



SYMILA : Una basa de donadas sintaxicas per l'occitan e las otras lengas romanicas de França

Patric Sauzet, Yaël Champclaux

► To cite this version:

Patric Sauzet, Yaël Champclaux. SYMILA : Una basa de donadas sintaxicas per l'occitan e las otras lengas romanicas de França. Fidelitats e dissidéncias - XIIeme Congrès de l'Association Internationale d'études occitanes, Jul 2017, Albi, France. pp.271-284. hal-03174041

HAL Id: hal-03174041

<https://hal.science/hal-03174041>

Submitted on 22 Mar 2021

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial - NoDerivatives 4.0 International License

ACTES
DU
DEL **XII^{e/n}** CONGRÈS

de l'Associacion Internacionala d'Estudis Occitans

de l'Association Internationale d'Études Occitanes

ALBI, 10-15/07 2017

édités par Jean-François Courouau

en collaboration avec David Fabié

editats per Joan-Francés Courouau

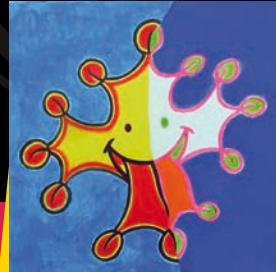
en collaboracion amb Dàvid Fabié

Fid elitats élites et dissidéncias dências dissidéncias dences

Section française de l'Association internationale d'études occitanes

SFAIEO

Vol. 1



SYMILA : Una basa de donadas sintaxicas per l'occitan e las otras lengas romanicas de França

L'*Atlas linguistique de la France* (Gilliéron / Edmont 1902-1910) gausís pas de la melhora reputacion en cò dels occitanistas que fan sovent sias las criticas qu'Antoine Thomas, en tot que reconeguèsses l'ample "gigantal" de l'òbra, formulava en 1904 : manca d'autenticitat lexicala e d'exactitud fonetica mai que mai (Thomas 1904). Sul fons de la sosevaluacion globala de l'ALF pels lingüistas en França, los occitanistas an pas tirat de l'ALF tot çò qu'i auríán pogut trobar, comprés lo lexic. Juli Ronjat l'utilizèt intensivament per redigir la *Grammaire (h)istorique* (Ronjat 1930-1941), mas plan de sintèsis o d'introduccions lingüísticas a l'occitan desconeisson l'ALF qu'es tanben pasmens un atlàs panoccitan (o gaireben) e lo sol, coma es un atlàs de tot lo domeni primari del francés¹.

L'ALF permet de sasir d'un còp tot lo domeni occitan quand los atlases regionals son trocejats e an pas totjorn de questionaris parallèls. Tanben l'ALF, mens ric e mens especific en lexic que sos sucessors regionals, es probablament mai ric en sintaxi que quelques uns, per sa part publicada almens. Guylaine Brun-Trigaud mostrèt que 25 % del material de l'ALF es format de frasas que se pòdon reconstituir e estudiar (Brun-Trigaud 1990). L'ALF es per tant un document excepcional per l'estudi de la sintaxi occitana (coma, d'autre costat, per la dels parlars d'oïl o francoprovençals e pus mendrament d'unes parlars catalans). Totun la publicacion de l'ALF en mapas leùmens lexicalas rescond aquela dimension e la rend de mal explechar (levat quand la frasa figura tota sus una mapa o un bon tròç). Per de simples rasons tipograficas, la publicacion papièr podiá dificilament restituïr un material sintaxic localizat.

Lo projècte SYMILA *Syntactic microvariation in the Romance languages of France* se dona per tòca de bastir una basa documentària amb lo material sintaxic de l'ALF, occitan coma francés, francoprovençal o catalan. Las resultas de la primièira fasa finançada del projècte son consultables sul sit <http://symila.univ-tlse2.fr/>. La basa d'informacion del projècte SYMILA (per sa partida ALF²) es bastida d'una part per acullir lo material sintaxic de l'ALF, d'autra part per explicitar la natura d'aquel material en i apontent d'informacions gramaticals que ne melhoren l'intelligibilitat e ne permetan una consultacion mai elaborada.

Lo projècte representa una escomessa documentària que demandèt de bastir una basa de donadas de tres dimensions : l'espaci geografic (639 punts d'enquèsta), lo sistèma de cada parlar (180 frasas reconstituidas) e la successió dels mots de cada frase (fins a gaireben un vintenat de mots per las frasas mai longas). Nos acontentarem aici d'evocar l'estructura de la basa, e en amont lo questionari ALF e la notacion que calguèt gerir, e mai en aval lo ròtle de las notacions

¹ L'ALF, tornem-o dire es plan mal nomenat. Cobris pas tota França, solament las regions romanofònas. Cobris tanben autre causa que França (la Belgica e la Soïssa romanicas, sens comptar las Illas normandans e quelques punts d'Itàlia). Es pas exactament tanpauc "galloromanic" que, sens parlar del volum cors, incorpòra de punts catalans que segon çò que se fa d'aquela "lenga pont" siá son benlèu pas galloromanics, mas que s'o son, manca un grand tròç del galloromanic a l'atlàs, que lo catalan se redusís pas a Rosselhon. En fach l'ALF es l'atlàs de l'espaci romanic ont lo francés es (o èra al moment de l'enquèsta) la lenga d'educacion, çò que permetiá l'enquèsta per traduccion del francés qu'es al principi de l'ALF.

² La valorizacion de las donadas ALF es una part del projècte Symila (SYMILA-ALF), l'autra part (SYMILA-NES, per "novèlles enquèstas sintaxicas") que se'n tròba pas qu'un escapolon en linha, se fonda sus d'enquèstas novèlles dedicadas a la sintaxi. La plaça manca per las evocar aici.

ortograficas dins l'economia de la basa, que son una illustracion de l'utilitat de la codificacion grafica e lingüistica de la lenga per menar a bon pro son estudi scientific quitament dins una perspectiva purament descriptiva.

1. Preables: questionari e notacion fonetica

Lo questionari de l'ALF es pas estat conservat. La publicacion en mapas alfabeticas e l'utilizacion principalament lexicologica o lexicografica que se faguèt de l'Atlàs (en començar pels trabalhs del quite Gilliéron) an resconduda la presència d'una importanta documentacion sintaxica dins aquela òbra.³ L'importància ja mençonada de las frasas dins l'elicitacion de l'ALF se pòt estableir (Guylaine Brun-Trigaud (1990) o faguèt) per la sintesi dels titols de las mapas, ont los contexes d'elicitacion quand n'i a un son donats. Pro de comprehende que cada còp tot lo context es estat notat e cartografiat. Permet de restablir lo questionari e las frasas qu'i cabián. L'utilizacion dels quasèrns d'enquèsta permetèt d'anar mai luènh e tornar trobar completament lo questionari dins l'ordre que foguèt somés als informators. Los quasèrns d'enquèsta de l'ALF son depausats a la BNF⁴. Compòrtan pas que las responsas, depausadas totun d'un biais rigorosament constant. En utilitzant de quasèrns occitans (que son los mai complets, perque son los de las darrereras enquèstas ont lo questionari èra estat enriquesit) se pòt inferir la question, l'estimul indicat çà que la pels titols de mapas. Lo questionari reconstituït es disponible sul sit SYMILA (http://symila.univ-tlse2.fr/alf/questionnaire_alf_reconstitue) e tanben dins la rejoncha de questionaris facha pel projècte TUL-QUEST (<http://tulquest.huma-num.fr/>). Donam en annèxa a la fin d'aquesta presentacion una pagina d'un quasèrn reproduchuda, e las responsas correspondentes a un punt d'enquèsta (Annèxas 2-4).

L'ALF utiliza una notacion fonetica definida per Pierre Rousselot e utilizada per el dins la *Revue des Patois Galloromans* (RPG) (Rousselot 1887). Per tant, sul sit del projècte SYMILA designam la notacion de l'ALF "notacion RPG". Aquesta notacion fonetica es nascuda a la meteissa època que la notacion definida per Paul Passy⁵ e que devenguèt l'*Alfabèt fonetic internacional* (AFI, API, IPA) (Passy 1893). Dins las meteissas èpocas se definiguèron d'autres sistèmas de notacion, notadament lo d'Eduard Böhmer (1875), d'ont deriva puèi lo sistèma dich "romanista" mes al punt e difusat per Edouard Bourciez.

Lo sistèma RPG es estat continuat dins los atlases regionals fins a una època tota recenta. L'Atlàs de Provença tot escars publicat es lo primièr que rompa amb la tradicion aprèp que la basa THESOC a convertida la notacion dels atlases regionals (Bouvier *et alii* 2016). L'emplec d'una notacion fonetica diferente contribuís a aprigondir lo valat entre los "dialectològs" e los autres lingüistas. Lo valat es prejudicable pel domeni francés qu'alènha l'estudi de l'estandard dels dialèctes primaris (e fa de l'estandard una lenga fora-sòl). E per l'occitan, falta d'estandard largament establit, marginaliza tot l'estudi de la lenga vojat dins una "dialectologia" qu'es pas un aspecte de la lingüistica, mas una mena d'autra lingüistica que la lingüistica. Utilizar l'AFI es una condicion per rejónher la comunautat dels lingüistas e rendre las donadas de nostre domeni accessibles al pus grand nombre de cercoires. Avèm doncas transpausada la notacion RPG en notacion IPA. Pretendèm pas que la correspondéncia siá exacta dins lo sens que se poiriá definir un equivalent acostic absolut comun a las doas notacions. Avèm volgut assegurar d'un costat la mai granda similitud d'intencion de notacion (barradura o apertura vocalica, anterioritat o

³ L'interès sintactic de l'ALF es demora globalament inexpleitat. Senhalem doas excepcions interessantas: l'estudi de Gaston Tuailhon sus l'interrogacion a partir d'una mapa-frasa (Tuailhon 1975), lo libre de David Heap sul subjècte nul que pren en compte la massa de las donadas mas repausa sus una tipizacion de las donadas (Heap 2000).

⁴ Jos la cota : NAF 11971-12030. Lo projècte SYMILA permetèt de finançar la numerizacion d'una part dels quasèrns d'enquèsta que la BNF a puèi mesos en linha. Seria desirable que l'ensem dels quasèrns foguèsson numerizats.

⁵ Paul Passy collaborèt çà que la a la *Revue des patois galloromans* (Passy 1891).

posterioritat, vosament o desvosament consonantico...), d'autre costat una transposicion bivocà, combinacion (signe e diacritics) per combinacion, que permet la reversibilitat. Apontam que la preséncia de las mapas-fonts dins la bása SYMILA permet a cada moment de verificar las transposicions.

Coma per donar rason a Michel de Certeau que plaça dins la vocala l'esséncia de la variacion patesa coma la vesian Grégoire e sos correspondents (Certeau *et alii* 1975, 110 sqq), son las vocalas qu'an demandat lo mai d'elaboracion per transpausar. Avèm comptadas dins las notacions de l'ALF 296 notacions vocalicas (letras amb diacritics) diferentes. Los detalhs de la transposicion, principis e aplicacion, son donats dins lo document en linha sul sit SYMILA (http://symila.univ-tlse2.fr/alf/notacion_phonetique). Evocam pas aici que quelques punts importants.

Dins la transposicion del sistèma vocalic a calgut transpausar las notacions de l'accentuacion, de la longor e de la qualitat vocalica.

Cò de mai simple es estat l'accentuacion⁶: remplaçam lo tiret soscrich de l'RPG per un tiret auçat abans la vocala 'kasäire'⁷ > [kas'aire]. En cò fasant, seguissèm pas la convencion estandard recomendada per l'Associacion fonetica internacionala qu'es de notar l'accentuacion a la debuta de la sillaba, abans l'ataca (dins l'exemple donat : [ka'saire]). Nòstra causida a una rason practica: plaçar la notacion de l'accent tonic dins una posicion atenenta a la vocala accentuada permet la reversibilitat automatica amb la notacion RPG que seriá de plan pus mal definir amb una notacion de l'accent a l'iniciala de sillaba. Un problema particular se pausariá en cas d'elision devant una vocala tonica notada: coma separam los mots (comprès los clitics e las formas embegudas) se notariá l'accent dins un mot different de l'original [lɔme] per 'l ɔmē'. Se pòt tanben avançar una defensa de principi d'aquesta notacion. L'accent tonic es una mesa en relieu d'una sillaba entre las autres (cò que justifica la convencion de l'AFI) mas en cada sillaba avent pas qu'un cimèl sillabic, es equivalent de notar la prominéncia a l'iniciala o al cimèl de la sillaba. La darrièira causida a l'avantatge de demandar pas de determinar la còpa sillabica per notar l'accent tonic (e la còpa sillabica pòt èsser problematica, aital dins un parlar d'oïl entre [etrāg,r'e] o [etrā,gr'e] per una realization d'"étranglerait" o en occitan entre [ka.ler,jo] o [ka.le,rjo] per "caleria" (una forma gascona per *calriá*)). Es comòde de poder notar l'accent tonic sens trencar aperabans de questions possiblament espinosas de sillabacion.

Per l'apertura, avèm seguida una logica diferente segon las classas d'apertura. Per las vocalas nautas, transpausam los accents aguts e grèus de l'RPG en diacritics AFI : 'í' se transpausa en [i], 'í' se transpausa en [i], e 'í' en [i] (e identicament per las 'u' simpla o gansada de l'RPG que venon [y] e [u]). Per contra, per las vocalas mejanas, transpausam 'é', 'ó' per [e], [o] mas 'è', 'ò' per [ɛ], [ɔ] cò que mena a causir una notacion [é] per 'é' sens diacritic d'apertura de l'RPG. D'un biais rescontram aici una validacion de nòstra causida. Nos avisam que 'í' o 'ú' sens diacritic que conservam sens diacritic son frequentas dins l'ALF, mentre que 'é', 'è', 'ó', o 'ò', rendudas per de signes simples [e], [e] ... son mai frequentas que 'é' o 'ó' sens diacritic. Ne resulta un aleugeriment de la notacion que se pòt prene coma un signe d'adequacion. Meteissa confirmacion d'adequacion per l'estalvi de diacritics dins la transposicion de 'á' en [a] e de 'á' en [a], mas de 'á' en [a] : 'á' e 'á' son mai frequentas dins l'ALF que 'á'⁸.

La RPG nòta regularament de brèvas (per un breve '') e de longas (per un macron ''). Transpausam las brèvas de l'ALF per una vocala sens diacritic: 'í' es [i] e las longas pel diacritic

⁶ L'accentuacion es la dimension mai criticada e mai criticable de la notacion fonetica de l'ALF. Ni per aquò la transpausam sens cap de modificacion. Las solas modificacions portadas a la notacion fonetica d'origina concernisson la segmentacion en mots segon las exigéncias de l'establiment de glòsas. A cada còp la modificacion es mençonada dins una annotation de la frasa.

⁷ Plaçam las notacions RPG entre '...' e reservam los cròcs [...] a l'AFI.

⁸ Dins lo cas d'"á", transpausam (sus la bása dels exemples de l'RPG e de las formas notadas dins l'ALF) 'á' definit erronèamente coma mai barrat que 'á' o 'á' coma una vocala posteriora ([a]).

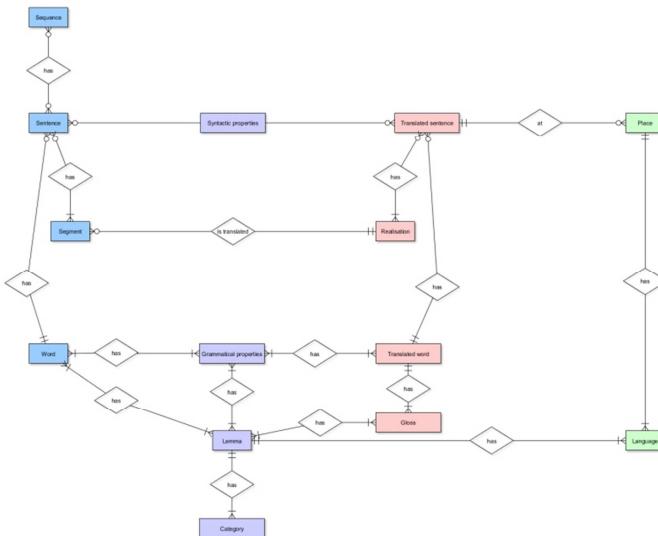
pòstpausat de l'AFI: 'í' es [i:]. La vocala sens diacritic de longor de l'RPG es notada pel signe de mièja longor en AFI: [i] per 'í'. Dins la practica, lo breve, transpausat per l'abséncia de diacritic es força frequent, lo macron rar e l'abséncia de diacritic excepcionala. Notam pas de longor sus las vocalas nasalizadas perqu'avèm remarcat que, en tot que siá possible en principi, l'ALF combina pas jamai los dos signes. Es aquí un exemple que demòstra que l'operacion de transposicion se podia pas definir totalament *a priori* mas se deviá establir en fucion de la practica efectiva d'Edmont. Segon los principis de la notacion RPG 'é' sens diacritic es non marcat, mas dins la practica notacionala 'é' o 'é' amb un breve ([e] o [e] de l'AFI) son las valors non marcadas. E per tal, un còp de mai, la leugieretat de la transcripcion obtenguda ne valida la pertinéncia.

Las consonantas pausan plan mens de problèmes, primièr per tal que son plan mens nombrosas. Los signes de basa son largament los meteisses. La c crosada ('é') correspond a [ʃ], simpla variacion de simbòl. I a pas de signe simple per las fricativas apicalas non estridentas: 'š' e 'z' respectivament valon [θ] e [ð]... Una dificultat qu'avèm resolguda per observacion dels cases reals son las combinasons de simbòls que son per principi dobèrtas dins la notacion RPG ont tot signe se pòt combinar amb tot signe. Las avèm trobadas mai que mai per notar las oclusivas palatalas : 'k' capelat de 't' s'interpreta [c], e per notar de consonantas mièjas vosadas o mièjas devosadas, aital 'd' capelat de 't' (dins la materialitat tipografica: seguit de 't' en expausant) que transpausam per [d] ([d] amb un diacritic de desvosament).

Insistiscam sus un punt per acabar a prepaus de la transcripcion fonetica: assajam de prepausar los equivalents mai probables a las notacions d'Edmont signe per signe. Modificam pas las combinasons. Aital enregistram lo fach que l'RPG desconeix la nocion d'africada e nòta pas que de sequéncias 'ts', 'tc' ... que transpausam per [ts], [tʃ] e non pas per [ts], [ʃ]... Edmont nòta pas tanpauc la sillabicitat e conservam de notacions [au], [ao]... per de sequéncias que sabèm monosillabicas: [au], [aq]...⁹

2. Estructura de la basa

L'estruutura informatica de la basa de donadas concebuda per Yaël Champclaux especificament pel projècte SYMILA permet d'integrar las tres dimensions del material (espaciala, paradigmatica e sintagmatica) e navegar entre elas. Se pòt representar dins l'esquèma seguent (donat sul sit del projècte).



⁹ O dins una grafia fonologizanta [aw] ...

Tot çò en blau dins l'esquèma ven del questionari de l'ALF: “sequéncias de frasas” (“sequences”) ont figuraren las “frasas” reconstituïdes de l'ALF (“sentences”)¹⁰. Las frasas, objecte central de la basa, son dividides d'un costat en “segments” (mots o grups de mots cartografiats) e d'autre costat en “mots” (“words”) que son a pauc prèp los mots ortografics, levat quelques seguidas de mots categorizadas coma d'entitats lexicalas (coma “parce que” o “peut-être”).

Tot çò en ròse correspond al material de las respondas a l'enquèsta d'Edmont. Las traduccions de frasas reconstituïdes son analisades parallèlament en “segments” e en “mots”. L'analisi en “segments” correspond a la publicacion cartografiada de l'ALF e totas las mapas d'ont es tirada l'informacion sintaxica son disponiblas dins lo sit (cada frase dona los ligams a las mapas correspondentes çò que permet de verificar la sasida de las formas foneticas¹¹). Tot çò ròse ven doncas de las respondas foneticamente notadas per Edmond Edmont e cartografiadas per Jules Gilliéron. Levat çò qu'es sonat “glòsa” (“gloss”) e qu'i tornarem.

Evidentament las respondas son associadas caduna al punt geografic ont son estadas reculhidas (“place”). Cada punt es estat assignat a una “lenga” (“language”), causida renduda necessària per la lematizacion mesa en plaça que ne parlam un pauc mai luènh. Los punts de l'ALF son estats identificats en longitud e latitud e projectats sus una mapa manejabla (OpenStreetMap). De cada punt se pòt navegar cap a las formas qu'i son estadas reculhidas.

L'informacion en malve al centre de l'esquèma es tota d'informacion aponduda o almens explicitada, a l'escasenç de la bastison de la basa SYMILA. L'informacion es aponduda a partir del questionari: las frasas del questionari son estadas sintacticament caracterizadas (complexitat, modalitats...) e los mots que las compausan lematitzats, categoritzats e gramaticalmente caracteritzats (basicament : genre, nombre, animacion, cas quand ne vira, per las formas nominalas, classa morfologica, temps, aspècte, mode, persona pels verbs, quelques indicacions tanben sus la reccion de las preposicions e l'estatut fonologic dels elements: tonicitat, cliticitat). Per defaut, l'informacion sintaxica globala associada a las frasas-estimuls es reportada sus las frasas-responsa. *A priori*, una interrogativa se revira per una interrogativa, una negativa per una negativa e una frase complexa per una frase complexa. I a quelques cases rars de non isomorfia (coordinacion per subordinacion o l'invers per exemple) e la basa permet la correccion. Al nivèl dels mots, l'informacion grammatical pòt pas èsser sistematicament inferida de l'estimul. Totun, naturalament, al centre del domeni francés, arriba sovent que la resposta del testimoni es pas qu'una variacion fonetica minima de l'estimul. Per tirar avantatge de la proximitat estrecha de la lenga d'enquèsta amb bon nombre dels parlars documentats, los lèmas dels mots del questionari ALF servisson tanben a lematizar las respondas, e las glòsas de las respondas pòdon tanben èsser identicas a de mots ortografics del questionari.

Lo vector per associar los mots fonetics amb d'informacion grammatical son los lèmas ('lemmas') e las glòsas ('glosses')

3. Lo sistèma de lèmas, de glòsas e de formes ortograficas

L'ALF es un Atlàs mut. I cabon gaireben pas cap d'informacions lingüisticas explicitas. Es lèumens perque lo legeire compren la forma francesa de l'estimul e l'identifica grammaticalament que las formes son analisablas pel legeire.

Semanticament, tot repausa sus la traduccio. Lo francés lenga normada e codificada deliura censat un sens univòc. Aqueste aspècte es estat pro criticat e s'es considerat que mai d'un mot francés era possiblemente ambigús e podia induire de respondas falsas o pas pro precisas. Tota la reflexion de l'escola “dels mots e de las causas” s'avodèt a afinar la coneissenç del referent per superar las insufisèncias de la traduccio. Lo novèl atlàs engenhat per Albèrt Dauzat foguèt

¹⁰ Dins lo questionari, las frasas venon sovent per sequéncias que se seguisson coma un pichòt tèxt. Avèm conservada aquesta ligason.

¹¹ E de senhalar d'errors se ne vira a l'autor d'aquestas linhas.

despartit en Atlasses regionals per tal d'èsser fondat sus una coneissença exacta de las *realia* localas que permeta l'exactitud lexicala. Per una basa sintaxica es pas un punt essencial.

Gramaticalament l'ALF senhala quelques escarts entre la lenga de l'estimul e las traduccions, pel genre dels noms en particular quand se dedusís pas ni de l'estimul ni de la forma de la responsa. D'autres escarts son pas senhalats, dins las formas verbals o pronominalas notadament. Lèmas e glòsas permeton d'aportar una informacion gramatical completa e independenta de l'estimul.

Los lèmas son l'objècte mai conegut per gerir a l'encòp la variacion morfologica (intèrna a la lenga e a cada dialècte) e la variacion dialectala. Es ja cò qu'es mes en plaça dins la basa THESOC que recampa una bona part de las donadas lexicalas dels Altlasses regionals occitans (Dalbera *et alii* 2005). La lematizacion (dins una lenga flexionala) es una operacion necessària a tota entreprise de lexicografia. Es doblament necessària dins una lenga ont la variacion dialectala es integrada a la lexicografia. Lo THESOC a enregistradas (per ara) las donadas lexicalas dels atlasses regionals, jos la forma de mots isolats. La lematizacion retenguda met en relacion las formas foneticas (en notacion AFI) e de lèmas que neutralizan a l'encòp la flexion e la variacion dialectala. Los lèmas son preses dins lo diccionari occitan-francés de Loís Alibèrt. Son doncas en grafia classica (segون la codificacion de Loís Alibèrt, ara comunament utilizada) e la forma es la forma centrala de l'occitan, una forma lengadociana.

Dins lo THESOC, "galina" lematiza aitanplan una forma [gal'ino] ... que [garj'o] o [dza'l'ino]. Las formas del THESOC, de noms mai que mai, donan pauc d'escasença d'illustrar los efièches grammaticals de la lematizacion. Totun quelques formas verbals son conjugadas ("lusisson" ...) e lo lèma es, coma dins un diccionari, l'infinitiu. Lo THESOC prepausa d'autres camps que la forma fonetica observada e lo lèma que l'interpreta. Un etim es tanben donat e mai una "forma ortografica". L'etim esperlonga naturalament lo lèma, que tipicament un lèma remanda a un etim unic e presenta una relacion univòca a l'etim (evolucion fonetica o manleu). La "forma ortografica" del THESOC es prevista (e pas encara mesa en plaça) coma una forma ortografica de tipe mistralian, cò es amb de convencion de notacion mai fonetizantas e de tipe mai francés que la grafia classica, mas pas ortodòxament mistraliana dins la mesura ont deu èsser obtenguda per conversion automatica de la notacion fonetica¹².

L'informacion gramatical dins lo THESOC es ligada a cada forma fonetica, que pòt pas èsser estacada al lèma (per definicion o pòt pas èsser tota), ni a la "forma ortografica" qu'es pas concebuda coma una forma autònoma, ni a l'estimul (integrat dins la basa THESOC coma informacion semantica en tant que l'estimul es un mot francés, censat semanticament fixat, e qu'es completat per de precisions discriminantas se ne vira). Non solament las caracteristicas grammaticals de la responsa pòdon diferir de l'estimul a causa de las proprietats de la lenga o del dialècte de traducción, mas tanben l'elicitacion es facha tot còp dins una forma flechida autre que la que correspond al lèma (aital dins mai d'un punt gascon l'intrada semanticà "poule" es renduda per [gar'ios] lematizat "galina". L'informacion sul nombre es donada dins un camp "morfologia". Es tanben precisat dins lo meteis camp que lo mot es un nom femenin, informacion que poiriá èsser portada e aportada pel lèma.

Dins la basa SYMILA, la caracterizacion grammatical de las formas, qu'es una question marginala per la basa THESOC, es centrala. Coma lo material retengut son de frasas, i cabon regularament de formas verbals flechidas que demandan una caracterizacion explicita, d'ont mai importanta que pòt coïncidir pas amb las caracteristicas de l'estimul. Dins la basa SYMILA las proprietats grammaticals de las formas son associadas a las formas foneticas per l'intermediari dels lèmas e de cò que sonam "glòsas". Los lèmas son la meteissa causa que cò que son dins THESOC. Son de formas neutralizadas per la flexion e lo dialècte. Coma dins la basa THESOC los lèmas son restacats a un camp etimologic e un etimon es donat (e mai siá pas una tòca centrala de

¹² Ai personalament de doblets sus l'interès d'aquela notacion.

l'entrepresa SYMILA, mas puslèu una pèira d'espera per la mesa en relacion amb d'autres sistèmas s'informacion). Los lèmas específics a caduna de las lengas que los parlars locals enregistrats per l'ALF s'i restacan, çò es l'occitan (que nomeni en primièr dins aqueste collòqui), lo francés, lo francoprovençal, lo catalan e lo ligurian (per un punt: Fontan ALF 990)¹³. Pel domeni d'oïl se son recuperadas coma basa las formas de l'estimul, de las question de l'ALF¹⁴. Se son tanben aponduts de lèmas franceses quand la responsa d'un parlar d'oïl usa d'un mot different de la question e del francés estandard se ne vira. Aital un lèma “geline” es apondut al lèma “poule” eissit del questionari ALF e lo francés a un lème “geline” e un lèma “poule” coma l'occitan a un lèma “pola” e un lème “galina”. Los lèmas del francoprovençal son los que pausan mai de dificultat, essent lo pauc d'estandardizacion de la lenga. Seguissèm las solucions graficas del diccionari de Dominique Stich (Stich *et alii* 2003). Lo travalh de lematizacion per las donadas francoprovençalas es lo mens avançat amb lo ligurian ont es a pena escapolat. Lo catalan pausa pas de problema particular levada la necessitat de lematizar las formas especificament rosselhonesas.

L'operacion de lematizacion supausa la referéncia a una lenga codificada graficament e mai a una forma pivòt, a una forma prototípica, a un estandard (en prenent lo mot dins lo sens de modèl) quina sián las foncions e los usatges de la dicha forma dins la vida culturala e sociala de la lenga. D'aquel punt de vista, las situacions son mai que mai variadas dins l'espaci cobert per l'ALF, del francés que sa forma estandard es talament estableida que per pauc lo ligam es romput amb l'ensem dialectal que n'es eissit, al francoprovençal ont la quita possibilitat de l'establiment de formas-pivòt es discutida e son utilitat (quitament scientifica) denegada per una part dels especialistas. Al mièg, lo catalan es en via avançada de normalizacion, d'installacion sociala e la disponibilitat scientifica de l'estandard es totalament evidenta. Per l'occitan, coneissèm la situacion. La grafia classica es largament mas pas totalament acceptada. L'estandardizacion, la mesa en circualacion d'un estandard es luènh d'esser acceptada mas la natura e las formas de l'estandard son relativament claras. L'emplec a la Mistral o “a la Ronjat” del provençal literari (rodanenc elaborat) coma forma estandard panoccitana es pas gaire mai defenduda ni practicada uèi (mas lo provençal literari demòra una forma d'expression productiva e la norma classica deu fòrça a la norma mistraliana). L'idèa d'un estandard general de l'occitan e, n'i aguèsse un, de l'ample de son emplec, es largament debatuda (e quitament dels estàndards regionals) e pro discutida, encara qu'una estandardizacion de fach se faga sovent darrièr la revindicacion de variacion, es un tèma d'estudi sociolingüistic que s'ameritarà d'aprigondir). Pasmens es admés pro generalament que, se i deu aver un estandard occitan, correspond a una forma de lengadocian, e doncas la forma d'occitan ja codificada per Loís Alibèrt. Per un prepaus scientific e de lematizacion, per un diccionari general de l'occitan coma per las basas de donadas del tipe THESOC o SYMILA, la causida alibertina elaborada permet d'establir una nomenclatura lingüistica coerenta, a usatge scientific (e mai mai, segon l'utilitat o l'escasença, mas es pas lo debat d'aquesta presentacion).

Per explicitar brèument aquelas causidas, digam que son lengadocianas doncas sud occitanas e conservativas (J.P. Chambon parla a prepaus de lengadocian de son “ultraconservatism”, Chambon 2009, 793). Doncas las evolucions específicamente gasconas o nòrd occitanas son pas enregistradas dins los lèmas, coma ja vist amb lo simple exemple del lèma “galina” (vs. “garia” e “jalina”). Tanpauc son pas retengudas las evolucions recentas coma la vocalizcion de l'-l finala simpla en latin dins tota la periferia occitana (lo lèma es “ostal” e pas “ostau”). Notem que las causidas de la grafia occitana fan una larga part de la besonha e dispensan de causir. La grafia classica “vin” o “pan” es panoccitana e cobris dirèctament un grand nombre de realizations (amb o sens betacisme, amb o sens casuda d'-n finala ...). D'unas evolucions específicamente lengadocianas

¹³ Las donadas còrsas de l'ALF, publicadas a despart son pas integradas dins la bása SYMILA.

¹⁴ Per aqueles lèmas recuperats automaticament, lo camp etimologic es pas estat emplit, lo francés es pro documentat etimologicament per autra part.

(coma “fial”, “abrial” per “fil”, “abril”) son pas tanpauc retengudas. Entre las solucion lengadocianas, ja Pèire Bèc parlava de la causida necessària entre la resolucion –ch- e –it- de latin –kt- (*fach o fait*). Coma Bèc retenèm la forma en –ch-. Per la vocalizacion de l’-l intèrna, se reten la solucion tolosana tipica, vocalizacion devant las coronalas (levat s) e pas devant las autres consonantas: *sautar, fauç, alba, qualche, fals*.

Los lèmas pòdon sufre dins una basa de la tòca essencialament lexicala. Dins una basa sintaxica, ont los objèctes manipulats son centralament de frasas, i a clarament una manca que cal comolar entre las formas foneticas e los lèmas. La manca es la d’una forma normalament legibla e de l’informacion gramatical variable e per tant absenta del lèma. Tanben, manca als lèmas la tencha locala, que per principi la neutralizan. Las “glòsas” qu’apelam venon comolar lo valat. Las glòsas son de formas ortograficas que tenon compte (segon los principis de la grafia alibertina) de la variacion dialectala de l’occitan e que tanben, en tant que formas flechidas, pòdon portar l’informacion gramatical de cada forma en context. Las glòsas conservan la dialectalitat de basa mas asseguran una melhora lisibilitat comun que la notacion fonetica. Per melhorar encara la lisibilitat de las donadas las glòsas son dobladas per l’afichatge de formas ortograficas que son provesidas de majusculas e de puntuacion, e mai presentan los embevemens tipograficament acostumats. Las formas ortograficas permeton de limitar la lista de glòsas religadas als lèmas e que permeton de seguir cada lèma fins a caduna de sus realizations flechidas e dialectalizadas dins la basa.

Aplicam al francés los principis de la grafia occitana. D’un costat notam d’especificitat dialectalas ancianas e estructurantas coma lo “cacheur” picard per “chasseur” o “jhournal”, “jhournau” en santongés per “journal”. Mas d’un autre latz una grafia coma “moi” pòt conservar en sincronica la variacion d’interpretacion qu’a coneiguda diacronicment ([moj], [møe], [mwe], [mwø], [mwa], [ma]).

En mai de sa fonction de vector d’informacion grammatical, l’introduccion de las formas ortograficas utilizadas coma de glòsas permet de seguir la practica acostumada de la sintaxi de trabalhar sus de notacions ortograficas dins las lengas qu’an una grafia d’usatge. Dins las lengas qu’an pas d’ortografia fixada, la notacion dels linguistas de frasas o de tèxtes seguits es lèumens l’escasença de metre al punt una notacion practica qu’es potencialament una grafia d’usatge, una ortografia.

Es doncas natural de trabalhar en sintaxi occitana, lenga provesida d’una ortografia (e de quelques autres) sus la basa de notacions ortograficas. Es çò que fa Ronjat dins sa tesi sus la sintaxi e dins la *Grammaire (h)istorique*. Sul pache, quand illustra de fenomèns generals, formula los exemples dins l’occitan estandard qu’assumís, çò es en “provençal literari” forma elaborada de rodanenc (Vouland 2004). Lafont procedis parièr dins *La Phrase occitane*. Cita dins sus grafias d’origina (tot còp escalabrosas) los autors que cita, mas en grafia occitana d’usatge sos exemples fargats, e se i a pas de rason de los assignar a un dialècte particular, los formula en occitan estandard.

La consultacion de la basa SYMILA se pòt far segon lo luòc: siá per una pagina dedicada que compòrtta una mapa zoomejable e una lista dels luòcs, siá tornar dins la pagina d’accès “per frasa” que permet tanben l’accès per luòc, e mai, i anam tornar un accès crosat. La consultacion se pòt far “per frasas”: totes las frasas, una frasa, quelques frasas causidas. Se pòt far per frasa e per luòc: totes las frasas d’un luòc o de mai d’un luòc, quelques frasas causidas d’unes luòcs causits etc. Se pòdon afichar fins a cent frasas aital mesas en parallè sus una sola pagina. O se pòt afichar totes las frasas d’un punt çò que permet de sasir sus regularitats (tipicament sus l’emplec dels pronoms subjèctes per exemple).

Se pòt encara (sus tota la basa sasida o per una causida de luòcs) cercar las frasas que presentan tala o tala proprietat sintaxica globala (complexitat, ellipsi, interrogacion...) o de proprietats particularas sus un mot particular (conjoncion enonciativa, pronom indefiniti, negacion febla etc.).

4. Conclusion

La basa SYMILA ja dins son estat de desenvolopament actual permet de manipular una part significativa del material sintaxic contengut dins l'ALF. La notacion fonetica adoptada rend lo material mai legible e partejable dins la comunautat scientifica. L'apondeson de glòsas e de lèmas ortografics a permés l'explicitacion e sovent l'interpretacion grammatical del material. Aquela explicitacion es possibla solament per la manipulacion d'una forma grafica d'usatge, regularizada e estandardizada de la lenga. Sens aquela ressorsa (o un equivalent *ad hoc* que n'a pas la pertinéncia sociala) la manipulacion de las donadas es esquartairada entre la notacion fonetica e los etimons latins o protoromanics supausats. L'informacion portada pel sistèma lèmas-glòsas es ja disponible per interrogar la basa. Dins una forma plenament desenvolopada la basa SYMILA completada aculhirà tot lo material ALF, serà provesida d'una interfàcia de consultacion mai plegadissa¹⁵, permetrà una interrogacion grammatical mai complèxa e articulada amb lo lexic e la lematizacion. Manca pas que lo finançament.

Réferéncias bibliograficas

- BÖHMER, Eduard (1875). « De sonis grammaticis accuratius distinguendis et notandis », *Romanische Studien* 1, 295-302.
- BOUVIER, Jean-Claude / MARTEL, Claude / BRUN-TRIGAUD, Guylaine (2016). *La langue d'oc telle qu'on la parle. Atlas linguistique de la Provence*, Forcalquier, Alpes de Lumières.
- BRUN-TRIGAUD, Guylaine (1990). *Le Croissant. Le concept et le mot. Contribution à l'histoire de la dialectologie française au XIX^e siècle*, Lyon, Université Lyon III, Centre d'études linguistiques Jacques Goudet, Série Dialectologie.
- CERTEAU, Michel de / JULIA, Dominique / REVEL, Jacques (1975). *Une politique de la langue. La Révolution française et les patois. L'enquête de Gégoire*, Paris, Gallimard.
- CHAMBON Jean-Pierre / GREUB, Yan (2009). « L'émergence du protogascon et la place du gascon dans la Romania », in Guy Latry (ed.), *La voix occitane. Actes du VIII^e congrès de l'Association Internationale d'Études occitanes, Bordeaux, 12-17 octobre 2005*, Bordeaux, PUB, 787-794.
- DALBERA, Philippe / DALBERA-STEFANAGGI, Marie-José / STRAZZABOSCO, Dominique (2005). *THESOC, base de données linguistiques* <https://www.qwant.com/?client=brz-moz&q=thesoc>.
- GILLIÉRON, Jules / EDMONT, Edmond (1902-1920). *Atlas linguistique de la France*, Paris, H. Champion, 35 fasc. de cartes (ALF).
- HEAP, David (2000). *La variation grammaticale en géolinguistique. Les pronoms sujets en roman central*, München, Lincom, 194 p.
- PASSY, Paul (1891). « Patois de Sainte-Jamme (Seine et Oise) », *Revue des patois galloromans* 4, 7-16.
- PASSY, Paul (1893). « L'alphabet phonétique international », *Le maître phonétique*, 2-4.
- RONJAT, Jules (1930-32-37-41). *Grammaire istorique des parlers provençaux modernes*, Montpellier, Société des Langues Romanes, 4 vol.
- ROUSSELOT, Pierre (1887). « Introduction à l'étude des patois », *Revue des patois gallo-romans* 1, 1-22.
- SAUZET, Patrick / DAGNAC, Anne / SPORTICHE, Dominique / CHAMPCLAUX, Yaël (2015). *SYMILA Syntactic variation in the Romance languages of France*, Système d'information en ligne [<http://symila.univ-tlse2.fr>].

¹⁵ En particular ara s'aficha pas tota l'informacion grammatical aportada a las formas. Mas l'afichatge es ja relativatament cargat. Seria util de poder gerir e reglar aquel afichatge segon lo besonh de l'utilizaire de la basa.

- STICH, Dominique / GOUVERT, Xavier / FAVRE, Alain (2003). *Dictionnaire des mots de base du francoprovençal. Orthographe ORB supradialectale standardisée*, Thonon-les-Bains, Le Carré.
- THOMAS, Antoine (1904). « L'Atlas linguistique de la France », *Le Journal des savants* 2, 89-96.
- TUAILLON, Gaston (1975). Analyse syntaxique d'une carte linguistique : ALF 25 “Où vas-tu?”, *Revue de linguistique romane* 39, 79-96.
- VOULAND, Pierre (2004). *Du provençal rhodanien parlé à l'écrit mistralien*, Aix-en-Provence, Edisud.

Annèxa 1 Exemple consultacion

a) Traducción de la frasa estimul : « J'ai pris un moineau au piège. » a Vabre (ALF 755)

The screenshot shows the SYMLA interface with the title "Syntactic Microvariation in the Romance Languages of France". The main area displays the syntactic analysis of the sentence "J'ai pris un moineau au piège." with various grammatical annotations and morphological breakdowns. Below the main analysis, there is a detailed table for "Phrase 16 J'ai pris un moineau au piège." which includes columns for parts of speech, gender, number, and grammatical properties like "Phrase complète, simple, Déclarative, Affirmative," and a "true" status indicator.

b) Detall de la traducción de la frasa estimul : « J'ai pris un moineau au piège. » a Vabre

This screenshot shows a detailed view of the SYMLA interface for the same sentence. It highlights the morphological analysis of each word, such as "é PREZ YM PASERAK A LA T'ENDO" and provides a comprehensive breakdown of the sentence's structure and properties. The table below the analysis shows the same grammatical details as the previous screenshot, including the "true" status.

Se legisson sucessivament :

- la frasa estimul en francès
- la frasa responsa reconstituïda en fonética AFI
- la meteisa frasa responsa en fonética AFI trocejada en mot
- la transposicion ortografica (version tipograficament afichabla de las glòsas).
- los lèmas (en capitalas)
- las proprietats gramaticals dels mots donadas pels lèmas e las glòsas.

Dins las columnas a man drecha, las proprietats de la frasa, e los números de las mapas ALF d'ont venon las donadas (tres aici). Los números son clicables e permeton de cargar en linea l'imatge de las mapas. La mençon "true" senhala que la frasa es estada exaustivament glosada e lematizada.

Annèxa 2 La pagina 3 del questionari ALF al punt 715, Sant Mamet (« Saint Mamet »)

		715	3
paysé	lei paunyé káumézañ	Kon fa d'el Gé, lai	
trémble	dé flári.	tsuñ (junc) pléò, mè	
bet	lei siréy en detsa	zé kópò pà.	
âme	káumézañ yó yue tsuñ	úno primo l'endro	
pièlo	gréja (C)	pérò ; kwén	
sâle	lò binò ; pé dé binò	osyétsò	
sey ; "	" (D), "	rožin ; grappò	
té	chpinò	nájé, f.; rohkólu, ~	
bin	selò	önglónò	
wigü ; pruvé, ~ (I)	rey	kostónò ; kostónè ; pélu	
bui	fúeyò	en nival dé précer (~)	
brûso	rükò ; óubùn	ókert ónado, l'ò ótsu	
rumé . f.	" "	belkuò dé frutò (I)	
ryzyé ; (A)	käppa d'el bué, pé	osyjáy déur Géne	
bwigü	fayré dé fai.	kéni léiz ánbre	
tumbric	(B)	n'érat kórgar.	
prumyé	mé suéy osyétsa tsuñ	ré mabtòm pà	
perye	ün ánbre, ópwyá	nökhòy prumyòg,	
myé	k'ntro lai pé. úno	ré nuzirón lezi.	
prumyé	brokò fwéyridò m'is	pyelalò	
swéy	kumbado su lò karo	frambwézò	
ney rómbats	é m'is fia zoné d'el na	présigé	
finje ; figo	ei lu kák pé mé ròdò	kumangé	

Annèxa 3 Transcripcion API de la pagina 3 del questionari ALF al punt 715

nº	p. 3 col 1	nº	col 2	nº	col 3
183	fr'ajse	215	le ⁱ pumje / kumeſu / de fl'uri	238	kõn fa del b'ẽn / lu tsũ /
184	tr'ẽ ^m ble·			239	pl'ẽ:ɔ· / me / se k'ɔpɔ / pa
185	bet				
186	'orme	216	lei sir'ej / ou detsa / kumesa /	239	yno pumco t'ẽndro·
187	p̄i'ulɔ·		jo j̄l'ẽ tsur		
188	s'aule·				
189	se:ɔj	217	gr'efá	240	p'erɔ·
190	-	218	gr'efu [nòta C]	241	kwẽn
191	te:l	219	ls b'ipɔ·	242	ʃirj'etsɔ·
192	b̄in	220	pe de b'ipɔ·	243	r'ɔz̄i:n
193	bw'ieu	221	--	244	gr'apɔ·
194	pr'ynel	222	p'uda [nòta D]	245	n'uz̄e ; rohk'ɔy
195	b'ui	223	--	246	onc'ulḡa·
196	br'usɔ·	224	--	247	kɔstɔnɔ·
197	r'ume [f]	225	--	248	k'ɔstɔp̄e
198	r'uz̄e	226	ehp'ipɔ·	249	p'elu
199	egl'ɔtje [nòta A]	227	s'ebɔ·	250	ɛn n̄ual / de pr'iset [m]
200	gr'ato tju	228	rej		
201	bw'ieu	229	f̄l'ejɔ·	251	əkest ənn'adɔ· / ʌɔ ɔtsyt /
202	tsip'ebre·	230	r'ykɔ·		belkwɔ / de fr'y:tsɔ·
204	--	231	'ouby ⁿ	252	ɔurjaj / deyt / b'eire· / kesi /
205	--	232	--		le'z aubre / n eru / k'ɔrgat
206	p'umje	233	--		
207	p'erje	234	kupa / del bwe / per fajre· /	253	se mɔntsɔm pa / nɔhtroj
			de f'axi		pr'ymoj / se mouzir'ou / l'eu
208	n'uye				
209	pr'ymlje	235	me s̄qej / ɔsjeta tsuz̄ ȳn		
210	sir'ej		'aubre / ɔpuja / k'ɔntro lu pe	254	pjel'aλɔ·
211	sir'ej soub'atse·	236	yno br̄ko / pwejr'ido· / m es	255	frɔmbw'ezɔ·
212	--		t̄m'bado / sy lo k'a:ro· / e m o	256	--
			/ fa / s'ɔ:n̄a / del na		
213	f̄igje			257	pr'esige
214	f̄igo·	237	ej lu ka ^k ke me r'ɔ:do	258	kuj'asje

Annèxa 4 La pagina 3 del questionari ALF

(en gras las frases o segments de frase, entre parentèsis los n° de mapas)

nº	col 1	nº	col 2	nº	col 3
183	frêne (611)	215	Les pommiers / commencent à fleurir. (1058; 311; 583)	238	Quand il fait du vent / le roseau / plie / mais / ne / rompt/ pas. (1370; 1166; 1037; 799; 896; 1162; 896)
184	tremble n.m. (arbre) (1329)	216	Les cerisiers / ont déjà / commencé (/ à fleurir) / il y a huit jours. (218; 383; 313; 583; 729)	239	une pomme tendre (1055)
185	bouleau (158)	217	greffer (666)	240	poire (1047)
186	ormeau (948)	218	greffon (en note) (1833)	241	coing (1510)
187	peuplier (1008)	219	la vigne (1392)	242	cerise (217)
188	saulle (1196)	220	cep de vigne (1780)	243	raisin (1129)
189	sureau (1270)	221	sarment	244	grappe de raisin (1832)
190	hièble (1595)	222	tailler la vigne (1907)	245	noix (920)
191	tilleul (1303)	223	épamprer (1816)	246	noisette (919)
192	osier (955)	224	pampre (1654)	247	châtaigne (251)
193	aubépine (68)	225	échalas (rame) (434)	248	châtaignier (1497)
194	cenelle (fruit de l'aubépine) (1490)	226	épine (476)	249	bogue de châtaigne (1407)
195	buis (186)	227	sève (1230)	250	un noyau / de pêche (926; 987)
196	bruyère (183)	228	racine (1126)	251	Cette année / il y a eu / beaucoup / de fruit. (44; 103; 120)
197	ronce (1163)	229	feuille (559)	252	Vous auriez / dû / voir / comme / les arbres / en étaient / chargés. (99; 402; 1408; 310; 52; 513; 240)
198	rosier (1167)	230	écorce (442)	253	Si nous ne mangeons pas / nos prunes / elles se moisiront / bientôt. (806; 1097; 869; 132)
199	églantier (452)	231	aubier (1446)	254	pelure de pommes (993)
200	gratte-cul (cynorhodon) (452)	232	provin (1096)	255	framboise (609)
201	buisson (187)	233	provigner (1682)	256	framboisier (609)
202	genévrier (636)	234	couper / du bois / pour faire / des fagots (35; 144; 530; 526)	257	pêcher n.m. (1659)
204	genièvre (baie) (636)	235	Je me suis / assis / sous un arbre / appuyé / contre le tronc. (500; 63; 51; 48; 1334)	258	cognassier (1510)
205	genièvre (boisson) (636)	236	Une branche / pourrie / m'est tombée / sur la figure / et m'a / fait / saigner / du nez. (170; 1076; 1312; 566; 88; 533; 1180; 908)		
206	pommier (1058)				
207	poirier (1049)				
208	noyer (arbre) (927)				
209	prunier (1099)				
210	cerisier (218)				
211	cerisier sauvage (218)	237	La tête me tourne		
212	cerise sauvage (218)				
213	figuier (1567)				
214	figue (1567)				