


Renouvellement du service d'ingestion de catalogue VizieR

G.Landais , I. Brossard, N.
Barloy, F-X. Pineau, A. Vanhule



□ Le service d'ingestion VizieR



Le processus d'ingestion VizieR


- Mise en ligne des données (principalement tabulaires) issus d'articles, de missions terrestres ou spatiales
- Créée par F. Ochsenbein en **1995**
- Service certifié par le CTS (2018)



Statistiques

- 25,839 catalogues
- 62,694 tables
- **1,059,497 colonnes**
- 8,312,847 spectres
- 51,431 images
- ~ **1,200 nouveaux catalogues/an**

Origine des catalogues
VizieR



□ La FAIR-isation des données



Données traitées

- Les données sont mise en ligne par une équipe de documentaliste
- Des flux de données propres à l'origine des données (ex : Grand catalogues, A&A, AAS, ...) MAIS tous utilisent le même corpus et format de méta-données
- Des données majoritairement statiques (versioning et mise à jour rare)

Distribution

- L'entité est le catalogue qui est un "dataset" dont tous les éléments sont documentés
- Les données sont accessibles via une base de données unique et via différents formats et protocoles
- Distribution des métadonnées dans l'IVOA, ADS, EOSC, Recherche DataGouv.



□ Objectif de la migration



Essentiellement technologique

- Un code modulaire, plus simple à faire évoluer
- Utiliser des technologies plus récentes : C → Python

Conservative

- Doit pouvoir remettre en ligne les données historique (>98%)
- Conservation des méta-données existantes
- Doit s'insérer dans l'écosystème actuel (VizieR, CDS, IVOA ...)
- Conserver les habitudes des personnes en charge de l'ingestion

□ Objectif de la migration



Une migration du code qui s'insère dans la maintenance évolutive de VizierR

- Migration de SGBD Sybase → PostgreSQL (G.Landais, 2008)
- Recherche textuelle → Elasticsearch (Y.Bish, G.Landais, 2019)
- Indexation globale : Qbox → MOC (mocset, moc-cli, F-X. Pineau, 2023)
- Migration du système de gestion des grands catalogues : → AT2S (F-X. Pineau, 2024)
- Migration du système de gestion du traitement des données Spectres et images (N.Barloy)

Charge de travail

- Début des travaux : 2021, 2022
- Développeurs :
 - Permanent : G.Landais (20%), F-X.Pineau
 - contractuels : A.Vanhule (05/2022 → 11/2023), I. Brossard (05/2024 → ...)




Principe du traitement de mise en ligne



Le processus d'ingestion

- Programme en ligne de commandes (Linux) à l'usage des documentalistes du CDS
- Système **semi automatisé**
 - Extraction «**directe**» de méta-données:
 - Fichier ReadMe (générés par les auteurs ou les documentalistes)
 - Fichier de configuration (généré par les documentalistes)
 - Ressource externes (ex : BCS pour ORCID ou DOI article)
 - Extraction « **indirecte** » automatique de méta-données partir de textes issues (règles induites)

Détection de filtres, UCD, association de colonnes
Ex : erreur, ou alors rassembler positions et mouvement propres
- Opération sur les tables effectués , paramétrable dans le fichier de configuration



□ Les metadonnées de bases



Le fichier ReadMe

- Le fichier ReadMe (format ASCII) décrit les paquets (paquet SIP).
- Un format lisible (human readable)
- Contient les informations de bases, nécessaires à la **préservation** sur le long terme: auteur, abstract, description des colonnes, etc.

```
I/320          SPM 4.0 Catalog          (Girard+, 2011)
=====
Yale/San Juan Southern Proper Motion Catalog 4 (SPM4)
  Girard T.M., van Altena W.F., Zacharias N., Vieira K., Casetti-Dinescu D.I.,
  Castillo D., Herrera D., Lee Y.S., Beers T.C., Monet D.G., Lopez C.E.
  <Astron. J. 142, 15 (2011)>
  ~2011AJ...142...15G
  ~2011yCat.1320....0P
=====
ADC_Keywords: Positional data ; Proper motions ; Photometry, photographic ;
              Photometry, CCD
Keywords: Astrometry - Catalogs

Description:
  The SPM4 Catalog contains absolute proper motions, celestial
  coordinates, and B,V photometry for 103,319,647 stars and galaxies
  between the south celestial pole and -20 degrees declination. The
  catalog is roughly complete to V=17.5. It is based on photographic
  and CCD observations taken with the Yale Southern Observatory's
  double-astrograph at Cescro Observatory in El Leoncito, Argentina.
  The first-epoch survey, taken from 1965 to 1979, was entirely
  photographic. The second-epoch survey is approximately 1/3
  photographic (taken from 1988 to 1998) and 2/3 CCD-based (taken
  from 2004 through 2008).

  Full details about the creation of the SPM4.0 catalog can be found
  in the paper, and also in the document "spm4_doc.txt" file which
  describes the original files, accessible from
  http://www.astro.yale.edu/astrom/spm4cat/

File Summary:
-----
  FileName  Rec1  Records  Explanations
-----
  ReadMe    80      1      This file
  spm4.sam  165     1000    Sample of SPM4 output (out of 103319647 stars)
  spm4_doc.txt 80      671    Documentation of the SPM Catalog
-----

See also:
  http://www.astro.yale.edu/astrom/spm4cat/ : SPM Catalog 4 Home Page
  I/289 : UCAC2 Catalogue (Zacharias+ 2004)
  I/322 : UCAC4 Catalogue (Zacharias+ 2012)
  II/246 : 2MASS All-Sky Catalog of Point Sources (Cutri+ 2003)
  VII/233 : The 2MASS Extended sources (IPAC/UMass, 2003-2006)

Byte-by-byte Description of file: spm4.sam
-----
  Bytes  Format Units  Label  Explanations
-----
  1- 10  I10    ---  SPMID  Unique identifier (4)
 12- 22  F11.7 deg  RAdeg  Right ascension (J2000, epoch=2000.0)
 24- 34  F11.7 deg  DEdeg  Declination (J2000, epoch=2000.0)
 36- 40  F5.1 mas   e_RAdeg Error in right ascension at Epoch
 42- 46  F5.1 mas   e_DEdeg  Error in declination at Epoch
 48- 55  F8.2 as/yr pmRA   Absolute proper motion in RA (*cos(DE))
 57- 64  F8.2 as/yr pmDE   Absolute proper motion in Declination
 66- 71  F6.2 as/yr e_pmRA Error in pmRA at Epoch
 73- 78  F6.2 as/yr e_pmDE Error in pmDE at Epoch
 80- 86  F7.2 yr    Epoch  [1965/2007] weighted mean epoch of observation
 88- 94  F7.2 yr    Ep1     [1965/1982] weighted mean 1st-epoch
 96-102  F7.2 yr    Ep2     [1987/2007] weighted mean 2nd-epoch (2)
104-105 I2    ---  N1     [1/20] Number of 1st-epoch plates used
107-108 I2    ---  N2     [0/14] Number of 2nd-epoch plates used
110-110 I1    ---  Nc     [0/9] Number of 2nd-epoch CCD frames used (3)
112-116 F5.2 mag  Bmag   ? Johnson B magnitude estimation (1)
118-122 F5.2 mag  Vmag   ? Johnson V magnitude estimation (1)
124-124 I1    ---  ib     [1/3] source flag for B mag (1)
126-126 I1    ---  iv     [1/3] source flag for V mag (1)
128-133 F6.3 mag  Jmag   ? 2MASS J magnitude
135-140 F6.3 mag  Hmag   ? 2MASS H magnitude
142-147 F6.3 mag  Kmag   ? 2MASS Ks magnitude
149-149 I1    ---  iga1   [0/3] galaxy/extended-source flag (5)
151-151 I1    ---  ica1   [1/7] input catalog source flag (6)
-----

Note (1): ib and iv give the source of the magnitude estimation as:
  1 = compiled input catalog
  2 = 1st-epoch SPM plates
  3 = 2nd-epoch SPM CCD observations
```

□ Les métadonnées avancées



Le fichier de configuration d'ingestion d'un catalogue Vizier

- Le fichier de configuration (format ~LaTeX) contient les informations “riches” qui permettent d’avoir des données **interopérables**

Ex: UCD, filtres, définitions de liens, opération de crossmatch, etc

- Utilisation d'un **langage de macro** (basé sur LaTeX)

Exemple de commandes

- Déclaration d'une opération d'UNION

```
\vizMerge{ table[567] }{ plx }{ Parallax and motion fits for objects with high-quality  
(Table 5), low-quality (Table 6) and poor-quality (Table 7) parallaxes }
```

- Déclaration d'une opération de jointure

```
\vizPaste{ tablec2 tablec3 }{ galaxies }{ Model and galaxy parameters }
```

- Déclaration de l'ajout d'une colonne calculée (créant un lien sur une table externe avec le nombre de records)

```
\vizAddCount{ table1 }{ Nf }{ table4 2MASS=@{2MASS}}{ dbtype=i2 fmt=3d }  
{ \use{vPop}\lucd{NUMBER}Number of fit results for this star (link to Table 4) }
```

- Assignment d'un UCD

```
\vizUCD{ table6 }{ * Ratio* }{ =phot.flux;arith.ratio;em.radio }
```

- Déclaration de l'ajout de colonnes de position depuis un catalogue Vizier (~jointure sur table3.Seq=table5.ID ...)

```
\vizPosition{ table5 table6 table7 table8 }{ source=J/ApJS/235/4/table3 Seq=@{ID} Eq=J2000 Ep=2000 precool=5 }  
{ Positions from the 105-month Swift-BAT survey (Oh+, 2018, J/ApJS/235/4) }
```

- Ajout de colonnes “lien” sur Simbad (possible utilisation d'expressions de tests complexes)

```
\vizSimbad{ table1 }{ \ifmatch{VESTA}{${Name}}}{ \else{2MASS J${Name$3-}}}{ \fi }  
\vizSimbadName{ table8 }{ table8.sim }
```

□ Structurer les méta-données



Transformation des informations au format JSON

- ReadMe
- Fichier de config (LaTeX)
- UCD

```
{
  "expression": [
    {
      "latex": {
        "key": "\\vizSimbad",
        "parameter": {
          "expression": {
            "expression": [ { "string": "table1" } ]
          }
        }
      },
      "expression": {
        "expression": [
          {
            "latex": {
              "key": "\\lifmatch",
              "parameter": {
                "expression": {
                  "expression": [ { "string": "VESTA" } ]
                }
              }
            },
            "expression": {
              "expression": [ { "ref": "${Name}" } ]
            }
          }
        ]
      }
    }
  ]
}
```



Extrait de la sérialisation JSON du fichier de config


```
ID: "J/A+A/267/515"
global_info: { title: "Very cold C-rich circumstellar envelopes (Omont+ 1993)", year: "1993", authors: "Omont A., Loup C., Forveille T., te Lintel Hekkert P., Habing H., Sivagnanam P., ..." }
viz_tables:
  0:
    name: "table1"
    dbname: "c32670515t1"
    explain: "Supergiants"
    union:
      0:
        join:
          0:
            name: "table1.dat"
            desc: "Supergiants"
            line_count: 19
            line_len: 58
            columns:
              0: { class_type: "compute", name: "add_recno", param: "", ... }
              1:
                class_type: "simple"
                name: "No"
                dbname: "no"
                explain: "Identification number in table1 and table2"
                unit: null
                dbunit: null
                vounit: null
                bbb: "1-3"
                ffmt: "A3"
                fmt: "%-3s"
                type: "VT_CHAR"
                dbtype: "VT_CHAR"
                length: 3
                flags: "VO_DISPLAY | VO_SELECT | VO_FK"
                ucd1p: "meta.id"
              2: { class_type: "simple", name: "Name", dbname: "name", ... }
              3: { class_type: "simple", name: "Sp", dbname: "sp", ... }
              4: { class_type: "simple", name: "Region", dbname: "region", ... }
              5: { class_type: "simple", name: "LRS", dbname: "lrs", ... }
              6: { class_type: "simple", name: "FIRAS", dbname: "firas", ... }
              7: { class_type: "simple", name: "n", dbname: "n", ... }
            1: { name: "table2", dbname: "c32670515t2", explain: "Sources with CO(2-1) or HCN(1-0) emission", ... }
            2: { name: "table3", dbname: "c32670515t3", explain: "Non-detected sources", ... }
            3: { name: "table4", dbname: "c32670515t4", explain: "CO/HCN line ratios", ... }
            4: { name: "table5", dbname: "c32670515t5", explain: "Estimates of mass-loss rates", ... }
            5: { name: "master", dbname: "c32670515master", explain: "Master list of very cold C-rich sources, main sample (table A1) and additional sources (table A2)", ... }
    global_notes:
```

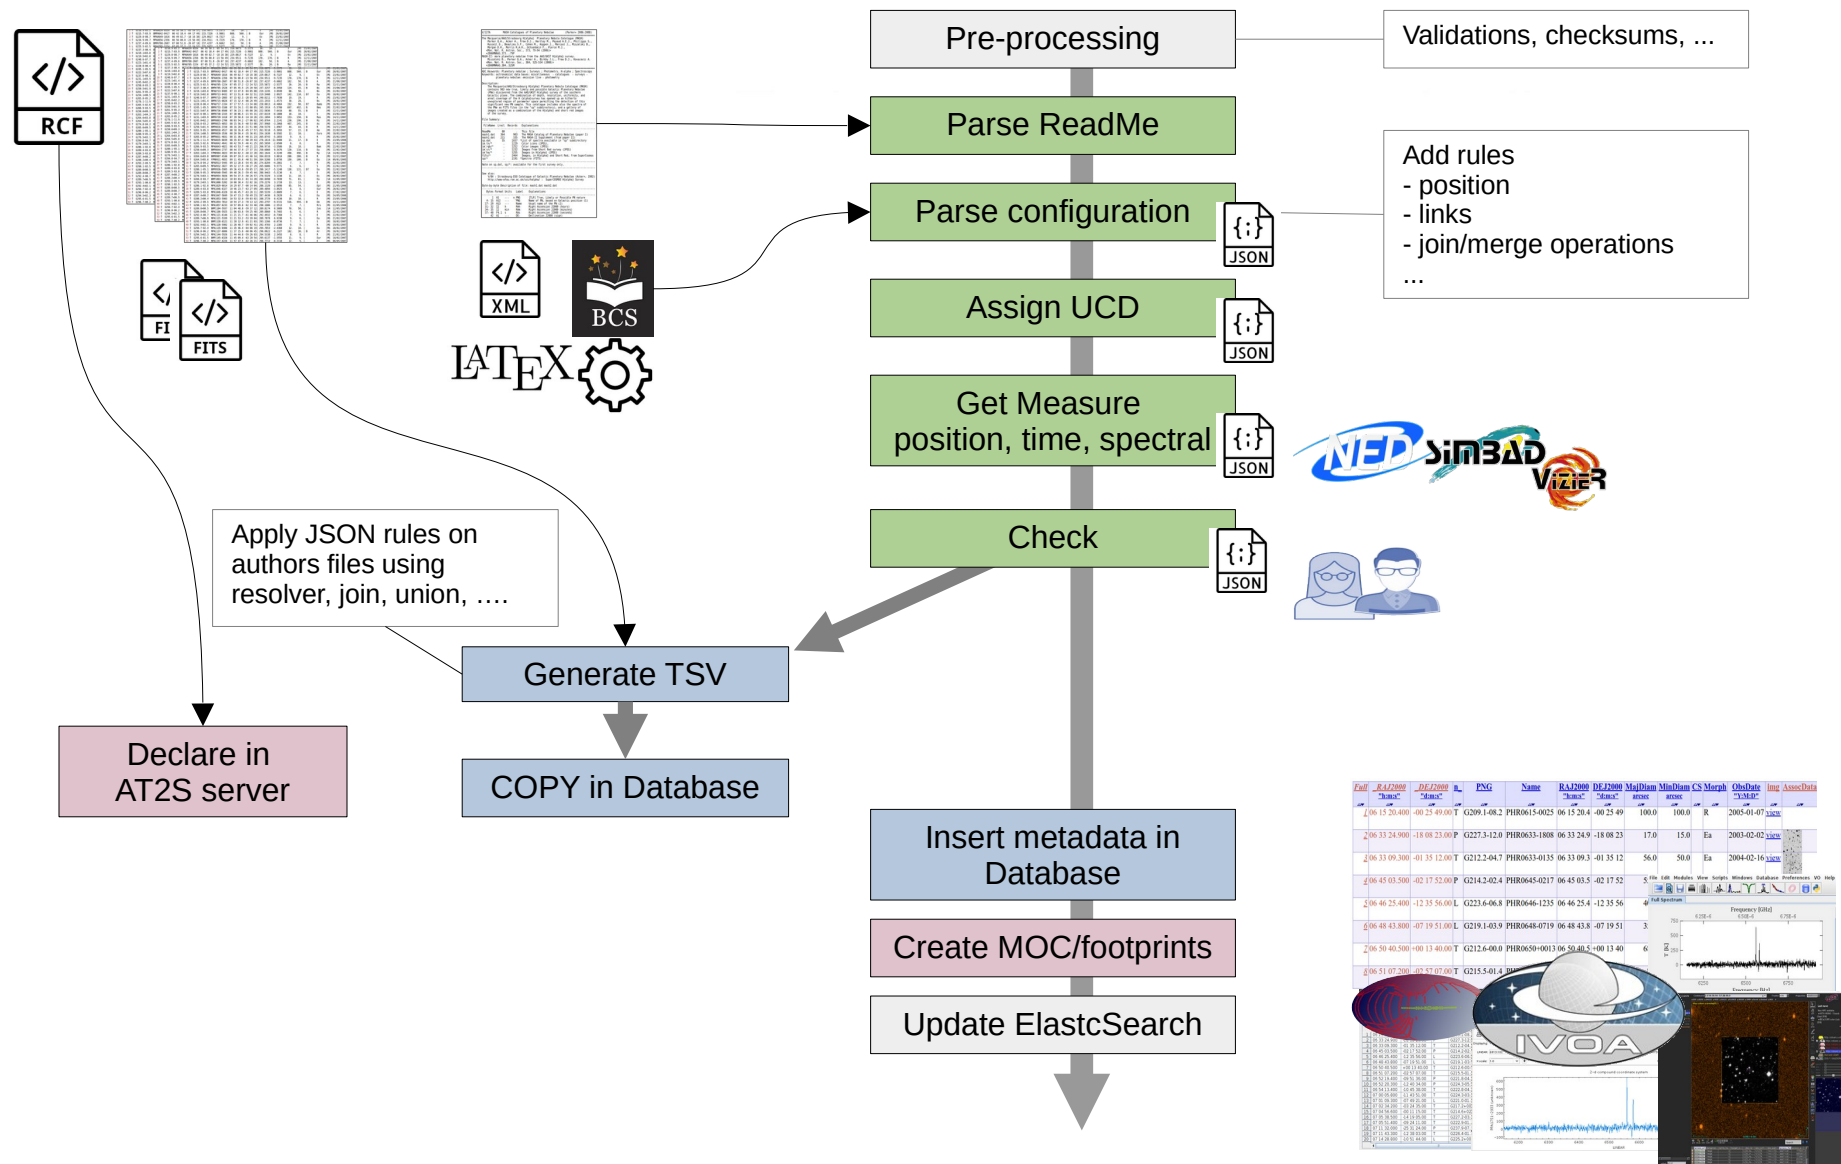
Extrait de la sérialisation JSON de l'ensemble des méta-données pour l'ingestion d'un catalogue

□ Structurer les méta-données



Diagramme de classes, utilisé par les API d'ingestion du catalogue VizierR





Technologies




Technologies

Languages: C, AWK, Cshell, LaTeX

Database: PostgreSQL

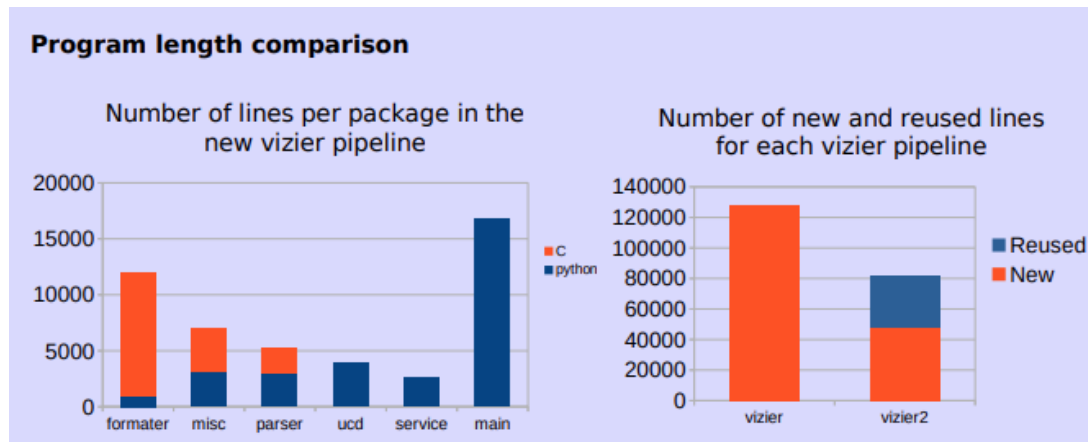
Dépendances: unity, healpix (nasa), erfa



Languages: C/C++, Rust, Python, LaTeX, BASH, ANTLR4

Databases: PostgreSQL, ElasticSearch, AT2S

Dépendances: unity, healpix (nasa), erfa, antlr




Graphes par I.Brossard, Poster ADASS, Goerlitz 2025

□ Quoi de 9 ?



- Il s'agit principalement d'une migration technologique
- Modification sur le stockages des colonnes float (stocke en float/double précision) avec gestion des valeurs NULLES
- Mais quelques nouveautés :
 - Intégration UCD1 → UCD1+ dans le workflow
 - Exploitation des liens en Datalink (cf I.Brossard, IVOA Goerlitz)
 - Indexation globale MOC (en prod)
 - Affiliation et ORCID généralisés (en cours)
 - Ajout des licences (en cours)

Extraction d'une série temporelle VizieR
via TOPCAT





Conclusions



- Une migration longue - 4 ans de labeurs
- ~130K lignes de codes, écrites en C dans un « ancien style »
- Manque de documentation :
De nombreuses règles induites, non documentées
- Des partis -pris historique n'ayant plus de raisons pratiques
- Un code plus optimisé pour l'ingestion des tables

```
(INFO) - database - Database Connection (psycpg): dbname=vizier user=asu port=5433 host=127.0.0.1
==> initialize database access [OK]
==> Parse Readme [OK]
==> Parse status [OK]
==> [OK]
(INFO) - database - Database Connection (psycpg): dbname=vizier user=asu port=5433 host=127.0.0.1
(WARN) - metabuild - \vizFoot not managed yet (\vizFoot{-scale 1})
(WARN) - metabuild - undefined vizSet attribute atEnd
(WARN) - metabuild - min dbtype i2t is ignored
==> Build basics metadata [OK]
==> Analyse UCD [OK]
==> Build columns metadata [OK]
(INFO) - database - Database Connection (psycpg): dbname=vizier user=asu port=5433 host=127.0.0.1
(WARN) - metabuild - Column u_Epoch doesn't look as a Time column
==> Build measures metadata [OK]
(ERROR) - metabuild - extract columns from tox \ifragexp{[A-Za-z0-9]*[A-Za-z0-9]* [A-V][A-Za-z][a-z]}{0!} \wSim{v* @!}{@!}\alse{@!}}{vi: Latex wSim is not defined: abort
==> Build computed metadata [OK]
==> Build resolver metadata [OK]
==> last check update [OK]
==> Check indexes [OK]
==> check UCD [OK]

-----
REPORT ReadMe/status analysis
- Table vsx (paste) vsx.dat,/home/cats/tmp/gl/vsx_n_010.match
Position: FKS , equinox=2000 (RAJ2000,DEJ2000,,,)
Time: Epoch system=HELIOCENTER_default,rep=JD
-----
(INFO) - database - Database Connection (psycpg): dbname=vizier user=asu port=5433 host=127.0.0.1
(INFO) - database - Database Connection (psycpg): dbname=vizier user=cds port=5433 host=127.0.0.1
==> remove catalogue [OK]
(INFO) a2csv: file /home/cats/B/vsx/refs.dat is gzipped

[.....] (3433601/10300701)
```