

I LE CHEMINEMENT CONCEPTUEL

Une fois fixés les objectifs et le cadre de la démarche souhaitable, nous exposons dans ce chapitre le cheminement conceptuel qui nous a amené à choisir le thème de la robustesse des systèmes d'aide à la description, à la classification et la détermination des objets biologiques pour cette thèse.

L'élaboration de notre approche est le fruit d'une démarche expérimentale bénéficiant de plusieurs expériences sur le terrain "en vraie grandeur". Nous retraçons maintenant l'historique de celles-ci afin de faire ressortir les points importants à retenir pour justifier notre méthode d'acquisition des connaissances et mettre en valeur notre conception de la robustesse.

1.1 Les systèmes experts à l'INRA

L'INRA (Institut National de la Recherche en Agronomie) a développé quinze systèmes experts spécialisés dans le diagnostic des maladies des plantes : le projet SEPV¹ [Le Renard, 1988]. Par exemple, TOM est le premier système expert en agriculture de cette série [Blancard *et al.*, 1985]. Il détermine les maladies des tomates sur ordinateur ou Minitel à partir de la description des symptômes par les agriculteurs ou techniciens agricoles. En 1986, tous ces systèmes fabriqués par un couple "cogniticien-expert" étaient à l'état de prototypes avancés, et l'INRA a alors décidé de les tester sur le terrain afin d'évaluer leur fiabilité entre les mains des utilisateurs de la profession agricole. Étant alors en troisième année d'une école d'ingénieurs en agriculture (l'ISARA : Institut Supérieur d'Agriculture Rhône-Alpes), et attiré par les systèmes experts sans avoir la compétence informatique pour en développer, nous avons proposé un stage de longue durée à l'INRA sur le thème de l'*utilisation*, afin de confronter l'offre et la demande. Le but était d'analyser l'impact socio-économique des systèmes experts dans le milieu agricole et de proposer des solutions d'adaptation de ces systèmes à leurs utilisateurs. Nous avons pu ainsi expérimenter pendant 10 mois cinq systèmes experts sur le terrain (le blé, la betterave, le pêcher, la tomate et l'œillet) et proposer une étude plus approfondie sur le système œillet [Conruyt, 1986]. Lors d'un mémoire de fin d'études de l'ISARA en 1987, dans le cadre d'un autre projet sur l'apprentissage automatique des maladies de la tomate (INSTIL § 1.2), nous avons pu mettre au point par écrit une méthode d'acquisition des connaissances descriptives en

¹ Systèmes Experts en Pathologie Végétale.

pathologie végétale qui tient compte des différents intervenants dans la chaîne du diagnostic [Conruyt & Piaton, 1987]. Ces écrits ont rassemblé nos premières spécifications pour des travaux sur la robustesse.

1.1.1 Bien définir la cible des systèmes experts

Une connaissance du terrain pour établir quelle est la chaîne du diagnostic pour chaque culture est primordiale. Cette chaîne fait intervenir trois catégories de personnes avec des niveaux de raisonnement et de souhait différents :

1.1.1.1 Les experts

Ils reçoivent une grande quantité d'échantillons à chaque campagne culturale (ex : 300 cas pour la tomate en 1987), ils raisonnent principalement à partir des symptômes sur la plante. Leur vision des symptômes s'effectue à une échelle d'observation individuelle. Elle est variée et pointue, car s'appuyant sur des observations à la loupe binoculaire et au microscope. Cette vision leur fait adopter un vocabulaire très spécifique et difficile à communiquer aux autres utilisateurs. Par exemple, le concept de nécrose porte une information non explicitée liée au dessèchement des tissus atteints, à leur couleur brune et à leur limite bien distincte, ceci vu à la loupe binoculaire [Blancard, 1988].

Les experts sont intéressés par tous les outils d'aide qui leur permettent d'accélérer le diagnostic et de le rendre plus fiable, de se décharger du travail de routine (filtrage des cas "sans intérêt"). Ils recherchent aussi tout ce qui peut leur permettre d'approfondir leurs connaissances, ou d'élargir leur domaine de compétence au delà de leur propre spécialité.

1.1.1.2 Les techniciens ou conseillers agricoles

Contrairement aux experts, ils sont constamment en contact avec les agriculteurs par les suivis d'exploitation, le recueil d'échantillons de plantes malades. Ils ont une meilleure connaissance de l'itinéraire technique de la culture et du contexte socio-économique de l'exploitation. Leur responsabilité vis à vis de l'exploitant est importante puisque ce sont eux qui donnent l'ordonnance (nature du produit de traitement, dose, mode d'application). Ils ont donc un mode de raisonnement plus global au niveau du problème dans la culture.

Leurs souhaits portent non seulement sur l'amélioration de leurs connaissances, mais aussi sur des outils d'aide et d'orientation. Il leur importe en effet, en cas de doute, de pouvoir faire confirmer leur diagnostic par un expert, à moins de disposer eux-mêmes d'outils permettant d'affiner leurs résultats. Mais leur

préoccupation majeure n'est pas tant l'obtention du diagnostic que son utilisation : que faut-il conseiller de faire à l'agriculteur demandeur ?

1.1.1.3 Les agriculteurs

Si les techniciens raisonnent en terme de potentiel de dégât causé par la maladie, les agriculteurs la considèrent comme un préjudice non seulement à déterminer et localiser (espace et temps), mais aussi à quantifier. Comme cela a une incidence directe sur leur revenus d'exploitation, ils raisonnent encore plus globalement en terme de préjudice pour la commercialisation. De ce fait, ils sont très exigeants vis à vis du conseil en protection des cultures.

Leurs demandes se situent à différents niveaux. Ils voudraient pouvoir déterminer eux-mêmes, immédiatement, les maladies les plus courantes ; quand ils doivent passer par la chaîne complète du diagnostic, ils souhaitent recevoir rapidement les résultats. Ils veulent connaître l'opportunité des interventions curatives : savoir si l'atteinte à leur culture est grave, et bénéficier d'outils d'aide aux traitements, intégrant les critères économiques et les données de leur exploitation. Enfin, ils souhaitent aussi des renseignements sur la raison de l'installation de la maladie dans la culture de manière à prendre des mesures prophylactiques ou préventives dès la prochaine campagne.

1.1.1.4 Conclusion

Tous ces intervenants sont des consultants potentiels des systèmes experts de l'INRA. Il faut donc prendre en compte leur grande hétérogénéité de niveaux techniques, et la variété des utilisations qu'ils comptent faire du diagnostic. Dans SEPV, il a fallu gérer l'important écart qui existe entre les experts qui peuvent fournir l'expertise, et les nombreux techniciens et agriculteurs qui peuvent y avoir accès. Le problème de l'adaptation des niveaux, pris en charge par les cognitivistes (ces personnes construisant les bases de connaissances), s'est révélé encore plus central qu'il ne l'avait été perçu *a priori*. Il n'y a pas qu'un modèle d'utilisateur à prendre en compte. Concilier les exigences d'un outil de qualité professionnelle et celles d'un produit de type grand public complique considérablement un projet de conception, de développement et de validation.

1.1.2 Bien définir les objectifs et les moyens

L'objectif de SEPV était de construire des systèmes experts de détermination des maladies. L'acte de diagnostic, essentiellement visuel, consiste à déduire la présence d'une maladie de l'observation de symptômes, manifestations plus ou moins caractéristiques de la maladie. Le savoir-faire de l'expert s'appuie donc sur deux capacités à reproduire :

1.1.2.1 Savoir observer

Il faut savoir faire un tour rapide des différents symptômes, pour focaliser rapidement l'observation sur les plus “pertinents”, en faisant un tri pour ne garder que les éléments les plus caractéristiques (par exemple, ne pas tenir compte des symptômes sans signification, ou ne s'intéresser qu'au meilleur stade d'évolution, ou encore “sérifier” les problèmes quand on s'aperçoit que plusieurs maladies sont présentes en même temps, etc.).

La mémoire visuelle de l'expert joue un rôle essentiel, lui permettant de se rappeler “qu'il a déjà vu ça quelque part”, et de remonter à des cas analogues ou plus typiques.

Il est particulièrement difficile, voire impossible, de déceler une “méthode” dans la façon de procéder de l'expert, tant il semble que chaque observation de plante soit menée différemment des autres. Le rôle de l'expérience joue en effet à fond, en particulier l'expérience à court terme (référence à des cas analogues vus il y a peu de temps : l'expert fait des comparaisons “en mémoire vive”).

1.1.2.2 Savoir raisonner

En simplifiant, on pourrait dire que l'expert interprète les symptômes en termes de caractéristiques de maladie, ce qui lui permet tout à la fois de se focaliser vers un petit nombre de maladies possibles (qu'il va falloir confirmer) et de ne pas prêter attention à d'autres maladies (ce qui revient à les éliminer de façon implicite).

C'est cette démarche complexe d'élimination et de confirmation d'hypothèses, souvent entrecoupée de remises en cause et de retours en arrière, qui permet de parvenir à un diagnostic. Dans les cas où aucun élément suffisamment discriminant n'a pu être relevé, il est nécessaire de recourir à des moyens complémentaires (mise en culture par exemple), pour pouvoir préciser le résultat. Car le résultat du diagnostic n'est pas toujours unique et certain, et il se trouve de fait souvent accompagné d'un commentaire en cas de doute.

Cette manière de diagnostiquer, issue presque entièrement de l'expérience, correspond à un savoir-faire et pas du tout à la connaissance telle qu'on peut la trouver formalisée dans les ouvrages spécialisés. Nous sommes dans un domaine qui se laisse difficilement ramener à un ensemble de “lois”, où l'incertain et l'approximatif s'insinuent partout.

1.1.2.3 Conclusion

Il sera important qu'un système de détermination souhaitant reproduire le savoir-faire de l'expert tienne compte de l'application de ces deux capacités : savoir observer et savoir raisonner. Plus tard, grâce aux techniques d'apprentissage, nous apprendrons qu'une troisième qualité intermédiaire entre l'observation et le raisonnement est primordiale : c'est la **capacité à décrire les observations**. Les descriptions permettent la liaison entre l'observation et le raisonnement. Elles s'appuient sur l'élaboration d'un questionnaire tenant compte à la fois d'un modèle d'observation de l'expert (modèle descriptif de l'observable indiquant quoi observer) et du niveau de perception de ces connaissances par les utilisateurs (adaptation au vocabulaire et à la manière d'observer des utilisateurs). En effet, on avait tendance à oublier qu'un système expert était fait pour être diffusé auprès d'autres utilisateurs que les experts.

1.2 Le projet INSTIL

A côté de la méthode de constitution d'un système expert par transmission de la connaissance, qui est celle qui a été suivie dans SEPV en mettant en place la chaîne "expert(s) - cognicien - système expert - utilisateurs", nous avons expérimenté une autre méthode visant à améliorer le processus d'acquisition des connaissances. Le problème des systèmes experts construits selon la technique classique est qu'ils nécessitent beaucoup de connaissances descriptives : les règles doivent être maintenues continuellement avec l'apparition de nouvelles maladies et de nouveaux symptômes.

INSTIL signifie "Integrating Numeric and Symbolic Techniques In Learning". Le but de ce projet européen entre 1986 et 1989 (ESPRIT I n° 1063) a été de construire "automatiquement" un système expert de diagnostic des maladies de la tomate à l'aide de techniques d'apprentissage numériques et symboliques.

L'idée était de comparer l'approche classique d'élicitation des connaissances avec celle d'extraction automatique de règles à partir d'exemples. Chaque exemple est constitué de la description d'une plante malade et du diagnostic correspondant de la part de l'expert. Du point de vue mathématique, un **exemple** est un couple $(d(w), c)$ où w est un individu observé (la plante malade par exemple), $d(w)$ est sa description associée, et c est le nom de la classe auquel l'individu appartient (le diagnostic correspondant). La description peut être formalisée de différentes manières selon la complexité de l'individu à décrire (voir chapitre 4).

Les algorithmes d'apprentissage étaient utilisés pour aider à la classification des maladies par méthode inductive (les caractériser par un arbre ou des règles de

décision), puis à la détermination de nouvelles observations² (par méthode déductive). Ces algorithmes sont les suivants :

1.2.1 *Neddie*

Neddie est un descendant d'ID₃ [Quinlan, 1983]. A partir d'exemples de plusieurs concepts, il fabrique un arbre de décision qui sépare les concepts de manière efficace. En termes de stratégies de recherche, Neddie effectue une recherche en gradient (“divide and conquer”, pas de retour en arrière) du plus général au plus spécifique en utilisant un critère d'évaluation numérique appelé gain d'information qui est fondée sur la mesure d'entropie de Shannon (1949). Neddie possède les fonctionnalités permettant de transformer un arbre de décision en règles [Corlett, 1983] ou encore l'arrêt de la construction de l'arbre avant son terme en utilisant le test du χ^2 quand toutes les variables candidates à un nœud (les attributs³ explicatifs) sont indépendantes de la variable décision (la maladie à expliquer). Néanmoins au départ, Neddie était limité dans son mode de représentation des connaissances et n'utilisait pas de théorie initiale du domaine : chaque exemple était décrit dans une ligne d'un tableau de données (représentation plane ou “attribut-valeur”) sans possibilité d'introduire de logique d'ordre 1 (avec variables) dans une description. En outre, cette connaissance “à-plat” ne permet pas de prendre en compte les connaissances de bon sens entre les différents composants d'une description et issues d'une modélisation initiale du domaine [Manago & Conruyt, 1989]. Nous verrons avec KATE (§ 1.4) que ces possibilités sont impératives pour exploiter la richesse des domaines vivants que nous voulons traiter.

1.2.2 *Main*

Main est une implantation partielle de l'algorithme de l'étoile AQ [Michalski *et al.*, 1981] version 11 [Michalski, 1983]. Prenant des exemples positifs et négatifs d'un concept (les exemples négatifs⁴ sont ceux qui n'appartiennent pas au concept), il génère un ensemble de descriptions conjonctives qui couvrent tous les exemples positifs et un nombre prédéfini par l'utilisateur d'exemples négatifs CE [Manago, 1988].

L'algorithme commence par sélectionner au hasard un exemple e_1 (le *noyau*) dans l'ensemble des exemples positifs. La liste des attributs de l'exemple est ensuite généralisée à l'aide de règles de généralisation (règle de l'oubli, règle

² L'observation est définie mathématiquement par le couple $(d(w), \emptyset)$ du fait que le nom de la classe n'est pas connu et reste à déterminer.

³ Dans cette thèse, la sémantique choisie pour le mot “attribut” est celle du domaine de l'intelligence artificielle ou de l'analyse des données, c'est à dire la “variable” (ex : couleur, forme, taille, etc.) et non pas dans le sens de “ce qui est attribué à un individu” que nous appellerons la “valeur”.

⁴ Ou contre-exemples du concept.

d'élargissement des valeurs possibles, etc.) et en tenant compte d'heuristiques pour contrôler la recherche multi-directionnelle.

$G(e_1, CE)$ est appelé l'*étoile de e_1* et représente l'ensemble de toutes les descriptions les plus générales qui couvrent le noyau (complétude) et ne couvrent pas les exemples négatifs (cohérence). Comme cela représente un nombre trop élevé de descriptions dans la pratique, l'algorithme effectue une recherche en faisceau pendant la génération de l'étoile pour produire une *étoile bornée* $G(e_1, CE/m)$ ne contenant que les m meilleures descriptions selon certains critères et seuils de tolérance fixés au départ. Les exemples positifs qui ne sont pas couverts par l'étoile sont éliminés et le processus de départ est répété jusqu'à ce que tous les exemples soient couverts.

Contrairement à Neddie, Main utilise une stratégie hybride (en faisceau) ascendante guidée par les données (lors du choix d'un exemple) et descendante guidée par un modèle (lors de la génération de l'étoile bornée). C'est un système à la fois numérique et symbolique qui exploite une représentation plus ou moins orientée objets : VL₂ (Variable-Valued Logic) comme sous-ensemble de la logique du premier ordre [Michalski, 1980]. Main ne savait pas traiter les attributs à valeur numérique.

1.2.3 Maggy

Maggy est une implantation de l'algorithme d'appariement structurel et un descendant du système Agape [Kodratoff & Ganascia, 1986]. Il prend un ensemble d'exemples positifs et produit les généralisations conjonctives les plus spécifiques [Michalski, 1983]. Maggy utilise une représentation des connaissances fondée sur les *frames* permettant de décrire les observations (les observés) sous forme d'objets structurés ainsi que d'autres connaissances initiales de bon sens sur le domaine (hiérarchies d'objets, propriétés déductives, etc.) constituant le modèle descriptif (l'observable). Maggy peut être utilisé pour trouver toutes les généralisations conjonctives possibles d'un ensemble d'exemples (étant donné un modèle descriptif) ou sélectionner une généralisation fondée sur la quantité d'information perdue pendant la procédure. Considérons l'exemple suivant :

E_1 : [objet1 <classe pourriture> <couleur blanc>] & [objet2 <classe tache> <couleur brun>]

E_2 : [objet1 <classe pourriture> <couleur jaune>] & [objet2 <classe tache> <couleur blanc>]

En faisant l'hypothèse qu'il y a une taxonomie des couleurs et que les pourritures et les taches sont des sortes de symptômes, Maggy extrait la généralisation "il y a une pourriture de couleur claire et une tache" plutôt que "il y a un symptôme blanc et un autre symptôme". Ceci provient du fait que davantage d'information est perdue en produisant la seconde généralisation [Manago, 1986]. Maggy renvoie à la fois la généralisation et une mesure de la quantité d'information perdue pendant le processus de généralisation.

Maggy fonctionne en logique du premier ordre et utilise une stratégie de recherche du meilleur d'abord guidée par les données : il combine la recherche en gradient et en profondeur d'abord (tous les chemins sont explorés, mais les plus prometteurs le sont en premier). C'est un système symbolique.

1.2.4 Conclusion

Comme le montrent ces différents algorithmes, le projet INSTIL visait à réunir différents modes de raisonnements par inférence (induction, déduction), des stratégies de recherche multiples (recherches ascendante, descendante, en profondeur, en largeur d'abord), des méthodes d'induction différentes (numériques, symboliques) et des modes de représentation divers (logique des propositions, prédicats).

Dans ce projet, notre rôle a été double :

D'une part, nous avons pu fournir les exemples en amont de la phase de traitement par ces algorithmes ; grâce à la connaissance des utilisateurs finaux, nous avons pu ainsi proposer dans le cadre d'un mémoire de fin d'étude ISARA [Conruyt & Piaton, 1987] une méthode d'acquisition des exemples à l'aide d'un questionnaire interactif adaptée au domaine de la pathologie végétale. C'est cette méthode qui a servi de base à la construction du projet de thèse afin de réaliser pratiquement les outils permettant d'acquérir les connaissances initiales aux traitements. Ainsi, l'expérience de deux années d'utilisateur des systèmes experts sur le terrain a permis de comprendre la difficulté du "savoir observer et décrire" des différents intervenants dans la chaîne du diagnostic et de passer d'une proposition sur papier à une réalisation informatique concrète.

D'autre part, il nous restait à comprendre les mécanismes de raisonnement des logiciels d'apprentissage automatique (induction, déduction) pour les comparer au "savoir raisonner" de l'expert, ceci afin de concevoir un système de détermination globalement **plus fiable**. Comprendre le traitement des exemples a été donc l'objectif poursuivi pour pouvoir établir des comparaisons entre les différents programmes à la lumière de la qualité des descriptions fournies. N'ayant pas au départ les connaissances informatiques suffisantes, les différents algorithmes ont été regardés comme autant de boîtes noires et nous avons analysé les résultats en sortie par rapport aux données en entrée. Nous avons ainsi pu constater une nouvelle fois l'importance de la **qualité des descriptions** en entrée, ce qui justifiait de consacrer nos efforts futurs sur cet aspect de l'acquisition des connaissances.

1.3 Des systèmes experts à l'apprentissage

Dans ce paragraphe, nous allons évoquer quelles sont les relations entretenues entre les deux approches que nous avons expérimentées, c'est-à-dire celle à l'INRA avec les systèmes experts dits "de première génération" et celle en apprentissage numérique symbolique dans le cadre d'ESPRIT (projet INSTIL).

Nous résumons d'abord les avantages et inconvénients des systèmes à base de connaissances par rapport aux programmes informatiques classiques (§ 1.3.1). Cette première comparaison est plutôt théorique. Elle est suivie d'un bref exposé (§ 1.3.2) sur les tentatives des chercheurs en informatique pour faire face au problème de l'acquisition des connaissances soulevé par l'emploi des règles de déduction dans les systèmes experts de première génération. Les systèmes experts de seconde génération mettent l'accent sur l'acquisition des connaissances de l'expert par le cognicien du point de vue de la simulation de son raisonnement à l'aide de modèles.

Or, la modélisation du raisonnement demande d'abord la compréhension des concepts sur lesquels on raisonne. En privilégiant plutôt les descriptions que les règles de détermination, nous allons montrer que l'apprentissage inductif à partir d'exemples est mieux adapté à la logique de fonctionnement de l'expert. Du point de vue pratique, nous n'oublions pas cependant qu'un système expert, même s'il est construit par apprentissage inductif, est utilisé par d'autres personnes que l'expert. L'adaptation des connaissances à l'utilisateur final a fait l'objet de recherches pendant deux années d'utilisation des systèmes experts sur le terrain. Nous en donnerons un aperçu au § 1.3.3. Enfin, en comparant les résultats d'INSTIL et ceux de SEPV au § 1.3.4, nous verrons que la qualité des descriptions à traiter par apprentissage est primordiale, ce qui nécessite la conception d'un modèle descriptif correctement défini.

1.3.1 Les systèmes experts

Les systèmes experts ou encore *systèmes à base de connaissances* sont des programmes informatiques qui ont pour but de reproduire le raisonnement d'un expert humain *dans un domaine bien précis*, afin de résoudre un problème donné de manière aussi performante.

Du point de vue de la méthode, alors que dans les systèmes informatiques traditionnels le programme récolte toute l'information sous forme procédurale, dans les systèmes experts l'information spécifique au domaine est déclarée dans une base de connaissances heuristiques (les règles de raisonnement) et sont séparées de leur mécanisme d'interprétation (le moteur d'inférences). Pour une explication de l'anatomie des **systèmes experts de première génération**, le lecteur pourra se reporter à [Laurière, 1982], [Cordier, 1984] ou [Bonnet, 1984].

La façon classique permettant d'acquérir toutes ces connaissances est celle qui utilise le cognitif, spécialiste du recueil, de la représentation et de l'implantation sur ordinateur des connaissances expertes. La transmission (l'élicitation) des connaissances nécessite une méthodologie bien définie :

- 1) prendre un expert reconnu, motivé et disponible,
- 2) se familiariser avec le vocabulaire du domaine,
- 3) déterminer par interview les modalités du raisonnement de l'expert,
- 4) écrire la base de connaissances,
- 5) faire valider la base par l'expert, puis d'autres experts,
- 6) faire valider dans le milieu cible.

Les avantages de cette démarche sont bien connus :

les règles énoncées donnent une meilleure accessibilité au non informaticien,
 les facultés explicatives et justificatives sont directement reliées aux informations que l'utilisateur a lui-même rentrées,
 L'expert, aidé ou non du cognitif, peut lui-même corriger et mettre à jour les connaissances introduites, etc..

Néanmoins, malgré des réussites remarquables telles que MYCIN en médecine (maladies infectieuses) [Shortliffe, 1976], DENDRAL en chimie (structures moléculaires) [Buchanan & Feigenbaum, 1978], ou encore PROSPECTOR en géologie (prospection minière) [Duda *et al.*, 1979], il faut bien reconnaître que la mise au point d'une base de connaissances (le recueil d'expertise) reste très délicate :

l'expérience de l'expert s'est forgée à son insu, elle ne s'explique pas facilement hors contexte,
 le formalisme des règles ... alors ... n'est pas toujours adapté à son raisonnement, ainsi qu'au traitement des exceptions (multiplication des prémisses), ou encore aux capacités d'explication (la trace des règles ne suffit pas),
 la modification d'une grosse base de règles est difficile à gérer (maintien de la cohérence), et coûteuse (faisant intervenir le cognitif),
 les performances se dégradent au moindre oubli et cela donne une image néfaste des compétences du système expert à ses utilisateurs,
 il n'existe pas de méthodologie prédéfinie d'extraction des connaissances, etc..

Toute la question est de savoir comment faire pour acquérir le raisonnement de l'expert et le modéliser sous forme de règles de production. Feigenbaum (1981) a identifié cette tâche d'élicitation comme le "goulet d'étranglement" de

l'acquisition des connaissances pour construire des systèmes experts opérationnels.

1.3.2 Acquérir les connaissances de l'expert

Un système expert n'est valable que s'il contient les connaissances les plus récentes, précises, justes, complètes et détaillées des meilleurs experts, et que si une remise à jour régulière de cette connaissance est réalisée.

Certains chercheurs ont essayé de mieux formaliser la nature même des connaissances du point de vue de la philosophie [Smith & Medin, 1981], de la psychologie et de la linguistique [Rosch *et al.*, 1976], [Schank, 1982], [Kleiber, 1990], conduisant les chercheurs en IA à utiliser d'autres formes de représentation des connaissances que la forme déclarative des règles de production. Ce sont par exemple les graphes conceptuels de Sowa (1984), les descriptions à base de *frames* [Minsky, 1975], les *scripts* [Schank & Abelson, 1977], les procédures (méthodes, démons) attachés aux objets [Roberts & Goldstein, 1977], les hiérarchies d'objets et les mécanismes d'héritage [Brachman & Schmolze, 1985], [Rechenmann, 1988], les objets composites [Stefik & Bobrow, 1986], [Ducourneau, 1989]. Pour obtenir une description de ces langages de frames au sein des langages à objets, le lecteur peut se référer à Masini [Masini *et al.*, 1989]. Ils ont été conçus pour aider les cognitivistes à modéliser une connaissance causale, c'est-à-dire reposant sur la compréhension des effets et des causes sous-jacents au fonctionnement du système expert [Giarratano & Riley, 1989]. Ainsi, il est possible de modéliser des connaissances de structure, de fonctionnement et de comportement des objets.

Consécutivement, d'autres chercheurs se sont focalisés sur le processus de l'acquisition des connaissances lui-même afin de mettre au point une méthodologie de modélisation des connaissances et de développement de systèmes experts pour en faciliter la validation et la maintenance.

Par exemple, pour les systèmes de diagnostic, l'approche consiste à représenter les connaissances de l'expert sur le comportement des composantes élémentaires du système à maintenir [Courtois, 1990]. Cette approche dite avec "connaissances profondes" caractérise les **systèmes experts de seconde génération**. La description des objets de la connaissance est réalisée par une décomposition structurelle et fonctionnelle et se formalise par l'intermédiaire de modèles physiques, comportementaux [Davis, 1984] et de fonctionnement [Milne, 1987].

Par ce moyen, le cognitiviste est amené à structurer la connaissance à différents niveaux pour le problème du diagnostic tout en utilisant les acquis des langages de représentation des connaissances décrits plus haut. De ce fait, la démarche est

très proche de la méthodologie KADS [Wielinga *et al.*, 1992b] de modélisation des connaissances.

Dans KADS, quatre niveaux (stratégie, tâche, inférence, et domaine) sont définis pour expliciter les compétences de l'expert (son modèle d'expertise) : le niveau *stratégie* permet de décrire les objectifs opérationnels de son action (conception, simulation, planification, diagnostic, etc.), le niveau *tâche* spécifie les raisonnements nécessaires qu'il adopte pour atteindre les buts, le niveau *inférence* permet de choisir les structures inférentielles dans une bibliothèque pour accomplir les tâches, et le niveau *domaine* décrit les concepts et relations utilisés par les autres niveaux [Kirsch *et al.*, 1993].

Par rapport aux travaux des systèmes experts de seconde génération qui se sont surtout intéressés à la modélisation des connaissances de résolution de problèmes [Clancey, 1985], [Breuker & Wielinga, 1989], [Chandrasekaran, 1987], dans KADS l'accent a été mis principalement sur la modélisation des connaissances spécifiques au domaine d'application [Wielinga *et al.*, 1992a].

En ce qui nous concerne, nous avons pu observer la pratique de diagnostic de l'expert des maladies des tomates D. Blancard pendant la campagne de 1987. Le modèle de raisonnement de l'expert (comment il résout le problème) face à un cas concret en pathologie végétale semble passer par trois étapes successives qui lui permettent d'atteindre plus vite son diagnostic (voir annexe 2) :

identification d'un contexte,
recherche d'éléments menant à une présomption,
utilisation de critères de confirmation.

Partant de cette constatation, les chercheurs de l'INRA ont trouvé intéressant d'intégrer de telles métaconnaissances dans la base de connaissances de manière à simuler un comportement analogue à celui de l'expert en situation. Pour Delhotal (1987), chacune des étapes correspond à un "paquet de règles" ou bloc, avec ses buts intermédiaires propres, et constitue en quelque sorte un sous-système expert.

Le découpage en unités fonctionnelles, outre qu'il correspond à une modélisation satisfaisante de la démarche de l'expert, présente aussi l'avantage de faciliter le travail du cognicien, que la structuration de la base de connaissances autorise à travailler sur des "unités" de connaissances plus homogènes et plus réduites. Nous remarquons que ces étapes correspondent chacune à une tâche de diagnostic au sens de KADS. Cette remarque est aussi valable pour les générateurs de systèmes experts de seconde génération comme par exemple SMECI [Smeci, 1991].

Mais dans ces systèmes, on ne se cantonne pas seulement au niveau de la structuration d'une base de règles. Outre les connaissances déclaratives, SMECI intègre des connaissances factuelles représentées sous forme d'objets (catégories, prototypes) et des connaissances procédurales (démonstrations, méthodes). Ainsi, ces systèmes experts répondent à la critique comme quoi ils sont encore trop superficiels au niveau de la représentation profonde des associations phénoménologiques qu'ils sont capable de faire [Bonnet, 1984], [Pitrat, 1987] : en effet, ils peuvent posséder un **modèle** d'organisation des objets du domaine et l'utiliser pour inférer des données manquantes par un raisonnement de bon sens (si type(culture) est "plein-champ", alors chauffage(culture) est "froid" et mode(culture) est "en-terre"), ils donnent la possibilité de décomposer le problème en modules de connaissance (tâches) indépendants et de piloter la résolution de problèmes à l'aide de stratégies d'inférence variées (profondeur, largeur, meilleur d'abord).

Comme nous le constatons, les systèmes experts se sont développés surtout autour de la simulation du raisonnement. Or, **avant de raisonner** pour résoudre un problème, **il faut être capable d'acquérir les concepts** sur lesquels on raisonne.

Cette faculté est le propre de l'**induction** qui est le processus qui va inférer des règles générales (ou plutôt des hypothèses) à partir des cas particuliers. Cette raison nous a conduit à étudier l'apprentissage inductif à partir d'exemples qui permet de découvrir des connaissances déclaratives (des définitions, c'est-à-dire quelque chose de vrai ou faux) caractérisant des concepts, à partir de connaissances factuelles (des descriptions, cf. chapitre 3). Les règles induites sous la forme d'un arbre de décision sont ensuite utilisées comme pour les systèmes experts de première et seconde génération.

De plus, l'apprentissage automatique a été désigné pour répondre à la constatation suivante : autant l'expert peut être compétent pour résoudre des problèmes concrets, autant il n'est pas nécessairement un bon professeur capable d'expliquer de façon logique par des règles abstraites comment il raisonne. Nous pensons qu'il est effectivement plus simple et plus naturel de laisser l'expert décrire des échantillons de différentes classes que de lui demander de fournir des définitions qui permettront de les reconnaître. Cela permet aussi de tenir compte des exceptions multiples que l'on trouve obligatoirement dans la nature et qui constituent toutes des exemples "couvrant" la même classe. De ce fait, l'expert peut adopter une démarche exploratoire pour comprendre la manière dont il a lui-même pu (auparavant) apprendre son domaine : les règles en sortie peuvent être contrôlées par les données qu'il a lui-même entrées, ce qui est plus "confortable" que l'énoncé de règles abstraites. Le résultat est de toute manière identique à celui des générateurs de systèmes experts : il s'agit de construire un système à base de connaissances.

Du point de vue de l'expert, les concepts correspondent aux classes à reconnaître (c'est-à-dire ici les diagnostics) et pour le cogniticien il s'agit aussi des buts du système ou variables à expliquer. Ainsi, acquérir le raisonnement de l'expert consiste à saisir sa **logique de fonctionnement** dans la phase d'acquisition des connaissances. Mais cela ne suffit pas car l'expert et le cogniticien ne sont pas les seuls utilisateurs mis en jeu. Il faut compléter cette logique par une phase de mise en situation avec les personnes concernées par la version finale du système expert : c'est la **logique d'utilisation** [Richard, 1983] [Mahé & Vesoul, 1987].

Ainsi, comme nous l'avons constaté lors de campagnes de validation des systèmes experts sur le terrain, il s'avère nécessaire d'être plus général dans notre définition des concepts en biologie : l'apprentissage de concepts ne se résume pas seulement à reconnaître les buts du système (ex : maladies), mais aussi d'autres concepts aux contours mal définis tels que les types de symptômes, la nature des traitements, etc.. Par exemple, qu'est-ce qu'une tache, une anomalie de coloration, un jaunissement pour l'expert, pour l'agriculteur et le technicien ? La question de savoir comment nous arrivons à formuler nos concepts reste entière !

C'est pourquoi l'alternative de l'apprentissage à partir d'exemples nous semble plus intéressante que l'approche système expert traditionnelle parce qu'il est possible de faire intervenir l'utilisateur final avant même l'élaboration automatique des règles : nous lui demandons de fournir des descriptions d'un même échantillon qui aura été déjà décrit et identifié par l'expert. En multipliant ce procédé (cette approche a été adoptée dans INSTIL), on favorise la construction de règles plus robustes par rapport aux consultations futures du système par des utilisateurs variés : par cette méthode, la consultation n'est plus seulement le fruit d'un dialogue entre l'expert et le cogniticien mais profite de la variabilité des descriptions au niveau de leurs descripteurs (ceux qui décrivent).

1.3.3 Adaptation à l'utilisateur

Bien adapter les systèmes experts à leur cible est une priorité et cela demande des épreuves de validation sur le terrain : la principale difficulté réside en effet dans les écarts d'interprétation de l'observation et du vocabulaire entre utilisateurs, ce qui peut conduire à des diagnostics incorrects [Conruyt, 1986]. Pour tous, le système expert apparaît comme un questionnaire interactif dans lequel ils sont plus ou moins guidés. Il y a beaucoup de manières de présenter le questionnaire ou l'ordre des questions à poser à l'utilisateur. Le problème fondamental est alors de confronter la logique de l'expert qui décrit avec celle des autres utilisateurs [Conruyt & Piaton, 1987].

En effet, un échantillon réel (plante malade à un stade plus ou moins évolué) n'est pas observé ni décrit de la même façon par un expert, un technicien ou un

agriculteur. En définitive, c'est bien sûr l'expert qui donne son propre canevas de description, mais le cogniticien doit généralement l'arranger à la lumière d'une validation de terrain, pour qu'il devienne plus ergonomique et plus convivial (interface homme-machine, complexité des questions, dialogues d'explication, glossaire, etc.). Par exemple pour notre expérimentation sur le terrain, un aspect important du questionnaire était de le laisser ouvert sur les possibilités différentes d'interprétation des utilisateurs à propos de tout caractère d'un objet : il y avait un champ commentaire associé à chaque attribut et l'information contenue a pu être analysée après la première phase de validation, ce qui a contribué grandement à l'amélioration du questionnaire.

Dans le cas fréquent où plusieurs experts ont contribué à la construction du système expert, seule la validation peut permettre de repérer les convergences de symptômes, les redondances ou les trous entre les expertises séparées.

Elle doit se faire dans des sites soigneusement choisis, ou :

- le besoin en diagnostic est réel, de par l'arrivée de nombreux échantillons de plantes malades,
- l'utilisation des systèmes experts est possible, en termes de disponibilité de consultants non spécialisés,
- les diagnostics peuvent être confirmés ou infirmés par un expert humain,
- un suivi peut être assuré par le cogniticien concerné.

La phase de validation, qui en théorie n'intervient qu'une fois le prototype terminé, gagne à commencer le plus tôt possible, dès que le système est montrable, et devient un élément permanent et central de la construction du système. Cela permet aux utilisateurs de se familiariser avec lui, aux experts de régler les différents types de **bruits**⁵ qui peuvent avoir été introduits par l'utilisateur. Pour l'application sur la tomate, on a pu ainsi mettre en évidence trois niveaux de bruits :

bruits liés à la collecte et à l'observation des exemples,
bruits liés au remplissage du questionnaire,
bruits liés à l'établissement du diagnostic.

Ces bruits apparaissent tout au long d'une chaîne intitulée "Du problème à la maladie diagnostiquée". La fiabilité du diagnostic dépend de l'accumulation des bruits antérieurs tout au long de la chaîne. Une méthodologie de collecte, d'observation et de description des exemples a pu être proposée afin d'obtenir de meilleurs exemples pour l'apprentissage [Conruyt & Piaton, 1987] (figure 1.1). Nous y reviendrons au chapitre 2 lorsque nous aborderons le problème de la robustesse.

⁵ Une définition générale du bruit est : "tout ce qui détériore l'information sur l'environnement que l'on cherche à connaître".

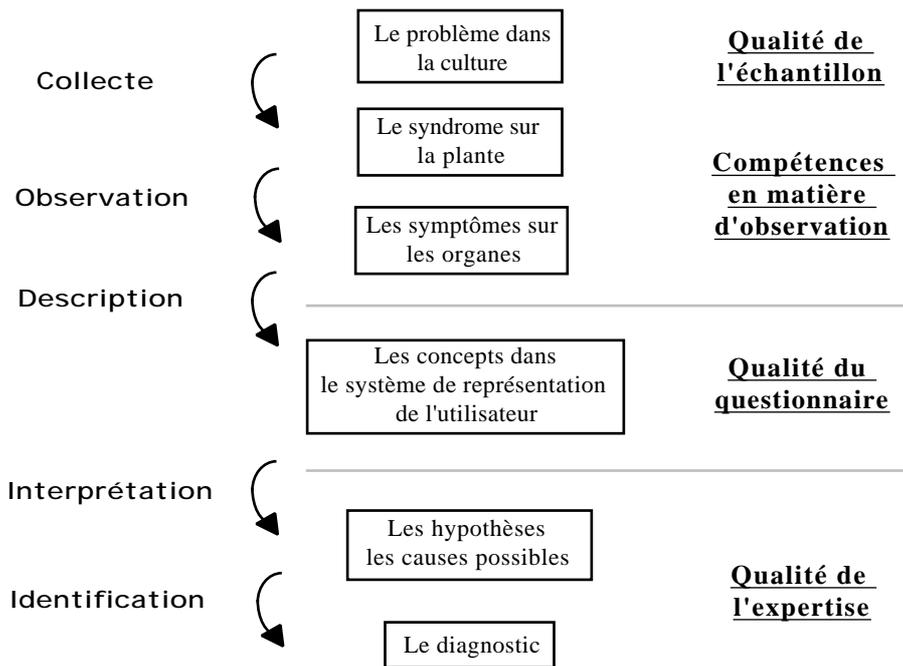


Fig. 1.1: Notre méthodologie de collecte, d'observation et de description des exemples

C'est l'analyse des cas de “mauvais fonctionnement” du système expert qui a pu en effet permettre à l'expert et au cogniticien de proposer des solutions d'amélioration. Un mauvais fonctionnement n'était d'ailleurs pas forcément un échec absolu du système : le diagnostic peut s'avérer plus ou moins divergent de celui de l'expert (par exemple : mauvais classement des maladies du fait que le diagnostic présente plusieurs maladies simultanément).

Il faut aussi se demander pourquoi telle question apparemment inutile a été posée, ou au contraire pourquoi telle autre qui aurait été logique n'est pas apparue. Enfin il faut analyser l'influence des “mauvaises” réponses de l'utilisateur, de façon à améliorer les résultats du système expert face à des données plus ou moins inappropriées.

1.3.4 Comparaison des deux approches

Le but du stage de DEA d'Intelligence Artificielle que nous avons effectué [Conruyt, 1988] dans le cadre du projet INSTIL était de comparer deux systèmes à bases de connaissances en présence de tout l'univers “bruité” de description des maladies de la tomate de la campagne de 1987. Le premier système TOM (développé par un couple “cogniticien-expert”) était opérationnel, et l'autre INSTOM (généralisé par les logiciels d'apprentissage Neddie et Main) était à l'état de prototype.

Une première validation par l'expert (D. Blancard) des règles produites automatiquement a montré qu'elles étaient trop générales (imprécises et incomplètes) et difficilement interprétables. Il s'est donc révélé nécessaire de comprendre le fonctionnement des logiciels d'apprentissage, de corriger certains "bugs" et de tester leurs performances propres afin d'obtenir de meilleures règles.

Pour cela, une méthodologie d'évaluation a été mise au point en faisant intervenir différents tests *locaux* (dits de "robustesse" et de "précision") avec plusieurs niveaux de difficulté sémantique en fonction :

- du nombre d'exemples (17 à 21),
- du nombre de classes (2 à 3),
- des objets impliqués (types de symptômes, organes).

D'autres tests plus *globaux* faisaient intervenir :

- un plus grand nombre d'exemples et de classes (32 à 34),
- des types de cas différents (cas typiques ou photos, cas réels bruités),
- deux types de diagnostic (simple ou multiple, c'est à dire avec plusieurs maladies présentes simultanément sur la même plante).

Ces moyens expérimentaux ont été implantés dans un environnement de tests.

Les résultats sont d'ordre à la fois quantitatifs (durées d'élaboration de l'arbre de décision et des règles de production en fonction du nombre d'exemples et du nombre de classes) et qualitatifs (appréciation de la justesse des règles en fonction de la nature des caractères observés, de l'homogénéité des exemples).

Nous avons pu mettre en évidence certaines incohérences dans les règles apprises qui sont dues à des insuffisances dans la phase d'acquisition des connaissances. Nous mettons ainsi en lumière **l'importance de la bonne structuration des connaissances de base** au sein d'un modèle descriptif pour un apprentissage correct. En effet, ce modèle indique les relations structurelles entre les concepts, il peut dans un premier temps être utilisé pour acquérir les exemples à l'aide d'un questionnaire et servir de guide d'observation. La qualité des exemples à apprendre (les données observées) dépend directement de la qualité de la phase de modélisation des descriptions (données observables). Dans un deuxième temps, il servira aussi au système d'apprentissage pour généraliser en utilisant les hiérarchies d'objets (en sachant par exemple que le terme de symptôme est plus général que le terme de tache). Ces constatations sont à l'origine de l'implantation du système d'induction KATE utilisant une représentation orientée objets : les *frames*.

Au cours de ce stage, des propositions pour améliorer les connaissances de base avec notamment un nouveau statut des descripteurs sous forme de différents types dépendants les uns des autres (objets, attributs et valeurs) ont pu être fournies. Nous avons mis aussi en évidence qu'il existe quelques règles générales de construction d'un bon modèle de représentation des connaissances dans le domaine du diagnostic : elles seront développées au chapitre 4.

Partant des recherches sur le bruit de [Manago & Kodratoff, 1987], des travaux complémentaires ont pu enfin être menés sur son traitement dans un univers réel de description (coût du diagnostic, recouvrement et priorité des concepts, tolérance des attributs numériques, confiance dans les exemples) [Conruyt & Lesaffre, 1988].

Tous ces efforts de contrôle des entrées et d'évaluation des sorties du système ont contribué à la production de règles de meilleure qualité syntaxique en pratiquant un réglage progressif des logiciels d'apprentissage.

Néanmoins, du point de vue de leur sémantique, l'expert a été surpris de l'aspect nouveau de certaines d'entre elles qui expriment souvent des évidences en phytopathologie formulées d'une manière inhabituelle. Certaines d'entre elles sont extrêmement concises et jugées positivement. D'autres, cependant, sont trop générales et peuvent choquer même si leur formulation syntaxique est jugée vraie. Par exemple, la manière de Main de caractériser certaines maladies par la négative est déroutante :

(Si $\neg A$ et si $\neg B$ et si $\neg C$ et ... et si $\neg X$ alors conclusion)

exemple :

Si existe(tache-ou-plage-sur-foliolle) = non & existe(anomalie-de-la-forme-ou-de-la-taille-sur-foliolle) = non & existe(jaunissement-sur-foliolle) = non & existe(autres-anomalies-sur-foliolle) = non & existe(jaunissement/dessechement-sur-foliolle) = non & existe(dessechement/tache-ou-plage-sur-foliolle) = non & existe(fletrissement/jaunissement-sur-foliolle) = non & existe(ravageurs-sur-foliolle) = non & existe(tache-ou-plage/autres-anomalies-de-coloration-sur-foliolle) = non & existe(jaunissement/tache-ou-plage-sur-foliolle) = non & existe(fletrissement/tache-ou-plage-sur-foliolle) = non & existe(fletrissement-sur-foliolle) = non & existe(dessechement-sur-foliolle) = non & existe(autres-anomalies-de-coloration-sur-foliolle) = non

Alors Oidium (0.20), Pvy (0.80)

Cette règle signifie "S'il n'y a aucun de ces 16 symptômes, alors la maladie est Oidium avec une probabilité de 0,2 ou Pvy avec une probabilité de 0,8". Elle n'est pas jugée compréhensible par l'expert, parce qu'elle n'est pas facile à interpréter, mais elle peut néanmoins être tout à fait correcte pour classer de nouveaux exemples.

Ainsi, pour pouvoir comparer efficacement les logiciels d'apprentissage (INSTOM) et le système expert TOM, il ne suffit pas de disposer de règles syntaxiquement cohérentes par rapport aux exemples appris. L'objectif est aussi

d'acquérir des règles ayant un sens pour l'expert. Ceci n'est atteint que si une modélisation préalable du domaine a été établie pour indiquer les relations entre les différents objets constitutifs ainsi que leurs statuts respectifs (objet, attribut, valeur). La conclusion de ce travail est que la modélisation du domaine est la première étape indispensable pour apprendre à partir d'exemples. Ce travail n'a pas pu être réalisé à temps avant la fin du projet INSTIL. C'est la raison qui explique la faiblesse des résultats de l'évaluation des mécanismes d'apprentissage au niveau qualitatif [Lesaffre *et al.*, 1989].

1.3.5 Conclusion

Dans ce paragraphe, nous avons comparé les différentes démarches des chercheurs pour acquérir des connaissances expertes. Ces comparaisons sont établies en fonction de l'expérience acquise pendant les deux années d'utilisation des systèmes experts (1986-1987). Les systèmes experts essayent de modéliser le raisonnement d'un expert dans un domaine précis. Plutôt que de le modéliser sous forme de règles et d'appliquer un mécanisme déductif, nous préférons appliquer la méthode inverse en utilisant l'**apprentissage inductif** à partir d'exemples pour acquérir les règles expertes. Nous avons justifié ce choix en analysant le raisonnement de l'expert d'un point de vue pratique (la logique de fonctionnement : § 1.3.2), puis nous avons montré l'importance de la validation des connaissances sur le terrain (la logique d'utilisation). En effet, la qualité de l'expertise est nécessaire mais n'est pas suffisante pour obtenir des résultats robustes : l'**adaptation des connaissances** à l'utilisateur cible est déterminante pour l'acceptation du système expert. Enfin, pour le traitement des connaissances, nous avons voulu comparer les techniques d'apprentissage et un système expert classique (§ 1.3.4). Nous avons appris alors qu'il était nécessaire de bien **structurer les connaissances de fond** pour obtenir des descriptions de qualité. Ce fut là l'origine de la conception du logiciel KATE.

1.4 KATE

KATE (Knowledge Acquisition Tools for Expert systems) est un logiciel d'apprentissage à partir d'exemples issu des travaux d'INSTIL et de la thèse de Manago (1988). Tous les acteurs de ce projet ont souligné la nécessité pour les logiciels d'apprentissage automatique de posséder un bon formalisme de représentation des connaissances du domaine et des mécanismes d'exploitation capables de tirer partie de ce formalisme.

1.4.1 Une bonne représentation des connaissances

Un système d'apprentissage doit s'adapter à une représentation plus complexe de la réalité. Comme le système ID3 dont il est issu, Neddie utilise une

représentation des connaissances par vecteurs “attribut-valeur” (logique des propositions ou logique d'ordre 0). Il n'utilise aucune connaissance sur le domaine, c'est à dire aucune taxonomie (ex : blanc et jaune sont des couleurs claires), aucune règle (ex : lorsqu'il y a une multitude de taches sur une feuille, alors leur taille est petite), aucune relation. Il ne peut pas par exemple représenter les objets composites (une plante est formée d'une tige, de feuilles, de racines, etc.) et les hiérarchies de spécialisation d'objets (un symptôme peut être précisé par les termes de tache, anomalie de coloration, flétrissement, etc.).

Si ce mode de représentation des connaissances est adéquat pour certaines applications simples, il s'est avéré beaucoup trop limité pour notre application en pathologie végétale. Nous devons être capable de représenter un nombre quelconque d'objets du même type : il peut en effet y avoir jusqu'à six symptômes différents sur une même plante avec par exemple deux sortes de taches sur les feuilles qui n'indiquent pas la même maladie ! Cette caractéristique objective (car naturellement présente) ne peut pas s'exprimer autrement qu'en introduisant des variables indicées aux objets comme par exemple tache(1) et tache(2) indiquant que l'on a deux sortes de taches, ce qui est la caractéristique d'un formalisme d'ordre 1 ou logique des prédicats.

De plus, la description des exemples est faite de manière subjective par des observateurs de nature multiple. Les utilisateurs moins qualifiés que l'expert ne reconnaissent pas forcément les symptômes à décrire : ils peuvent en voir qui sont secondaires ou non pertinents aux yeux de l'expert (par rapport aux maladies possibles de la plante). Ceci peut être dû soit à des “faux symptômes” (par exemple, des taches de cuivre issues d'un précédent traitement à la bouillie bordelaise) ou à des problèmes d'évolution ou de convergence des symptômes observés à des stades avancés de la maladie (ex : un flétrissement évoluant en jaunissement pour le “chancre bactérien”). La manifestation de la maladie donnera l'apparence de deux symptômes différents que le technicien agricole décrira alors que l'expert n'en verra qu'un seul, celui qui est la cause primaire de la maladie (le flétrissement est ainsi le symptôme “pathognomonique” de *Corynebacterium michiganense*) [Conruyt & Piaton, 1987]. Ce “bruit” lié aux compétences en matière d'observation (fig. 1.2) illustre la complexité des descriptions de symptômes que les utilisateurs sont capables de fournir au système d'apprentissage.

Il est donc souhaitable que le système sache montrer comment observer, au travers d'un questionnaire guidant l'observation de l'utilisateur. Cela nécessite une hiérarchisation des descripteurs entre eux, chacun obtenant un statut propre plus ou moins dépendant des autres dans la hiérarchie. La recherche d'un certain ordre de description met en lumière la notion d'**objet** dans la structuration des connaissances. Il n'est plus possible de considérer les caractéristiques comme indépendantes les unes des autres comme cela est le cas dans les tableaux de données classiques utilisés par ID3 ou Neddie.

Ces remarques ont amené un des acteurs principaux d'INSTIL à concevoir le système KATE [Manago, 1991] comme une extension de Neddie afin d'être en mesure de traiter les entités complexes du monde réel. Dans ce système, on s'appuie sur une représentation à base de schémas (ou *frames*) [Minsky, 1975], qui est une représentation par objets structurés dérivée de la logique d'ordre 1 [Nilsson, 1980].

La formalisation de ces objets du point de vue mathématique est décrite au chapitre 5, leur formalisation informatique au chapitre 6. Ensuite, les extensions apportées à l'algorithme d'induction utilisant ces connaissances structurées sont formalisées au chapitre 7.

1.4.2 Des mécanismes d'exploitation adaptés

Un *frame* ou *schéma* est une structure de données à trois niveaux *frame-attribut-facette* représentant une unité d'information descriptive (un descripteur) avec une sémantique donnée [Winston, 1977], [Bobrow & Winograd, 1977], [Masini *et al.*, 1989]. Si le descripteur est un objet, il peut aussi bien représenter une famille d'objets (une classe) qu'un objet particulier (une instance de la classe). La distinction entre ces deux types d'objets est importante du point de vue de l'**héritage** (qui permet le partage et la réutilisation des propriétés entre les objets) car la nature des relations qu'ils entretiennent n'est pas la même :

deux objets de type "classes" sont reliés par la relation d'inclusion entre ensembles avec un lien de type "sorte-de",
un objet de type "instance" est un élément appartenant à un objet de type "classe" et le lien est de type "est-un" [Giarratano & Riley, 1989].

Un *frame* n'accède qu'à (ne connaît que) l'information dont il dispose "en propre", c'est à dire à ses propriétés ou champs associés (les *slots*), et aux valeurs qu'elles prennent. Chaque champ est nommé et possède un type qui permet de déterminer soit les caractéristiques locales de l'objet (type **attribut**), soit les relations que l'objet entretient avec d'autres objets (type **relation**). D'autres types sont également possibles. Certains sont prédéfinis et d'autres peuvent être introduits par la personne chargée de représenter les connaissances de l'expert :

les **démons** sont des messages procéduraux prédéfinis qui permettent d'appliquer des *réflexes* (activés automatiquement lors de l'accès à la valeur de l'attribut) ou des règles de bon sens sur les objets (appliquées à la demande de l'utilisateur). Ces règles appelées aussi *méthodes* permettent soit :

- 1) un raisonnement guidé par les faits en chaînage avant (déduire la valeur d'un champ à partir de celle d'un autre champ à l'aide d'un démon “si-ajouté” : par exemple, le fait que le mode de culture soit “plein-champ” permet de déduire automatiquement que le type de culture est “en-sol” et que le mode de chauffage de cette culture est “froid”),
- 2) un raisonnement guidé par les buts en chaînage arrière (déduire la valeur du champ à partir de celle de plusieurs autres champs à l'aide d'un démon “si-besoin” : par exemple, si l'on cherche à renseigner le rapport entre la longueur des ailes et la longueur du corps d'un insecte, un message “rapport” est envoyé à la longueur des deux objets pour savoir s'ils sont connus. Si oui, le rapport peut être calculé sinon la procédure n'est pas déclenchée, et cela tant que les deux autres valeurs ne sont pas indiquées par l'utilisateur,

la **cardinalité** explicite le fait qu'un objet puisse être absent (0), présent (1), et s'il est présent, puisse être décrit plusieurs fois. Dans ce dernier cas, on parle alors de **mutiplicité** de l'objet,

l'**utilité** de l'objet indique son mode d'utilisation, soit qu'il est significatif pour la classification, soit qu'il est simplement là pour structurer la description (il est alors fictif, cf. § 4.6.4.1).

Chaque champ nommé est aussi un frame dépendant de l'objet auquel il est associé. Les champs possèdent leurs propres types (appelés *facettes*) qui donnent différentes informations complémentaires :

l'ensemble des valeurs possibles pour une classe (*range*), la valeur observée pour une instance. On doit noter ici que les champs de type relation ont des valeurs qui sont elles mêmes d'autres objets alors que les champs de type attribut possèdent des valeurs “terminales” non explicitées sous forme de frames. Il y a néanmoins une exception avec les valeurs qui sont classifiées (l'attribut possède alors une taxonomie de valeurs) et qui sont décrites aussi par des frames,

la valeur par défaut prise par l'attribut de l'objet,

la question associée au champ,

Outre le type *relation* expliqué ci-dessus, d'autres types permettent de préciser la nature des valeurs associées au champ : types nominal (valeurs discrètes), classifié (taxonomie de valeurs), booléen (oui-non), entier, réel, avec les combinaisons valides pour les types numériques (intervalle) et qualitatifs (ordonné),

la cardinalité de l'attribut qui indique le nombre de valeurs tolérées pour fournir une réponse plus ou moins précise à la question (cf. § 4.6.4.3).

L'intérêt d'utiliser cette approche se situe à deux niveaux :

Au niveau de la **description**, il est possible de concevoir un modèle d'organisation des connaissances selon différents points de vue détaillés au chapitre 4. L'idée principale est de proposer à un utilisateur quelconque du système un questionnaire sous la forme d'un guide d'observation (comment observer ?) avec le principe de pouvoir décrire du niveau le plus général au niveau le plus particulier (en partant de la racine !) selon différentes directions (dépendances et spécialisations). Ce guide est l'ossature du questionnaire, il n'est pour autant pas contraignant : si l'utilisateur désire directement décrire un objet à un niveau donné de la structure proposée, le questionnaire va inférer l'existence des objets dont il dépend avant de permettre la description de l'objet.

Au niveau de la **classification**, une procédure de filtrage des objets et des attributs pertinents dans le contexte d'un nœud de l'arbre de décision permet de contraindre l'espace des tests possibles pour le calcul du gain d'information. Pour ID3, le gain d'information est calculé pour tous les attributs qui n'apparaissent pas déjà dans le chemin courant de l'arbre (menant de la racine au nœud courant). Pour KATE, seuls les descripteurs applicables au nœud courant sont pris en compte pour le calcul du gain d'information de chacun d'eux (voir plus bas).

KATE n'est donc pas une nouvelle technique d'induction à part entière, elle représente une extension des algorithmes ID3 et Neddie pour le traitement de données complexes. Pour comprendre sur un exemple simple le principe de la discrimination par arbre selon ID3, on peut se référer à [Quinlan, 1983] et [Manago, 1988]. En analyse des données, il s'agit d'un processus analogue de segmentation [Diday, 1982].

Pour sa part, KATE teste systématiquement le gain d'information d'un attribut associé à un objet. Il exploite la structure des schémas pour engendrer dynamiquement les tests dont le gain d'information va être calculé [Manago *et al.*, 1991].

Considérons une base d'exemples pour une application de diagnostic en pathologie végétale (figure 1.2) :

Exemple	Maladie	Symptôme	...
ex1	Verticilliose	flétrissement	...
ex2	Botrytis	tache	...
ex3	Botrytis	tache	...
ex4	Alternariose	tache	...
.	.	.	.
.	.	.	.

Tache	Zonations(tache)	Taille(tache)	...
ex2	oui	18	...
ex3	non	16	...
ex4	oui	2	...
.	.	.	.
.	.	.	.

Fig. 1.2 : Tableau des exemples formés d'objets structurés pour les maladies des tomates

Le but est de reconnaître efficacement une maladie à partir de ses caractéristiques. L'algorithme d'induction de KATE permet de construire automatiquement un arbre de décision tel celui de la figure 1.3 :

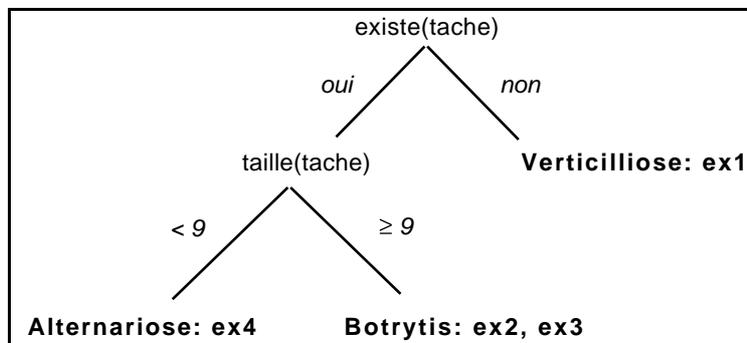


Fig. 1.3 : Un arbre de décision pour la reconnaissance de maladies de la tomate

Un nœud, dans l'arbre de décision, porte soit sur l'introduction d'un nouvel objet, soit sur un champ d'un objet apparaissant déjà dans l'arbre de décision. Les nœuds sont donc soit du type "Y a-t-il une tache ?" soit du type "Quelle est la taille de la tache déjà instanciée plus haut dans l'arbre ?"

- Quand tous les exemples conformes à la valeur du test (libellé à la branche courante de l'arbre de décision) contiennent un objet du même type (une tache par exemple), ses champs deviennent des tests candidats au calcul du gain d'information en plus des objets qui n'ont pas été introduits plus haut dans l'arbre. Le résultat du meilleur test conduit soit à introduire un nouvel objet dans le chemin courant de l'arbre de décision, soit à préciser la

description de l'objet courant au niveau de ses attributs ou encore de ses spécialisations.

- Si un seul des exemples au nœud courant ne contient pas un objet du même type, le gain d'information du test “existe(objet)” est calculé et les tests portants sur ses champs ne sont pas considérés.

Pour les détails concernant l'algorithme, voir le chapitre 7.

Cet arbre peut dans un deuxième temps être exploité pour identifier un nouveau cas : les nœuds de l'arbre correspondent à des questions posées à l'utilisateur, les feuilles correspondent aux diagnostics donnés par le système expert.

L'algorithme ID₃ utilise la mesure numérique du *gain d'information* dérivée des travaux en théorie de l'information fondée sur l'entropie [Shannon, 1949]. Le but est de déterminer à chaque niveau les critères les plus discriminants. En phase d'apprentissage de l'arbre, le gain d'information des différents critères est calculé et celui estimé le plus discriminant est sélectionné de façon irrévocable (pas de retour en arrière ou de recherche en faisceau). Ce processus est répété récursivement jusqu'à ce qu'il ne reste plus que des exemples de la même classe (ici le nom du diagnostic). ID₃ utilise une stratégie de recherche heuristique en gradient [Nilsson 1980] qui tend à produire un arbre globalement efficace : en moyenne, un nombre minimum de questions sont posées à l'utilisateur durant la consultation interactive de l'arbre de décision.

L'induction permet de transformer une base de données brutes en une connaissance opérationnelle exploitable. Elle permet en outre d'apprendre automatiquement trois types de connaissances :

- un ensemble de critères optimaux (en un certain sens) pour reconnaître efficacement un concept (une *généralisation* des exemples d'apprentissage),
- un ordre sur les critères en fonction de leur capacité à discriminer les exemples des différentes classes (information de contrôle),
- une partition des exemples d'apprentissage aux feuilles de l'arbre.

Outre la construction d'un arbre de décision, des règles de production peuvent ensuite être obtenues par élagage de l'arbre [Manago, 1988].

Comparé à d'autres algorithmes d'induction, ID₃ présente certains avantages : plusieurs exemples peuvent appartenir à la même classe dans la base à traiter, il peut y avoir plus de deux classes différentes à discriminer (nous ne sommes pas limité à un apprentissage de type exemples et contre-exemples), les critères nominaux (à valeurs discrètes) peuvent avoir plusieurs valeurs pour marquer l'imprécision des réponses de l'utilisateur, etc.. Les implantations de l'algorithme ID₃ gèrent également les critères à valeurs continues et ordonnées

(comme les valeurs entières et réelles) en “binarisant” le test. Un seuil est calculé dynamiquement comme pour le critère “taille” de la figure 1.3. Notons qu'un critère numérique peut apparaître à plusieurs reprises avec des seuils différents dans un même chemin de l'arbre. L'algorithme est très efficace et peut traiter de grosses bases d'exemples (la complexité algorithmique est linéaire en fonction du nombre des exemples). De plus, sa stratégie descendante (création de partitions des exemples au nœud courant) permet de traiter certains problèmes de “bruit” à l'aide de méthodes statistiques comme un élagage en ². Il permet également de prendre en compte des coûts associés aux critères et qui dépendent du domaine d'application: coût financier d'un test, durée d'intervention sur une chaîne de production pour une application dans l'industrie manufacturière, douleur infligée à un patient pour une application médicale, fiabilité d'un critère visuel pour une application d'aide à la photo-interprétation, etc.. On préférera ainsi faire deux tests qui ne coûtent rien plutôt qu'un seul qui a un coût associé. On peut donc optimiser d'autres critères outre l'efficacité du diagnostic.

1.5 L'aide à la classification au MNHN

A la suite de l'expérience en pathologie végétale décrite ci-dessus, une autre possibilité d'appliquer les systèmes experts a été proposée au MNHN (Muséum National d'Histoire Naturelle de Paris) au sein du Laboratoire de Biologie des Invertébrés Marins et de Malacologie (LBIMM, URA 699 du CNRS). Il ne s'agissait pas ici de faire de l'aide au diagnostic de symptômes décrits sur des invertébrés marins mais plutôt de concevoir et réaliser des outils informatiques pour aider les biologistes à identifier des spécimens, mais aussi à créer des regroupements de descriptions d'individus, d'espèces ou de sous-genres.

1.5.1 Comparaison avec l'opération SEPV de l'INRA

La problématique est ici analogue à la précédente en ce qui concerne la démarche scientifique, tout en étant plus générale :

au lieu de s'intéresser au couple “symptôme-diagnostic”, on travaille sur le couple “description-détermination”. En effet, le diagnostic peut être considéré comme une forme de détermination dans un certain contexte (la maladie) tout comme le symptôme est une forme de description selon ce même point de vue,

on s'intéresse davantage à la nature et à la diversité des spécimens eux-mêmes. L'objectif n'est pas seulement de déterminer un “avoir” (comme le nom de la maladie possédée par le spécimen), mais plutôt de déterminer un nom propre, ce qui fait “l'être” (c'est *Solanum lycopersicum*⁶), que l'on

⁶ Plus connu sous le nom vernaculaire de “tomate”.

appelle la *classe*, et qui permettra de reconnaître par la suite d'autres spécimens,

la classe est établie par l'étude des relations, l'analyse et la comparaison des différences et des ressemblances entre les divers spécimens qui composent l'échantillon. Les spécimens sont d'abord regroupés en *Espèces*, puis de manière ascendante, on regroupe les *Espèces* en *Genres*, puis les *Genres* en *Familles*, etc.. Le résultat est la fabrication d'une hiérarchie de classes ou taxinomie.

De ce fait au MNHN, nous ne sommes pas en présence d'un seul but d'identification d'un *avoir* (comme une maladie), mais aussi et surtout d'un objectif de **classification** (ce qui fait l'*être*).

Pour [Brusca R.C. & Brusca G.J., 1990] :

«The term biological classification has two meanings. First, it means the process of classifying, which consists of the delimiting, ordering, and ranking of organisms into groups. Second, it means the product of this process itself, or the classificatory scheme. The natural world has an objective structure that can be empirically documented and described. One goal of science is to describe this structure, and classifications are one way of doing this. Carrying out the process of classification constitutes one of the principal tasks of the systematist or taxonomist.»

La classification est donc plutôt un processus alors qu'une classification est assimilée à un résultat. Nous approfondirons la définition de la classification au chapitre 3. Les personnes chargées d'établir des classifications naturelles sont appelées des systématiciens. Pour [Matile *et al.*, 1987] :

«La systématique est l'étude et la description de la diversité des êtres vivants, la recherche de la nature et des causes de leurs différences et de leurs ressemblances, la mise en évidence des relations de parenté existant entre eux et l'élaboration d'une classification traduisant ces relations de parenté.»

Cette définition de la systématique est tout un programme qui a pour but La Classification Finale des êtres vivants (l'organisation de la nature qui s'impose à l'homme). Dans notre travail, nous nous contenterons d'étudier les aspects qui ne sont pas liés à la phylogénie et à l'évolution des êtres vivants, c'est-à-dire décrire, nommer, distinguer les différentes sortes et permettre l'identification de nouveaux échantillons.

Néanmoins, ces classifications servent de reformulation des descriptions et permettent de raffiner le modèle descriptif. C'est à partir de ce modèle que l'on pourra peut-être par la suite établir de vrais classifications fondées sur les reconstructions phylogénétiques.

Une autre caractéristique de notre approche est que les objets que l'on cherche à décrire dans cette thèse sont plutôt des spécimens que des *Espèces*, comme cela semble souhaitable au MNHN du fait que c'est le travail quotidien des

taxonomistes que de recueillir des collections d'individus et de les classer. Ainsi, nous nous plaçons du point de vue des nominalistes tels que Buffon ou Adanson qui soulignaient que les systématiciens ne peuvent étudier que des échantillons, sachant qu'ils n'ont pas la certitude qu'un échantillonnage ne renferme pas plusieurs Espèces qu'ils ne savent pas encore distinguer⁷ :

La détermination exacte de l'objet d'étude constitue un préliminaire indispensable à toute recherche [Matile *et al.*, 1987]. Par exemple, l'identification de maladies (le diagnostic) nécessite d'abord une classification des plantes afin d'identifier des objets comparables entre eux appartenant à une même classe bien établie : on ne compare pas les symptômes d'un plant de pomme de terre avec ceux d'un plant de tomate (bien qu'ils appartiennent tous les deux à la même famille des Solanacées !). De même, la classification des maladies nous est fournie au départ sans que l'on souhaite la remettre en cause (figure 1.4).

Inversement, la classification naturelle des spécimens étudiés au Muséum considère différentes classes qui ne sont ni sûres ni définitives : ces classes peuvent être elles mêmes remises en question dans l'avenir.

Dans le processus d'identification de maladies, c'est la description de l'association "symptôme-organe" dont le tout forme un *syndrome* qui est importante. Pour la détermination de spécimens, c'est simplement la description de l'organe (le composant) avec ses caractéristiques propres (selon différents points de vue) qui permet à elle seule de trouver le nom de la classe.

⁷ Dans ce contexte, la démarche du systématicien sur les spécimens est identique à celle du mathématicien sur les nombres. Ils forment des hypothèses en essayant de découvrir des régularités dans leurs observations, qu'ils expérimentent ensuite sur d'autres individus afin de renforcer ou réfuter leurs hypothèses.

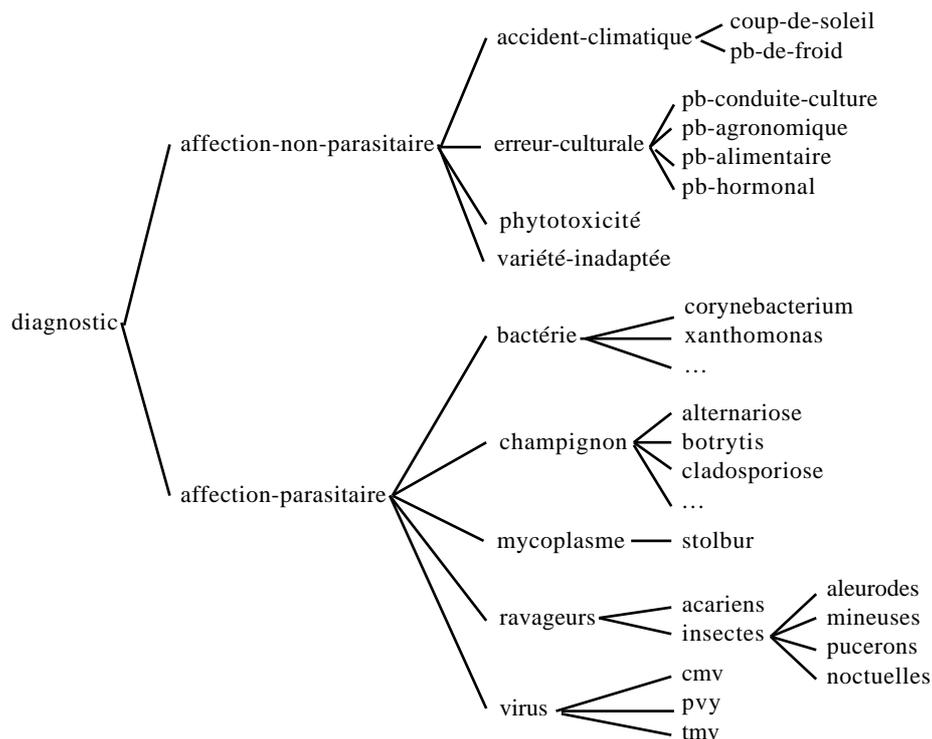


Fig. 1.4 : Une classification des maladies de la tomate

C'est pourquoi en pathologie végétale, on n'avait pas représenté explicitement la structure de la plante avec des objets composites (les organes) qui dépendent les uns des autres. On a plutôt cherché à représenter la hiérarchie de spécialisation des symptômes en englobant le nom de l'organe sur lequel ils étaient situés (figure 1.5) :

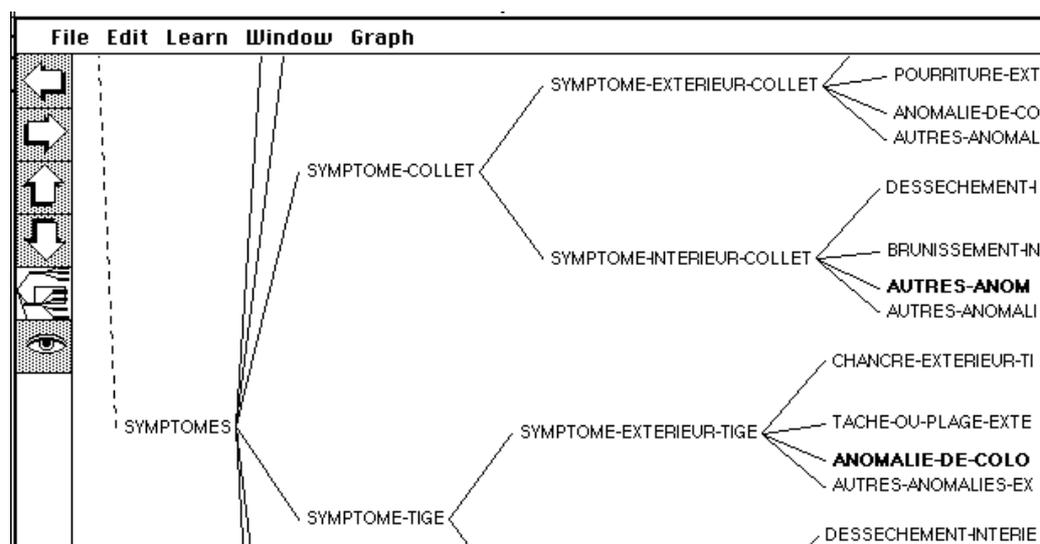


Fig. 1.5 : Représentation de la hiérarchie des symptômes dans TOM

Par cette pratique, on mettait en valeur la notion d'héritage dans les arbres de spécialisation qui permettait de regrouper les propriétés communes aux objets les plus spécifiques vers les objets les plus généraux (figure 1.6). Par exemple, la

localisation et la répartition du symptôme sur la tige sont des champs (attributs) de l'objet "symptôme-extérieur-tige" qui sont hérités par les différents noms de symptômes (chancre-extérieur-tige, tache-ou-plage-extérieur-tige, etc.). On pouvait aussi justifier le bien fondé de l'héritage multiple en faisant hériter l'attribut "mesure" d'une tache quelconque vers l'objet "tache-ou-plage-extérieur-tige", alors que la couleur dépend toutefois de l'organe ou se situe le symptôme (elle masque la couleur de la tache-ou-plage plus générale) :

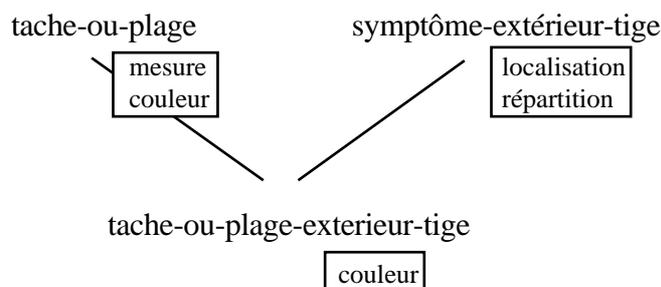


Fig. 1.6 : Représentation de la hiérarchie d'un symptôme en utilisant l'héritage multiple

Si ce mode de représentation est séduisant du point de vue informatique, il ne correspond pas du tout à la réalité biologique : un symptôme dépend d'un organe et non l'inverse ! De plus, la préoccupation de l'expert est d'obtenir des descriptions de qualité faites par lui-même ou d'autres biologistes. Comment faire alors pour guider l'observateur dans un tel graphe avec héritage multiple ? La préoccupation majeure de l'informaticien doit donc être de s'adapter à la réalité du domaine et de se prémunir contre son penchant naturel à vouloir faire "rentre" le domaine étudié dans un modèle préfabriqué, quand bien même il s'agirait d'un langage à "objets".

Il n'est d'ailleurs pas exclu que la notion d'"héritage multiple" ne corresponde à aucune réalité naturelle tangible, et ne constitue en fait qu'un artifice pour traiter de l'influence de contextes variables.

En fait dans le problème précédent, on a mélangé à tort deux dimensions orthogonales qui sont la composition d'objets et la spécialisation d'objets. Ces deux dimensions doivent être distinguées dans le modèle descriptif et dans la représentation des connaissances, comme nous le verrons au chapitre 4.

1.5.2 Utilisation des langages de frames et de l'hypertexte

Pour répondre au problème d'obtenir des descriptions de qualité qui tiennent compte de la manière d'observer de l'expert, nous nous sommes tourné vers un langage de type hypertexte : HyperTalk d'Hypercard™. Ce choix permettait de construire rapidement des prototypes de questionnaires sans avoir à se préoccuper de la représentation interne des connaissances.

Un questionnaire “sur mesure” pour l’application tomate a été fabriqué à l’INRA de Guadeloupe en 1989 à partir des propositions écrites dans le mémoire de fin d’études de l’ISARA. Nous nous sommes intéressé plus à l’aspect ergonomique du questionnaire en ajoutant des dessins expliquant le vocabulaire, des messages d’observation et des animations graphiques.

Entre temps, D. Blancard avait édité son manuel d’identification des maladies de la tomate basé à la fois sur la localisation des symptômes par organe et des descriptions graphiques (dessins, photos) de concepts (folioles filiformes, taches en œil d’oiseau sur fruit, etc.). Cet ouvrage est un véritable guide d’observation empruntant à TOM une grande partie de ses connaissances ainsi que la façon dont celles-ci sont organisées dans le système. Il peut servir de base à la conception d’un authentique questionnaire multimédia, ce qui permettrait [Blancard, 1988]. Il était clair que **le questionnaire devenait notre préoccupation majeure pour l’obtention d’exemples de qualité**. D’ailleurs, D. Blancard a par la suite édité un autre ouvrage sur d’autres cultures maraîchères, ce qui illustre bien l’intérêt porté à cette démarche nouvelle pour des outils de diagnostic.

Constatant que la procédure d’observation des symptômes sur différentes plantes utilisait le même schéma, c’est-à-dire un schéma fondé sur une description structurée par organes, l’idée est alors venue d’automatiser un processus de construction automatique de questionnaires en s’appuyant à la fois sur une structure de connaissances (frames) représentant le modèle descriptif et les entités hypertextes d’HyperCard (boutons, champs, cartes, etc.). Il ne serait alors plus la peine de fabriquer à chaque fois un questionnaire hypertexte par plante à partir de rien, mais de le générer à l’aide d’un programme associant les objets, attributs et valeurs des connaissances de fond aux entités hypertextes.

Cette trame de questionnaire pourrait être ensuite personnalisée par l’expert. Cette idée nouvelle a servi de base à l’élaboration de notre sujet de thèse présenté au MNHN, en collaboration avec l’INRA, l’INRIA et la société Acknowledge (rebaptisée Acknosoft en 1991).

Notons que le couplage entre des outils d’acquisition de connaissances, les langages de frames et l’hypertexte n’est pas neuf : ils permettent d’aborder le concept d’*Hypermedia* pour favoriser la communication des connaissances expertes vers des utilisateurs variés [Gaines & Linster, 1990]. D’autres auteurs [Rada & Barlow, 1989] se sont plus intéressés à la paire systèmes experts et hypertexte pour constituer le concept d’*expertexte*, mettant en avant le couplage entre les règles et les entités hypertextes et non pas entre les objets du modèle eux-mêmes et ces entités (ceci constitue l’originalité de notre travail, cf. § 6.4.2).

1.5.3 L'application SPONTAX

Le projet SPONTAX (acronyme signifiant “Sponge taxonomies”) servant de support d’application à cette thèse a pour objectif d’aider les biologistes à la classification et à la détermination d’éponges marines. Il est important de distinguer deux types de processus de classification pour bien fixer les objectifs :

Le premier type est la **classification naturelle** établie par les spécialistes qui ont regroupé les spécimens à des niveaux taxinomiques différents selon certains critères morphologiques et avec des méthodes diverses (embryologiques, biochimiques, histologiques, cytologiques, etc.). Les éponges appartiennent au Phylum Porifera (qui porte des pores) dans la Série des Invertébrés. Ce sont des animaux. Elles vivent presque toutes en milieu benthique (sur les fonds marins) à des profondeurs variées [Brusca R.C. & Brusca G.J., 1990]. A peu près 9000 espèces d’éponges ont été décrites au sein de trois Classes (Calcarea, Hexactinellida, Demospongia). Les Demospongia regroupent 95% des espèces vivantes décrites.

Les données sur lesquelles nous allons travailler représentent des spécimens d'un seul Genre d'éponges siliceuses appelé *Hyalonema* et appartenant à la Classe des Hexactinellida (figure 1.7). Ce sont principalement des éponges de grande profondeur ancrées dans des sédiments mous et bien individualisées.

Série	--> Invertébrés
Embranchement	--> Porifera
Classe	--> Hexactinellida
Ordre	--> Amphidiscophora
Famille	--> Hyalonematidæ
Genre	--> <i>Hyalonema</i>
Sous-Genre	--> <i>Prionema</i>
Espèce	--> <i>spinosum</i>

Fig. 1.7 : Disposition du Genre *Hyalonema* dans la hiérarchie linéenne

Le second type est la **classification artificielle** correspondant à une méthode informatique de partitionnement des descriptions. En analyse des données, les partitions obtenues (qui n’ont pas nécessairement de concept associé) produisent une classification alors qu’en intelligence artificielle, on recherche des définitions associées aux partitions (voir § 3.3.2). Le but poursuivi au départ du projet était de comparer deux classifications naturelles établies par deux experts au début du siècle [Schulze, 1902], [Ijima, 1926] avec une classification artificielle basée sur une technique informatique (apprentissage inductif avec KATE). Il faut savoir que les classifications qui ont été proposées sur ces espèces de *Hyalonema* sont essentiellement basées sur des caractères microscopiques liés aux différentes sortes de spicules⁸. Les

⁸ Les spicules sont de minuscules aiguilles siliceuses, dont l'agencement plus ou moins

exemples sur lesquels nous avons travaillé pour établir cette classification artificielle sont aussi bien des cas réels d'éponges, c'est-à-dire des descriptions de spécimens, que des cas virtuels. Ces derniers regroupent des descriptions de plusieurs spécimens dont on ne maîtrise pas toujours l'origine : les individus sont récoltés par dragage, ce qui ne permet pas de récupérer toujours des spécimens entiers. Est-ce que la description effectuée est celle d'un spécimen unique et entier ou bien a-t-elle été reconstituée à partir de morceaux d'individus différents jugés appartenir à la même classe ? Cette information n'est pas toujours indiquée dans les descriptions livresques anciennes.

L'autre but de l'étude au LBIMM est de construire un **système expert de détermination**, permettant de reconnaître des Sous-Genres de *Hyalonema* à partir de nouvelles observations d'éponges. Les observations sont des descriptions de nouveaux spécimens dont on ne connaît pas la classe de détermination, c'est-à-dire à quel Sous-Genre ils appartiennent.

De ces deux objectifs différents (classification et détermination) a découlé un troisième, celui de la **modélisation** des connaissances descriptives de l'expert. En effet, pour répondre aux objectifs de classification et de détermination, il est nécessaire de constituer une base de descriptions conforme à sa richesse et sa diversité naturelles : avec l'expérience acquise des autres projets (SEPV et INSTIL), nous savons qu'il ne faut pas appauvrir les données pour s'adapter aux outils de représentation des connaissances et aux algorithmes de traitement. Au contraire, il faut laisser s'exprimer toute l'expertise disponible dans les connaissances de départ. Ce point de vue est pour nous un **élément capital de la robustesse** des systèmes de détermination en biologie.

Nous nous sommes volontairement restreints au Genre *Hyalonema* pour lequel on peut disposer d'un grand nombre de descriptions répertoriées (plus d'une centaine). Le domaine à décrire est représentatif d'une grande majorité d'autres domaines en systématique, sans être trop complexe ni trop simple : les spécimens sont bien individualisés (ce ne sont pas des colonies), sans polymorphisme, et sont représentés par un squelette (et non par des parties molles plus sujettes aux modifications du milieu). Néanmoins, on peut trouver une grande variabilité de descriptions possible au sein d'un même Sous-Genre. Le choix de ce domaine a aussi été favorisé par la disponibilité bienveillante de l'expert M. Lévi, dont le départ définitif à la retraite poserait le problème crucial de la perte d'une expertise non transmise au MNHN. La nature restreinte, pas trop complexe, et bien délimitée du domaine a été retenue en priorité pour servir de support à la création des outils informatiques (éditeur de modèle descriptif et de questionnaire).

enchevêtré constitue une sorte de squelette qui rigidifie le corps mou de l'éponge.

Une fois créés, ces outils nous ont permis de concevoir un modèle descriptif et une base de 125 exemples classés en douze Sous-Genres. Le schéma de l'annexe 3 montre la distribution des descriptions en fonction des Sous-Genres. On trouve pour chacun d'eux les numéros d'exemples correspondants et le nombre de descriptions. La répartition n'est pas homogène, elle illustre la représentativité des Sous-Genres disponibles au moment de la récolte en mer (échantillonnage très aléatoire lié à la compétence scientifique de l'équipage) et dans la collection. Trois Sous-Genres sont rares (*Thamnonema*, *Phialonema* et *Onconema*) alors qu'un autre est abondant (*Cyliconema*). Cette abondance est à relier aussi au nombre de descriptions disponibles dans la littérature chez les différents auteurs.

Par rapport au traitement de ces descriptions, M. Lévi espère voir apparaître une classification dont il pourra *a posteriori* juger de l'efficacité (par rapport à l'état de ses connaissances). Il s'agit pour lui de savoir s'il est opportun de faire confiance à un système de classification artificiel pour son travail quotidien de systématicien.

1.6 Conclusion

A la suite de toutes ces années d'expérimentation, nous nous apercevons que nous avons traité la problématique de l'acquisition des connaissances à l'envers. En effet, les cognitiens de l'INRA ont commencé par utiliser des méthodes d'élicitation de connaissances et la logique mathématique pour représenter le savoir de l'expert sous forme de règles déductives ❶ (figure 1.8).

Or, ils se sont rendu compte que :

l'expert a des difficultés à exprimer ses règles oralement,
les domaines traités ne sont pas caractérisés par l'heuristique et
l'expérience acquise,
le formalisme des règles de production est inadapté à certaines formes de
raisonnement non monotone, les cas atypiques ou exceptionnels étant
difficilement pris en compte par ce formalisme,
la maintenance d'une base de règles est délicate, etc..

L'émergence des techniques d'apprentissage et des langages à base d'objets a donné alors la possibilité de mettre au point des méthodes inductives d'extraction de règles automatiquement à partir d'exemples représentés par des frames ❷. En adoptant ce principe dans INSTIL, on a déplacé le problème de l'acquisition des connaissances en amont, c'est-à-dire au niveau de l'acquisition des exemples à l'aide d'un questionnaire. Les chercheurs en informatique espéraient de cette manière générer un modèle du domaine automatiquement à partir du traitement inductif des exemples [INSTIL Project Summary, p. 40, 1989]. C'était sans compter la difficulté d'obtenir des descriptions de qualité pour apprendre de bonnes règles [Conruyt & Piaton, 1987],[Conruyt, 1988]. Cette qualité découle des bonnes observations que doit effectuer l'utilisateur du système, qu'il soit expert ou non. En construisant plusieurs questionnaires sur un même problème et en les confrontant à la réalité du terrain (le contexte de description et le vocabulaire sont différents entre les utilisateurs et l'expert), l'expert s'est rendu compte qu'il existait une structure fondamentale de description de son domaine sur lequel devait s'appuyer le questionnaire pour guider correctement l'observateur [Blancard, 1989]. Nous avons nommé cette structure le *modèle descriptif*. Le cogniticien se doit de représenter correctement ces connaissances de fond que l'on appellera aussi "l'observable" dans nos applications. Ces connaissances implicites sont souvent "de bon sens" et dépendantes du domaine. Le cogniticien ne peut pas se passer de l'aide de l'expert pour les expliciter.

Donc, le problème s'est encore déplacé d'un cran en amont afin de savoir comment acquérir un bon modèle descriptif du domaine ❸. C'est finalement cette question qui est pour nous à la source du problème de l'acquisition des

connaissances dans le contexte de l'apprentissage à partir d'exemples... de qualité.

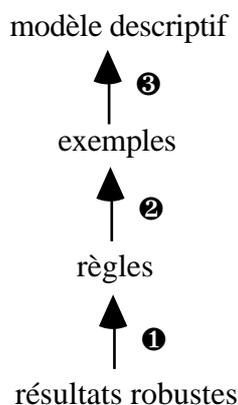


Fig. 1.8 : Chronologie de notre approche de l'acquisition des connaissances

L'acquisition de cette ⁹ du domaine est aussi l'objet de recherches actives dans le cadre de la modélisation des connaissances [Reynaud & Tort, 1994], [Charlet *et al.*, 1994] et de la méthodologie KADS [Breuker & Wielinga, 1989]. Mais leur méthode et la notre n'ont rien à voir !

D'une part, leur approche est axée sur la modélisation du raisonnement de l'expert : nous préférons déléguer la construction du raisonnement aux outils d'apprentissage, qui renvoient une image résumée des connaissances de l'expert. Ce dernier peut ensuite les analyser à la lumière des descriptions qu'il a introduites. Ainsi, en faisant une interface entre l'expert et sa connaissance, nous fournissons une aide à l'expert avant tout alors que la méthodologie KADS fournit une aide au cognicien pour éliciter les connaissances expertes.

D'autre part, bien qu'elle soit vue comme un standard de l'ingénierie de la connaissance, KADS est une approche descendante, c'est-à-dire qu'elle a été pensée au niveau conceptuel, puis appliquée ensuite dans différents domaines, la plupart industriels. Pour nous, la méthodologie KADS est trop générique, théorique et abstraite et ne s'adapte pas facilement aux spécificités des domaines biologiques que nous voulons traiter. Comme nous l'expliquerons au chapitre 3, la diversité et la complexité des objets naturels à traiter nous obligent à l'inverse à expérimenter des solutions adaptées à des problèmes concrets posés par les utilisateurs. Nous passons ainsi d'un niveau pratique à un niveau théorique (approche expérimentale ascendante). En privilégiant l'observation et l'écoute des besoins des utilisateurs, nous parions sur une adaptation progressive des outils à leur demande, ce qui constitue pour nous le véritable défi de la robustesse de l'acquisition des connaissances.

⁹ (Philo) : la partie de la métaphysique qui s'intéresse à l'Être en tant qu'Être [Petit Robert, 1993]. Il s'agit donc ici de décider quels sont les objets que l'on retient comme existant dans le domaine selon leur pertinence vis à vis de l'objectif à atteindre.

En fait, nous sommes plus proches de la démarche expérimentale propre à la Statistique telle qu'elle est exprimée par Tomassone [Tomassone, 1991] (voir chapitre 2). Nous y ajouterons toutefois l'impératif d'explicitier le modèle descriptif pour obtenir des données de qualité : c'est un élément majeur de la robustesse des systèmes de détermination. Un des buts de cette thèse est d'apporter une solution à ce problème d'acquisition de descriptions robustes (observables et observées) dans le domaine de la biologie qui nous intéresse.

Pour nous, le modèle descriptif n'est pas l'ensemble des règles apprises par une ou l'autre des techniques d'induction. Il n'est pas une intension du domaine dévoilée par le traitement de l'observé comme pourraient le penser certains informaticiens trop éloignés des applications. Le modèle descriptif est l'ensemble des connaissances observables initiales exprimant la structure naturelle du domaine que l'expert doit expliciter. Cette tâche permet la transmission de son "savoir observer" au sein d'un questionnaire, véritable guide d'observation. En utilisant ce guide, l'observateur est à même de fournir des descriptions les plus complètes et cohérentes possibles qui soient l'image la plus proche des individus ou spécimens à décrire.

Une fois que la source du problème de l'acquisition des connaissances a été identifiée, nous sommes capables de reconsidérer la problématique dans le bon sens, en partant d'un modèle descriptif du domaine et en procédant par étapes jusqu'aux résultats :

- 1) Acquisition du modèle descriptif,
- 2) Acquisition des exemples ou des cas,
- 3) Traitement des connaissances descriptives,
- 4) Validation des résultats.

Il reste néanmoins à définir les objectifs du système afin de pouvoir adapter les outils de traitement des descriptions. Les besoins des biologistes rencontrés au MNHN sont multiples, mais parmi eux, les systématiciens et les naturalistes font appel surtout à des outils d'aide à la classification et à l'identification de spécimens, qui se basent sur leur travail quotidien.

