

Apprentissage en corpus de couples nom-verbe pour la construction d'un lexique génératif

Pascale Sébillot¹, Pierrette Bouillon², Vincent Claveau², Cécile Fabre³,
Laurence Jacquemin⁴, Jacques Nicolas¹

¹ IRISA - Campus de Beaulieu - 35042 Rennes cedex - France

² TIM/ISSCO - Université de Genève - 40 Bvd du Pont-d'Arve - CH-1205 Genève - Suisse

³ ERSS - Université de Toulouse II - 5 allées A. Machado - 31058 Toulouse cedex - France

⁴ Université Libre de Bruxelles - Infodoc - 50 av. F. Roosevelt - CP173/2 - B-1050 Bruxelles - Belgique

Abstract

NLP systems involving disambiguation and rephrasing require a fine-grained description of the semantics of lexical units. In this paper we describe a means for automatically extracting such information from corpora, in the framework of Pustejovsky's Generative Lexicon. In one of the components of this lexical model, called the *qualia structure*, words are described in terms of semantic roles. The qualia structure of a noun is mainly made up of verbal associations, encoding relational information. For example, the French verb *mesurer* refers to the telic role of the noun *jaugeur*. Our aim is, for a given noun (N), to be able to automatically extract from a corpus the verbs (V) that could belong to its qualia structure. More precisely, in this paper, we describe a method based on learning techniques within the Inductive Logic Programming framework, that permits us to distinguish in the corpus between N-V pairs that are linked by a semantic relation and pairs that are not. Results compared with a Khi2 score demonstrate that the method is very promising, not only because an important proportion of relevant pairs are detected, but also because it provides information that can be used to build linguistic rules.

Keywords: Lexical data acquisition from corpora, Generative Lexicon, statistical tagging, machine learning, inductive logic programming

Résumé

Désambiguïser, paraphraser sont des activités qui nécessitent pour les systèmes de TAL de s'appuyer sur des descriptions lexicales fines. Dans ce but, cet article propose une méthode pour extraire automatiquement à partir de corpus des informations lexicales définies par Pustejovsky dans le cadre du Lexique Génératif. Dans une des composantes de ce modèle lexical, la structure des *qualia*, les noms sont décrits à l'aide de rôles sémantiques, principalement en termes d'associations verbales. Par exemple, le mot *mesurer* exprime le rôle télique du nom *jaugeur*. Notre méthode consiste à extraire automatiquement, pour un nom (N) donné, les verbes (V) qui permettent de remplir cette structure des *qualia*. Elle est basée sur une technique d'apprentissage dans le cadre de la Programmation Logique Inductive, et nous permet de distinguer les paires N-V liées par une relation sémantique de celles qui ne le sont pas. Les résultats obtenus, comparés à un test du Khi2 sont encourageants à deux titres : cette technique repère une proportion importante de paires pertinentes et fournit des informations qui peuvent être utilisées pour construire des règles linguistiques.

Mots-clés : Acquisition de données lexicales à partir de corpus, Lexique Génératif, étiquetage statistique, apprentissage automatique, programmation logique inductive

1. Introduction

Pour les systèmes de TAL, le fait de disposer d'informations lexicales riches sur le plan sémantique constitue un apport précieux pour la résolution de certains des problèmes les plus complexes du traitement de la langue, comme la désambiguïsation ou le repérage de paraphrases. Le modèle du Lexique Génératif (Pustejovsky, 1995), basé sur une représentation compositionnelle du sens, donne accès à un réseau d'informations lexicales utilisables pour formaliser ce type de mécanismes. Ainsi, un des principaux composants du modèle, la structure des *qualia*, représente un mot en termes de rôles sémantiques qui rendent explicites les différents éléments de sens nécessaires à sa définition. Le rôle fonctionnel indique la fonction typique de l'objet dénoté (*visser* pour *vis*, ou *couper* pour *couteau*), l'agentif le mode de création (*construire* pour *porte*), le constitutif ses éléments constitutifs (*manche* pour *couteau*) et le formel sa catégorie sémantique (*artefact* pour *couteau*). Ces informations sont d'un intérêt certain ; par exemple, la fonction typiquement associée au nom *jaugeur* – *mesurer* – permet d'établir des liens entre des termes sémantiquement proches (*jaugeur de carburant*, *mesure du carburant*, *mesurer le carburant*). Cette relation de proximité sémantique intéresse en particulier les systèmes de reconnaissance de terminologie et de recherche d'information. L'apport d'informations de nature verbale augmente en effet les possibilités de reformulation des termes nominaux (Fabre, 1998), basée traditionnellement sur des relations de nature intracatégorielle (liens de synonymie et d'hyponymie).

Le coût de construction d'un lexique de cette nature est cependant prohibitif. L'objectif de notre travail¹ est donc de concevoir des techniques permettant d'assister l'acquisition de certaines composantes du Lexique Génératif à partir de corpus de textes. L'apport de ces informations lexicales sera ensuite évalué dans le cadre d'un système de recherche d'information.

Cet article présente les premiers résultats obtenus dans la phase d'acquisition. D'une part, nous y explicitons la méthode d'apprentissage développée pour identifier automatiquement les paires Nom-Verbe (N-V par la suite) pertinentes du point de vue de la structure des *qualia*. D'autre part, nous montrons que cette méthode donne des résultats meilleurs qu'un simple test du Khi2 ; ce dernier peut certes mettre en évidence des couples N-V fortement corrélés, mais sans distinguer automatiquement ceux dont les éléments sont effectivement liés sur le plan sémantique de ceux qui ne présentent pas cette propriété. Après avoir décrit les principes de la méthode utilisée, nous en explicitons la mise en œuvre et la validation, puis tirons nos premières conclusions.

2. Principes généraux de la méthode

Notre objectif, comme nous venons de le préciser, est d'être capable de distinguer automatiquement les couples N-V liés par une relation sémantique codée dans le Lexique Génératif par opposition aux autres couples N-V. Pour ce faire, nous avons choisi de développer une méthode d'apprentissage automatique. L'avantage de l'apprentissage automatique (Mitchell, 1997), dont le but est de construire des programmes à partir d'exemples de fonctionnement dont on connaît la validité, est son caractère adaptatif. Une méthode d'apprentissage développée dans un domaine donné est en effet applicable sans difficultés à un autre domaine.

Parmi les diverses "techniques" possibles, nous avons retenu la programmation logique induc-

1. Ce travail a bénéficié du concours de l'Agence universitaire de la Francophonie (AUPELF-UREF) (Action de recherche partagée "Acquisition automatique d'éléments du Lexique Génératif pour améliorer les performances de systèmes de recherche d'informations", réseau FRANCIL).

tive (PLI) (Muggleton and De-Raedt, 1994) où les programmes que l'on cherche à inférer à partir d'un ensemble de faits observés (les exemples d'apprentissage) et d'un ensemble de connaissances a priori sont des programmes logiques (ensemble de clauses de Horn). Plus précisément ici, en fournissant un ensemble de couples N-V en relation sémantique au sein d'un contexte (exemples positifs), et éventuellement un ensemble de couples N-V non liés sémantiquement (exemples négatifs), on infère des règles générales (clauses) "expliquant" ces exemples positifs, et c'est ce caractère explicatif de la PLI qui a guidé notre choix. En effet, en plus de fournir un prédicteur (ceci est un couple N-V pertinent, ceci ne l'est pas), elle offre une théorie fondée sur les données. Son niveau cognitif est suffisamment élevé pour qu'elle ne soit pas une simple boîte noire, contrairement à des nombreuses méthodes statistiques fournissant un résultat brut sans explication.

Nous utilisons Progol (Muggleton, 1995), la mise en œuvre de la PLI développée par Muggleton, qui présente l'avantage d'être disponible et de pouvoir traiter un nombre important de données. De plus, cet algorithme a déjà été utilisé dans de multiples domaines avec satisfaction.

Concrètement, la mise au point de la méthode d'apprentissage comporte deux phases disjointes : d'une part, il convient de développer et de valider de manière interne la méthode, c'est-à-dire de régler les paramètres nécessaires à l'apprentissage. D'autre part, il faut évaluer la méthode empiriquement sur un corpus. Dans la suite, nous décrivons en détail la mise en œuvre de ces deux phases.

3. Méthode d'apprentissage : mise en œuvre et validation

3.1. Préparation du corpus

La première tâche de la mise en œuvre consiste à choisir un corpus et à l'étiqueter le plus soigneusement possible (étiquetage catégoriel). Une partie de ce corpus sert à l'apprentissage alors que l'ensemble sert de corpus de validation. Pour cette première expérience, nous avons choisi le corpus de l'Aérospatiale MATRA CCR, manuel de maintenance d'hélicoptères. A priori, ce corpus nous semblait idéal pour différentes raisons : outre sa cohérence, il contient un grand nombre de termes concrets (*vis, écrou, porte, réservoir, etc.*) pour lesquels la méthode proposée semble particulièrement indiquée : ces noms apparaissent fréquemment avec des verbes qui indiquent leur fonction typique (les écrous doivent être *serrés*, les réservoirs *remplis*, etc.) ou leur mode de création (la porte est *construite* d'une certaine manière, etc.).

L'analyse du corpus a été réalisée séquentiellement avec une série d'outils d'annotation développés dans le cadre du projet MULTEXT (Armstrong, 1996) : après segmentation avec *MtSeg*, les mots sont analysés et lemmatisés avec *Mmorph* ((Petitpierre and Russell, 1994) ; (Bouillon et al., 1998)), puis désambiguïsés par l'étiqueteur probabilistique *Tatoo* (HMM, Hidden Markov model², (Rabiner, 1989)). Cette chaîne d'outils présente deux avantages pour notre recherche. D'une part, le modèle statistique, calculé automatiquement suivant l'algorithme Baum-Welch (Baum, 1972), peut être affiné par un ensemble de règles linguistiques, sous la forme de bigrammes, comme illustré ci-dessous :

PRON	NOUN-SG	=0
	NOUN-PL	=0
!PI	ADJ-PL	=0

2. *Mmorph* et *Tatoo* sont disponibles gratuitement à l'adresse <http://www.issco.unige.ch/tools/>.

ADJ-SG = 0

Ces règles sont très utiles pour biaiser le modèle quand les données d'apprentissage sont insuffisantes et nous permettent d'obtenir des résultats tout à fait satisfaisants, inférieurs à 2% d'erreurs. Dans l'exemple ci-dessus, les deux premières contraintes spécifient qu'un pronom ne peut pas être suivi d'un nom singulier ou pluriel ; la seconde précise que les adjectifs singuliers et pluriels ne commencent normalement pas une phrase³. Il est possible, grâce à *Tatoo*, de modifier ces biais interactivement : dans ce but, il suffit d'étiqueter une petite partie du corpus à la main. L'outil permet alors de comparer les résultats obtenus manuellement avec ceux de l'étiqueteur. Il affiche le nombre d'erreurs par catégorie, avec leur contexte. Une fenêtre permet de modifier les biais sur base de cette information et de ré-étiqueter le corpus en tenant compte des modifications.

D'autre part, une distinction fondamentale est faite ici entre l'information lexicale, fournie par *Mmorph* sous forme de structures de traits, et les étiquettes syntaxiques atomiques qui doivent être désambiguïsés par l'étiqueteur. Cette distinction permet à l'utilisateur de choisir les étiquettes en fonction de l'application et du degré de précision souhaitée. Par exemple, la plupart des participes passés peuvent aussi être utilisés comme adjectifs. Leur désambiguïsation est difficile parce qu'elle se fonde linguistiquement sur la présence d'un auxiliaire. Or celui-ci peut être séparé du verbe par différents éléments qui complexifient à la fois le modèle statistique et la désambiguïsation (Chanod and Tapanainen, 1998). Pour éviter ici que certains participes soient considérés comme des adjectifs et pour ne pas perdre des prédicats potentiellement pertinents, nous avons décidé de ne pas résoudre cette ambiguïté : ces mots reçoivent donc une seule étiquette, VERB-ADJ. Bien sûr, ce traitement pourrait s'avérer inutile dans un autre corpus où les participes passés sont moins nombreux. L'intérêt des outils utilisés ici est de pouvoir modifier aisément le jeu d'étiquettes en fonction des besoins.

3.2. Préparation des données d'apprentissage

La seconde tâche consiste à préparer les données d'apprentissage, c'est-à-dire à sélectionner un ensemble de couples N-V positifs et négatifs représentatifs et à déterminer le contexte d'apparition qui devra être pris en compte par le programme d'apprentissage. Divers tests sont donc nécessaires à la mise au point des exemples d'apprentissage, et il faut être capable de juger de la valeur des paramètres choisis. Nous abordons brièvement les critères de choix en fin de section 3.3, définis à l'aide de la détermination d'une mesure de la qualité de l'apprentissage réalisé.

Dans notre cas, la méthode suivante s'est avérée la plus satisfaisante : pour constituer la base d'exemples, un premier programme extrait, pour tous les noms du corpus, les 10 verbes qui leur sont le plus associés selon la méthode du Khi2. Nous obtenons par exemple des couples tels que (*écrou, serrer*) ou (*porte, fermer*), mais aussi des paires dont les éléments ne sont pas liés sémantiquement, telles que (*roue, prescrire*) ou encore (*rayure, rebuter*). Ces paires sont ensuite annotées manuellement comme pertinentes ou non pertinentes par rapport à ce que l'on veut apprendre (c'est-à-dire la structure des *qualia*). Le nombre de 10 semble être un bon compromis dans le cas présent, mais d'autres options peuvent être envisagées, notamment annoter uniquement la meilleure paire, prendre quelques noms significatifs et annoter toutes les paires possibles, etc.

Pour le contexte, nous retenons la catégorie grammaticale du mot avant et après le nom, celle du

3. PI désigne la matrice qui contient la probabilité pour une étiquette de commencer une phrase.

mot avant le verbe, le type de verbe (participe passé, infinitif ou autre), la distance en nombre de verbes conjugués et la position du verbe par rapport au nom (post- ou préposé). Ici, le problème est d'être assez spécifique pour bloquer les généralisations non pertinentes, tout en permettant une généralisation suffisante. Les exemples positifs et négatifs nécessaires à Progol que l'on cherche à générer sont donc de la forme :

[:-]⁴POSITIF(CATÉGORIE_AVANT_N, CATÉGORIE_APRÈS_N, CATÉGORIE_AVANT_V, TYPE_DE_V, DISTANCE, POSITION).

Ces exemples sont construits de la façon suivante : un programme prend en entrée les paires N-V annotées manuellement comme pertinentes et repère, pour chacune d'elles, les phrases dans lesquelles le N et le V concernés apparaissent conjointement. Il convient toutefois de contrôler à la main si ces N et ces V sont effectivement liés dans ces phrases. À partir des phrases retenues, les exemples positifs sont automatiquement générés, en excluant les adjectifs, les adverbes et les déterminants.

On obtient, par exemple, la clause exemple positif :

POSITIF(VRBINF,P_DE,VID,VRBINF,0,NEG).

dans laquelle on considère comme pertinente la paire N-V où le V (de type infinitif (VRBINF) et sans contexte gauche (VID)) est suivi (NEG) par le N, dont le contexte gauche est un verbe à l'infinitif (premier VRBINF) et qui est suivi de la préposition *de* (P_DE) (par exemple *ouvrir la porte de ...*).

Les exemples négatifs sont construits de la même façon à partir des couples N-V non pertinents repérés parmi ceux fortement corrélés. Par exemple,

:-POSITIF(VID,P_PAR,NC,VRBPP,0,POS).

indique qu'une paire N-V où le V (de type participe passé (VRBPP)) suit (POS) le N (sans contexte gauche (VID) et suivi de la préposition *par* (P_PAR)) n'est pas pertinente (par exemple, *freinage par gouille fendues*).

Sur notre corpus, nous obtenons de cette manière un ensemble de 4031 exemples positifs et d'environ 7000 exemples négatifs.

3.3. Apprentissage proprement dit

À partir des exemples positifs et négatifs, Progol peut maintenant inférer un certain nombre de clauses correspondant à des généralisations effectuées à partir de certains des exemples positifs – les autres exemples positifs ne pouvant être généralisés et les exemples négatifs servant à contraindre les généralisations excessives. Il faut cependant lui indiquer auparavant les classes de catégories de mots permettant ces généralisations. On peut ainsi choisir de regrouper les prépositions par type (lieu, moyen, etc.) ou encore de les généraliser en une seule catégorie.

Voici un exemple de généralisation obtenu par Progol :

POSITIF(A,B,C,D,E,F) :- VIDE(A), AUX_ETRE(C), PREPOSITIONDE(B), PRES(E).

Ici est considéré comme positif tout couple N-V (i) sans verbe conjugué entre N et V ("proximité" dénotée par PRES(E)), (ii) dont le nom n'a pas de contexte gauche (VIDE(A)) et est suivi

4. La présence du signe :- indique un exemple négatif, son absence un exemple positif.

de la préposition *de* (PREPOSITIONDE(B)) et (iii) dont le verbe est précédé de l'auxiliaire *être* (AUX_ETRE(C)).

Ces clauses permettent à leur tour de valider notre méthode d'apprentissage. L'objectif en PLI est en effet d'obtenir un ensemble de clauses suffisamment générique pour couvrir la majorité des exemples positifs proposés et suffisamment spécifique pour bien "coller" au concept que l'on cherche à apprendre et ne pas couvrir trop d'exemples négatifs (on peut cependant autoriser un certain taux de bruit).

Nous n'entrerons pas ici dans le détail de cette partie validation interne de la méthode. Elle consiste, pour chaque ensemble différent d'éléments de contexte formant les exemples positifs et négatifs, à produire et étudier la courbe des couvertures théorique⁵ et empirique⁶ des clauses généralisées produites par Progol, à déterminer parmi ces clauses celles qui sont pertinentes pour l'évaluation des performances de la méthode en se basant sur la forme de la courbe (dans notre cas, nous retenons par exemple toutes les clauses généralisées obtenues), et à évaluer la qualité de l'ensemble des clauses généralisées retenues, c'est-à-dire à calculer le pourcentage d'exemples positifs d'apprentissage couverts par le paquet de clauses et le pourcentage d'exemples négatifs d'apprentissage rejetés par lui ; ces valeurs du rappel et de la précision de la méthode d'apprentissage (avec le réglage de paramètres choisi) sont regroupées au sein d'un indice, dans notre cas, le coefficient de Pearson. Enfin, pour un même choix de paramètres de contexte, nous faisons évoluer le taux de bruit autorisé afin d'obtenir le meilleur coefficient de Pearson possible, soit le plus proche de 1.

Pour les éléments de contexte décrits en 3.2 et en retenant l'ensemble des clauses généralisées produites par Progol, nous obtenons les résultats suivants : avec un taux de bruit de 37%, 87.99% des exemples positifs sont reconnus par les clauses et seuls 5.03% des exemples négatifs sont également couverts ; le coefficient de Pearson est alors de 0.84.

3.4. Évaluation empirique

Pour valider la méthode sur corpus, il s'agit, dans notre cas, d'utiliser les règles générales produites par Progol pour étiqueter les couples N-V du corpus et de juger la pertinence des décisions prises (précision et rappel par rapport à un étiquetage manuel, et comparaison de la liste des couples proposés par rapport aux couples fortement corrélés). Comme le nombre de couples N-V au sein du corpus est beaucoup trop important pour pouvoir mener à bien cette tâche sur tout le corpus, voire même sur un pourcentage significatif de celui-ci, nous nous sommes limités à sept noms significatifs (*vis, écrou, porte, voyant, prise, capot et bouchon*). Le tableau suivant résume les résultats obtenus, en faisant varier la fréquence d'apparition des paires dans le corpus (1 ou 6 occurrences nécessaires) :

Avec 1 occurrence nécessaire	Avec 6 occurrences nécessaires
correctement trouvés : 49	correctement trouvés : 23
incorrectement trouvés : 54	incorrectement trouvés : 4
non trouvés : 10	non trouvés : 36
Pearson = 0.5138	Pearson = 0.5209

5. Notre mesure de généralité théorique d'une clause généralisée est le nombre de clauses non générales qui peuvent être déduites d'elle.

6. Nombre d'exemples positifs couverts.

Ces résultats nous semblent tout à fait prometteurs, surtout en comparaison avec ceux produits par le Khi2 :

correctement trouvés : 38
incorrectement trouvés : 124
non trouvés : 21
Pearson = 0.1206

Tout d'abord, la méthode proposée permet la détection d'une proportion importante de couples pertinents (49/59, soit 83.05%, par rapport au 64% du test Khi2) ; ensuite, il est encourageant de constater que, dans certaines paires non trouvées, le V est sémantiquement moins associé au N, par exemple *prise nettoyer* et *prise défreiner* (vs *prise brancher*, *prise débrancher*, *prise alimenter*, *prise raccorder*, etc.) ou *vis freiner* (vs *vis visser*). Enfin, le bruit, relativement élevé, ne remet pas en question notre méthode : la syntaxe n'est évidemment pas assez précise pour distinguer, parmi les exemples grammaticalement possibles, ceux qui sont sémantiquement pertinents. Par exemple, une structure du type 'Vinf det N' est en général pertinente (*ouvrir la porte*, etc.), sauf dans les cas bien précis où le N indique un groupe d'objets (*nettoyer l'ensemble du réservoir*) ou une partie (*vider le fond du réservoir*). Dans même ordre d'idée, la paire 'V N2' de la structure 'V N1 N2' est pertinente si le N1 indique un groupe d'objets ou une partie (*vider fond réservoir*, *déposer ensemble groupe_auxiliaire*), mais pas dans les autres cas (*poser les obturateurs capot* ; *retirer les obturateurs capot*). Finalement, le texte contient beaucoup d'énumérations du type : (i) *poser les barettes de fermeture : rondelles, écrous : serrer au couple* ; (ii) *vérifier le harnais : couture, boucle* ; etc. Celles-ci ont la même structure syntaxique ('V det N1 : N2, N3'), mais diffèrent sur le plan sémantique : dans la première phrase, le verbe *poser* n'est pas lié au nom N2 *rondelles* qui dépend de *serrer au couple* ; en revanche dans la seconde phrase, *vérifier couture* et *vérifier boucle* sont des paires significatives, puisque *couture* et *boucle* sont des parties du *harnais*. Dans la prochaine phase du projet, les textes seront étiquetés sémantiquement suivant la méthode décrite dans (Ruch et al., 1999), dans le but de réduire le bruit. Une classification, aussi sommaire soit-elle, distingue en effet les parties et groupes des autres mots. De même, *écrou*, *vis*, *couture* et *boucle* dénotent des types d'ARTEFACTS différents. Dans WordNet par exemple, *vis* et *écrou* sont considérés comme des BLOCKS ("*a small square or hexagonal metal block with internal screw thread to be fitted onto a bolt*") ; *couture* est un JOINT ("*by which parts or objects are joined together*") et *boucle* un DEVICE ("*an instrumentality invented for a particular purpose*").

4. Conclusion

Nous avons proposé et validé ici une méthode d'analyse textuelle, pour extraire un type particulier de connaissances lexicales sur les mots d'un corpus. Celle-ci combine des méthodes statistiques (pour l'étiquetage) et d'apprentissage automatique. Sa particularité est d'être adaptative. D'une part, elle peut facilement être appliquée à différents domaines et, d'autre part, elle peut être affinée en ajoutant des connaissances (sémantiques, par exemple) ou en changeant les paramètres (exemples positifs et négatifs, contexte, etc.). Nous n'avons présenté que les premiers résultats, mais ils sont le prélude obligé de tout travail plus ambitieux. Ils montrent en tout cas que la méthode offre une alternative intéressante à celle du Khi2 : il ne s'agit plus seulement ici d'extraire les couples statistiquement corrélés, mais d'apprendre automatiquement les règles linguistiques qui distinguent les couples pertinents dans une perspective particulière de ceux qui ne le sont pas.

Références

- Armstrong S. (1996). Multext: Multilingual Text Tools and Corpora. In Feldweg H. and Hinrichs W. editors, *Lexikon und Text*. Tübingen: Niemeyer.
- Baum L. (1972). An Inequality and Associated Maximization Technique in Statistical Estimation for Probabilistic Functions of Markov Processes. *Inequalities*, 3.
- Bouillon P., Lehmann S., Manzi S., and Petitpierre D. (1998). Développement de lexiques à grande échelle. In *Actes du colloque de Tunis 1997 "La mémoire des mot"*, Tunis.
- Chanod J.-P. and Tapanainen P. (1998). Statistical and Constraint-based Taggers for French. Technical Report MLTT-016, Ranx Xerox Research Center.
- Fabre C. (1998). Repérage de variantes dérivationnelles de termes. Technical report, Carnets de grammaire, Équipe de Recherche en Syntaxe et Sémantique UMR 5610, CNRS et Université de Toulouse-Le Mirail.
- Mitchell T. M. (1997). *Machine Learning*. McGraw-Hill.
- Muggleton S. (1995). Inverse entailment and Progol. *New Generation Computing*, 13(3-4).
- Muggleton S. and De-Raedt L. (1994). Inductive Logic Programming: Theory and Methods. *Journal of Logic Programming*, 19-20.
- Petitpierre D. and Russell G. (1994). Mmorph - the Multext Morphology Program. Technical report, ISSCO.
- Pustejovsky J. (1995). *The Generative Lexicon*. Cambridge:MIT Press.
- Rabiner L. (1989). A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. In Waibel A. and Lee K. editors, *Readings in Speech Recognition*. IEEE.
- Ruch P., Bouillon P., Baud R.-H., Rassinoux A.-M., and Scherrer J.-R. (1999). MEDTAG: Tag-like Semantics for Medical Document Indexing. In *Actes de AMIA99 Annual Symposium*, Washington, DC.