude de pharmaco-épidémiologie

- Algèbre d'opérations « élémentaires » sur des « parcours de soins »

- Sélection de patients sur un critère $\sigma_{\varphi}(D)$

- eg. sélection des **patients épileptiques**

- Projection d'événements sur un critère attributaires $\pi_{\varphi}(D)$

- eg. sélection des **antiépileptiques**

- Sélection d'événements sur critère temporels $\tau_{\varphi}(D)$

- eg. événements **avant une hospitalisation**



- Induction d'événements $\iota_{\varphi}(D)$

- eg. **exposition à un antiépileptique**

- Labellisation d'un patient sur un critère

- eg. patients avec switches

$$\lambda(\iota_{\varphi}(\tau_{\varphi}(\pi_{\varphi}(\sigma_{\varphi}(D))))))$$



Éléments d'une étude de pharmaco-épidémiologie

- Algèbre d'opérations « élémentaires » sur des « parcours de soins »

- Sélection de patients sur un critère $\sigma_{\varphi}(D)$

- eg. sélection des **patients épileptiques**

- Projection d'événements sur un critère attributaires $\pi_{\varphi}(D)$

- eg. sélection des **antiépileptiques**

- Sélection d'événements sur critère temporels $\tau_{\varphi}(D)$

- eg. événements **pas après une hospitalisation**


- Induction d'événements $\iota_{\varphi}(D)$

- eg. **exposition à un antiepileptique**

- Labellisation d'un patient sur un critère

- eg. patients avec switches

$$\lambda(\iota_{\varphi}(\tau_{\varphi}(\pi_{\varphi}(\sigma_{\varphi}(D))))))$$



Éléments d'une étude de pharmaco-épidémiologie

- Algèbre d'opérations « élémentaires » sur des « parcours de soins »

- Sélection de patients sur un critère $\sigma_{\varphi}(D)$

- eg. sélection des **patients épileptiques**

- Projection d'événements sur un critère attributaires $\pi_{\varphi}(D)$

- eg. sélection des **antiépileptiques**

- Sélection d'événements sur critère temporels $\tau_{\varphi}(D)$

- eg. événements **avant une hospitalisation**




- Induction d'événements $\iota_{\varphi}(D)$

- eg. **exposition à un antiépileptique**

- Labellisation d'un patient sur un critère

- eg. patients avec switches

$$\lambda(\iota_{\varphi}(\tau_{\varphi}(\pi_{\varphi}(\sigma_{\varphi}(D))))))$$



Éléments d'une étude de pharmaco-épidémiologie

- Algèbre d'opérations « élémentaires » sur des « parcours de soins »

- Sélection de patients sur un critère $\sigma_{\varphi}(D)$

- eg. sélection des **patients épileptiques**

- Projection d'événements sur un critère attributaires $\pi_{\varphi}(D)$

- eg. sélection des **antiépileptiques**

- Sélection d'événements sur critère temporels $\tau_{\varphi}(D)$


- eg. événements **avant une hospitalisation**










- Induction d'événements $\iota_{\varphi}(D)$

- eg. **exposition à un antiépileptique**

- Labellisation d'un patient sur un critère

- eg. patients avec switches

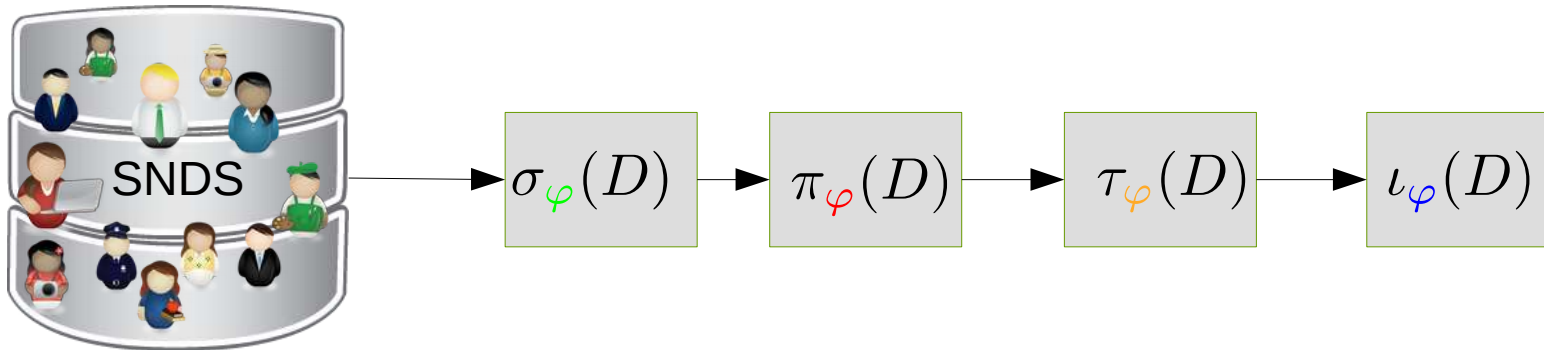


| | | |
|---|---|---|
|  |  |  |
|  |  | |
|  | |  |
|  | |  |

$$\lambda(\iota_{\varphi}(\tau_{\varphi}(\pi_{\varphi}(\sigma_{\varphi}(D))))))$$

Éléments d'une étude de pharmaco-épidémiologie


- Algèbre d'opérations « élémentaires » sur des « parcours de soins »
 - Représentation graphique (workflow)



$$\lambda(\iota_\varphi(\tau_\varphi(\pi_\varphi(\sigma_\varphi(D))))))$$

Éléments d'une étude de pharmaco-épidémiologie

- Exemple de l'étude GENEPI
 - Représentation d'une étude de type case-crossover



Critères des opérateurs

- Critères complexes (phénotypiques, informationnels ou inductifs)
 - Besoin d'intégrer des raisonnements complexes sur les parcours de soins
 - Besoin de flexibilité pour exprimer des contraintes variées
- Critères exprimés sous une forme de logique du premier ordre
 - Expressivité élevée
 - Lisibilité et flexibilité de contraintes
- Résolution hybride
 - Contraintes exprimées par des programmes logiques
 - utilisation de solveur ASP (clingo)

$$o_{\varphi}(D) = \{d \in D \mid d, \mathcal{M} \models \varphi\}$$

Gebser, M., Kaminski, R., Kaufmann, B., & Schaub, T. (2014). Clingo= ASP+ control: Preliminary report. arXiv preprint arXiv:1405.3694.

Exemple d'expression de critère

- Période de stabilité d'un traitement antiépileptique : une année sans crise et au moins 10 délivrances d'antiépileptique

```
#const nb_delivery=10.
#const p_duration=365.

aed(AED) :- AED=(n03ax09;n03ax14;n03ax11;n03ag01;n03af01;n03af02).

%% choice of the index date as a crisis event
1{ end(T) : seq(T, 9999), T>p_duration } 1.

begin(TB) :- end(T), TB=T-p_duration.

%% no crisis within the period
:- 1 { seq(T,9999) : T<E, T>=B }, end(E), begin(B).

%% number of deliveries of class AED
nbprescript(AED,N) :- N=#sum{T:seq(T,C), T<E, T>=B, cip(C,AED) },
begin(B), end(E), aed(AED).

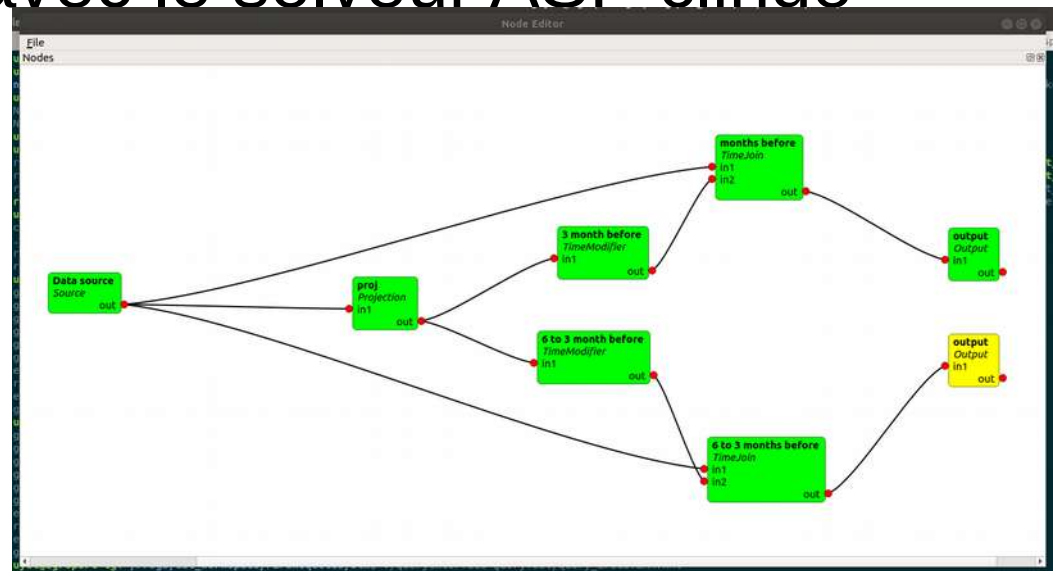
stable :- N>=nb_delivery, nbprescript(AED,N), aed(AED).
:- not stable.
```

φ :

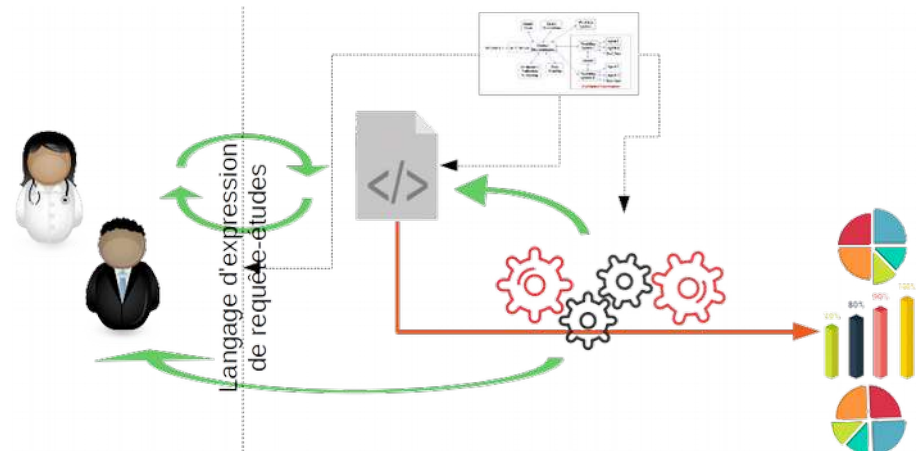
Preuve de concept

- Outil basé sur un modèle de données SNDS simplifié
- Implémentation des opérateurs et du moteurs d'exécution de requêtes
 - Interconnexion avec le solveur ASP clingo

- Interface de visualisation des workflows

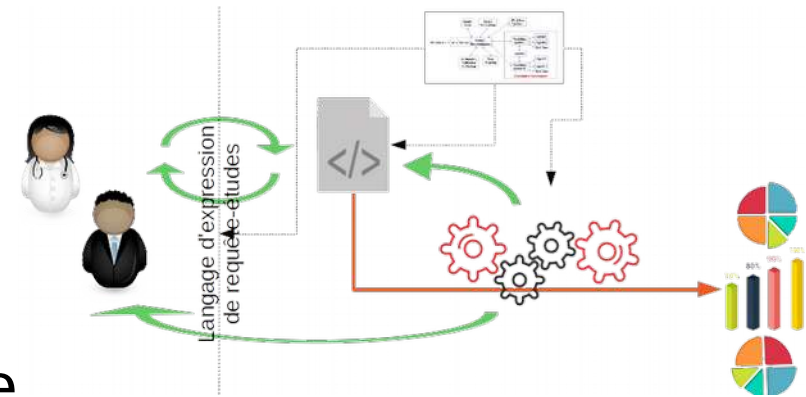


En résumé ...



Vers la (semi-)automatisation des études ?

- Pourquoi (semi-)automatiser ?
 - Concentrer les épidémiologistes sur les tâches à valeur ajoutée
 - Faciliter la **réutilisation** et la reproductibilité des études
- Automatisation des études : Déterminer les workflows qui répondent le mieux à une étude
 - Ajout de variables dans les workflow
 - Optimiser les workflows : *Automatic Data Science*




Automating Data Science, Tijl De Bie, Luc De Raedt, Holger H. Hoos, Padhraic Smyth, Dagstuhl Seminar, 2018

Conclusions

- SNDS : source pour la *pharmaco-épidémiologie numérique*
 - source de données intéressantes
 - Usage secondaire => fossé sémantique
- **Modéliser et raisonner sur les parcours de soins permet de combler (en partie) le fossé sémantique**
 - Besoin d'outils pour faciliter ces manipulations
 - Besoin de méthodologie informatique pour augmenter les possibilités de la pharmaco-épidémiologie numérique
 - Flexibles et expressives : pour exploiter au mieux les données
 - Réutilisables et automatisables : pour focaliser les épidémiologistes sur les questions difficiles
- Techniques récentes de data science pour aborder la pharmaco-epi
- Présentation d'un système hybride
 - Conception d'une requête sous forme algébrique
 - Spécialisation des opérateurs algébriques par des spécifications logiques

Perspectives

- Déterminer des sous-classes de spécialisation d'opérateurs
 - La versatilité perd en performance
 - Identifier des sous-classes de spécialisation utiles et performants
 - Conserver l'expressivité sur les aspects temporels
 - Exploration du concept de chronique pour spécifier des situations d'intérêt
- Besoin d'expérimentations de nos outils
 - Sur son usage
 - Sur l'automatisation (partielle) de l'exécution des workflows
- Aller vers l'analyse automatique des études
 - Une étude dispose d'une représentation formalisée manipulable automatiquement



Merci de votre attention

Remerciements

- Pr. E. Oger
- PharmD. E. Polard
- A. Happe
- Equipe REPERES du CHU et de l'EHESP
- Equipes Inria/IRISA
- D. Gross-Amblard, O. Dameron, A. Termier, V. Masson,