



HAL
open science

Langage normalisé pour la description des informations médicales en radiologie

Philippe Duquesnel

► **To cite this version:**

Philippe Duquesnel. Langage normalisé pour la description des informations médicales en radiologie. Modélisation et simulation. Université Joseph-Fourier - Grenoble I, 1969. Français. NNT: . tel-00281650

HAL Id: tel-00281650

<https://theses.hal.science/tel-00281650>

Submitted on 23 May 2008

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.

N° d'ordre

THESE

présentée à

LA FACULTE DES SCIENCES DE L'UNIVERSITE DE GRENOBLE

pour obtenir

LE GRADE DE DOCTEUR DE TROISIEME CYCLE

" Mathématiques Appliquées "

par

Philippe DUQUESNEL



Langage normalisé pour la description des informations médicales en radiologie



Thèse soutenue le 19 juin 1969, devant la Commission d'examen :

Monsieur J. KUNTZMANN Président

Messieurs GEINDRE

VAUQUOIS

BOUSSARD

Examineurs

LISTE des PROFESSEURS

DOYEN HONORAIRE : M. MORET

DOYEN : M. BONNIER

PROFESSEURS TITULAIRES :

MM. NEEL Louis	Chaire de Physique expérimentale
HEILMANN René	Chaire de Chimie
KRAVTCHEKOV Julien	Chaire de Mécanique Rationnelle
CHABAUTY Claude	Chaire de calcul différentiel et Intégral
BENOIT Jean	Chaire de Radioélectricité
CHENE Marcel	Chaire de Chimie Papetière
FELICI Noël	Chaire d'Electrostatique
KUNTZMANN Jean	Chaire de Mathématiques Appliquées
BARBIER Reynold	Chaire de Géologie Appliquée
SANTON Lucien	Chaire de Mécanique des Fluides
OZENDA Paul	Chaire de Botanique
FALLOT Maurice	Chaire de Physique Industrielle
KOSZUL Jean Louis	Chaire de Mathématiques
GALVANI O.	Mathématiques
MOUSSA André	Chaire de Chimie Nucléaire
TRAYNARD Philippe	Chaire de Chimie Générale
SOUTIF Michel	Chaire de Physique Générale
CRAVA Antoine	Chaire d'Hydrodynamique
REULOS R.	Théorie des Champs
BESSON Jean	Chaire de Chimie
AVANT Yves	Physique Approfondie
GALLISSOT	Mathématiques
Mlle LUTZ Elisabeth	Mathématiques
BLAMBERT Maurice	Chaire de Mathématiques
BOUCHEZ Robert	Physique Nucléaire
LLIBOUTRY Louis	Géophysique
MICHEL Robert	Chaire de Minéralogie et Pétrographie
BONNIER Etienne	Chaire d'Electrochimie et d'Electrometallurgie
DESSEAUX Georges	Chaire de Physiologie Animale
PILLET E.	Chaire de Physique Industrielle et Electrotechn
VOCCOZ Jean	Chaire de Physique Nucléaire Théorique
DEBELMAS Jacques	Chaire de Géologie Générale
GERBER R.	Mathématiques
PAUTHENET R.	Electrotechnique
VAUQUOIS B.	Chaire de calcul électronique
BARJON R.	Physique Nucléaire
BARBIER Jean-Claude	Chaire de Physique
SILBER R.	Mécanique des Fluides
BUYLE-BODIN Maurice	Chaire d'Electronique
DREYFUS B.	Thermodynamique

PROFESSEURS TITULAIRES (suite)

MM.	KLEIN J.	Mathématiques
	VAILLANT F.	Zoologie et Hydrobiologie
	ARNAUD Paul	Chaire de Chimie
	SENGEL P.	Chaire de Zoologie
	BARNOUD F.	Chaire de Biozythèse de la Cellulose
	BRISSONNEAU P.	Physique
	GAGNAIRE	Chaire de Chimie Physique
Mme	KOFLER L.	Botanique
	DEGRANGE Charles	Zoologie
	PEBAY-PEROULA J.C.	Physique
	RASSAT A.	Chaire de Chimie Systématique
	DUCROS P.	Vhaire de Cristallographie Physique
	DODU Jacques	Chaire de Mécanique Appliquée I.U.T.
	ANGLES D'AURIAC P.	Mécanique des Fluides
	LACAZE A.	Thermodynamique

PROFESSEURS SANS CHAIRE

MM.	GIDON P.	Géologie et Mnéralogie
	GIRAUD P.	Géologie
	PERRET R.	Servomécanisme
Mme	BARBIER M.J.	Electrochimie
Mme	SOUTIF J.	Physique
	COHEN J.	Electrotechnique
	DEPASSEL R.	Mécanique des Fluides
	GASTINEL N.	Mathématiques Appliquées
	GLENAT R.	Chimie
	BARRA J.R.	Mathématiques Appliquées
	COUMES A.	Electronique
	PERRIAUX J.	Géologie et Minéralogie
	ROBERT A.	Chimie Papetière
	BIAREZ J.P.	Mécanique Physique
	BONNET G.	Electronique
	CAUQUIS G.	Chimie Générale
	BONNETAIN L.	Chimie Minérale
	DEPOMMIER P.	Etude Nucléaire et Génie Atomique
	HACQUES Gérard	Calcul Numérique
	POLOUJADOFF M.	Electrotechnique

PROFESSEURS ASSOCIES

MM.	NAPP-ZINN	Botanique
	RODRIGUES Alexandre	Mathématiques Pures
	STANDING Kenneth	Physique Nucléaire

MAITRES DE CONFERENCES

MM.	LANCIA Roland	Physique Atomique
Mme	KAHANE J.	Physique
	DEPORTES C.	Chimie
Mme	BOUCHE L.	Mathématiques
	SARROT-REYNAUD	Géologie Propédeutique

MAITRES DE CONFERENCES (suite)

Mme	BONNIER M.J.	Chimie
MM.	KAHANE A.	Physique Générale
	DOLIQUE J.M.	Electronique
	BRIERE G.	Physique M.P.C.
	DESRE G.	Chimie S.P.C.N.
	LAJZROWICZ J.	Physique M.P.C.
	VALENTIN P.	Physique M.P.C.
	BERTRANDIAS J.P.	Mathématiques Appliquées T.M.P.
	LAURENT P.J.	Mathématiques Appliquées T.M.P.
	CAUBET J.P.	Mathématiques Pures
	PAYAN J.J.	Mathématiques
Mme	BERTRANDIAS F.	Mathématiques Pures M.P.C.
	LONGEGUEUE J.P.	Physique
	NIVAT M.	Mathématiques Appliquées
	SOHM J.C.	Electrochimie
	ZADWORNY F.	Electronique
	DURAND F.	Chimie Physique
	CARLER G.	Biologie Végétale
	AUBERT G.	Physique M.P.C.
	DELPUECH J.J.	Chimie Organique
	PFISTER J.C.	Physique C.P.E.M.
	CHIBON P.	Biologie Animale
	IDELMAN S.	Physiologie Animale
	BOUVARD Maurice	Hydrologie
	RICHARD Lucien	Botanique
	PELMONT Jean	Physiologie Animale
	BLOCH D.	Electrotechnique I.P.
	BOUSSARD J.Claude	Mathématiques Appliquées I.P.
	MOREAU René	Hydraulique I.P.
	BRUGEL L.	Energétique I.U.T.
	SIBILLE R.	Construction Mécanique I.U.T.
	ARMAND Yves	Chimie I.U.T.
	BOLLIET Louis	Informatique I.U.T.
	KUHN Gérard	Energétique I.U.T.
	GERMAIN J.P.	Construction Mécanique I.U.T.
	CONTE René	Thermodynamique
	JOLY Jean René	Mathématiques Pures
Mme	PIERV Yvette	Biologie Animale
	BENZAKEN Claude	Mathématiques Appliquées

MAITRE DE CONFERENCES ASSOCIES

MM.	SAWCZUK A.	Mécanique des Fluides
	CHEEKE J.	Thermodynamique
	YAMADA O.	Physique du Solide
	NATR Lubomir	B.M.P.V.
	NAYLOR Arch	Physique Industrielle
	SILBER Léo	Radioélectricité
	NOZAKI Akihiro	Mathématiques Appliquées
	RUTLEDGE Joseph	Mathématiques Appliquées
	DONOHÓ Paul	Physique Générale
	EGGER Kurt	B.M.P.V.

1.III. - L'Analyseur syntaxique	41
1.III.1. Syntaxe et sémantique	41
 CHAPITRE 2 - DOCUMENTATION AUTOMATIQUE ET LANGAGE NORMALISE	 52
2.I. - Correspondance biunivoque entre la phrase française et la phrase analysée	52
2.I.1. Rappel et terminologie employée	53
2.I.2. Si deux phrases françaises ont même sens, les phrases éditées sont analogues	53
2.I.3. Si deux phrases éditées sont analogues, elles ont même présentation interne	55
2.I.4. Réciproques	56
2.II - Relation d'inclusion entre demandes d'examen	56
2.II.1. Forme des inclusions	57
2.II.1.1. Inclusion au niveau du mot français	57
2.II.1.2. Inclusion au niveau de la syntaxe	58
2.II.1.3. Inclusion hybride	58
2.II.1.4. Non inclusion	58
2.II.2. Forme de l'inclusion au niveau de la syntaxe entre les représentations internes	59
2.II.2.1. Concepts et règles de grammaires	59
2.II.2.2. Reconnaissance d'inclusion entre deux représentations internes	62
2.II.2.2.1. Mise en évidence de la structure d'une phrase	63
2.II.2.2.2. Mise en évidence des inclusions élémentaires	64
2.II.2.2.3. Inclusion entre deux phrases analysées	65
2.II.3. Forme de l'inclusion au niveau des mots français	66
2.II.3.1. Diverses formes d'inclusions au niveau des mots français	66
2.II.3.2. Règle de recherche d'une inclusion lors de la comparaison de suites d'unités lexicales	67
2.III - Principe général de l'algorithme de reconnaissance d'inclusion	68
2.III.1. Principe général de l'algorithme de comparaison	69
2.III.2. Remarque pratique sur l'enregistrement de la structure d'une phrase analysée	70

CHAPITRE 3 - LE TRAITEMENT DES FICHIERS	76
3.I - Introduction du fichier hybride	76
3.I.1. Définition du fichier hybride	76
3.I.2. Problèmes de traitement d'un fichier hybride	77
3.I.3. Exposé d'un principe d'implémentation	78
3.I.3.1. Eclatement de l'enregistrement logique	78
3.I.3.2. Eclatement du fichier - fichier logique	79
3.II - Application - Le dossier médical radiologique	80
3.II.1. Description du fichier	80
3.II.1.1. Première description du fichier logique	80
3.II.1.2. Structure syntaxique du dossier médical	82
3.II.1.3. Problèmes posés par l'emploi d'une structure variable	84
3.II.1.4. Introduction du fichier descripteur	85
3.II.2. Traitement du fichier des dossiers médicaux	88
3.II.2.1. Documentation automatique	88
3.II.2.2. La mise à jour	90
3.II.2.3. Programme de nettoyage	91
CONCLUSION	93

R E M E R C I E M E N T S

Je tiens à remercier Monsieur le Professeur KUNTZMANN qui a bien voulu présider le Jury d'examen ainsi que Monsieur le Professeur VAUQUOIS qui a accepté de faire partie de ce jury.

Que Monsieur le Professeur GEINDRE accepte l'expression de mes remerciements sincères pour le grand intérêt qu'il a manifesté pour mon travail.

Je remercie le Docteur VALOIS qui, sacrifiant si spontanément une grande partie de son temps libre habituellement destiné à la préparation d'innombrables rallyes automobiles, s'est chargé de toute la partie médicale nécessaire à ce travail en même temps qu'il s'initiait aux "secrets" de l'informatique.

Je remercie également Monsieur BOUSSARD qui après m'avoir conseillé l'année dernière de reprendre mon travail pour le programmer en tenant compte des possibilités offertes par le nouveau calculateur du Laboratoire, m'a amené grâce à ses nombreux conseils et remarques à changer, en l'améliorant je l'espère, ce travail.

Je voudrais évoquer l'ambiance que j'ai trouvée au long de mon séjour dans l'Equipe de Gestion composée à mon arrivée de Messieurs PECCOUD et DAGAND qui s'intéressaient aux problèmes de sémantique économique : problèmes impressionnants pour un néophyte.

Que Monsieur PECCOUD accepte mes remerciements tardifs mais sincères pour les encouragements au travail et à la persévérance (combien nécessaires à l'époque !) qu'il m'a donné dans les premiers temps de ce travail ; non moins utile m'a été l'aide efficace que m'a apportée Monsieur DAGAND avec une patience et une constance remarquable.

Que l'ensemble de mes camarades de l'équipe reçoivent sans trop sourire mes remerciements non seulement pour les innombrables petits services qu'ils m'ont rendus mais aussi pour l'ambiance dans laquelle nous avons travaillé, ambiance qui a parfois causé bien du souci à Monsieur PECCOUD !

J'espère que Madame TREVISAN qui a assuré la réalisation matérielle de ce travail en gardera un souvenir autre qu'un nombre impressionnant d'allers-retours au pas de course dans les couloirs de l'Institut Polytechnique. Qu'elle trouve ici l'expression de mes remerciements sincères.

Enfin, je profite de cette page pour rendre hommage à mes Parents dont le soutien tout moral n'a pas été négligeable et aussi à ma Femme dont la belle confiance dans les capacités de son mari(!) m'a puissamment stimulé.

I N T R O D U C T I O N

Au cours de ces quinze dernières années, en même temps que l'introduction des ordinateurs dans le domaine de la gestion permettait de réaliser des progrès sensibles dans les méthodes de traitement des informations, la médecine, du fait de ses progrès propres, amassait des connaissances de plus en plus nombreuses et complexes.

La nécessité d'exploiter cette masse d'informations a amené tout naturellement certaines personnes à s'intéresser aux méthodes nouvelles de traitement des informations issues de l'apparition des ordinateurs.

C'est pourquoi un certain nombre d'études dans le domaine du traitement intégré des informations dans un centre hospitalier ont déjà été entreprises et menées à terme dans certains centres hospitaliers. Parmi celles-ci on s'est intéressé aux études dont le but est d'examiner quelles possibilités offrent les ordinateurs pour gérer automatiquement l'ensemble des dossiers médicaux de tous les malades présents dans un centre hospitalier.

L'impression générale laissée par l'ensemble des systèmes dont on a eu connaissance [1] est la suivante :

Une partie importante des informations recueillies au cours du séjour d'un malade dans un centre hospitalier échappe ou bien s'adapte mal aux divers processus de traitement automatisé des informations.

Comme on va le voir de façon plus détaillée dans le paragraphe suivant, il existe tout un ensemble d'informations qui ne peuvent être enregistrées de manière satisfaisante par les moyens classiques que sont les grilles précodées utilisées par l'ensemble des divers systèmes dont on a eu connaissance.

I - LE DOSSIER MEDICAL - L'INFORMATION EN MILIEU HOSPITALIER

Il apparaît que la majeure partie des informations concernant un malade (Etat-Civil, Ecologie, Antécédents, ..., Examens Cliniques, Examens de Laboratoire, etc...) se trouve dans le dossier médical complet. Ce dossier se présente généralement comme une suite de divers examens.

Un certain nombre de ces informations apparaît comme très facilement et très utilement codable, telles par exemple, un numéro de sécurité sociale, une adresse, un poids, un résultat chiffré d'analyse. Par contre, apparaissent de sérieuses difficultés pour le codage d'informations telles un syndrome clinique, un compte-rendu opératoire.

En effet, le langage médical est essentiellement descriptif, et, si l'on veut coder ces informations on se heurtera à plusieurs difficultés :

- 1° - La codification, malgré un travail très lourd, n'apportera pas grand chose car le vocabulaire médical est en lui-même très analytique et représente en lui-même un code suffisamment satisfaisant pour ne pas le remplacer par un autre.
- 2° - La science médicale exige une telle précision qu'il est indispensable, le plus souvent, de conserver les nuances sémantiques permises par le langage courant.
- 3° - Les programmes établis à partir de codes sont très lourds à manipuler. Messieurs Bernier et Kempf [2] ont, par exemple, calculé que pour décrire avec une certaine précision un syndrome douloureux gastrique, il faut 9 caractères : type de douleur, siège, irradiations, ..., qui nécessite l'emploi de 100 mots. Ces 100 mots peuvent être générateurs de 13 milliards de possibilités différentes.

La codification par l'intermédiaire de feuilles de marque ou de procédés similaires, se heurte au même écueil et la multiplicité et le nombre des documents représente une difficulté supplémentaire [3].

4° - Enfin un code aussi complet et aussi universel soit-il reste un cadre rigide et s'adapte plus ou moins bien aux diverses disciplines ; ainsi, le code S.N.O.P. qui donne satisfaction aux anatomopathologistes est difficilement utilisable par un anatomiste ou un clinicien et la nomenclature O.M.S. utilisée par les hygiénistes ne satisfait pas aux exigences d'une observation hospitalière [4].

Aussi pour cette seconde catégorie d'informations, est-on appelé à envisager un mode d'expression aussi riche que le langage médical courant, mais qui permette néanmoins de repérer, stocker, et exploiter automatiquement ces informations [5].

Les informations qui ne seront pas codées seront écrites telles quelles, mais seront repréées par des étiquettes qui, elles, permettront l'exploitation automatique des informations ainsi stockées.

Ces étiquettes ne seront pas codées. En effet, les codes ainsi utilisés devraient avoir une finesse suffisante pour ne donner accès qu'à une quantité suffisamment réduite de renseignements pour pouvoir être exploitée à la main. Un code trop grossier serait inutilisable.

Par exemple : si l'on s'intéresse à un certain type de fractures du tibia et que les codes ne permettent de trier que sur l'indicatif "fracture" on risque de se retrouver avec une masse d'informations inexploitable.

La finesse exigée entraînera encore la création d'un code lourd à manipuler. Mais surtout, on retombe sur l'écueil suivant, déjà signalé, à savoir qu'un code n'est jamais universel. Or, les informations enregistrées pendant le séjour d'un malade dans un hôpital le sont dans le seul but immédiat de documentation. Il est donc important de garder à ces étiquettes leur potentiel d'informations afin de pouvoir faire dessus de la documentation automatique. Ainsi, on

créera à partir de l'observation d'un nombre suffisant d'informations, un système capable de "comprendre" les divers concepts susceptibles d'apparaître dans les informations ainsi que les liaisons logiques reliant ces concepts. Les utilisateurs pourront utiliser ce système grâce à un interface capable de traduire un français réduit et normalisé en une "phrase" assimilable par le système.

Par exemple : un compte-rendu radiologique se présentera de la manière suivante :

Etiquette : (en langage normalisé)

Radiographie de face puis de profil de l'épaule gauche,
Périarthrite de l'épaule gauche.

Commentaire : (en langage libre)

Les clichés de l'épaule pratiqués de face et de profil ne montrent aucune anomalie de la structure osseuse. Les surfaces articulaires et l'interligne ne présentent pas d'image anormale. Il existe une calcification arciforme située au-dessus de la grosse tubérosité humérale.

Ainsi, un enregistrement logique du fichier des dossiers médicaux va maintenant pouvoir contenir des informations de trois types distincts :

- 1° - Des informations de type classique
- 2° - Des informations écrites à l'aide du langage normalisé
- 3° - Des informations écrites sous un format libre. Nous allons examiner les caractéristiques d'un fichier de ce type.

II - FICHER HYBRIDE - PRINCIPES ET CONTRAINTES D'EXPLOITATION

Nous appellerons fichier hybride un fichier contenant des informations hybrides c'est-à-dire des informations qui peuvent être enregistrées sous l'une des trois formes décrites ci-dessus.

La forme de tels enregistrements ne permet plus d'exploiter d'une manière satisfaisante un tel fichier par des procédés classiques.

- 1° - La forme hybride des informations amènerait à écrire des procédures d'entrées-sorties très générales et par conséquent lourdes et lentes.
- 2° - Si l'utilisation d'enregistrements hybrides permet d'enregistrer des informations plus précises et en plus grand nombre, en revanche les enregistrements vont voir leur taille grandir dans des proportions importantes (un dossier médical peut facilement se composer de cinq à six mille caractères).
- 3° - Il n'est plus possible d'évaluer avec une précision suffisante la longueur d'un enregistrement.
- 4° - La mise à jour d'enregistrements tels les dossiers médicaux doit-être faite avec une fréquence de l'ordre de la journée. En raison des caractéristiques des enregistrements, cette mise à jour fréquente sera extrêmement coûteuse.
- 5° - Enfin, il faut noter que bien souvent, les divers types d'information (codée, écrite en langage artificiel, écrite en langage naturel) ne sont pas utilisés ensemble.

Exemple :

La recherche du dossier médical d'un malade sera faite en examinant la partie identification du dossier (information codée).

Une recherche de cancer d'estomac sera faite sur le diagnostic (information écrite en langage normalisé).

Enfin, on ne pourra faire aucune opération automatique sur le commentaire écrit en langage clair. On le demandera le plus souvent pour avoir un complément d'information si besoin est.

C'est pourquoi, il est apparu intéressant de substituer à la notion de fichier celle de fichier logique.

Un fichier logique est formé de plusieurs fichiers physiques : ce sont les fichiers composants.

La notion d'enregistrement logique garde tout son sens. C'est l'ensemble de divers enregistrements logiques des fichiers composants. Ces divers enregistrements étant reliés entre eux par un système approprié de pointeurs.

Remarque :

Il faut noter que la décomposition d'un fichier en fichiers composants ainsi que la définition du contenu des enregistrements logiques dépendent essentiellement de l'utilisation que l'on désire faire de ce fichier.

Cette dernière remarque a guidé la présentation de ce travail.

Le chapitre 1 expose comment on a créé le langage normalisé.

Le chapitre 2 décrit une méthode permettant de faire des recherches documentaires dans un ensemble de données décrites à l'aide d'un langage normalisé.

Le chapitre 3 propose un principe de configuration proche d'une organisation séquentielle indexée pour mettre à jour et interroger un fichier contenant des informations hybrides. [6]

CHAPITRE 1

LANGAGE NORMALISE EN RADIOLOGIE

1.I. - GRAMMAIRE REPRESENTATIVE DU LANGAGE : PRINCIPE DE CONSTRUCTION ET DESCRIPTION

- 1.I.1 - Principe de la méthode
- 1.I.2 - Description du modèle syntaxique
- 1.I.3 - Description de la grammaire

1.II. - EDITEUR

- 1.II.1 - Principe de l'analyse morphologique d'un mot
- 1.II.2 - Reconnaissance des bases incluses dans un mot
- 1.II.3 - Programmes annexes

1.III. - ANALYSEUR SYNTAXIQUE

- 1.III.1 - Syntaxe et sémantique

C H A P I T R E 1

LANGAGE NORMALISE EN RADIOLOGIE

1.I. - GRAMMAIRE REPRESENTATIVE D'UN LANGAGE NORMALISE

1.I.1. - Principe de la méthode

1.I.1.1. - Quelques rappels sur le traitement automatique des langues.

Avant d'exposer en détail le système choisi pour décrire certaines informations médicales, on va essayer de situer ce système de description par rapport à d'autres systèmes de normalisation .

On ne parlera pas des systèmes à grilles précodées puisque, par définition (cf. page 2) le système proposé veut essayer d'éliminer les insuffisances des grilles précodées pour le traitement de certaines informations.

On a dit que ce système essaierait de traduire les divers concepts apparaissant dans une information ainsi que les relations logiques qui les lient.

Les techniques de Kwic-index [7] maintenant très répandues, peuvent traduire les concepts apparaissant dans une information écrite en français par exemple, mais ne peuvent rendre compte des relations liant les divers concepts. Au contraire les techniques utilisées pour la traduction automatique [8] et qui sont basées sur le schéma de principe de la figure 1.I.1., essaient d'explicitier les concepts apparaissant dans une phrase française par exemple, et les relations qui lient ces concepts.

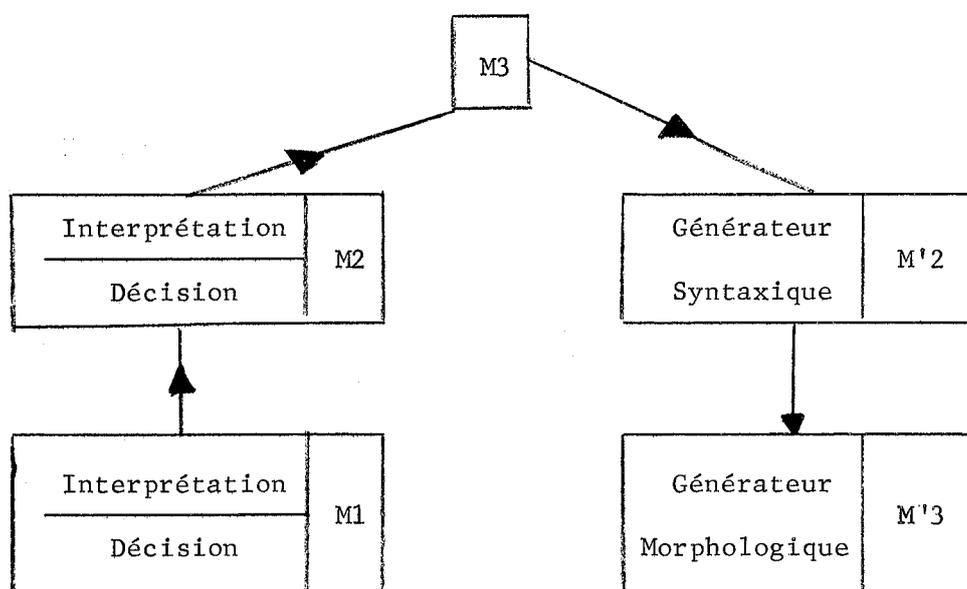


FIGURE 1.I.1.

Ce modèle fonctionne théoriquement de la manière suivante :

A partir d'une chaîne du langage source, on remonte par l'intermédiaire du modèle morphologique M1 puis du modèle syntaxique M2 au modèle sémantique idéal M3 qui est commun à toutes les langues. Ce modèle M3 permettrait donc d'exprimer la sémantique d'une phrase indépendamment de la manière dont on l'a formalisée. Les générateurs M'2 et M'1 permettent de générer les structures syntaxiques et morphologiques du langage cible souhaité.

Or on sait que le modèle M3 est hypothétique parce que dans le cas de langages naturels ce modèle est context-sensitive [9].

En documentation automatique le langage cible est le même que le langage objet. On peut se contenter de stocker la chaîne produite par le modèle M3. La chaîne cible s'obtient simplement par paraphrasage. Le but essentiel de la documentation automatique est de pouvoir faire certaines opérations sur les concepts mis en évidence par la chaîne issue du modèle M3.

C'est pourquoi beaucoup de systèmes de documentation automatique [10] utilisent le modèle de la figure 1.I.1., de la manière suivante :

- 1° - Les générateurs M'2 et M'1 n'existent pas car on stocke les chaînes produites par M3.
- 2° - On cherche à déduire des chaînes produites par M1 et M2 les concepts sémantiques contenus dans une chaîne du langage source.

Exemple :

La Rand Corporation stocke le résultat des analyses de chaînes documentaires bibliographiques sous formes de prédicats. L'exploitation se fait à l'aide des méthodes de calcul sur les prédicats [11].

La méthode présentée ci-dessous tient compte des facilités permises par les restrictions d'emploi du modèle en traduction automatique.

1.I.1.2. - Méthode de création du langage normalisé

On a créé les divers modèles de la manière suivante :

- 1° - L'étude d'environ 3000 demandes d'examen radiologique a permis de mettre en évidence les divers concepts qui apparaissent dans une demande d'examen radiologique. Cette étude a permis de dégager également les structures reliant ces concepts.

- 2° - On a cherché à mettre en évidence des structures hors contexte [12].
- 3° - De plus ces structures C.F. (qui sont théoriquement issues du modèle M3) respectaient à peu de chose près la syntaxe des phrases françaises du langage source. On a donc confondu le modèle M3 et le modèle M2. C'est ainsi que l'on a remplacé la syntaxe française (uniquement en ce qui concerne les demandes d'examen !) par une syntaxe basée sur des concepts.

Exemple :

Les notions de noms, d'adjectifs, d'articles, etc... n'existent plus. On construira une "phrase" à l'aide de la règle suivante par exemple :

$$\text{DER} \longrightarrow \text{TER} \quad \text{T}$$

où DER est l'axiome et correspond au concept :

"Demande d'examen radiologique"

TER est une catégorie syntaxique correspondant au concept :

"Technique d'examen"

T est une autre catégorie syntaxique correspondant au concept :

"Topographie examinée"

La syntaxe des langages de programmation est basée sur des principes analogues [13].

- 4° - Le modèle M1 permettra de traduire un mot français par l'unité syntaxique attachée à ce mot (la syntaxe française a comme unités syntaxiques par exemple : le nom, l'adjectif, le verbe, etc...). Ce modèle corrige automatiquement certaines tournures grammaticales (c'est-à-dire syntaxiques) interdites par la syntaxe mais dont l'emploi est agréable pour un utilisateur (cf. § 1.II.4 page 40).

Exemple :

La syntaxe du modèle syntaxique exige que la Topographie radiographiée soit placée après la technique d'examen utilisée comme dans

Radiographie du poumon

Cependant l'utilisateur peut utiliser les mots tels

BRONCHOGRAPHIE

On peut résumer ceci de la manière suivante :

- on a défini les concepts que l'on désirait stocker,
- on a créé un modèle syntaxique simple,
- on a ajusté un modèle morphologique permettant de faire la transition entre la phrase française et la chaîne assimilable par le modèle syntaxique.

1.1.2. - Description du modèle syntaxique

On a dégagé au niveau le plus général trois concepts fondamentaux dont on va donner une description succincte.

1.1.2.1. - Technique d'examen utilisé (TER)

Il s'agit dans le cas présent de la technique d'examen radiologique.

Définition :

Ce concept décrit la technique employée pour faire la radiographie. Ce concept ne comprend pas la description des actes éventuellement pratiqués sur le patient.

Description :

Ce concept peut être exprimé en français par un seul mot tel :

TOMOGRAPHIE

ou bien toute une suite de mots tels :

RADIOGRAPHIE OBLIQUE ANTERIEURE GAUCHE

Remarque :

Les exemples ci-dessus ainsi que ceux qui suivront, dans la suite de la description du modèle syntaxique seront donnés en français et non à l'aide d'unités syntaxiques.

1.I.2.2. - Topographie examinée (T)

Définition :

Il s'agit des expressions décrivant avec plus ou moins de précision la partie du corps qui est examinée.

Description :

Cette notion fait appel à deux sous-notions :

- la topographie anatomique (TA)
- la topographie descriptive (TD)

La topographie anatomique apparaît toujours explicitement.

Exemple :

'ESTOMAC' suffit à désigner une région précise du corps humain.

La topographie descriptive ne donne pas de précisions supplémentaires sur la localisation même de la région radiographiée mais des renseignements sur les constituants de cette région (os, muscle, veine, etc...) ou sur la forme de cette région (apophyse, canal, etc...)

1.I.2.3. - Technique opératoire (TOR)

Définition :

La technique opératoire est l'ensemble des actes pratiqués sur le patient afin de rendre possible l'examen ou simplement afin d'améliorer ou de modifier son déroulement.

Description :

En radiologie, ces techniques décrivent pour l'essentiel, :

- la position du patient

ex : DEBOUT, COUCHE

- les techniques d'opacification

ex : avec OPACIFICATION

Les descriptions que l'on vient de donner ici sont très succinctes et vont maintenant être reprises en détail. On se reportera utilement à l'annexe 1 de ce chapitre qui contient la description de la grammaire. Il faut comprendre l'écriture de cette grammaire de la manière suivante [14] :

- L'opérateur ::= signifie :

'PEUT ETRE COMPOSE PAR'

- Des groupes de lettres sont les codes désignant chaque concept.

- L'exemple donné par les trois premières lignes va permettre de montrer comment doivent être comprises les règles.:

Ces trois premières lignes sont :

DER ::= DER OPL3 DER

TER T

TER T TOR

EX.1.1.1.

Ceci indique que le concept DER peut être composé de trois manières différentes. Ces alternatives peuvent se combiner entre elles par exemple

RADIOGRAPHIE DE L'ESTOMAC SANS PREPARATION PLUS RADIOGRAPHIE DE LA RATE

TER T TOR OPL3 TER T

EX.1.1.2.

DER OPL3 DER

DER

1.I.3. - Description de la grammaire

La grammaire décrite à l'annexe 1 est composée de quatre groupes de règles, les trois derniers décrivant les trois concepts fondamentaux décrits ci-dessus.

Le groupe 1 indique la composition au niveau le plus haut d'une demande d'examen.

1.I.3.1. - Groupe de règles numéro 1

- Règle 1

Définition :

Une demande d'examen peut être composée d'une suite de demandes d'examen séparées par l'opérateur logique OPL3 (cf. EX.1.I.3)

- Règle 2

Définition :

L'axiome commence toujours par la description de la technique d'examen utilisée (TER) qui est toujours suivie de la description de la topographie examinée.

Description :

EX.1.I.7.

TOMOGRAPHIE DE L'EPAULE GAUCHE

TER

T

- Règle 3

Définition :

Une demande d'examen peut être composée (dans l'ordre) par :

- une technique d'examen radiologique (TER),
- la topographie radiographie (T),
- éventuellement La Technique opératoire utilisée.

Description :

EX.1.I.8.

ENCEPHALOGRAPHIE GAZEUSE

TOR

1.I.3.2. - Groupe de règles numéro 2

- Règle 4

Définition :

La description d'une technique d'examen radiologique peut se faire à l'aide d'une seule unité syntaxique :

EX.1.I.9

RADIOGRAPHIE

MTER

Description :

Il faut signaler ici une utilisation spéciale de cette règle : L'unité syntaxique décrivant la technique d'examen radiologique peut être imbriquée dans les mots du type ANGIOGRAPHIE. Dans ce cas la décomposition du mot extraira de ce mot deux bases (cf. § 1.II.1. page 26)

ANGI représentant la Topographie radiographiée

GRAPHIE représentant la technique d'examen radiographique

- Règle 5

Définition :

On peut affiner la description précédente à l'aide d'un groupe de qualificatifs radiologiques (GQR)

Description :

EX.1.I.10

RADIO DE-FACE

GQR

- Règles 6 et 7

Définition :

Un groupe de qualificatifs radiologiques peut être un groupement radiologique ou bien un nom propre de radiologue.

Description :

EX.1.I.11

OBLIQUE ANTERIEUR GAUCHE

GR

CHAUSSE-III (il s'agit d'une incidence spéciale d'examen du crâne).

NR

- Règle 8

Définition :

Un groupe de qualificatifs radiologiques peut être composé d'un ensemble de groupes de qualificatifs radiologiques séparés par l'opérateur logique ET

Description :

EX.1.I.12

RADIOGRAPHIE DE-FACE ET PROFIL

GQR OPL1 GQR

- Règles 9 et 10

Définition :

Un groupe radiologique peut être composé

- soit d'un simple qualificatif radiologique (cf. EX.1.I
- soit d'un qualificatif radiologique suivi d'un groupe radiologique (cf EX.1.I.14)

EX.1.I.13

RADIOGRAPHIE OBLIQUE

GR

EX.1.I.14

RADIOGRAPHIE OBLIQUE ANTERIEURE GAUCHE

GR

Description :

Ces deux règles permettent de générer des suites de qualificatif avec une structure d'états finis [12]

- Règles 11, 12, 13

Un qualificatif radiologique peut être soit :

- un mot d'incidence (MI)
OBLIQUE
FRONTAL
- soit un qualificatif (Q)
ANTERIEUR
- soit un qualificatif radiologique (QTER)
AXIAL

1.I.3.3. - Groupe de règles numéro 3

- Règle 14

Définition :

Une topographie examinée peut être une suite de topographies séparées par l'opérateur logique OPL2 associé au mot français PU.

Description :

Exemple :

EX.1.I.15

RADIOGRAPHIE DE FACE DE L'EPAULE GAUCHE

PUIS DU BRAS GAUCHE

OLP2

Notons que cette phrase indique que les deux examens de l'épaule et du bras sont faits de face.

- Règle 15

Définition :

Une topographie peut être exprimée à l'aide d'une topographie anatomique seule.

Exemple :

EX.1.I.16

RADIOGRAPHIE DU GROS INTESTIN

TA

- Règle 16

Définition :

Une topographie peut commencer par une topographie descriptive TD qui donne des renseignements annexes sur la partie du corps humain décrite par TA

Exemple :

EX.1.I.17

LA GRANDE COURBURE DE L'ESTOMAC

TD

Description :

On remarque que les renseignements fournis par la topographie descriptive bien que n'étant pas de nature anatomique à proprement parler précisent la topographie examinée.

- Règles 17 et 18

Définition :

La topographie de centrage du rayon d'incidence peut terminer la description d'une topographie.

Exemple :

EX.1.I.18

RADIOGRAPHIE DU PIED CENTREE SUR LE GROS ORTEIL

TC

Description :

Il s'agit de pouvoir préciser parfois la partie du corps sur laquelle est centrée le rayon. Un tel concept aurait du être placé dans le concept des groupes de qualificatifs radiologiques (GQR). Le simple soucis de lever plus facilement une ambiguïté a conduit à inclure ce dernier concept dans celui de topographie (T).

- Règles 19 à 26

Cet ensemble de règles montre de quelle manière on peut construire une topographie descriptive.

- Règle 19

Un simple mot peut représenter ce concept :

exemples :

EX.1.I.19

ARC, ARCADE

CANAL, etc...

- Règle 20

Si l'on désire affiner ce concept on peut le faire en plaçant à droite un groupe de qualificatifs de topographie descriptive (GQD1).

Exemple :

EX.1.I.20

L'AILE DROITE DU NEZ

MTD GQD1

- Règles 21 à 26

Ces règles permettent une normalisation de la construction de GQD1. La règle 22 indique qu'un "GQD1" peut commencer par un qualificatif gauche (QG) c'est-à-dire par un qualificatif employé

d'habitude en français avant le nom qu'il qualifie :
exemple :

EX.1.I.21

LA GRANDE COURBURE

QG MTD

Ce qualificatif est placé par le modèle d'édition à droite du mot MTD qui le suit forcément. Cet artifice a été nécessaire à cause de la présence d'une règle analogue pour former une topographie anatomique TA. On se trouvait lors de la reconnaissance d'un qualificatif gauche devant une ambiguïté.

Ainsi l'analyseur syntaxique trouvera toujours des suites telles

LA COURBURE GRANDE

ou bien L'ARC PETIT.

- Règles 27 à 34

Ce groupe de règles est analogue au précédent. Un mot de topographie anatomique MTA suffit à décrire à lui seul une topographie anatomique :

EX.1.I.22

RADIOGRAPHIE DE L'ESTOMAC

MTA

- Règle 35

Définition :

Une topographie de centrage est toujours composée d'un opérateur de centrage (CS) suivi de T2.

Description :

EX.1.I.23

RADIOGRAPHIE DU PIED CENTRE SUR LE GROS ORTEIL

CS

T2

- Règles 36 et 37

Définition :

T2 est composé soit d'une topographie anatomique, soit d'une topographie descriptive suivie d'une topographie anatomique (cf. EX.1.I.23).

Description :

Le concept T2 représente un sous-ensemble des topographies (cf. règles n^{os} 15 et 16). Ceci interdit qu'une topographie de centrage soit composée également d'une topographie de centrage

1.1.3.4. - Groupe de règles numéro 4

Comme le montre la règle 3 ce groupe peut ne pas être utilisé pour définir une demande d'examen radiologique.

- Règle 38

Définition :

La technique opératoire radiologique peut être composée uniquement d'un mot indiquant la position du patient.

Exemple :

EX.1.I.24

RADIOGRAPHIE DU BASSIN ASSIS
MPR

- Règles 39 à 46

Ces règles permettent uniquement de décrire la technique d'opacification employée.

- Règle 40

Définition :

Une technique opératoire peut être composée d'un opérateur de moyen (OPM) suivi d'un mot de technique opératoire (MTOR)

EX.1.I.25

RADIOGRAPHIE DE L'ABDOMEN SANS PREPARATION
OPM MTOR

Description :

La présence d'un opérateur de moyen permet de dire si l'on a ou non employé la technique opératoire décrite (cf. EX.1.I.24)

- Règle 41

Définition :

Une technique opératoire peut également être composée d'un opérateur de moyen, suivi d'un mot de technique opératoire, suivi d'un groupe de qualificatifs de technique opératoire (GQTOR)

EX.1.I.25

ANGIOGRAPHIE AVEC OPACIFICATION INTRA-ARTERIELLE
OPM MTOR GQTOR

- Règles 43 et 46

Définition :

Une technique opératoire peut être composée des concepts indiqués par les règles 39 à 42, ces concepts pouvant être suivis du concept T2.

EX.1.1.27

RADIOGRAPHIE DE L'ESTOMAC AVEC OPACIFICATION PAR VOIE HAU

T2

Description :

T2 permet de préciser la topographie sur laquelle est fait l'acte d'opacification.

1.1.3.5. - Remarques générales sur la grammaire.

Cette grammaire a été prévue pour reconnaître des chaînes et non pour en générer, c'est pourquoi on peut trouver dedans, des règles permettant de générer des chaînes dont le sens est très discutable.

A ce propos, il faut signaler que le modèle syntaxique que l'on vient de décrire accepterait des demandes d'examen syntaxiquement correctes mais n'ayant aucun sens. Rappelons qu'il n'a aucun pouvoir de décision en ce qui concerne les soins à donner au malade. Son but immédiat est d'assurer une simple gestion des demandes d'examen radiologique.

A partir du moment où la signification d'une demande d'examen peut être utilisée pour générer automatiquement un certain nombre d'opérations (telles par exemple la détermination automatique des films à utiliser, le calcul du "R" de l'acte médical etc...) il est nécessaire de ne plus permettre la reconnaissance de phrases n'ayant pas de sens.

Si l'on désirait réaliser un programme détectant les demandes d'examen qui n'ont pas de sens, il faudrait inclure ce programme au niveau de l'analyseur syntaxique. De tels programmes existent dans presque tous les systèmes de saisie d'information médicale [15].

Si un tel programme n'a pas paru nécessaire dans l'immédiat, c'est parce qu'il est apparu que les mots employés différaient, dans leur ensemble, suffisamment entre eux pour ne pas autoriser facilement des confusions. Il faut remarquer qu'une confusion entre deux mots représentant des unités syntaxiques différentes à de granche chance d'entraîner une mauvaise syntaxe de la demande d'examen.

Exemple :

Si un utilisateur intervertit l'utilisation des opérateurs logiques PUIS et PLUS, l'analyseur refusera de reconnaître la demande d'examen.

Actuellement, une erreur dans la syntaxe d'une demande d'examen entraîne systématiquement le refus de cette demande. Cependant lorsque les entrées de demandes d'examen seront faites à partir de console, il sera possible de modifier assez facilement les décisions à prendre en cas d'erreur.

L'analyseur pourra signaler à l'auteur ses fautes et dans la plupart des cas acceptera les corrections faites par l'auteur.

D'autres remarques peuvent être faites sur la nature même de cette grammaire :

- les dérivations infinies sont toutes faites à l'aide de règles de type états finis [12]

- les unités syntaxiques peuvent être divisées en deux groupes :

les mots : MTA, MTD, MTER, MTOR, MPR

un mot suffit souvent à décrire un des trois concepts fondamentaux.

les qualificatifs : sont forcément associés à un mot et ne peuvent en aucun cas décrire seuls un des trois concepts fondamentaux.

- Enfin, le plus souvent l'ordre des unités syntaxiques apparaissant dans les chaînes analysables par le modèle M2 est le même que celui d'apparition des mots dans la phrase française. Les exceptions (telles l'emploi de qualificatifs gauches) sont redressées par l'éditeur.

On peut décrire succinctement le mécanisme de l'éditeur par le schéma ci-dessous :

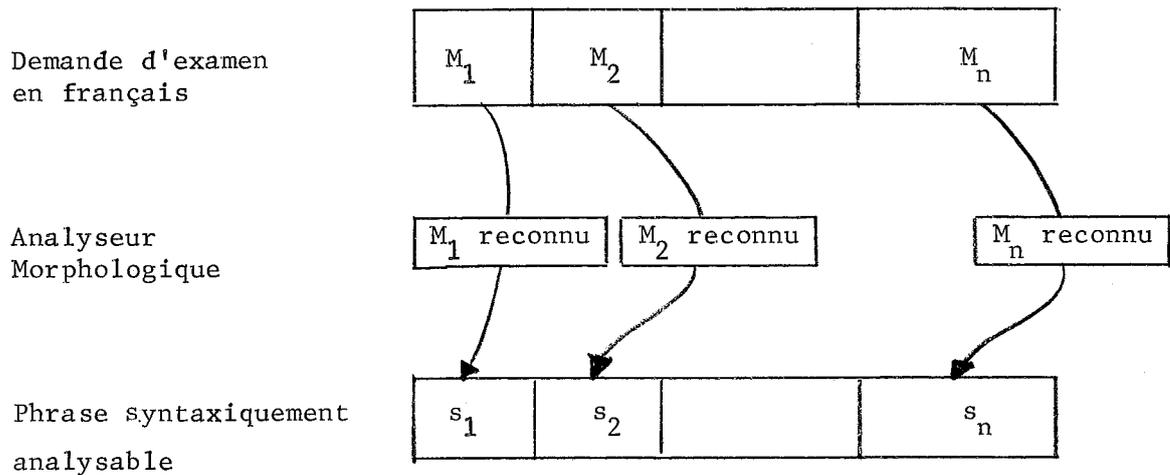


FIGURE 1.II.1

1.II.1. - Principe d'analyse morphologique d'un mot

Le dictionnaire ne contenant que la partie significative d'un mot (sa base) il est nécessaire d'extraire d'un mot la ou les base(s) qui le composent pour trouver les divers renseignements syntaxiques et morphologiques attachés à chaque base.

Exemple :

Le dictionnaire ne contient que la base

SCAPUL

qui entrera dans la composition des mots tels

SCAPULAIRE , SCAPULAIRES

Les terminaisons ou désinences 'AIRE' et 'AIRES' sont considérées comme non significatives.

EX.1.II.2

1.II.1.1. - Principe général de la décomposition des mots

Les règles de construction d'un mot sont présentées à l'aide de la grammaire ci-dessous écrite sous la forme normale de Backus [16] .

$$\begin{aligned}
\text{mot} & ::= \langle \text{groupe de base} \rangle \langle \text{désinence} \rangle \\
\langle \text{groupe de bases} \rangle & ::= \langle \text{groupe de bases} \rangle \langle \text{base} \rangle \mid \langle \text{base} \rangle \\
\text{désinence} & ::= \langle \text{terminaison} \rangle \mid \langle \text{vide} \rangle
\end{aligned}$$

les unités syntaxiques sont soulignées :

une base est en général la partie significative d'un mot :

EX.1.II.3 DUODEN (duodenal)

une terminaison est un groupe de lettres qui, concaténée à une base ou à un groupe de bases, donne un mot.

EX.1.II.4 Terminaison : AL
Base : DUODEN

les terminaisons sont un sous-ensemble des suffixes français.

vide : veut dire la chaîne vide

EX.1.II.5 Base : DUODENUM
désinence : vide

1.II.1.2. - L'automate de reconnaissance des mots

La description précédente n'étant pas satisfaisante a été affinée de la façon suivante :

A - On a scindé les Bases en trois types distincts

1° - Les bases non composables de type 1

Ces bases ne peuvent être suivies que d'une désinence

DUODENUM → désinence : vide

EX.1.II.6 GRAND → désinence : $\left\{ \begin{array}{l} \text{vide} \\ - e \\ - es \\ - s \end{array} \right.$

2° - Les bases forcément composables de type 2.

Elles sont forcément suivies d'une autre base de n'importe quel type

EX.1.II.7

CARDIO employé avec CARDIO-VASCULAIRE

3° - Les bases composables de type 0.

Ces bases peuvent être suivies soit d'une désinence soit d'une base de type quelconque.

EX.1.II.8

DUODEN employé avec DUODEN/AL

et DUODEN/OGRAPHIE

B - On remarque que souvent les suites de bases sont reliées entre elles par un groupe de lettres telles :

la lettre 0 : DUODEN O GRAPHIE

les symboles 0-

ou encore -

ou la chaîne vide .

On obtient l'automate de reconnaissance suivante [12] :

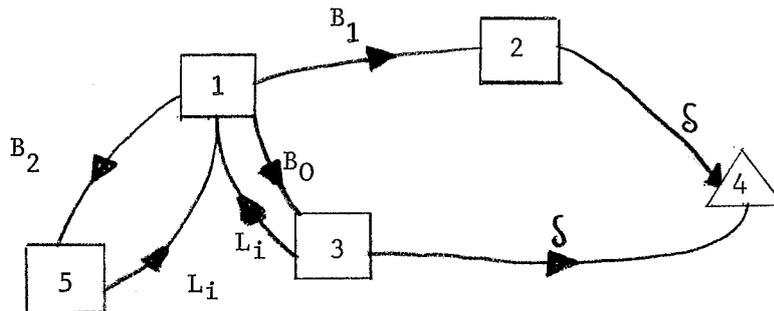


FIGURE 1.II.2

B_1 base type 1

B_2 base type 2

B_0 base type 0

L_i liaison

S désinence

L'état 1 est l'état initial

L'état 4 est l'état final.

1.II.1.3. - Le dictionnaire des bases

Ce dictionnaire se compose de deux parties indépendantes : l'arbre des bases et la table de traduction.

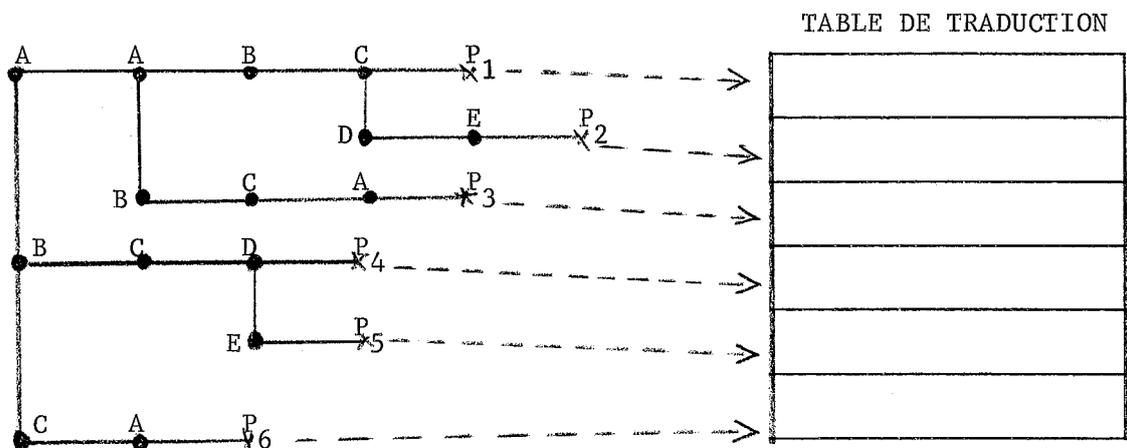
1.II.1.3.1. - Description de l'arbre des bases et de la table de traduction

L'arbre des bases est l'ensemble des bases retenues et organisées en arbre de manière classique [17]. Chaque feuille de l'arbre est un pointeur dans la table de traduction. Ce pointeur permet d'aller chercher dans la table de traduction les renseignements associés à la base correspondant à chaque pointeur.

Exemple :

Soient les bases : AABC, AABDE, ABCA, BCD, BCE, CA

le schéma de principe est le suivant :



Les branches verticales séparant deux lettres indiquent que l'on peut utiliser l'une ou l'autre de ces lettres. Les branches horizontales séparant deux lettres indiquent que ces deux lettres se suivent forcément.

FIGURE 1.II.3

La table de traduction apparaît comme un tableau. Chaque ligne de cette table contient les renseignements associés à la base qui pointe sur cette ligne ; les renseignements contenus sont les suivants :

- 1) Unité syntaxique de la base
- 2) Le type de la base
- 3) L'adresse d'une phrase synonyme de cette base (éventuellement)
- 4) L'adresse d'une base ayant un rapport de nature sémantique avec cette base.

Nous allons examiner rapidement ces deux derniers renseignements.

Les synonymes :

Tout d'abord, lorsque plusieurs bases sont synonymes, on choisit arbitrairement un synonyme de référence et on remplace le pointeur de chaque base par le pointeur de la base de référence choisie.

Cependant parfois une base contient implicitement des informations qu'il est nécessaire d'explicitier. Le cas le plus courant est le cas des bases qui sont des noms propres de médecins.

Exemple :

En radiologie un certain nombre de noms propres contiennent implicitement la description d'incidences spéciales de radiologie.

On crée donc un fichier (le FICHER EXPLICATIF) contenant pour chaque base ayant une phrase synonyme :

le nom de la base suivie de la phrase synonyme

Dans ce cas, on signale dans la table de traduction du dictionnaire des bases, à la ligne correspondant à cette base, le numéro séquentiel d'apparition de la traduction de cette base dans le fichier explicatif.

Exemple d'enregistrement du fichier explicatif :

EX.1.II.9

CHEVILLE = ARTICULATION TIBIO-TARSIENNE

Les Inclusions sémantiques :

Il s'agit en utilisant le système décrit par la figure 1.II.4 d'indiquer qu'il existe entre deux bases une inclusion de nature sémantique :

Exemple :

Dans le dictionnaire on a systématiquement indiqué pour chaque base se rapportant à un organe l'appareil ou la région qui le contient :

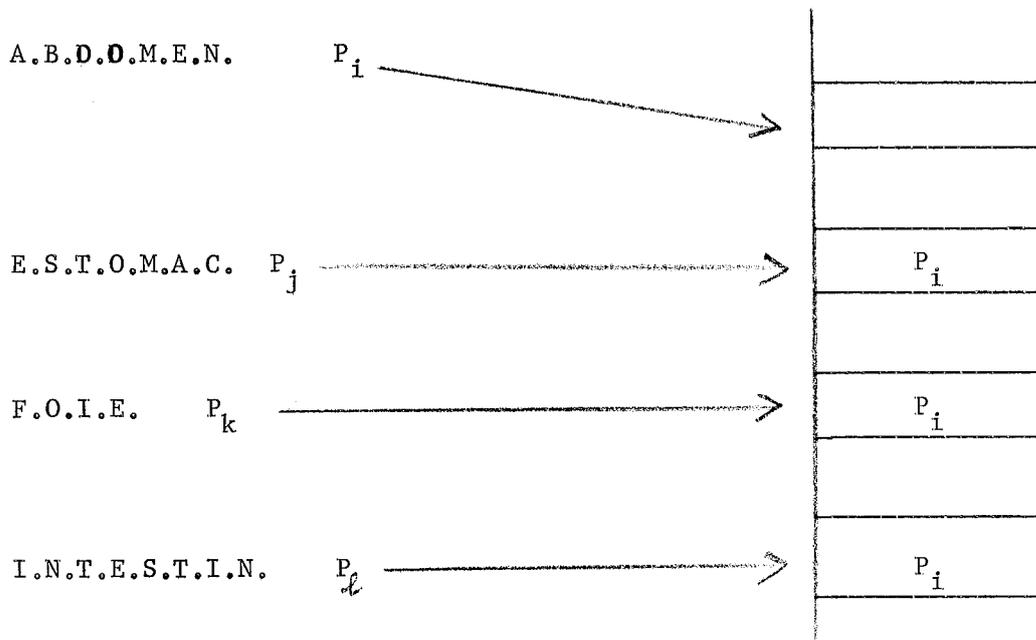


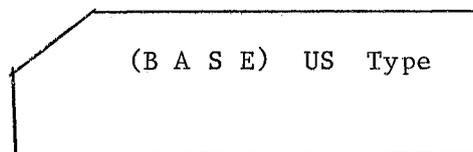
FIGURE 1.II.4

Ce système est évidemment extrêmement pauvre. Il serait intéressant, du moins en ce qui concerne les bases de topographies anatomiques, de créer un système de relations cohérent tel les réseaux utilisés pour améliorer les techniques de documentation automatique classique [18].

Cependant, il semblerait plus intéressant de subdiviser le concept de topographie anatomique en un certain nombre de sous-concepts.

1.II.1.3.2. - Construction et mise à jour du dictionnaire

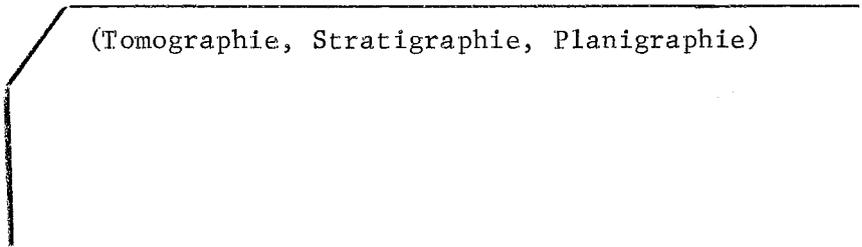
La construction et la mise à jour du dictionnaire sont faites avec les mêmes procédures élémentaires. Un premier programme travaille sur un fichier dont les enregistrements sont constitués d'une base suivie de la valeur de son unité syntaxique et de son type



A chaque lecture d'enregistrement la base est rajoutée à l'arbre en même temps que son pointeur est créé automatiquement.

L'unité syntaxique et le type sont stockés dans la ligne de la table référencée par le pointeur que l'on vient de créer.

Ce fichier étant épuisé, on trouve un autre fichier contenant des listes de bases synonymes.



(Tomographie, Stratigraphie, Planigraphie)

Le synonyme de référence est toujours en tête. Ainsi le calcul des références se fait par simples lectures dans l'arbre.

Le fichier des inclusions sémantiques est tout à fait analogue et traité par des programmes très semblables.

1.II.2. - Reconnaissance des bases incluses dans un mot

La reconnaissance se fait au moyen de deux programmes qui travaillent l'un sur l'arbre des bases, l'autre sur la table de traduction.

Ces deux programmes travaillent d'une manière conversationnelle par l'intermédiaire du programme RECMOT. Le résultat du premier est communiqué au second qui rend lui aussi un résultat au premier, jusqu'à ce que toutes les bases composant un mot et éventuellement la désinence terminant ce mot aient été identifiées.

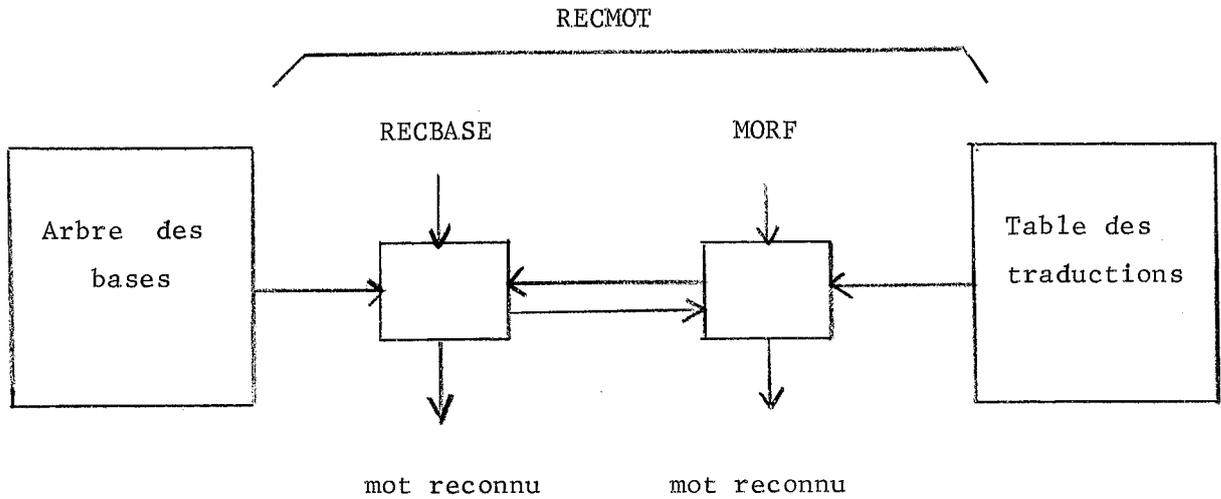


FIGURE 1.II.6

Ce schéma montre en plus qu'un mot peut avoir été reconnu en définitive par l'un ou l'autre des programmes. Nous allons voir plus précisément quand les divers cas se présentent.

1.II.2.1. - Description de la procédure RECBASE

Cette procédure fournit dans une première pile (pile de bases) l'ensemble des bases du dictionnaire contenues dans un mot et dans une seconde pile (la pile des fin de mots) la fin du mot associée à chacune des bases.

Exemple : Soit le mot AAABCA

Supposons un dictionnaire qui contienne les bases :

- AA P_i
- AAAB P_j
- AAABC P_k

La procédure donnera naissance aux deux piles suivantes :

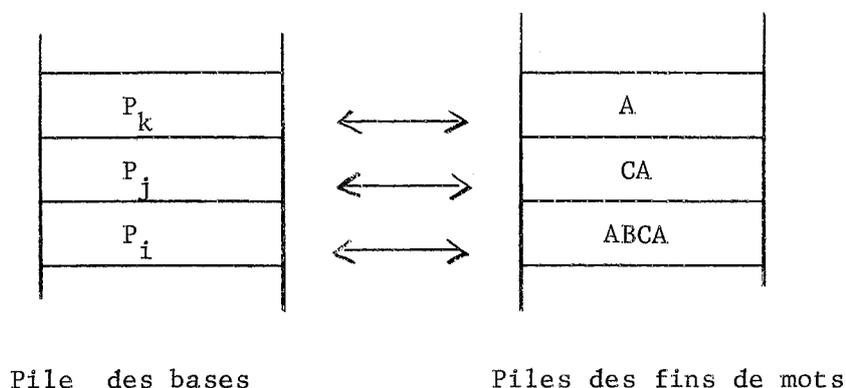


FIGURE 1.II.7

Remarquons que l'organisation de l'arbre est telle que l'on a toujours au sommet la base la plus longue contenue dans le mot.

1.II.2.2. - Description de la procédure MORF

Cette procédure travaille sur les deux piles :

elle cherche le couple (base, fin de mot) compatible avec le type de la base qu'elle lit dans la table de traduction.

Deux cas peuvent se produire :

- le couple est correct

- 1) la fin du mot est désinence ; RECMOT arrêtera l'analyse
- 2) la fin du mot n'est pas une désinence mais la base est composable et MORF donnera la fin de mot comme nouveau mot à aller reconnaître dans l'arbre.

- le couple est incorrect dans les autres cas ; on élimine ce couple et on passe au suivant.

Il faut noter que cet algorithme suppose qu'un mot n'a qu'une seule décomposition possible. Dans le cas contraire, il faudrait systématiquement épuiser toutes les piles.

1.II.2.3. - Description du programme d'analyse des mots : RECMOT

C'est le programme qui analyse les informations fournies soit par RECRASE soit par MORF et qui décide de la poursuite ou non de l'analyse.

La poursuite s'arrête si la fin du mot est une désinence (qui peut être vide) ou si les piles sont épuisées et dans ce cas il y a une erreur.

Dans le cas général le programme construit lui aussi deux piles qui contiennent les piles trouvées par RECRASE. En effet, dans le cas où la procédure MORF indique que la fin de mot associée à une base est certainement à son tour une base, la procédure RECRASE est réactivée et les nouvelles piles trouvées sont empilées car le processus peut se renouveler au niveau des piles que l'on vient de trouver.

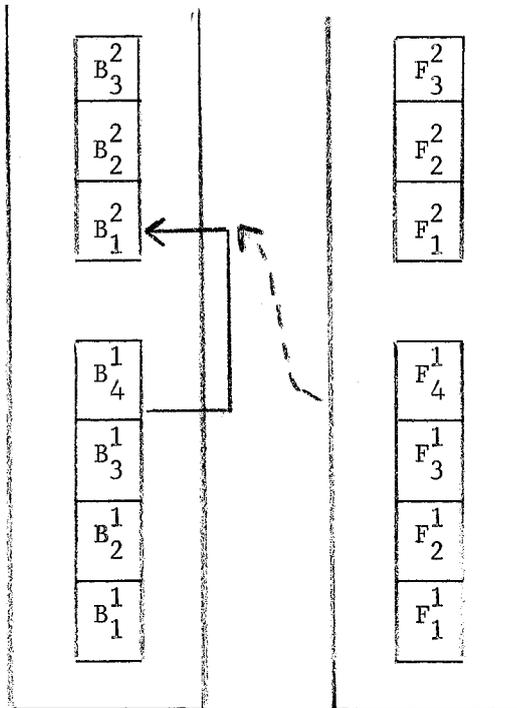


FIGURE 1.II.8

La pile ci-dessus montre qu'un mot M peut éventuellement commencer par l'une des quatre bases B_1^1 , B_2^1 , B_3^1 , B_4^1

Si le mot M commence par B_4^1 alors F_4^1 contient à son tour certainement une base qui peut être B_1^2 , B_2^2 , B_3^2 .

Ainsi une pile de bases correspond à l'ensemble des bases pouvant éventuellement suivre la base qui est au sommet de la pile de bases inférieure.

Supposons maintenant que l'examen de tous les couples des piles supérieures soit négatif. On en déduit alors que le couple du sommet des deux piles inférieures est incorrect. On supprime donc et les deux piles supérieures et le couple incorrect et on peut recommencer l'analyse du couple suivant s'il y en a un. Dans l'exemple précédent on aurait la nouvelle configuration de départ ci-dessous :

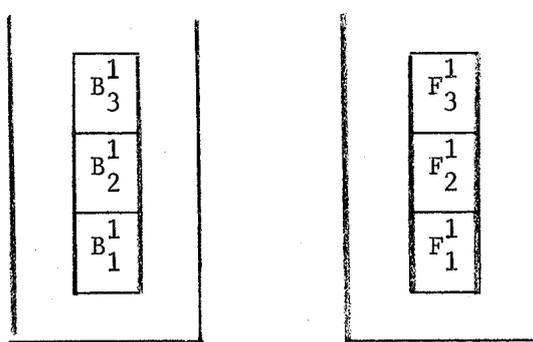


FIGURE 1.II.9

L'examen du couple (B_3^1, F_3^1) pourra conduire à son tour la création de pile d'ordre supérieur. Une fois l'analyse terminée, le programme de reconnaissance donne le contrôle au programme de construction de la ligne à éditer.

L'exemple suivant va nous permettre d'illustrer la méthode que l'on vient de décrire. Les bases qui sont supposées figurer dans l'arbre des bases ne sont pas toutes réelles ; certaines ont été introduites pour les besoins de l'exemple.

Supposons que le dictionnaire des bases contiennent les bases suivantes (les numéros représentent les pointeurs associés à chaque base).

ANG 1
 ANGI 2
 ANGIOG 3
 RAP 4
 GRAPHIE 5

Le mot à décomposer est le mot ANGIOGRAPHIE.

L'état des deux piles va évoluer de la manière suivante :

la pile de gauche est PLISTBAS, celle de droite PWORD

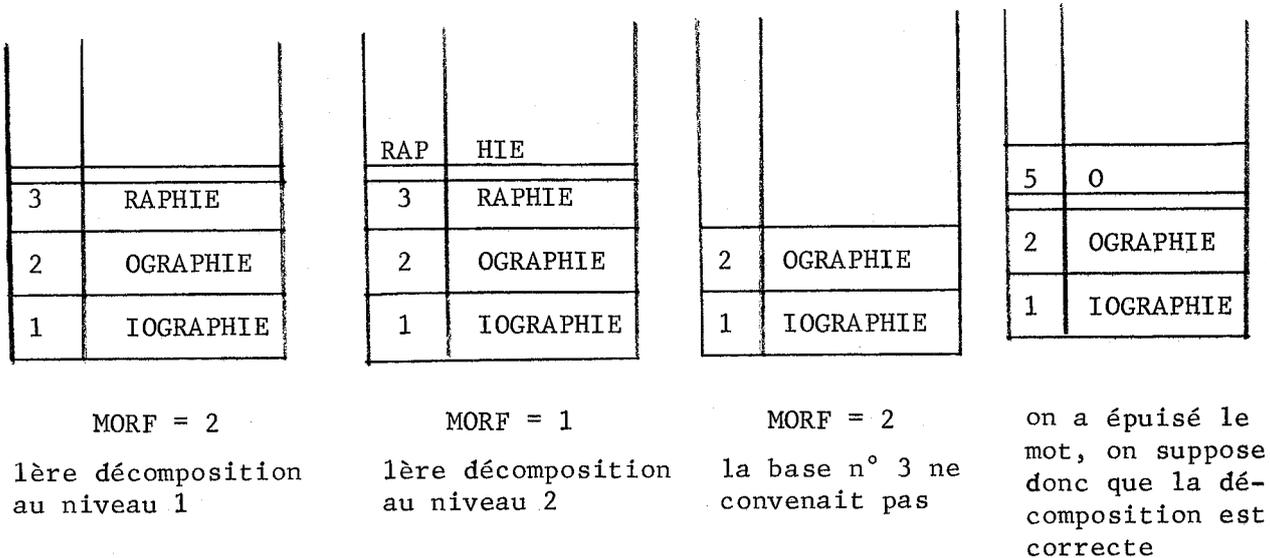


FIGURE 1.II.10

Notons que le schéma ci-dessus utilise deux traits horizontaux pour séparer de différents niveaux.

La valeur donnée par la procédure MORF détermine en s'aidant de la valeur du "type" de la base, si la fin de mot associée à la base (si elle existe) peut éventuellement contenir une autre base. L'exemple ci-dessus s'explique de la manière suivante :

- 1) On a d'abord trouvé dans le dictionnaire trois bases pouvant éventuellement commencer le mot ANGIOGRAPHIE.
- 2) La valeur 2 retournée par MORF indique que si la base que l'on vient de trouver, est correcte. La fin de mot 'RAPHIE' contient certainement une autre base.

- 3) La deuxième pile indique que l'on a effectivement trouvée une base incluse dans 'RAPHIE'.
- 4) La valeur 1 donnée en retour par la procédure MORF indique que la fin de mot 'HIE' associée à la base trouvée RAP est erronée (par exemple RAP peut être une base non composable et 'HIE' ne fait pas partie des désinences).
- 5) Comme on n'a trouvé au niveau 2, qu'une seule possibilité pour le mot RAPHIE, ceci implique que le choix de la base 3 au niveau 1 est incorrect.
- 6) Le niveau 1 offre encore des possibilités. On repart avec la base 2 et la fin de mot OGRAPHIE.
- 7) La valeur 2 retournée par la valeur de MORF autorise à chercher une base dans la fin de mot 'GRAPHIE' (il faut noter, que la procédure MORF a enlevé systématiquement le 'O' commençant la fin de mot OGRAPHIE).
- 8) La base 'GRAPHIE' est trouvée dans le dictionnaire, la fin de mot est vide (représentée par 0), MORF n'est pas activée car, comme nous l'avons signalé, on suppose qu'un mot n'admet qu'une seule décomposition.

1.II.2.4. - Description de programme de construction de la ligne analysable : EDITI

Lorsque l'analyse d'un mot est terminée, il est facile d'extraire de la pile contenant les piles de bases, les bases composant le mot :

On prend les sommets des piles de bases. On a donc accès à ces bases dans l'ordre inverse de leur ordre dans le mot.

Exemple :

Si un mot est composé des bases $B^1 B^2 B^3$

On aura une configuration finale du type suivant :

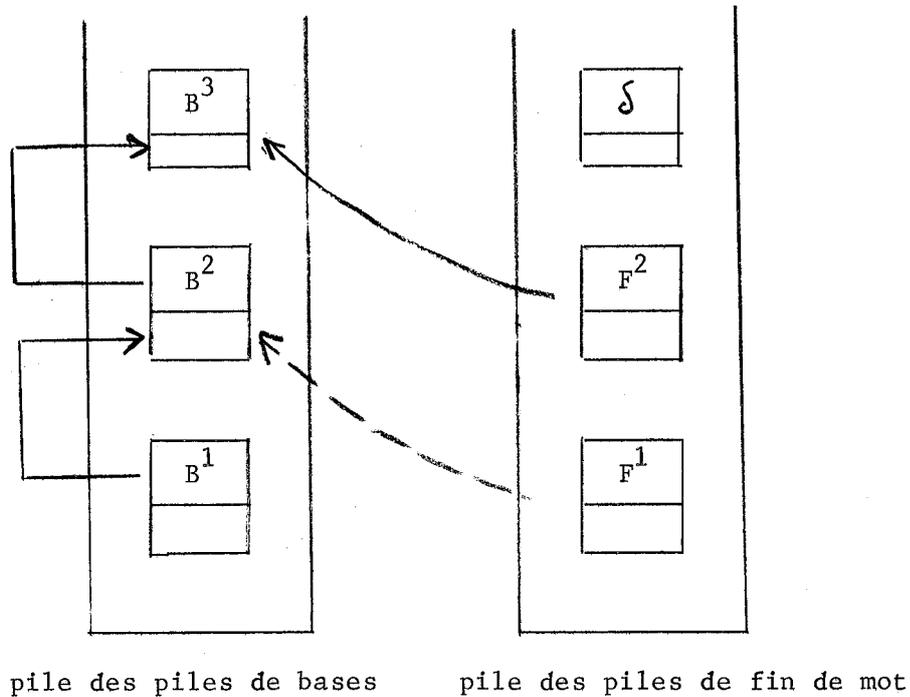


FIGURE 1.II.11

Le programme EDITION rassemblera ces bases et également les unités syntaxiques associées à chacune d'elles. Au passage, il remplacera le cas échéant les bases par leur synonyme de référence.

Si les bases ont toutes la même unité syntaxique US_i , il crée le groupe suivant :

$$C_4 = (US_i, B^1, B^2 \dots B^p)$$

Si certaines bases ont des unités syntaxiques différentes, il créera autant de groupes que d'unités syntaxiques différentes.

Enfin, les groupes seront rajoutés les uns à la suite des autres dans la phrase à éditer ou (phrase analysable).

Lorsque tous les mots d'une phrase auront été reconnus on aura finalement une ligne du type :

C_1	C_2	C_3	\dots	C_N
-------	-------	-------	---------	-------

où les C_i ont la configuration suivante :

$$(US, UL_1, UL_2, \dots, UL_n)$$

Les UL_i étant les unités lexicales des bases trouvées dans un mot c'est-à-dire les pointeurs associés à chaque base.

NOTES :

1) Dans le cas où un mot est une base à lui seul, le programme RECMOT n'active même pas MORF.

2) En pratique, la base la plus longue qui est au sommet d'une pile de bases est souvent la bonne. En plus seuls les mots de Topographie et technique d'examen sont composés.

3) Si aucune base du dictionnaire n'est contenue dans un mot, les piles de bases et de fin de mot ne sont pas créées et tout se passe comme si le couple inférieur était incorrect.

1.II.3. - Programmes annexes

L'éditeur se présente donc comme un programme de transition entre l'utilisateur et l'analyseur syntaxique.

Afin de permettre à l'utilisateur une grande facilité pour l'écriture des demandes d'examen, nous avons du créer deux programmes annexes encadrant l'éditeur :

1° - Le lecteur de phrases :

Ce programme transforme une suite de mots séparés par des blancs en une structure de liste acceptable par l'éditeur. Ce programme supprime au passage les mots ne servant pas pour l'analyse de la phrase : le, la, etc..

2° - L'emploi en français de mots composés tels UROGRAPHIE donne naissance à des résultats inacceptable par l'analyseur syntaxique. Le rôle de ce deuxième programme consiste à remettre le mot à sa place :

Exemple : UROGRAPHIE donne naissance à la base Ur (=rein) et GRAPHIE (=radiographie).

Dans ce cas on inversera simplement l'ordre des mots.

Notons que ce programme peut devenir assez complexe à cause de cas tels le suivant :

ANGIOGRAPHIE GENERALE GAUCHE VEINEUSE

Il faudra alors trouver dans la suite des adjectifs la césure où viendra se placer la base "ANGIO".

Ces deux programmes ne seront pas décrits en détail car le premier présente peut d'intérêt et le second ne travaille encore que d'une manière très simpliste.

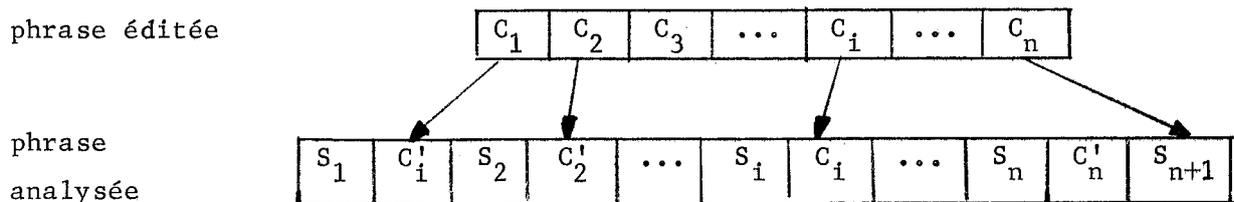
Notons enfin, que le programme d'édition appelle ce dernier programme uniquement dans certains cas et que la structure de la ligne ainsi modifiée est la même que celle décrite en page 39 .

1.III. - L'ANALYSEUR SYNTAXIQUE

Principe général de fonctionnement

L'analyseur utilisé est un analyseur descendant [19] .

Il transforme une phrase éditée en une phrase analysée suivant le schéma ci-dessous :



Les S_i représentent la suite des numéros des règles utilisées pour reconnaître l'unité syntaxique associée à chaque C_i.

Les C'_i représentent la suite des unités lexicales associées à chaque C_i (cf. page 39).

L'analyseur n'utilise que la suite des unités syntaxiques associées à la suite des C_i.

N.B. -

La suite S_{n+1} peut éventuellement être vide.

Exemple :

Phrase française	RADIOGRAPHIE DE LA JAMBE DROITE
EX.1.III.1 Phrase éditée	((10 , 3) (20 , 2) (3 , 1))
Phrase analysée	2 4 (3) 15 28 (2) 29 31 33 (1)

L'exemple réel ci-dessus suppose que :

- les bases radiographie, jambe et droit ont respectivement pour unité lexicale les valeurs 3, 2 et 1 et pour valeur de l'unité syntaxique 10, 20, 3.
- les valeurs 10, 20, 3 correspondent respectivement à MTER, MTA et Q
- les nombres qui ne sont pas entre parenthèses représentent les numéros des règles de la grammaire telle qu'elle est en annexe.

Les nombres entre parenthèses représentent encore les valeurs des unités lexicales des bases de l'exemple. (ces nombres ne sont pas les nombres réels).

1.III.1. - Syntaxe et sémantique

La sortie d'une phrase analysée indique que la structure syntaxique de la phrase a été reconnue.

Or, on a dit que les règles de grammaire traduisaient également la sémantique d'une demande d'examen.

Nous allons préciser ceci et examiner dans quelles limites on peut parler de sémantique.

Comme le problème général de reconnaissance sémantique d'une phrase n'est pas résolu on a recours à l'artifice suivant :

On a partitionné le vocabulaire en classes d'équivalence définies par la relation d'équivalence "Appartient au même concept que". Les classes d'équivalences représentent l'ensemble des concepts insécables apparaissant dans une demande d'examen radiologique. C'est l'ensemble de ces concepts qui constitue le vocabulaire terminal de la grammaire ; nous les appellerons également concepts de base.

De plus, chaque classe de règles de la grammaire correspond à un concept décrit par les parties droites de cette classe de règles.

On peut donc parler de sémantique uniquement dans la limite des classes d'équivalences définies par le vocabulaire terminal de la grammaire.

Nous dirons que le domaine de compréhension du système s'arrête au niveau des unités syntaxiques de la grammaire.

Exemple :

Lorsqu'on écrit :

EX.1.III.2

RADIOGRAPHIE DU BRAS

Le système ne "comprend" pas cette phrase comme nous mais il comprend la structure suivante :

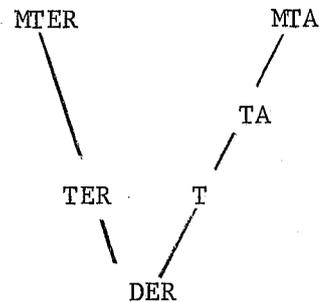


FIGURE 1.III.1

Le système reconnaît l'apparition des différents concepts et la structure dans laquelle ils apparaissent mais son domaine de compréhension s'arrête aux limites syntaxiques.

Remarquons bien qu'une phrase n'ayant pas de sens en français peut en avoir une pour le système.

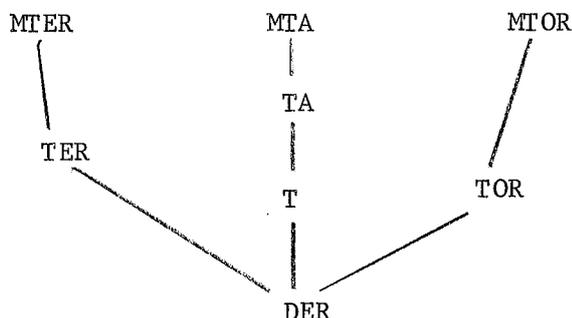
Exemple :

RADIOGRAPHIE DU FEMUR AVEC OPACIFICATION(!)

Cet exemple n'as pas de sens.

Cependant, il est syntaxiquement correct et par conséquent l'analyseur ne rejettera pas cette demande d'examen.

On peut dire que l'analyseur a compris une partie de cette demande d'examen. Il a compris qu'il s'agissait du concept DER décrit à l'aide des concepts de bases MTER, MTA et MTOR, et que ces concepts sont reliés entre eux par la structure ci-dessous.



C'est pourquoi, pour pouvoir garder les images associées à chaque mot français (et par conséquent à une phrase française), on garde dans le résultat de l'analyse syntaxique le numéro de l'unité lexicale représentant chaque classe d'équivalence.

Ainsi, les problèmes de recherche d'information dans un fichier contenant des demandes d'examen analysées seront traités en deux temps :

- 1) Les structures de la question et de l'enregistrement seront comparées suivant une méthode que l'on va décrire au chapitre II.
- 2) Ensuite il sera nécessaire de remonter au niveau des mots français :

exemple :

RADIOGRAPHIE DU BRAS et

RADIOGRAPHIE DU POUMON

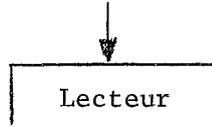
sont deux demandes d'examen qui ont même structure syntaxique mais pas le même sens.

La définition du domaine dans lequel le système est capable de "comprendre" va nous permettre dans le chapitre suivant de montrer comme fonctionne le système de documentation automatique sur un ensemble d'enregistrements

EXEMPLE DE PROCESSUS D'ANALYSE

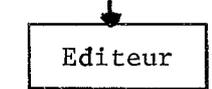
Phrase écrite par l'utilisateur

(RADIOGRAPHIE DU BASSIN EN POSITION DEBOUT)



Phrase donnée par le lecteur

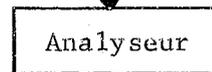
((debout) (bassin) (radiographie))



Phrase donnée par l'éditeur

((10,336)(20,35) (30,106))

Phrase donnée par l'analyseur syntaxique :



(3,4,(336),15,27,(35),38,(30))

On remarque sur cet exemple réel que les codes des unités syntaxiques MTER, MTA et MPR sont respectivement 10, 20 et 30

I	DER	:: DER <u>OPL3</u> DER	(1)
		TER T	(2)
		TER T TOR	(3)
	TER	:: <u>MTER</u>	(4)
		<u>MTER</u> GQR	(5)
	GQR	:: GR	(6)
		<u>NR</u>	(7)
		GQR <u>OPL1</u> GQR	(8)
II	GR	:: QR	(9)
		QR GR	(10)
	QR	:: <u>MI</u>	(11)
		<u>Q</u>	(12)
		<u>QTER</u>	(13)
	T	:: T <u>OPL2</u> T	(14)
		TA	(15)
		TD TA	(16)
		TA TC	(17)
		TD TA TC	(18)
	TD	:: <u>MTD</u>	(19)
		<u>MTD</u> GQD1	(20)
III	GQD1	:: GQD	(21)
		<u>QG</u> GQD	(22)
	GQD	:: GD	(23)
		QD GQD	(24)
	QD	:: <u>Q</u>	(25)
		<u>MTD</u>	(26)
	TA	:: <u>MTA</u>	(27)
		<u>MTA</u> GOA1	(28)
	GOA1	:: GOA	(29)
		<u>QG</u> GOA	(30)

III

GQA ::= QA (31)
QA GQA (32)
QA ::= Q (33)
MTA (34)
NOMB (47)
TC ::= CS T2 (35)
T2 ::= TA (36)
TD TA (37)

IV

TOR ::= MPR (38)
MTOR (39)
OPM MTOR (40)
MTOR GQT01 (41)
OPM MTOR GQT01 (42)
MTOR T2 (43)
OPM MTOR T2 (44)
MTOR T2 (45)
OPM MTOR GQT01 T2 (46)
GQT01 ::= QTOR (47)
QTOR GQT01 (48)

A N N E X E 2

LISTE DES SYMBOLES TERMINAUX

ET DES CODES ASSOCIES

MI	Mot d'Incidence	11
MPR	Mot de Position Radiologique	30
MTA	Mot de Topographie Anatomique	20
MTD	Mot de Topographie Descriptive	22
MTER	Mot de Technique d'Examen Radiologique	10
MTOR	Mot de Technique Opératoire Radiologique	31
NR	Nom propre de Radiologue	12
OPL1	Opérateur Logique 1	01
OPL2	Opérateur Logique 2	07
OPL3	Opérateur Logique 3	08
Q	Qualificatif	03
QG	Qualificatif Gauche	04
CS	opérateur de Centrage	05
QTOR	Qualificatif de Technique Opératoire Radiologique.	32
NOMB	Nombre	06
OPM	Opérateur de Moyen	02

La chaîne parenthésée montre la représentation interne de l'arbre des bases qui est schématisé à l'aide du schéma supérieur que l'on a déjà décrit en page 29.

L'exemple restreint nous montre qu'une base peut commencer par l'une des trois lettres A, B, C notées formellement s_1^1, s_2^1, s_2^1

A nouveau, la lettre A ne peut commencer que par B ou C symbolisée par s_1^2 et s_2^2 .

Si un mot commence par A, on ira chercher la suite de ce mot dans la liste notée ℓ_1^1 et la recherche se poursuivra jusqu'à la rencontre d'un pointeur symbolisé par un astérisque.

DOCUMENTATION AUTOMATIQUE ET LANGAGE NORMALISE

I - CORRESPONDANCE BIUNIVOQUE ENTRE LA PHRASE FRANCAISE ET LA PHRASE ANALYSEE

- I.1. - Rappel et terminologie employée
- I.2. - Si deux phrases françaises ont même sens, les phrases éditées sont analogues.
- I.3. - Si deux phrases éditées sont analogues, elles ont même représentation interne.

II - RELATION D'INCLUSION ENTRE DEMANDES D'EXAMEN

- II.1. - Forme des inclusions
- II.2. - Forme de l'inclusion au niveau de la syntaxe entre les représentations internes
- II.3. - Forme de l'inclusion au niveau des mots français

III - PRINCIPE GENERAL DE L'ALGORITHME DE RECONNAISSANCE D'INCLUSION

- III.1. - Principe général de l'algorithme de comparaison
- III.2. - Remarque pratique sur l'enregistrement de la structure d'une phrase analysée.

DOCUMENTATION AUTOMATIQUE ET LANGAGE NORMALISE

Introduction

Après avoir montré qu'il est possible de donner une même représentation interne de deux phrases françaises ayant même sens, on décrira comment la définition de relations d'inclusion entre des phrases analysées (on emploiera dans ce chapitre indifféremment les termes "phrase analysée" ou "représentation interne") permet de retrouver dans un ensemble de phrases analysées et enregistrées dans un fichier, telle ou telle information désirée.

2.1 - CORRESPONDANCE BIUNIVOQUE ENTRE LA PHRASE FRANCAISE ET LA PHRASE ANALYSEE

Nous allons montrer que cette correspondance est vraie dans le domaine de compréhension du système puis également au niveau des mots français.

2.I.1. - Rappel et terminologie employée

- Une demande d'examen sous sa forme première sera appelée phrase française :
EX.2.I.0 exemple : (RADIOGRAPHIE DU BRAS DROIT)
- Le résultat de l'édition sera appelé phrase éditée :
EX.2.I.1 exemple : ((MTER,UL1)(MTA,UL2)(Q,UL3))
- Le résultat de l'analyse syntaxique sera nommé indifféremment :
 phrase analysée
 phrase comprise
 représentation interne
EX.2.I.2 exemple : $S_1 C_1' S_2' C_2' S_3 C_3' S_4$

rappelons que les S_i sont les suites des numéros de règles employées par l'analyseur et que les C_i' sont des listes contenant la (ou les) valeur(s) de (ou des) l'unité(s) lexicale(s) de chacun des mots français utilisés dans la phrase française.

Enfin, la synonymie de deux phrases française formellement différentes sera définie subjectivement.

- exemple : (RADIOGRAPHIE PULMONAIRE DROITE)
EX.2.I.3 (RADIOGRAPHIE DU POU MON DROIT)
 (BRONCHOGRAPHIE) et RADIOGRAPHIE DES BRONCHES

2.I.2. - Si deux phrases françaises ont même sens, les phrases éditées sont analogues.

On dira que deux phrases éditées sont analogues si tout couple (US_i, C_i') de l'une apparaît dans l'autre et réciproquement. Ceci n'implique pas que l'ordre d'apparition de ces couples soit le même.

- L'emploi de synonymes est résolu par le procédé connu du synonyme de référence
- Tout mot contenant des informations implicites est remplacé par la suite explicite des informations qu'il contient. Ce problème complexe dans un cas général est ici assez simple car en pratique seuls les noms propres rentrent dans cette catégorie et la suite des "informations de traduction" se place d'un bloc à la place du "mot traduit".
- Enfin, le programme d'édition sait redresser l'ordre des couples (programme utilitaire de l'éditeur) dans des cas parfois engendrés par l'utilisation des mots composés tels ANGIOGRAPHIE, UROGRAPHIE, BRONCHOGRAPHIE, etc...

En effet, l'emploi d'un mot composé du type de BRONCHOGRAPHIE produit une phrase éditée dont l'aspect est le suivant :

EX.2.I.3

((MTA, UL2) (MTER, UL1))

où UL2 représente la valeur de l'unité lexicale de la base BRONCH et UL1 celle de la base RADIOGRAPHIE car GRAPHIE et RADIOGRAPHIE sont synonymes.

Un simple examen des règles de la grammaire décrite à la fin du chapitre 1 montre que la phrase éditée de l'exemple 2.I.3 ne sera pas reconnue par l'analyseur. Il est nécessaire d'inverser les deux éléments de cette liste. Ceci se trouve justifié en considérant que l'édition de la phrase française :

RADIOGRAPHIE DES POUMONS

aura comme résultat

((MTER, UL1) (MTA, UL2))

L'important est de remarquer que ce dernier programme ne nécessite pas un algorithme général à base de sémantique mais est chargé de résoudre un nombre restreint de problèmes particuliers. Ce nombre est restreint à cause du petit nombre de mots du vocabulaire.

Ce programme du type de ceux utilisés en documentation automatique permet de bâtir des phrases éditées identiques (grâce au petit nombre de cas recensés) lorsque deux phrases françaises ont même sens. Il y a une exception : celle de l'utilisation d'opérateurs logiques.

EX.2.I.4

(RADIOGRAPHIE FACE ET PROFIL DU CRANE)

(RADIOGRAPHIE PROFIL ET FACE DU CRANE)

ne donneront pas lieu à des phrases éditées mais seulement analogues.

Ce cas sera traité après l'analyse syntaxique de la phrase éditée

Conclusion :

Les caractéristiques de ces programmes est leur manque total de généralité. Il s'agit plutôt d'algorithmes très particuliers destinés à produire le résultat désiré. Le seul intérêt réside dans le fait que ces programmes portent sur des ensembles ayant un petit nombre d'éléments et peuvent donc être assez complets.

2.I.3. - Si deux phrases éditées sont analogues elles ont même représentation interne

On vient de voir que le seul cas où deux phrases éditées (issues de phrases françaises ayant le même sens) ne sont pas identiques est le cas d'emploi d'opérateurs logiques.

2.I.3.1. - Cas des phrases éditées identiques

La grammaire étant non ambiguë les représentations internes de deux phrases éditées identiques sont identiques.

La grammaire a pour données deux suites identiques d'unités syntaxiques (ex.2.1.5).

Les C_i des couples (US_i, C'_i) sont identiques par hypothèse. La représentation interne associée à la suite de règles qui a permis d'arriver à US_i le C'_i correspondant (ex.2.I.2 page 53).

EX.2.I.5

$(US_1, C_1) (US_2, C_2) \dots (US_n, C_n)$

$(US_1, C_1) (US_2, C_2) \dots (US_n, C_n)$

2.I.3.2. - Cas des suites analogues mais non identiques

Les représentations internes seront différentes. Mais l'analyse syntaxique une fois faite, le système est capable de reconnaître l'opérateur logique ainsi que sa portée.

On scindera l'enregistrement en deux :

exemple :

(RADIO DE FACE ET DE PROFIL DU CRANE)

la représentation interne de cette phrase sera scindée en deux phrases analysées correspondant aux deux phrases françaises suivantes :

EX.2.I.6

(RADIO DE FACE DU CRANE)

(RADIO DE PROFIL DU CRANE)

2.I.4. - Réciproques

Deux phrases analysées identiques fourniront évidemment des phrases françaises identiques et par conséquent ayant même sens. Cependant, il faudra se montrer extrêmement prudent lorsque deux phrases sont synonymes ; comme on vient de le voir, le système ne sait reconnaître la synonymie de deux phrases françaises que dans certains cas particuliers. Entre autres, deux phrases synonymes de structures totalement différentes ne seront pas reconnues par ce système. Cet aspect a pu être négligé jusqu'à présent en radiologie.

2.II. - RELATION D'INCLUSION ENTRE DEMANDES D'EXAMEN

Le but de la documentation automatique n'est pas de retrouver seulement tous les enregistrements identiques à un enregistrement particulier

(l'enregistrement question) mais tous ceux qui contiennent toutes les informations contenues dans la question.

EX.2.II.1

"RADIOGRAPHIE DU BRAS"

"RADIOGRAPHIE DU BRAS GAUCHE"

On peut dire très subjectivement que les informations contenues dans la première phrase se retrouvent toutes dans la seconde.

Si la première phrase est la question, la deuxième phrase répondra à la question.

Définition de l'inclusion entre deux phrases :

On dira qu'une phrase P1 est incluse dans une phrase P2 si les informations contenues dans P1 se retrouvent toutes dans P2.

EX.2.II.2

"RADIOGRAPHIE DU BRAS" est contenue dans

"RADIOGRAPHIE DU BRAS GAUCHE"

Notons que cette terminologie est arbitraire car on pourrait très bien dire l'inverse de la façon suivante :

"RADIOGRAPHIE DU BRAS GAUCHE" implique

"RADIOGRAPHIE DU BRAS"

2.II.1. - Forme des inclusions

Il s'agit de voir quelles sont les diverses formes d'inclusions entre deux phrases françaises.

2.II.1.1. - Inclusion au niveau du mot français

exemple :

P₁ RADIOGRAPHIE DE L'ABDOMEN

P₂ RADIOGRAPHIE DE L'ESTOMAC

P₁ est incluse dans P₂

EX.2.II.3

Les deux phrases auront même structure syntaxique puisque la grammaire comprendra la même chose pour chacune des deux phrases.

Ce genre d'inclusion sera reconnu à l'aide des techniques de documentation habituelle .

2.II.1.2. - Inclusion au niveau de la syntaxe

Exemple :

EX.2.II.4

P₁ RADIOGRAPHIE DU BRAS
P₂ RADIOGRAPHIE DU BRAS GAUCHE
P₁ est incluse dans P₂

La grammaire sera capable de reconnaître que dans le second cas de topographie est affinée par l'emploi d'un qualificatif.

Il s'agit donc d'inclusion dans le domaine de compréhension du système.

2.II.1.3. - Inclusion hybride

Exemple :

EX.2.II.5

P₁ RADIOGRAPHIE DE L'ABDOMEN
P₂ RADIOGRAPHIE DU FOIE AVEC OPACIFICATION
P₂ est incluse dans P₁

Une telle inclusion sera reconnue par les techniques classiques pour l'inclusion au niveau des topographies, par une technique propre à la grammaire pour l'utilisation d'une technique opératoire.

2.II.1.4. - Non inclusion

Des phrases peuvent ne pas être comparables :

exemple 1 :

EX.2.II.6

P₁ RADIOGRAPHIE DES POUMONS
P₂ RADIOGRAPHIE DU GENOU

Dans ce cas la grammaire comprend la même chose. La différence est au niveau des mots.

Exemple 2 :

EX.2.II.7

RADIOGRAPHIE DE PROFIL DE L'EPAULE
RADIOGRAPHIE DE L'EPAULE GAUCHE

Ici, il y a deux inclusions en sens inverse au niveau de la syntaxe.

Il est bien évident que ces deux types d'inclusions peuvent se combiner.

2.II.2. - Forme de l'inclusion au niveau de la syntaxe entre les représentations internes

Dans ce paragraphe nous parlerons uniquement d'inclusion au niveau syntaxique, c'est-à-dire dans le domaine de compréhension du système.

2.II.2.1. - Concepts et règles de grammaire

La grammaire a été conçue de telle manière que chaque classe de règles de grammaire corresponde à un concept du système, les parties droites correspondant aux diverses descriptions de ce concept.

Exemple :

TER : ensemble de moyens techniques utilisés pour faire une radiographie

La classe TER s'écrit :

EX.2.II.8

TER \rightarrow_1 MTER | MTER GQR

MTER est une unité syntaxique, c'est-à-dire un concept de base du système.

GQR est un concept qui sera décrit à son tour à l'aide d'autres concepts et ceci à un niveau inférieur de la structure.

Sur l'exemple précédent on voit bien comment l'emploi de la règle 2 va permettre d'affiner plus ou moins la description d'une technique de radiologie.

L'utilisation de la règle numéro 2 va permettre de générer une phrase telle que la technique d'examen radiologique décrite contienne la technique d'examen radiologique d'une phrase générée à l'aide de la règle 1.

Considérons maintenant une règle du type :

$$QA \longrightarrow Q \mid \underline{MTA}$$

L'utilisation de l'une ou l'autre règle pour décrire QA n'indique pas un affinement mais une différence réelle dans la description de ce concept.

a) - Définition d'un couple d'affinement :

Il s'agira d'un couple de règles (N, N+1) tel que l'emploi de la règle N+1 au lieu de la règle N corresponde à un affinement de la description de la classe qui contient ces règles.

L'utilisation systématique de cette définition implique que l'on puisse ramener à une forme identique à celle de l'exemple cité plus haut toutes les règles pour lesquelles il est nécessaire de définir un couple d'affinement. Ceci est toujours possible si l'affinement se fait toujours du même côté.

exemple :

Soit la règle :

$$\text{EX.2.II.9} \quad X \longrightarrow \begin{array}{l} 1 \ A \quad \mid \quad 2 \ A \ B \quad \mid \quad 3 \ A \ C \end{array}$$

L'utilisation de B ou C correspond bien à un affinement. Mais le couple n'apparaît pas de manière explicite ; on écrit alors :

$$\begin{array}{l} \text{EX.2.II.10} \quad X \longrightarrow \begin{array}{l} 1 \ A \quad \mid \quad 2 \ A \ Y \\ Y \longrightarrow \begin{array}{l} 3 \ B \quad \mid \quad 4 \ C \end{array} \end{array} \end{array}$$

les règles 1 et 2 forment un couple d'affinement, les règles 3 et 4 correspondent bien à des descriptions différentes du concept fictif Y.

La définition d'un tel concept pourrait être :
concept qui peut affiner X quand X commence par le concept A.

b) - Introduction de concepts vides :

La forme de l'exemple 2.II.8 ou 2.II.10 n'est pas satisfaisante car la reconnaissance du concept A dépend de ce qui le suit. On utilise pour remédier à cet inconvénient, une technique utilisée en analyse syntaxique [20]

EX.2.II.11 si $X \longrightarrow_1 A \quad \bigg|_2 A B$
on écrit :

EX.2.II.12 $X \longrightarrow_1 A \quad Y$
 $Y \longrightarrow_2 \emptyset \quad \bigg|_3 B$

l'exemple 2.II.11 montre le couple d'affinement 1, 2.

l'exemple 2.II.12 montre que le couple d'affinement est maintenant 2, 3 ;

\emptyset représente le concept vide.

De plus, dans un couple d'affinement (N, N+1) N correspondra toujours à l'utilisation de la règle vide.

En définitive, après avoir ramené quand cela est nécessaire les classes de règles à la forme de l'exemple 2.II.11, on les ramènera à la forme de l'exemple 2.II.12 (cf. forme interne de la grammaire).

c) - Caractéristique fondamentale de la grammaire :

L'introduction de couples d'affinement entraîne qu'il existe une seule manière d'affiner un concept X dans le domaine de compréhension du système

C'est l'emploi de la règle non vide du couple d'affinement Y associé au concept X.

- En effet, si l'on utilise la règle non vide du couple d'affinement Y on affine Y par la construction même de la grammaire.
- Si l'on désire affiner un concept X tel celui de l'exemple 2.II.11 et que l'on puisse le faire sans utiliser le couple d'affinement Y c'est parce qu'il existe une règle de classe X contenant A en partie droite.

exemple :

EX.2.II.13

$$X \longrightarrow D A E$$

S'il existe une telle règle c'est que toutes les règles n'ont pas été transformées en des règles du type de l'exemple 2.II.12.

Notons que dans ce cas la transformation d'une telle règle change la grammaire. En effet, on a le groupe de règles :

$$\left\{ \begin{array}{l} X \longrightarrow A Y \quad | \quad D A E \\ Y \longrightarrow \emptyset \quad | \quad B \end{array} \right.$$

On transformera ce groupe en l'ensemble suivant :

$$\left\{ \begin{array}{l} X \longrightarrow_1 Z A Y \\ Y \longrightarrow_2 \emptyset \quad |_3 F \\ F \longrightarrow_4 B \quad |_5 E \\ Z \longrightarrow_6 \emptyset \quad |_7 D \end{array} \right.$$

Ce groupe permettra de générer à partir de X la chaîne suivante :

$$D A B \text{ (règles 1, 7, 3, 4)}$$

2.II.2.2. - Reconnaissance d'inclusion entre deux représentations internes

Nous avons vu en 2.II.2.1 comment la présence d'une inclusion au niveau syntaxique est traduite par le passage sur un couple d'affinement de la grammaire. Ceci se retrouve immédiatement dans la représentation interne.

Nous avons vu (ex.2.I.2) comment on a schématisé la représentation interne d'une phrase. Nous allons adopter maintenant un schéma un peu plus complet :

EX.2.II.14

$$n_1 n_2 \dots n_i (*) n_j \dots n_k (*) \dots (*) n_1 \dots n_p$$

les n_i représentent les numéros de règles de grammaire fournis par l'analyseur.

L'astérisque entre parenthèses indique la présence des unités lexicales des mots français ; cette présence est sans effet, ici puisque nous travaillons dans le domaine de compréhension du système.

On schématisera par la suite la présence d'une règle vide n_i en l'entourant d'un rond. Ceci implique que l'on possède la liste des numéros des règles vides (le couple d'affinement en découle immédiatement).

2.II.2.2.1. - Mise en évidence de la structure d'une phrase

Ainsi le simple parcours d'une suite de la forme de celle de la l'exemple 2.II.14. nous donne immédiatement la liste des numéros de règles représentant une règle vide.

Cette suite représente plus qu'une simple suite linéaire : chaque numéro correspond à l'appel d'un sous-programme de l'analyseur chargé d'analyser la structure d'un concept.

Cette suite représente la trace des appels aux diverses procédures de l'analyseur. On peut donc au cours de l'analyse créer explicitement la structure de la phrase.

On peut schématiser les divers niveaux d'une structure de la manière suivante :

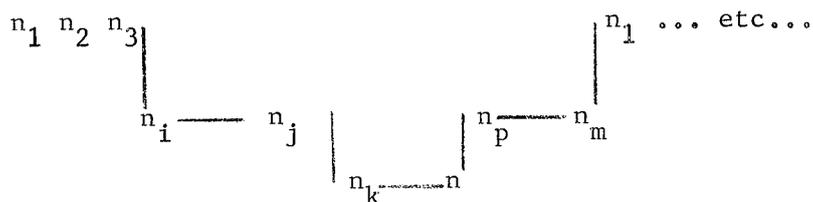


FIGURE 2.II.1

Dans ce cas tout niveau inférieur à 1 commence par un numéro de règle d'un couple d'affinement de la grammaire et il s'agit du numéro correspondant à la règle non vide.

D'une manière symétrique le passage sur le numéro correspondant à la règle vide d'un couple d'affinement indique la non utilisation du sous-programme permettant l'affinement et indique que l'on reste au même niveau de la structure.

2.II.2.2.2. - Mise en évidence des inclusions élémentaires

Ainsi, lorsque l'on compare deux suites P_1 et P_2 représentant deux phrases analysées, on teste l'égalité des numéros de règles de même rang dans les suites et on avance ainsi de suite sans se soucier du niveau auquel on descend.

La progression va s'arrêter lors de la rencontre de deux numéros distincts :

- 1° - s'il ne s'agit pas d'un couple d'affinement alors les deux phrases sont différentes du point de vue syntaxique et n'ont donc pas le même sens.
- 2° - s'il s'agit d'un couple d'affinement n_m, n_{m+1} alors il y a inclusion élémentaire entre les deux suites et on est dans le cas de figure suivant :

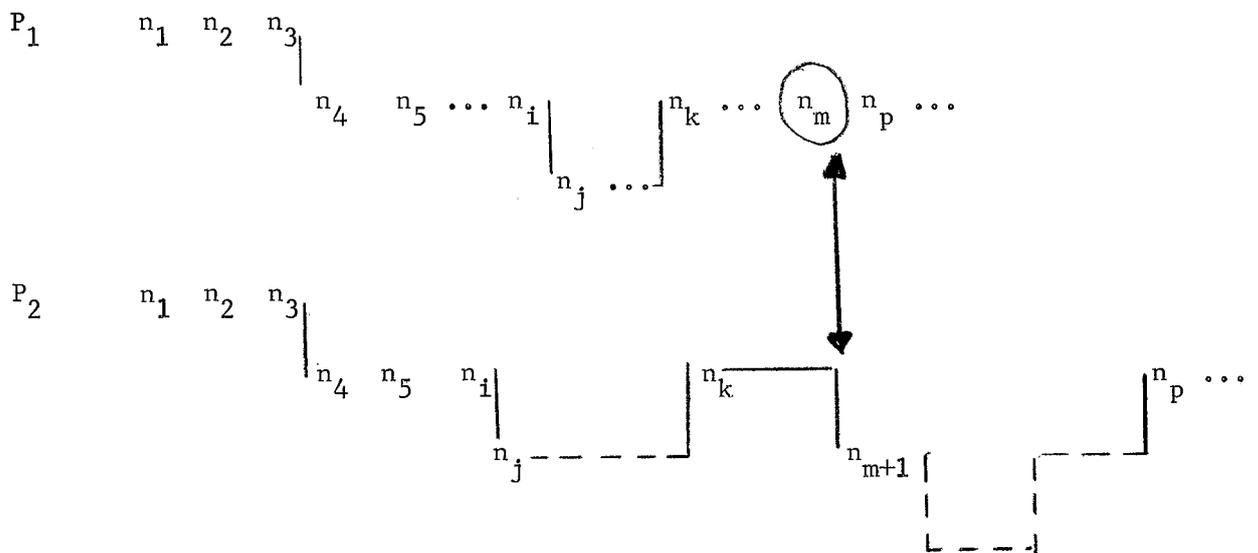


FIGURE 2.II.2

La figure 2.II.2 indique que le niveau où l'on se trouve importe peu. La figure élémentaire correspondant à l'apparition d'un couple d'affinement est la suivante :

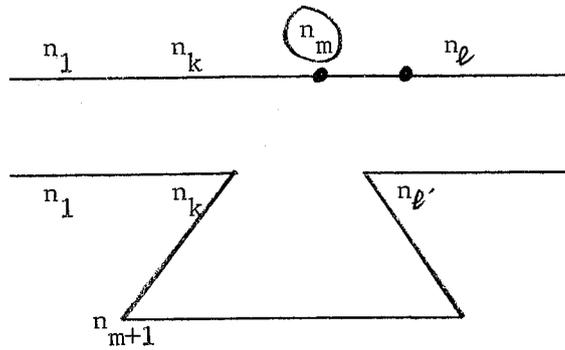


FIGURE 2.II.3.

On reprend ici le schéma d'appel d'un sous-programme.

Après la détermination du sens de l'inclusion la progression reprend en sautant, dans la suite qui le contient, le sous-programme c'est-à-dire en restant au même niveau.

La comparaison du couple suivant le couple d'affinement est à nouveau soumise aux mêmes règles de comparaison.

2.II.2.2.3. - Inclusion entre deux phrases analysées

L'exemple 2.II.10 montrait deux inclusions élémentaires syntaxiques de sens inverse. Ceci correspond à la figure suivante :

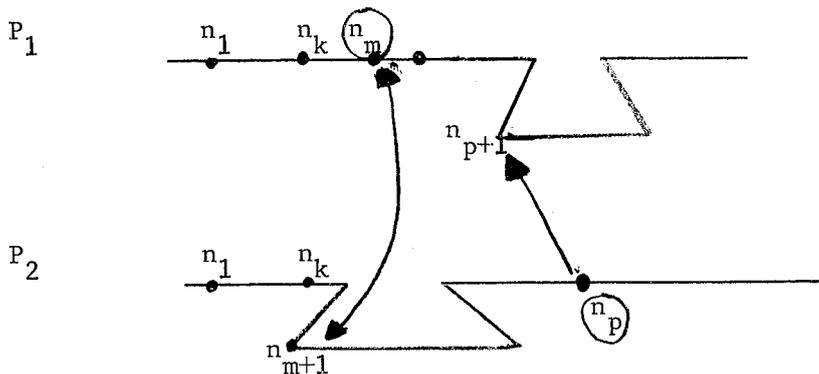


FIGURE 2.II.4.

Si deux phrases françaises F1 et F2 sont comparables, avec par exemple F1 incluse dans F2, alors leurs représentations internes respectives P1 et P2 ne vont contenir que des inclusions élémentaires de même sens dans le cas où il n'y a pas d'identités entre les numéros de règles de même rang.

Réciproquement, si deux suites P1 et P2 ne diffèrent que par la présence d'inclusions élémentaires de même sens alors les phrases françaises F1 et F2 associées à P1 et P2 seront liées par une relation d'inclusion dont le sens sera le sens commun à toutes les inclusions élémentaires.

2.II.3. - Forme de l'inclusion au niveau des mots français

Au niveau de la représentation interne, ces inclusions vont être mises en lumière grâce au C_i de l'exemple 2.I.5

Au lieu d'utiliser la représentation donnée par l'exemple 2.II.13 nous allons utiliser maintenant la représentation suivante pour une phrase analysée :

$$\text{EX.2.II.14} \quad S_1(UL_1^1, \dots, UL_n^1) \dots S_i(UL_1^i, \dots, UL_p^i)$$

l'indice inférieur indique le rang de l'unité lexicale dans la suite.

l'indice supérieur i indique qu'il s'agit des valeurs des unités lexicales associées à la suite S_i .

2.II.3.1. - Diverses formes d'inclusions au niveau des mots français

Les exemples donnés au paragraphe 2.II.1.1 ne justifient pas l'exemple 2.II.14.

En effet, ces deux exemples supposent que chacune des suites entre parenthèses de l'exemple 2.II.14 contiennent un seul élément ; on aurait ainsi le schéma particulier :

$$S_1(UL^1) S_2(UL^2) S_3$$

Le schéma décrit par l'exemple 2.II.14 peut être fourni après analyse d'une phrase française utilisant des mots composés :

exemple :

EX.2.II.15

RADIOGRAPHIE DE L'ARTICULATION SCAPULO-HUMERALE

$S_1(UL_1^1) S_2(UL_1^2) S_3(UL_1^3, UL_2^3) S_4$

Cet exemple permet de mettre en évidence un second type d'inclusion explicite cette fois.

La phrase suivante :

EX.2.II.16

RADIOGRAPHIE DE L'ARTICULATION HUMERALE

$S_1(UL_1^1) S_2(UL_1^2) S_3(UL_1^3) S_4$

est incluse dans la phrase précédente.

Au niveau de la représentation interne cette inclusion sera mise en évidence par comparaison de la dernière suite d'unité lexicale de chacune des représentations internes.

La suite (UL_1^3, UL_2^3) de l'exemple 2.II.15 contiendra toutes les informations contenues dans la suite (UL_1^3) de l'exemple 2.II.16.

2.II.3.2. - Règles de recherche d'une inclusion lors de la comparaison de suites d'unités lexicales

Une suite L1 d'unités lexicales sera dite incluse dans une suite L2 (également d'unités lexicales) si toutes les informations contenues dans L1 sont contenues dans L2.

Nous allons montrer que L1 est incluse dans L2 si et seulement si tous les éléments de la suite L1 se trouvent dans la suite L2 sous l'une des deux formes suivantes :

- 1° - chacun des éléments de L1 apparaît explicitement dans la suite L2
- 2° - Il peut exister des éléments de L1 qui bien que n'apparaissant pas explicitement dans la suite L2 sont liés à certains éléments de L2 par une relation sémantique subjective (telle celle qui lie abdomen et estomac).

- a) - Si tous les éléments de la suite L1 se trouvent dans L2 sous l'une des deux formes décrites plus haut alors tous les renseignements contenus dans L1 sont aussi contenus dans L2.

Ceci résulte du fait que le sens attaché aux mots du vocabulaire est pas hypothèse, indépendant du contexte.

- b) - Si tous renseignements contenus dans une liste d'unités lexicales L1 sont également contenus dans une liste d'unités lexicales L2 alors, tous les éléments de L1 apparaissent dans L2 sous l'une des deux formes décrites ci-dessus.

L'ensemble des renseignements contenus dans une liste L1 d'unités lexicales est une suite de renseignements élémentaires indépendants les uns des autres, chaque renseignement élémentaire étant associé d'une manière biunivoque aux unités lexicales.

Si l'ensemble des renseignements contenus dans L1 se retrouve dans L2 alors on doit pouvoir retrouver dans L2 chacun des renseignements élémentaires de L1 donc chacune des unités lexicales associées à ces renseignements. On peut retrouver explicitement dans L2 l'unité lexicale associée à un renseignement élémentaire de L1 ou bien il peut exister une relation sémantique explicitée dans la table de traduction entre un renseignement élémentaire de L1 et le renseignement associé à une unité lexicale de L2 auquel cas la suite L1 apparaît indirectement dans L2.

2.III. - PRINCIPE GENERAL DE L'ALGORITHME DE RECONNAISSANCE D'INCLUSION

Cet algorithme reconnaît non seulement les inclusions au niveau de la syntaxe, mais lors de la rencontre de mots français, il devra reconnaître les inclusions existants éventuellement entre ceux-ci ; le sens des inclusions purement sémantique jouera le même rôle que celui des inclusions reconnues au niveau de la syntaxe.

2.III.1. - Principe général de l'algorithme de comparaison

-- Il s'agit d'examiner deux suites composées de deux sortes d'éléments :

- a) les numéros des règles de grammaire utilisés pour bâtir la phrase
- b) les valeurs des unités lexicales des mots français utilisés.

-- On examine les couples d'éléments de même rang de la suite.

- a) si les couples sont égaux alors on passe au couple suivant
- b) si les couples ne sont pas égaux alors on examine la cause de l'inégalité :

- il s'agit d'une véritable inégalité alors les deux phrases sont différentes et on sort.

- il s'agit d'une inclusion élémentaire et on note sons sens. Si elle est incompatible avec les précédentes les phrases sont différentes et on sort.

Sinon,

s'il s'agit d'inclusion au niveau du mot, on continue en séquence sinon on recherche la fin du sous-programme entraînant l'inclusion et on continue la comparaison entre le couple d'élément suivant respectivement le symbole de la règle vide et le sous-programme affinant l'autre suite.

-- Ou bien les deux suites sont épuisées ensembles et se terminent par des éléments identiques ou par une inclusion au niveau du mot. Ou bien le dernier symbole de la première suite épuisée est le symbole vide d'un couple d'affinement et la fin de l'autre suite correspond à nouveau à un sous-programme d'affinement.

Exemple :

EX.2.III.1.

P₁ RADIOGRAPHIE DE L'ESTOMAC

P₂ RADIOGRAPHIE DE L'ABDOMEN

Dans ce cas les deux suites sont épuisées ensembles mais la comparaison des mots 'ABDOMEN' et 'ESTOMAC' indique P₂ incluse dans P₁.

P₁ RADIOGRAPHIE DE L'ESTOMAC

P₂ RADIOGRAPHIE DE L'ESTOMAC SANS PREPARATION

La suite représentant P₁ sera épuisée la première mais elle se terminera par le symbole vide du couple d'affinement exprimant l'existence ou la non-existence d'une technique opératoire Radiologique.

2.III.2. - Remarque pratique sur l'enregistrement de la structure d'une phrase analysée

Nous avons dit que la structure d'une phrase analysée pouvait être explicitée par l'analyseur. Ceci peut se faire par parenthésage par exemple. Le parenthésage est indispensable dans le cas général pour connaître la fin d'un sous-programme lorsque dans la comparaison de deux suites on veut le sauter pour continuer la comparaison des éléments (cas de la figure 2.II.3). Cependant, nous allons voir que dans le cas présent on peut se passer du parenthésage :

1° - Il est inutile d'expliciter les parenthèses ouvrantes, le passage sur l'élément non vide d'un couple d'affinement suffit à indiquer la présence d'un sous-programme.

2° - Il est possible de ne pas explicitement les parenthèses fermantes si $n_l = n_i$ (cf. figure 2.II.3). Ceci implique qu'on ne puisse pas avoir l'un des deux cas de figure ci-dessous ou une combinaison des deux :

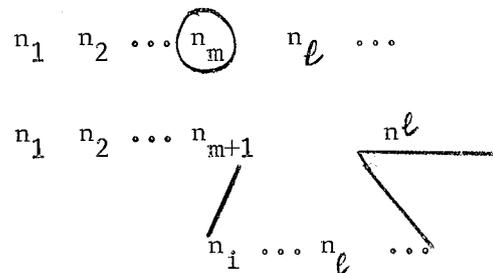


FIGURE 2.III.1.

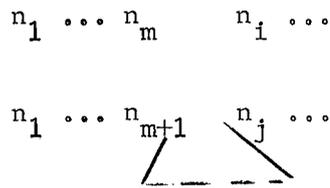


FIGURE 2.III.2.

Le cas de figure 2.III.1 correspond à un ensemble de règles du type suivant :

EX.2.III.2

$$\begin{array}{l}
 A \longrightarrow BC \\
 B \longrightarrow \emptyset \mid E C D
 \end{array}$$

Ceci correspond à un affinement par la gauche du concept A. Ce cas ne présentait que lors de l'utilisation des qualificatifs gauches tels (le "grand") ce cas est éliminé par l'éditeur qui replace ce qualificatif à droite.

Le cas de la figure 2.III.2 correspond au groupe de règles suivant :

EX.2.III.3.

$$\begin{array}{l}
 A \longrightarrow_1 B C \\
 B \longrightarrow_2 E X \\
 X \longrightarrow_3 \emptyset \mid_4 D \\
 C \longrightarrow_5 E \mid_6 F
 \end{array}$$

On pourra former les suites :

EX.2.III.4

$$\begin{array}{l}
 1, 2, \textcircled{3}, 5 \text{ et} \\
 1, 2, 4, 6 \\
 \quad \swarrow \searrow \\
 \quad \quad D
 \end{array}$$

Ce cas s'élimine facilement en remplaçant la règle

$$C \longrightarrow_5 E \mid_6 F \text{ par les deux règles}$$

EX.2.III.5

$$\begin{array}{l}
 C \longrightarrow_6 \mid J \\
 J \longrightarrow_7 E \mid_8 F
 \end{array}$$

Ainsi quelque soit les règles utilisées on aura toujours des figures du type suivant :

EX.2.III.6

P_1 : 1, 2, (3) , 6

P_2 : 1, 2, 4 6


Ainsi on associe à un couple d'affinement un troisième élément qui est l'élément devant suivre systématiquement l'un ou l'autre des deux éléments formant le couple d'affinement.

D'où la règle suivante :

Lorsque la progression de l'algorithme de comparaison est arrêté par la présence de l'utilisation d'un couple d'affinement (EX.2.III.6), on reprend la comparaison entre les éléments des suites P_1 et P_2 dès que l'on a trouvé dans P_2 le délimiteur du sous-programme. Ce délimiteur est l'élément qui suit immédiatement dans P_1 , l'élément vide du couple d'affinement qui donne naissance au sous-programme.

Ces dernières remarques permettent d'effectuer une comparaison de suites linéaires et non plus de structures.

REMARQUE :

La cause profonde de cette simplification est due à l'équivalence de ce langage à un langage d'états-finis.

En effet, les règles de grammaire ne contiennent pas de véritables brécations. Toutes les productions infinies sont fournies par des règles de type états finis.

GRAMMAIRE FORME INTERNE

DER	→	TER T PHIO PHI8	(1)
PHIO	→	PHI	(2)
		TOR	(3)
TER	→	MTER PHI1	(4)
PHI1	→	PHI	(5)
		GQR	(6)
GQR	→	GR PHI2	(7)
		NR PHI2	(8)
GR	→	PHI	(9)
		QR GR	(10)
QR	→	MI	(11)
		Q	(12)
		QTER	(13)
T	→	PHI6 TA PHI5 PHI11	(14)
PHI6	→	PHI	(15)
		TD	(16)
TD	→	MTD PHI3	(17)
PHI3	→	PHI	(18)
		GQD1	(19)
GQD1	→	GQD	(20)
		QG GQD	(21)
GQD	::=	PHI	(22)
		QD GQD	(23)
QD	::=	<u>Q</u>	(24)
		<u>MTD</u>	(25)
TA	::=	<u>MTA</u> PHI4	(26)
PHI4	::=	PHI	(27)
		GQA1	(28)
GQA1	::=	GQA	(29)
		<u>QG</u> GQA	(30)

GQA ::= PHI (31)
QA GQA (32)

QA ::= Q (33)
MTA (34)

PHI5 ::= PHI (35)
CS T2 (36)

T2 ::= PHI6 TA (37)

TOR ::= MPR (38)
PHI9 MTOR PHI7 PHI10 (39)

PHI7 ::= PHI (40)
GQT01 (41)

PHI10 ::= PHI (42)
T2 (43)

GQT01 ::= PHI (44)
QTOR GQT01 (45)

PHI9 ::= PHI (46)
OPM (47)

PHI2 ::= PHI (48)
OPL1 GQR (49)

PHI8 ::= PHI (50)
OPL3 DER (51)

PHI11 ::= PHI (52)
OPL2 T (53)

LE TRAITEMENT DES FICHIERS

I - INTRODUCTION DU FICHER HYBRIDE

- I.1. - Définition du fichier hybride
- I.2. - Problèmes de traitement d'un fichier hybride
- I.3. - Exposé d'un principe d'implémentation

II - APPLICATION : LE DOSSIER MEDICAL EN RADIOLOGIE

- II.1. - Description du fichier
- II.2. - Description des traitements

LE TRAITEMENT DES FICHIERS

3.I. - INTRODUCTION DU FICHER HYBRIDE

Après avoir décrit dans les deux chapitres précédents le système documentaire qui devait permettre le stockage sur mémoire magnétique de toutes les informations médicales relevées par le médecin, on va aborder maintenant les problèmes posés par l'exploitation des fichiers ainsi créés.

3.I.1. - Définition du fichier hybride

C'est un fichier dont les enregistrements sont hybrides, c'est-à-dire que les enregistrements d'un tel fichier contiennent des informations des trois types suivants :

- a) - des informations codées ;
- b) - des informations issues de la reconnaissance de phrases françaises écrites à l'aide d'un langage normalisé,
- c) - des informations écrites en langage libre.

Il faut noter que le troisième type d'information est facultatif. Le caractère hybride d'un fichier et les problèmes qui lui sont associés sont essentiellement dus à la présence simultanée des deux premiers types d'information.

Comme on va le voir, les problèmes posés par l'apparition d'information hybride se situent essentiellement au niveau de l'enregistrement logique alors que les solutions adoptées se situeraient plus au niveau du fichier dans son ensemble.

3.I.2. - Problèmes de traitement d'un fichier hybride

Les problèmes soulevés sont essentiellement dus aux deux facteurs suivants :

1. - La taille des enregistrements

La présence dans un enregistrement de toutes les informations recueillies rend celui-ci extrêmement grand et lourd à manipuler. On verra qu'un dossier médical contient facilement plusieurs milliers de caractères et atteint relativement couramment 10.000 caractères. De plus l'emploi de langage normalisé et de langage libre permet des variations très importantes de la taille d'un enregistrement.

2. - La diversité des informations

Le traitement simultané des trois types d'informations ne présente que très rarement un certain intérêt.

Tout d'abord on peut dire que les trois types d'informations ne présente que très rarement un certain intérêt.

Tout d'abord, on peut dire que les trois types d'informations satisfont à des besoins d'information différents et très souvent complémentaires

- 1° - Le langage libre ne sert qu'à être restitué à la demande de l'utilisateur pour avoir un maximum de précision sur des informations qui ont été enregistrées soit sous forme normalisée soit sous forme codée.
- 2° - Le fait d'avoir choisi pour l'enregistrement de certaines informations la forme codée ou la forme normalisée implique que l'utilisateur connaisse avec une certaine précision le but dans lequel il enregistre ces informations.

Le choix entre la forme normalisée et la forme codée pour l'enregistrement de certaines informations peut être guidé par la remarque suivante :

Si l'enregistrement est fait dans un but unique et bien défini de statistique ou de recherche médicale, le codage apparaît souhaitable alors que la forme normalisée se prête plus à la recherche d'information ; il faut noter que la forme normalisée permet de créer des codes nécessaires à telle ou telle recherche ultérieure.

Il devient alors extrêmement pénible lors d'un traitement qui ne portera que sur un seul type d'information de l'enregistrement d'avoir à manipuler les informations des deux autres types ; c'est pourquoi le principe exposé ci-dessous a été adopté pour stocker les enregistrements hybrides.

3.I.3. - Exposé d'un principe d'implémentation

3.I.3.1. - Eclatement de l'enregistrement logique

A ce moment on peut être tenté de faire éclater l'enregistrement primitif en trois enregistrements logiques distincts, à la condition de sauvegarder les relations pouvant exister entre les informations des divers types. On parlera alors de groupes logiques d'enregistrements.

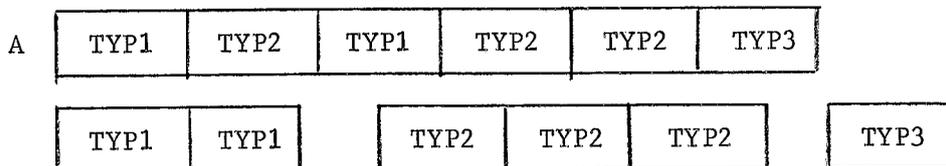


FIGURE 3.I.1

Exemple :

On peut supposer que la première zone de l'enregistrement A contient entre autre la date de la demande d'examen qui se trouve stockée dans la deuxième zone de l'enregistrement A.

3.I.3.2. - Eclatement du fichier - Fichier logique

La critique que l'on peut faire au fichier obtenu en éclatant ses enregistrements est la suivante :

S'il est vrai que l'on peut avoir accès au type d'information désirée, il n'en reste pas moins m.aladroit d'avoir dans ce fichier toujours la moitié ou plus, des enregistrements qui ne seront pas traités lors d'une exploitation.

Exemple :

Comme bien souvent on ne pourra pas avoir d'enregistrements de longueur fixe, il faudra recopier le fichier pour rajouter des informations aux divers enregistrements logiques. Ceci entraînera une recopie de tous les commentaires !

Il peut alors être intéressant d'éclater le fichier en fichiers composants qui contiendront chacun un type d'information. Il sera évidemment nécessaire de posséder si besoin est, un système de pointeurs sauvegardant l'aspect logique du fichier physique ainsi éclaté.

Au niveau des généralités, il est superflu d'aller plus loin dans la définition du fichier logique.

En effet, comme l'indique le titre du paragraphe ceci est un principe. La mise en oeuvre de ce principe dépend essentiellement des traitements que l'on désire faire sur les informations, ce qui entraîne que la décomposition en trois fichiers contenant chacun un type d'information et un seul, n'a pas lieu systématiquement.

L'exemple du dossier médical radiologique permettra de voir comment ce principe s'est imposé de lui-même et comment on l'a appliqué.

3.II. - APPLICATION - LE DOSSIER MEDICAL RADIOLOGIQUE

3.II.1. - Description du fichier

Après avoir montré que le fichier des dossiers médicaux a bien l'aspect d'un fichier hybride tel qu'il a été défini au paragraphe précédent, nous verrons apparaître un nouvel aspect de ce fichier qui cette fois semble plus lié à la complexité résultant de la nature médicale du dossier .

3.II.1.1. - Première description du fichier logique

Le fichier des dossiers médicaux va contenir des informations de trois types définis au paragraphe précédent.

1° - Informations codées :

Il s'agira essentiellement des informations de nature administrative, de gestion et enfin d'un certain nombre d'informations médicales parfaitement codables.

Exemple :

- Informations administratives :

NOM, PRENOM, ADRESSE, NUMERO SECURITE SOCIALE, etc...

- Informations de gestion :

Numéro de lit,

Date d'entrée,

Informations diverses sur la nature des clichés radiographiqu

EX.3.II.1

- Informations médicales :

Température,
Tension,
Résultats de laboratoire.

2° - Des informations écrites en langage normalisé :

Il s'agira le plus souvent de demande d'examen et des diagnostics associés.

Exemple :

EX.3.II.2

DEMANDE D'EXAMEN RADIOLOGIQUE
DIAGNOSTIC ISSU DE L'INTERPRETATION DES CLICHES

3° - Des commentaires écrits en langage libre :

Il pourra s'agir du détail d'une observation clinique ou par exemple de l'interprétation d'un examen radiologique.

Les trois types d'informations semblent à priori devoir être utilisées à des fins assez différentes :

1° - Les informations codées : seront essentiellement utilisées pour la gestion administrative de l'hôpital et des services, sauf les informations de nature plus médicales qui seront plutôt utilisées à des fins de documentation automatique.

Ce dernier point va entraîner, comme on le verra plus loin, que le fichier composant contenant au départ des informations sous forme normalisée contiendra également certaines informations codées qui se rapportent directement aux précédentes.

Exemple :

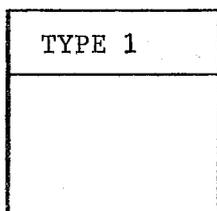
On laissera dans le même fichier les demandes d'examen radiologique avec leur date, que l'on séparera des données telles le numéro de l'opérateur, la quantité et la qualité des films utilisés.

2° - Les informations écrites en langage normalisé : seront, comme on vient de le dire, utilisées essentiellement dans le but immédiat de faire de la documentation automatique.

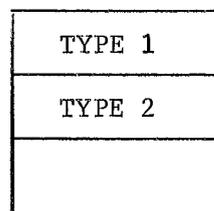
3° - Les commentaires : seront placés sur un autre fichier ; on aura accès à ces commentaires seulement à partir des informations qu'ils "commentent".

Le fichier logique sera ainsi celui décrit sur la figure ci-dessous :

Fichier des données
de gestion : FG



Fichier Documentaire
FD



Fichier Commentai
FC

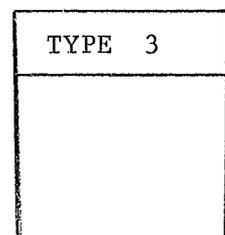


FIGURE 3.II.1

- le fichier FG ne contiendra que des informations codées,
- le fichier FD contiendra des groupes logiques d'enregistrements qui contiendront des informations codées et des informations de type normalisé,
- le fichier FC ne contiendra que des commentaires.

Cette configuration ne résout pas un autre problème propre au dossier médical cette fois.

La structure du dossier médical ne peut pas être fixe.

3.II.1.2. - Structure syntaxique du dossier médical

Avant de continuer, il faut noter que la décomposition d'un fichier n'altère pas la description logique de ses enregistrements. On peut donc parler

sans inconvénient de la structure d'un enregistrement d'un fichier sans tenir compte du fait que le fichier est décomposé ou non.

L'impossibilité de pouvoir donner une structure fixe à un dossier médical est due essentiellement à deux faits :

1° - La forme et le contenu d'un dossier médical dépendent essentiellement du malade. Les dossiers radiologiques de deux malades peuvent être extrêmement différents :

Le premier peut être celui d'un patient atteint d'une affection cardiaque par exemple, alors que l'autre peut être relatif à un étudiant en parfaite santé qui s'est cassé le péroné en faisant du ski

Alors que dans le premier dossier se développera toute une structure propre à recevoir les informations recueillies au cours du traitement du premier patient, le second dossier, lui ne contiendra que quelques renseignements essentiellement destinés à prouver le bon état cardiologique du second patient.

2° - Un type de structure satisfaisant un service pourra difficilement satisfaire un autre service en raison même de la spécialisation des services.

Il apparaît alors intéressant de donner un certain nombre de règles pour construire le dossier médical [15].

Exemple :

Pour le dossier radiologique on pourrait écrire un jeu simple et très incomplet des règles tel :

DR → <PG> <PM>

PM → <PF> <PDY>

PDY → <EXR> | <EXR> <PDY>

EX.3.II.3

où DR = Dossier Radiologique

PG = Partie Gestion

PM = Partie Médicale

PF = Partie Fixe (constantes médicales propres au malade)

PDY = Partie DYnamique

EXR = EXamen Radiologique.

3.II.1.3. - Problèmes posés par l'emploi d'une structure variable

Il existe essentiellement deux sortes de traitements courants sur le fichier des dossiers médicaux.

1° - La documentation automatique

Elle satisfait essentiellement deux besoins des utilisateurs :

- rechercher des renseignements sur tel malade
- rechercher le (ou les) malade(s) dont les dossiers contiennent tels ou tels renseignements.

2° - La mise à jour

On peut faire l'approximation suivante :

La mise à jour est faite uniquement par rajout de groupes données tels :

- un compte-rendu post-opératoire
- un compte-rendu d'examen radiologique
- les résultats d'une thérapeutique, etc...

Si on peut admettre même un cheminement assez pénible dans une structure portant sur plusieurs milliers de caractères, pour trouver tel ou tel renseignements, la mise à jour d'un tel ensemble de données apparaît comme extrêmement lourde du fait du volume de données à manipuler. Enfin, si l'on ne veut pas devoir recopier le fichier à chaque fois il faudra utiliser une méthode d'accès aléatoire.

Les méthodes à accès aléatoire ne sont pas très satisfaisantes et nécessitent des études sérieuses si l'on veut avoir une perte de place acceptable. D'autre part, cette méthode ne supprime pas la mise à jour même des enregistrements.

C'est pourquoi la solution proposée repose sur l'idée suivante : il faut éviter le plus possible de manipuler l'énorme ensemble de données qu'est un dossier médical.

3.II.1.4. - Introduction du fichier descripteur

La première idée qui vient à l'esprit est la suivante : on associe à chaque enregistrement logique un enregistrement dit descripteur. Cet enregistrement fournit la structure de l'enregistrement suivant. On aurait ainsi une suite de doublets d'enregistrements, le premier de chacun des doublets donnant en quelque sorte le plan détaillé de l'enregistrement suivant : on peut schématiser grossièrement cette idée en disant que chaque enregistrement est précédé d'une Data-Division Cobol [21].

Ceci est à peu près satisfaisant du point de vue documentation automatique bien que les enregistrements demeurent de taille très importante.

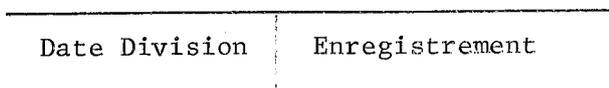
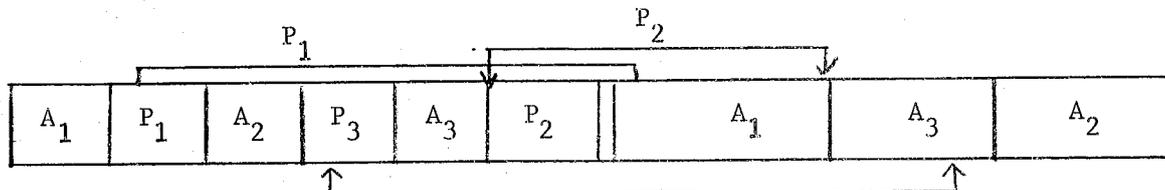


FIGURE 3.II.2

Par contre, du point de vue mise à jour, ceci n'exclut pas les manipulations complexes sur l'ensemble volumineux des données composant un dossier médical.

Pour remédier à cela on affecte à chaque groupe de données une référence permettant de l'identifier et on ajoute ce groupe données à la fin de l'enregistrement logique qui doit être mis à jour. La structure du descripteur seul, est alors modifiée. Le descripteur contient les références des groupes de données.



Le descripteur pourra être par exemple, composé d'une liste traduisant la structure de l'enregistrement correspondant. Les listes de plus

bas niveau ayant deux atomes : le premier étant la clé de référence et le second indiquant la catégorie syntaxique d'un groupe de données. Un inconvénient subsiste encore au niveau de la mise à jour de l'ensemble du fichier. Cette mise à jour nécessite de nombreux passages, car les groupes de données sont souvent volumineux. Il est difficile d'en stocker beaucoup en mémoire pour les classer de manière à avoir un passage séquentiel pour cet ensemble. Dans le cas de fichiers séquentiels la lecture et la recopie de tous les enregistrements seront nécessaires.

On sépare alors les descripteurs des enregistrements logiques qu'ils décrivent. Les descripteurs sont regroupés sur un fichier descripteur et les groupes de données utilisés pour la mise à jour du fichier sont enregistrés les uns à la suite des autres sur le fichier des données qui est un fichier hybride.

Le descripteur traduit toujours la structure de l'enregistrement logique. Il traduit cette structure avec une finesse au moins égale à la catégorie des groupes de données qui servent pour la mise à jour. C'est-à-dire que si un groupe donné est un examen cardiologique par exemple, on ne trouvera pas dans le descripteur la structure interne de l'examen cardiologique, mais seulement le code de la catégorie syntaxique "Examen cardiologique" avec la référence permettant de retrouver dans le fichier des données, ce groupe de données. Si par contre, le groupe de données est plus fin ou plus synthétique, on trouvera dans le descripteur mention d'information plus ou moins fine. Il faut alors rester dans un juste milieu.

Le descripteur ne doit pas être composé de catégories syntaxiques trop fines sous peine de voir les enregistrements de ce fichier devenir trop conséquents et de ne pouvoir être exploité dans des conditions satisfaisantes.

Dans l'autre sens un descripteur trop pauvre en informations permet rapidement de trouver un groupe de données, mais ce groupe de données risque d'être trop important pour pouvoir être exploité avec profit.

Enfin, on peut dire que le principe de tout ceci est indépendant du système sur lequel on travaille. Seul le système de clés de référence et les opérations de "nettoyage" dépendent du système avec lequel on opère.

Fichier descripteur

Fichier hybride des données

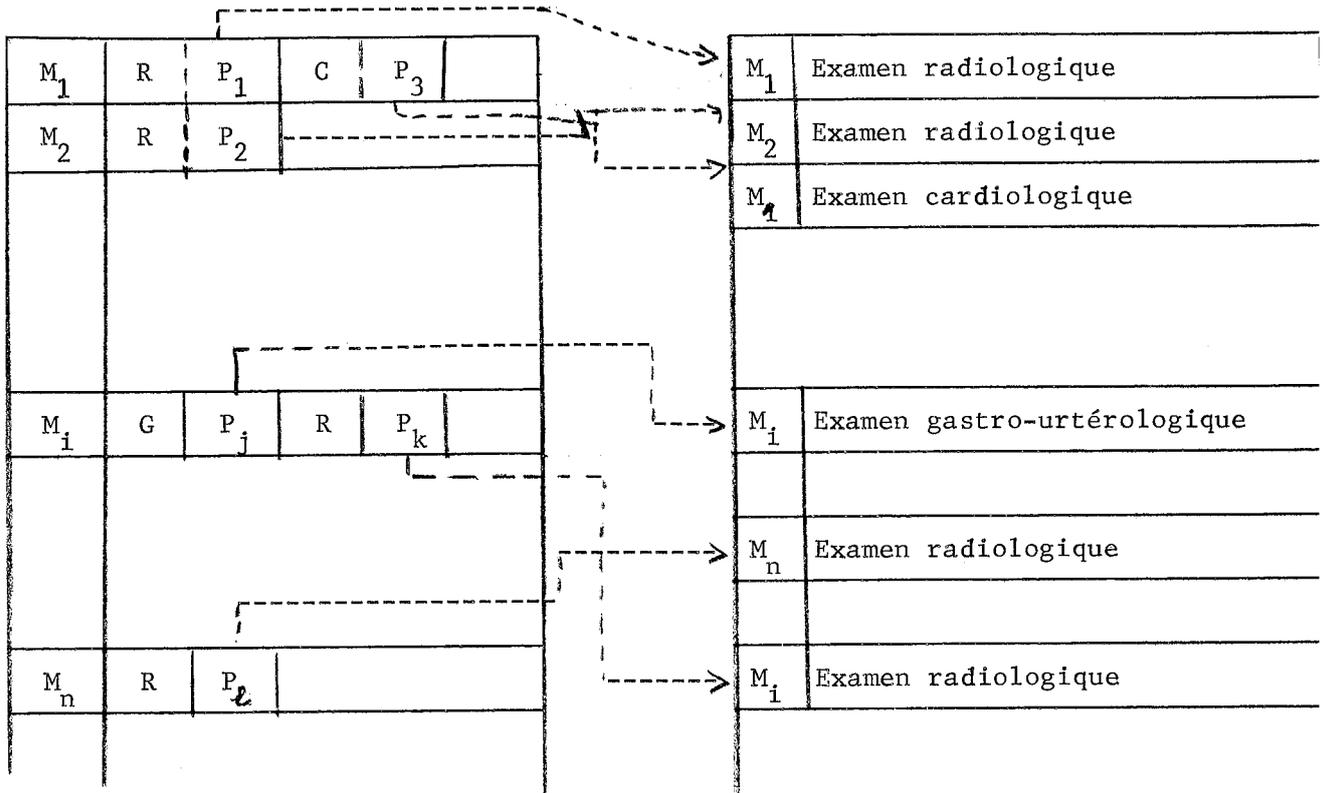


FIGURE 3.II.4

M_i représente le malade i .

Les nombres à droites des enregistrements du fichier des données représentent les numéros de séquence logique des enregistrements hybrides.

Enfin, outre le fait qu'il faut maintenant deux fichiers au lieu d'un, la recherche d'un enregistrement à partir du fichier descripteur entraîne toute une série de recherches dans le fichier des données.

Ce genre d'organisation apparaît donc souhaitable pour des fichiers dont les enregistrements sont suffisamment volumineux pour qu'un enregistrement soit inexploitable à la main et par conséquent pour faire une recherche sélective de groupes donnés à l'intérieur de l'enregistrement.

3.II.2. - Traitement du fichier des dossiers médicaux

3.II.2.1. - Documentation automatique

La figure 3.II.4 suffit à expliquer comment se fait la documentation automatique sur le fichier :

- si l'on recherche certains renseignements dans le dossier d'un malade M_i
 - a) on ira chercher dans le fichier descripteur, l'enregistrement relatif à ce malade. Cet enregistrement fournira une liste de couples de données. Le premier élément de chaque couple (le code d'une certaine catégorie syntaxique) devra permettre de savoir si l'enregistrement référencé par le pointeur (deuxième élément du couple) est susceptible ou non de contenir le renseignement cherché. L'enregistrement descripteur d'un dossier médical permet une recherche sélective parmi les groupes logiques de données qui constituent le dossier médical.
 - b) Enfin, la recherche se poursuivra dans chacun des groupes logiques de données du fichier de données.

Exemple :

Si l'on recherche le diagnostic de l'examen cardiologique du malade M_1 (fig.3.II.4), l'examen de l'enregistrement correspondant au malade M_1 dans le fichier descripteur indiquera qu'il doit examiner le troisième enregistrement logique du fichier des données.

- l'organisation de la figure 3.II.4 permet également de répondre au deuxième genre de question posée en documentation automatique.
 - a) en recherchant d'abord dans le fichier des données l'ensemble des malades dont le dossier contient un certain renseignement.
 - b) Puis en remontant au fichier descripteur.

Exemple :

Sortir le diagnostic de l'examen cardiologique des malades qui se sont cassés le tibia.

- on recherchera d'abord toutes les fractures du tibia dans le fichier des données ce qui permettra d'avoir la référence de ces malades.
- on cherchera à l'aide du fichier descripteur le diagnostic des examens cardiologiques subis par ces patients (ceci est à nouveau une question du premier type).

Fichier descripteur

M ₁	R	P ₁	C	P ₃	
M ₂	R	P ₂	G	P ₁₊₁	
⋮					
M _i	G	P _j	R	P ₁	
⋮					
M _k	R	P _k			
M _{n+1}	C	P ₁₊₂			
⋮					

Fichier hybride des données

M ₁	
M ₂	
M ₁	
⋮	
M _i	
⋮	
M _n	
⋮	
M _i	
M ₂	
M _{n+1}	

Mise à jour du
fichier descrip-
teur

UPDTE

PRECR

Reconnaissance des groupes
de données

Entrée des groupes de
données (par télétypes ou bandes)

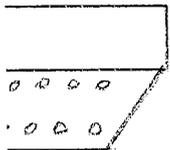


FIGURE 3.II.5

3.II.2.2. - La mise à jour

1° - Les données brutes sont entrées soit par l'intermédiaire d'une bande ou d'un lecteur de cartes, soit au clavier.

Dans l'exemple de la radiologie, il s'agit pratiquement de la description d'examens radiologiques.

2° - Ces données sont reconnues par le programme PRECR (Programme de REConnais- sance Radiologique). Ce programme a plusieurs fonctions simples.

- Tout d'abord il reconnaît les éléments du groupe logique de données.

Dans le cas présent, ce programme séparera les informations comptables et de gestion des informations de nature médicale.

Il activera les programmes d'analyse de phrases écrites en langage normalisé.

Ce programme a deux types de résultats.

1° - La production d'informations correctes telles qu'on désire les enregistrer dans le fichier hybride des données.

2° - La production du code de la catégorie syntaxique qu'il vient de reconnaître et l'identité du malade.

Exemple :

Dans le cas du fichier radiologique ce programme vérifiera seulement que les groupes logiques de données sont bien des examens radiologiques.

3° - Le code produit par le programme PRECR, l'identité du malade et le pointeur sur le premier enregistrement libre sont transmis à un programme UPDTE, alors que les informations issues du groupe logique d'entrée sont recopiées en séquence dans le fichier hybride.

4° - Le programme UPDTE est le programme de mise à jour proprement dit.

Ce programme recherche si le malade existe dans le fichier descripteur.

Si oui (1er cas de la figure 3.II.5) on met à jour l'enregistrement descripteur correspondant. Cette mise à jour est maintenant simplifiée car elle ne porte que sur une structure dont les données élémentaires sont des codes faciles à manipuler.

Si non (2ème cas de figure avec le malade M_{n+1}) on crée l'enregistrement descripteur du nouveau malade.

Cette organisation appelle un certain nombre de remarques :

- les deux programmes UPDTE et PRECR sont indépendants l'un de l'autre. Leur seul lien est un code fournit par PRECR.
- UPDTE dépend de l'organisation du fichier descripteur alors que PRECR dépend de l'organisation choisie pour le fichier hybride.
- la relative simplicité de cette organisation se paie par un programme de NETTOYAGE assez lourd.

3.II.2.3. - Programme de NETTOYAGE

Lorsqu'un malade quitte le centre hospitalier, il n'est plus nécessaire de garder son dossier au milieu des dossiers des malades présents.

L'organisation de la figure 3.II.4 ne permet pas d'enlever le dossier du malade pour regagner simplement de la place sur le fichier hybride. En effet, cette manipulation nécessite soit l'implantation d'un système de pointeurs pour gérer l'espace libre du fichier hybride, soit la recopie du fichier hybride et la remise à jour du système des pointeurs du fichier descripteur.

La première méthode paraissait assez complexe à mettre en oeuvre et ôtait du même coup la simplicité de l'écriture sur le fichier hybride et l'intérêt d'avoir un enregistrement descripteur.

La seconde méthode, celle de recopie du fichier hybride avec mise à jour du système des pointeurs du fichier descripteur ne peut pas être envisagé pour un seul malade.

La solution adoptée est la suivante :

On utilisera la seconde méthode seulement quand il y aura un nombre suffisant de patients qui sont partis ; pendant ce temps, leurs dossiers seront marqués "désactivés".

La procédure de nettoyage se passera comme suit et l'organisation des fichiers et des programmes sera de même type que celle décrite figure 3.II.5.

- le fichier hybride aura le rôle du fichier d'entrée.
- le programme PRECR est remplacé par un programme plus simple PRECG qui n'a pas besoin de reconnaître les données d'entrées mais seulement de regarder si elles font partie ou non d'un dossier désactivé.

Si oui, la donnée est perdue

Si non, la donnée est réécrite, sa catégorie syntaxique donnée à UPDTE qui reconstitue le descripteur au fur et à mesure de la même manière que pour la mise à jour.

Ceci n'est pas forcément la meilleure méthode, on pourrait à l'aide de l'ancien descripteur regrouper les enregistrements d'un même patient sur le fichier hybride par exemple. Il faut alors pouvoir déterminer si l'augmentation de temps due à une manipulation de tout un fichier en accès direct est justifiée par un gain de temps dans l'exploitation ultérieure du fichier.

C O N C L U S I O N

Ce travail ne prouve pas que l'on puisse appliquer à tous les domaines médicaux la méthode de description des informations qui vient d'être présentée. Cependant sa mise en oeuvre dans le domaine restreint des demandes d'examen radiologique ne nuit pas à sa généralité.

En effet, il est possible d'utiliser cette méthode pour décrire certaines informations d'un domaine particulier si les deux conditions suivantes sont vérifiées :

- 1° - Il faut pouvoir tirer de l'examen d'un nombre suffisant d'informations les divers concepts auxquels on s'intéresse ainsi que les relations logiques qui les lient.
- 2° - Il faut ensuite pouvoir créer une grammaire hors-contexte (ou bien d'états finis) qui traduise avec une approximation jugée suffisante ces relations.

Un tel travail de mise en place dépend essentiellement du domaine d'information dont on s'occupe ; ce travail a été facile en radiologie, mais nous savons qu'il sera plus délicat pour exprimer les diagnostics par exemple.

Actuellement, le choix des concepts retenus dans un domaine d'information, la création de la syntaxe normalisée sont des opérations subjectives. Bien que le système supporte facilement des modifications et permette des améliorations issues de l'expérience, il serait certainement intéressant de pouvoir s'aider d'un modèle permettant d'introduire une certaine rigueur dans l'analyse des informations, puis dans la phase de création de la syntaxe normalisée [15].

Ce modèle de description des informations a été créé initialement pour permettre, dans le cadre d'un système d'exploitation plus vaste, le stockage de toutes les informations produites par les médecins. Les informations ainsi stockées devaient pouvoir être exploitées dans l'immédiat à des fins documentaires. La méthode documentaire développée au chapitre 2 ne doit sa simplicité que grâce au fait que la grammaire est équivalente à une grammaire d'états finis. Il s'avèrera certainement nécessaire dans l'avenir de renoncer au mode d'exploitation linéaire des formes internes tel qu'il a été défini. Cependant la forme adoptée pour stocker les informations n'influe nullement sur la description du fichier médical qui a été proposée. Cette description est très incomplète, car aucune implantation réelle n'a été faite ni aucune étude de coût d'exploitation n'a pu être menée. La création de la méthode de gestion d'un dossier important nous a cependant conduit à revoir les notions de fichier et d'enregistrement utilisées par les langages de programmation tels PL1 ou COBOL par exemple. Un tel besoin d'élargir les notions d'enregistrement et de fichier s'est déjà fait sentir depuis un certain temps [22], il apparaît souhaitable d'intégrer des outils de description plus riches dans les langages de programmation.

Il ne faut donc voir, à travers la mise en oeuvre du système dans le domaine radiologique, que la présentation d'une méthode d'indexation automatique des informations plus souple d'emploi et plus riche que les méthodes classiques utilisant les mots clefs par exemple. Il faut noter que cette méthode

ne diffère des méthodes nouvelles permises par les systèmes conversationnels que dans le choix des moyens employés pour permettre une certaine richesse sémantique des informations.

Alors que les systèmes conversationnels tirent leur richesse sémantique du dialogue imposé à l'utilisateur pour lui faire préciser sa pensée de proche en proche, le système que l'on vient de décrire essaie de tirer la sienne d'un outil assez souple et riche en lui-même, pour permettre à l'utilisateur de s'exprimer en une seule fois.

BASES COMMENCANT PAR: A

(ABCEDEGRAPHIE)	10	1
(ABDOMIN)	20	0
(ABDOMEN)	20	1
(ACROMI)	20	0
(AGRANDISSEMENT)	14	1
(AILE)	22	1
(AMNICGRAPHIE)	10	1
(ANGI)	22	0
(ANTER)	03	0
(ANNULAIRE)	20	1
(ACRT)	20	0
(APCPHYSE)	22	1
(APPAREIL)	22	1
(ARC)	22	1
(ARCADE)	22	1
(ARCELIN)	12	1
(ARTER)	22	1
(ARTHR)	22	0
(ARTICULAIRE)	22	1
(ARTICULATION)	22	1
(ASCENDANT)	03	1
(ASSIS)	30	1
(ASTRICAL)	20	1
(ATLAS)	20	1
(ATL)	20	2
(AURICULAIRE)	20	1
(AVANT-ERAS)	20	1
(AVEC)	9	1
(AXILLAIRE)	20	1
(AXIS)	20	1
(AXIAL)	14	1
(AGE-OSSEUX)	10	1

BASES COMMENCANT PAR: C

(CAISSE)	22	1
(CALCANEUM)	20	1
(CAN)	22	1
(CARDIA)	20	1
(CARDIAQUE)	20	1
(CARDIC)	20	2
(CARDIC-TUBERCULAIRE)	20	1
(CARCTIC)	20	0
(CAFF)	20	1
(CATETERISME)	31	1
(CARTILAGE)	22	1
(CARTILAGIN)	22	1
(CAVITE)	22	1
(CAV)	20	0
(CEINTURE)	22	1
(CENTRE-SUR)	13	1
(CEREER)	20	0
(CERVEAU)	20	1
(CERVIC)	20	0
(CHAUSSE-II)	12	1
(CHAUSSE-III)	12	1
(CHAFNIERE)	22	1
(CHEVILLE)	20	1
(CINECENSIGRAPHIE)	10	1
(CHCLANGI)	20	0
(CHOLECYST)	20	0
(CINQUIEME)	04	1
(CHOLEDOQUE)	20	1
(CLAVICUL)	20	0
(CLICHE)	14	1
(CLICHE-RETARD)	14	1
(CLINOIDE)	20	1
(COCCYX)	20	1
(COECC)	20	2
(COECUM)	20	1
(COELIAQUE)	20	1
(COEUR)	20	1
(COL)	22	1
(COLLIQUE)	20	1
(COLE)	20	2
(COLLEN)	20	1
(COLONNE)	22	1
(COMPARAT)	14	1
(COMPRESSION)	31	1
(CONDUIT)	22	1
(CONDYL)	20	1
(CONTRASTE)	32	1
(CORPS-ETRANGER)	14	1
(COPEN)	20	0
(CORONAIRE-STOMACHIQUE)	20	1
(COST)	20	0
(COU)	20	1
(COLICHE)	30	1
(COUDE)	20	1

(COURSE)
(COX)
(CYCLOIDE)
(C)

03 1
20 0
14 1
20 1

BASES COMMENCANT PAR: D

(DEUXIEME)	04	1
(DEBUT)	30	1
(DECUBITUS)	30	1
(DEFERENT)	20	2
(DIPLOGRAPHIE)	10	1
(DIRECT)	03	1
(DISC)	22	0
(DISQUE)	22	1
(DIGIT)	20	1
(DGS)	20	1
(DORS)	20	0
(DUELE)	03	1
(DRCIT)	03	1
(DUCCENUM)	20	1
(DENT)	20	1
(DIDIEE)	12	1
(DOSE)	31	1
(D)	20	1
(DE-FACE)	14	1
(DIXIEME)	04	1
(DOUZIEME)	04	1

BASES COMMENCANT PAR: E

(EGAILLE)			22	1
(ECRAN)			14	1
(ELECTROKIMOGRAPHIE)			10	1
(ENCEPHAL)			20	0
(EPAULE)			20	1
(EPREUVE)			03	1
(EPINE)			22	1
(EPICUR)			20	1
(ESTOMAC)			20	1
(ET)	1	1		
(ETAGE)			22	1
(ETHMOIDE)			20	1
(EXAMEN)			03	1
(EXTERNE)			03	1

BASES COMMENCANT PAR: F

(FACE)	20	1
(FACI)	20	1
(FEMUR)	20	1
(FEMOR)	20	0
(FENTE)	22	1
(FILM)	14	1
(FISTUL)	22	0
(FCIE)	20	1
(FUNCTIONNELLE)	14	1
(FRONT)	20	0
(FRONTAL)	14	1

BASES COMMENCANT PAR: G

(GALACT)	20	0
(GALACTOPHORE)	20	1
(GANGLION)	22	1
(GANGLIENNAIRE)	22	1
(GASTR)	20	0
(GAUCHE)	03	1
(GAZEL)	31	1
(GENCL)	20	1
(GLANCE)	22	1
(GLANDELLAIRE)	22	1
(GLENCIDE)	20	1
(GOLTTIERE)	22	1
(GRANE)	04	1
(GRANE-CS)	20	1
(GRAFFIE)	10	1
(GRELE)	03	1
(GFCG)	04	1
(GRESSESSE)	20	1

BASES COMMENCANT PAR: H

(FANCHE)	26	1
(HARTMANN)	12	1
(FALT)	02	1
(HAUTE-TENSION)	14	1
(HEPAT)	20	0
(HUITIEME)	04	1
(HIL)	20	1
(HIRTZ)	12	1
(HISTORADIOGRAPHIE)	10	1
(HORIZONT)	03	1
(HUMER)	20	0
(HUMERUS)	20	1
(HYDROPHYS)	20	1
(HYDROLOGIE)	31	1
(HYSTER)	20	0

BASIC COMMERCANT PREFIX I

{ILE}	25	0
{ILECN}	20	1
{ILTACLE}	20	1
{ILI}	20	0
{ILICN}	20	1
{INCE}	25	1
{INFERIEUR}	03	1
{INFUN(TIBULUM)}	22	1
{INGESTION}	31	1
{INJECTION}	31	1
{INSPIRATION}	30	1
{INSUFFLATION}	31	1
{INTERNE}	02	1
{INTESTIN}	20	0
{INTRA-ARTERIELLE}	32	1
{INTRA-ARTICULAIRE}	32	1
{INTRA-MUSCULAIRE}	32	1
{INTRA-RACHIDIEN}	32	1
{INTRA-VEINEUX}	32	1
{INTERLIGNE}	22	1
{ICEE}	32	1
{ISCHIATIQUE}	20	1
{ISCHIC}	20	2
{ISCHICN}	20	1

BASES COMMENCANT PAR: J

(JEJLN)	20	0
(JEJUNM)	20	1

BASES COMMENCANT PAR: K

(KYNE(CRAPHIE)	10	1
(KYST(CRAPHIE)	10	1

BASES COMMENCANT PAR: L

(LACRYM)	20	1
(LAME)	22	1
(LAME-CRIBLEE)	20	1
(LANGU)	20	1
(LATER)	03	0
(LAVEMENT)	31	1
(LARYNG)	20	0
(LARYNX)	20	1
(LIT)	14	1
(LOCALISATION)	14	1
(LCGE)	22	1
(LCMB)	20	0
(L)	20	1
(LYMPHOGRAPHIE)	10	1
(LACUEFRIERE)	12	1

BASES COMMENCANT PAR: M

(MAIN)	20	1
(MAJEUR)	20	1
(MALAIRE)	20	1
(MALLECLE)	22	1
(MANN)	20	0
(MASSIF)	22	1
(MASTICIDE)	20	1
(MAXILL)	20	0
(MAYER)	12	1
(MECIAN)	03	1
(MECIASTIN)	20	0
(MEMBRE)	20	1
(MENTON)	20	1
(MENTONNIERE)	20	1
(MESETER)	20	0
(MESLFE)	03	1
(METACARP)	20	0
(METATARS)	20	0
(MANCELVRE)	31	1
(METRIE)	10	1
(MITION)	31	1
(MITIONNELLE)	31	1
(MODIFICATEUR-DE-COMPORTEMENT)	31	1
(MOYEN)	03	1
(MYEL)	20	0

BASES COMMENCANT PAR: 0

{CBLIQUE}	11	1
{CCCIPUT}	20	1
{CCCIPJT}	20	0
{CCONTICIDE}	20	1
{CEIL}	20	1
{DESCRIFAG}	20	0
{CLECCRANE}	20	1
{CMCPLATE}	20	1
{CPACIFIANT}	31	1
{CPACIFICATION}	31	1
{CPAGLE}	32	1
{CPERE}	03	1
{CPTIGLE}	20	1
{CRBIT}	20	0
{CREILLE}	20	1
{CRGANE}	22	1
{CRTEJL}	20	1
{CRTHCCIAGRAMME}	10	1
{CS}	22	1
{CNZIEME}	04	1
{CS-CPCCPU}	20	1
{CS-PYCIDE}	20	1
{CSSELET}	20	1

BASES COMMENCANT PAR: P

(PALAIS)	20	1
(PALATIN)	20	1
(PANCREAS)	20	1
(PANCREAT)	20	0
(PARIET)	22	0
(PAROTIDE)	20	1
(PARTIES-MOLLES)	22	1
(PELV)	20	1
(PELVIS)	20	1
(PERFLUSION)	31	1
(PERICARDE)	20	1
(PERITON)	20	1
(PERICNEE)	20	1
(PHALANGE)	22	1
(PHALANGETTE)	22	1
(PHALANGINE)	22	1
(PHARYNG)	20	0
(PHARYNX)	20	1
(PHLEB)	20	2
(PREMIER)	04	1
(PIEC)	20	1
(PINE)	20	0
(PISIFORME)	20	1
(PLACENT)	20	2
(PLAN)	14	1
(PLANTIGRAPHIE)	10	1
(PLEUR)	20	1
(PLEVRE)	20	1
(PNEUMC)	20	2
(POIGNET)	20	1
(POINCTION)	31	1
(PORT)	20	0
(POSTER)	03	0
(POUCE)	20	1
(POMON)	20	1
(PRIMITIVE)	03	1
(PREPARATION)	31	1
(PROCEUTUS)	30	1
(PROCLIT)	31	1
(PROFIL)	11	1
(PLUS)	8	1
(PAR)	9	1
(PLIS)	7	1
(PROSTATE)	20	1
(PTERYGOICE)	20	1
(PUE)	20	1
(PUEIS)	20	1
(PULMONAIRE)	20	1
(PUBIS)	20	1
(PYEL)	20	2
(PYRAMICAL)	20	1
(PNEUMC-PERITICINE)	31	1

BASES COMMENCANT PAR: C

(QUATRIEME)	04	1
(QUATREZIEME)	04	1
(QUINZIEME)	04	1

BASES COMMENCANT PAR: R

(RACHIE)	20	0
(RACHIS)	20	1
(RACI)	20	1
(RACICLL)	20	2
(RACICGRAPHIE)	10	1
(RACIC-CINEMA)	10	1
(RACICMANOMETRIE)	10	1
(RACICMENSURATION)	10	1
(RACICFELVIMETRIE)	10	1
(RACICPHOTOGRAPHIE)	10	1
(RACIESCOPIE)	10	1
(RACICSTEREOGRAPHIE)	10	1
(RACILS)	20	1
(RATF)	20	1
(REIN)	20	1
(REN)	20	1
(RECHERCHE-DE-CORPS-ETRANGER)	10	1
(RETRCGRACE)	31	1
(RETRC)	03	2
(RHINC)	20	2
(RCHFF)	20	1
(RCTATION)	31	1
(RCTLL)	20	1
(REPAS)	31	1

BASES COMMENCANT PAR: S

(SACR)			20	0
(SACRUM)			20	1
(SAGIT)			02	1
(SALFETRIERE)			12	1
(SALFINGO)			25	2
(SCANOGRAPHIE)			10	1
(SANS)	S	1		
(SCUS)	S	1		
(SCAFFOIDE)			20	1
(SCAFUL)			20	0
(SCHECK)			12	1
(SCHULLER)			12	1
(SEMI-LUNAIRE)			20	1
(SEMINALE)			20	1
(SELECT)			14	1
(SERIE)			14	1
(SEFIGRAPHIE)			10	1
(SEPTIEME)			04	1
(SCUS-CCCIPITAL)			32	1
(SPHENC)			20	2
(SPHENIC)			20	1
(SPLEN)			20	0
(SGUELETTE)			20	1
(STANDARD)			14	1
(STENVERS)			12	1
(STEREORADIOGRAPHIE)			10	1
(STERN)			20	0
(STERNLM)			20	1
(STRATIGRAPHIE)			10	1
(STYLC)			20	2
(STYLCIC)			20	1
(SUB-LINGU)			20	1
(SUCCRADIOGRAPHIE)			10	1
(SUPER)			03	0
(SUFFEN)			20	1
(SYMPHYSE)			22	1
(SIAL)			20	2
(SINCS)			22	1
(SINCS-GAVERNEUX)			20	1
(SCMPET)			22	1
(SCUS-(LAVIERE)			20	1
(SCUS-(UTANEE)			32	1
(SIXIEME)			04	1

BASES COMMENCANT PAR: T

{TREIZIEME}	04	1
{THORACIQUE}	20	1
{THORAX}	20	1
{THYMUS}	20	1
{THYFCID}	24	1
{TIEIA}	20	1
{TIBI}	20	0
{TCMCCGRAPHIE}	10	1
{TCT}	32	1
{TRACHE}	20	0
{TRAITEMENT}	31	1
{TRANSOSSEUX}	32	1
{TRAPEZE}	20	1
{TRAPEZCICE}	20	1
{TRENCELENBURG}	30	1
{TROIS-QUART}	11	1
{TRENQ}	20	1
{TROU}	22	1
{TRCU-DECHIRE}	20	1
{TRCU-GRAND-RENQ}	20	1
{TRCU-VALE}	20	1
{TRCU-PETIT-RENQ}	20	1
{TUEAGE}	31	1
{TUBERCOSITE}	22	1
{TRCISIEME}	04	1
{TARS}	20	1
{TECHNIQUE}	14	1
{TELERADIOGRAPHIE}	10	1
{TEMPCR}	20	0
{TESTICULE}	20	1
{TETE}	20	1
{TEMPE}	20	1

BASES COMMENCANT PAR: U

(LRETR)	20	0
(LRETR)	20	0
(URCENCE)	03	1
(URCENT)	03	1
(LTERIN)	20	1
(LTERLS)	20	1
(UR)	20	2

BASES COMMENCANT PAR: V

(VAISSEAU)	22	1
(VALSALVA)	22	1
(VALVE)	22	1
(VALVULE)	22	1
(VASCULAIRE)	22	1
(VEIN)	22	1
(VENTRICUL)	20	0
(VERTEBR)	20	1
(VESICLL)	20	0
(VESSIE)	20	1
(VOMER)	20	1

BASES COMMENCANT PAR: W

(WCFMS)

12 1

LISTE DES BASES UTILISEES EN RADIOLOGIE

BASES COMMENCANT PAR: B

(EAS)	03	1
(EASSE)	03	1
(EASE)	27	1
(EASSIN)	20	1
(BILIAIRE)	20	1
(BLONDEAU)	12	1
(BOEHLER)	12	1
(BOUCHE)	20	1
(BOUCHE-DE)	22	1
(BRACHI)	20	0
(BRACHIO-CEPHALIQUE)	20	1
(BRANCHE)	22	1
(ERAS)	20	1
(BRONCH)	20	0
(BULLE)	22	1

BASES COMMENCANT PAR: N

(NEUVIEME)	04	1
(NAS)	20	0
(NEPR)	20	2
(NERF)	22	1
(NERV)	22	1
(NEZ)	20	1

BASES COMMENCANT PAR: Y

(YEUX)

20 1

BASES COMMENCANT PAR: Z

(ZYGMATIQUE)

20 1

B I B L I O G R A P H I E

[1] J.J. BERNIER, VIDON et J. MASSELOT

Etude des contraintes de divers systèmes d'entrée des informations
d'après 500 dossiers de gastro-entérologie.

Symposium de Toulouse, pp. 301-320

P. DENOIX

L'électronique instrument de la logistique hospitalière.

Technique hospitalière n° 259, avril 67
n° 265, oct. 67

TUBIANA et D. SCHWARTZ

Problèmes posés par la recherche en informatique médicale.

Symposium consacré à la Radiologie
18-19 Novembre 1967

B. KEMPF compagnie I.B.M.

Rapport Hoptimis

I.B.M. FRANCE, Juin 1966

Pf GEINDRE, Dr VALOIS, service de Radiologie du C.H.R. de Grenoble

BACH, compagnie I.B.M.

Utilisation d'un petit ordinateur dans un service de radiodiag-
nostic.

W. Mc CREIGHT, Directeur du Centre Médical UNIVAC international de STOCKHOLM

Gestion hospitalière en temps réel

Symposium de Toulouse, Mars 1968

Compagnie I.B.M.

Shared Hospital Accounting system (S.H.A.S.)

L. CHEVROT

Méthodes d'exploitation et de stockage du dossier radiologique

Bulletin d'Informatique Médicale
2ème année, n° 1, pp. 21-22

B.2.

R.AMIEL et M. de HAULME

Le recueil et le traitement des informations en psychiatrie.
Symposium de Toulouse, pp. 343-360

J.P.BROUSTET

Classement, mise à jour et interrogation automatique des dossiers médicaux stockés sur ordinateur.
Symposium de Toulouse, pp. 361-378

[2] J.J. BERNIER et B. KEMPF

Le traitement des dossiers médicaux par ordinateur.
Le cours médical n° 1, 1967

[3] Compagnie I.B.M.

Questionnaires for preventive and internal Medecine
Department for medical information
Karlinska sjukhuset - Stockholm

[4] Committee of nomenclature and classification disease.

Systematized Nomenclature Pathologic.

[5] Ph. DUQUESNEL et F. PECCOUD

Langage artificiel en radiologie - Fichiers hybrides
Communication A.F.I.R.O., Nancy 1967

Pr SCHNEIDER

Exploitation d'un dossier médical en pédiatrie.
Communication présentée à UPSALA
Octobre 1968

[6] Compagnie I.B.M.

I.B.M. System/360 - PL1/Reference Manual
File n° 536029
Form n° C 28-8201-1

[7] H.P. LUHN

Keyword in Context for technical litterature (Kwic-Index),
I.B.M. Corporation, Advanced System,
Development Division, Yorktown Height,
New York, Report RC-127, 1959.

- [8] B. VAUQUOIS
Le système de traduction automatique du C.E.T.A.
C.N.R.S., Février 1967
- [9] D. AUGEREAU
Utilisation des informations sémantiques en traduction automatique
Thèse présentée à l'Université de Grenoble
Octobre 1962
- [10] M. COYAUD
Analyse morphologique en documentation automatique
C.N.R.S., art. 22, 1964
Problèmes d'analyse automatique de documents
C.N.R.S., Mai 1967
- M. LESK
The SMART System
Information storage and Retrieval
Scientific Report n° ISR to the national
Foundation, December 1964
- G. SALTON
A document Retrieval System for Man-Machine Interaction
Proceedings of the 19 th ACM annual
Conference, Philadelphie, 1964
- J.C. GARDIN, F. LEVY
Le SYNTHOL
Proceedings I.F.I.P. Congress, 1962
- [11] M.E. MARON et R. LEVIEN
Relationnal data file, a tool for mechanized inference
execution and data retrieval.
The Rand Corporation R.M.-4793-PR,
Dec. 1965.
- [12] B. VAUQUOIS
Cours de Logique et programmation,
Tomme III : Théorie des langages
Cours Polycopié - Université de
Grenoble
- N. CHOMSKY
Formal properties of grammars
Hand book of Mathematical Psychology, vol. 2, dec. 1959

S. GINSBURG

The mathematical Theory of Context-Free Languages

Mc Graw Hill, 1966

- [13] L. BOLLIET, N. GASTINEL et P.J. LAURENT
Un nouveau langage scientifique ALGOL,
Manuel pratique, Hermann, Paris, 1964
- [14] M. GROSS et A. LENTIN
Notions sur les grammaires formelles.
- [15] J.R. ABRIAL, G. BEAUME, G. HENNERON, B. LEPAPE, R. MORIN et G. VIGLIANO
Système de définition et d'interrogation de données.
Communication interne à l'I.M.A.G.
avril, 1969
- [16] DELACROIX, EPSTEIN, LOUMENA
Analyse morphologique du substantif et de l'adjectif français.
C.N.R.S., C.E.T.A., Doc. G-1501-2
- [17] G. VEILLON
Consultation d'un dictionnaire et analyse morphologique en traduction automatique.
Thèse présentée à l'Université de Grenoble
- TREHEL
Contribution à la théorie des catalogues
C.N.R.S., Doc. C.E.T.A., Grenoble
Etude des treillis de catalogues
R.I.R.O., 1ère année, N° 4, 1967, pp.39-4
- [18] G. DAGAND
Documentation sur une banque de données de statistiques nationales.
Rapport final d'un contrat supporté par
la D.A.T.A.R., octobre 1968
- [19] L. BOLLIET
Notation et processus de traduction des langages symboliques.
Thèse présentée à l'Université de Grenoble
Juin, 1967

- [20] M. GRIFFITHS et M. PELTIER
Grammar transformation as an aid to compiler
Communication interne à l'I.M.A.G.
- [21] COBOL 61 Extended
Report to conference on data systems languages
- [22] G. DAGAND
Langage d'implémentation de fichiers évolutifs, "The Life project"
File 1968, Copenhague, novembre 1968

VU

Grenoble, le

Le Président de la Thèse

VU

Grenoble, le

Le Doyen de la Faculté des Sciences

Vu, et permis d'imprimer,

Le Recteur de l'Académie de GRENOBLE