Les catalogues et GROBID

Simon Gabay, Mohamed Khemakhem, Laurent Romary

Les catalogues et GROBID

Simon Gabay
Université de Neuchâtel

Mohamed Khemakhem
ALMAnaCH
Paris 7
Centre Marc Bloch

Laurent Romary
ALMAnaCH
Centre Marc Bloch
BBAW

15 novembre 2018

L'encodage automatique de catalogues de vente en TEI avec *GROBID dictionaries*

GROBID (dictionaries)

Langages

La famille GROBID

- Bibliographie: `http://cloud.science-miner.com/grobid`
- NERD: `http://cloud.science-miner.com/nerd`
- Quantities: `http://cloud.science-miner.com/quantity`
- le petit nouveau: Dictionaries

Langages

GROBID dictionaries

- Développé par Mohamed Khemakhem (Paris VI-CMB/Humboldt)
- Initialement prévu pour les ressources lexicales numérisées (dictionnaires, glossaires, lexiques. . .)
- Détourenement du système pour les sources *Encyclopedic-like*
- Annuaires, catalogues. . .

L'encodage TEI et *GROBID dictionaries*

Langages

La TEI de *GROBID dictionaries*

- Les options d'encodage sont limitées...
- ...et basée sur la TEI pour les ressources lexicographiques
- la structure des dictionnaires et des catalogues est cependant similaire: on peut exploiter cette ressemblance...
- ...ce qui entraîne une utilisation quelque peu «métaphorique» de la TEI

ABERDEEN [*aberdin'*], v. d'Ecosse, ch.-l. de comté; port sur la mer du Nord; 170.000 h. Université.

ABERDEEN (G. H. Gordon, *comte d'*), homme d'Etat anglais, né à Edimbourg. Premier ministre en 1852, il conclut avec la France une alliance contre la Russie (1784-1860).

ABER-VRACH, fl. côtier du Finistère (Atlantique); 34 kil. Station marémotrice d'essai.

ABGAR, nom de huit rois d'Edesse, en Mésopotamie (132 av. J.-C.-216 apr.).

ABIA, roi de Juda, fils de Roboam, vainqueur de Jéroboam, roi d'Israël (957-955 av. J.-C.).

ABIDJAN, ch.-l. de la Côte-d'Ivoire (A.-O. F.), sur une vaste lagune navigable; 15.000 h.

ABIMÉLECH [*lèk*], fils de Gédéon. Il devint Juge d'Israël, après avoir fait égorger ses frères; il établit son pouvoir sur Sichem et fut tué au siège de Thèbes, en Palestine (vers 1100 av. J.-C.).

ABIRON, lévite qui fut englouti dans la terre avec Coré et Dathan, tous trois révoltés contre Moïse et Aaron (*Bible*).

Le *Petit Larousse illustré*

ABERDEEN (G. H. Gordon, *comte d'*), homme d'Etat anglais, né à Edimbourg. Premier ministre en 1852, il conclut avec la France une alliance contre la Russie (1784-1860).

```
<entry>
    <form type="lemma">
        <persName>ABERDEEN</persName>
        <addName>(G. H. Gordon, comte d')</addName><pc>,</pc>
        <desc>homme d'Etat anglais, né à Edimbourg</desc>
    </form>
    <pc>.</pc>
    <sense>
        <def>Premier ministre en 1852, il conclut avec la France
            une alliance contre la Russie (1784-1860)</def>
    </sense>
    <pc>.</pc>
</entry>
```

Le *Petit Larousse illustré*

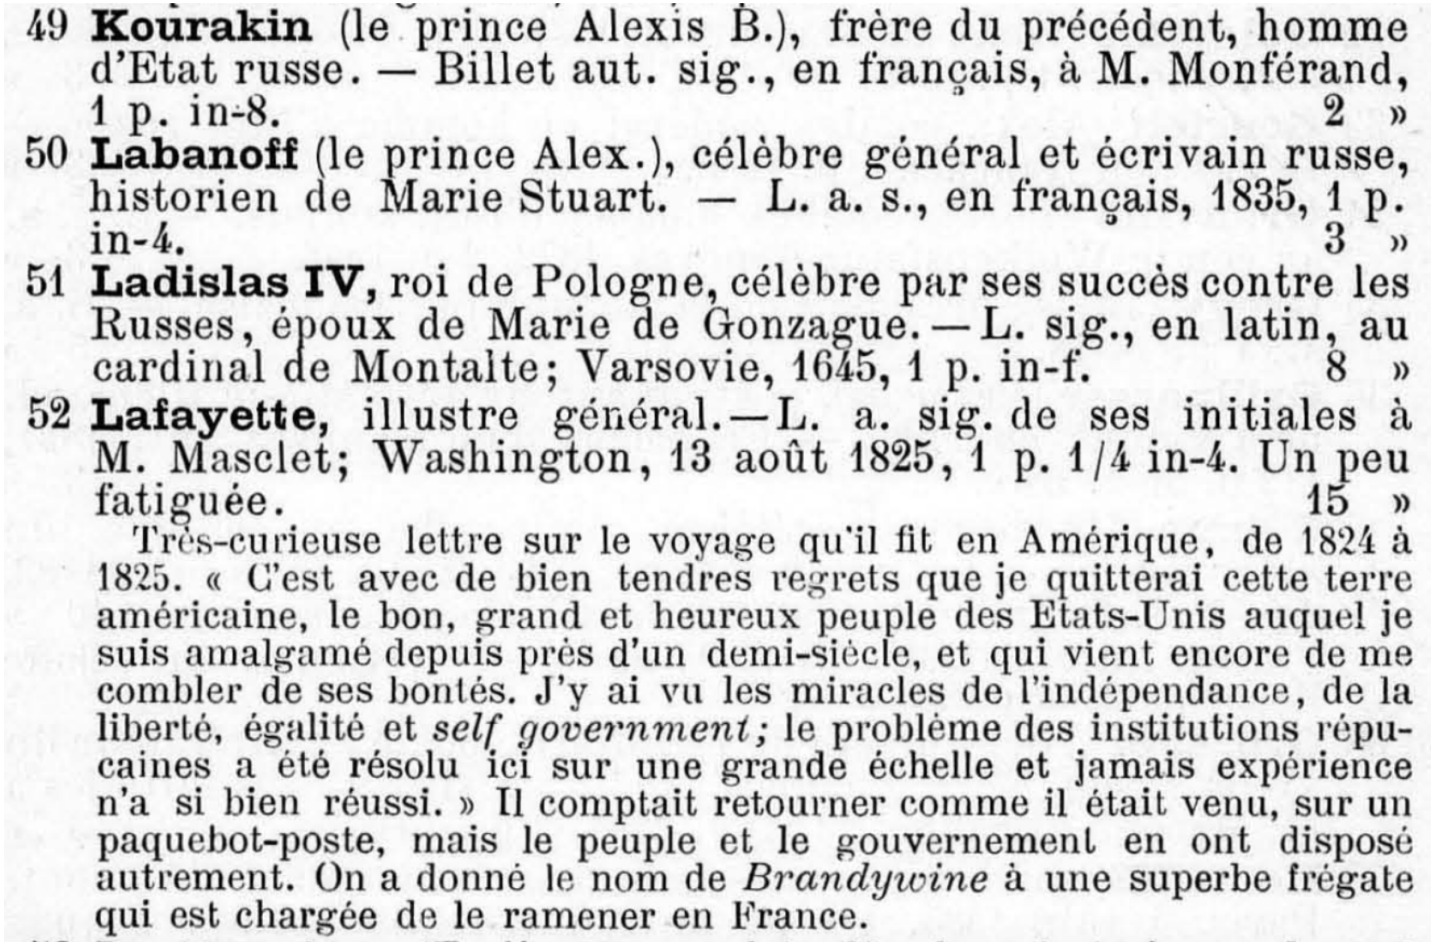

49 **Kourakin** (le prince Alexis B.), frère du précédent, homme d'Etat russe. — Billet aut. sig., en français, à M. Monférand, 1 p. in-8. 2 »

50 **Labanoff** (le prince Alex.), célèbre général et écrivain russe, historien de Marie Stuart. — L. a. s., en français, 1835, 1 p. in-4. 3 »

51 **Ladislas IV,** roi de Pologne, célèbre par ses succès contre les Russes, époux de Marie de Gonzague. — L. sig., en latin, au cardinal de Montalte; Varsovie, 1645, 1 p. in-f. 8 »

52 **Lafayette,** illustre général. — L. a. sig. de ses initiales à M. Masclet; Washington, 13 août 1825, 1 p. 1/4 in-4. Un peu fatiguée. 15 »

Très-curieuse lettre sur le voyage qu'il fit en Amérique, de 1824 à 1825. « C'est avec de bien tendres regrets que je quitterai cette terre américaine, le bon, grand et heureux peuple des Etats-Unis auquel je suis amalgamé depuis près d'un demi-siècle, et qui vient encore de me combler de ses bontés. J'y ai vu les miracles de l'indépendance, de la liberté, égalité et *self government;* le problème des institutions républicaines a été résolu ici sur une grande échelle et jamais expérience n'a si bien réussi. » Il comptait retourner comme il était venu, sur un paquebot-poste, mais le peuple et le gouvernement en ont disposé autrement. On a donné le nom de *Brandywine* à une superbe frégate qui est chargée de le ramener en France.

Revue des autographes

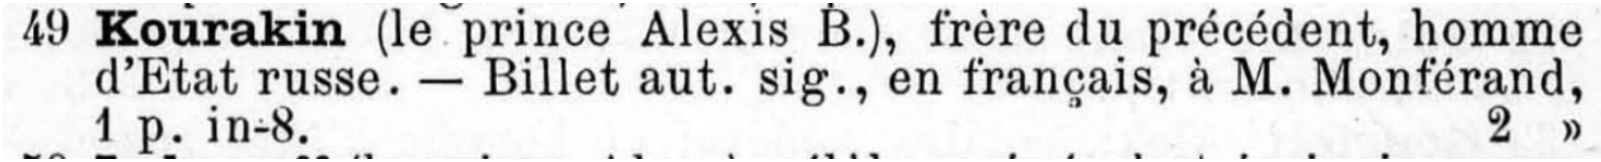

49 **Kourakin** (le prince Alexis B.), frère du précédent, homme d'Etat russe. — Billet aut. sig., en français, à M. Monférand, 1 p. in-8. 2 »

```
1  <entry>
2      <num>49</num>
3      <form type="lemma">
4          <surName>Kourakin</surName>
5          <addName>(le prince Alexis B.),</addName>
6          <desc> frère du précédent, homme d'Etat russe.</desc>
7      </form>
8      <sense>
9          <pc>-</pc>
10         <def>
11             <bibl>Billet auto sig., en francais, à M. Monférand, 1 p, in-
               8.</bibl> <num type="price">2 »</num>
12         </def>
13     </sense>
14 </entry>
```

Revue des autographes

Installer *GROBID dictionaries*

container docker

Quelques remarques

- *GROBID dicionaries* utilise un *container* docker (qu'il faut télécharger)
- Cela permet de fournir simplement un espace de travail avec toutes les librairies, dépendances et outils nécessaires
- L'installation se fait *via* le terminal

Ligne de commande

```
$ docker pull medkhem/grobid-dictionaries
```

Téléchargement du *container*

```
docker pull medkhem/grobid-dictionaries
Using default tag: latest
latest: Pulling from medkhem/grobid-dictionaries
bc9ab73e5b14: Pull complete
193a6306c92a: Pull complete
e5c3f8c317dc: Pull complete
a587a86c9dcb: Pull complete
a4c7ee7ef122: Pull complete
a7c0dad691e9: Pull complete
367a6a68b113: Pull complete
60c0e52d1ec2: Pull complete
c9d22bc43935: Pull complete
e3de5a273367: Pull complete
c8a45fcf02c1: Pull complete
a9cba52ae4f5: Pull complete
9a69063e63f8: Pull complete
7189b29e6a6d: Pull complete
e59d50656f46: Pull complete
de8d2ebe6e42: Pull complete
Digest: sha256:e7b30f49637da3c8ce86462418e11e2667b35e728d8a8036ee640d34bbd23e16
Status: Downloaded newer image for medkhem/grobid-dictionaries:latest
```

container docker

On lance docker

Ligne de commande

```
$ docker run -it medkhem/grobid-dictionaries bash
```

Données d'entraînement

Principe d'entraînement

- le *container* doit être synchronisé avec un dossier *toydata* (disponible sur `https://github.com/MedKhem/grobid-dictionaries`)
- C'est dans ce dossier *toydata* que vont être placées les données d'entraînement
- On exécute la commande [1]

Ligne de commande

```
$ docker run -v
PATH_TO_YOUR_TOYDATA/toyData:/grobid/grobid-dictionaries/r
-p 8080:8080 -it medkhem/grobid-dictionaries bash
```

[1] Nous sommes sur mac, pour les commandes sous windows, cf. `https://github.com/MedKhem/grobid-dictionaries`

Teaching GROBID dictionaries

Langages

Sous le capot

- Développé en Java
- Utilise des champs aléatoires conditionnels (*conditional random fields*), des modèles statistiques utilisés en reconnaissance des formes et plus généralement en apprentissage statistique
- Ces champs fonctionnent en cascade
- C'est donc du *machine learning*...
- ...et ça commence donc par du *machine teaching*

Premier niveau d'entraînement

Dictionary Segmentation

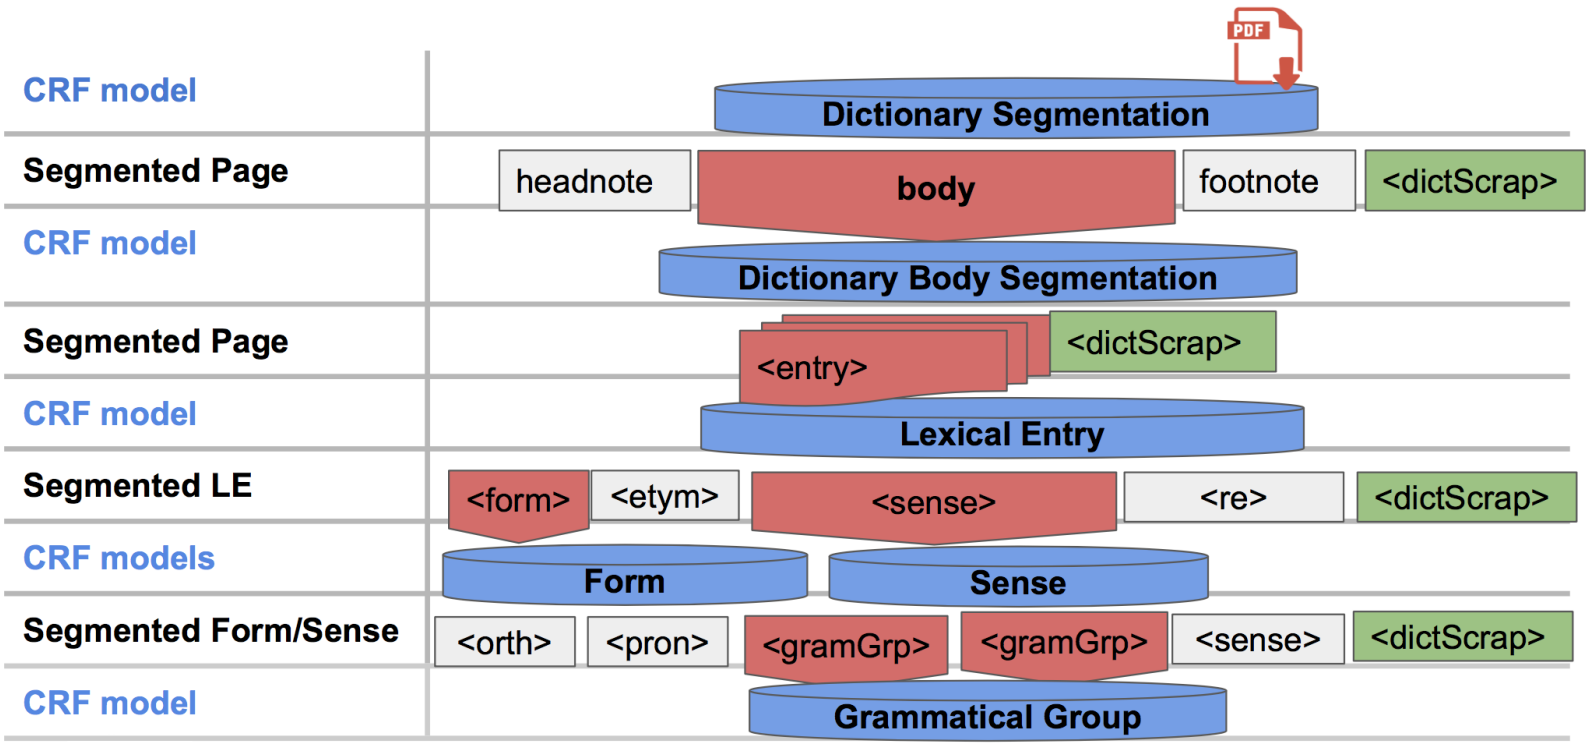

Dictionary Segmentation

L'objectif est de séparer le corps du texte du reste (titre courant, numéro de page. . .)

Entraînement

On crée les données d'entraînement

ligne de commande

```
$ java -jar

/grobid/grobid-dictionaries/target/grobid-dictionaries-0.4.3-SNAPSHOT.one-jar.jar -dIn

resources/dataset/dictionary-segmentation/corpus/pdf/ -dOut resources -exe

createTrainingDictionarySegmentation
```

On annote

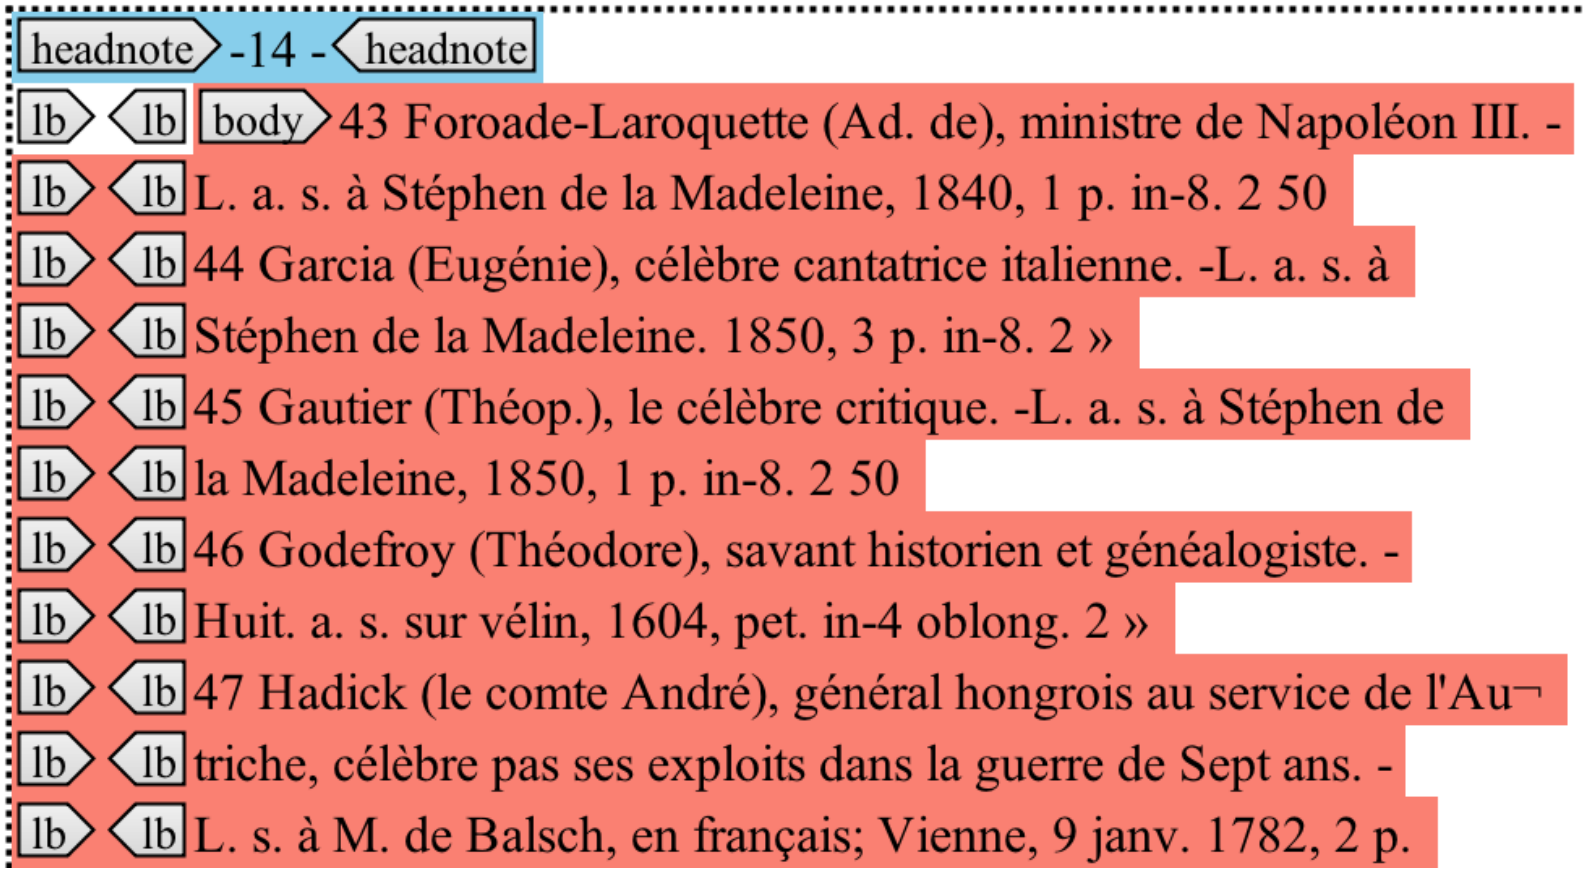
headnote -14 - headnote
lb lb body 43 Foroade-Laroquette (Ad. de), ministre de Napoléon III. -
lb lb L. a. s. à Stéphen de la Madeleine, 1840, 1 p. in-8. 2 50
lb lb 44 Garcia (Eugénie), célèbre cantatrice italienne. -L. a. s. à
lb lb Stéphen de la Madeleine. 1850, 3 p. in-8. 2 »
lb lb 45 Gautier (Théop.), le célèbre critique. -L. a. s. à Stéphen de
lb lb la Madeleine, 1850, 1 p. in-8. 2 50
lb lb 46 Godefroy (Théodore), savant historien et généalogiste. -
lb lb Huit. a. s. sur vélin, 1604, pet. in-4 oblong. 2 »
lb lb 47 Hadick (le comte André), général hongrois au service de l'Au¬
lb lb triche, célèbre pas ses exploits dans la guerre de Sept ans. -
lb lb L. s. à M. de Balsch, en français; Vienne, 9 janv. 1782, 2 p.

Entraînement

On entraîne à partir des données annotées

ligne de commande

```
$ mvn generate-resources -P train_dictionary_segmentation -e
```

L'entraînement est lancé

```
[ 301] obj=133.17    act=332    err= 0.02%/42.86% time=0.21s/51.04s
[ 302] obj=133.17    act=341    err= 0.01%/14.29% time=0.21s/51.25s
[ 303] obj=133.17    act=332    err= 0.02%/42.86% time=0.21s/51.46s
[ 304] obj=133.17    act=341    err= 0.01%/14.29% time=0.21s/51.67s
[ 305] obj=133.16    act=332    err= 0.02%/42.86% time=0.21s/51.88s
[ 306] obj=133.16    act=340    err= 0.01%/14.29% time=0.21s/52.09s
[ 307] obj=133.16    act=333    err= 0.02%/42.86% time=0.21s/52.29s
[ 308] obj=133.16    act=336    err= 0.01%/14.29% time=0.21s/52.50s
[ 309] obj=133.15    act=333    err= 0.01%/28.57% time=0.21s/52.71s
[ 310] obj=133.15    act=333    err= 0.00%/ 0.00% time=0.21s/52.92s
[ 311] obj=133.15    act=330    err= 0.01%/28.57% time=0.21s/53.13s
[ 312] obj=133.15    act=318    err= 0.00%/ 0.00% time=0.21s/53.34s
[ 313] obj=133.14    act=318    err= 0.01%/14.29% time=0.21s/53.55s
[ 314] obj=133.14    act=318    err= 0.00%/ 0.00% time=0.21s/53.76s
[ 315] obj=133.14    act=319    err= 0.01%/14.29% time=0.21s/53.97s
[ 316] obj=133.14    act=329    err= 0.00%/ 0.00% time=0.21s/54.17s
[ 317] obj=133.13    act=318    err= 0.01%/14.29% time=0.21s/54.38s
[ 318] obj=133.13    act=317    err= 0.00%/ 0.00% time=0.21s/54.59s
[ 319] obj=133.13    act=318    err= 0.01%/28.57% time=0.14s/54.73s
[ 320] obj=133.12    act=326    err= 0.00%/ 0.00% time=0.14s/54.87s
[ 321] obj=133.12    act=317    err= 0.01%/14.29% time=0.14s/55.00s
[ 322] obj=133.12    act=325    err= 0.00%/ 0.00% time=0.14s/55.14s
[ 323] obj=133.12    act=326    err= 0.01%/14.29% time=0.15s/55.29s
[ 324] obj=133.12    act=324    err= 0.00%/ 0.00% time=0.14s/55.43s
[ 325] obj=133.11    act=325    err= 0.01%/14.29% time=0.14s/55.57s
[ 326] obj=133.11    act=325    err= 0.00%/ 0.00% time=0.15s/55.72s
[ 327] obj=133.11    act=326    err= 0.01%/28.57% time=0.14s/55.86s
[ 328] obj=133.10    act=326    err= 0.01%/28.57% time=0.22s/56.07s
[ 329] obj=133.10    act=324    err= 0.01%/28.57% time=0.14s/56.21s
[ 330] obj=133.10    act=326    err= 0.01%/14.29% time=0.15s/56.36s
[ 331] obj=133.10    act=326    err= 0.02%/42.86% time=0.15s/56.51s
[ 332] obj=133.10    act=335    err= 0.01%/14.29% time=0.14s/56.64s
```

On contrôle la qualité de l'entraînement

```
label                accuracy     precision    recall       f1

<entry>              100          100          100          100
<pc>                 100          100          100          100

all fields ENTRY     100          100          100          100     (micro average)
                     100          100          100          100     (macro average)

===== Field-level results =====

label                accuracy     precision    recall       f1

<entry>              100          100          100          100
<pc>                 100          100          100          100

all fields           100          100          100          100     (micro average)
                     100          100          100          100     (macro average)

===== Instance-level results =====

Total expected instances:   2
Correct instances:          2
Instance-level recall:      100
```

Deuxième niveau d'entraînement

Body Segmentation

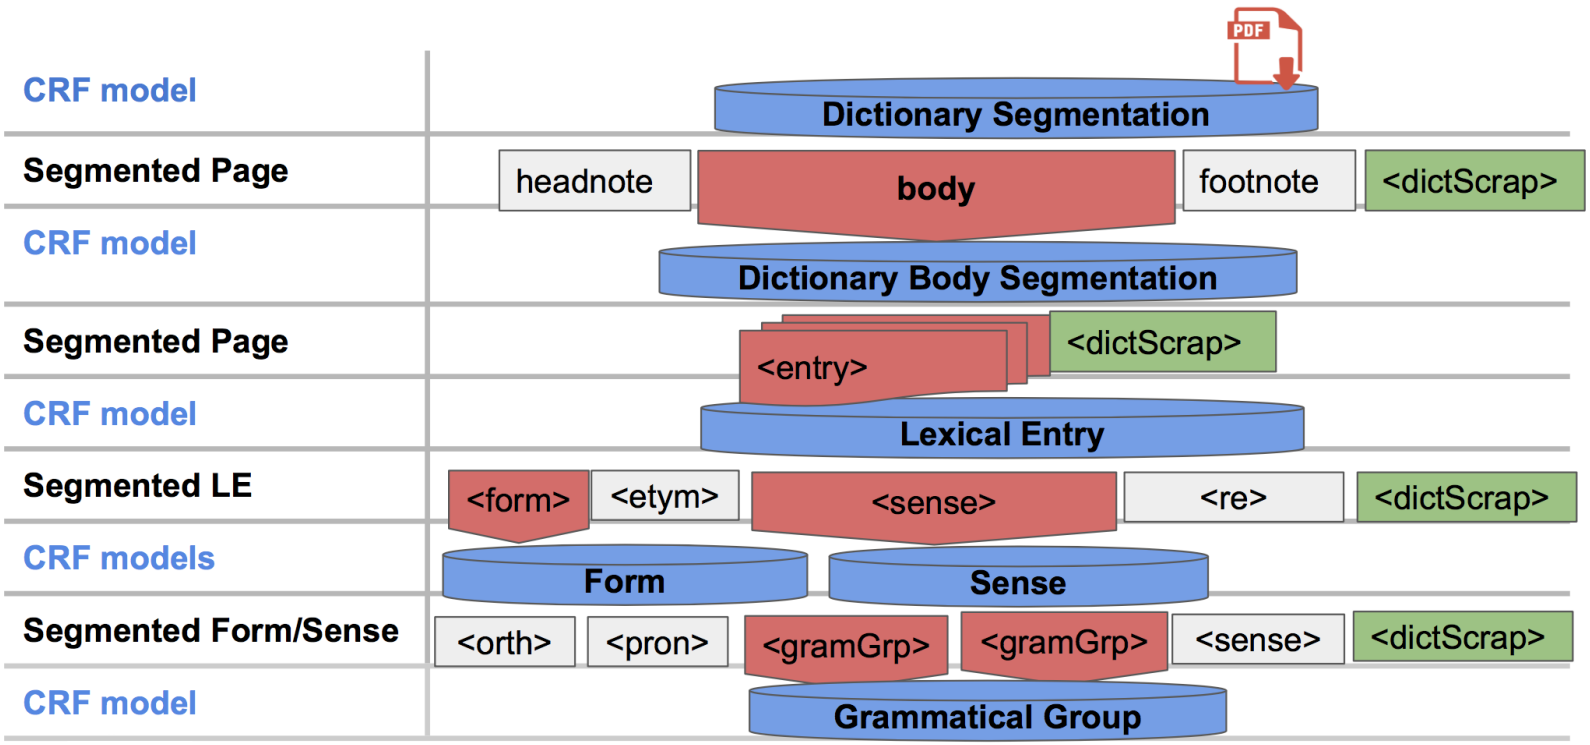

Body Segmentation

L'objectif est de séparer les différentes entrées

```
<entry>
    54

        Lassalle
        (A.-Ch.-L. de),
        le plus brillant général de cavalerie des guerres de la République et de
        l'EmpIre, né à Metz, tué à la bataille de Wagram

    .-

            L. a. s. au général Dugua; 1 p. in-f.
            10 »

        Superbe lettre sur la campagne d'Egypte. Il profite du départ du général Desaix
        pour lui donner des nouvelles. Desaix lui laisse le commandement de la colonne
        qui doit poursuivre Mourad-Bey, et qui se compose de 400 hommes de cavalerie, 4
        pièces de canon et 160 dromadaires. Le général Boyer a, dans une petite
        affaire, tué 10 mameloucks et 40 arabes, etc.

</entry>
```

Body Segmentation

Entraînement

On crée les données d'entraînement

ligne de commande

```
$ java -jar

/grobid/grobid-dictionaries/target/grobid-dictionaries-0.4.3-SNAPSHOT.one-jar.jar -dIn

resources/dataset/dictionary-segmentation/corpus/pdf/ -dOut resources -exe

createTrainingDictionaryBodySegmentation
```

On annote

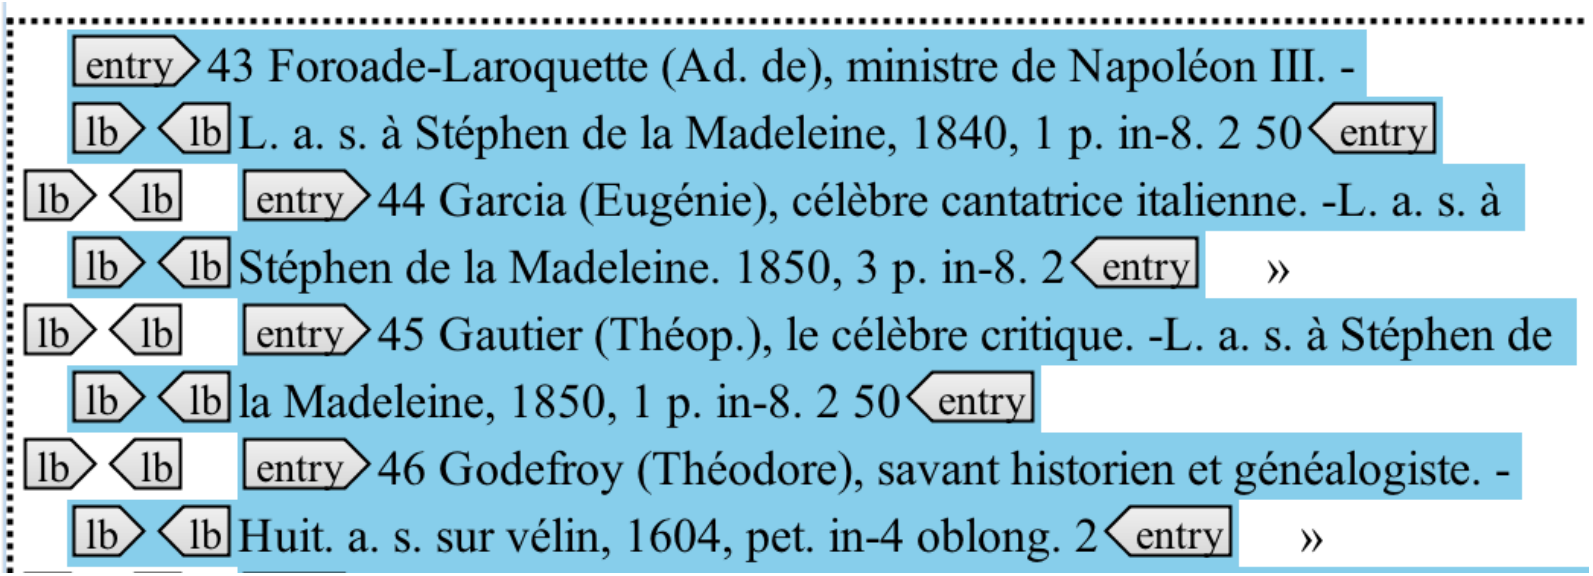
entry 43 Foroade-Laroquette (Ad. de), ministre de Napoléon III. -
lb lb L. a. s. à Stéphen de la Madeleine, 1840, 1 p. in-8. 2 50 entry
lb lb entry 44 Garcia (Eugénie), célèbre cantatrice italienne. -L. a. s. à
lb lb Stéphen de la Madeleine. 1850, 3 p. in-8. 2 entry »
lb lb entry 45 Gautier (Théop.), le célèbre critique. -L. a. s. à Stéphen de
lb lb la Madeleine, 1850, 1 p. in-8. 2 50 entry
lb lb entry 46 Godefroy (Théodore), savant historien et généalogiste. -
lb lb Huit. a. s. sur vélin, 1604, pet. in-4 oblong. 2 entry »

Entraînement

On entraîne à partir des données annotées

ligne de commande

```
$ mvn generate-resources -P train_dictionary_body_segmentation -e
```

Et on passe au modèle suivant

Troisième niveau d'entraînement

Lexical Entry

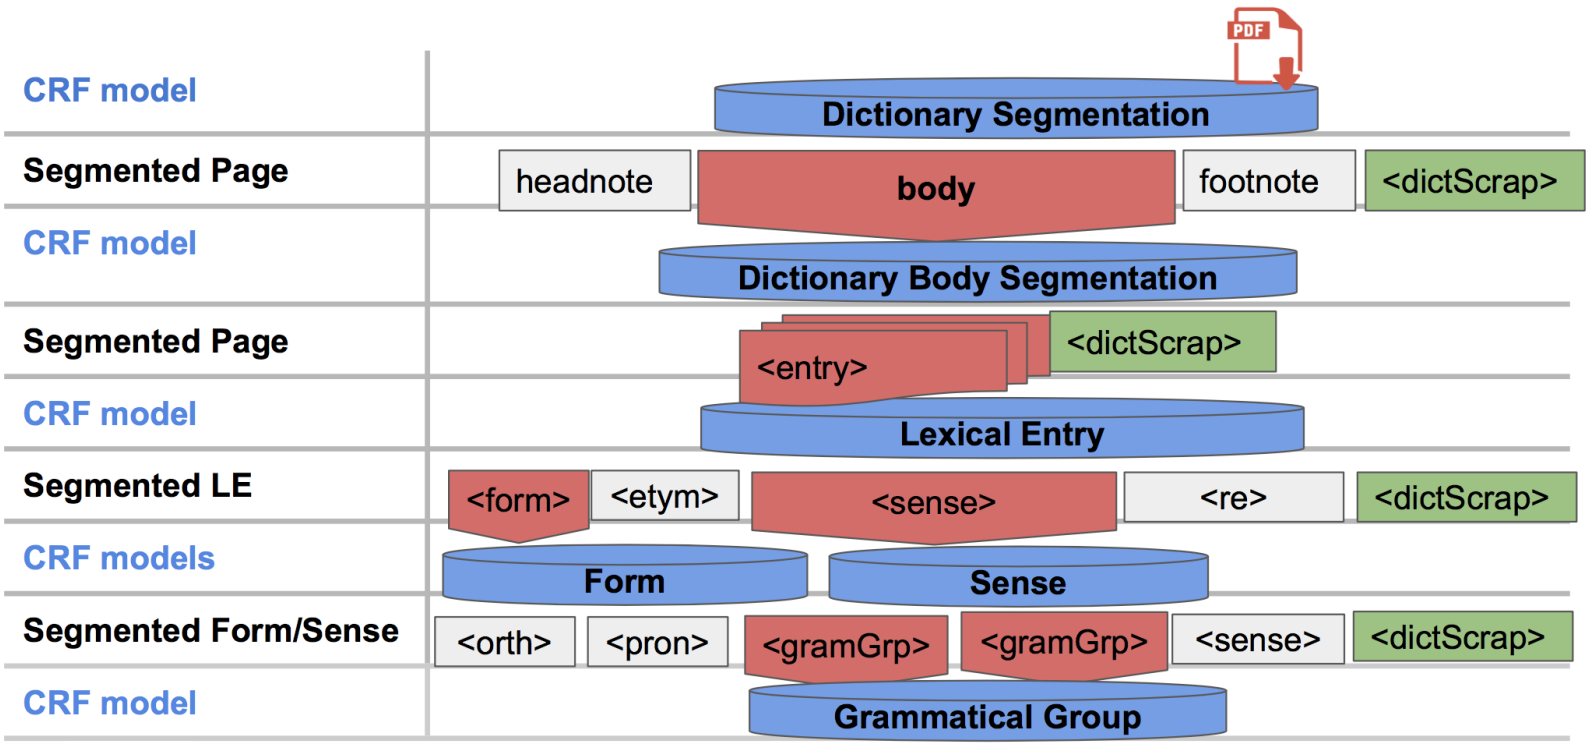

Lexical Entry

L'objectif est de séparer les grandes articulations de chaque entrée du catalogue

```
<entry>
    <num>54</num>
    <form type="lemma">
        Lassalle
        (A.-Ch.-L. de),
        le plus brillant général de cavalerie des guerres de la République et de
        l'EmpIre, né à Metz, tué à la bataille de Wagram
    </form>
    <sense> .-

            L. a. s. au général Dugua; 1 p. in-f.
            10 »

        Superbe lettre sur la campagne d'Egypte. Il profite du départ du général Desaix
        pour lui donner des nouvelles. Desaix lui laisse le commandement de la colonne
        qui doit poursuivre Mourad-Bey, et qui se compose de 400 hommes de cavalerie, 4
        pièces de canon et 160 dromadaires. Le général Boyer a, dans une petite
        affaire, tué 10 mameloucks et 40 arabes, etc.
    </sense>
</entry>
```

Lexical Entry

Entraînement

On crée les données d'entraînement

ligne de commande

```
$ java -jar

/grobid/grobid-dictionaries/target/grobid-dictionaries-0.4.3-SNAPSHOT.one-jar.jar -dIn

resources/dataset/dictionary-segmentation/corpus/pdf/ -dOut resources -exe

createTrainingLexicalEntry
```

On annote

num 43 num form Foroade-Laroquette (Ad. de), ministre de Napoléon III form. -
lb lb sense L. a. s. à Stéphen de la Madeleine, 1840, 1 p. in-8. 2 50 sense
lb lb

num 44 num form Garcia (Eugénie), célèbre cantatrice italienne form. - sense L. a. s. à
lb lb Stéphen de la Madeleine. 1850, 3 p. in-8. 2 sense

num 45 num form Gautier (Théop.), le célèbre critique form. - sense L. a. s. à Stéphen de
lb lb la Madeleine, 1850, 1 p. in-8. 2 50 sense
lb lb

Entraînement

On entraîne à partir des données annotées

ligne de commande

```
$ mvn generate-resources -P train_lexicalEntries -e
```

Et on passe au modèle suivant

Quatrième niveau d'entraînement

Form

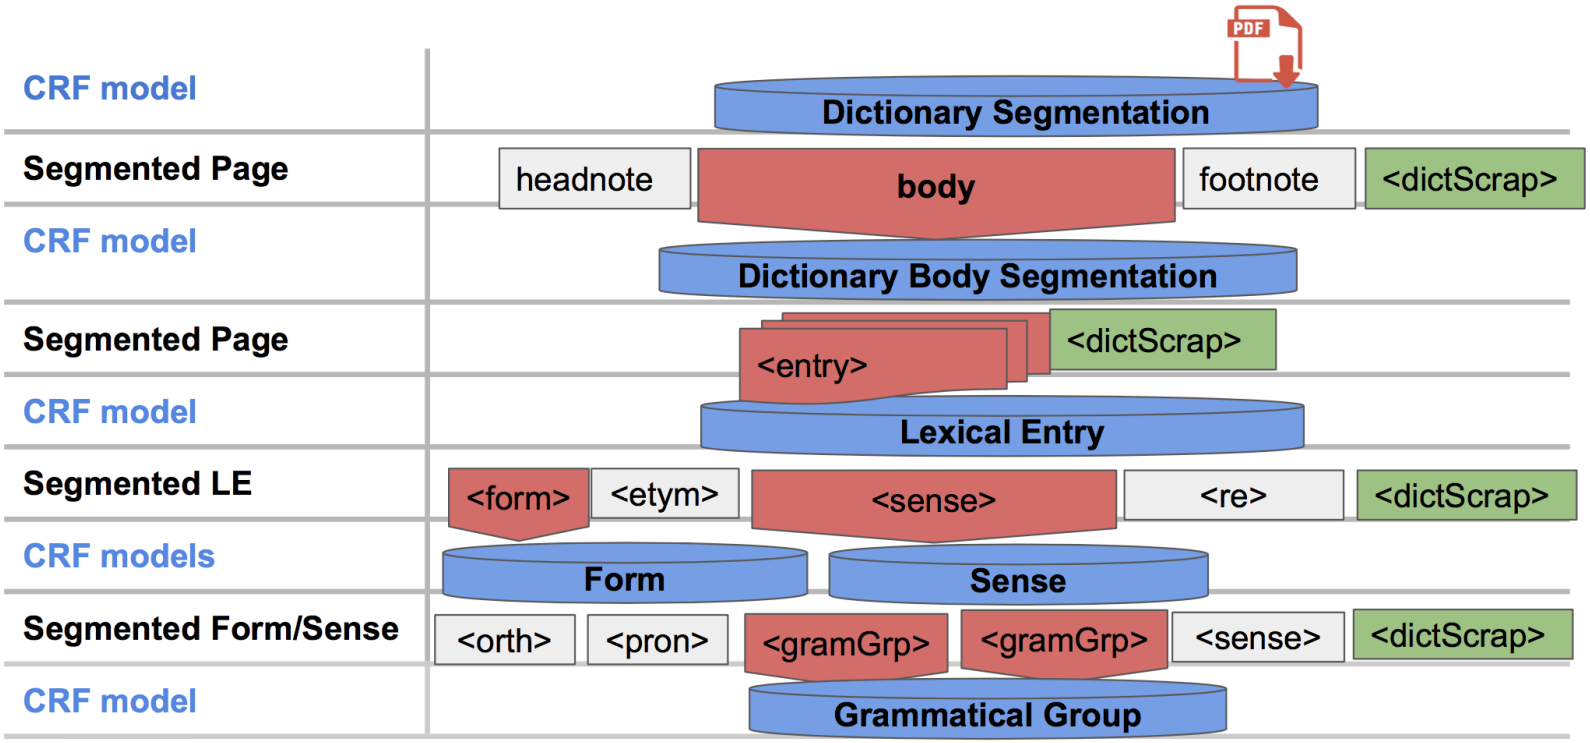
CRF model
Dictionary Segmentation
Segmented Page
headnote
body
footnote
<dictScrap>
CRF model
Dictionary Body Segmentation
Segmented Page
<entry>
<dictScrap>
CRF model
Lexical Entry
Segmented LE
<form>
<etym>
<sense>
<re>
<dictScrap>
CRF models
Form
Sense
Segmented Form/Sense
<orth>
<pron>
<gramGrp>
<gramGrp>
<sense>
<dictScrap>
CRF model
Grammatical Group

Form

On va traiter séparement le niveau *Form* et le niveau *Sense*, l'un après l'autre

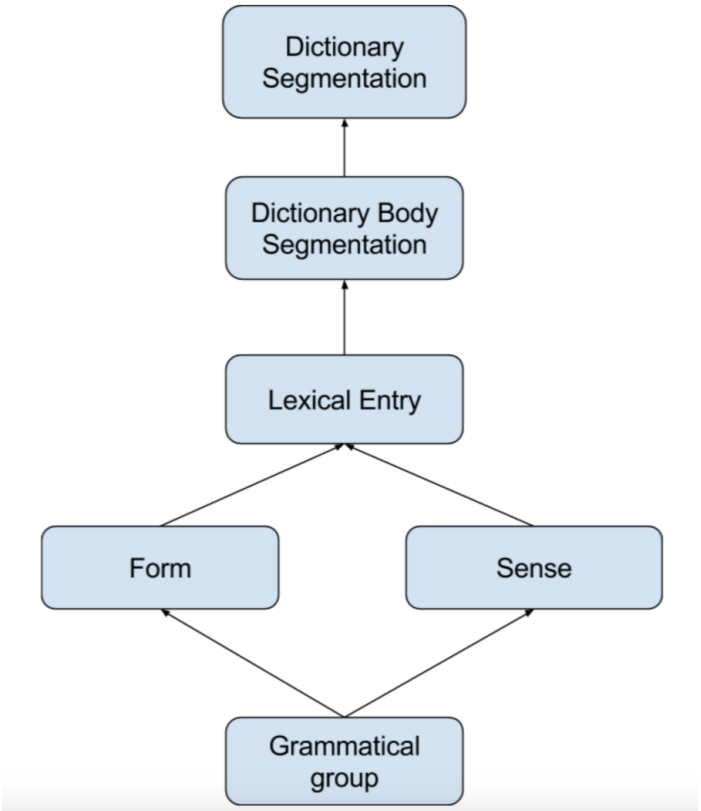

Form

L'objectif est de séparer les différentes informations dans <form> (nom et informations biographiques)

```
<entry>
    <num>54</num>
    <form type="lemma">
        <surname>Lassalle</surname>
        <addName>(A.-Ch.-L. de)</addName>,
        <desc>le plus brillant général de cavalerie des guerres de la République et de
        l'EmpIre, né à Metz, tué à la bataille de Wagram</desc>
    </form>
    <sense> .-

            L. a. s. au général Dugua; 1 p. in-f.
            10 »

        Superbe lettre sur la campagne d'Egypte. Il profite du départ du général Desaix
        pour lui donner des nouvelles. Desaix lui laisse le commandement de la colonne
        qui doit poursuivre Mourad-Bey, et qui se compose de 400 hommes de cavalerie, 4
        pièces de canon et 160 dromadaires. Le général Boyer a, dans une petite
        affaire, tué 10 mameloucks et 40 arabes, etc.
    </sense>
</entry>

```

Form

Entraînement

On crée les données d'entraînement

ligne de commande

```
$ java -jar

/grobid/grobid-dictionaries/target/grobid-dictionaries-0.4.3-SNAPSHOT.one-jar.jar -dIn

resources/dataset/dictionary-segmentation/corpus/pdf/ -dOut resources -exe

createTrainingForm
```

On annote

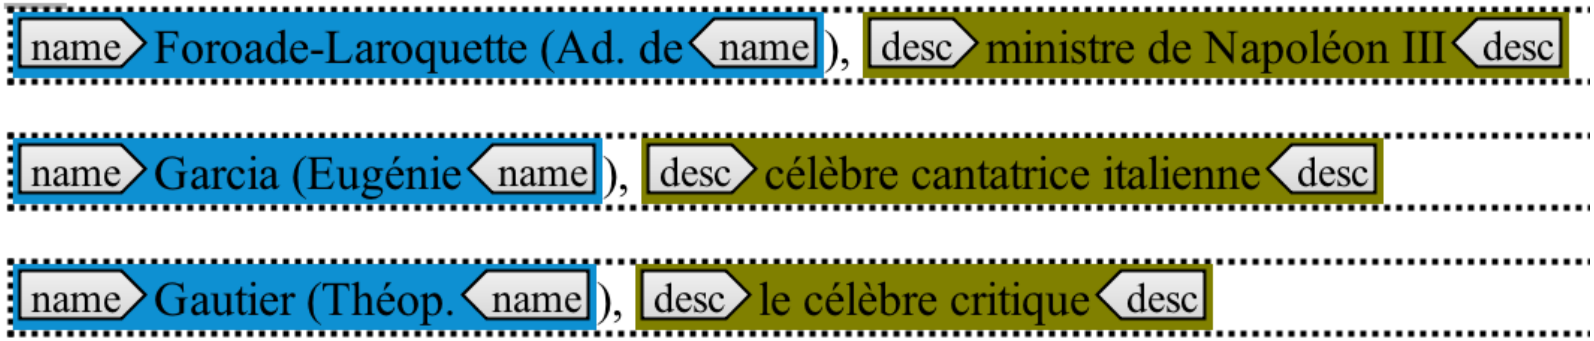
name Foroade-Laroquette (Ad. de name), desc ministre de Napoléon III desc
name Garcia (Eugénie name), desc célèbre cantatrice italienne desc
name Gautier (Théop. name), desc le célèbre critique desc

Entraînement

On entraîne à partir des données annotées

ligne de commande

```
$ mvn generate-resources -P train_form -e
```

Et on passe au modèle suivant

Quatrième niveau d'entraînement *bis*

Sense

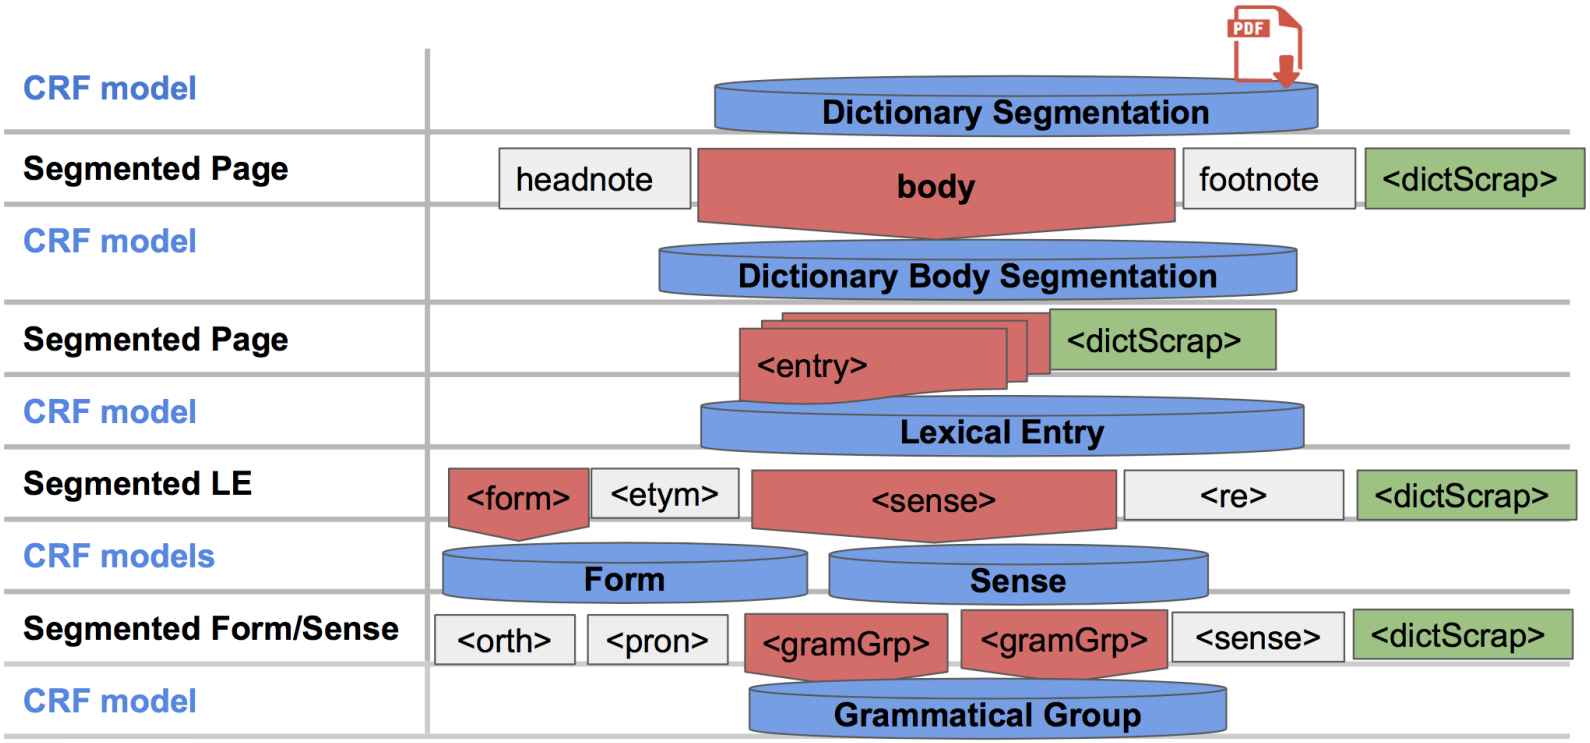
CRF model
Dictionary Segmentation
Segmented Page
headnote
body
footnote
<dictScrap>
CRF model
Dictionary Body Segmentation
Segmented Page
<entry>
<dictScrap>
CRF model
Lexical Entry
Segmented LE
<form>
<etym>
<sense>
<re>
<dictScrap>
CRF models
Form
Sense
Segmented Form/Sense
<orth>
<pron>
<gramGrp>
<gramGrp>
<sense>
<dictScrap>
CRF model
Grammatical Group

Sense

L'objectif est de séparer la description du manuscrit (<def>) des éventuelles notes additionnelles (<note>)

```
<entry>
    <num>54</num>
    <form type="lemma">
        Lassalle
        (A.-Ch.-L. de),
        le plus brillant général de cavalerie des guerres de la République et de
        l'EmpIre, né à Metz, tué à la bataille de Wagram
    </form>
    <sense> .-
        <def>
            L. a. s. au général Dugua; 1 p. in-f.
            10 »
        </def>
        <note>Superbe lettre sur la campagne d'Egypte. Il profite du départ du général
        Desaix pour lui donner des nouvelles. Desaix lui laisse le commandement de la
        colonne qui doit poursuivre Mourad-Bey, et qui se compose de 400 hommes de
        cavalerie, 4 pièces de canon et 160 dromadaires. Le général Boyer a, dans une
        petite affaire, tué 10 mameloucks et 40 arabes, etc.</note>
    </sense>
</entry>
```

Sense

Entraînement

On crée les données d'entraînement

ligne de commande

```
$ java -jar

/grobid/grobid-dictionaries/target/grobid-dictionaries-0.4.3-SNAPSHOT.one-jar.jar -dIn

resources/dataset/dictionary-segmentation/corpus/pdf/ -dOut resources -exe

createTrainingSense
```

On annote

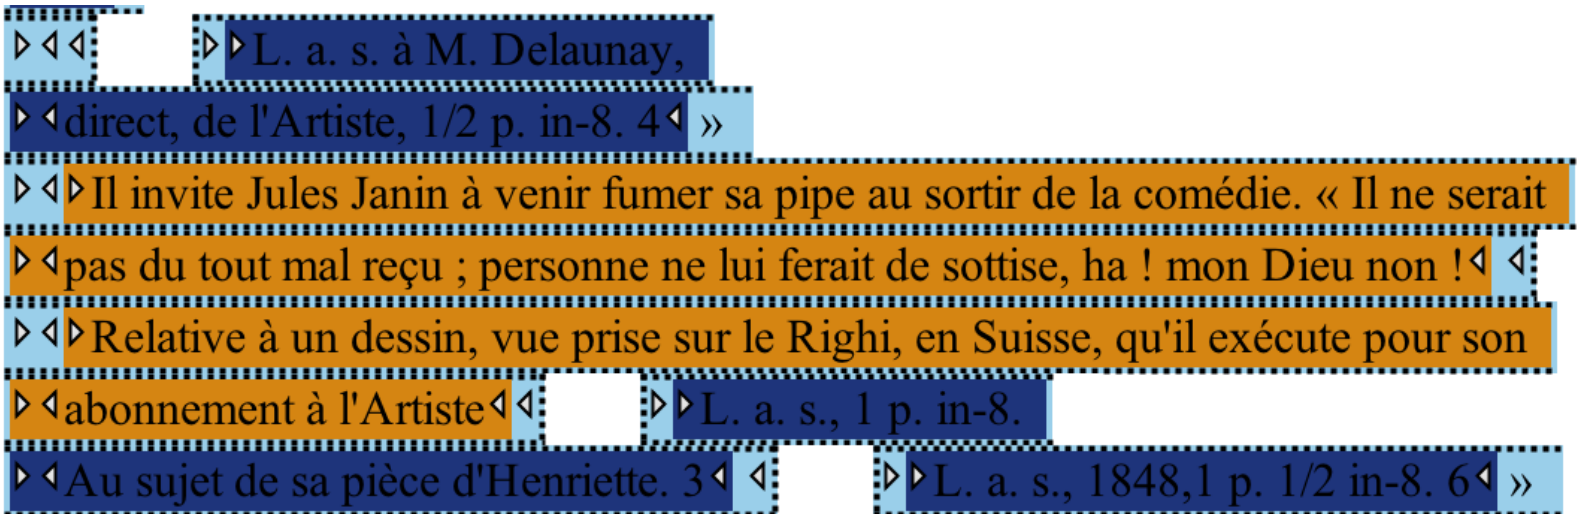
L. a. s. à M. Delaunay,
direct, de l'Artiste, 1/2 p. in-8. 4 »
Il invite Jules Janin à venir fumer sa pipe au sortir de la comédie. « Il ne serait
pas du tout mal reçu ; personne ne lui ferait de sottise, ha ! mon Dieu non !
Relative à un dessin, vue prise sur le Righi, en Suisse, qu'il exécute pour son
abonnement à l'Artiste
L. a. s., 1 p. in-8.
Au sujet de sa pièce d'Henriette. 3
L. a. s., 1848,1 p. 1/2 in-8. 6 »

Entraînement

On entraîne à partir des données annotées

ligne de commande

```
$ mvn generate-resources -P train_sense -e
```

Et on passe au modèle suivant

Cinquième niveau d'entraînement (à construire)

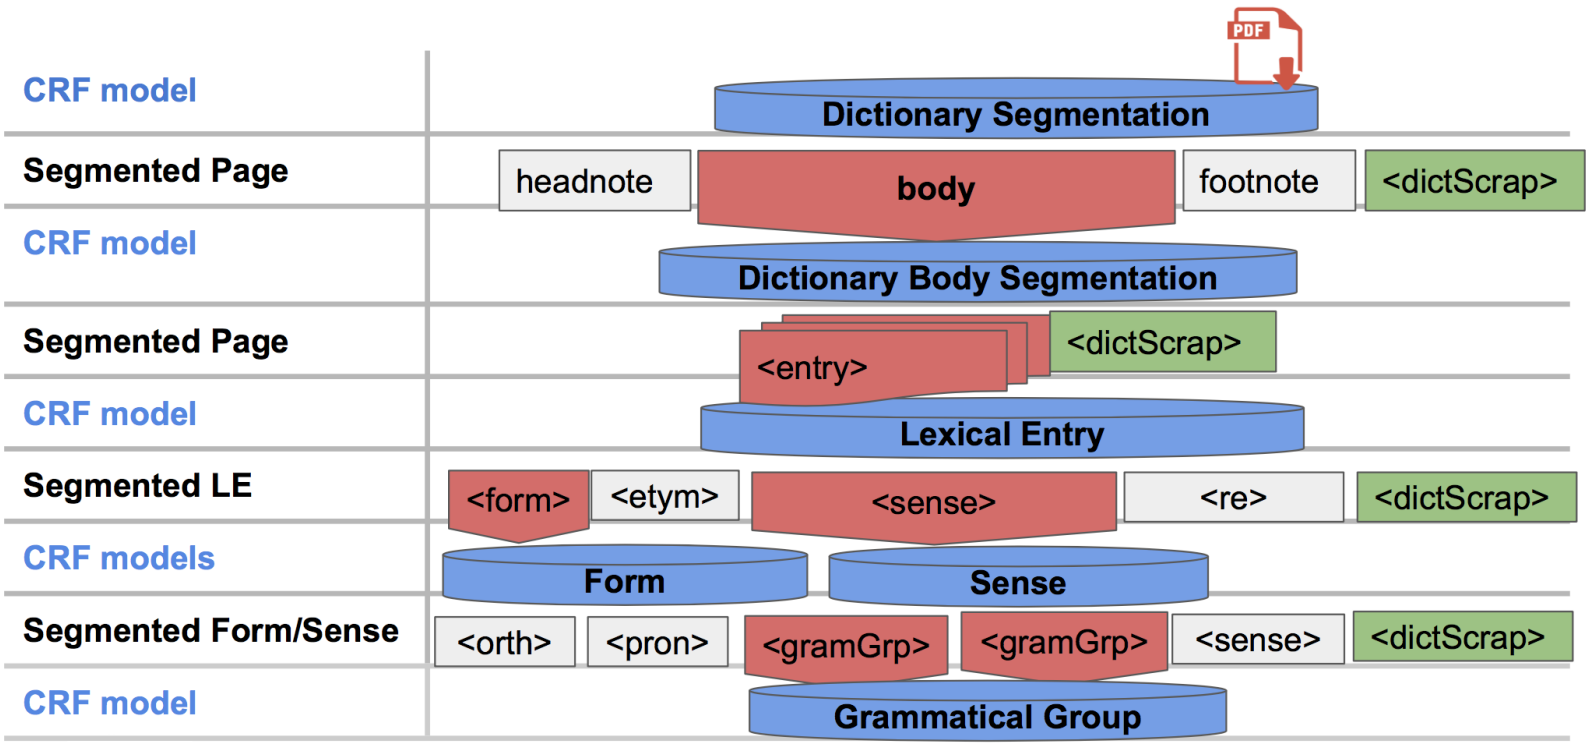

Revue des autographes

```xml
<entry>
    <num>54</num>
    <form type="lemma">
        <surname>Lassalle</surname>
        <addName>(A.-Ch.-L. de)</addName>,
        <desc>le plus brillant général de cavalerie des guerres de la République et de l'EmpIre, né à Metz, tué à la bataille de Wagram</desc>
    </form>
    <sense> .-
        <def>
            <bibl>L. a. s. au général Dugua; 1 p. in-f.</bibl>
            <num type="price">10 »</num>
        </def>
        <note>Superbe lettre sur la campagne d'Egypte. Il profite du départ du général Desaix pour lui donner des nouvelles. Desaix lui laisse le commandement de la colonne qui doit poursuivre Mourad-Bey, et qui se compose de 400 hommes de cavalerie, 4 pièces de canon et 160 dromadaires. Le général Boyer a, dans une petite affaire, tué 10 mameloucks et 40 arabes, etc.</note>
    </sense>
</entry>
```

Grammatical group

Visualiser

Une API permet d'utiliser *GROBID dictionaries* une fois qu'il a été entraîné

- Il faut exécuter le service

ligne de commande

```
mvn -Dmaven.test.skip=true jetty:run-war
```

- Et aller à l'adresse `http://localhost:8080/` sur son navigateur

On utilise *GROBID dictionaries via* l'API

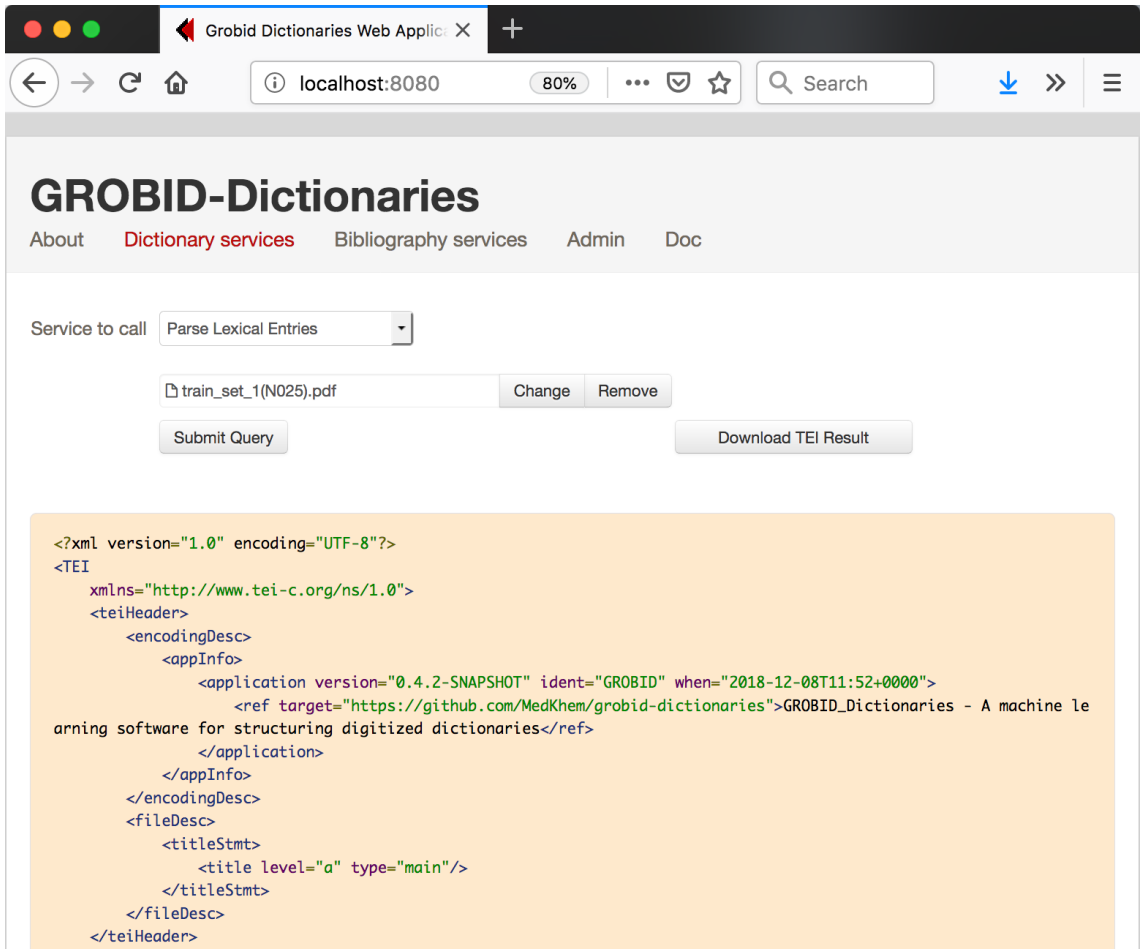

Conclusion

Problèmes

Quelques problèmes à résoudre

- Grobid s'appuie sur la mise-en-page (gras, italique, retour à la ligne. . .)
- Il s'appuie aussi sur le texte: point, virgule, cadratin. . .
- Cela signifie qu'il lui faut un bon système d'OCR, car la qualité de l'OCRisation du PDF est cruciale
- Mais quel OCR?
- En plus de la question de l'entrée des données se pose celle de la sortie. Étant donnée la simplicité du schéma, cette problème est le moins complexe
- Simplifier l'utilisation au moyen d'un *pipeline*?

Aller plus loin

Nos données d'entraînement sont disponibles en ligne

- `https://github.com/gabays/grobid`

Télécharger GROBID

- `https://github.com/MedKhem/grobid-dictionaries`

Utiliser GROBID

- `https://github.com/MedKhem/grobid-dictionaries/wiki/Docker_Instructions`
- `https://github.com/MedKhem/grobid-dictionaries/wiki/How-to-Annotate`

Suivez-nous

Suivez-nous

- `http://editiones-hypotheses.org`
- `https://twitter.com/e_ditiones`

Bibliographie

- Mohamed Khemakhem, Luca Foppiano, Laurent Romary, "Automatic Extraction of TEI Structures in Digitized Lexical Resources using Conditional Random Fields", *electronic lexicography, eLex 2017*, Leiden (Netherlands), [https://hal.archives-ouvertes.fr/hal-01508868]
- Mohamed Khemakhem, Axel Herold, Laurent Romary, "Enhancing Usability for Automatically Structuring Digitised Dictionaries", *GLOBALEX workshop at LREC 2018*, Miyazaki (Japan) [https://hal.archives-ouvertes.fr/hal-01708137]
- Mohamed Khemakhem, Laurent Romary, Simon Gabay, Hervé Bohbot, Francesca Frontini, Giancarlo Luxardo, "Automatically Encoding Encyclopedic-like Resources in TEI", *TEI 2018*, Tokyo (Japan) [https://hal.inria.fr/hal-01819505]