

UNIVERSITÉ DU QUÉBEC À MONTRÉAL

MODÉLISATION DE L'APPRENTISSAGE ASCENDANT DES CONNAISSANCES
EXPLICITES DANS UNE ARCHITECTURE COGNITIVE HYBRIDE

THÈSE
PRÉSENTÉ
COMME EXIGENCE PARTIELLE
DU DOCTORAT EN INFORMATIQUE COGNITIVE

PAR
SÉBASTIEN HÉLIE

MARS 2007

UNIVERSITÉ DU QUÉBEC À MONTRÉAL
Service des bibliothèques

Avertissement

La diffusion de cette thèse se fait dans le respect des droits de son auteur, qui a signé le formulaire *Autorisation de reproduire et de diffuser un travail de recherche de cycles supérieurs* (SDU-522 – Rév.01-2006). Cette autorisation stipule que «conformément à l'article 11 du Règlement no 8 des études de cycles supérieurs, [l'auteur] concède à l'Université du Québec à Montréal une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de [son] travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, [l'auteur] autorise l'Université du Québec à Montréal à reproduire, diffuser, prêter, distribuer ou vendre des copies de [son] travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de [la] part [de l'auteur] à [ses] droits moraux ni à [ses] droits de propriété intellectuelle. Sauf entente contraire, [l'auteur] conserve la liberté de diffuser et de commercialiser ou non ce travail dont [il] possède un exemplaire.»

REMERCIEMENT

J'aimerais d'abord remercier Dr. Robert Proulx, doyen de la faculté des sciences humaines à l'Université du Québec À Montréal et superviseur des travaux liés à la présente thèse, pour son soutien et ses commentaires au cours des quatre dernières années. De même, j'aimerais remercier Dr. Denis Cousineau, professeur au département de psychologie de l'Université de Montréal et superviseur des travaux liés à mon mémoire de maîtrise, pour son amitié ainsi que pour m'avoir enseigné la rigueur nécessaire à l'activité scientifique. De plus, il y a lieu de remercier Dr. Bernard Lefebvre, professeur au département d'informatique de l'Université du Québec À Montréal et co-directeur de la présente thèse, pour sa collaboration et ses encouragements tout au long des travaux effectués. Finalement, l'auteur tient à remercier Dr. Mark Steyvers, professeur au département de sciences cognitives à University of California Irvine, pour la transmission de statistiques descriptives des données empiriques modélisées dans la Section 6.1.

Plusieurs collègues et amis ont contribué de près ou de loin aux travaux présentés dans ce document. D'abord, je remercie Dr. Sylvain Chartier, stagiaire postdoctoral au centre de recherche de l'Institut Philippe Pinel, pour de nombreuses discussions fructueuses ainsi que pour son aide dans les travaux liés à la présente thèse. Aussi, j'aimerais souligner la contribution de mes collègues Gyslain Giguère, étudiants au programme de doctorat en informatique cognitive de l'Université du Québec À Montréal, et Dr. Dominic Forest, Professeur à l'école de bibliothéconomie et des sciences de l'information de l'Université de Montréal : de nombreuses discussions ainsi que leurs commentaires sur des versions précédentes de la présente thèse ont grandement amélioré la qualité des travaux ainsi que celle de leur présentation. Finalement, j'aimerais remercier Gabrielle Beaulieu, mon épouse, pour son support, son amitié, et son amour au cours de mes études universitaires et pour les années à venir.

Cette thèse a été rendue possible grâce au support financier du Fonds Québécois pour la Recherche sur la Nature et les Technologies ainsi qu'à celui du Conseil de Recherches en Sciences Naturelles et en Génie du Canada.

TABLE DES MATIÈRES

LISTE DES FIGURES	vii
LISTE DES TABLEAUX.....	x
RÉSUMÉ	xi
INTRODUCTION	1
CHAPITRE I	
L'UTILISATION D'ARCHITECTURES COGNITIVES COMME PRINCIPE UNIFICATEUR DE LA MODÉLISATION PSYCHOLOGIQUE.....	5
1.1 Le test de Newell	6
1.2 Le décathlon cognitif selon Sun (2004).....	8
1.3 Évaluation des architectures existantes.....	10
1.4 CLARION: Un modèle d'induction dans une architecture cognitive.....	13
1.5 CLARION: Problèmes d'implémentation et faiblesses théoriques	17
1.6 Conclusion	20
CHAPITRE II	
DÉVELOPPEMENT D'UNE THÉORIE GÉNÉRALE DE LA COGNITION HUMAINE .	21
2.1 Postulats.....	22
2.2 Analyse rationnelle de la cognition.....	27
2.3 Le raisonnement incertain.....	28
2.4 La recherche de causalité.....	29
2.5 Conclusion	30
CHAPITRE III	
BIAIS ENVIRONNEMENTAUX ET APPRENTISSAGE NON-SUPERVISÉ	31
3.1 L'élégance d'un environnement orthogonal	31
3.1.1 Stimuli et environnements.....	32
3.1.2 Modèles	33
3.1.3 Résultats et discussion.....	35
3.2 La complexité d'un environnement corrélé	39

3.2.1	Stimuli et environnements	40
3.2.2	Modèles	40
3.2.3	Résultats et discussion.....	43
3.3	Conclusion	47
CHAPITRE IV		
APPRENTISSAGE DE LA DISTRIBUTION CONJOINTE DE L'ENVIRONNEMENT		
À L'AIDE D'UN NOUVEAU MODÈLE CONNEXIONNISTE NON-SUPERVISÉ.....		
4.1	Modèle	51
4.1.1	Architecture	51
4.1.2	Transmission ascendante	53
4.1.3	Transmission descendante	54
4.1.4	Apprentissage	55
4.2	Simulations	56
4.2.1	Apprentissage ascendant d'une distribution conjointe	57
4.2.2	Apprentissage interactif de catégories non-linéairement séparables	60
4.3	Conclusion	62
CHAPITRE V		
DÉVELOPPEMENT D'UN MODÈLE GÉNÉRAL DE LA COGNITION HUMAINE.....		
5.1	Architecture générale.....	65
5.2	Connaissances implicites	66
5.3	Connaissances explicites.....	69
5.4	Interaction synergique de l'information implicite et explicite.....	74
5.5	Apprentissage.....	75
5.6	Conclusion	79
CHAPITRE VI		
ÉVALUATION DE TELECAST		
6.1	Apprentissage ascendant des connaissances explicites.....	80
6.1.1	Expérience et prédictions du modèle existant	81
6.1.2	Prédictions de TELECAST	85
6.1.3	Discussion	88
6.2	Interaction des connaissances implicites et explicites dans une tâche d'apprentissage de séquences	89
6.2.1	Expérience	89

6.2.2	Prédictions du DSRN	92
6.2.3	Prédictions de CLARION.....	94
6.2.4	Prédictions de TELECAST	97
6.2.5	Discussion	101
6.3	Conclusion	101
CONCLUSION.....		103
APPENDICE A		
DÉMONSTRATION DU BIAIS DE ARTI		108
RÉFÉRENCES		110

LISTE DES FIGURES

Figure		Page
1.1	Architecture de CLARION. (Tirée de Sun et al., 2001.).....	14
2.1	Exemple de réseau de connaissances Bayésien.....	27
3.1	Stimuli utilisés pour former les environnements simples. (Tirée de Hélié et al., 2006 _a .).....	32
3.2	Distributions utilisées comme environnements simples. (a) Distribution uniforme. (b) Distribution bimodale. (c) Distribution en escalier. (d) Distribution exponentielle (Tirée de Hélié et al., 2006 _a .)	33
3.3	(a) Architecture du BSB. Le carré gris représente un délai dans la transmission. (b) Architecture du réseau compétitif. (Tirée de Hélié et al., 2006 _a .).....	34
3.4	Valeurs propres de la matrice de poids de connexions développée par le BSB. Les cases représentent les mêmes conditions que dans la Figure 3.2. (Tirée de Hélié et al., 2006 _a .)	36
3.5	Vecteurs propres de la matrice de connexions du BSB. Dans chaque case, la première ligne représente la catégorie « A » alors que la seconde représente la catégorie « B ». Les cases représentent les conditions de la Figure 3.2. (Tirée de Hélié et al., 2006 _a .).....	37
3.6	Vecteurs de poids de connexions du modèle compétitif rendus discrets suite à un écrasement. Les cases représentent les conditions de la Figure 3.2. (Tirée de Hélié et al., 2006 _a .).....	38
3.7	Stimuli utilisés pour former les environnements complexes. (Tirée de Hélié et al., 2006 _a .).....	40
3.8	Distributions utilisées comme environnements complexes. (a) Distribution uniforme. (b) Distribution multimodale. (c) Distribution en escalier. (d) Distribution exponentielle (Tirée de Hélié et al., 2006 _a .)	41
3.9	(a) Architecture de NDRAM. (b) Architecture de ART1. Les cercles représentent des mécanismes de sélection alors que les rectangles représentent des couches de neurones. La partie à gauche des pointillés est le réseau comme tel, alors que la partie droite représente le module de vigilance. (Tirée de Hélié et al., 2006 _a .).....	41

3.10	Valeurs propres développées par NDRAM après entraînement dans chacune des conditions. Les cases représentent les mêmes conditions que dans la Figure 3.8. (Tirée de Hélie et al., 2006 _a .)	44
3.11	(A) Attracteurs développés par NDRAM après entraînement dans chaque condition. (B) Poids de connexions (W_{bu}) développés par ART1 dans chaque condition. L'ordre des unités de F2 est respecté. Dans les deux cases, les conditions sont celles présentées à la Figure 3.8.	45
4.1	Architecture de JPEX. Les cercles noirs représentent des connexions. (Tirée de Hélie et al., 2006 _b .)	52
4.2	Stimuli utilisés dans les simulations.	57
4.3	Poids compétitifs développés par JPEX. Chaque ligne représente un champ récepteur différent. L'ordre des unités dans la couche de sortie est respecté.	58
4.4	Associations devant être apprises par JPEX.	61
4.5	Performance de JPEX au problème du OU-Exclusif.	62
5.1	Architecture générale de TELECAST.	66
5.2	Architecture modifiée de JPEX utilisée pour modéliser les connaissances implicites dans TELECAST.	68
5.3	Hypergraphe de connaissances Bayésien utilisé pour représenter les connaissances explicites dans TELECAST.	70
5.4	Exemple de réseau de connaissances Bayésien avec paramètres. (Tirée de Neapolitan, 2004.)	73
6.1	Structures causales à différencier dans la première expérience de Steyvers et al. (2003). (a) Cause commune. (b) Effet commun.	81
6.2	Exemple d'affichage. (Tirée de Steyvers et al., 2003.)	82
6.3	Résultats empiriques et prédictions du modèle. (Tirée de Steyvers et al., 2003.)	83
6.4	Stimuli utilisés pour simuler la tâche de Steyvers et al. (2003).	85
6.5	Résultats des simulations à l'aide de TELECAST.	88
6.6	Structure et résultats de l'Expérience 1. (Tirée de Curran et Keele, 1993.)	90
6.7	Architecture du DSRN. (Tirée de Cleeremans, 1993.)	93

6.8	Résultats obtenus à l'aide du DSRN. (Tirée de Sun et al., 2005.).....	94
6.9	Résultats obtenus à l'aide de CLARION. (Tirée de Sun et al., 2005.).....	96
6.10	Stimuli utilisés pour simuler la tâche de Curran et Keele (1993).....	98
6.11	Prédictions de TELECAST dans la tâche de Curran et Keele (1993). La ligne discontinue représente le groupe insensible, la ligne pleine le groupe sensible, et la ligne pointillée le groupe intentionnel.	100

LISTE DES TABLEAUX

Tableau		Page
1.1	Critères d'évaluation des architectures cognitives	7
2.1	Étapes de l'analyse rationnelle de la cognition	28
3.1	Équations décrivant les modèles utilisés dans les environnements simples	35
3.2	Classification des vecteurs aléatoires dans les environnements simples	39
3.3	Équations du modèle NDRAM	42
3.4	Équations du modèle ART1	43
3.5	Classification des vecteurs aléatoires dans les environnements complexes	46
4.1	Densité utilisée pour entraîner JPEX et le modèle Hebbien	57
4.2	Densité estimée par JPEX	59
4.3	Covariance estimée par le modèle Hebbien	60
5.1	Algorithme utilisé par TELECAST pour construire le réseau de connaissances Bayésien	78
6.1	Paramètres libres utilisés dans TELECAST	87
6.2	Paramètres libres utilisés dans CLARION	95

RÉSUMÉ

Le but de la présente recherche est de développer une théorie unificatrice de la cognition humaine et de proposer un modèle l'implémentant. Pour ce faire, les architectures cognitives existantes (ACT-R, SOAR, EPIC et CLARION) ont été comparées à l'aide du test de Newell et du décathlon cognitif proposé par Sun. Parmi les architectures recensées, CLARION est la seule à expliquer l'apprentissage ascendant des connaissances explicites, en plus d'expliquer l'interaction synergique entre les connaissances explicites et implicites. L'importance de ces deux phénomènes, tant aux niveaux théorique qu'empirique, ainsi que l'absence de leur explication dans la plupart des architectures cognitives connues, justifie leur emphase dans la théorie développée. De plus, la théorie proposée postule que les connaissances implicites se développent de façon autonome et que les connaissances explicites sont incertaines.

Afin de modéliser les connaissances implicites, un réseau connexionniste non-supervisé doit être développé. Pour ce faire, deux grandes familles de modèles connexionnistes non-supervisés ont été comparées à l'aide de simulations : les réseaux compétitifs et les mémoires associatives. Les résultats montrent que seules les mémoires associatives sont en mesure d'effectuer une estimation de la densité environnementale; ce type de modèle doit donc être inclus dans la modélisation des connaissances implicites. Cependant, aucune des mémoires associatives existantes n'est en mesure de construire complètement les connaissances explicites (apprentissage ascendant des règles et des symboles). Ainsi, une nouvelle mémoire associative bidirectionnelle est développée (JPEX). JPEX est en mesure d'extraire les états de l'environnement (symboles) et d'estimer leur distribution conjointe.

Les connaissances explicites sont modélisées à l'aide d'un réseau de connaissances Bayésien. Comme ce dernier est un graphe d'indépendances qui représente une distribution conjointe, celui-ci peut être construit directement à partir des poids de connexions de JPEX. Le réseau de connaissances Bayésien résultant peut être interprété comme un ensemble de règles incertaines. Une fois ces deux modules en place, le modèle complet peut être implémenté.

L'architecture cognitive proposée s'appelle Tensor LEarning of CAusal STructure (TELECAST). Cette implémentation de la théorie unificatrice développée tient compte de toutes les contraintes énumérées. À l'aide de TELECAST, une tâche d'inférence de structures causales et une tâche d'apprentissage de séquences sont modélisées. Les résultats montrent que TELECAST fait au moins aussi bien qu'un modèle spécifiquement développé pour la tâche d'inférence causale, tout en étant assez général pour modéliser d'autres expériences. Dans la tâche d'apprentissage de séquences, TELECAST prédit plus précisément les données empiriques que les modèles qui le précèdent, tout en ayant moins de paramètres libres. Cet

accord entre les prédictions de TELECAST et les données colligées en psychologie cognitive, ainsi que la localité des calculs effectués, confirment la plausibilité psychologique de cette nouvelle architecture cognitive. Pour conclure, TELECAST est évalué à l'aide du test de Newell ainsi que du décathlon cognitif proposé par Sun. Cette évaluation permet de mettre en évidence l'absence d'un élément important dans TELECAST, soit une procédure d'apprentissage descendant. Des travaux futurs liés à l'ajout de cette procédure permettront à TELECAST d'expliquer l'automatisation des activités routinières chez les participants humains.

Mots clés : modèle hybride, apprentissage ascendant, réseau connexionniste, réseau Bayésien, architecture cognitive.

INTRODUCTION

Depuis le milieu des années quatre-vingt, la modélisation cognitive occupe de plus en plus de place en psychologie (Pitt et Myung, 2002). Ces modèles, conçus spécifiquement pour expliquer les données colligées à l'aide d'un paradigme expérimental particulier, font des prédictions quantitatives de plus en plus précises (Roberts et Pashler, 2000). Cette précision, reflétée par la diminution d'une mesure d'erreur, se fait habituellement en ajoutant des paramètres libres au modèle, et le *sur-apprentissage (overfitting)* est un problème courant (Geman, Bienenstock, et Doursat, 1992). L'un des problèmes découlant de cette approche en modélisation est la perte de perspective. Souvent, le modèle résultant n'offre aucune explication nouvelle quant au processus modélisé et la justification des paramètres est peu plausible ou déficiente (validité externe: Robert, 1988). Sans la possibilité de contribuer à l'explication des phénomènes cognitifs, un modèle devient une simple équation, et l'évaluation d'un *modèle* devient une question purement numérique ou mathématique.

Devant ce problème grandissant, Newell (1990) a proposé de réorienter la recherche sur la modélisation en psychologie. Plutôt que de développer isolément des théories spécifiques à chaque domaine, les chercheurs devraient prendre du recul et chercher une théorie unificatrice. Un tel projet implique l'utilisation d'*architectures cognitives*, qui sont des modèles généraux pouvant expliquer les données colligées dans plusieurs domaines simultanément (Newell, 1992). Ainsi, le problème de la compatibilité entre les modèles disparaît et l'attention est redirigée vers les principes à la base des architectures; non sur les paramètres. Afin d'illustrer son projet, Newell proposa *SOAR* (Laird, Newell, et Rosenbloom, 1987) comme architecture cognitive. Il convient de mentionner qu'à cette époque, très peu de théories étaient assez générales pour être qualifiées d'architectures cognitives, la seule exception à notre connaissance étant le *Adaptive Control of Thought (ACT)*: Anderson, 1983). Aussi, comme l'emphase doit être mise sur les principes des architectures cognitives et non sur les paramètres, l'évaluation et la comparaison de leurs performances est problématique. Cependant, ce problème fut anticipé par Newell, qui prit soin d'énumérer une liste de critères

devant éventuellement être rencontrés par les architectures cognitives. Malheureusement, Newell n'eut pas le temps de peaufiner cette liste, et elle fut ignorée pendant plusieurs années.

Une dizaine d'années plus tard, Anderson et Lebiere (2003) ont revus les critères de Newell afin de proposer le *test de Newell*. Ce test comprend les douze critères originaux et une architecture accumule des points liés à sa performance pour chaque critère (i.e., il s'agit d'un *décathlon cognitif*: Vere, 1992). Selon Anderson et Lebiere, la plus récente version de ACT (ACT-R: Anderson et al., 2004) se compare avantageusement aux modèles connexionnistes multicouches dans le test de Newell. Jusqu'à présent, aucune autre comparaison n'a été effectuée.

Pour amorcer les travaux liés à la présente thèse, le test de Newell et le décathlon cognitif proposé par Sun (2004) ont été utilisés pour comparer ACT-R et SOAR avec une autre architecture cognitive plus récente, le *Executive Process-Interactive Control (EPIC)*: Meyer et Kieras, 1997). Bien que les résultats donnent un léger avantage à ACT-R, ce dernier est incapable d'expliquer l'apprentissage ascendant des connaissances explicites et l'interaction entre les connaissances explicites et implicites. Ces deux critères, absents du test de Newell, sont fondamentaux dans le décathlon cognitif. Suivant ce constat, Sun propose une nouvelle architecture cognitive pour expliquer ces phénomènes: le *Connectionist Learning with Adaptive Rule Induction ON-line (CLARION)*: Sun et Peterson, 1998_a, 1998_b; Sun, Merrill, et Peterson, 2001). Le nouveau modèle proposé remporte de loin le décathlon cognitif, et fait au moins aussi bien que ACT-R dans le test de Newell: CLARION est l'architecture cognitive la plus sophistiquée en ce moment, et tous nouveaux modèles doit pouvoir s'y mesurer. Ainsi, le but de la présente thèse est de développer une nouvelle architecture cognitive capable de se mesurer à CLARION au test de Newell et dans le décathlon cognitif.

Le point de départ des travaux présentés est l'identification de deux faiblesses théoriques et deux erreurs d'implémentation dans CLARION. Au niveau théorique, le module procédural (implicite) de CLARION utilise un réseau connexionniste supervisé, alors que les expériences portant sur l'apprentissage implicite ne fournissent habituellement pas de rétroaction aux participants (Cleeremans, 1997; Cleeremans, Destrebecqz, et Boyer, 1998;

Curran et Keele, 1993). De plus, les règles déclaratives représentant les connaissances explicites sont déterministes, alors que les données empiriques suggèrent l'utilisation de règles incertaines (McClelland et Chappell, 1998; Movellan et McClelland, 2001; Oaksford et Chater, 1998; Shiffrin et Steyvers, 1997). Au niveau de l'implémentation, CLARION utilise des représentations distribuées pour représenter les connaissances implicites, alors que ces dernières devraient être sous-symboliques (i.e., les éléments du vecteur représentationnel ne devraient pas référer à une caractéristique). L'utilisation de sous-symboles pour représenter les connaissances implicites rappelle la difficulté à accéder à ce type de connaissances (Cleeremans, 1997; Sun et al., 2001). Aussi, l'apprentissage ascendant des règles propositionnelles se trouvant dans le module déclaratif est partiel; seules les règles sont apprises, pas les propositions. La présente recherche propose de solutionner les problèmes théoriques et les erreurs d'implémentation de CLARION à l'aide d'un modèle hybride utilisant un nouveau réseau connexionniste sous-symbolique non-supervisé (le Joint Probability EXtractor: Hélie, Proulx, et Lefebvre, 2006_b) pour représenter les connaissances implicites et un réseau de connaissances Bayésien (Neapolitan, 2004; Pearl, 1988, 2000) pour représenter les connaissances explicites. Ainsi, l'apprentissage implicite se fait sans rétroaction, l'information implicite est codée de façon sous-symbolique, et les connaissances explicites sont incertaines et entièrement construites de façon ascendante (un réseau Bayésien est une distribution). La performance du modèle résultant, TENSOR LEARNING OF CAUSAL STRUCTURE (TELECAST), a été évaluée en comparant ses prédictions avec les données colligées dans des tâches d'inférence de structures causales (Steyvers et al., 2003) et d'apprentissage de séquences (Curran et Keele, 1993).

Cet ouvrage est organisé comme suit. Le Chapitre I présente le test de Newell et le décathlon cognitif. Ces critères d'évaluation sont utilisés afin de départager les architectures cognitives suivantes: ACT-R, SOAR, EPIC, et CLARION. Comme CLARION est le grand gagnant, le fonctionnement de ce modèle est détaillé avant de présenter ses faiblesses théoriques et ses erreurs d'implémentation. Ensuite, le Chapitre II présente les principes à la base de l'architecture cognitive développée dans la présente thèse. Comme le succès de l'architecture proposée repose en grande partie sur le modèle utilisé pour représenter les connaissances implicites (apprentissage ascendant), le Chapitre III porte sur l'étude de deux grandes familles de modèles non-supervisés, soit les réseaux compétitifs (i.e., Carpenter et

Grossberg, 1987; Kohonen, 1982; Rumelhart et Zipser, 1986) et les mémoires associatives (i.e, Anderson et al., 1977; Hopfield, 1982; Kosko, 1988). La capacité des mémoires associatives à effectuer une estimation de densité suggère son utilisation pour modéliser les connaissances implicites. Cependant, à notre connaissance, aucune mémoire associative existante n'est en mesure d'extraire toute l'information nécessaire à l'émergence d'un réseau de connaissances Bayésien. Le Chapitre IV porte donc sur le développement d'un tel modèle, JPEX. Une fois le module implicite en place, l'architecture de TELECAST peut être construite. Le Chapitre V sert à présenter ce nouveau modèle. La plausibilité psychologique de TELECAST est mise à l'épreuve dans le Chapitre VI qui présente les résultats de simulations du processus d'apprentissage ascendant des connaissances explicites, ainsi que de celui d'interaction synergique entre les connaissances explicites et implicites. Finalement, la conclusion sert à évaluer le modèle développé à l'aide du test de Newell et du décathlon cognitif. Comme les résultats sont positifs, plusieurs pistes de recherches pour des travaux futurs sont ensuite proposées.

CHAPITRE I

L'UTILISATION D'ARCHITECTURES COGNITIVES COMME PRINCIPE UNIFICATEUR DE LA MODÉLISATION PSYCHOLOGIQUE

Depuis le siècle des Lumières, la recherche liée à l'unification des théories a eu un fort impact sur les explications utilisées dans plusieurs domaines fondamentaux de la physique. Par exemple, Newton a unifié la théorie du mouvement céleste avec celle du mouvement terrestre, alors que Maxwell a unifié les théories liées à l'électricité et au magnétisme. Bien que plusieurs centaines d'années furent nécessaires pour que les travaux portant sur l'unification des théories constituent une contribution significative à l'explication des phénomènes physiques, certains chercheurs croient que la science cognitive, malgré son évidente jeunesse, peut dès maintenant bénéficier du principe d'unification (Anderson et Lebiere, 2003; Newell, 1992; Sun, 2004). Selon Newell (1992), les données colligées en psychologie sous-déterminent les théories cognitives (i.e., elles supportent simultanément un grand nombre de modèles), et ce manque de contraintes peut être en partie compensé par des exigences quant à la généralité des théories proposées. Ainsi, l'utilisation de modèles cognitifs généraux, permettant l'explication de plusieurs types de données, serait préférable à celle de modèles spécifiques, puisque les premiers sont plus facilement falsifiables (Popper, 1959). Encore selon Newell, ces *architectures* générales de la cognition humaine devraient être soumises à un décathlon cognitif, et accumuleraient des points pour chaque ensemble de données expliqué (Vere, 1992). Ainsi, une architecture cognitive générale, dont les prédictions diffèrent davantage des données empiriques que celles faite par un modèle spécifique à cette tâche, serait tout de même préférée si son imprécision est compensée par sa généralité.

Plus spécifiquement, une architecture cognitive propose un ensemble unique de mécanismes capable de couvrir l'ensemble des domaines de la cognition (Newell, 1992), dont la résolution de problèmes, la prise de décisions, les activités routinières, la mémoire, l'apprentissage et la perception. Bien que loin d'être exhaustive, cette courte liste constitue en soi un ensemble de phénomènes que très peu de modèles cognitifs peuvent prétendre expliquer simultanément. Parmi les architectures cognitives actuellement existantes, Newell propose SOAR (Laird et al., 1987) pour participer au décathlon cognitif, alors que John Anderson et ses collègues proposent ACT (Anderson, 1983; Anderson et al., 2004). Plus récemment, EPIC (Meyer et Kieras, 1997) est également entré dans la compétition.

1.1 Le test de Newell

Quelques années avant que Vere (1992) ne propose l'idée d'utiliser un décathlon cognitif, Newell avait déjà commencé à réfléchir sur les critères pouvant être utilisés pour départager les différentes architectures cognitives (Newell, 1990). Cependant, Newell n'eut pas le temps d'élaborer ces idées (seulement deux pages leur furent allouées) et cette proposition fut en grande partie oubliée. Plus récemment, Anderson et Lebiere (2003) reprirent les critères énumérés par Newell à leur compte et proposèrent le *test de Newell* (voir Tableau 1.1, première colonne). Ces critères d'évaluation ont été divisés en trois catégories: généraux, comportementaux, et cognitifs. Bien que cette classification soit absente dans l'article original de Anderson et Lebiere, elle facilitera la comparaison avec l'autre décathlon cognitif (Sun, 2004).

Le premier critère général, familier pour la plupart des chercheurs depuis l'avènement du connexionnisme (Rumelhart et McClelland, 1986), est la plausibilité biologique. Selon Anderson et Lebiere (2003), celle-ci relève de la possibilité d'implémenter une architecture dans un substrat neuronal. Ainsi, le modèle n'a pas besoin d'être composé d'unités neuronales. Il peut s'agir d'une explication abstraite, mais cette dernière doit ultimement être réductible à l'explication biologique. Le second critère relève d'une prise d'engagement vis-à-vis la théorie de l'évolution; l'architecture doit résulter d'un processus évolutif. Ainsi, l'intelligence des mammifères en général et des humains en particulier devrait se situer sur un continuum, et l'architecture devrait être en mesure de représenter ce continuum (i.e., en modifiant des paramètres de façon quantitative). Le troisième critère concerne la possibilité

de modifier l'architecture en fonction de sa croissance (ontogénie) ainsi que suite au contact de cette dernière avec l'environnement (apprentissage). Le développement des organismes vivants facilite l'atteinte des buts de l'organisme. Symétriquement, une architecture cognitive devrait se développer et agir de façon à atteindre les buts qu'elle s'est fixés (rationalité).

Tableau 1.1
Critères d'évaluation des architectures cognitives

<u>Anderson et Lebiere (2003)</u>	<u>Sun (2004)</u>
Général	Général
1. Plausibilité biologique	1. Réalisme cognitif
2. Évolution	2. Réalisme évolutif
3. Développement	3. Éclectisme méthodologique et technique
4. Rationalité	4. Réalisme écologique
Comportement	Comportement
1. <i>Temps réel</i>	1. Réactivité
2. Dynamisme	2. Séquence
3. Langage naturel	3. Routine
4. Méta-cognition	4. Adaptation <i>essai-erreur</i>
Cognition	Cognition
1. Plusieurs types de connaissances	1. Dichotomie explicite / implicite
2. Base de données vaste	2. Apprentissage ascendant
3. Apprentissage	3. Interaction synergique
4. Flexibilité	4. Modularité

Anderson et Lebiere (2003) ont aussi proposé quatre critères d'évaluation comportementaux. D'abord, l'architecture doit être en mesure d'opérer en *temps réel*. Le nombre d'étapes nécessaires pour effectuer une tâche devrait refléter sa difficulté et, du même coup, le temps de réaction des humains (variable dépendante habituelle en psychologie cognitive). Le second critère met l'emphase sur la capacité d'un organisme intelligent

d'adapter son comportement en fonction du résultat de ses actions sur le monde. En particulier, le monde naturel n'est pas statique, ce qui implique qu'un comportement utile au moment présent ne le sera pas nécessairement dans l'avenir. Comme les organismes vivants, les architectures cognitives doivent être en mesure de tenir compte de ces changements et d'ajuster leurs comportements en conséquence. Troisièmement, une architecture cognitive devrait éventuellement être en mesure d'utiliser un langage naturel pour communiquer avec d'autres agents du même type (i.e., simulations sociales). Finalement, une architecture cognitive devrait faire preuve de méta-cognition (i.e., savoir qu'elle sait), d'un sens d'existence, allant même jusqu'à la conscience.

Le troisième type de critères d'évaluation est cognitif, parmi lesquels on retrouve d'abord un postulat concernant la coexistence de plusieurs types de connaissances plus ou moins abstraites. Newell (1990) n'a pas beaucoup élaboré sur ce sujet, mais il a mentionné que l'humain utilise des symboles ainsi que leurs abstractions. Ainsi, une architecture cognitive doit être en mesure de combiner les symboles (*chunking*) afin de faciliter leur utilisation subséquente. Ensuite, l'intelligence humaine repose sur une énorme base de connaissances. Une architecture cognitive devrait être en mesure d'utiliser et de construire une telle base (apprentissage, ce qui constitue le critère suivant). Finalement, le dernier critère cognitif est celui jugé le plus important par Newell (1990), qui croit que l'intelligence est une fonction générale de l'environnement et qu'une architecture cognitive doit être équivalente à une machine de calcul universelle (Newell et Simon, 1976; Turing, 1936).

1.2 Le décathlon cognitif selon Sun (2004)

Suite à la proposition du test de Newell (Anderson et Lebiere, 2003), Sun (2004) proposa sa propre version du décathlon cognitif. Il suggéra également douze critères qu'il classa en trois catégories (Tableau 1.1, deuxième colonne). Malgré la présence de certaines répétitions, les critères évoqués par Sun s'appliquent essentiellement aux architectures cognitives en tant qu'explication fonctionnelle du comportement. Plus spécifiquement, le premier critère général concerne la plausibilité cognitive du modèle. Selon Sun, le concepteur d'une architecture cognitive devrait s'assurer que cette dernière reproduit les caractéristiques fondamentales (qualitatives) du comportement, en faisant abstraction des détails qui visent uniquement à diminuer la mesure d'erreur entre les données prédites par un modèle et les

données empiriques¹. Le second critère concerne le réalisme évolutif et est équivalent au second critère général du test de Newell. Le troisième critère concerne surtout l'étape de la création d'une architecture cognitive. Selon Sun, il faut s'inspirer du plus grand nombre de disciplines possible et ne pas rejeter trop rapidement certaines approches qui peuvent à prime abord sembler problématiques. Par exemple, il serait hâtif de rejeter un modèle uniquement sur la base de critères liés à la plausibilité biologique, puisque les connaissances dans le domaine neuropsychologique sont pour l'instant incomplètes, et dans bien des cas spéculatives. Finalement, le critère de réalisme écologique met en évidence l'importance d'expliquer d'abord les tâches simples, du moins pour l'humain, telles la reconnaissance de formes, plutôt que de se lancer directement dans l'explication de tâches plus complexes comme la géométrie et de la cryptographie. Sun explique que ces premières tâches sont nécessaires à la survie d'une espèce, alors que les secondes ne le sont pas. Il est donc essentiel qu'une architecture cognitive soit en mesure de les expliquer.

Au niveau du comportement, les trois premiers critères sont liés et se rapportent à la contrainte de temps réel évoquée par Anderson et Lebiere. Sun met en évidence le caractère séquentiel et routinier des activités humaines. Aussi, il explique que le calcul nécessaire à ces activités est rapidement automatisé, ce qui explique la diminution des temps de réactions suite à la répétition d'une tâche. Par exemple, un enfant apprenant à lacer ses souliers doit réfléchir à chaque étape de cette opération. Cependant, après des années de pratique, rares sont ceux qui ont encore besoin de penser aux opérations effectuées. Dans bien des cas, il est même impossible d'énumérer les étapes impliquées sans effort mental. Le dernier critère comportemental est la capacité d'apprendre de ses erreurs: il est possible de s'adapter à un environnement dynamique nécessitant plusieurs types de comportements en fonction du contexte (deuxième critère comportemental du test de Newell).

Nous partageons avec Sun la conviction que les critères directement liés à la cognition sont les plus importants dans le développement d'une architecture cognitive puisque ces derniers concernent les postulats liés aux processus et structures impliqués dans l'activité

¹ Comme c'est souvent le cas en psychologie. Voir Roberts et Pashler (2000) et Pitt et Myung (2002) pour les dangers liés à cette approche.

cognitive humaine (l'*Architecture* de la cognition). D'abord, Sun partage avec Anderson et Lebiere un postulat quant à la présence simultanée de plusieurs types de connaissances et processus. Cependant, Sun va plus loin et spécifie les types de processus coexistants, soient les processus explicites et les processus implicites. Les premiers réfèrent aux processus et connaissances verbalisables, conscients, auxquels la méta-cognition a accès. Par exemple, les connaissances factuelles sont explicites (i.e., la tour Eiffel est à Paris). Le second type de processus, implicites, réfère à toutes les connaissances non-verbalisables auxquelles la méta-cognition n'a pas accès. Par exemple, les connaissances procédurales peuvent être effectuées de façon implicite (i.e., la série de mouvements utilisée pour lacer des souliers se fait sans y réfléchir). En plus de postuler la présence de deux types de connaissances distincts, Sun contraint leur ordre de développement: bien qu'il existe des données empiriques supportant la présence d'apprentissage descendant (de l'explicite vers l'implicite: Logan, 1988), les données supportent également la présence d'apprentissage ascendant (de l'implicite vers l'explicite: Karmiloff-Smith, 1994), et cette dernière direction semble être la plus fondamentale (Berry et Broadbent, 1988; Siegler, 2006; Stanley et al., 1989; Sun, 2004). La modélisation de l'apprentissage ascendant devrait donc être priorisée dans le développement d'une architecture cognitive. Ensuite, Sun postule que les connaissances implicites et explicites interagissent de façon synergique pour solutionner chaque tâche. La performance d'un système utilisant ces deux types de connaissances est toujours supérieure à celle d'un système utilisant uniquement l'un ou l'autre de ces types de connaissances. Finalement, Sun postule une certaine modularité des processus, ces derniers étant fonctionnellement (traitement hermétique) ou physiquement (dans le cerveau) séparés.

1.3 Évaluation des architectures existantes

La famille d'architectures ACT, développée par Anderson et ses collègues, est la plus ancienne et de loin la plus connue: elle servira donc d'étalon de comparaison (*benchmark*). Dans le cadre de la présente évaluation, sa version la plus récente, ACT-R 5.0, sera utilisée (Anderson et al., 2004).

ACT-R est un système de production composé d'une mémoire déclarative ainsi que d'une mémoire procédurale. La première mémoire contient les connaissances alors que la seconde contient les règles de production. Le module déclaratif s'occupe de reconnaître ce

qui est présenté au modèle et du calcul de l'activation des règles, alors que la partie procédurale s'occupe de calculer l'utilité de chaque règle activée et de déclencher la plus appropriée. Par exemple, ACT-R peut être utilisé pour simuler une tâche de conditionnement classique dans laquelle un rat apprend à appuyer sur un levier pour obtenir de la nourriture. Dans ACT-R, si un levier est détecté par le module déclaratif (stimulus), toutes les règles associées dans la mémoire procédurale seront activées. Si l'une d'elles mentionne qu'appuyer sur le levier fera apparaître de la nourriture, et que l'organisme modélisé a faim, l'utilité de cette règle sera élevée (telle que calculée par le module procédural). ACT-R choisira d'appuyer sur le levier.

Anderson et Lebiere (2003) ont eux-mêmes évalué ACT-R en fonction du test de Newell. Selon eux, la force de cette architecture se situe surtout au niveau cognitif. Le modèle est muni d'une procédure d'apprentissage descendant appelée *chunking*: lorsqu'une règle est appliquée de manière efficace dans un contexte donné, un *chunk* est créé et ce dernier peut par la suite être reconnu sans passer par le processus de calcul d'utilité, ce qui diminue le temps de réaction. Aussi, ACT-R est un système de production équivalent à une machine de Turing, qui par définition est extrêmement flexible. Par contre, ACT-R offre peu de possibilité de développement, tant à l'échelle phylogénique qu'ontogénique. Ainsi, les règles doivent être codées à l'avance dans le module procédural, et aucune composante de ACT-R ne permet d'expliquer le principe d'évolution. Aussi, l'architecture constitue une explication strictement fonctionnelle du comportement; les arguments avancés quant à sa plausibilité biologique sont au mieux spéculatifs.

En ce qui concerne le décathlon cognitif (Sun, 2004), la force de ACT-R se situe surtout au niveau comportemental. ACT-R rencontre avantageusement chacun des critères comportementaux proposés par Sun, car cette architecture peut appliquer de façon successive ses règles de production. Aussi, le caractère routinier de l'activité cognitive est mis en évidence par la procédure de *chunking*. De plus, suite à des erreurs d'identification, ACT-R ajuste automatiquement ses paramètres afin de faciliter l'identification subséquente d'un même stimulus. Cependant, du point de vue cognitif, les réponses de ACT-R proviennent toujours d'un seul système mnésique: il n'y a donc pas d'interaction synergique. Aussi, l'apprentissage ascendant des règles de production est manquant.

Tout comme ACT-R, SOAR (Laird et al., 1987) est un système de production, à la différence près que ce dernier provient du domaine de l'intelligence artificielle. Cette architecture contient une liste de buts emmagasinés dans une pile (*goal stack*) gérée à l'aide d'une mémoire de travail et d'une mémoire à long terme. La mémoire de travail sert à identifier les stimuli présents ainsi qu'à récupérer les règles de production ayant ces stimuli parmi leurs prémisses (les règles sont emmagasinées dans la mémoire à long terme). Ensuite, l'utilité de chaque règle présente dans la mémoire de travail est évaluée en fonction de la pile de buts et la règle la plus appropriée est choisie. Tout comme ACT-R, SOAR construit des chunks pour automatiser l'utilisation des règles les plus courantes.

Puisque SOAR est fonctionnellement similaire à ACT-R, leurs performances au test de Newell le sont également. La force de SOAR se situe surtout au niveau cognitif et le test de Newell ne permet pas de distinguer ces deux architectures. Toutefois, le décathlon cognitif met en évidence des différences cognitives et comportementales importantes entre SOAR et ACT-R. Au niveau comportemental, SOAR ne peut pas automatiquement ajuster ses paramètres afin de faciliter l'identification des stimuli alors que ACT-R le peut. Au niveau cognitif, SOAR ne distingue pas les processus implicites des processus explicites, alors que cette distinction semble claire chez les humains. ACT-R semble donc supérieur à SOAR.

La dernière architecture cognitive évaluée, EPIC (Meyer et Kieras, 1997), est aussi un système de production mais cette dernière est munie de capteurs sensoriels et d'effecteurs, puisqu'elle représente le courant de la cognition incarnée (Lakoff et Johnson, 1999). Le système de production contient une mémoire de travail, une mémoire à long terme, et une mémoire de production. La mémoire de travail joue le même rôle que celle de SOAR, alors la mémoire à long terme joue celui de la mémoire déclarative de ACT-R. La mémoire de production est similaire à la mémoire procédurale de ACT-R.

La performance de EPIC est identique à celle de ACT-R au test de Newell à deux exceptions près. D'abord, contrairement à ACT-R, EPIC est capable d'utiliser un langage naturel grâce à ses modules effecteurs. Ensuite, EPIC est incapable d'apprendre: tous les paramètres et toutes les règles de productions doivent être codés dans le modèle avant de simuler une tâche. Dans le décathlon cognitif, EPIC est la seule architecture remplissant le

critère de réalisme écologique, mais l'absence de processus d'apprentissage la désavantage aux niveaux comportemental et cognitif. En résumé, si l'on compte simplement le nombre de critères remplis, la performance de EPIC est équivalente à celle de ACT-R; par contre, l'absence totale d'apprentissage dans EPIC est un problème grave qui permet à ACT-R de se hisser au haut du podium.

Bien que ACT-R soit le modèle qui performe le mieux au test de Newell ainsi qu'au décathlon cognitif, sa performance est plutôt décevante au niveau cognitif. D'ailleurs, aucune des architectures testées n'est en mesure d'expliquer l'apprentissage ascendant, qui consiste en l'apprentissage de structures de connaissances suite au contact avec l'environnement. Dans toutes les architectures recensées, les règles doivent toujours être spécifiées à l'avance. Aussi, la réponse émise résulte toujours d'un seul et unique module, ce qui fait peu de place à l'interaction synergique des représentations. Comme ces deux critères sont parmi les plus importants selon Sun, il créa une nouvelle architecture cognitive, CLARION (Sun et Peterson, 1998_a, 1998_b; Sun, et al., 2001), pour pallier à ces lacunes. Ce modèle constitue le point de départ des travaux liés à la présente thèse: son fonctionnement sera donc détaillé dans la section qui suit.

1.4 CLARION: Un modèle d'induction dans une architecture cognitive

L'architecture de CLARION (Sun et al., 2001) est présentée dans la Figure 1.1. Elle est composée de trois modules distincts: une mémoire procédurale, une mémoire déclarative et une mémoire épisodique. La mémoire procédurale contient les connaissances implicites et est modélisée à l'aide d'un réseau connexionniste multicouches utilisant des représentations sous-symboliques (Smolensky, 1988). La première couche du réseau est en contact avec les stimuli (codés à l'aide de vecteurs binaires), alors que la troisième couche représente l'utilité de chaque action possible (*Q-values*: une unité par action). La deuxième couche contient des unités cachées permettant d'établir des relations non-linéaires entre les stimuli et l'utilité des

actions². La quatrième couche contient toujours une seule unité, qui sélectionne de façon stochastique l'action la plus utile:

$$p(a | x) = \frac{e^{Q(x,a)/\alpha}}{\sum_i e^{Q(x,a_i)/\alpha}} \quad 1.1$$

où $Q(x, a_i)$ représente l'utilité de l'action a_i lorsque le stimulus x est présent, et α est un paramètre libre représentant le niveau de bruit dans le système.

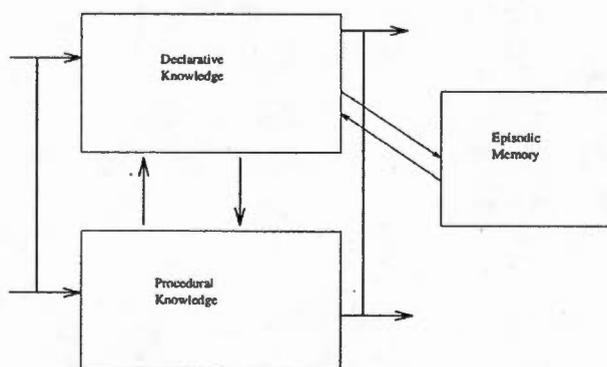


Figure 1.1 Architecture de CLARION. (Tirée de Sun et al., 2001.)

Les poids de connexions utilisés pour calculer l'utilité de chaque action sont appris par renforcement en utilisant la règle standard de rétropropagation de l'erreur à une exception près: le terme d'erreur n'est pas la différence entre la sortie du réseau et la sortie désirée. Il s'agit plutôt de:

$$err_i = \begin{cases} r + \gamma \times \text{Max}_b [Q(y, b)] - Q(x, a) & \text{si } a_i = a \\ 0 & \text{sinon} \end{cases} \quad 1.2$$

où r représente le renforcement reçu suite à l'action choisie, γ constitue un facteur de réduction reflétant le délai entre le choix de l'action et la rétroaction reçue, y se veut le nouvel état résultant de l'action choisie, et $\text{Max}_b [Q(y, b)]$ calcule le renforcement hypothétique

² Les trois premières couches forment un réseau connexionniste multicouches standard. Le lecteur peut se référer à un texte d'introduction aux réseaux de neurones pour une formalisation de la transmission (i.e., Haykin, 1994; Hertz, Krogh, et Palmer, 1991).

obtenu suite au choix optimal d'une action. Un modèle muni d'une règle de rétropropagation utilisant cette définition du terme d'erreur est dit un algorithme de *Q-learning* (Watkins, 1989). Ainsi, cette règle permet au module procédural de CLARION de s'adapter de façon optimale à un environnement Markovien³ sans connaître la réponse désirée (Watkins et Dayan, 1992).

Les connaissances explicites se trouvent dans la mémoire déclarative de CLARION qui est modélisée par un réseau connexionniste local divisé en deux couches: la couche d'entrée contient les prémisses des règles propositionnelles (stimuli), alors que la seconde couche contient les conséquents (une unité = un conséquent = une action). La matrice de connexions entre ces deux couches représente de façon binaire la présence ou l'absence d'associations entre chaque prémisse et chacun des conséquents. Aussi, l'activation de chaque action est rendue discrète en utilisant une fonction sigmoïde. Lorsque le module déclaratif est utilisé, l'action effectuée par le modèle à chaque essai est choisie de façon stochastique en fonction de l'activation de chaque action en mémoires procédurale et déclarative. L'Éq. 1.1 devient alors:

$$p(a | x) = \frac{e^{wv+(1-w)q}}{\sum_i e^{wv_i+(1-w)q_i}} \quad 1.3$$

où w est le poids accordé aux connaissances déclaratives dans la décision finale, alors que v et q représentent l'activation de l'action a aux niveaux déclaratif et procédural respectivement. L'Éq. 1.3 représente un modèle de l'interaction synergique des représentations dans CLARION, une propriété absente dans les architectures présentées précédemment.

La seconde caractéristique importante de CLARION est l'apprentissage ascendant des règles propositionnelles contenues dans la mémoire déclarative. L'idée derrière cette adaptation est la suivante: si une action choisie par la mémoire procédurale est généralement efficace lorsqu'un certain stimulus est présent, une règle représentant cette association sera

³ Dans un environnement Markovien, l'état actuel dépend uniquement de l'état le précédant immédiatement.

construite au niveau déclaratif. Ainsi, la prochaine fois que ce stimulus sera rencontré, la règle nouvellement créée sera utilisée et, si elle est efficace, CLARION pourra tenter de la généraliser. Dans le cas contraire, CLARION tentera de spécifier les conditions de déclenchement de la règle. Mathématiquement, la modification des règles déclaratives se fait à l'aide d'une mesure de gain d'information:

$$GI(A, B) = \log_2 \left[\frac{S(A) + 1}{S(A) + E(A) + 2} \right] - \log_2 \left[\frac{S(B) + 1}{S(B) + E(B) + 2} \right] \quad 1.4$$

où $GI(A, B)$ est le gain d'information suite à la modification d'une règle (ajout de la condition A) par rapport à l'état précédent sa modification (B), $S(A)$ et $E(A)$ sont le nombre de fois où la condition A est satisfaite et que l'action résultant de l'application de la règle produit un résultat respectivement positif ou négatif. Les indices statistiques nécessaires au calcul du gain d'information sont contenus dans la mémoire épisodique et, à chaque essai, sont mis à jour de la façon suivante:

$$\begin{aligned} S(A) &= 0.90 \begin{cases} S(A) & \text{sinon} \\ S(A) + 1 & \text{si } e(y) - Q(x, a) + r > \text{seuilCons} \end{cases} \\ E(A) &= 0.90 \begin{cases} E(A) & \text{sinon} \\ E(A) + 1 & \text{si } e(y) - Q(x, a) + r < \text{seuilCons} \end{cases} \end{aligned} \quad 1.5$$

où seuilCons est un paramètre libre. En utilisant ces indices statistiques et Éq. 1.4, les règles déclaratives sont modifiées de la façon suivante: Si Éq. 1.4 $> \text{seuilCons}$ et qu'il n'existe pas de règle liant le stimulus actuel à l'action entreprise, CLARION ajoute une règle (**CONSTRUCTION**). Sinon, si le résultat de l'action entreprise est positif, mais que l'ajout d'une autre prémisses augmente le gain d'information, CLARION ajoute un lien entre la nouvelle prémisses et l'action (**GÉNÉRALISATION**). Finalement, si le résultat de l'action est négatif et que le retrait d'une prémisses permet d'augmenter le gain d'information, CLARION retire le lien entre cette prémisses et l'action (**SPÉCIFICATION**). Le succès ou l'échec d'une action est jugé en fonction d'un seuil différent pour la généralisation et la spécification de règles (seuilGen , seuilSpec).

Puisque CLARION est un modèle reposant en partie sur l'apprentissage par renforcement, il est parfaitement adapté à l'apprentissage de séquences d'évènements. Ainsi,

cette architecture a été utilisée pour naviguer dans des labyrinthes (Sun et Peterson, 1998_b) et des champs de mines (Sun et al., 2001; Sun et Peterson, 1998_a, 1998_b). Dans les deux cas, l'apprentissage est rapide, la performance du modèle complet est toujours supérieure à celle de l'un ou l'autre de ses modules pris isolément (synergie) et les règles développées par CLARION concordent avec les rapports verbaux des participants humains (apprentissage ascendant). De plus, comme CLARION met l'emphase sur la distinction entre les connaissances implicites et explicites, les tâches classiques mesurant la mémoire implicite (i.e., tâche de contrôle dynamique, apprentissage de séquences) peuvent être modélisées (Sun, Slusarz, et Terry, 2005).

En ce qui concerne le test de Newell (Anderson et Lebiere, 2003), la force de CLARION se situe surtout aux niveaux cognitif et général. Il implémente plusieurs types de connaissances, apprend de son environnement, peut expliquer le processus évolutif et le développement. En fait, l'adaptation suite à l'évolution, au développement ou au contact avec l'environnement est ce qui distingue CLARION des architectures qui le précèdent. Tout s'apprend dans CLARION. En ce qui a trait au décathlon cognitif (Sun, 2004), le succès de CLARION n'est pas une surprise, puisque cette architecture a été développée avec ces critères d'évaluation en tête. Selon Sun, l'incapacité de CLARION à décomposer en étapes les problèmes à régler (i.e., se créer une pile de buts) est sa principale faiblesse.

1.5 CLARION: Problèmes d'implémentation et faiblesses théoriques

Bien que CLARION (Sun et al., 2001) obtienne le meilleur score (parmi les modèles évalués) au test de Newell (Anderson et Lebiere, 2003) ainsi qu'au décathlon cognitif (Sun, 2004), cette architecture cognitive possède des faiblesses importantes au niveau de l'implémentation et au niveau théorique. Le premier problème d'implémentation de CLARION concerne la modélisation du module procédural. Sun et ses collègues soulignent que les connaissances implicites se trouvant dans ce module devraient être modélisées par un réseau connexionniste sous-symbolique (Cleeremans, 1997; Dienes et Perner, 1996; Smolensky, 1988). La difficulté d'interprétation des sous-symboles représente bien le manque d'accessibilité des connaissances implicites. Cependant, dans la version actuelle du modèle, seulement la deuxième couche du module implicite est réellement sous-symbolique; les deux dernières couches représentent respectivement l'utilité de chaque action en fonction

du stimulus ainsi que le choix de l'action (le tout de façon locale), alors que la première couche du module est simplement une description distribuée du stimulus présent. Pour bien saisir la portée de cette confusion, il faut d'abord comprendre la différence entre les représentations distribuées et les représentations sous-symboliques: toutes les représentations sous-symboliques sont distribuées, mais l'inverse est faux. Dès que plusieurs unités d'un modèle connexionniste sont utilisées pour représenter un concept⁴, la représentation est distribuée (sinon, elle est locale). Par exemple, le vecteur {1, 0, 1, 0, 0, 1} peut être une représentation distribuée du concept *éléphant*. Par contre, si les éléments du vecteur réfèrent chacun à un concept d'une granularité plus petite, les unités ne sont pas réellement sous-symboliques; la représentation demeure symbolique. Par exemple, le premier élément peut représenter la trompe, le second le fait de pouvoir voler, le troisième la couleur grise, etc., et les valeurs {1, 0} peuvent être utilisées pour représenter la présence ou l'absence de ces caractéristiques. Ce type de représentations, distribuées symboliques, est souvent confondu avec les représentations sous-symboliques, même s'il n'existe aucune façon objective de départager les symboles des sous-symboles. Pour qu'une représentation soit réellement sous-symbolique, il doit exister une différence qualitative entre cette représentation et une autre qui est symbolique. Ainsi, il est possible de départager *a priori* ces deux types de représentations. Dans le cas du module procédural de CLARION, la première couche est distribuée et symbolique, puisque la valeur donnée à chaque unité réfère directement à la présence ou l'absence d'un symbole. Ainsi, si l'on prend pour exemple la tâche de navigation dans un champ de mines (Sun et al., 2001; Sun et Peterson, 1998_a, 1998_b), dans laquelle un véhicule doit traverser un champ de mines afin d'atteindre un objectif sans entrer en collision avec les explosifs, la première unité du stimulus représente le niveau d'essence, les unités trois à six représentent la direction du déplacement, etc. En résumé, CLARION utilise des représentations symboliques distribuées pour modéliser les connaissances implicites, alors qu'il devrait utiliser des représentations sous-symboliques.

Le second problème d'implémentation de CLARION concerne l'apprentissage ascendant des règles propositionnelles présentes dans le module déclaratif. Dans la version

⁴ Il est important de noter que l'utilisation du terme *concept* est neutre et ne vise aucunement à participer au débat quant à l'existence ou l'inexistence d'une telle chose.

actuelle de CLARION, les propositions (prémises et actions) sont déjà présentes dans le module avant le début de l'apprentissage, et seuls les liens entre ces symboles émergent du niveau procédural (règles); aucune explication n'est offerte quant à la provenance des symboles (i.e., apprentissage, innéisme, etc.). Ainsi, seules les règles sont ancrées; pas les symboles (Harnad, 1990). Pour être en mesure d'expliquer complètement la provenance des règles propositionnelles présentes au niveau déclaratif, CLARION devrait être en mesure de trouver de façon autonome quelles sont les règles et les prémisses représentant les entités impliquées de façon causale dans son environnement.

Au niveau théorique, deux faiblesses ont été identifiées dans CLARION: l'algorithme d'apprentissage du module procédural et le caractère déterministe des règles propositionnelles du module déclaratif. Au niveau du module procédural, les tâches utilisées pour montrer la présence d'apprentissage implicite ne fournissent habituellement pas de rétroaction aux participants (Cleeremans, 1997; Cleeremans et al., 1998; Lewicki, Hill, et Bizot, 1988; Sun et al., 2005). Or, le module procédural de CLARION est un réseau connexionniste supervisé. Ce choix d'algorithme d'apprentissage pour modéliser l'apprentissage implicite est donc hautement discutable. Par exemple, quand CLARION est utilisé pour modéliser une tâche d'apprentissage de séquences (Sun et al., 2005; Chapitre VI de la présente thèse), une rétroaction est fournie au module procédural et les règles déclaratives sont apprises seulement lorsque la bonne réponse est émise; la tâche modélisée ne fournissait aucune rétroaction aux participants humains (Curran et Keele, 1993). La mise en évidence de cette différence cruciale entre la tâche modélisée et la tâche effectuée par les participants suggère d'interpréter avec prudence les résultats obtenus par CLARION.

La seconde faiblesse théorique de CLARION se situe au niveau décisionnel. La réponse émise par le modèle est toujours stochastique et suit une distribution de Boltzmann (voir Éq. 1.1 et Éq. 1.3). La variabilité des réponses qui résultent de ce processus de décision est en accord avec les données empiriques (Anderson et al., 1977; Estes, 1976; Kruschke, 1992; Medin et Schaffer, 1978; Nosofsky, 1986). Cependant, l'idée que l'incertitude quant au choix de l'action appropriée soit le propre du module procédural est difficile à défendre. Il est plus intuitif de penser que l'incertitude liée au choix de l'action relève plutôt de délibérations conscientes se déroulant dans le module déclaratif. Par exemple, les données empiriques

amassées à l'aide de tâches impliquant un processus conscient de délibération (i.e., prévision du gagnant d'une élection fictive: Estes, 1976) ont tendance à refléter les fréquences observées, alors que la catégorisation de stimuli simples (i.e., des formes géométriques de couleurs) entraîne un processus de décision déterministe (Ashby et Gott, 1988; Ashby et Maddox, 1992). Aussi, plusieurs résultats empiriques montrent que, lorsqu'une tâche est automatisée et qu'elle devient implicite, la variabilité des réponses diminue (Hélie et Cousineau, 2005; Logan, 1988, 1992). Ces données, de même que les résultats présentés précédemment, suggèrent que l'incertitude décisionnelle se situe au niveau des connaissances explicites; pas au niveau de l'identification perceptuelle (implicite). Ainsi, le module déclaratif devrait être composé de règles incertaines, plutôt que d'ajouter l'incertitude lors de l'étape de l'intégration avec le module procédural (Éq. 1.3).

1.6 Conclusion

En résumé, le test de Newell (Anderson et Lebiere, 2003) et le décathlon cognitif (Sun, 2004) suggèrent des critères pour évaluer et comparer la performance des architectures cognitives. ACT-R (Anderson et al., 2004), SOAR (Laird et al., 1987), EPIC (Meyer et Kieras, 1997) et CLARION (Sun et al, 2001) ont été comparé à l'aide de ces critères et CLARION semble mieux performer que ses concurrents dans les deux cas. Le fonctionnement de CLARION a été détaillé et les arguments présentés mettent en doute l'utilisation d'un modèle supervisé et symbolique pour représenter les connaissances implicites et de règles binaires dont les propositions sont préexistantes dans le système pour modéliser les connaissances explicites. La présente recherche vise précisément à conserver la capacité d'explication de CLARION tout en proposant des solutions aux divers problèmes mis en évidence. Pour ce faire, le cadre théorique utilisé pour développer la nouvelle architecture cognitive constituant l'objet de la présente thèse sera présenté dans le chapitre suivant, et la solution à chacun des problèmes énumérés dans cette section sera mise en évidence.

CHAPITRE II

DÉVELOPPEMENT D'UNE THÉORIE GÉNÉRALE DE LA COGNITION HUMAINE

L'objectif de la présente thèse est de mettre en place les fondations d'une nouvelle architecture générale de la cognition humaine répondant aux critères cognitifs du décathlon proposé par Sun (2004). L'étendue des travaux publiés suggère que le développement d'une architecture cognitive se fait de façon continue et est souvent l'œuvre d'une vie; le modèle exposé dans le présent document ne peut donc pas prétendre à l'exhaustivité. Ainsi, l'emphase sera mise sur l'apprentissage ascendant des connaissances explicites ainsi que sur l'interaction synergique des connaissances. Ces deux phénomènes sont exclus dans la plupart des travaux effectués dans le domaine des architectures cognitives, malgré leur présence dans les données empiriques colligées en psychologie cognitive (Berry et Broadbent, 1988; Curren et Keele, 1993; Mathews et al., 1989; Siegler, 2006; Stanley et al., 1989; Sun et al., 2005; Sun et Peterson, 1998_a, 1998_b). Par exemple, Stanley et ses collègues ont demandé à des participants d'ajuster le nombre de travailleurs dans une usine afin de garder la quantité de sucre produite constante. Ce type de tâches s'appelle *contrôle de systèmes complexes* et le nombre d'employés nécessaire à chaque moment dépend de la production au moment précédent. Les résultats obtenus suggèrent que les connaissances explicites acquises dans cette tâche sont limitées et sont verbalisables seulement tard dans l'apprentissage (même si les participants s'améliorent rapidement). De même, Evans et al. (2003) ont montré une dissociation entre les rapports verbaux (explicites) des participants et leurs performances dans une tâche d'apprentissage de fonction. Les rapports verbaux des participants sont toujours insuffisants pour expliquer leurs performances. Cette seconde expérience suggère que l'apprentissage explicite n'est pas complété au moment du rapport verbal alors que l'apprentissage implicite est beaucoup plus avancé. Aussi, Karmiloff-Smith (1994)

argumente que les enfants développent d'abord des connaissances implicites et que celles-ci sont explicitées seulement plus tard dans le développement.

En ce qui concerne l'interaction synergique des connaissances, plusieurs expériences en psychologie cognitive ont montré un effet implicite de la similarité des exemplaires sur l'application de règles explicites (i.e., Allen et Brooks, 1991; Sloutsky et Fisher, 2004). Aussi, Sun et al. (2005) rapportent des résultats expérimentaux qui montrent un effet du moment et de la pertinence des instructions verbales sur l'apprentissage implicite dans une tâche d'apprentissage de grammaire artificielle. Dans certains cas, les instructions facilitent l'acquisition des connaissances alors que dans d'autres, elles la ralentissent. Finalement, Mathews et al. (1989) ont montré dans une autre tâche d'apprentissage de grammaire artificielle que la présence simultanée de connaissances explicites et implicites résulte en une meilleure performance des participants. Cette synergie des connaissances a été répliquée quelques années plus tard dans une tâche d'apprentissage de séquences (Curran et Keele, 1993).

Bien que la modélisation de l'apprentissage ascendant des connaissances explicites et de l'interaction synergique des connaissances occupe l'essentiel de la présente thèse, cette emphase ne vise aucunement à minimiser l'importance des autres phénomènes cognitifs, tels que l'automatisation ou la gestion des buts en mémoire de travail. De nombreux travaux ont déjà couvert ces phénomènes (Anderson, 1983; Anderson et al., 2004; Laird et al., 1987; Meyer et Kieras, 1997), ce qui facilitera leur ajout au modèle dans des travaux futurs.

2.1 Postulats

D'abord, nous postulons la présence de deux types de connaissances qualitativement différents, les connaissances implicites et explicites (Dienes et Berry, 1997; Dienes et Perner, 1999), contenus dans deux modules distincts (modularité). La présence de cette dichotomie chez les participants humains a été montré à plusieurs reprises depuis les années soixante à l'aide trois tâches différentes, soit l'apprentissage de séquences (Curran et Keele, 1993; Stadler, 1992), le contrôle de systèmes complexes (Berry et Broadbent, 1988; Stanley et al., 1989) et l'apprentissage de grammaires artificielles (Mathews et al., 1989; Reber, 1967,

1989). Dans tous les cas, les participants réussissent à apprendre des relations complexes entre différents stimuli sans en être conscients.

Le postulat quant à la modularité des connaissances a été débattu pendant de nombreuses années en psychologie cognitive (Fodor, 1983; pour un contre-argument, voir Fodor, 2000). Cependant, les arguments en faveur de l'existence de plusieurs modules sont de plus en plus convainquant. Au niveau empirique, les connaissances acquises dans une tâche sont souvent spécifiques au contexte dans lequel elles ont été apprises et se transfèrent rarement (Hélie et Cousineau, 2005). Aussi, l'utilisation de modules spécialisés est une façon utile de limiter l'accroissement de la complexité d'un système lorsque celui-ci apprend de nouvelles connaissances (Sun, 2004). Par exemple, la plupart des chercheurs remettant en question la présence de plusieurs modules distincts utilisent des réseaux connexionnistes. Ainsi, la seule façon d'éviter l'interférence entre les différents processus appris est d'utiliser des représentations linéairement séparables, ce qui complexifie énormément le modèle résultant puisqu'il doit être en mesure de générer ces représentations (Hadley, 1999, 2003). Pour toutes ces raisons, ce postulat a été accepté et inclus dans la présente thèse.

Comme les connaissances explicites et implicites diffèrent au niveau de leur accessibilité, les représentations utilisées pour les modéliser doivent refléter cette différence: les connaissances explicites seront locales et symboliques, alors que les connaissances implicites seront sous-symboliques. Ce postulat mérite une légère digression puisque la distinction entre les représentations symboliques et sous-symboliques a toujours été problématique en science cognitive. Au niveau de l'implémentation, les représentations symboliques et sous-symboliques diffèrent souvent seulement au niveau de la granularité des représentations. Afin d'éviter ce problème sérieux, nous définissons une représentation sous-symbolique comme étant un signal analogique, continu, représenté par un vecteur résidant dans un espace Euclidien. En contraste, les représentations symboliques sont discrètes, digitales, et correspondent à l'inclusion ou l'exclusion d'un vecteur dans un sous-espace Euclidien. Il est à noter que l'utilisation de définitions mathématiques permet de réduire l'ambiguïté présente dans les définitions théoriques habituellement utilisées. Ces dernières seront à nouveau spécifiées lorsque le choix du modèle utilisé pour implémenter les deux types de connaissances sera arrêté.

Tout comme celle de Sun et ses collègues (2001; Sun, 2000, 2004), la théorie développée dans la présente thèse vise à mettre en évidence la prépondérance de l'apprentissage ascendant des connaissances explicites. Au-delà des justifications empiriques présentées en début de chapitre, l'avantage d'avancer la présence d'un tel type d'apprentissage est que ce postulat permet de dépolariiser les positions quant au débat opposant l'innéisme à la *tabula rasa*. Peu importe l'existence ou non de connaissances innées, un agent intelligent est en mesure d'apprendre de nouvelles connaissances au contact de son environnement. Par exemple, il est beaucoup plus facile de croire que les connaissances quant aux accélérateurs de particules sont apprises plutôt qu'innées. Par contre, cette croyance n'exclut pas la possibilité que la segmentation des scènes en objets soit innée. Dans tout les cas, le processus d'apprentissage ascendant des connaissances explicites devra être en mesure d'apprendre l'entièreté des représentations. Aussi, permettre à un modèle de générer ses propres codes permet de solutionner au moins partiellement le problème de l'ancrage des symboles (Harnad, 1990; Sun, 2000, 2004). Suivant Sun, les connaissances explicites sont représentées à l'aide de règles causales. Cependant, le processus menant au développement de ces règles doit aussi apprendre les propositions composant ces règles. Ainsi, les règles et les symboles sont ancrés.

Bien que le développement de la présente théorie soit inspiré des travaux de Sun et ses collègues sur les architectures cognitives (Sun, 2000, 2004; Sun et al., 2001, 2005), notre position diffère de la leur à deux égards importants: la supervision du module procédural et le déterminisme des règles déclaratives. Si la distinction entre les connaissances procédurales et déclaratives réfère à celle entre les connaissances implicites et explicites en psychologie cognitive, ce que Sun et ses collègues clament, le module procédural devrait s'organiser de façon autonome puisque les tâches utilisées pour montrer la présence d'apprentissage implicite ne fournissent aucune rétroaction aux participants. Par exemple, la tâche la plus utilisée pour montrer la présence d'apprentissage implicite est l'apprentissage de séquences (i.e., Curran et Keele, 1993; Stadler, 1992). Dans une telle tâche, un stimulus apparaît à l'un de plusieurs endroits prédéterminés sur un écran d'ordinateur, et le participant doit simplement appuyer sur la touche du clavier correspondant à cette position. Suivant l'enregistrement de la réponse, aucune rétroaction n'est fournie, et un autre stimulus est présenté. La variable dépendante est le temps nécessaire au participant pour appuyer sur la

touche correspondant à la position du stimulus. Le résultat classique est que, s'il existe une séquence de positions, les temps de réactions diminuent avec la pratique, bien que les participants soient incapables de verbaliser cette séquence (suite à l'expérience, les participants sont souvent surpris d'apprendre qu'il y avait une séquence). Lorsque cette tâche est simulée avec CLARION, le module procédural reçoit une rétroaction alors que les participants humains n'en recevaient pas (Sun et al., 2005). Ainsi, ce problème lié à l'algorithme d'apprentissage implicite réduit la précision de la modélisation de certaines tâches classiques en psychologie cognitive.

Au-delà de cette contrainte quant à l'auto-organisation des connaissances implicites, le modèle choisi pour les implémenter doit supporter l'utilisation des représentations sous-symboliques. Ainsi, un réseau connexionniste non-supervisé (Barlow, 1989; Zemel, 1994) sera utilisé pour modéliser l'apprentissage implicite (Cleeremans, 1997). Les réseaux connexionnistes non-supervisés peuvent généralement être classés en deux catégories selon le type d'apprentissage impliqué: les mémoires associatives (i.e., Anderson et al., 1977; Hopfield, 1982; Kosko, 1988) et les modèles compétitifs (i.e., Carpenter et Grossberg, 1987; Kohonen, 1982; Rumelhart et Zipser, 1986). Ces premières, aussi appelées méthodes de projection (Zemel, 1994), donnent souvent un résultat similaire à celui d'une analyse en composantes principales (Diamantaras et Kung, 1996). En ce qui concerne les modèles compétitifs, ils sont équivalents à des méthodes statistiques par noyau en général (Zemel, 1994), et souvent plus particulièrement à une analyse des *k moyens* (Rumelhart et Zipser, 1986). Le Chapitre III de la présente thèse compare ces deux familles de modèles à l'aide de simulations afin de choisir les éléments de chacune d'elles devant être inclus dans un modèle des connaissances implicites.

La seconde différence entre la théorie développée dans le cadre de la présente thèse et l'architecture cognitive proposée par Sun et ses collègues concerne les règles déclaratives, qui sont de nature déterministe et binaire dans CLARION. Chaque prémisse est liée ou non avec chaque action et l'action supportée par le plus grand nombre de prémisses est choisie. Or, deux prémisses peuvent supporter, à des degrés différents, une même action. Par exemple, l'action de fuite peut être supportée par la vue d'un créancier ou par la vue d'un ours sauvage. Cependant, la seconde association est sans aucun doute plus importante que la

première (à moins d'avoir affaire à un créancier physiquement très agressif). Dans tous les cas, CLARION ne permet pas de représenter ce rapport inégal entre prémisses et actions. Dans un même ordre d'idées, chaque prémisses supportant une action est équivalente dans CLARION (i.e., aucune prémisses n'est plus importante qu'une autre).

Afin d'implémenter les règles causales représentant les connaissances explicites, le modèle développé utilise un réseau de connaissances Bayésien (Neapolitan, 2004; Pearl, 1988, 2000). Un réseau de connaissances Bayésien est un graphe d'indépendances (*IMAP*) représentant une distribution conjointe. Par exemple, la Figure 2.1 illustre un réseau de connaissances Bayésien représentant la distribution conjointe des variables $\{U, W, X, Y, Z\}$ et mettant en évidence les indépendances conditionnelles suivantes¹: $\{I(\{X\}, \{Y\} | \{U\}), I(\{U\}, \{Z, W\} | \{X, Y\}), I(\{X, Y, U\}, \{W\} | \{Z\})\}$.

La mise en évidence des relations d'indépendances présentes dans la distribution permet de faciliter sa factorisation, et ainsi de simplifier la transmission de l'incertitude. Par exemple, dans le cas de la Figure 2.1:

$$P(U, W, X, Y, Z) = P(W | Z)P(Z | X, Y)P(X | U)P(Y | U)P(U) \quad 2.1$$

Le calcul de cette distribution est beaucoup plus simple que celui d'une distribution dans laquelle les indépendances sont inconnues: celui-ci nécessiterait le conditionnement de chaque variable avec chaque sous-ensemble des autres.

L'utilisation des probabilités est une façon naturelle de modéliser l'incertitude des règles. En effet, le support relatif d'une prémisses pour une action donnée peut être expliqué par l'incertitude de la règle. Aussi, les probabilités sont équivalentes à la théorie des ensembles, qui représentent des règles en contexte, tout comme les règles propositionnelles de CLARION (Sun, 2000). De plus, l'utilisation d'un réseau de connaissances Bayésien comme modèle psychologique est en accord avec l'approche rationnelle de la cognition (Anderson, 1990; Oaksford et Chater, 1998), les études sur le raisonnement incertain (Chin-Parker et Ross, 2002; Cosmides et Tooby, 1996; Gigerenzer et Hoffrage, 1995), ainsi que les

¹ $I(a, b | c)$ se lit a est indépendant de b étant donné c .

études sur la recherche de causalité (Cheng et Holyoak, 1995; Steyvers et al., 2003; Wasserman et al., 1993).

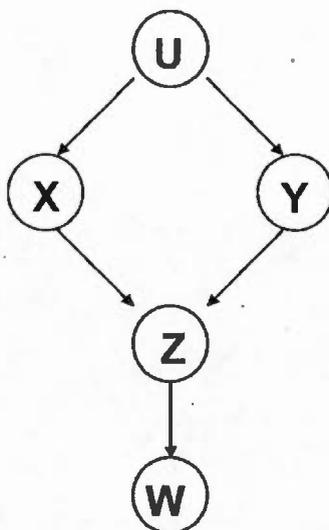


Figure 2.1 Exemple de réseau de connaissances Bayésien.

2.2 Analyse rationnelle de la cognition

L'étude rationnelle de la cognition est basée sur le postulat que l'humain s'adapte de façon optimale (dans les limites de ses capacités: Simon, 1972) à son environnement (Anderson, 1990). Il est donc possible d'étudier l'humain indirectement en étudiant l'environnement qu'il tente d'optimiser. Selon Anderson (1991), six étapes sont nécessaires à l'analyse rationnelle de la cognition (Tableau 2.1). Le principal avantage d'étudier la cognition sous un angle rationnel est que toutes les étapes impliquées portent sur l'environnement, plutôt que sur les structures cognitives. De ce fait, les hypothèses faites portent également sur l'environnement et sont directement vérifiables, ce qui diffère des hypothèses à propos des processus cognitifs (Anderson, 1991). Comme l'environnement est souvent jugé stochastique (étape 2), cette nouvelle approche s'appuie sur de nombreuses années de recherche sur le raisonnement incertain (voir section suivante): ainsi, la plupart des modèles en résultant sont des réseaux de connaissances Bayésiens (McClelland et Chappell, 1998; Movellan et McClelland, 2001; Oaksford et Chater, 1998; Shiffrin et Steyvers, 1997).

Tableau 2.1
Étapes de l'analyse rationnelle de la cognition

1.	Spécification de ce que le système cognitif doit optimiser (i.e., la mémoire tente d'optimiser le rappel).
2.	Émission de postulats à propos de la structure de l'environnement auquel le système doit s'adapter (en l'occurrence, déterministe ou stochastique).
3.	Émission de postulats quant aux coûts associés à l'optimisation de la performance (efforts cognitifs).
4.	Dérivation de la fonction de décision optimale en lien avec les trois premières étapes (i.e., le critère de décision Bayésien).
5.	Comparaison des résultats empiriques avec les prédictions du modèle.
6.	Si les prédictions ne correspondent pas aux résultats empiriques, modification des étapes 1 à 3 (ce qui modifie automatiquement l'étape 4) et reconsidération du modèle.

2.3 Le raisonnement incertain

Le raisonnement incertain est étudié en psychologie depuis les années soixante-dix. Classiquement, on demande aux participants d'estimer la probabilité de différents événements, et les estimations obtenues violent les axiomes de Kolmogorov (Ross, 1998). Par exemple, Tversky et Kahneman (1983) ont fait lire la description d'une ancienne étudiante en philosophie à des participants pour ensuite leurs demander: 1) « Quelle est la probabilité qu'elle soit aujourd'hui caissière? » et, 2) « Quelle est la probabilité qu'elle soit caissière et militante dans un mouvement féministe? ». Les participants ont estimé le second cas plus probable que le premier, alors que les axiomes de Kolmogorov postulent que la probabilité d'une conjonction d'événements (caissière ET militante) ne peut être plus grande que celle de ses atomes (caissière, militante). L'interprétation usuelle est que les humains utilisent des heuristiques plus ou moins efficaces plutôt que le calcul Bayésien, qui est normatif (pour une revue, voir Kahneman, Slovic, et Tversky, 1982).

Après vingt ans de consensus sur l'incapacité des humains à propager efficacement l'information incertaine, il fut montré simultanément par Gigerenzer et Hoffrage (1995) et

Cosmides et Tooby (1996) que les humains n'utilisent pas des heuristiques inefficaces pour propager l'incertitude quant à des événements, mais bien le calcul Bayésien. Ainsi, les résultats obtenus durant les années soixante-dix ne reflétaient pas une incapacité à propager l'information, mais plutôt un problème méthodologique des études classiques lié à la difficulté d'interprétation des probabilités: il semble que l'incertitude ne soit pas représentée par des probabilités au niveau cognitif. Par exemple, quand les participants sont confrontés aux mêmes problèmes en format *fréquentiste* (i.e., 0.13 vs. 13/100), l'incertitude propagée est conforme au calcul Bayésien. Le format fréquentiste est une façon beaucoup plus naturelle de représenter l'incertitude, puisqu'il requiert seulement la mémorisation d'un tableau de contingences des événements. De plus, Chin-Parker et Ross (2002) ont montré que lorsque des participants humains doivent inférer l'identité de personnages dans une histoire courte, les choix alternatifs affectent la probabilité du choix final², ce qui est en accord avec le théorème de Bayes.

2.4 La recherche de causalité

Tout système adaptatif complexe, humain ou non, opérant dans un environnement d'une complexité réaliste, doit être en mesure d'induire des relations causales entre les événements (Cheng et Holyoak, 1995). En particulier, les humains tentent de prédire le résultat de leurs actions, ce qui leur a valu le surnom de *scientifiques amateurs* (*intuitive scientists*). Au cours des dernières années, des chercheurs ont tenté d'étudier les processus impliqués dans l'inférence de la structure représentant les dépendances entre les causes et les effets (Steyvers et al., 2003). Par exemple, Steyvers et ses collègues ont demandé à des participants de déterminer lequel de trois extra-terrestres contrôlait les pensées des autres. Si un extra-terrestre réussissait à contrôler les pensées d'un autre, ce dernier pensait la même chose que lui avec la probabilité α (et il pensait quelque chose d'autre avec la probabilité $1 - \alpha$). À chaque essai, les participants voyaient ce que pensaient les trois extra-terrestres, et deux types de dépendances étaient possibles: soit l'extra-terrestre du centre tentait de contrôler les pensées des deux autres (cause commune), soit les deux autres tentaient de contrôler les pensées de celui du centre (effet commun). Les résultats montrent qu'un grand nombre de

² Lorsque ces derniers sont disponibles en mémoire (Simon, 1972).

participants arrive rapidement à inférer la structure de dépendance correcte. Comme la différence entre ces deux types de structures est probabiliste, ce résultat suggère que non seulement l'incertitude du raisonnement se propage de façon conforme au théorème de Bayes (voir section précédente) mais, qu'en plus, la structure causale est construite en tenant compte de cette incertitude.

2.5 Conclusion

En somme, la théorie développée contient quatre postulats, les deux premiers sont empruntés à CLARION (Sun et al., 2001), alors que les deux autres permettent de distinguer au niveau théorique l'approche adoptée. Les postulats empruntés à CLARION sont la présence de deux types de connaissances qualitativement différents contenus dans deux modules séparés mais s'intégrant de façon synergique pour émettre une réponse, et l'apprentissage ascendant des connaissances explicites à partir des connaissances implicites. Cependant, l'implémentation de ces principes est problématique dans CLARION, puisque les représentations utilisées pour modéliser les connaissances procédurales et déclaratives ne diffèrent pas qualitativement, et que seules les règles sont apprises de façon ascendantes à partir des connaissances procédurales. Afin d'implémenter ces deux modules, la présente théorie suggère d'utiliser un réseau connexionniste non-supervisé pour modéliser les connaissances implicites et un réseau de connaissances Bayésien pour modéliser les connaissances explicites. L'utilisation de ces modèles permet d'explicitier les différences théoriques entre l'approche adoptée et CLARION: l'auto-organisation des connaissances implicites et le caractère relatif et incertain des connaissances explicites. Comme toutes les connaissances proviennent initialement du réseau utilisé pour modéliser les connaissances implicites, le choix de ce dernier est crucial au succès du modèle final. Le prochain chapitre sera donc dédié à l'étude approfondie des réseaux connexionnistes non-supervisés. L'objectif visé par l'étude qui suit est d'identifier les caractéristiques propres à chacune des familles de modèles (compétitifs et associatifs) afin d'être en mesure de développer un modèle répondant à tous les objectifs fixés par la théorie.

CHAPITRE III

BIAIS ENVIRONNEMENTAUX ET APPRENTISSAGE NON-SUPERVISÉ¹

Le développement d'un bon modèle pour implémenter les connaissances implicites est garant du succès de l'architecture cognitive qui sera développée, puisque ce dernier servira également à construire les connaissances se trouvant dans le module explicite. Comme le module explicite sera implémenté à l'aide d'un réseau de connaissances Bayésien (Neapolitan, 2004; Pearl, 1988, 2000), qui représente une distribution conjointe, l'information quant à cette distribution doit être présente dans le modèle représentant les connaissances implicites.

Afin de déterminer le type de modèles connexionnistes à utiliser, deux familles de réseaux non-supervisés ont été comparées: les réseaux compétitifs (i.e., Carpenter et Grossberg, 1987; Kohonen, 1982; Rumelhart et Zipser, 1986) et les mémoires associatives (i.e., Anderson et al., 1977; Hopfield, 1982; Kosko, 1988). Le critère de comparaison choisi est la possibilité pour ces modèles d'apprendre les biais environnementaux (i.e., effectuer une estimation de densité). Pour ce faire, la performance de chaque famille de modèles fut évaluée dans des environnements respectivement simples et complexes dans lesquels la fréquence des exemplaires et des catégories fut variée.

3.1 L'élégance d'un environnement orthogonal

La première série de simulations présente des modèles simples, (quasi-)linéaires, dans des environnements simples: les stimuli ont peu de dimensions, sont normalisés, et les deux catégories sont orthogonales. Le principal avantage lié à l'utilisation de modèles linéaires est

¹ Ce chapitre reprend les résultats publiés dans Hélie, Chartier, et Proulx (2006).

que les résultats peuvent facilement être analysés à l'aide d'outils mathématiques exacts (i.e., analyses spectrales). Aussi, il sera plus facile d'identifier le processus responsable pour le comportement du modèle si ce dernier contient moins de postulats. En ce qui a trait aux environnements simples, l'orthogonalité des catégories leurs permet d'être apprises par des modèles linéaires, et l'interférence suite à l'apprentissage de plusieurs catégories est nulle. Finalement, la longueur des représentations ne contamine pas le comportement des modèles lorsqu'elles sont égales.

3.1.1 Stimuli et environnements

Les stimuli utilisés pour former les environnements simples sont présentés dans la Figure 3.1. Chaque exemplaire est codé à l'aide d'un vecteur bipolaire ($\pm\sqrt{8}$). Ainsi, la longueur de chaque stimulus est un. Aussi, les six exemplaires ont été séparés en deux catégories orthogonales: chaque stimulus appartenant à la catégorie « A » est orthogonal à chaque stimulus de la catégorie « B » et la corrélation entre les différents membres d'une catégorie est 0,5.

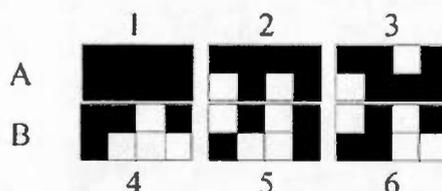


Figure 3.1 Stimuli utilisés pour former les environnements simples. (Tirée de Hélie et al., 2006_a.)

Afin de tester simultanément la sensibilité des modèles à la fréquence des exemplaires et des catégories, quatre distributions ont été utilisées pour former les environnements (voir la Figure 3.2). Tel que montré, la première distribution (a) est uniforme et constitue la condition contrôle des présentes simulations: les exemplaires et les catégories sont équiprobables. La seconde distribution (b) est bimodale et a été construite à l'aide de deux distributions normales ayant comme moyennes $\mu = \{2; 5\}$ et un écart-type commun $\sigma = 0,5$. Dans cette condition, les deux catégories sont équiprobables, mais les stimuli deux et cinq sont biaisés: ils sont quatre fois plus fréquents que les autres. La troisième condition (c) utilise une distribution en escalier: ainsi, la catégorie « A » est plus fréquente que la catégorie « B » (5:

4), mais chaque stimulus est aussi probable que les autres membres de sa catégorie. Finalement, la dernière condition (d) présente une distribution exponentielle avec une moyenne $\lambda = 3$. Ainsi, la catégorie « A » est plus fréquente que la « B », et le stimulus 1 est plus fréquent que le stimulus 2, qui est plus fréquent que le stimulus 3, etc.

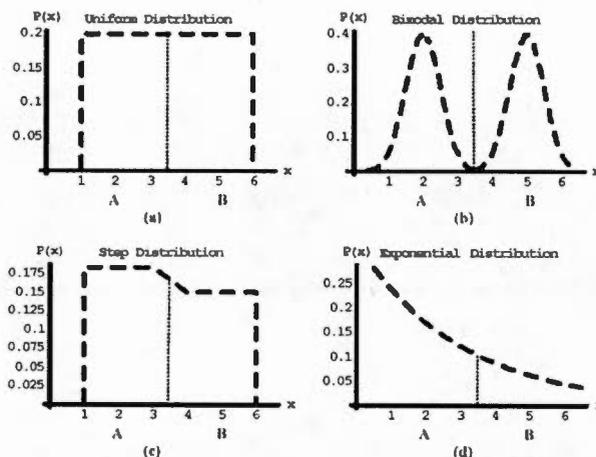


Figure 3.2 Distributions utilisées comme environnements simples. (a) Distribution uniforme. (b) Distribution bimodale. (c) Distribution en escalier. (d) Distribution exponentielle (Tirée de Hélie et al., 2006a.)

3.1.2 Modèles

Les modèles utilisés sont les plus simples représentants de chacune des familles (voir Figure 3.3). Dans le cas des réseaux compétitifs, le réseau simple présenté dans Rumelhart et Zipser (1986) a été utilisé alors dans le cas des mémoires associatives, le *Brain-State-in-a-Box* (BSB: Anderson et al., 1977) a été choisi. Le réseau compétitif effectue un traitement équivalent à une analyse des k moyens en minimisant la fonction de Lyapunov suivante:

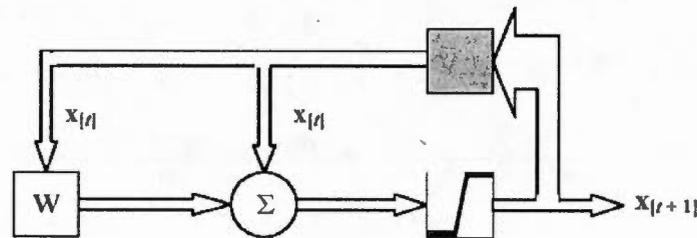
$$E(\mathbf{x}) = \sum_i \sum_{\mathbf{x} \in w_i} (\mathbf{w}_i - \mathbf{x})^2 \quad 3.1$$

où w_i est un vecteur de poids et \mathbf{x} est un stimulus appartenant à la catégorie i . En mots, Éq. 3.1 montre que ce réseau compétitif minimise la somme des distances Euclidiennes entre les stimuli et le vecteur de poids de connexions le plus près.

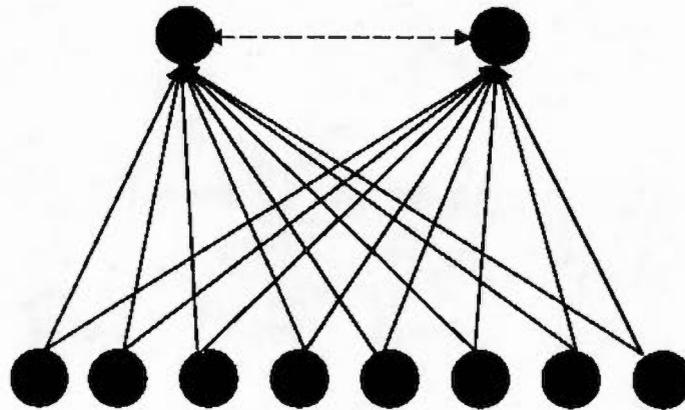
Quant à lui, le BSB effectue un traitement similaire à une analyse en composantes principales et minimise la fonction de Lyapunov suivante (Golden, 1986):

$$E(\mathbf{x}) = -\frac{1}{2} \mathbf{x}^T \mathbf{W} \mathbf{x} \quad 3.2$$

où \mathbf{x} est un stimulus et \mathbf{W} est la matrice de poids de connexions. Minimiser Éq. 3.2 équivaut à maximiser la variance des attracteurs du modèle. Les équations décrivant le fonctionnement de ces deux modèles sont présentées dans le Tableau 3.1.



(a)



(b)

Figure 3.3 (a) Architecture du BSB. Le carré gris représente un délai dans la transmission. (b) Architecture du réseau compétitif. (Tirée de Hélie et al., 2006_a.)

Un réseau compétitif et un BSB différents ont été entraînés pendant 500 essais dans chacune des conditions présentées dans la Figure 3.2. Suivant ces sessions de pratique, 500 vecteurs aléatoires uniformes $[-1, 1]$ ont été présentés à chacun des réseaux pour fin de catégorisation. Le nombre de stimuli classés dans chacune des catégories représente une

estimation du volume de la catégorie, qui devrait être proportionnel à la fréquence de présentation de ses membres.

Tableau 3.1
Équations décrivant les modèles utilisés dans les environnements simples

	Compétitif	BSB
Transmission	$Gagnant = \underset{i}{Min} \ w_i - x\ _2$	$x_{[t+1]} = f(Wx_{[t]} + \phi x_{[t]})$
Apprentissage	$w_{i[k]} = w_{i[k-1]} + \eta(x - w_{i[k-1]})$	$W_{[k]} = W_{[k-1]} + \eta(x_{[p]}x_{[p]}^T)$

Note. w_i est un vecteur de poids de connexions, x est un stimulus, $\|\bullet\|_2$ est la distance Euclidienne, $w_{i[k]}$ est le vecteur de poids gagnant, $f(z)$ est une fonction de saturation ayant comme bornes ± 1 , η est un paramètre d'apprentissage, $x_{[t]}$ est un stimulus au temps t , $W_{[k]}$ est la matrice de poids de connexions après k essais, p est le nombre d'itérations dans le réseau avant apprentissage et ϕ est le paramètre de restriction. Dans les présentes simulations, $p = 7$, $\phi = 1$, et $\eta = \{0.01, 0.0001\}$ dans le réseau compétitif et le BSB.

3.1.3 Résultats et discussion

D'abord, les deux modèles ont réussi à apprendre les stimuli dans toutes les conditions: le rappel des stimuli appris est parfait. L'analyse des résultats peut donc être entamée avec confiance. D'abord, puisque les catégories utilisées sont orthogonales, les vecteurs propres sont les minimums d'énergie² dans le BSB (Diamantaras et Kung, 1996), ce qui justifie une décomposition spectrale de la matrice des poids de connexions. Les valeurs propres sont présentées à la Figure 3.4, qui met en évidence l'effet de la fréquence des catégories. Quand les catégories sont équiprobables (cases *a* et *b*), les deux valeurs propres sont quasi-identiques (différence moyenne = $1,89 \times 10^{-3}$). Au contraire, quand la catégorie « A » est plus probable que la « B », la première valeur propre est plus grande que la seconde: dans la case *c* (escalier), la différence entre les deux valeurs propres est trois fois plus grande que lorsque les catégories sont équiprobables, et ce ratio augmente à douze fois dans la case *d* (exponentielle).

² Un minimum d'énergie est couramment appelé « attracteur » lorsque la dynamique des réseaux de neurones est considérée.

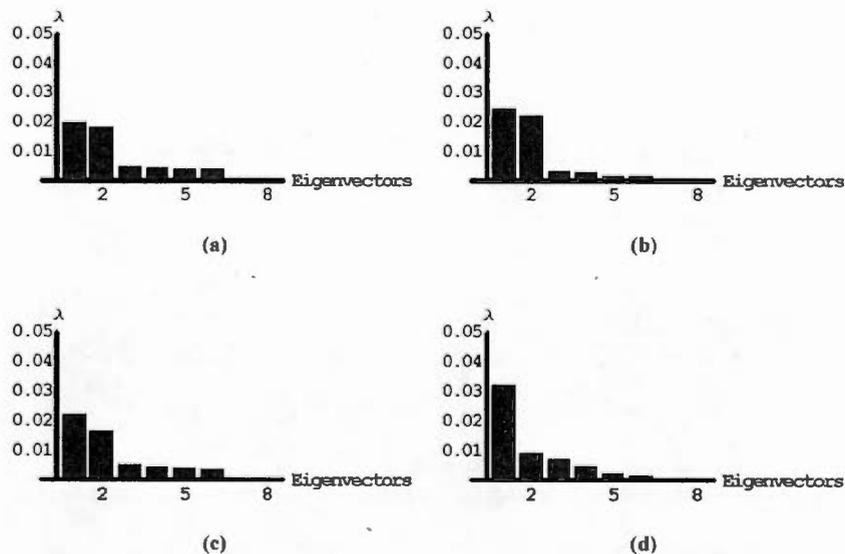


Figure 3.4 Valeurs propres de la matrice de poids de connexions développée par le BSB. Les cases représentent les mêmes conditions que dans la Figure 3.2. (Tirée de Hélie et al., 2006_a.)

La Figure 3.5 montre les vecteurs propres de la matrice de poids du BSB dans chaque condition. Il est intéressant de noter que la fréquence des exemplaires produit une rotation des vecteurs propres vers les stimuli qui sont les plus fréquents. Ainsi, les conditions dans lesquelles les membres des catégories sont équiprobables génèrent des attracteurs identiques (cases *a* et *c*), alors que les conditions où certains exemplaires sont biaisés ont des attracteurs qui ressemblent aux membres les plus fréquents (cases *b* et *d*).

L'analyse des poids de connexions du BSB montre que ce dernier est affecté indépendamment par la fréquence des catégories (valeurs propres) et la fréquence des stimuli (vecteurs propres). De la même manière, l'observation des poids de connexions du réseau compétitif suggère que ce dernier est affecté par la fréquence des stimuli (Figure 3.6). Les poids de connexions ressemblent aux stimuli les plus fréquents dans le cas de la condition bimodale (case *b*); par contre, ce déplacement des vecteurs de poids est absent dans le cas de la condition exponentielle (case *d*). Cette inconsistance apparente des résultats suggère en fait une sensibilité réduite aux effets de fréquences des exemplaires. Dans le cas de la distribution bimodale, les stimuli biaisés sont quatre fois plus probables que les autres, ce qui est suffisant

pour attirer les poids de connexions. En contraste, dans la condition exponentielle, le ratio d'exemplaires 1 par exemplaires 2 est seulement 7:5, et celui d'exemplaires 1 par exemplaires 3 est 2:1. Ces ratios sont insuffisants pour attirer les vecteurs de poids du réseau compétitif (même s'ils étaient suffisants pour attirer les vecteurs propres du BSB).

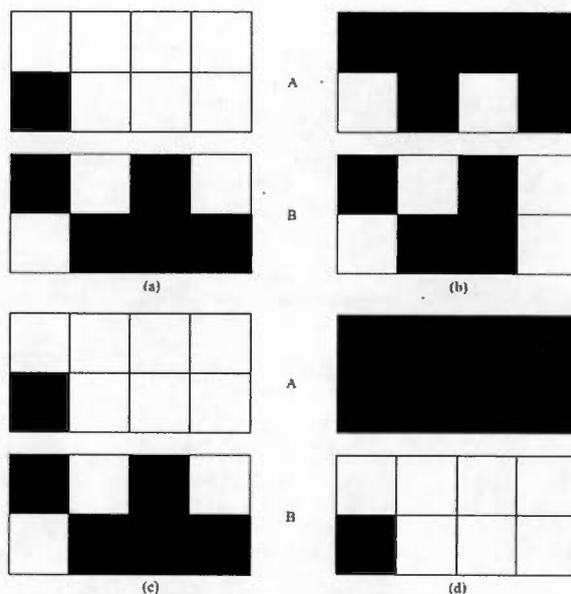


Figure 3.5 Vecteurs propres de la matrice de connexions du BSB. Dans chaque case, la première ligne représente la catégorie « A » alors que la seconde représente la catégorie « B ». Les cases représentent les conditions de la Figure 3.2. (Tirée de Hélie et al., 2006_a.)

Les résultats de la phase test sont présentés dans le Tableau 3.2. D'abord, le BSB estime bien la densité dans chacune des conditions (tous les $\chi^2(1) < 7,053$, $p > .001$), ce qui montre bien sa capacité à absorber les biais environnementaux. Quant au réseau compétitif, il est incapable d'estimer les densités lorsque les catégories ne sont pas équiprobables (tous les $\chi^2(1) > 15,75$, $p < .001$). En fait, les estimations du modèle compétitif ne diffèrent jamais d'une distribution uniforme (tous les $\chi^2(1) < 6,728$, $p > .001$), alors que celles du BSB diffèrent de l'uniforme dans la condition en escalier et l'exponentielle (les deux $\chi^2(1) > 23,13$, $p < .001$).

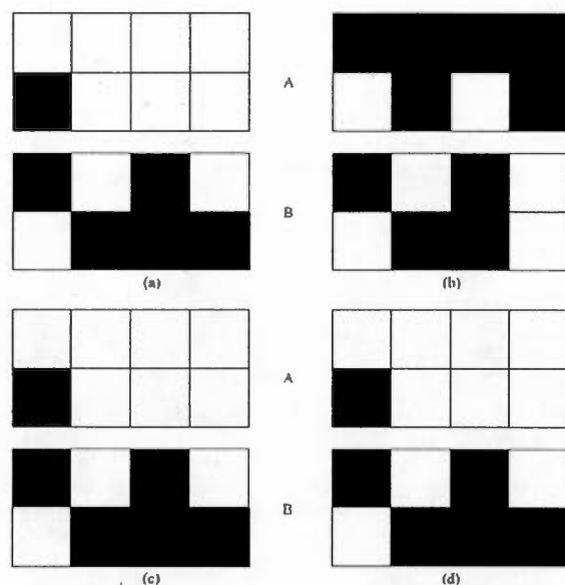


Figure 3.6 Vecteurs de poids de connexions du modèle compétitif rendus discrets suite à un écrasement. Les cases représentent les conditions de la Figure 3.2. (Tirée de Hélie et al., 2006_a.)

En résumé, le BSB est sensible aux effets de fréquence des exemplaires et des catégories. Les premières sont visibles dans la position des vecteurs propres de la matrice de poids (Figure 3.5), alors que les dernières se voient dans les valeurs propres (Figure 3.4) ainsi que dans l'estimation du volume des catégories à l'aide des vecteurs aléatoires (Tableau 3.2). Le réseau compétitif est sensible à la fréquence des exemplaires, tel que montré par la position de ses poids de connexions (Figure 3.6), mais l'estimation du volume des catégories suggère une insensibilité à la fréquence de ces dernières. Cependant, il est utile de se rappeler que ces simulations ont été effectuées dans des environnements simples avec des modèles extrêmement simplistes rarement utilisés de nos jours. La seconde série de simulations permettra d'établir si des modèles plus sophistiqués se comportent de la même façon dans des environnements plus écologiquement valides.

Tableau 3.2

Classification des vecteurs aléatoires dans les environnements simples

	BSB			Réseau Compétitif		
	<u>A</u>	<u>B</u>	χ^2	<u>A</u>	<u>B</u>	χ^2
Uniforme	153 (0,46)	178 (0,54)	0,593	237 (0,47)	263 (0,53)	0,512
Bimodale	220 (0,44)	276 (0,56)	2,915	246 (0,49)	254 (0,51)	0,200
Escalier	195 (0,64)	110 (0,36)	7,053	238 (0,48)	262 (0,52)	15,75*
Exponentielle	357 (0,72)	142 (0,28)	3,085	221 (0,44)	279 (0,56)	222,4*

Note. 500 vecteurs aléatoires ont été testés dans chaque cellule. Les vecteurs n'apparaissant pas dans les conditions du BSB se sont stabilisés dans des *attracteurs poubelles*. Les nombres entre parenthèses représentent les proportions. * indique une différence significative entre la fréquence observée et la fréquence théorique selon un test $\chi^2(1)$, $\alpha = .001$. La valeur critique est 10,83.

3.2 La complexité d'un environnement corrélé

Cette seconde série de simulations teste un représentant sophistiqué de chacune des deux familles de modèles présentées précédemment dans des environnements complexes: plus de dimensions et trois³ catégories corrélées. Cette série de simulations sert à montrer que les postulats supplémentaires présents dans les versions modernes des modèles compétitifs et associatifs n'affectent pas le résultat de l'analyse précédente.

³ Il est important de noter qu'il existe une différence qualitative entre les environnements composés de deux catégories et ceux composés de trois. Dans le premier cas, le modèle peut apprendre seulement une catégorie et définir l'autre comme étant le complément de la première. Dès que plus de deux catégories existent, elles doivent être apprises séparément. Si plus de trois catégories sont incluses dans l'environnement, la différence devient quantitative.

3.2.1 Stimuli et environnements

Les stimuli utilisés pour former les environnements complexes sont présentés dans la Figure 3.7. Il s'agit de chiffres écrits à la main puis transformés en vecteurs en appliquant une grille 16×16 et en utilisant pour chaque case la valeur ± 1 . La corrélation entre les membres d'une même catégorie varie entre 0,74 et 0,95, alors que celle entre des stimuli appartenant à des catégories différentes varie entre 0,22 et 0,42.

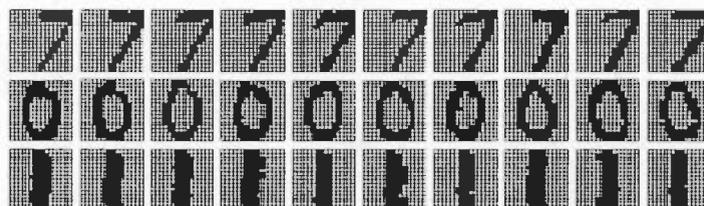


Figure 3.7 Stimuli utilisés pour former les environnements complexes. (Tirée de Hélie et al., 2006_a.)

Comme ce fut le cas pour la simulation d'environnements simples, quatre distributions ont été utilisées afin de contrôler la fréquence des exemplaires et des catégories. Ces distributions sont présentées dans la Figure 3.8. Les cases représentent les mêmes conditions que dans les environnements simples (Figure 3.2) à quelques exceptions près. D'abord, la distribution multimodale (case *b*) contient maintenant trois modes correspondant aux moyennes de trois distribution normales $\mu = \{5; 15; 25\}$ ayant un écart-type commun $\sigma = 2$. La distribution en escalier (case *c*) contient maintenant trois marches, et le ratio de « 7 » pour « 0 » est 7:5, alors que celui de « 7 » pour « 1 » est 7:4. Finalement, la fonction exponentielle (case *d*) a une moyenne $\lambda = 25$ et le ratio de « 7 » pour « 0 » est maintenant 3:2, alors que celui de « 7 » pour « 1 » est 9:4.

3.2.2 Modèles

Les modèles utilisés devaient répondre à deux critères: être capables de catégoriser des stimuli bipolaires et, comme les catégories sont corrélées, être munis d'une procédure de vigilance (Grossberg, 1976_a). Ainsi, ART1 (Carpenter et Grossberg, 1987) a été choisi pour représenter les réseaux compétitifs et NDRAM (Chartier et Proulx, 2005) a été choisi pour représenter les mémoires associatives. Ces modèles sont schématiquement illustrés dans la Figure 3.9. NDRAM est une mémoire associative non-linéaire à laquelle un détecteur de

nouveauté a été ajouté (Chartier et al., 2006). Dans NDRAM, l'information entre dans le réseau, effectue un certain nombre d'itérations, et l'état résultant est comparé avec le stimulus initial: s'ils sont suffisamment similaires (vigilance), ces derniers sont moyennés et le résultat est utilisé dans la règle d'apprentissage. Sinon, le stimulus n'est pas reconnu et il est directement fourni à la règle d'apprentissage (sans tenir compte de l'état résultant du réseau). Les équations de NDRAM sont présentées dans le Tableau 3.3.

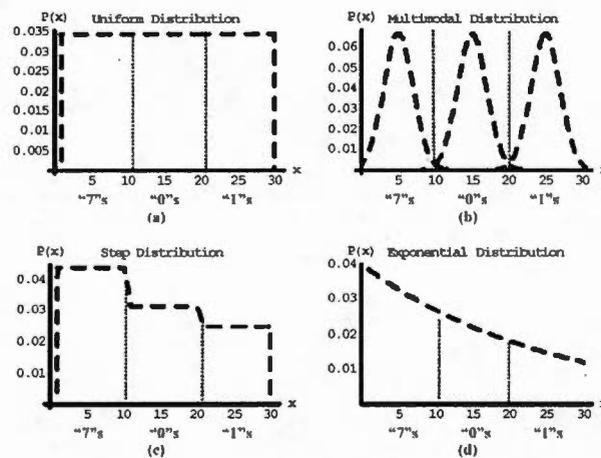


Figure 3.8 Distributions utilisées comme environnements complexes. (a) Distribution uniforme. (b) Distribution multimodale. (c) Distribution en escalier. (d) Distribution exponentielle. (Tirée de Hélie et al., 2006_a.)

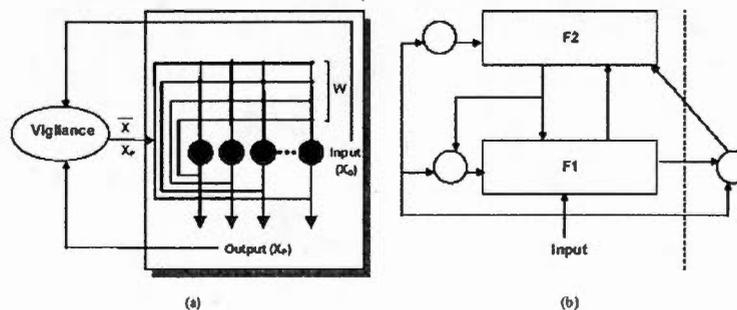


Figure 3.9 (a) Architecture de NDRAM. (b) Architecture de ART1. Les cercles représentent des mécanismes de sélection alors que les rectangles représentent des couches de neurones. La partie à gauche des pointillés est le réseau comme tel, alors que la partie droite représente le module de vigilance. (Tirée de Hélie et al., 2006_a.)

Tableau 3.3.
Équations du modèle NDRAM

Transmission	$\mathbf{x}_{[t+1]} = g(\mathbf{W}\mathbf{x}_{[t]})$ $g(x) = \begin{cases} 1 & , \text{si } x > 1 \\ (\delta + 1)x - \delta x^3 & , \text{si } -1 \leq x \leq 1 \\ -1 & , \text{si } x < -1 \end{cases}$
Résonance	$z = \begin{cases} 1, \frac{\mathbf{x}_{[0]}^T \mathbf{x}_{[p]}}{\ \mathbf{x}_{[0]}\ _2 \ \mathbf{x}_{[p]}\ _2} > \rho \\ 0, \frac{\mathbf{x}_{[0]}^T \mathbf{x}_{[p]}}{\ \mathbf{x}_{[0]}\ _2 \ \mathbf{x}_{[p]}\ _2} \leq \rho \end{cases}$
Apprentissage	$\mathbf{W}_{[k]} = \zeta \mathbf{W}_{[k-1]} + \eta (\bar{\mathbf{x}} \bar{\mathbf{x}}^T - \mathbf{x}_{[p]} \mathbf{x}_{[p]}^T)$ $\bar{\mathbf{x}} = \frac{z(\mu \mathbf{x}_{[0]} + \mathbf{x}_{[p]})}{1 + \mu z} \mathbf{x}_{[0]} (1 - z)$

Note. $\mathbf{x}_{[t]}$ représente le stimulus au temps t , $\mathbf{W}_{[k]}$ est la matrice de poids de connexions après k essais d'apprentissage, δ représente la pente de la fonction de transmission, p est le nombre d'itérations avant apprentissage, ρ est le paramètre de vigilance, ζ est l'efficacité mnésique, η est un paramètre d'apprentissage, et μ pondère l'apport du stimulus initial dans $\bar{\mathbf{x}}$. Dans les simulations qui suivent, $\eta = 0,001$, $\delta = 0,4$, $\zeta = 0,9999$, $\mu = 0,01$, $\rho = 0,7$, et $p = 10$.

ART1 est un réseau compétitif basé sur les notions de vigilance et de résonance adaptative (Grossberg, 1976_b). Dans le modèle ART1, l'information passe de la première couche (F1) à la seconde couche (F2) afin de déterminer la catégorie à laquelle le stimulus appartient (à travers une couche de poids de connexions \mathbf{W}_{bu}). Ensuite, l'intersection entre la catégorie choisie et le stimulus initial est renvoyée à la couche d'entrée (à travers une autre couche de poids de connexions \mathbf{W}_{ud}) afin de comparer la reconstruction (F1') avec le stimulus initial (F1). Si ces deux vecteurs sont suffisamment similaires (vigilance), le modèle est en mode résonance, et il peut ajuster ses poids de connexions. Sinon, une autre catégorie est choisie et la transmission recommence. Les équations décrivant sa dynamique sont résumées dans le Tableau 3.4.

Tableau 3.4
Équations du modèle ART1

Transmission	$\mathbf{F1} = \begin{cases} 1, & \frac{\mathbf{x}}{1 + a(\mathbf{x} + \mathbf{b}) + \mathbf{c}} > 0 \\ 0, & \frac{\mathbf{x}}{1 + a(\mathbf{x} + \mathbf{b}) + \mathbf{c}} \leq 0 \end{cases}$ $\mathbf{F2} = \begin{cases} 1, & \mathbf{F2}_i = \text{Max}(\mathbf{W}_{bu} \mathbf{F1}) \\ 0, & \mathbf{F2}_i \neq \text{Max}(\mathbf{W}_{bu} \mathbf{F1}) \end{cases}$ $\mathbf{F1}' = \begin{cases} 1, & \frac{\mathbf{x} + d\mathbf{W}_{td} \mathbf{F2} - \mathbf{b}}{1 + a(\mathbf{x} + d\mathbf{W}_{td} \mathbf{F2}) + \mathbf{c}} > 0 \\ 0, & \frac{\mathbf{x} + d\mathbf{W}_{td} \mathbf{F2} - \mathbf{b}}{1 + a(\mathbf{x} + d\mathbf{W}_{td} \mathbf{F2}) + \mathbf{c}} \leq 0 \end{cases}$
Résonance	$\rho \leq \frac{\ \mathbf{F1}\ _2^2}{\ \mathbf{F1}'\ _2^2}$
Apprentissage	$\mathbf{w}_{bu}(\mathbf{i}) = \frac{L}{L-1 + \sum_j \mathbf{F1}'_j} \mathbf{F1}'$ $\mathbf{w}_{td}^T(\mathbf{i}) = \mathbf{F1}'$

Note. $\mathbf{F1}$ représente la première couche, $\mathbf{F2}$ la deuxième, $\mathbf{F1}'$ la reconstruction de la première à partir de la deuxième, $\|\cdot\|_2$ est la norme $L2$, \mathbf{x} est le stimulus, \mathbf{W}_{bu} est la matrice de poids de $\mathbf{F1}$ vers $\mathbf{F2}$, \mathbf{W}_{td} est la matrice de poids de $\mathbf{F2}$ vers $\mathbf{F1}$, ρ est le paramètre de vigilance, \mathbf{i} est l'unité gagnante, et $\{a, \mathbf{b}, \mathbf{c}, d, L\}$ sont des paramètres libres. Dans les simulations qui suivent, $a = 1$, $\mathbf{b} = \{1,5\}^{256}$, $\mathbf{c} = \{5\}^{256}$, $d = 0,9$, $\rho = 0,4$, et $L = 45$.

Un réseau ART1 et un réseau NDRAM différents ont été entraînés pendant 10 000 essais dans chacune des conditions présentées dans la Figure 3.8. Suivant ces sessions de pratique, 500 vecteurs aléatoires uniformes $[-1, 1]$ ont été présentés à chacun des réseaux pour fin de catégorisation. Le nombre de stimuli classés dans chacune des catégories représente une estimation du volume de la catégorie, qui devrait être proportionnel à la fréquence cumulée des membres de sa catégorie.

3.2.3 Résultats et discussion

D'abord, les deux modèles ont réussi à apprendre parfaitement les stimuli d'apprentissage dans toutes les conditions. Les résultats au test peuvent donc être interprétés avec confiance, puisque la phase d'apprentissage a été complétée avec succès. Dans la première série de simulations, la sensibilité du BSB (Anderson et al., 1977) à la fréquence des catégories était suggérée par le spectre de valeurs propres. Il est donc justifié d'effectuer une décomposition spectrale des poids de connexions de NDRAM (Chartier et Proulx, 2005) pour voir si cet effet s'y trouve. La Figure 3.10 montre les valeurs propres. Contrairement au BSB, les valeurs propres de NDRAM ne semblent pas affectées par les manipulations: la différence entre les conditions est de l'ordre de 1×10^{-5} . Cependant, les catégories dans cette série de simulations sont composées de stimuli corrélés: ainsi, les attracteurs ne sont pas les vecteurs propres mais plutôt des combinaisons linéaires de ces derniers⁴. Ainsi, les valeurs propres ne sont pas directement associées aux catégories et l'effet de leur fréquence peut quand même être présent au test.

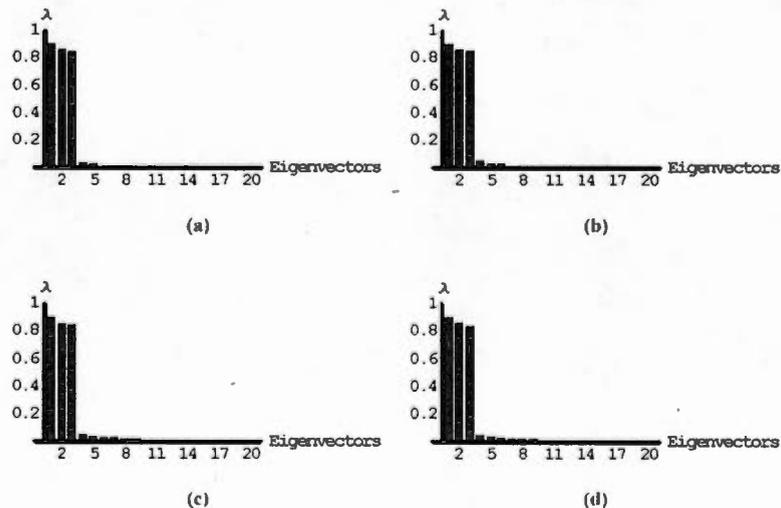


Figure 3.10 Valeurs propres développées par NDRAM après entraînement dans chacune des conditions. Les cases représentent les mêmes conditions que dans la Figure 3.8. (Tirée de Hélié et al., 2006_a.)

⁴ Après convergence dans la fonction de transmission (voir $g(x)$ dans le Tableau 3.3).

Comme les vecteurs propres ne représentent pas directement les catégories, il est plus utile d'observer les attracteurs dans NDRAM. La Figure 3.11A montre les attracteurs développés par NDRAM dans chacune des conditions: ces derniers sont la moyenne théorique des stimuli (Chartier, 2004). Puisque les membres des catégories sont très corrélés (r moyen = 0,87), les moyennes entre les différentes conditions le sont aussi (r moyen > 0,9), et l'effet de la fréquence des exemplaires n'est pas visuellement apparente (mais elle l'est au niveau numérique). En ce qui concerne les poids de connexions de ART1 (case B), ils ne sont pas affectés ni par la fréquence des exemplaires, ni par celle des catégories.

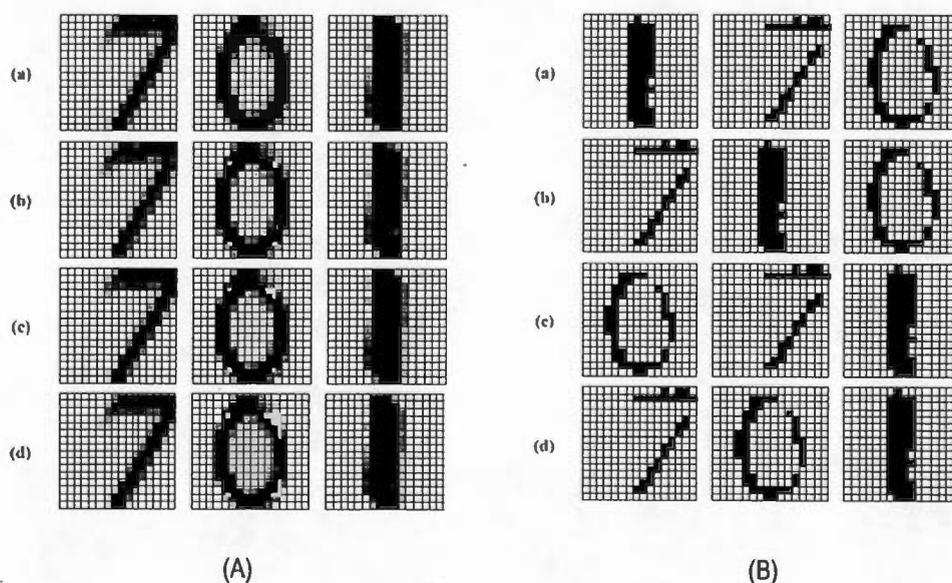


Figure 3.11 (A) Attracteurs développés par NDRAM après entraînement dans chaque condition. (B) Poids de connexions (W_{bu}) développés par ART1 dans chaque condition. L'ordre des unités de F2 est respecté. Dans les deux cases, les conditions sont celles présentées à la Figure 3.8.

Les résultats de la phase test sont présentés dans le Tableau 3.5. Comme dans le cas des modèles simples, la mémoire associative (NDRAM) est en mesure d'estimer la densité environnementale dans toutes les conditions (tous les $\chi^2(2) < 6,095$, $p > .001$). Cependant, le réseau compétitif (ART1) est incapable d'estimer la densité dans tous les environnements (tous les $\chi^2(2) > 375,9$, $p < .001$). Le comportement de ART1 est différent de celui du réseau compétitif simple (qui estimait toujours une distribution uniforme), en ce qu'il est biaisé vers

les catégories dont la cardinalité de l'intersection des membres est la plus grande (dans ce cas-ci la catégorie « 1 »: pour une démonstration, voir l'Appendice A).

Tableau 3.5
Classification des vecteurs aléatoires dans les environnements complexes

NDRAM				
	"7"	"0"	"1"	χ^2
Uniforme	170 (0.34)	145 (0.29)	185 (0.37)	5.089
Multimodale	172 (0.34)	145 (0.29)	183 (0.37)	6.095
Escalier	231 (0.46)	134 (0.27)	135 (0.27)	5.207
Exponentielle	251 (0.50)	143 (0.29)	106 (0.21)	1.533

ART1				
	"7"	"0"	"1"	χ^2
Uniforme	6 (0.01)	134 (0.27)	360 (0.72)	375.9*
Multimodale	5 (0.01)	133 (0.27)	362 (0.72)	382.8*
Escalier	8 (0.02)	137 (0.27)	355 (0.71)	653.6*
Exponentielle	9 (0.02)	114 (0.23)	377 (0.75)	922.9*

Note. 500 vecteurs aléatoires sont inclus à chaque ligne. Les nombres entre parenthèses représentent les proportions. * indique une différence significative entre la fréquence observée et la fréquence théorique selon un test $\chi^2(2)$, $\alpha = .001$. La valeur critique est 13,82.

En résumé, NDRAM est sensible aux effets de fréquence des exemplaires et des catégories. Ce premier effet est visible dans la position des attracteurs, qui représentent la moyenne théorique des stimuli (Figure 3.11A). Le second effet passe inaperçu suite à l'observation du spectre des valeurs propres (Figure 3.10), mais est tout de même présent dans la phase test (Tableau 3.5). Au contraire, ART1 est insensible tant à l'effet de la fréquence des exemplaires qu'à celui de la fréquence des catégories. De plus, ART1 est biaisé

et choisi de façon prépondérante la catégorie dont l'intersection des membres est le plus important.

3.3 Conclusion

Les résultats des simulations montrent que les mémoires associatives, simples et complexes, sont en mesure d'estimer la densité environnementale lorsque l'apprentissage est complété. Elles réagissent à la fréquence des stimuli et des catégories de façon indépendante. Au contraire, les réseaux compétitifs sont incapables d'estimer les biais environnementaux. Cette incapacité résulte de la fonction de décision (*Min* ou *Max*), qui écrase l'espace multidimensionnel en un espace unidimensionnel où seule la dimension la plus importante est retenue. Le reste de l'information est alors perdu. Par exemple, dans la Section 3.2, les trois unités de **F2** sont actives avant que la fonction *Max* ne soit appliquée. Cette activation peut être représentée par un vecteur dans un espace tridimensionnel. Cependant, après l'application de la fonction *Max*, une seule dimension demeure et l'information liée à la projection du vecteur sur les autres axes est perdue.

Par contre, cette réduction de la dimensionnalité au niveau de la couche de sortie a certains avantages qui justifient l'utilisation des réseaux compétitifs. Bien qu'il ne s'agissait pas de l'objectif des présentes simulations, celles-ci permirent de mettre en évidence un net avantage des réseaux compétitifs au niveau de la vitesse de convergence. Par exemple, dans le cas de la simulation d'un environnement complexe, le modèle ART1 convergeait après une centaine d'itérations alors que NDRAM avait besoin des 10 000. Cet avantage de ART1 résulte directement de l'application de la fonction *Max*, puisque qu'elle réduit la variabilité des réponses émises par les modèles compétitifs. Aussi, la simplicité et le succès de la procédure de recrutement d'unités du modèle ART1 (Carpenter et Grossberg, 1987) suggèrent que les propriétés des modèles compétitifs pourraient être plus adaptées aux tâches d'identification. Ainsi, un modèle compétitif pourrait servir à identifier et extraire rapidement les variables (symboles) incluses dans un réseau Bayésien, alors qu'un membre de la famille des mémoires associatives permettrait d'extraire l'information nécessaire à l'apprentissage automatique des arcs formant le réseau Bayésien. Dans le chapitre suivant, un nouveau réseau connexionniste, utilisant les forces de ces deux types d'apprentissages non-supervisés, sera

développé afin de modéliser adéquatement les connaissances implicites dans l'architecture cognitive faisant l'objet des présents travaux.

CHAPITRE IV

APPRENTISSAGE DE LA DISTRIBUTION CONJOINTE DE L'ENVIRONNEMENT À L'AIDE D'UN NOUVEAU MODÈLE CONNEXIONNISTE NON-SUPERVISÉ¹

Ce chapitre vise à développer un réseau connexionniste non-supervisé capable de modéliser les connaissances implicites incluses dans l'architecture cognitive faisant l'objet de la présente thèse. La restriction du choix aux modèles non-supervisés vise à corriger la première faiblesse théorique identifiée dans CLARION (Sun et al., 2001). D'abord, rappelons brièvement les critères devant être satisfaits par le modèle utilisé. Premièrement, le réseau doit être en mesure d'employer des représentations sous-symboliques (Smolensky, 1988), différant qualitativement des représentations symboliques se trouvant dans le module explicite. L'emphase sur la présence d'une différence qualitative entre les représentations symboliques et sous-symboliques vise à éviter la confusion commune entre les représentations distribuées et les représentations réellement sous-symboliques (confusion à laquelle CLARION n'échappe pas). Deuxièmement, le réseau doit contenir l'information nécessaire à la construction automatique d'un réseau de connaissances Bayésien (Neapolitan, 2004; Pearl, 1988, 2000): la sélection des variables causalement impliquées dans l'environnement et apprentissage de la distribution conjointe de ces variables. Il est à noter que le choix des variables était l'un des problèmes d'implémentation de CLARION. Les variables (propositions) étaient incluses a priori dans le module déclaratif. Suite aux analyses conduites dans le chapitre précédent, un réseau compétitif peut être directement utilisé pour sélectionner les variables composant le réseau Bayésien formant les connaissances explicites.

¹ Ce chapitre reprend les résultats publiés dans Hélie et al. (2006_b).

Une fois ces variables sélectionnées, les mémoires associatives (i.e., Anderson et al., 1977; Hopfield, 1982; Kosko, 1988) sont en mesure d'effectuer une estimation de leur densité.

Cependant, il est important de noter que les capacités d'estimation de densité des mémoires associatives sont limitées; les poids de connexions sont une estimation de la covariance entre les unités formant le réseau (Kohonen, 1972). Or, si des représentations sous-symboliques sont utilisées, la densité conjointe entre les *états* du modèle est nécessaire; pas celle entre les unités. Ainsi, le modèle compétitif devrait sélectionner les états causalement impliqués dans le monde et la mémoire associative doit estimer la distribution conjointe de ces derniers. Par contre, l'utilisation conjoint de ces deux types de modèles ne règle pas tout. L'estimation de la covariance est équivalente à l'estimation de la distribution conjointe si et seulement si les variables sont liées deux à deux. Lorsque plus de deux variables sont causalement impliqués dans l'environnement, l'estimation de la covariance est insuffisante pour décrire la distribution conjointe.

Ce dernier point concernant les cas où plus de deux variables sont causalement impliquées est important, puisque plusieurs expériences empiriques montrent que les participants humains sont en mesure de comprendre et d'inférer les chaînes causales (i.e., Ahn et al., 1995). De plus, la capacité des humains à apprendre des relations non-linéairement séparables telles que « comme entrée, vous pouvez choisir une soupe ou une salade mais pas les deux » (le problème du OU-Exclusif, Minsky et Papert, 1969) requiert la connaissance de la distribution conjointe complète. Dans les deux cas (causalité indirecte et relations non-linéairement séparables), la connaissance de la covariance est insuffisante². À notre connaissance, aucune mémoire associative n'est actuellement en mesure de répondre à tous ces critères. Un nouveau réseau connexionniste a donc été développé pour modéliser les connaissances implicites.

² En fait, il est possible d'inférer les facteurs causaux indirects à l'aide d'une matrice de covariance uniquement (à l'aide de différences de tétrades: Bolen et Ting, 1993). Par contre, cette méthode est difficilement défendable au niveau de la plausibilité psychologique, puisque des tests qualitativement différents sont utilisés à chaque fois qu'une variable est ajoutée dans la chaîne causale.

4.1 Modèle

Afin de remplir tous les critères nécessaires à la modélisation des connaissances implicites, un nouveau réseau connexionniste non-supervisé a été développé: le *Joint Probability EXtractor* (JPEX). JPEX utilise plusieurs champs récepteurs, implémentés à l'aide de réseaux compétitifs, afin de mettre en évidence les différents états de l'environnement (symboles). La densité conjointe des symboles est par la suite estimée à l'aide d'un nouveau type de mémoires associatives. Ainsi, JPEX est en mesure de construire les symboles pertinents au système dans son environnement (choisir les variables) et d'estimer la distribution conjointe complète (pas seulement la covariance) à l'aide d'une règle d'apprentissage tensorielle.

4.1.1 Architecture

L'architecture de JPEX est présentée à la Figure 4.1. JPEX est composé de N champs récepteurs contenant chacun n unités. Chaque champ récepteur est connecté avec une couche de sortie unique à ce dernier (contenant m unités)³. Ensemble, ces deux parties du modèle forment un réseau compétitif simple (Rumelhart et Zipser, 1986) auquel un détecteur de nouveauté de type vigilance a été ajouté (Grossberg, 1976_a). Le champ récepteur est sous-symbolique, car chaque unité représente l'un des vecteurs formant la base d'un espace Euclidien (qui par définition est continu). Par exemple, chaque unité d'entrée d'un champ récepteur visuel peut représenter un pixel dans une image (Grossberg, 2003). En contraste, la couche de sortie est symbolique: une seule unité par champ récepteur est active à chaque essai, représentant l'hypersphère dans laquelle le vecteur-stimulus se trouve⁴. Chaque hypersphère représente un symbole et chaque représentation sous-symbolique se trouve à l'intérieur d'un seul et unique symbole (et à l'extérieur de tous les autres, ce qui met en

³ En fait, aucune contrainte n'existe quant à la taille des champs récepteurs et des couches de sortie. Le n et le m de chaque champ récepteur peuvent différer.

⁴ Plus précisément, l'hypersphère représentée par l'unité de sortie i a pour équation:

$$(\mathbf{x} - \mathbf{w}_i)^T (\mathbf{x} - \mathbf{w}_i) = \|\mathbf{w}_i\|^2 + \|\mathbf{x}\|^2 - 2\rho\|\mathbf{x}\| \|\mathbf{w}_i\|$$

où \mathbf{x} est le vecteur-stimulus, \mathbf{w}_i est le centre de l'hypersphère, ρ est le paramètre de vigilance, et $\|\cdot\|$ est la norme. Le rayon de l'hypersphère est la racine du terme à droite de l'égalité.

évidence le caractère discret des symboles). Finalement, en recrutant des unités de sortie à l'aide du détecteur de nouveauté, le réseau construit lui-même les hypersphères qui lui seront utiles en assignant une sémantique aux états des champs récepteurs pertinents dans la tâche qu'il doit accomplir, formant ainsi son propre ensemble de symboles.

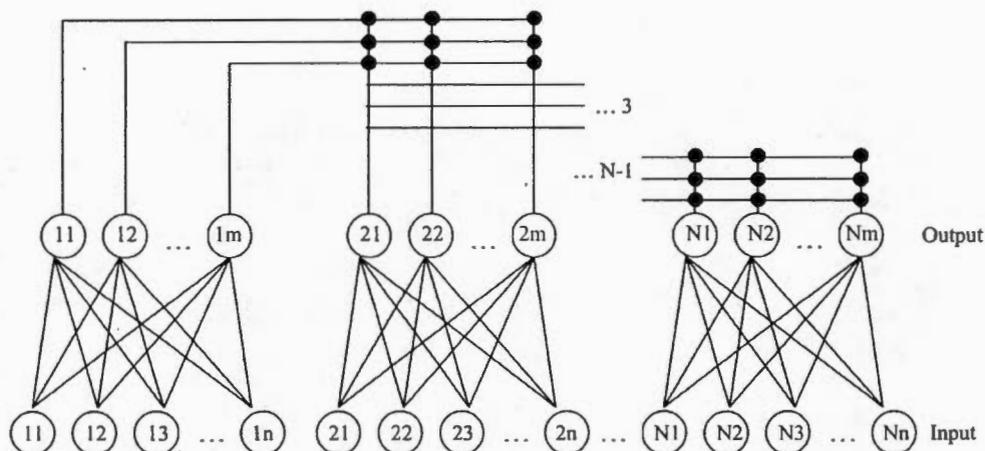


Figure 4.1 Architecture de JPEX. Les cercles noirs représentent des connexions. (Tirée de Hélie et al., 2006.)

La principale innovation de JPEX se situe au niveau des couches de sortie. Chaque couche est connectée aux couches avoisinantes, de façon à former une mémoire associative bidirectionnelle généralisée (Humpert, 1990; Kosko, 1988) connectées de façon sérielle. Ainsi, chaque unité de la couche de sortie i est connectée à chaque unité des couches de sortie $i - 1$ et $i + 1$. Ces connexions sont représentées par un tenseur associatif, qui permet à JPEX d'encoder la distribution conjointe des couches de sorties. La notion de tenseur étant moins répandue que celle de matrice, une légère digression est de mise.

L'algèbre tensorielle est une généralisation de l'algèbre matricielle ayant plusieurs applications en physique. De façon informelle, un tenseur de rang N peut être simplement introduit comme étant un tableau de nombres comportant N dimensions⁵. Ainsi, un tenseur de rang 0 est un nombre, un tenseur de rang 1 est un vecteur, et un tenseur de rang 2 est une

⁵ Le rang d'un tenseur indique le nombre d'indices nécessaire à la désignation d'un élément dans ce dernier.

matrice (il est commun de présenter les matrices comme des tableaux de nombres dans des textes d'introduction à l'algèbre linéaire: Leroux, 1983). De plus, comme toutes les matrices sont des tenseurs de rang deux, il s'agit d'une réelle généralisation et tous les théorèmes et opérateurs utilisés en algèbre matricielle peuvent également être appliqués aux tenseurs. En particulier, le produit scalaire peut aussi être utilisé avec des tenseurs. Le rang d'un nouveau tenseur résultant du produit scalaire de deux autres tenseurs est la somme de leur rang moins deux. En conséquence, l'application du produit scalaire à un tenseur et un vecteur diminue le rang du tenseur [$r(\text{APRÈS}) = r(\text{AVANT}) - 1$, où $r(\mathbf{X})$ retourne le rang de \mathbf{X}]. Bien que loin d'être exhaustive, cette courte introduction à l'algèbre tensorielle est suffisante pour comprendre le fonctionnement de JPEX⁶.

4.1.2 Transmission ascendante

Dans JPEX, chaque champ récepteur reçoit de l'activation qu'il passe à sa couche de sortie afin d'identifier le symbole présent:

$$\mathbf{y}_{[i]} = \mathbf{W}_{[i]} \mathbf{x}_{[i]} \quad 4.1$$

où $\mathbf{y}_{[i]}$ est le vecteur de sortie du $i^{\text{ième}}$ réseau compétitif, $\mathbf{x}_{[i]}$ est le vecteur représentant l'état du $i^{\text{ième}}$ champ récepteur, et $\mathbf{W}_{[i]}$ est la matrice de poids de connexions du $i^{\text{ième}}$ réseau compétitif.

Une fois l'activation transmise aux couches de sorties, l'unité la plus active de chaque couche de sortie est choisie comme étant la gagnante. Si l'activation d'une unité gagnante est plus petite qu'un seuil prédéfini (vigilance: Grossberg, 1976_a), le stimulus n'est pas reconnu comme faisant partie des catégories existantes et une nouvelle unité de sortie est recrutée. Cette dernière est choisie comme gagnante et le vecteur de poids la liant au champ récepteur est initialisé comme étant le stimulus:

$$\begin{aligned} \text{Max}[\mathbf{y}_{[i]}] &\leq \rho \|\mathbf{x}_{[i]}\| \|\mathbf{w}_{[i,k]}\| \\ \mathbf{w}_{[i,m+1]} &= \mathbf{x}_{[i]} \end{aligned} \quad 4.2$$

⁶ Le lecteur intéressé peut se référer à l'excellent condensé écrit par Kay (1988).

où $0 \leq \rho \leq 1$ est le paramètre de vigilance; $w_{[i,k]}$ est le vecteur liant l'unité de sortie la plus active (k) et le $i^{\text{ème}}$ champ récepteur; $\|\cdot\|$ est la norme; et $w_{[i, m+1]}$ est le vecteur de poids entre une unité nouvellement recrutée et le champ récepteur en contact le nouveau stimulus.

La valeur donnée au paramètre de vigilance peut directement être interprétée comme étant la corrélation entre le vecteur de poids, représentant la position de l'hypersphère (symbole) la plus proche, et le stimulus. Ainsi, ρ représente la projection linéaire minimale entre ces deux vecteurs pour qu'ils soient considérés suffisamment similaires pour représenter le même symbole. Si la première ligne de l'Éq. 4.2 est fautive, $x_{[j]}$ se trouve à l'intérieur de l'hypersphère de centre $w_{[i,k]}$. Une fois ce processus de vérification complété, l'unité gagnante de chaque champ récepteur se voit assignée la valeur 1, alors que l'activation des autres unités est fixée à 0.

4.1.3 Transmission descendante

Dans la Figure 4.1, chaque couche de sortie (i) est connectée avec deux autres couches de sortie: $i - 1$ et $i + 1$. Si les trois couches concernées reçoivent simultanément un signal (i.e., un stimulus est présent dans chacun des trois champs récepteurs), l'activation demeure au niveau associatif et la règle d'apprentissage tensoriel est appliquée (voir section suivante). Sinon, si l'une des trois couches de sorties ne reçoit aucun signal (i.e., son champ récepteur n'est en présence d'aucun stimulus), un signal descendant est envoyé vers le champ récepteur inactif.

Comme dans le reste du modèle, la propagation descendante du signal de JPEX s'effectue à l'aide du produit scalaire. Quand un champ récepteur est inactif et que tous les autres sont activés simultanément, un signal descendant est envoyé vers le champ récepteur inactif en utilisant le produit scalaire de façon itérative:

$$y_k = (((V y_1) y_2) \dots) y_{k-1} \quad 4.3$$

où y_k est la couche de sortie du champ récepteur inactif et V est le tenseur associatif. Le rang du tenseur résultant de l'application de Éq. 4.3 est:

$$r(\mathbf{y}_k) = r(\mathbf{V}) + \sum_{i=1}^{k-1} [r(y_i) - 2] \quad 4.4$$

$$= 1$$

Le vecteur \mathbf{y}_k est l'estimation la plus probable de la couche de sortie du $k^{\text{ème}}$ champ récepteur et ce vecteur peut être envoyé vers le champ récepteur à travers ses poids compétitifs:

$$\mathbf{x}_{[k]} = \mathbf{W}_{[k]}^T \mathbf{y}_{[k]} \quad 4.5$$

où $\mathbf{x}_{[k]}$ est le champ récepteur précédemment inactif, duquel l'activation représente maintenant la position du centre de l'hypersphère représentant le symbole le plus probable (étant donné le contenu des autres champs récepteurs).

4.1.4 Apprentissage

Deux types d'apprentissages ont lieu à chaque essai dans JPEX: compétitif (\mathbf{W}) et associatif (\mathbf{V}). Tous les poids de connexions sont initialisés avec des zéro aux deux niveaux. L'apprentissage au niveau compétitif est décrit par (Hertz et al., 1991):

$$\mathbf{w}_{[i,k,t+1]} = \mathbf{w}_{[i,k,t]} + \eta(\mathbf{x}_t - \mathbf{w}_{[i,k,t]}) \quad 4.6$$

où $0 \leq \eta \leq 1$ est un paramètre d'apprentissage général, et $\mathbf{w}_{[i,k,t]}$ est le vecteur de poids de connexions de l'unité gagnante (k) du $i^{\text{ème}}$ champ récepteur au temps t . À chaque essai, seulement le vecteur de poids de l'unité gagnante dans chaque réseau compétitif est mis à jours. Cette règle d'apprentissage maximise le chevauchement entre les membres d'une catégorie et le centre de l'hypersphère la représentant. Le vecteur de poids représentant une catégorie tend donc vers la moyenne arithmétique des membres de cette catégorie (Rumelhart et Zipser, 1986).

La plupart des nouvelles propriétés de JPEX résultent de l'apprentissage au niveau associatif. À ce niveau, le produit tensoriel, proposé par Smolensky (1990) et développé dans Smolensky et Legendre (2006), est utilisé pour intégrer l'activation des couches de sorties de tous les réseaux compétitifs:

$$\mathbf{V}_{[t+1]} = \mathbf{V}_{[t]} + \bigotimes_{i=1}^N \mathbf{y}_i \quad 4.7$$

où $\mathbf{V}_{[t]}$ est le tenseur associatif au temps t , \mathbf{y}_i est le vecteur de sortie du $i^{\text{ème}}$ réseau compétitif, et \otimes est le produit tensoriel usuel défini par:

$$\bigotimes_{i=1}^N \mathbf{y}_i = \begin{cases} \mathbf{y}_1 \mathbf{y}_2^T \mathbf{y}_3 \mathbf{y}_4^T \dots \mathbf{y}_N, & \text{si } N \text{ est impair} \\ \mathbf{y}_1 \mathbf{y}_2^T \mathbf{y}_3 \mathbf{y}_4^T \dots \mathbf{y}_N^T, & \text{sinon} \end{cases} \quad 4.8$$

Le résultat de cette règle d'apprentissage est un tenseur de rang N qui représente soit un tableau ($N = 2$), un parallélépipède rectangle ($N = 3$), ou un paralléloèdre rectangle ($N > 3$) de contingences. Chaque coordonnée permet l'estimation optimale d'une probabilité conjointe d'ordre $N - 1$, puisque les comptes présents dans le tenseur associatif suivent une distribution de Poisson⁷. Comme cette dernière est membre de la famille exponentielle, les fréquences observées constituent des statistiques suffisantes à l'estimation de la distribution ayant générée ces données (Agresti, 1990). Aussi, les probabilités conjointes d'ordre inférieur (et les marginales) peuvent être obtenues en écrasant le tenseur à l'aide de sommations.

4.2 Simulations

La première simulation vise à montrer la capacité d'estimation de densité de JPEX dans un environnement incluant des relations de premier et second ordres. La performance de JPEX dans cette tâche est comparée avec celle d'un modèle identique à JPEX, mais utilisant l'apprentissage Hebbien standard (plutôt que l'apprentissage tensoriel). La seconde simulation montre la capacité de JPEX d'apprendre des relations non-linéairement séparables (le OU-Exclusif). Contrairement à la première simulation, cet apprentissage hétéro-associatif utilise la propagation ascendante et descendante pour apprendre les relations et émettre ses réponses. Les stimuli utilisés dans les deux simulations sont présentés à la Figure 4.2. Il s'agit de chiffres écrits à la main et digitalisés en vecteur bipolaires à l'aide de grilles 8×8 .

⁷ Pour suivre une distribution de Poisson, la probabilité de chaque entier non-négatif doit être positive (Ross, 1998).

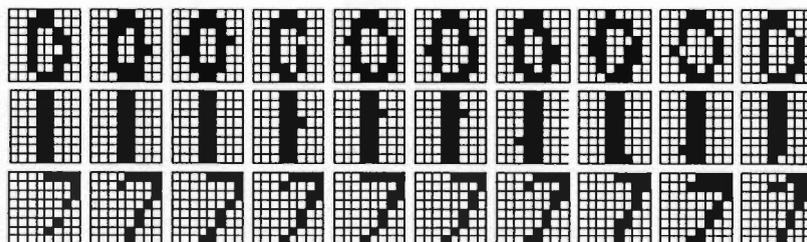


Figure 4.2 Stimuli utilisés dans les simulations.

4.2.1 Apprentissage ascendant d'une distribution conjointe

Afin d'illustrer les capacités d'estimation de densité de JPEX, les stimuli présentés dans la Figure 4.2 ont été présentés trois à la fois (dans trois champs récepteurs distincts) en utilisant la distribution présentée dans le Tableau 4.1. Cette densité a été construite afin d'inclure des relations de premier et second ordres. Par exemple, l'impossibilité d'avoir simultanément un « 0 » dans les trois champs récepteurs est une relation de second ordre, puisque le stimulus présent dans chaque champ récepteur doit être considéré. En contraste, l'impossibilité d'obtenir un « 7 » dans le second champ récepteur et le chiffre « 1 » dans le troisième est une relation d'ordre un, puisque seules les valeurs de ces deux champs récepteurs sont considérées (la valeur du premier est inutile).

Tableau 4.1
Densité utilisée pour entraîner JPEX et le modèle Hebbien

CR2		0			1			7		
CR1	CR3	0	1	7	0	1	7	0	1	7
	0	0	0,02	0,04	0	0,07	0,04	0,11	0	0,07
	1	0,04	0,08	0,04	0,06	0,03	0	0,05	0	0,03
	7	0,05	0,1	0,05	0,04	0,02	0	0,04	0	0,02

Note. CRn est le $n^{\text{ième}}$ champ récepteur.

La règle d'apprentissage tensoriel incluse dans JPEX devrait lui permettre d'apprendre de façon indifférenciée toutes les relations présentes dans le Tableau 4.1. Par ailleurs, un modèle Hebbien devrait seulement être en mesure d'apprendre les relations d'ordre un et ignorer toutes les autres. Le modèle Hebbien utilisé pour fin de comparaison est identique en

tous points à JPEX, sauf pour la règle d'apprentissage au niveau associatif (Éq. 4.7) qui devient:

$$\mathbf{V}_{[t+1]}^{Hebb} = \mathbf{V}_{[t]}^{Hebb} + \mathbf{y}\mathbf{y}^T \quad 4.9$$

où $\mathbf{V}_{[t]}^{Hebb}$ est la matrice de covariance estimée au temps t , et \mathbf{y} est le vecteur résultant de la concaténation de tous les vecteurs de sorties (un par champ récepteur). Dans les deux modèles, $N = 3$, $n = 64$, $\eta = 0,2$, et $\rho = 0,55$. L'assignation des valeurs aux paramètres libres n'est pas optimale, mais les valeurs choisies ne sont pas responsables du succès ou de l'échec des modèles. Les valeurs données à N et n sont uniquement fonction des stimuli utilisés, alors que celles données à ρ et η affectent seulement le nombre de catégories développées et la vitesse d'apprentissage respectivement. Chaque modèle a été entraîné pendant 2 000 essais et, puisque tous les champs récepteurs étaient remplis à chaque essai, seule la transmission ascendante a été utilisée dans cette simulation.

Suivant la phase d'apprentissage, tous les stimuli étaient rappelés correctement par chaque champ récepteur de JPEX et du modèle Hebbien, ce qui indique que la partie compétitive des modèles a été bien entraînée. Les poids compétitifs développés par JPEX sont montrés dans la Figure 4.3⁸. Bien que les poids diffèrent d'un champ récepteur à un autre, les catégories sont toujours facilement reconnaissables. Les différences entre poids reflètent des fluctuations dues au hasard.

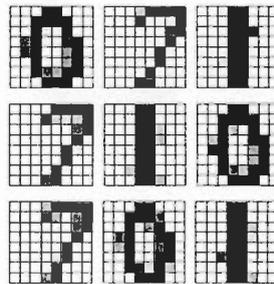


Figure 4.3 Poids compétitifs développés par JPEX. Chaque ligne représente un champ récepteur différent. L'ordre des unités dans la couche de sortie est respecté.

⁸ Les poids compétitifs développés par le modèle Hebbien sont similaires et ne sont pas illustrés.

D'un plus grand intérêt sont les poids associatifs développés par JPEX et le modèle Hebbien. Les résultats quant à la nouvelle règle d'apprentissage proposée (Éq. 4.7) sont concluants. JPEX réussit à extraire toutes les dépendances de premier et deuxième ordre présentes dans la densité utilisée pour présenter les stimuli (Tableau 4.2). Par exemple, il est impossible d'obtenir le chiffre « 1 » dans les deux premiers champs récepteurs et « 7 » dans le dernier. Cette impossibilité structurale présente dans le Tableau 4.1 l'est également dans le Tableau 4.2. De plus, l'apprentissage des relations de second ordre ne se fait pas au détriment de celles de premier ordre: l'impossibilité d'avoir un « 7 » dans le deuxième champ récepteur et le chiffre « 1 » dans le dernier a également été apprise par JPEX. En somme, la densité estimée par JPEX (Tableau 4.2) ne diffère pas de la densité théorique (Tableau 4.1: $G^2(8) = 3,46, p = 0.9$). De plus, la plus grande erreur d'estimation pour une cellule est seulement de 0,02.

Tableau 4.2
Densité estimée par JPEX

CR2		0			1			7		
CRI	CR3	0	1	7	0	1	7	0	1	7
		0	0 (0,00)	45 (0,02)	66 (0,03)	0 (0,00)	155 (0,08)	76 (0,04)	212 (0,11)	0 (0,00)
1		82 (0,04)	172 (0,09)	86 (0,04)	104 (0,05)	60 (0,03)	0 (0,00)	108 (0,05)	0 (0,00)	48 (0,02)
7		116 (0,06)	216 (0,10)	103 (0,05)	72 (0,04)	49 (0,02)	0 (0,00)	91 (0,04)	0 (0,00)	41 (0,02)

Note. CR*n* est le *n*^{ème} champ récepteur. Les nombres entre parenthèses sont les proportions.

Les résultats du modèle Hebbien sont présentés dans le Tableau 4.3. Tel que prévu, le modèle Hebbien est parfaitement capable d'apprendre les relations de premier ordre (comme JPEX). Cependant, il est incapable de détecter l'existence des relations d'ordres supérieurs. Par exemple, l'impossibilité d'avoir des chiffres « 1 » dans les deux premiers champs récepteurs et un « 7 » dans le troisième n'est pas détectée par le modèle Hebbien. Tout ce qu'il peut inférer est que la probabilité d'avoir le chiffre « 1 » dans le premier champ récepteur et « 7 » dans le troisième est 0,22. De même, la probabilité d'avoir le chiffre « 1 » dans le second champ récepteur et « 7 » dans le troisième est 0,15. La seule impossibilité correctement inférée par le modèle Hebbien est celle concernant la présence d'un « 7 » dans le second champ récepteur et le chiffre « 1 » dans le troisième. Cette relation a été apprise,

puisqu'elle est indépendante de ce qui se trouve dans le premier champ récepteur (tel que suggéré par la colonne de 0 dans le Tableau 4.1). Il s'agit donc d'une relation d'ordre un.

Tableau 4.3
Covariance estimée par le modèle Hebbien

		CR1			CR2			CR3		
		0	1	7	0	1	7	0	1	7
CR1	0	637 (1,00)	0 (0,00)	0 (0,00)	104 (0,16)	222 (0,35)	311 (0,49)	203 (0,32)	176 (0,28)	258 (0,41)
	1		663 (1,00)	0 (0,00)	361 (0,55)	157 (0,24)	145 (0,22)	302 (0,46)	217 (0,33)	144 (0,22)
	7			700 (1,00)	404 (0,58)	152 (0,22)	144 (0,21)	294 (0,42)	262 (0,37)	144 (0,21)
CR2	0				869 (1,00)	0 (0,00)	0 (0,00)	190 (0,22)	408 (0,47)	271 (0,31)
	1					531 (1,00)	0 (0,00)	203 (0,38)	247 (0,47)	81 (0,15)
	7						600 (1,00)	406 (0,68)	0 (0,00)	194 (0,32)
CR3	0							799 (1,00)	0 (0,00)	0 (0,00)
	1								655 (1,00)	0 (0,00)
	7									546 (1,00)

Note. CR n est le $n^{\text{ième}}$ champ récepteur. Les nombres entre parenthèses sont les proportions.

En résumé, l'environnement simple représenté par le Tableau 4.1 a été suffisant pour montrer les limites de l'apprentissage Hebbien standard et mettre en évidence les avantages liés à l'utilisation de l'apprentissage tensoriel. La prochaine simulation montrera la possibilité d'un apprentissage hétéro-associatif résultant de la propagation de l'information dans le tenseur associatif.

4.2.2 Apprentissage interactif de catégories non-linéairement séparables

Les stimuli présentés dans les deux premières lignes de la Figure 4.2 ont été utilisés afin de montrer la capacité d'apprentissage de relations non-linéaires de JPEX. Pour ce faire,

le problème du OU-Exclusif a été utilisé et les associations devant être apprises sont montrées dans la Figure 4.4. À chaque essai d'apprentissage, une ligne de la Figure 4.4 était choisie de façon aléatoire pour constituer l'état de l'environnement, qui comprend trois champs récepteurs correspondant aux trois colonnes ($N = 3$). Ainsi, si la deuxième ligne de la Figure 4.4 est choisie comme état de l'environnement, le premier et le troisième champs récepteurs étaient en contact avec des stimuli choisis aléatoirement dans la première ligne de la Figure 4.2, alors que le second champ récepteur recevait un stimulus choisi aléatoirement dans la seconde ligne de la Figure 4.2.

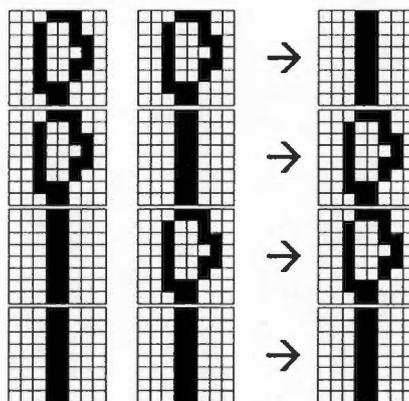


Figure 4.4 Associations devant être apprises par JPEX.

Dans la phase test, seulement les deux premières colonnes de la Figure 4.4 ont été présentées aux deux premiers champs récepteurs de JPEX. Le modèle devait rappeler le stimulus associé (i.e., celui dans la troisième colonne) dans le troisième champ récepteur en utilisant la propagation descendante.

Cette simulation illustre bien les deux types de transmissions possibles dans JPEX. Durant la phase d'apprentissage, tous les champs récepteurs étaient en présence de stimuli à chaque essai. Ainsi, la transmission du signal se faisait seulement de façon ascendante et le tenseur associatif se développait de façon itérative (comme dans la simulation précédente). Au test, un champ récepteur était vide à chaque essai. Ainsi, l'absence de signal dans l'une des couches de sorties déclenchait la propagation descendante de l'information à travers le tenseur associatif de la façon suivante. Lorsque le premier stimulus était présenté, il était reconnu et le symbole associé devenait actif dans la première couche de sortie. Ce vecteur de

sortie était par la suite transmis à travers la couche associative (Éq. 4.3), ce qui a eu pour effet de réduire le rang du tenseur. Le rang du tenseur associatif résultant était donc $3 + 1 - 2 = 2$ (une matrice). Ensuite, le stimulus présenté dans le second champ récepteur était également reconnu et sa couche de sortie était transmise à travers la matrice résultant de l'étape précédente (Éq. 4.3). Le rang du tenseur diminue ($2 + 1 - 2 = 1$) et le vecteur résultant est la couche de sortie la plus probable du troisième champ récepteur. Le vecteur final a été transmis à travers les poids compétitifs du troisième champ récepteur (Éq. 4.5), qui reflète maintenant la position du centre de l'hypersphère représentant le symbole le plus souvent associée aux autres stimuli durant la phase d'apprentissage.

Les mêmes valeurs ont été assignées aux paramètres libres que dans la simulation précédente et la simulation a été répétée 100 fois. Tel qu'illustré à la Figure 4.5, moins de 20 essais d'entraînement ont été nécessaire à l'apprentissage de toutes les associations de la Figure 4.4; le problème du OU-Exclusif était donc résolu. En contraste, un réseau connexionniste multicouches qui apprend par rétropropagation de l'erreur a souvent besoin de plusieurs milliers d'essais d'apprentissage pour résoudre ce même problème (Cousineau, 2005). Ainsi, JPEX est capable d'apprendre rapidement les problèmes de catégorisation non-linéairement séparables.

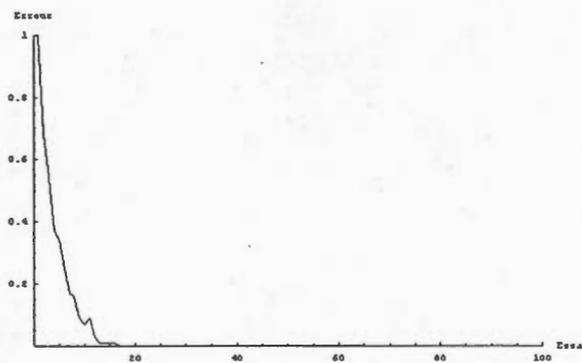


Figure 4.5 Performance de JPEX au problème du OU-Exclusif.

4.3 Conclusion

Dans le présent chapitre, un nouveau réseau connexionniste a été proposé pour modéliser les connaissances implicites. JPEX est un modèle non-supervisé qui extrait les états de l'environnement et estime leur distribution conjointe. Au niveau des champs

récepteurs, l'information est représentée de façon sous-symbolique (Smolensky, 1988), alors qu'au niveau des couches de sorties compétitives, l'information est symbolique. Les différentes couches de sorties sont connectées de façon sérielle à l'aide d'un tenseur associatif, qui représente un paralléloptope rectangle de contingences.

Dans la première simulation, les limites liées à l'extraction de la covariance à l'aide d'une règle Hebbienne standard ont été mises en évidence en simulant un environnement simple incluant des relations de premier et de second ordres. Bien que les relations de second ordre soient demeurées invisibles pour le modèle Hebbien standard, JPEX a été en mesure d'apprendre aussi bien les relations de premier ordre que celles d'ordres supérieurs.

Il est intéressant de noter que l'apprentissage tensoriel est en fait une généralisation de l'apprentissage Hebbien standard (Kohonen, 1972). Ainsi, JPEX hérite de la plausibilité psychologique de l'apprentissage Hebbien, de même que de toutes ses propriétés liées au calcul (i.e., complétion de stimuli, robustesse, optimalité, localité, absence de supervision: Proulx et Hélie, 2005). De plus, l'utilisation d'un tenseur associatif, plutôt qu'une matrice, structure la mémoire, ce qui permet à JPEX d'apprendre rapidement à solutionner des problèmes de catégorisation non-linéairement séparables, comme celui du OU-Exclusif. Selon la théorie de Smolensky et Legendre (2006), JPEX construit une représentation structurée de la conjonction de tous les essais d'apprentissage, ce qui est suffisant pour effectuer un traitement symbolique sur ceux-ci. Aussi, la transmission descendante dans JPEX est interprétée comme de la *contraction tensorielle* dans la théorie développée par Smolensky et Legendre. Finalement, même si les éléments du tenseur représentent des relations d'ordres supérieurs, les relations d'ordres inférieurs sont facilement accessibles en écrasant le paralléloptope rectangle à l'aide d'un opérateur de sommation.

Bien que la meilleure performance de JPEX ait un coût au niveau de la complexité du modèle⁹, les représentations tensorielles peuvent être compressées de plusieurs façons (Smolensky et Legendre, 2006). L'application d'un opérateur de compression se fait au détriment de l'exactitude, mais la saturation d'une mémoire compressée est graduelle et

⁹ La complexité de JPEX est $O(m^M)$ alors que celle du modèle Hebbien est $O[(m \times N)^2]$.

continue, ce qui permet la modélisation de structures et processus complexes, tels la mémoire humaine et le traitement du langage (incluses dans Smolensky et Legendre, 2006). Des travaux futurs devraient permettre de réévaluer la performance de JPEX en utilisant comme mémoire un tenseur compressé, c'est-à-dire un modèle incluant N champs récepteurs dont la densité conjointe est encodée à l'aide d'un tenseur de rang $k < N$.

Finalement, les simulations présentées dans le présent chapitre ont montré que JPEX est en mesure d'apprendre la densité conjointe de plusieurs champs récepteurs spatialement alignés. Cependant, JPEX peut également être utilisé pour apprendre les dépendances temporelles. Par exemple, le $N^{\text{ième}}$ champ récepteur peut refléter l'état actuel de l'environnement (temps t), alors que le $(N - 1)^{\text{ième}}$ peut refléter l'état de l'environnement au temps $t - 1$, etc. Ainsi, en utilisant suffisamment de champs récepteurs, JPEX serait peut-être en mesure d'apprendre à prédire correctement des séries chaotiques. Cependant, de nouvelles simulations sont requises afin d'évaluer les limites de l'estimation des probabilités conjointes.

CHAPITRE V

DÉVELOPPEMENT D'UN MODÈLE GÉNÉRAL DE LA COGNITION HUMAINE

Maintenant que la théorie permettant le développement d'une architecture cognitive a été mise en place, la création d'un modèle s'impose. Le présent chapitre décrit et formalise TELECAST (TEnsor LEarning of CAusal STructure), alors que le chapitre suivant présente les résultats de simulations qui mettent en évidence la correspondance entre les résultats empiriques et les prédictions du modèle développé.

5.1 Architecture générale

Un schéma général de TELECAST est présenté à la Figure 5.1. Tel que montré, l'architecture de TELECAST met en évidence une distinction nette entre deux types de connaissances, soit les connaissances implicites et explicites. La principale distinction entre ces deux types de connaissances se situe au niveau de l'accessibilité; les premières sont peu accessibles à la conscience alors que les secondes sont directement disponibles pour fin de rapport verbal (Cleeremans, 1997; Cleeremans et al., 1998). La présence de plusieurs types de connaissances répond à l'un des critères du test de Newell (Anderson et Lebiere, 2003) et le choix d'une dichotomie implicite / explicite répond au critère plus précis énoncé par Sun (2004). De plus, seul le module implicite est en contact avec l'environnement. Toute l'information sensorielle doit obligatoirement passer par le module implicite avant d'activer les symboles se trouvant au niveau explicite. De même, si les connaissances explicites sont en mesure de trouver la solution à un problème donné, cette dernière doit être transmise au module implicite afin qu'une réponse soit émise par le modèle. Ainsi, une tâche peut uniquement solliciter les connaissances implicites mais l'inverse est impossible.

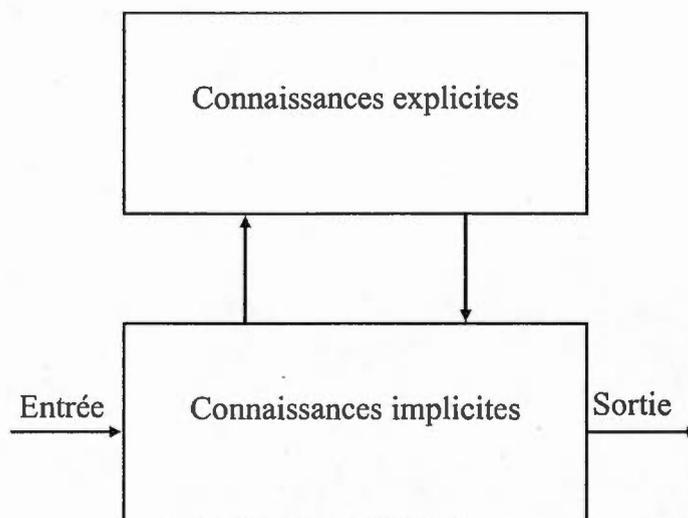


Figure 5.1 Architecture générale de TELECAST.

TELECAST possède deux caractéristiques importantes: les deux modules tentent de résoudre indépendamment les tâches qui leur sont présentées, et leurs réponses sont par la suite intégrées. Aussi, TELECAST génère automatiquement ses connaissances explicites à l'aide de l'information se trouvant dans son module implicite. Cette re-description de l'information, la rendant accessible à la conscience (Karmiloff-Smith, 1994), se fait à l'aide du tenseur associatif développé de façon implicite. Il est important de noter que ces deux particularités répondent à des critères cognitifs du décathlon proposé par Sun, et que seul CLARION rencontrait ces critères jusqu'à maintenant (Sun et al., 2001). Les deux sections qui suivent décrivent le fonctionnement des modules dans TELECAST. Ensuite, la Section 5.4 explique l'interaction synergique des modules, alors que la Section 5.5 présente les procédures d'apprentissage.

5.2 Connaissances implicites

Les connaissances implicites dans TELECAST sont implémentées à l'aide d'une version modifiée du modèle JPEX (Hélie et al., 2006_b). L'architecture modifiée de JPEX est présentée dans la Figure 5.2. La comparaison de cette Figure avec le modèle original (Figure 4.1) met en évidence une seule différence: les liens compétitifs sont maintenant

unidirectionnels. Ainsi, la transmission descendante à l'intérieur des connaissances implicites n'est plus permise; cette dernière est remplacée par une rétroaction descendante des connaissances explicites sur les connaissances implicites (voir Section 5.4). Cette contrainte sur la direction de la transmission de l'information vise à refléter la diminution de l'influence du traitement descendant lorsque l'information cognitive devient sensorielle. Par exemple, Fodor (1983) argumente que le traitement descendant doit arrêter avant d'atteindre les capteurs sensoriels, puisqu'une illusion visuelle est toujours perçue même lorsque l'observateur sait consciemment qu'il s'agit d'une illusion. À part cette différence, qui vise à accroître la plausibilité psychologique de JPEX comme modèle de la cognition implicite, la nouvelle version de JPEX est toujours composée de N champs récepteurs, chacun composé de n unités d'entrées sous-symboliques (Smolensky, 1988). Chaque champ récepteur est connecté à sa propre couche de sorties symboliques (contenant m unités) afin de former un réseau compétitif auquel un détecteur de nouveauté de type vigilance a été ajouté (Grossberg, 1976_a). Au niveau fonctionnel, toute l'information perceptuelle¹ doit nécessairement passer par les champs récepteurs, et les couches de sorties représentent des concepts (résumant l'information perceptuelle) ou des actions (la réponse du modèle se situe à ce niveau). Finalement, les couches de sorties sont connectées de façon sérielle afin d'apprendre la distribution conjointe des $N \times m$ symboles inférés par JPEX (pour plus de détails, voir le Chapitre IV).

Dans TELECAST, le tenseur associatif utilisé pour apprendre la distribution conjointe des symboles inférés est une mémoire implicite temporaire (mémoire tampon) qui sert à construire les connaissances explicites (voir Section 5.5). Ainsi, l'estimation de la distribution conjointe n'est pas directement accessible pour rapport verbal, mais les connaissances explicites extraites le sont (liens causaux et probabilités conditionnelles, cette prédiction sera détaillée dans la Conclusion). Aussi, la mémoire associative se vide lorsque l'objectif du modèle change dans la simulation. De ce fait, le tenseur peut servir à modéliser une structure de buts, en créant de l'amorçage. Par exemple, si l'agent cherche un état dans

¹ L'information perceptuelle provient de l'extérieur du modèle mais pas nécessairement de l'extérieur du corps. Par exemple, l'information perceptuelle peut être proprioceptive.

lequel trois champs récepteurs reçoivent simultanément le même signal, il est possible de faciliter cette recherche en insérant au préalable des traces mnésiques correspondant à cet objectif dans le tenseur (i.e., en initialisant les positions correspondantes avec des valeurs plus élevées). Ce type d'amorçage sera illustré à l'aide d'un exemple dans le Chapitre VI.

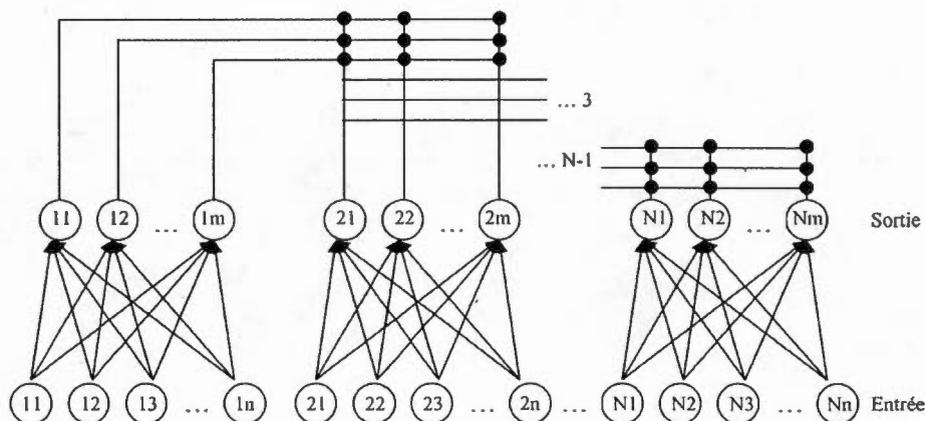


Figure 5.2 Architecture modifiée de JPEX utilisée pour modéliser les connaissances implicites dans TELECAST.

Mise à part l'absence de transmission descendante, la transmission des connaissances implicites se fait de la même façon que dans la version originale de JPEX. Les équations sont tout de même brièvement répétées; le lecteur peut se référer à la Section 4.1.2 du document pour plus de détails.

La transmission dans chaque réseau compétitif se fait en utilisant le produit scalaire standard:

$$\mathbf{y}_{[i]} = \mathbf{W}_{[i]} \mathbf{x}_{[i]} \quad 5.1$$

où $\mathbf{y}_{[i]}$ est le vecteur de sortie du $i^{\text{ème}}$ réseau compétitif, $\mathbf{x}_{[i]}$ est un vecteur représentant l'état du $i^{\text{ème}}$ champ récepteur et $\mathbf{W}_{[i]}$ est la matrice de poids de connexions du $i^{\text{ème}}$ réseau compétitif.

Une fois l'information transmise aux différentes couches de sorties, l'unité la plus activée dans chaque couche est choisie comme gagnante et son niveau d'activité est comparé avec un seuil pré-établi (vigilance: Grossberg, 1976_a). Si l'activation de l'unité gagnante est

plus grande que le seuil, l'état du champ récepteur est une instance du symbole activé. Sinon, un nouveau symbole est créé et l'unité symbolique recrutée est choisie comme gagnante. Le vecteur de poids liant cette unité au champ récepteur est initialisé en utilisant une copie de l'activation présente dans le champ récepteur:

$$\begin{aligned} \text{Max}[y_{[i]}] &\leq \rho \|x_{[i]}\| \|w_{[i,k]}\| \\ \mathbf{w}_{[i,m+1]} &= \mathbf{x}_{[i]} \end{aligned} \quad 5.2$$

où $0 \leq \rho \leq 1$ est le paramètre de vigilance; $w_{[i,k]}$ est le vecteur liant l'unité de sortie la plus active (k) et le $i^{\text{ème}}$ champ récepteur; $\|\cdot\|$ est la norme; et $w_{[i,m+1]}$ est le vecteur de poids entre une unité nouvellement recrutée et le champ récepteur recevant le nouveau stimulus.

Une fois le gagnant de chaque couche de sortie choisi, la représentation correspondant à chacune des unités gagnantes est activée au niveau des connaissances explicites, ce qui permet la propagation d'incertitude dans ce module.

5.3 Connaissances explicites

Les connaissances explicites sont implémentées à l'aide d'un *hypergraphe simple* de connaissances Bayésien (Neapolitan, 2004; Pearl, 1988, 2000). De façon informelle, un hypergraphe simple est un graphe dans lequel chaque sommet représente un ensemble de sommets; si ces ensembles sont disjoints, l'hypergraphe est dit *simple* (Berge, 1970). Par exemple, la Figure 5.3 présente les couches de sorties de JPEX (Figure 5.2) en mettant l'accent sur les connexions inhibitrices entre chaque unité d'une même couche de sortie (manquantes dans la Figure 4.1 et la Figure 5.2). Ces connexions sont représentées à l'aide de lignes discontinues pour mettre en évidence le caractère distinct de ces dernières. Il s'agit des seules connexions déterministes dans le modèle puisque l'activation d'une unité rend inactive toutes les autres unités appartenant à la même couche de sortie. Si seules ces connexions sont considérées, chaque couche de sortie forme une *clique* (sous-graphe totalement connecté) dont l'activité peut être entièrement résumée par une seule variable comprenant m états. Plus précisément, appelons G_{JPEX} le graphe dont l'ensemble des sommets et l'ensemble des arcs sont composés des symboles et des connexions déterministes se trouvant dans les couches de sorties de JPEX. Les connaissances explicites dans TELECAST sont implémentées à l'aide d'un hypergraphe dans lequel chaque sommet représente une clique de G_{JPEX} (tel que suggéré

par les pointillés dans la Figure 5.3). Ainsi, chaque sommet de l'hypergraphe représente une variable multivariée composés de m variables binaires, qui ensemble suivent une distribution de Dirichlet entièrement décrite par les $m - 1$ premières (Cooper et Herskovits, 1992):

$$Dir(x_1, x_2, \dots, x_{m-1}; u_1, u_2, \dots, u_m) = \frac{\Gamma\left(\sum_{i=1}^m u_i\right)}{\prod_{i=1}^m \Gamma(u_i)} \prod_{i=1}^m x_i^{u_i-1} \quad 5.3$$

où x_i représente la $i^{\text{ème}}$ variable ($\sum_{i=1}^m x_i = 1$) et u_i représente le $i^{\text{ème}}$ paramètre, qui peut être interprété comme le nombre d'occurrences de la variable x_i . Cette distribution peut être décrite à l'aide de $m - 1$ variables, puisque $x_m = 1 - \sum_{i=1}^{m-1} x_i$.

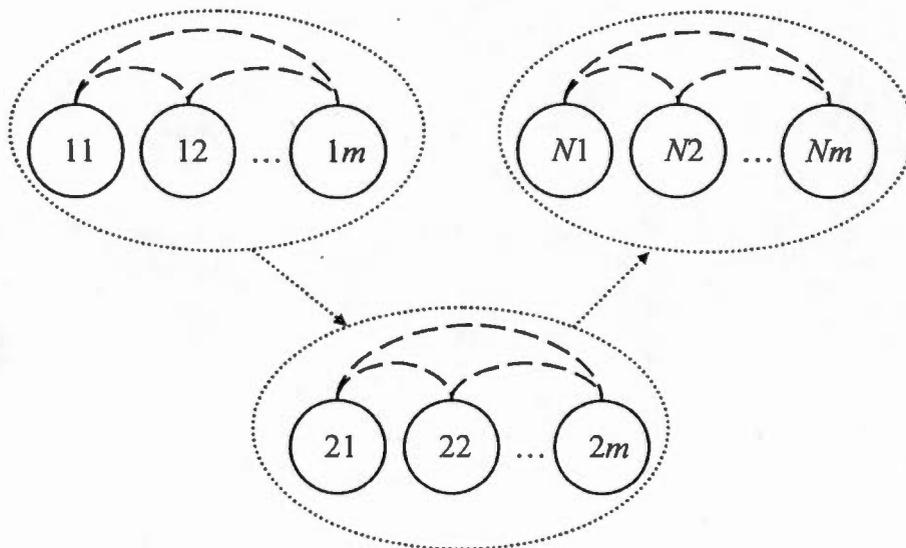


Figure 5.3 Hypergraphe de connaissances Bayésien utilisé pour représenter les connaissances explicites dans TELECAST.

Une fois les ensembles de sommets formant l'hypergraphe de connaissances Bayésien choisis, ce dernier est équivalent à un graphe ayant ces ensembles comme sommets. Il est donc possible de tracer des arcs représentant les liens de causalité entre les ensembles. Les

flèches pointillées de la Figure 5.3 sont un exemple de chaîne causale (i.e., l'activité humaine produit des gaz à effets de serres, qui produisent un réchauffement climatique). En plus de faciliter l'interprétation des règles développées par TELECAST, l'utilisation d'un hypergraphe résulte en un réseau Bayésien plus clairsemé (comprenant moins d'arcs), ce qui diminue de façon exponentielle la complexité du calcul de l'incertitude.

Le calcul de l'incertitude d'un sommet se fait à l'aide du tableau de paramètres décrivant la distribution de Dirichlet qu'il représente (les u_i), dont la taille dépend des arcs entrant dans celui-ci. Avant d'expliquer la composition de ces tableaux, certains termes relatifs à la théorie des graphes doivent être introduits. D'abord, si un sommet B est *enfant* d'un sommet A , un arc sort de A et pointe vers B (symétriquement, A est un *parent* de B). Ensuite, la *couverture de Markov* (*Markov blanket*: Pearl, 1988) d'une variable est composée de ses parents et de ses enfants. Chaque sommet est indépendant du reste du graphe étant donné sa couverture de Markov, c'est-à-dire qu'une fois l'état des parents et enfants d'un sommet A connu, l'information quant à l'état des autres variables formant le graphe est inutile pour déterminer l'état de A . Par exemple, dans la Figure 5.3, la deuxième clique est un parent de la N -ième. Comme la N -ième clique n'a pas d'enfant, la seconde clique forme sa couverture de Markov, rendant la N -ième clique indépendante du reste du graphe. Ainsi, une fois l'état de la seconde clique connu, l'état de la première n'affecte pas celle de la N -ième.

Le principe de couverture de Markov est particulièrement important dans un modèle psychologique. La couverture de Markov d'un sommet lui est directement adjacente, et l'information quant à son état est nécessaire et suffisante au calcul de la distribution du sommet. La localité de ce calcul d'incertitude contribue à la plausibilité psychologique du modèle. Au niveau formel, la présence de distributions de Dirichlet pour décrire les probabilités a priori est particulièrement utile, puisque cette famille de distributions est conjuguée. Ainsi, la distribution *a posteriori* (suivant de nouvelles observations) demeure de la même famille. En particulier, si un nouveau vecteur d'observations est disponible $\mathbf{s} = \{s_1, s_2, \dots, s_m\}$, la distribution présentée en Éq. 5.3 devient:

$$\begin{aligned} Dir(x_1, x_2, \dots, x_{m-1}; u_1, u_2, \dots, u_m | \mathbf{s}) = \\ Dir(x_1, x_2, \dots, x_{m-1}; u_1 + s_1, u_2 + s_2, \dots, u_m + s_m) \end{aligned} \quad 5.4$$

En mots, les paramètres (u_i) d'une distribution de Dirichlet sont tout simplement le nombre d'occurrences de chaque variable et, lorsque de nouvelles observations sont disponibles, elles sont simplement additionnées aux comptes précédents et la forme de la distribution demeure inchangée (Neapolitan, 2004). Ainsi, la seule information nécessaire à la spécification des paramètres d'un réseau de connaissances Bayésien discret est un tableau de contingences pour chaque sommet. Pour un sommet donné, ce tableau contient tout simplement le nombre d'occurrences de chacun de ses états, en fonction de chaque combinaison d'états de ses parents. Une fois normalisés, ces tableaux de paramètres deviennent des tableaux de probabilités. Par exemple, la Figure 5.4 montre un réseau Bayésien binaire avec paramètres. Comme les variables ont seulement deux états possibles, la probabilité d'un seul état est spécifiée et celle de l'autre peut être obtenu en soustrayant la première de un. Deux cas particuliers sont présents. D'abord, le sommet H n'a pas de parents. Ainsi, son tableau de probabilité contient des probabilités a priori. Enfin, les sommets ayant plus d'un parent (i.e., F) doivent conditionner leurs états sur la conjonction des états de leurs parents, pas sur celles de chacun des parents pris isolément. Cette mise en garde résulte du fait que deux sommets ne sont pas indépendants lorsque conditionnés sur l'état d'un enfant commun. De façon plus générale, le nombre de paramètres requis pour spécifier la distribution modélisée par un sommet est:

$$nbParamètres_A = (m_A - 1) \prod_{i=1}^p m_i \quad 5.5$$

où $nbParamètres_A$ est le nombre de paramètres nécessaire à la spécification du sommet A , m_i est le nombre d'états du sommet i , et i indexe chacun des p parents de A . Si le sommet A ne possède aucun parent, $nbParamètres_A = m_A - 1$. Comme une réduction du nombre d'arcs se traduit directement par une réduction du nombre de parents, l'utilisation d'un hypergraphe diminue la complexité du calcul de l'incertitude.

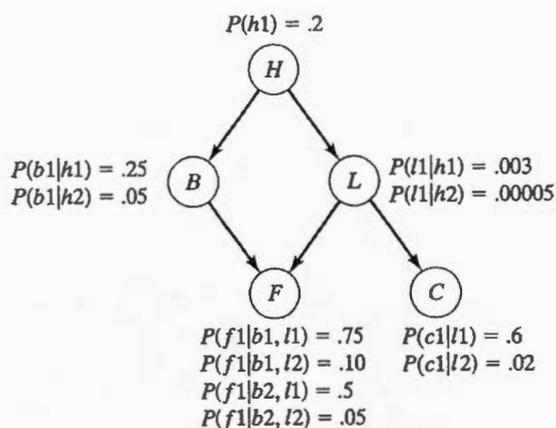


Figure 5.4 Exemple de réseau de connaissances Bayésien avec paramètres. (Tirée de Neapolitan, 2004.)

Une fois les valeurs assignées aux paramètres du réseau de connaissances, ce dernier est complet et prêt à l'inférence. Il existe plusieurs façons plus ou moins complexes de transmettre l'incertitude. Les cas les plus simples sont ceux où le sommet dont on cherche à connaître la distribution possède uniquement des enfants ou des parents. Dans ces deux situations, la distribution du sommet peut être directement inférée à l'aide du théorème de Bayes². Les choses se compliquent lorsqu'un sommet a des enfants et des parents, puisque ces deux sources d'information doivent être fusionnées pour déterminer la distribution a posteriori du sommet. Par exemple, si l'on cherche $P(B|l, h1)$ dans la Figure 5.4, l'information nécessaire à ce calcul ne se trouve pas dans le réseau. Il faut donc avoir recours à des algorithmes plus compliqués. Si le graphe est un arbre ou ne contient jamais plus d'une chaîne entre chaque paire de sommets (*singly connected*), l'algorithme de fusion propagation peut être utilisé (Neapolitan, 2004; Pearl, 1986, 1988, 2000). Cet algorithme est exact, conserve le caractère local du calcul Bayésien et sa complexité est proportionnelle à la longueur du plus long chemin dans le graphe. Lorsque plusieurs chaînes existent entre au

² Le cas limite est lorsqu'un sommet possède seulement des parents et que leur état est connu avec certitude. Alors, la distribution peut être directement lues dans le tableau de paramètres.

moins une paire de sommets (*multiply connected*), il n'existe, à notre connaissance, aucune solution exacte et locale au problème du calcul de l'incertitude. Heureusement, la modélisation des tâches en psychologie cognitive implique habituellement plusieurs sommets représentant des stimuli et un autre représentant la réponse (Kitzis et al., 1998; McClelland et Chappell, 1998; Movellan et McClelland, 2001; Shiffrin et Steyvers, 1997). La distribution devant être déterminée est celle de la réponse et le sommet la représentant possède uniquement des parents (les stimuli). Le théorème de Bayes est donc habituellement suffisant. Dans les cas où TELECAST serait utilisé pour effectuer des tâches de raisonnement plus complexes ou abstraites, l'algorithme de fusion propagation peut être directement implémenté sans aucune modification (pour un pseudo-code, voir Neapolitan, 2004).

Une fois l'incertitude propagée dans le réseau de connaissances Bayésien, la distribution inférée est transmise aux couches de sortie des champs récepteurs (transmission descendante). Si le stimulus présent dans un champ récepteur a précédemment été identifié avec certitude, la transmission descendante n'affectera pas le résultat de la compétition présente dans la couche de sortie, puisque le symbole correspondant au stimulus présenté aura une probabilité de 1. Par contre, si le stimulus n'a pas encore été présenté ou s'il n'a pas été identifié avec certitude, la propagation descendante peut affecter l'issue de la compétition entre les symboles.

5.4 Interaction synergique de l'information implicite et explicite

Selon le décathlon cognitif proposé par Sun (2004), il doit exister une interaction synergique entre les connaissances implicites et explicites. Dans TELECAST, cette interaction prend la forme d'attentes conscientes quant à la cooccurrence d'évènements. Par exemple, si le son d'une cloche précède habituellement une odeur de nourriture, les champs récepteurs olfactifs peuvent être sensibilisés par le son de la cloche. De même, une fois l'information se trouvant dans un champ récepteur de TELECAST identifiée, cette dernière peut se propager dans le module explicite et ainsi biaiser l'activation présente dans les autres couches de sorties. Plus précisément, l'interaction synergique dans TELECAST est décrite par:

$$\mathbf{y}_{[i, interaction]} = \psi \left[1 + \zeta P(\mathbf{y}_i \mid \prod_{j=1, j \neq i}^N y_j) \right] \mathbf{y}_i \quad 5.6$$

où $\mathbf{y}_{[i, interaction]}$ est le vecteur résultant de l'interaction synergique des activations ascendante et descendante, \mathbf{y}_i est le vecteur représentant l'activation ascendante (Éq. 5.1),

$P(\mathbf{y}_i \mid \prod_{j=1, j \neq i}^N y_j)$ est la distribution inférée par le module explicite, $0 < \psi \leq 1$ est un paramètre

attentionnel permettant de réduire l'activation en situation de multi-tâches et $0 \leq \zeta \leq 1$ est un paramètre pondérant l'apport des connaissances explicites dans la réponse finale. Le vecteur $\mathbf{y}_{[i, interaction]}$ joue exactement le même rôle que le vecteur de sorties précédant (Éq. 5.1). Ainsi, l'unité de sortie la plus active est choisie comme gagnante et son activation permet de déterminer son temps de réaction.

$$TR_i = a - b \text{Max}[\mathbf{y}_{[i]}] \quad 5.7$$

où $\mathbf{y}_{[i]}$ est le $i^{\text{ème}}$ vecteur de sortie (résultant de Éq. 5.1 ou Éq. 5.6), $b \geq 0$ est l'effet de l'activation des unités de sorties sur le temps de réaction, et $a \geq b \text{Max}[\mathbf{y}_{[i]}]$ est le temps de réponse maximum³. Suivant le calcul de TR_i , l'activation des unités gagnantes est fixée à un et celle des autres à zéro.

5.5 Apprentissage

L'apprentissage dans TELECAST se déroule *en ligne* (à chaque essai) à trois niveaux. Le premier type d'apprentissages est compétitif et se déroule dans la mémoire implicite. Les poids compétitifs sont initialisés avec des zéro, et ils empruntent directement la procédure d'apprentissage utilisée dans JPEX (Hélie et al., 2006_b):

$$\mathbf{w}_{[i, k, t+1]} = \mathbf{w}_{[i, k, t]} + \eta (\mathbf{x}_i - \mathbf{w}_{[i, k, t]}) \quad 5.8$$

où $0 \leq \eta \leq 1$ est un paramètre d'apprentissage général, et $\mathbf{w}_{[i, k, t]}$ est le vecteur de poids de connexions de l'unité gagnante (k) du $i^{\text{ème}}$ champ récepteur au temps t . À chaque essai, seulement le vecteur de poids de l'unité gagnante dans chaque réseau compétitif est mis à

³ Cette contrainte sur la valeur donnée à a assure que $TR_i \geq 0$.

jours. Pour plus détails, le lecteur peut se référer au Chapitre IV du présent document ou à Hélie et al. (2006_b).

Le second type d'apprentissages se déroule au niveau du tenseur associatif se trouvant dans le module implicite. La règle d'apprentissage est une généralisation de celle présente dans JPEX (Éq. 4.7). Elle est décrite par:

$$\mathbf{V}_{[t+1]} = \zeta \mathbf{V}_{[t]} + \bigotimes_{i=1}^N \mathbf{y}_i \quad 5.9$$

où $\mathbf{V}_{[t]}$ est le tenseur associatif au temps t , \mathbf{y}_i est le vecteur de sortie du $i^{\text{ème}}$ réseau compétitif (résultant de Éq. 5.1 ou Éq. 5.6), \otimes est le produit tensoriel usuel (Éq. 4.8), et $0 \leq \zeta \leq 1$ représente l'efficacité mnésique. Il est important de noter que le paramètre d'efficacité mnésique (Éq. 5.9) est aussi le paramètre pondérant l'effet des connaissances explicites dans la réponse finale (Éq. 5.6). Ainsi, il serait plus juste d'interpréter ζ comme un paramètre représentant la capacité d'un agent à construire et utiliser ses connaissances explicites (*awareness*).

Il a été expliqué dans le Chapitre IV que le contenu du tenseur représente l'estimation avec le maximum de vraisemblance (*Maximum Likelihood Estimation*) de la distribution conjointe des symboles inférés⁴. Comme cette représentation est contenue sous forme d'un tableau de contingences comprenant N dimensions, il est possible de l'utiliser pour construire un réseau Bayésien (Glymour et Cooper, 1999; Neapolitan, 2004). Il existe deux grandes familles de méthodes permettant la construction d'un réseau Bayésien à l'aide d'un tableau de contingences: les approches par contraintes (Spirtes, Glymour et Scheines, 1993) et les approches Bayésiennes (Cooper et Herskovits, 1992; Heckerman, 1995; Heckerman, Geiger, et Chickering, 1995; Heckerman, Meek, et Cooper, 1999). Pour fin d'implémentation dans TELECAST, une approche Bayésienne a été adoptée pour les raisons suivantes. D'abord, l'approche Bayésienne a l'avantage d'être calculée de façon locale, ce qui est important puisque la plausibilité psychologique doit être maintenue. Ensuite, l'efficacité de cette

⁴ Lorsque $\zeta = 1$. Pour $\zeta < 1$, les essais récents sont surreprésentés dans l'estimation de la distribution.

approche est monotone dans la taille de l'échantillon; plus la taille de l'échantillon est grande, mieux l'algorithme fonctionne. Cette seconde caractéristique peut sembler évidente, mais les approches par contraintes ne fonctionnent pas de façon monotone; un trop grand nombre de données résulte en trop de puissance statistique⁵. Finalement, le calcul utilisé par l'approche Bayésienne est du même type que celui permettant la transmission de l'incertitude dans un réseau de connaissances Bayésien. Ainsi, aucun axiome n'a été ajouté au modèle.

Dans l'approche Bayésienne, l'algorithme fait une recherche dans l'espace des graphes orientés acycliques afin de maximiser une mesure de désirabilité. Par exemple la vraisemblance du graphe G étant donné l'ensemble de données d est (Neapolitan, 2004):

$$\begin{aligned} score_B(d, G) &= \prod_{i=1}^N score_B(d, X_i, PA) \\ score_B(d, X_i, PA) &= \prod_{j=1}^q \frac{\Gamma(\omega/q)}{\Gamma(\omega/q + s_j)} \prod_{k=1}^{m_i} \frac{\Gamma(\omega/(qm_i) + s_{jk})}{\Gamma(\omega/(qm_i))} \end{aligned} \quad 5.10$$

où N est le nombre de sommets dans G ; X_i est un sommet de G (représentant la couche de sortie y_i); PA est l'ensemble des variables représentées par les parents de X_i ; q est le nombre d'états pouvant être prises par PA ; m_i est le nombre d'états de la variable représentée par X_i (le nombre d'unités dans la couche de sortie y_i); s_j est le nombre d'observations où PA est dans l'état j ; s_{jk} est le nombre d'observations où PA est dans l'état j et X_i est dans l'état k ; et $\omega > 0$ représente la sensibilité aux observations. Dans les faits, ω peut être interprété comme le nombre de cas rencontrés avant le début des observations. Ce nombre est distribué de façon uniforme à travers tous les états de PA et de X_i . Ainsi, si ω est grand par rapport à la taille de d , les observations auront peu de poids sur la vraisemblance de G . Par contre, si d est plus grand que ω , les données détermineront la vraisemblance de G . Dans les applications informatiques, où la taille de d est habituellement très grande, la valeur de ω n'affecte pratiquement pas la performance des algorithmes Bayésien. Par contre, lorsque l'apprentissage se fait en ligne, comme dans TELECAST, la valeur de ω doit être

⁵ Ce problème peut être théoriquement réglé en fixant la probabilité d'erreur de type II plutôt que celle de type I dans les tests d'indépendances, mais cette solution n'est pas viable, puisque le temps de calcul augmente de façon exponentielle.

soigneusement fixée afin d'éviter un comportement erratique en début d'apprentissage (lorsque la taille de d est très petite).

Il est important de noter que le score de désirabilité décrit par Éq. 5.10 peut être mis à jour de façon locale (i.e., en maximisant ce score à chaque sommet, le score du graphe est maximisé). Cette caractéristique est particulièrement importante dans un modèle psychologique. Dans le cas de TELECAST, $score_B$ est maximisé à l'aide d'un algorithme de recherche avare (*greedy search*) suggéré par Neapolitan (2004) et présenté dans le Tableau 5.1.

Tableau 5.1

Algorithme utilisé par TELECAST pour construire le réseau de connaissances Bayésien

-
1. Soit E un ensemble d'arcs (initialement vide); V un ensemble des sommets; et $G(V, E)$ le graphe ainsi formé.
 2. Exécuter:
 - a. Si la modification d'un arc (ajout, retrait, inversion) augmente $score_B$, sans créer un cycle, inclure la modification dans E .
 3. Tant que les modifications augmentent $score_B$.
-

Cet algorithme de recherche est complet dans l'espace des graphes orientés acycliques. Cependant, il peut se coincer dans des maximums locaux. Ce problème peut en partie être réglé en introduisant du bruit dans le système ou en fournissant un ordre des variables (Neapolitan, 2004).

Les paramètres du réseau de connaissances Bayésien peuvent être estimés à l'aide du tenseur associatif lorsque les parents de chaque sommet ont été choisis. Il suffit d'organiser les tableaux de paramètres des distributions de Dirichlet et de les normaliser (voir la Section 5.3 pour l'organisation des tableaux de paramètres). Si le besoin survient, les paramètres peuvent aussi être appris sans utiliser le tenseur associatif à l'aide d'un algorithme de rétropropagation (Cohen, Bronstein, et Cozman, 2001).

5.6 Conclusion

En résumé, TELECAST est une architecture hybride séparant de façon modulaire les connaissances implicites et explicites. Les premières sont modélisées à l'aide d'une nouvelle version de JPEX (Hélie et al., 2006_b), alors que les dernières le sont à l'aide d'un hypergraphe simple de connaissances Bayésien. TELECAST inclut une procédure permettant d'extraire les connaissances explicites à partir des connaissances implicites et une intégration synergique de l'information présente dans les deux modules. La plausibilité psychologique de ces deux procédures sera mise en évidence par les simulations présentées dans le chapitre suivant.

CHAPITRE VI

ÉVALUATION DE TELECAST

L'objectif principal de la présente thèse était de développer une nouvelle architecture cognitive capable d'expliquer l'apprentissage ascendant des connaissances explicites à partir des connaissances implicites (règles et symboles), de même que l'interaction entre ces deux types de connaissances dans la prise de décision. Aussi, l'architecture développée devait utiliser un modèle non-supervisé implémentant des représentations réellement sous-symboliques afin de modéliser les connaissances implicites, ainsi que des règles stochastiques pour modéliser les connaissances explicites. Un modèle implémentant ces contraintes a été développé au chapitre précédent: TELECAST. Dans ce chapitre, la plausibilité psychologique de TELECAST est mise à l'épreuve dans des tâches d'inférence causale (Steyvers et al., 2003) et d'apprentissage de séquences (Curran et Keele, 1993). Ces tâches ont été choisies puisqu'elles testent directement les critères cognitifs deux et trois du décathlon (Tableau 1.1: Sun, 2004): l'apprentissage ascendant et l'interaction synergique. Ces critères ont été identifiés comme les plus importants, car en plus d'être présents dans les données empiriques colligées en psychologie cognitive (voir le Chapitre 2), ils ont été mis de côté par toutes les autres architectures recensées (Anderson et al., 2004; Laird et al., 1987; Meyer et Kieras, 1997) sauf CLARION (Sun et al., 2001). Ainsi, le développement de TELECAST remplit un vide important laissé par les autres architectures cognitives.

6.1 Apprentissage ascendant des connaissances explicites

La présente tâche vise à montrer la plausibilité psychologique du processus d'apprentissage ascendant des connaissances explicites dans TELECAST.

6.1.1 Expérience et prédictions du modèle existant

Dans leur première expérience, Steyvers et ses collègues (2003) ont testé la capacité de participants humains à distinguer deux types de structures causales, soit la *cause commune* et l'*effet commun* (voir Figure 6.1). Ces deux structures sont statistiquement distinguables et les participants devaient les différencier par observation (sans intervention).

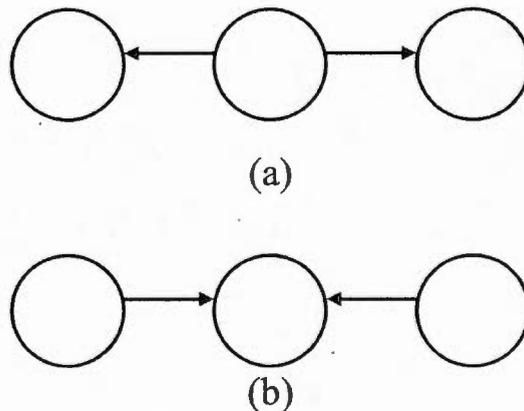


Figure 6.1 Structures causales à différencier dans la première expérience de Steyvers et al. (2003). (a) Cause commune. (b) Effet commun.

Pour ce faire, les participants voyaient trois extra-terrestres sur un écran d'ordinateur ainsi que leurs pensées (Figure 6.2). La pensée de chaque extra-terrestre est un trigramme et la taille (m) du vocabulaire est limitée. Aussi, les extra-terrestres possèdent des pouvoirs télépathiques leur permettant de contrôler les pensées des autres. À chaque essai, soit l'extra-terrestre du centre (C) tente de contrôler les pensées des deux autres (A et B); soit les deux autres (A et B) tentent de contrôler les pensées du premier (C). Le premier cas réfère à une structure de cause commune (Figure 6.1a), alors que le second réfère à une structure d'effet commun (Figure 6.1b). Dans tous les cas, la télépathie fonctionne avec une probabilité α et, si elle fonctionne, les deux extra-terrestres liés pensent au même trigramme. Si deux pouvoirs télépathiques fonctionnent simultanément (i.e., les extra-terrestres A et B réussissent à contrôler les pensées de C au cours d'un même essai), le hasard (uniforme) détermine qui copie ses pensées dans celles du contrôlé.



Figure 6.2 Exemple d'affichage. (Tirée de Steyvers et al., 2003.)

Cette structure d'expérience possède deux caractéristiques importantes. D'abord, la tâche est purement probabiliste. Deux extra-terrestres peuvent penser au même trigramme de façon purement aléatoire (sans qu'il n'existe de lien télépathique) avec une probabilité $1/m^2$. De même, un lien télépathique peut exister entre deux extra-terrestres même s'ils ne pensent pas au même trigramme (probabilité $1 - \alpha$). Aussi, seulement trois types d'essais permettent de distinguer les deux structures causales. Si $A = B = C$, la probabilité d'une cause commune augmente. Si $A = C$ et $B \neq C$ ou $B = C$ et $A \neq C$, la probabilité d'un effet commun augmente. Tous les autres patrons de pensées sont neutres quant à la structure les ayant générées. Ainsi, aucune information locale ne permet de distinguer les deux structures; il faut tenir compte des pensées des trois extra-terrestres simultanément pour les distinguer. Cette dernière caractéristique constitue un défi de taille pour un modèle psychologiquement plausible, puisque tous les calculs doivent être effectués de façon locale.

Après un court pré-test permettant de s'assurer qu'ils comprenaient le lien entre les graphes et les patrons de télépathie, quarante-sept participants ont reçu vingt blocs de pratique dans cette tâche. À chaque bloc, une structure causale était choisie de façon aléatoire (10 causes communes et 10 effets communs). À chaque bloc, huit essais étaient générés et présentés un à un aux participants. À chaque essai, le participant devait choisir la structure causale ayant le plus probablement généré les essais du bloc. Dans la présente expérience, dix trigrammes différents ont été utilisés ($m = 10$), et $\alpha = 0,80$. La variable dépendante était la proportion de réponses correctes.

Les résultats obtenus suggèrent la présence de trois types de participants: des participants optimaux (Bayesiens: $n = 8$), des participants sensibles aux évidences mais sans mémoire ($n = 18$) et des participants incapables d'effectuer la tâche ($n = 21$). Les résultats,

séparés par types sont présentés dans la Figure 6.3. Le panneau de gauche est probablement le plus informatif pour distinguer les trois types de participants. Les participants Bayésiens (triangles inversés) sont en mesure de calculer la vraisemblance des deux structures en fonction de l'information présente, tel que suggéré par leur bonne performance dès le premier essai. Ensuite, ils réussissent à intégrer l'information des essais précédant afin de préciser leur choix de structure (ils s'améliorent). Le second type de participants (triangles) est en mesure d'utiliser l'information présente à l'écran (ils performant bien dès le départ), mais ils sont incapable d'utiliser les essais précédant afin de préciser leur choix (ils sont amnésiques). Finalement, le troisième type de participants (cercles) n'arrive pas à distinguer les deux structures: leur performance est aléatoire du début à la fin.

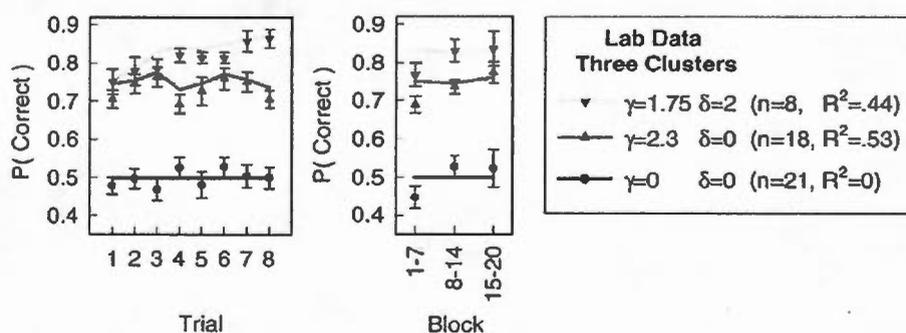


Figure 6.3 Résultats empiriques et prédictions du modèle. (Tirée de Steyvers et al., 2003.)

Steyvers et ses collègues (2003) expliquent ces résultats à l'aide d'un modèle simple: D'abord, les participants calculent à chaque essai le support accumulé au cours du présent bloc pour l'hypothèse de la cause commune:

$$\varphi = \sum_{t=1}^T \log \left[\frac{P(d_t | CC)}{P(d_t | EC)} \right] e^{-\frac{(T-t)}{\delta}} \quad 6.1$$

où $1 \leq T \leq 8$ est le numéro d'essai, $P(d_t | CC)$ est la vraisemblance de la structure cause commune étant donné l'information affichée à l'essai t , $P(d_t | EC)$ est la vraisemblance de la structure effet commun étant donné l'information affichée à l'essai t et $\delta > 0$ est un paramètre d'efficacité mnésique. Lorsque δ tend vers zéro, Éq. 6.1 reflète uniquement l'information présente à l'essai T , alors que quand δ tend vers l'infini, l'information des essais antérieurs

est intégrée. Il faut préciser que Éq. 6.1 émet le postulat fort que les participants connaissent le support objectif de chaque patron de résultats pour chacune des deux hypothèses.

Une fois le calcul de Éq. 6.1 terminé, le résultat est inséré dans une fonction sigmoïde et la structure la plus probable est choisie:

$$P(CC) = \frac{1}{1 + e^{-\gamma\phi}} \quad 6.2$$

où $\gamma \geq 0$ est un paramètre quantifiant la sensibilité du modèle aux données. Si $\gamma = 1$, $P(CC)$ représente directement la vraisemblance de cette structure étant donné l'information vue au cours du bloc (*probability matching*). Lorsque γ tend vers zéro, la décision devient aléatoire; lorsqu'il tend vers l'infini, la décision devient optimale.

Les deux paramètres libres du modèle proposé par Steyvers et al. (2003) permettent de représenter naturellement les trois types de participants (Figure 6.3, case de droite)¹. Lorsque δ et γ sont élevés, les participants intègrent l'information disponible à chaque essai du bloc et le critère de décision tend vers l'optimalité (Bayésien). Ces prédictions du modèle sont représentées par la ligne grise pale de la Figure 6.3. Par contre, si γ est élevé et δ tend vers zéro, le modèle est sensible aux données mais n'utilise pas l'information des essais précédant (second type de participants): les prédictions du modèle sont montrées par la ligne grise foncée. Finalement, si les deux paramètres tendent vers zéro, la décision est aléatoire, ce qui représente la performance des participants qui n'apprennent pas (ligne noire). Telles que vues, les prédictions du modèle (lignes pleines) représentent bien les données empiriques (symboles), peu importe que les données soient moyennées par bloc (case du centre) ou par essai (case de gauche). Cependant, ce modèle a été conçu spécifiquement pour modéliser cette tâche. Si TELECAST, qui est un modèle général, réussit à faire d'aussi bonnes prédictions, il sera jugé comme supérieur au modèle proposé par Steyvers et ses collègues (2003).

¹ Un seul ensemble de valeurs a été utilisé pour calculer les prédictions de chaque type de participants.

6.1.2 Prédications de TELECAST

Les stimuli utilisés pour modéliser cette tâche sont dix images analogiques représentant des trigrammes. Les trigrammes utilisés sont présentés à la Figure 6.4. Chaque image a été transformée en vecteur suite à l'application d'une grille 23×7 : ainsi, chaque stimulus était représenté par un vecteur binaire $\{-1, 1\}^{161}$.

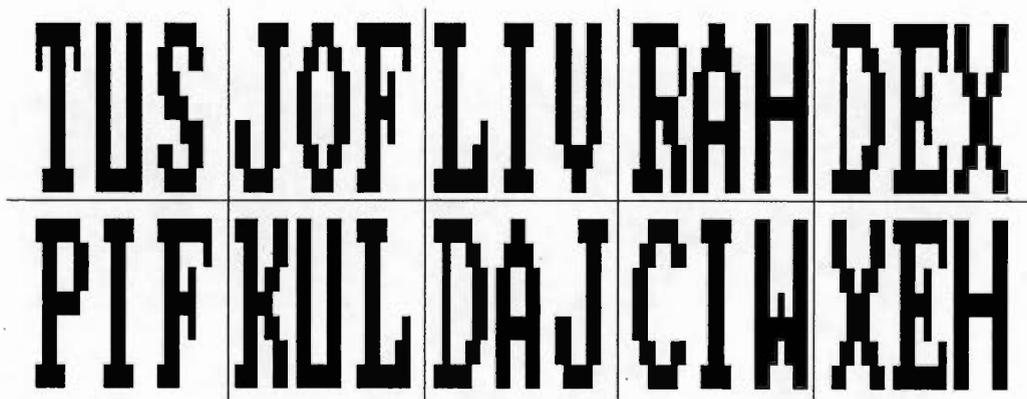


Figure 6.4 Stimuli utilisés pour simuler la tâche de Steyvers et al. (2003).

L'expérience était composée de vingt blocs. À chaque bloc, une structure causale (effet commun ou cause commune) était choisie aléatoirement, tout en s'assurant que la moitié des blocs soit associée à chacune des structures. Aussi, comme les participants savaient dès le début de l'expérience quel type de patrons chercher (suite au pré-test), les positions du tenseur associatif reflétant des évidences en faveur de l'une ou l'autre des deux structures (voir Section 6.1.1) ont été initialisées avec la valeur 1, alors que le reste des positions du tenseur ont été initialisées avec des 0. Cette insertion de traces mnésiques représente un amorçage de la structure en fonction de l'objectif visé (voir Section 5.2).

Chaque bloc était composé de huit essais. À chaque essai, trois trigrammes étaient choisis aléatoirement en fonction de la structure causale associée au bloc. Une fois choisis, les trigrammes étaient présentés simultanément dans trois champs récepteurs distincts². Ces stimuli étaient transmis à travers le module implicite de TELECAST afin d'activer les couches

² Comme l'information est transmise simultanément dans tous les champs récepteurs, il n'y a pas de transmission descendante modélisant les attentes.

de sorties (Éq. 5.1 et Éq. 5.2) et ainsi permettre l'apprentissage de la distribution conjointe des symboles développés par le modèle (Éq. 5.9). Comme $\rho = 0,55$, chaque trigramme crée une trace mnésique distincte dans chaque champ récepteur lors de sa première présentation ($m = 10$). À chaque essai, le modèle infère une structure causale à l'aide de l'algorithme contenu dans le Tableau 5.1. Cependant, comme l'expérience permet seulement deux réponses (*forced choice*), le modèle peut uniquement construire des causes communes et des effets communs. Ainsi, la structure maximisant Éq. 5.10 est choisie par TELECAST. À la fin de chaque bloc, le tenseur associatif est vidé et amorcé.

Les paramètres libres de TELECAST ainsi que leurs valeurs sont présentés dans le Tableau 6.1. Sept des neuf paramètres libres de TELECAST sont fixés en tenant compte uniquement de la tâche, alors que les deux autres permettent de représenter les différences individuelles. Les valeurs assignées aux paramètres libres n'ont pas été optimisées, mais ont été choisies afin de bien représenter les trois types de participants. Il est important de noter que les paramètres a et b n'ont pas été utilisés dans la présente simulation, puisque les temps de réponses n'ont pas été mesurés. De même, l'effet du paramètre ψ a été annulé en lui assignant la valeur 1, puisque cette tâche n'inclue pas de situations multi-tâches.

Les résultats obtenus avec les valeurs inscrites dans le Tableau 6.1, ainsi que les données empiriques, sont présentés dans la Figure 6.5. Clairement, les prédictions du modèle sont très près des données empiriques. La *racine de l'erreur quadratique moyenne (Root Mean Square Deviation)* est seulement 0,027 pour les participants optimaux ($\omega = 1,57$, $\zeta = 0,8$: ligne grise pale), 0,036 pour les participants sensibles aux données mais amnésiques ($\omega = 1,57$, $\zeta = 0,15$: ligne grise foncée) et 0,029 pour les participants qui n'apprennent pas ($\omega = 5$, $\zeta = 0,15$: ligne noire). De plus, en effectuant une simulation par participant, il a été possible de calculer les erreurs-types de chaque type de participants ($\alpha = .05$). Ainsi, le graphe suggère que les prédictions de TELECAST ne diffèrent pas significativement des données empiriques à l'exception d'un point: la moyenne des blocs un à sept dans la case de droite (groupe sensible aux données mais amnésique: ligne grise foncée). Une comparaison des prédictions de TELECAST avec celles du modèle proposé par Steyvers et ses collègues (2003, Figure 6.3) montre que le modèle de Steyvers ne réussit pas à prédire ce point non plus. Par contre, il est impossible de comparer l'erreur des deux modèles, puisque celle du modèle de Steyvers et

al. a été calculée à chaque essai (et non sur les statistiques descriptives). Toutefois, la performance qualitative des deux modèles est semblable.

Tableau 6.1
Paramètres libres utilisés dans TELECAST

<u>Paramètres</u>	<u>Type</u>	<u>Steyvers et al.</u> <u>(2003)</u>	<u>Curran et Keele</u> <u>(1993)</u>
N (Nb champs récepteurs)	Tâche	3	3
n (Nb unités par champ récepteur)	Tâche	161	217
η (Apprentissage, Éq. 5.8)	Tâche	0,2	0,2
ρ (Vigilance, Éq. 5.2)	Tâche	0,55	0,7
a (Temps de réponse, Éq. 5.7)	Tâche	-	1100
b (Temps de réponse, Éq. 5.7)	Tâche	-	2,74
Ψ (Attention, Éq. 5.6)	Tâche	1	{1; 0,8}
ω (Sensibilité, Éq. 5.10)	Tâche / Individuel	{1,57; 1,57; 5}	0,1
ζ (Awareness, Éq. 5.6 et Éq. 5.9)	Individuel	{0,8; 0,15; 0,15}	{1; 1; 0,77}

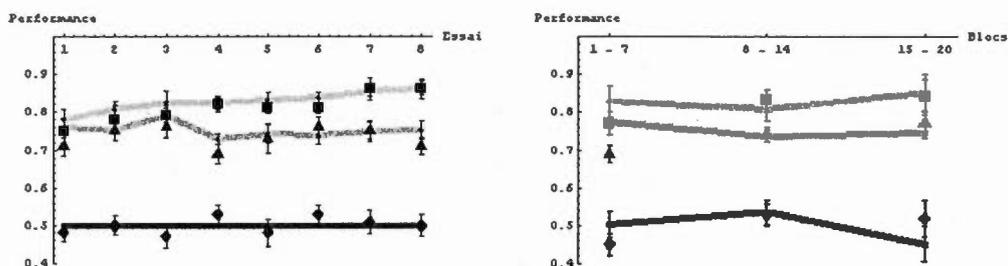


Figure 6.5 Résultats des simulations à l'aide de TELECAST.

6.1.3 Discussion

Les résultats obtenus à l'aide de TELECAST confirment la plausibilité psychologique du processus d'inférence de structures causales inclus dans le modèle. Les prédictions de TELECAST semblent se comparer avantageusement au modèle proposé par Steyvers et ses collègues (2003), bien que TELECAST ne soit pas un modèle construit spécifiquement pour expliquer cette tâche. Aussi, TELECAST explique le processus mnésique impliqué dans l'accumulation d'évidences d'un essai à l'autre à l'aide du tenseur associatif présent dans le module implicite (plutôt que de postuler la connaissance de probabilités objectives). Bien que TELECAST ait plus de paramètres libres que le modèle de Steyvers et al., seulement deux paramètres sont utilisés pour expliquer les différences individuelles: ζ et ω . Ce premier paramètre joue exactement le même rôle que δ dans le modèle de Steyvers et al.; il reflète la capacité des participants à intégrer l'information à travers les essais. Par contre, le rôle de ω diffère de celui de γ . Dans le modèle de Steyvers et al., la sensibilité aux données est modélisée par du bruit dans la fonction de décision (γ), alors que dans TELECAST la sensibilité aux données est liée directement au poids relatif des connaissances préalables à l'expérience (ω , qui suit une distribution uniforme). Dans le cas particulier de la présente expérience, la valeur donnée à ω doit être soigneusement choisie, puisque la structure effet commun possède beaucoup plus de paramètres libres que la cause commune³, ce qui biaise le modèle à choisir cette première structure.

³ Plus précisément, l'effet commun contient 918 paramètres libres alors que la cause commune en contient 189 (Éq. 5.5).

Maintenant que la plausibilité psychologique du processus d'inférence causale de TELECAST a été établie, celle de l'interaction entre les deux types de connaissances sera vérifiée dans la simulation qui suit.

6.2 Interaction des connaissances implicites et explicites dans une tâche d'apprentissage de séquences

Le but des présentes simulations est de montrer la plausibilité psychologique du processus d'interaction synergique inclus dans TELECAST à l'aide d'une tâche d'apprentissage de séquences incluant des phases d'attention divisée (Curran et Keele, 1993). Les résultats de TELECAST seront comparés à ceux obtenus à l'aide de CLARION (Sun et al., 2005) et du *Dual Simple Recurrent Network* (DSRN: Cleeremans, 1993).

6.2.1 Expérience

Dans l'expérience 1 de Curran et Keele (1993), deux tâches différentes sont utilisées: l'apprentissage de séquences et le décompte de tonalités. Dans la tâche d'apprentissage de séquences, une croix apparaît sur un écran d'ordinateur à l'une de quatre positions déterminées au préalable. La tâche du participant est simplement d'appuyer sur la touche du clavier associée à la position du stimulus. Le temps de réaction est alors enregistré et aucune rétroaction n'est fournie au participant. Par la suite, un nouveau stimulus est affiché. Dans la tâche de décompte de tonalités, un stimulus auditif est présenté à chaque essai. Ce stimulus peut être aigu ou grave. Les participants doivent compter le nombre de stimuli aigu et rapporter ce nombre à la fin de chaque bloc d'essais. Durant chaque bloc, entre 50% et 75% des stimuli auditifs sont aigus.

La structure de l'expérience est illustrée par la Figure 6.6. L'expérience est composée de douze blocs de 120 essais, pour un total de 1 440 essais. Ces douze blocs sont séparés en trois phases. Dans la phase de pratique (blocs un et deux), les participants effectuent de l'apprentissage de séquences aléatoires. Dans la seconde phase (blocs trois à huit), les participants effectuent de l'apprentissage de séquences prédéterminées (i.e., 1 – 2 – 3 – 2 – 4 – 3, excepté au bloc sept). Il est connu que lorsque les stimuli suivent une séquence prédéterminée, les temps de réponses diminuent, même si le participant n'est pas conscient de cette dernière (apprentissage implicite: Cleeremans, 1997; Cleeremans et al., 1998). Dans la

dernière phase (blocs neuf à douze), les participants doivent effectuer les deux tâches en même temps: l'apprentissage de séquences et le décompte de tonalités. Les phases sont séparées par des lignes verticales dans la Figure 6.6, et la lettre au-dessus de chaque numéro de bloc sert à identifier le type d'apprentissage de séquences. R indique que la séquence est aléatoire, alors que S indique que la séquence est prédéterminée. Finalement, deux groupes de participants ont été testés: le premier fut mis au courant de la séquence à apprendre entre la première et la deuxième phase (*intentionnel*), alors que le second n'a reçu aucune directive expérimentale (*implicite*).

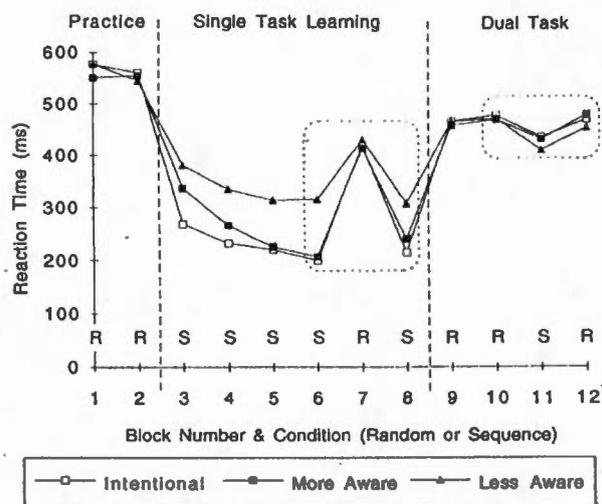


Figure 6.6 Structure et résultats de l'Expérience 1. (Tirée de Curran et Keele, 1993.)

La succession des phases dans cette expérience et l'utilisation de deux groupes distincts servent à tester plusieurs hypothèses. D'abord, comme aucune directive n'est donnée aux deux groupes avant le début de la première phase et que la séquence est purement aléatoire, la performance des deux groupes devrait être identique et les participants ne devraient pas s'améliorer (il n'y a rien à apprendre). Dans la seconde phase, les deux groupes devraient améliorer leur performance (apprendre la séquence de façon implicite), mais le groupe intentionnel devrait être meilleur que l'autre, puisque ce premier dispose de connaissances explicites liées à la séquence. Dans la troisième phase, les participants effectuent deux tâches simultanément, ce qui divise les ressources attentionnelles et réduit l'efficacité de l'utilisation des connaissances explicites. Ainsi, la différence entre les deux

groupes devrait disparaître. Cette expérience est donc parfaitement adaptée au besoin de tester l'interaction entre les connaissances implicites et explicites.

De façon opérationnelle, les connaissances de chaque participant, liées à la séquence, sont mesurées en utilisant la différence entre son temps de réponses médian durant un bloc dont les essais sont aléatoires et la moyenne des temps de réponses médians aux blocs précédant et suivant ce bloc aléatoire (ces derniers suivent une séquence prédéterminée)⁴. Dans la deuxième phase, il s'agit du temps de réponse médian au bloc sept moins la moyenne des temps de réponses médians des blocs six et huit (voir l'encadré dans la Figure 6.6). Le même procédé est utilisé dans la phase trois en utilisant la différence entre le temps de réponses médian au bloc onze et la moyenne de ceux aux blocs dix et douze⁵. Si les hypothèses mentionnées précédemment s'avèrent exactes, une analyse factorielle de la variance (ANOVA) Groupe (intentionnel; implicite) × Bloc (séquence aléatoire; séquence prédéterminée) devrait révéler une interaction statistiquement significative dans la phase deux (i.e., un groupe connaît mieux la séquence que l'autre). Ce surplus de connaissances devrait refléter les connaissances explicites du groupe intentionnel. Cependant, dans la phase trois, les connaissances explicites sont utilisées de façon moins efficace (à cause de l'attention divisée), et une analyse similaire devrait révéler une absence d'interaction (i.e., les deux groupes connaissent aussi bien la séquence).

Les résultats obtenus reflètent la performance de quarante-quatre participants: (14 intentionnels et 30 implicites). Entre la seconde et la troisième phase, un questionnaire a été distribué aux participants afin de tester leurs connaissances explicites de la séquence. Suivant les résultats au questionnaire, le groupe implicite a été divisé en deux sous-groupes: ceux pouvant écrire quatre éléments de la séquence ont été assigné au groupe *sensible* ($n = 19$),

⁴ L'utilisation de la moyenne des médianes des blocs précédant et suivant le bloc aléatoire permet d'écarter l'hypothèse selon laquelle le décretement de performance au bloc aléatoire est simplement dû à la fatigue.

⁵ Dans ce cas-ci, le bloc onze suit une séquence prédéterminée alors que les blocs dix et douze sont aléatoires. L'utilisation de la moyenne des médianes des blocs précédant et suivant le bloc dont la séquence est prédéterminée permet donc d'écarter l'hypothèse selon laquelle la diminution des temps de réponses au bloc onze résulte de l'apprentissage de la tâche de décompte de tonalités.

alors que les autres ont été assigné au groupe *insensible* ($n = 11$). Tous les participants du groupe intentionnel étaient en mesure de rappeler parfaitement la séquence.

Après avoir retiré les erreurs (moins de 5%), la médiane de chaque participant a été calculée à chaque bloc et les résultats individuels ont ensuite été moyennés par groupe afin de former la Figure 6.6. À première vue, la performance de tous les participants semble identique dans la première et la troisième phase, ce qui supporte les hypothèses de départs. Aussi, les groupes intentionnel (*intentional*) et sensible (*more aware*) semblent être meilleurs que le groupe insensible (*less aware*) dans la seconde phase, ce qui reflète l'utilisation des connaissances explicites. Ces observations furent confirmées à l'aide d'ANOVAs factorielles Groupe (intentionnel; sensible; insensible) \times Bloc (séquence aléatoire; séquence prédéterminée) dans les phases deux et trois. Dans la seconde phase, l'interaction des facteurs Groupe et Bloc était significative, indiquant que les groupes différaient quant à leur connaissance de la séquence. La présentation de stimuli suivant une séquence prédéterminée diminuait les temps de réponses de 210 ms pour le groupe intentionnel, 189 ms pour le groupe sensible, et 118 ms pour le groupe insensible. En ce qui concerne l'ANOVA sur les temps de réponses à la phase trois, seul le facteur Bloc a un effet significatif et l'interaction disparaît: ainsi, les connaissances liées à la séquence sont les mêmes pour tous les groupes lorsqu'ils doivent effectuer deux tâches simultanément, ce qui suggère que la différence dans la phase deux reflète uniquement l'apport des connaissances explicites.

Étant donné l'interaction complexe entre les deux types de connaissances dans l'Expérience 1 de Curran et Keele (1993), la reproduction de la Figure 6.6 est devenue un objectif pour les modèles hybrides incluant une dichotomie des connaissances explicites et implicites. Les résultats des modèles existants seront maintenant présentés.

6.2.2 Prédiction du DSRN

Le DSRN (Cleeremans, 1993) est un réseau récurrent simple (Elman, 1990), auquel un second réseau récurrent simple a été connecté pour servir de tampon (voir Figure 6.7). Le premier réseau récurrent (encadré SRN) permet l'apprentissage des connaissances implicites, alors que le second réseau (encadré BUFFER) sert à ajouter le stimulus suivant aux unités cachées du SRN, simulant ainsi les connaissances explicites liées à la séquence. Pour que le

second réseau (BUFFER) soit en mesure de fournir le stimulus suivant aux unités cachées du SRN, ce dernier est pré-entraîné sur la séquence. Le nombre d'essais de pré-entraînement permet d'illustrer le niveau de connaissances explicites, et du même coup la différence entre les groupes intentionnel, sensible et insensible. Pour modéliser la phase trois (double tâche), du bruit normalement distribué a été ajouté à la couche d'entrée du SRN et à la couche cachée du tampon. En tout, le modèle compte dix paramètres libres et les temps de réponses prédits sont une fonction linéaire de l'activité des unités de sorties.

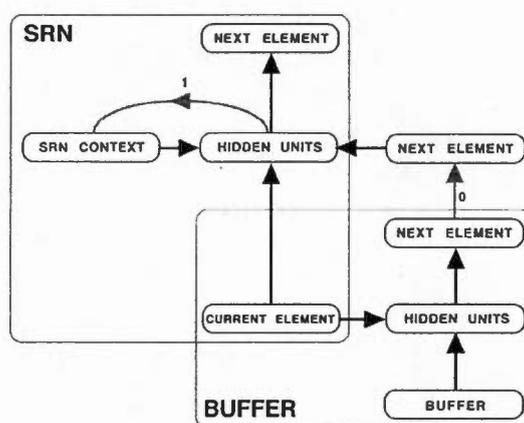


Figure 6.7 Architecture du DSRN. (Tirée de Cleeremans, 1993.)

Les temps de réponses prédits par le DSRN sont présentés à la Figure 6.8. Le modèle capture le patron général des résultats présentés à la Figure 6.6 et la racine de l'erreur quadratique moyenne est 79,4 ms (Sun et al., 2005). Cependant, plusieurs détails font défaut. Par exemple, le groupe sensible ressemble beaucoup plus au groupe insensible qu'au groupe intentionnel dans les simulations, alors que l'inverse est vrai des données empiriques. Aussi, la performance au bloc sept redevient aussi mauvaise qu'au départ, ce qui n'était pas le cas dans l'expérience de Curran et Keele (1993). Finalement, bien qu'il y ait clairement une interaction Groupe \times Bloc dans la phase deux de l'expérience, il n'est pas clair que cette interaction disparaît dans la troisième phase. Dans tous les cas, cette interprétation des résultats est purement spéculative, puisque qu'aucune analyse statistique n'a été effectuée sur les prédictions du DSRN. Finalement, le DSRN est un modèle entraîné par rétropropagation de l'erreur (alors que la tâche ne fournit pas de rétroaction) et la tâche de décompte de

tonalités n'a pas été modélisée. Bien que le DSRN soit un bon point de départ pour simuler l'Expérience 1 de Curran et Keele, la modélisation de la tâche est rudimentaire. Sun et ses collègues (2005) sont allés beaucoup plus loin dans la modélisation des subtilités de cette expérience.

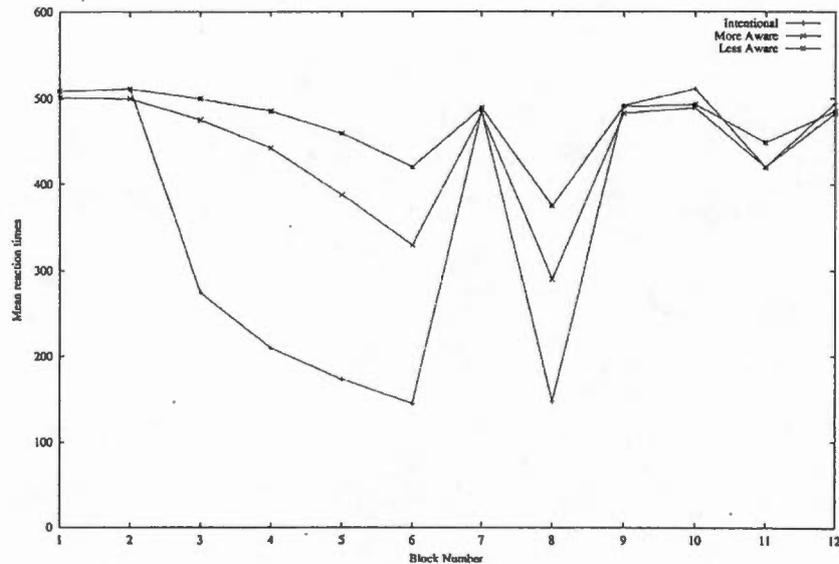


Figure 6.8 Résultats obtenus à l'aide du DSRN. (Tirée de Sun et al., 2005.)

6.2.3 Prédications de CLARION

L'architecture de CLARION est présentée à la Figure 1.1 et le fonctionnement du modèle a été détaillé dans la Section 1.4. Pour simuler l'Expérience 1 de Curran et Keele (1993), Sun et ses collègues (2005) utilisent un modèle CLARION composé de quarante-deux unités d'entrées et cinq unités de sorties. Les unités d'entrées forment une fenêtre mobile ayant accès au stimulus actuel, ainsi qu'à ceux des six derniers essais⁶. Ainsi, chaque stimulus utilise six unités: une par position possible (pour un total de quatre) et une par tonalité (pour un total de deux). Les quatre premières unités de sortie représentent les quatre positions possibles et la dernière unité est active uniquement lorsqu'un son aigu est présent.

⁶ Sept items sont disponibles à tous moments, ce qui selon Sun et ses collègues correspond à la taille de la mémoire de travail (Sun et al., 2005).

Le modèle est supervisé: les règles déclaratives peuvent être construites seulement si la réponse émise par CLARION est correcte. Les différences intergroupes ont été modélisées en changeant les valeurs données aux paramètres de seuils. Au cours des deux premières phases, le groupe intentionnel et le groupe sensible ont reçu les premières valeurs inscrites dans le Tableau 6.2, alors que le groupe insensible a reçu les deuxièmes. En situation double tâche (phase trois), les seuils de tous les groupes ont été changés pour les troisièmes valeurs du Tableau 6.2. Les directives expérimentales ont été modélisées en ajoutant des règles correspondant à la séquence dans le module déclaratif des participants du groupe intentionnel.

Tableau 6.2
Paramètres libres utilisés dans CLARION

<u>Paramètres</u>	<u>Valeurs</u>
γ	0,95
w	0,2
a	0,01
<i>seuilCons</i>	0,999
<i>seuilGen</i>	{3; 6; 6,5}
<i>seuilSpec</i>	{1; 1,5; 2}
Nb. Unités d'entrées	42
Nb. Unités de sorties	5
Nb. Unités cachées	20
Apprentissage	0,3
Momentum	0,15
a	600
b	100

Dix-neuf simulations par groupe ont été réalisées, modélisant dix-neuf participants par groupe. Les temps de réponses dans CLARION sont une fonction linéaire du taux d'erreurs:

$$TR_t = ae_t + b \quad 6.3$$

où TR_t est le temps de réponses au bloc t , e_t représente le taux d'erreurs au cours du bloc t , a est l'amplitude, et b est l'ordonnée à l'origine. Les résultats ainsi obtenus sont présentés dans la Figure 6.9.

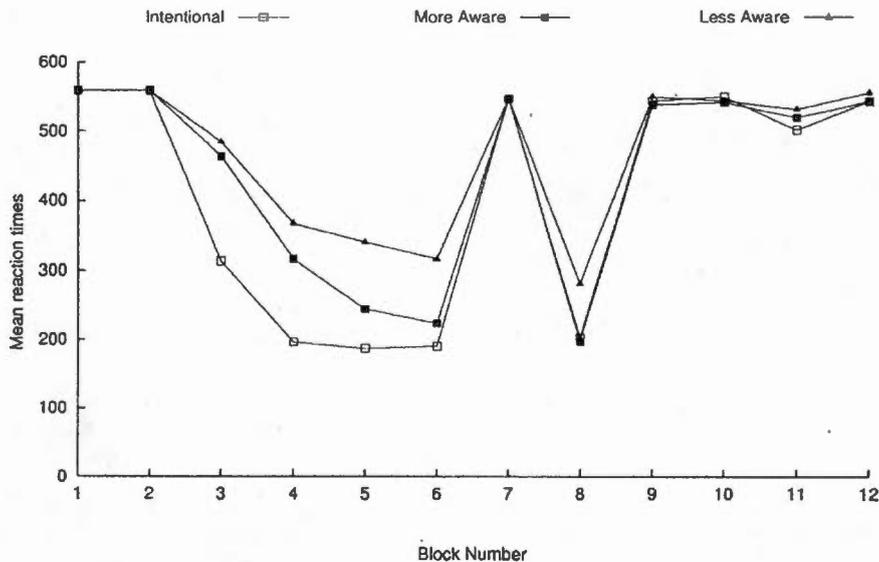


Figure 6.9 Résultats obtenus à l'aide de CLARION. (Tirée de Sun et al., 2005.)

Des comparaisons de la Figure 6.9 avec les Figures 6.6 et 6.8 suggèrent que les prédictions de CLARION sont beaucoup plus fidèles aux données empiriques que celles du DSRN (Cleeremans, 1993). La racine de l'erreur quadratique moyenne est de 73,1 ms. Au niveau qualitatif, le groupe sensible est beaucoup plus similaire au groupe intentionnel qu'au groupe insensible, reproduisant bien les données colligées. Par contre, comme celles du DSRN, les prédictions de CLARION au bloc sept sont identiques à la performance aux deux premiers blocs; la performance des participants humains ne se dégradait pas à ce point. Au niveau quantitatif, les mêmes analyses de variances ont été effectuées sur les prédictions de CLARION que sur les données empiriques. L'ANOVA sur les données de la phase deux montre une interaction significative des facteurs Groupe et Bloc, tel que trouvée par Curran et Keele. De plus, cette interaction disparaît dans les analyses effectuées sur la phase trois. Par

contre, il n'est pas mentionné si l'effet du facteur Bloc dans la phase trois est significatif, ce qui était le cas chez les participants humains.

Les simulations effectuées à l'aide de CLARION modélisent beaucoup plus soigneusement le paradigme proposé par Curran et Keele que les simulations effectuées par Cleeremans. Avec trois paramètres libres de plus (treize), les prédictions de CLARION approximent plus précisément les données empiriques, tout en modélisant la tâche de décompte de tonalités. Aussi, la correspondance des prédictions avec les données est confirmée par des analyses statistiques. Par contre, bien que la modélisation du paradigme de Curran et Keele faite par Sun et ses collègues soit supérieure à celle qui la précède, certains détails manquent. Par exemple, l'apprentissage des règles de CLARION est supervisé, alors que les participants ne recevaient pas de rétroaction dans l'expérience de Curran et Keele. Aussi, les taux d'erreurs semblent problématiques, même s'ils n'ont pas été rapportés. En se fiant à la Figure 6.9, les temps de réponses prédits par CLARION semblent varier entre 200 ms et 555 ms. Ainsi, selon Éq. 6.3, les taux d'erreurs doivent varier entre 16,6% et 75,8%. Dans tous les cas, le taux d'erreurs de CLARION est nettement supérieur à celui des participants humains (5%). Finalement, la modélisation des manipulations expérimentales à l'aide des seuils de modifications des connaissances explicites est élégante, mais son implémentation est trop simple pour modéliser la troisième phase. Dans la troisième phase, tous les participants arrêtent également d'utiliser leurs connaissances explicites (peu importe leur niveau de connaissances antérieur): un facteur multiplicatif du seuil existant serait probablement plus approprié (i.e., ψ dans TELECAST). Les simulations à l'aide de TELECAST tenteront d'améliorer les travaux novateurs effectués par Cleeremans et Sun et al.

6.2.4 Prédictions de TELECAST

Les stimuli utilisés dans la présente simulation sont sept images analogiques codées à l'aide de vecteurs en 217 dimensions (voir Figure 6.10). Les quatre stimuli du haut représentent les quatre positions dans l'apprentissage de séquences et ont été générés à l'aide de grilles 31×7 ; les vecteurs résultant étaient bipolaires $\{-1, 1\}^{217}$. Les trois stimuli de la seconde ligne représentent les stimuli auditifs présentés. Le premier représente l'absence de stimulation (phases un et deux), le second représente le stimulus grave, alors que le troisième

représente le stimulus aigu. Le stimulus grave a été généré en échantillonnant la fonction suivante à intervalle régulier [0, 120]:

$$g(t) = \text{Sin}(600\pi t) \quad 6.4$$

Le son aigu a été généré de la même façon, mais avec l'équation suivante:

$$a(t) = \text{Sin}(1800\pi t) \quad 6.5$$

Les stimuli ont été présentés trois à la fois à un modèle TELECAST composé de trois champs récepteurs: à un essai t , le premier champ récepteur recevait le stimulus visuel présenté à l'essai $t - 1$, le second recevait le stimulus visuel actuel (t), et le troisième recevait un stimulus auditif. Le stimulus présenté au premier champ récepteur pouvait donc servir à créer des attentes quant à celui qui sera présenté dans le deuxième (Éq. 5.6, si TELECAST a inféré un lien causal entre des deux champs récepteurs). Aussi, les relations de causalités devaient suivre un ordre temporel (i.e., une cause doit précéder son effet). Ainsi, l'algorithme présenté au Tableau 5.1 a été modifié afin de ne pas tester l'ajout d'arcs allant à l'encontre de ce principe⁷. La réponse du modèle à chaque essai est l'activité de la couche sortie du second champ récepteur. Le décompte des stimuli auditifs à la fin de chaque bloc de la phase trois est les paramètres de la distribution Dirichlet associée au troisième champ récepteur.

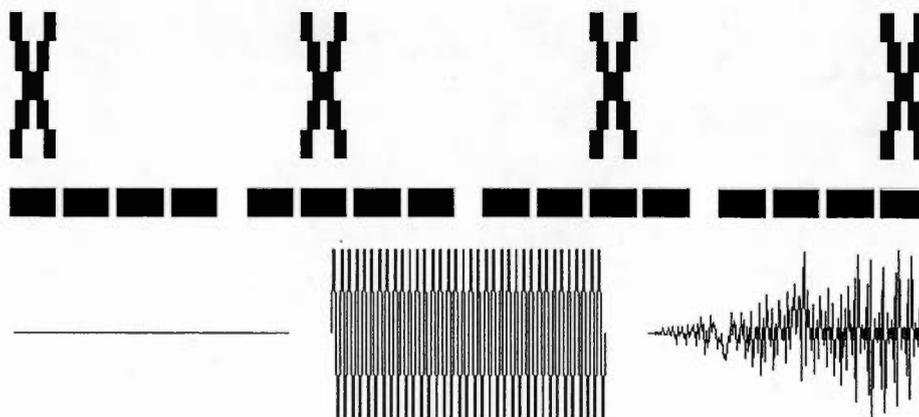


Figure 6.10 Stimuli utilisés pour simuler la tâche de Curran et Keele (1993).

⁷ Il est important de noter que l'ajout de cette contrainte à l'algorithme présenté au Tableau 5.1 le rend équivalent à l'algorithme K2 (Cooper et Herskovits, 1992).

Comme pour la collecte des données humaines, la simulation inclue douze blocs de 120 essais (pour un total de 1 440 essais). Une simulation différente a été faite pour chaque participant de l'expérience de Curran et Keele (1993): 14 intentionnels, 19 sensibles, et 11 insensibles. Entre la première et la seconde phase, les simulations du groupe intentionnel ont reçu des directives expérimentales: un arc a été ajouté entre les sommets du réseau de connaissances Bayésien représentant les premier et second champs récepteurs. Aussi, comme les participants humains avaient une minute pour étudier la séquence et que chaque essai durait environ 500 ms à ce stade de l'apprentissage, les simulations du groupe intentionnel ont reçu l'équivalent de vingt essais d'apprentissage sur la séquence afin d'estimer les paramètres du graphe représentant les connaissances explicites⁸. Comme les participants ne savaient pas quoi chercher au début de la phase un (ni même qu'il y avait une séquence), il était impossible d'amorcer le tenseur associatif à l'aide de traces mnésiques (comme dans la simulation précédente): le tenseur associatif a donc été initialisé avec des 1.⁹ Aussi, comme les participants n'étaient pas avertis des changements de séquences au cours de l'expérience (de prédéterminée à aléatoire et vice-versa), le tenseur n'est jamais vidé. Les différences intergroupes ont été modélisées à l'aide du paramètre ζ , et les valeurs données aux paramètres libres sont présentées dans le Tableau 6.1. Seules les valeurs données aux paramètres a et b ont été choisis afin de minimiser l'erreur quadratique. Les valeurs données aux autres paramètres n'ont pas été optimisées.

La valeur donnée au paramètre ρ permet à TELECAST créer un symbole par stimulus. Ainsi, $m = 4$ dans les deux premiers champs récepteurs et $m = 3$ dans le troisième. Comme dans l'analyse des données humaines, les erreurs du modèle ont été retirées (6,73%) et les médianes de chaque simulation à chaque bloc ont été moyennées. Les résultats ainsi obtenus sont présentés dans la Figure 6.11. Encore une fois, les prédictions de TELECAST sont très

⁸ Le chiffre vingt a été choisi de la façon suivante: une minute est équivalente à 60 000 ms, et $60\,000 / 500 = 120$ essais. Comme il y a six positions dans la séquence, $120 / 6 = 20$ présentations.

⁹ Puisque toutes les positions sont initialisées avec la même valeur, il n'y a pas d'amorçage. Au niveau de l'implémentation, la valeur un est préférée à la valeur zéro puisque le processus d'inférence de structures causales (Éq. 5.10) utilise la fonction $\Gamma(x)$, qui diverge lorsque x tend vers zéro.

similaires aux données colligées chez les participants humains (Figure 6.6): la racine de l'erreur quadratique moyenne est de 31,4 ms, améliorant les résultats obtenus précédemment d'un facteur de deux. Au niveau qualitatif, le groupe sensible est presque identique au groupe intentionnel, ce qui est en accord avec les données humaines: ils diffèrent uniquement au début de la deuxième phase. Au bloc trois, le groupe intentionnel est meilleur, car il connaît la séquence (suite aux directives expérimentales). Par la suite, la performance des deux groupes devient équivalente, puisqu'ils apprennent la séquence au même rythme ($\zeta = 1$). La performance du groupe insensible est plus lente que celle des deux autres groupes dans la deuxième phase, mettant en évidence l'absence de connaissances explicites efficaces ($\zeta = 0,77$). Dans la phase trois, la situation double tâche est modélisée en diminuant la valeur de ψ à 0,8. Ainsi, l'efficacité de l'interaction synergique diminue et les groupes deviennent tous équivalents.

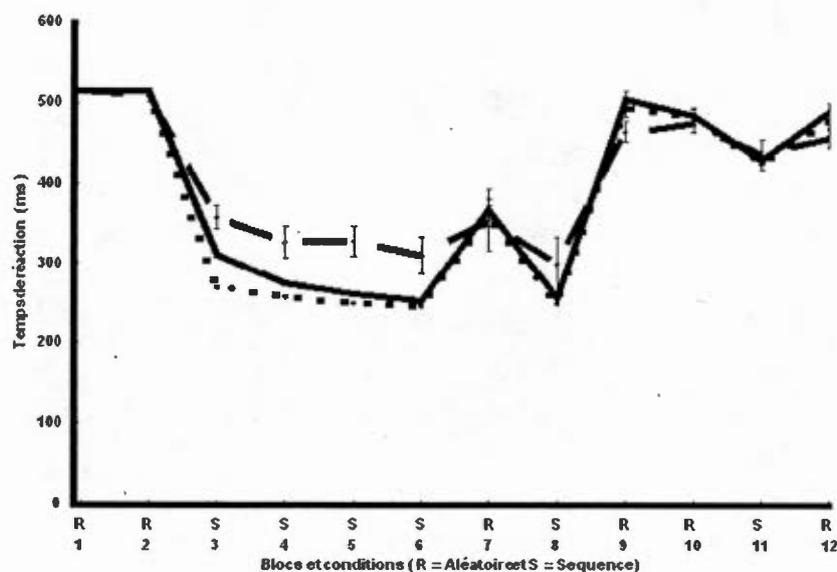


Figure 6.11 Prédictions de TELECAST dans la tâche de Curran et Keele (1993). La ligne discontinue représente le groupe insensible, la ligne pleine le groupe sensible, et la ligne pointillée le groupe intentionnel.

Au niveau quantitatif, des ANOVAs Groupe \times Bloc ont été effectuées dans les phases deux et trois. En ce qui concerne la phase deux, l'interaction Groupe \times Bloc est statistiquement significative ($F(2, 41) = 6,19, p < .01$). La quantité d'apprentissage a été évaluée à 50 ms pour le groupe insensible, 114 ms pour le groupe sensible, et 114 ms pour le

groupe intentionnel. Pour la phase trois, seul l'effet du facteur Bloc est significatif, comme ce fut le cas dans les données empiriques ($F(1, 41) = 86,76, p < .01$). Le temps de réponses moyen passait de 469 ms dans les blocs aléatoires à 419 ms dans le bloc incluant une séquence prédéterminée.

6.2.5 Discussion

Les simulations faites à l'aide de TELECAST confirment la plausibilité psychologique du processus d'intégration des connaissances implicites et explicites. Le paradigme de Curran et Keele (1993) a été modélisé de façon précise et tous les effets qualitatifs et quantitatifs présents chez les participants humains sont présents à une exception près. La performance de TELECAST se détériore moins au bloc sept que celles des participants humains. Pour les autres modèles, l'effet contraire était trouvé (i.e., la performance des modèles se détériorait trop). Cette sous-estimation du décrement de performance est purement quantitative et pourrait probablement être réglée si l'on permettait au paramètre ζ de prendre des valeurs plus grandes que 1 ou si la valeur donnée à b était augmentée.

Malgré le plus grand nombre de contraintes imposées par une modélisation plus granulaire du paradigme de Curran et Keele, TELECAST reproduit les données humaines avec une erreur deux fois plus petite que celles des modèles proposés par Cleeremans (1993) et Sun et al., tout en réduisant le nombre de paramètres libres (neuf). Il est intéressant de noter que la majorité des participants insensibles modélisés par TELECAST réalisent qu'il y a un lien entre les différents items de la séquence (i.e., 9 / 11 ont inféré un lien causal entre les sommets représentant le premier et le second champ récepteur). La différence se situe au niveau de l'estimation des paramètres de la distribution qui sur-représente les essais récents. Aussi, aucun des participants, peu importe le groupe d'appartenance, n'a inféré un lien causal entre le troisième champ récepteur (le stimulus auditif) et les deux autres. Tous les participants des groupes intentionnel et sensible ont correctement inféré la structure causale de la tâche.

6.3 Conclusion

Dans le présent chapitre, la plausibilité psychologique de TELECAST a été mise à l'épreuve à l'aide de deux tâches empiriques qui ont permis de tester le processus

d'apprentissage ascendant des connaissances explicites (Steyvers et al., 2003), ainsi que l'interaction de ces dernières avec les connaissances implicites dans le processus décisionnel (Curran et Keele, 1993). Bien que TELECAST n'ait pas été conçu spécifiquement pour modéliser la tâche d'inférence causale de Steyvers et ses collègues, sa performance semble se comparer avantageusement avec celle du modèle qu'ils ont proposé (qui lui est spécifique). Au niveau de l'interaction synergique, TELECAST permet de modéliser plus adéquatement la tâche proposée par Curran et Keele que les modèles qui le précède. Aussi, les prédictions faites par TELECAST sont plus près des données humaines que celles faites par CLARION (Sun et al., 2005) ou le DSRN (Cleeremans, 1993). Bien que la modélisation de ces tâches ne constitue qu'un premier pas dans la validation du modèle proposé, les résultats sont encourageants, et d'autres tâches seront modélisées dans un futur rapproché.

CONCLUSION

L'objectif de la présente thèse était de proposer une nouvelle architecture cognitive capable d'expliquer l'apprentissage ascendant des connaissances explicites, ainsi que l'interaction synergique liée au traitement simultané des connaissances explicites et implicites. Ces contraintes théoriques couvrent l'ensemble des critères cognitifs suggérés par le décathlon cognitif (Sun, 2004; Section 1.2). Jusqu'à maintenant, seul CLARION (Sun et Peterson, 1998_a, 1998_b; Sun et al., 2001) était en mesure de remplir ces critères. Cependant, CLARION souffre de deux faiblesses théoriques ainsi que de deux erreurs d'implémentation, qui ont été explicitées afin de les éviter dans la présente thèse (voir la Section 1.5). Il est important de noter que depuis le début des présents travaux, de nouveaux développements ont été ajoutés dans CLARION (Sun et Zhang, 2006; Sun, Zhang, et Mathews, 2006). CLARION inclus maintenant un module motivationnel ainsi qu'un module méta-cognitif. Aussi, l'information dans CLARION passe maintenant nécessairement pas le module procédural avant d'atteindre le module déclaratif, comme c'est le cas dans TELECAST (ce qui n'était pas le cas dans les versions précédentes de CLARION). Aussi, Sun a identifié et réglé les deux problèmes du module déclaratif mis en évidence dans le présent document: les règles déclaratives sont maintenant stochastiques, et les propositions sont apprises à partir de l'information présente dans le module procédural. Par contre, les problèmes du module procédural demeurent, ce qui distingue TELECAST de CLARION 5.0 (Sun, 2003).

Suite à une série de simulations ayant permise d'établir la capacité des mémoires associatives à effectuer une estimation de densité (Hélie et al., 2006_a; Chapitre III), JPEX (Hélie et al., 2006_b; Chapitre IV) a été créé afin de modéliser les connaissances implicites incluses dans l'architecture proposée. JPEX est un nouveau réseau connexionniste sous-symbolique, non-supervisé, capable de construire des symboles (représentant les états de l'environnement) et d'apprendre leur distribution conjointe. L'avantage de JPEX sur les mémoires associatives bidirectionnelles qui l'ont précédé (i.e., Humpert, 1990; Kosko, 1988) est qu'il utilise un tenseur de poids de connexions, plutôt qu'une matrice. L'utilisation du

tenseur permet de structurer la mémoire (Smolensky et Legendre, 2006), et du même coup de construire un réseau de connaissances Bayésien (Neapolitan, 2004; Pearl, 1988, 2000). Le modèle construit est par la suite utilisé pour modéliser les connaissances explicites (voir Chapitre II). Dans le réseau de connaissances Bayésien, l'incertitude liée aux règles causales représentées est propagée et l'inférence Bayésienne est utilisée pour modéliser les attentes conscientes lorsque le modèle se trouve en situation connue (interaction synergique).

Le modèle résultant s'appelle TELECAST (voir Chapitre V). La plausibilité psychologique du modèle proposé a été établie en modélisant une tâche d'inférence causale (Steyvers et al., 2003) ainsi qu'une tâche d'apprentissage de séquences (Curran et Keele, 1993). La performance de TELECAST est aussi bonne que celle d'un modèle spécifique à la tâche d'inférence causale, et meilleure que celles des modèles le précédant (Cleeremans, 1993; Sun et al., 2005) dans la tâche d'apprentissage de séquences (Chapitre VI). Au-delà de la capacité de TELECAST à prédire les données humaines, la plausibilité psychologique du modèle est consolidée par les processus de transmission d'information et d'apprentissage utilisés. D'abord, tout l'apprentissage se fait de façon non-supervisée et, si l'apprentissage hétéro-associatif est utilisé, la rétroaction est modélisée à l'aide d'un champ récepteur additionnel (pas un homoncule caché). Dans les faits, TELECAST apprend les contingences, peu importe que ce soit entre différents stimuli ou entre un stimulus et une réponse. Ces contingences sont apprises à l'aide d'une règle qui généralise l'apprentissage Hebbien dont la plausibilité psychologique n'est plus à refaire (Proulx et Hélie, 2005). Au niveau explicite, l'inférence de la structure causale, l'estimation des paramètres, ainsi que le calcul de l'incertitude se font tous de façon locale.

La comparaison de TELECAST avec les autres architectures cognitives à l'aide du test de Newell (Anderson et Lebiere, 2003) et du décathlon cognitif proposé par Sun confirme son potentiel. Au niveau du test de Newell, TELECAST se distingue surtout aux niveaux général et cognitif. Au niveau général, le paramètre permettant d'inférer et d'utiliser les connaissances explicites (ζ) peut être ajusté afin de modéliser différents stades de l'évolution. Aussi, TELECAST modélise bien le développement d'un organisme puisqu'il est en mesure de se construire et de se complexifier suite au développement cognitif de l'agent modélisé. Aussi, le caractère Bayésien du module explicite rend le modèle rationnel; seule la

plausibilité biologique n'a pas été étudiée, puisque TELECAST représente une explication psychologique (fonctionnelle) du comportement. Au niveau cognitif, l'architecture proposée inclut plusieurs types de connaissances, apprend de son environnement et est flexible. Par exemple, l'utilisation d'un tenseur permet d'effectuer des opérations symboliques structurées (Smolensky et Legendre, 2006). Par contre, TELECAST est implémenté à l'aide de réseaux connexionnistes et ne dispose donc pas d'une base de connaissances indépendante¹. Finalement, TELECAST a plus de difficulté à rencontrer les critères comportementaux. Seul le dynamisme a été expliqué par les nombreux algorithmes d'apprentissage présents. La contrainte de temps réel a été rapidement abordée en mettant en place une procédure permettant d'émettre des temps de réponses mais, dans sa version actuelle, TELECAST est incapable d'utiliser un langage naturel ou de faire preuve de méta-cognition.

Tout comme dans le test de Newell, la force de TELECAST se situe surtout aux niveaux général et cognitif dans le décathlon cognitif (Sun, 2004). D'abord, tous les critères cognitifs sont représentés avec succès dans le présent modèle, puisqu'il s'agissait de l'objectif principal de la présente thèse. Ainsi, il existe une dichotomie entre les connaissances explicites et implicites et elles se trouvent dans des modules différents. De plus, les connaissances explicites sont apprises de façon ascendante à partir des connaissances implicites et les deux types de connaissances interagissent de façon synergique. Au niveau général, l'architecture proposée est en mesure de reproduire le caractère qualitatif des données humaines et des tâches simples ont été modélisées avec succès. De plus, le réalisme évolutif est bien représenté par le paramètre ζ . Par contre, l'éclectisme méthodologique a été peu exploré; des travaux futurs permettront de le faire. En contraste, la plus grande faiblesse de TELECAST se situe au niveau comportemental des critères de Sun: le caractère routinier de l'activité humaine n'est pas représenté (chunking, apprentissage descendant). Cette opération devra être éventuellement ajoutée dans TELECAST afin de modéliser l'automatisation des compétences (Logan, 1988). Cependant, l'adaptation essai-erreur est incluse dans le modèle, puisque tout l'apprentissage se fait en ligne. Ce critère est le seul critère comportemental rencontré par TELECAST.

¹ Comme ACT-R, SOAR, et EPIC, qui sont des systèmes de production.

Bien que l'évaluation de TELECAST à l'aide des critères d'évaluation des architectures cognitives soit prometteuse, l'élégance computationnelle du modèle a été atteinte au coût d'une certaine perte de généralité. Par exemple, les symboles appris par TELECAST sont essentiellement perceptuels et réfèrent au niveau conceptuel de Gärdenfors (2000). Ainsi, la géométrie résultante ne permet pas un agencement arbitraire des symboles qui permettrait éventuellement d'effectuer un raisonnement plus abstrait. Un arrangement hiérarchique de plusieurs modèles (i.e., la sortie de TELECAST sert d'entrée à un autre TELECAST) permettrait probablement d'atteindre un certain niveau d'abstraction mais la modélisation du niveau symbolique de Gärdenfors nécessite une plus grande puissance représentationnelle, incluant entre autres des prédicats. L'ajout de prédicats permettrait également de représenter des connaissances explicites autres que celles liées à la causalité.

Finalement, une dernière caractéristique de TELECAST, qui confirme son utilité comme outil de recherche, concerne les prédictions faites par le modèle. Celles-ci suggèrent plusieurs pistes de recherches tant au niveau formel qu'au niveau empirique. Par exemple, l'architecture de TELECAST prédit que les participants humains enregistrent de façon implicite les probabilités conjointes (le tenseur de JPEX), mais ont uniquement accès aux probabilités conditionnelles (paramètres du réseau de connaissances Bayésien). Ainsi, la performance des participants devrait refléter ces deux types de probabilités, mais seulement les dernières seraient disponibles pour fin de rapport verbal. Cette prédiction forte suggère une expérience empirique qui pourrait permettre de faire de l'ordre dans les résultats (souvent contradictoires) liés à l'apprentissage des probabilités (Wasserman, 1990). De plus, les résultats présentés à la Section 6.2 suggèrent que, lorsque l'attention des participants est détournée et que leurs capacités de construction et d'utilisation des connaissances explicites sont réduites, les participants induisent tout de même la structure causale de l'environnement: ce sont les connaissances liées aux paramètres (probabilités conditionnelles) qui sont déficientes. Au niveau théorique, il fut argumenté que l'implémentation des représentations symboliques et sous-symboliques (Smolensky, 1988) devait différer de façon qualitative. Dans TELECAST, cette différence est un changement de métrique (de $L2$ vers $L1$). Cependant, toutes les métriques sont équivalentes au niveau topologique (Anthony, 2003). Ainsi, des travaux futurs pourraient permettre de distinguer ces deux types de représentations au niveau topologique, en passant d'une topologie métrique (sous-symboles) à une topologie

non-métrique (symboles). Finalement, TELECAST n'est qu'une implémentation possible de la théorie unificatrice présentée au Chapitre II. Ainsi, d'autres modèles hybrides peuvent être construits afin d'expérimenter, par exemple, avec des modèles neuro-floux (Hélie, Chartier, et Proulx, 2004; Jang, 1993).

APPENDICE A

DÉMONSTRATION DU BIAIS DE ART1

La présentation de vecteurs aléatoires à un modèle ART1 (Carpenter et Grossberg, 1987) est similaire au problème de l'urne présenté dans les volumes d'introduction aux probabilités (i.e., Ross, 1998). Dans le problème de l'urne, n tirages sont effectués dans une urne contenant N boules. Plus exactement, m boules sont blanches, alors que le reste ($N - m$) sont noires. La variable d'intérêt est le nombre de boules blanches tirées lors des tirages (X). Il est bien connu que X suit une distribution hypergéométrique:

$$P(X = i) = \frac{\binom{m}{i} \binom{N-m}{n-i}}{\binom{N}{n}} \quad \text{A.1}$$

Dans les présentes simulations, le nombre d'éléments formant un stimulus représente le nombre de boules dans l'urne (N), le nombre de tirages est équivalent au nombre de positions contenant une valeur non-nulle dans **F1** (n), et le nombre de boules blanches correspond au nombre de valeurs non-nulles dans le vecteur de poids de connexions (m). Comme **F1** est une version binaire du stimulus aléatoire (voir Tableau 3.4), n suit une distribution binomiale de paramètres ($N, 1/2$). Ainsi, l'espérance de l'activation d'une unité de sortie a est décrite par:

$$E(a) = \frac{L}{L-1+m} \left(\frac{1}{2}\right)^N \sum_{n=0}^N \binom{N}{n} \sum_{i=0}^n \frac{\binom{m}{i} \binom{N-m}{n-i}}{\binom{N}{n}} i \quad \text{A.2}$$

où $L = 45$ et $N = 256$ dans les simulations (Section 3.2). Cette équation montre que l'activation d'une unité de sortie est une fonction non-linéaire, positive, et monotone de m . Comme $m = \{59, 50, 32\}$ pour les catégories un, zéro, et sept respectivement, l'espérance de l'activation de la catégorie un (12,89) est plus grande que celle de la catégorie zéro (11,97), qui elle-même est plus grande que celle de la catégorie sept (9,47). Comme ART1 est un modèle compétitif, l'unité la plus active est toujours choisie, ce qui explique le biais présent dans le modèle.

RÉFÉRENCES

- Agresti, A. (1990). *Categorical Data Analysis*. New York: Wiley.
- Ahn, W.-K., Kalish, C.W., Medin, D.L., et Gelman, S.A. (1995). The role of covariation versus mechanism information in causal attribution. *Cognition*, *54*, 299-352.
- Allen, S.W. et Brooks, L.R. (1991). Specializing the operation of an explicit rule. *Journal of Experimental Psychology: General*, *120*, 3-19.
- Anderson, J.A., Silverstein, J.W., Ritz, S.A., et Jones, R.S. (1977). Distinctive features, categorical perception, and probability learning: Applications of a neural model. *Psychological Review*, *84*, 413-451.
- Anderson, J.R. (1983). *The Architecture of Cognition*. Cambridge, MA: Harvard University Press.
- Anderson, J.R. (1990). *The Adaptive Character of Thought*. Hillsdale, NJ: Lawrence Erlbaum Associates.
- Anderson, J.R. (1991). The adaptive nature of human categorization. *Psychological Review*, *98*, 409-429.
- Anderson, J.R., Bothell, D., Byrne, M.D., Douglass, S., Lebiere, C., et Qin, Y. (2004). An integrated theory of the mind. *Psychological Review*, *111*, 1036-1060.
- Anderson, J.R. et Lebiere, C. (2003). The Newell test for a theory of cognition. *Behavioral and Brain Sciences*, *26*, 587-640.
- Anthony, M. (2003). Introduction to topology. *Notes de Lecture*, London School of Economics and Political Science.
- Ashby, F.G. et Gott, R.E. (1988). Decision rules in the perception and categorization of multidimensional stimuli. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, *14*, 33-53.
- Ashby, F.G. et Maddox, W.T. (1992). Complex decision rules in categorization: Contrasting novice and experienced performance. *Journal of Experimental Psychology: Human Perception and Performance*, *18*, 50-71.
- Barlow, H.B. (1989). Unsupervised learning. *Neural Computation*, *1*, 295-311.
- Berge, C. (1970). *Graphes et Hypergraphes*. Paris, FR: Dunod.

- Berry, D.C. et Broadbent, D.E. (1988). Interactive tasks and the implicit – explicit distinction. *British Journal of Psychology*, 79, 251-272.
- Bolen, K.A. et Ting, K.-F. (1993). Confirmatory tetrad analysis. *Sociological Methodology*, 23, 147-175.
- Carpenter, G.A. et Grossberg, S. (1987). A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*, 37, 54-115.
- Chartier, S. (2004). *Un Nouveau Modèle de Réseaux de Neurones Artificiels à Attracteurs dans le Cadre de la Catégorisation Autonome*. Thèse Doctorale, Université du Québec À Montréal, Montréal, CA.
- Chartier, S., Hélie, S., Proulx, R., et Boukadoum, M. (2006). Vigilance procedure generalization for recurrent associative memories. Dans R. Sun et N. Miyake (Éds.) *Proceedings of the 28th Annual Meeting of the Cognitive Science Society* (p. 2458). Mahwah, NJ: Lawrence Erlbaum Associates.
- Chartier, S. et Proulx, R. (2005). NDRAM: Non-linear Dynamic Recurrent Associative Memory for learning bipolar and non-bipolar correlated patterns. *IEEE Transactions on Neural Networks*, 16, 1393-1400.
- Cheng, P.W. et Holyoak, K.J. (1995). Complex adaptive systems as intuitive statisticians: Causality, contingency, and prediction. Dans H.L. Roitblat et J.-A. Meyer (Éds.) *Comparative Approaches to Cognitive Sciences* (pp. 271-302). Cambridge, MA: MIT Press.
- Chin-Parker, S. et Ross, B.H. (2002). The effect of category learning on sensitivity to within-category correlations. *Memory & Cognition*, 30, 353-362.
- Cleeremans, A. (1993). Attention and awareness in sequence learning. Dans *Proceedings of the 15th Annual Meeting of the Cognitive Science Society* (pp. 330-335). Hillsdale, NJ: Lawrence Erlbaum Associates.
- Cleeremans, A. (1997). Principles for implicit learning. Dans D. Berry (Éd.) *How Implicit is Implicit Learning* (pp. 196-234). Oxford: Oxford University Press.
- Cleeremans, A., Destrebecqz, A., et Boyer, M. (1998). Implicit learning: News from the front. *Trends in Cognitive Sciences*, 2, 406-416.
- Cohen, I., Bronstein, A., et Cozman, F.G. (2001). Adaptive online learning of Bayesian network parameters. *Rapport Technique HPL-2001-156*, HP Laboratories.
- Cooper, G.F. et Herskovits, E. (1992). A Bayesian method for the induction of probabilistic networks from data. *Machine Learning*, 9, 309-347.

- Cosmides, L. et Tooby, J. (1996). Are humans good intuitive statisticians after all? Rethinking some conclusions from the literature on judgment under uncertainty. *Cognition*, 58, 1-73.
- Cousineau, D. (2005). Learning of an XOR problem in the presence of noise and redundancy. *Proceedings of the International Joint Conference on Neural Networks*. Montréal, QC: IEEE Press.
- Curran, T. et Keele, S.W. (1993). Attentional and nonattentional forms of sequence learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 19, 189-202.
- Diamantaras, K.I. et Kung, S.Y. (1996). *Principal Component Neural Networks: Theory and Applications*. New York: John Wiley & Sons.
- Dienes, Z. et Berry, D. (1997). Implicit learning: Below the subjective threshold. *Psychonomic Bulletin and Review*, 4, 3-23.
- Dienes, Z. et Perner, J. (1996). Implicit knowledge in people and connectionist networks. Dans G. Underwood (Éd.) *Implicit Cognition* (pp. 227-255). New York: Oxford University Press.
- Dienes, Z. et Perner, J. (1999). A theory of implicit and explicit knowledge. *Behavioral and Brain Sciences*, 22, 735-808.
- Elman, J.L. (1990). Finding structure in time. *Cognitive Science*, 14, 179-211.
- Estes, W.K. (1976). The cognitive side of probability learning. *Psychological Review*, 83, 37-64.
- Evans, J.B.T., Clibbens, J., Cattani, A., Harris, A., et Dennis, I. (2003). Explicit and implicit processes in multicue judgment. *Memory & Cognition*, 31, 608-618.
- Fodor, J.A. (1983). *The Modularity of the Mind*. Cambridge, MA: MIT Press.
- Fodor, J.A. (2000). *The Mind Doesn't Work That Way*. Cambridge, MA: MIT Press.
- Gärdenfors, P. (2000). *Conceptual Spaces: The Geometry of Thoughts*. Cambridge, MA: MIT Press.
- Geman, S., Bienenstock, E., et Doursat, R. (1992). Neural networks and the bias/variance dilemma. *Neural Computation*, 4, 1-58.
- Gigerenzer, G. et Hoffrage, U. (1995). How to improve Bayesian reasoning without instructions: Frequency formats. *Psychological Review*, 102, 684-704.
- Glymour, C. et Cooper, G.F. (1999). *Computation, Causation, & Discovery*. Menlo Park, CA: MIT Press.

- Golden, R.M. (1986). The "Brain-State-in-a-Box" neural model is a gradient descent algorithm. *Journal of Mathematical Psychology*, 30, 73-80.
- Grossberg, S. (1976_a). Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors. *Biological Cybernetics*, 23, 121-134.
- Grossberg, S. (1976_b). Adaptive pattern classification and universal recoding: II. Feedback, expectation, olfaction, illusions. *Biological Cybernetics*, 23, 187-202.
- Grossberg, S. (2003). Bring ART into ACT. *Behavioral and Brain Sciences*, 26, 610-611.
- Hadley, R.F. (1999). Connectionism and novel combination of skills: Implications for cognitive architectures. *Minds and Machines*, 9, 197-221.
- Hadley, R.F. (2003). A defence of functional modularity. *Connection Science*, 15, 95-116.
- Harnad, S. (1990). The symbol grounding problem. *Physica D*, 42, 335-346.
- Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. Englewood Cliffs, NJ: Macmillan Publishing Company.
- Heckerman, D. (1995). A tutorial on learning with Bayesian networks. *Rapport Technique MSR-TR-95-06*, Microsoft Research.
- Heckerman, D., Geiger, D., et Chickering, D.M. (1995). Learning Bayesian networks: The combination of knowledge and statistical data. *Machine Learning*, 20, 197-243.
- Heckerman, D., Meek, C., et Cooper, G. (1999). A Bayesian approach to causal discovery. Dans C. Glymour et G.F. Cooper (Éds.) *Computation, Causation, & Discovery* (pp. 141-165). Menlo Park, CA: MIT Press.
- Hélie, S., Chartier, S., et Proulx, R. (2004). Applying fuzzy logic to neural modeling. Dans M. Lovett, C. Schunn, C. Lebiere, et P. Munro (Éds.) *Proceedings of the Sixth International Conference on Cognitive Modelling* (pp. 352-353). Mahwah, NJ: Lawrence Erlbaum Associates.
- Hélie, S., Chartier, S., et Proulx, R. (2006_a). Are unsupervised neural networks ignorant? Sizing the effect of environmental distributions on unsupervised learning. *Cognitive Systems Research*, 7, 357-371.
- Hélie, S. et Cousineau, D. (2005). Mixed effects of training on transfer. Dans B.G. Bara, L. Barsalou, et M. Bucciarelli (Éds.) *Proceedings of the 27th Annual Meeting of the Cognitive Science Society* (pp. 929-934). Mahwah, NJ: Lawrence Erlbaum Associates.

- Hélie, S., Proulx, R., et Lefebvre, B. (2006). JPEX: A psychologically plausible Joint Probability EXtractor. Dans R. Sun et N. Miyake (Éds.) *Proceedings of the 28th Annual Meeting of the Cognitive Science Society* (pp. 1482-1487). Mahwah, NJ: Lawrence Erlbaum Associates.
- Hertz, J., Krogh, A., et Palmer, R.G. (1991). *Introduction to the Theory of Neural Computation*. Redwood City, CA: Addison-Wesley Publishing Company.
- Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79, 2554-2558.
- Humpert, B. (1990). Bidirectional associative memory with several patterns. *Proceedings of the International Joint Conference on Neural Networks* (pp. 741-750). San Diego, CA: IEEE Press.
- Jang, J.-S.R. (1993). ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transaction on Systems, Man, and Cybernetics*, 23, 665-685.
- Kahneman, D., Slovic, P., et Tversky, A. (1982) *Judgment Under Uncertainty: Heuristics and Biases*. Cambridge, MA: Cambridge University Press.
- Karmiloff-Smith, A. (1994). Précis of *Beyond Modularity: A Developmental Perspective on Cognitive Science*. *Behavioral and Brain Sciences*, 17, 693-745.
- Kay, D.C. (1988). *Schaum's Outline of Tensor Calculus*. New York: McGraw-Hill.
- Kitzis, S.N., Kelley, H., Berg, E., Massaro, D.W., et Friedman, D. (1998). Broadening the tests of learning models. *Journal of Mathematical Psychology*, 42, 327-355.
- Kohonen, T. (1972). Correlation matrix memories. *IEEE Transactions on Computers C*, 21, 353-359.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43, 59-69.
- Kosko, B. (1988). Bidirectional associative memories. *IEEE Transactions on Systems, Man, and Cybernetics*, 18, 49-60.
- Kruschke, J.K. (1992). ALCOVE: An exemplar-based connectionist model of category learning. *Psychological Review*, 99, 22-44.
- Laird, J.E., Newell, A., et Rosenbloom, P.S. (1987). Soar: An architecture for general intelligence. *Artificial Intelligence*, 33, 1-64.
- Lakoff, G. et Johnson, M. (1999). *Philosophy in the Flesh: The Embodied Mind and its Challenge to Western Thought*. New York: Basic Books.

- Leroux, P. (1983). *Algèbre Linéaire: Une Approche Matricielle*. Mont-Royal, QC: Modulo.
- Lewicki, P., Hill, T., et Bizot, E. (1988). Acquisition of procedural knowledge about a pattern of stimuli that cannot be articulated. *Cognitive Psychology*, 20, 24-37.
- Logan, G.D. (1988). Toward an instance theory of automatization. *Psychological Review*, 95, 492-527.
- Logan, G.D. (1992). Shapes of reaction-time distributions and shapes of learning curves: A test of the instance theory of automaticity. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 18, 883-914.
- Mathews, R.C., Buss, R.R., Stanley, W.B., Blanchard-Fields, F., Cho, J.R., et Druhan, B. (1989). Role of implicit and explicit processes in learning from examples: A synergistic effect. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 15, 1083-1100.
- McClelland, J.L. et Chappell, M. (1998). Familiarity breeds differentiation: A subjective-likelihood approach to the effects of experience in recognition memory. *Psychological Review*, 105, 724-760.
- Medin, D.L. et Schaffer, M.M. (1978). Context theory of classification learning. *Psychological Review*, 85, 207-238.
- Meyer, D.E. et Kieras, D.E. (1997). A computational theory of executive cognitive processes and multiple-task performance. Part 1. Basic mechanism. *Psychological Review*, 104, 2-65.
- Minsky, M.L. et Papert, S. (1969). *Perceptron: An Introduction to Computational Geometry*. Cambridge, MA: MIT Press.
- Movellan, J.R. et McClelland, J.L. (2001). The Morton-Massaro law of information integration: Implications for models of perception. *Psychological Review*, 108, 113-148.
- Neapolitan, R.E. (2004). *Learning Bayesian Networks*. Upper Saddle River, NJ: Prentice Hall.
- Newell, A. (1990). *Unified Theory of Cognition*. Cambridge, MA: Harvard University Press.
- Newell, A. (1992). Précis of *Unified Theory of Cognition*. *Behavioral and Brain Sciences*, 15, 425-492.
- Newell, A. et Simon, H.A. (1976). Computer science as empirical enquiry: Symbols and search. *Communications of the ACM*, 19, 113-126.
- Nosofsky, R.M. (1986). Attention, similarity, and the identification-categorization relationship. *Journal of Experimental Psychology: General*, 115, 39-57.

- Oaksford, M. et Chater, N. (1998). *Rational Models of Cognition*. Oxford: Oxford University Press.
- Pearl, J. (1986). Fusion, propagation, and structuring in belief network. *Artificial Intelligence*, 29, 241-288.
- Pearl, J. (1988). *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Mateo, CA: Morgan Kaufmann.
- Pearl, J. (2000). *Causality: Models, Reasoning, and Inference*. Cambridge, UK: Cambridge University Press.
- Pitt, M.A. et Myung, I.J. (2002). When a good fit can be bad. *Trends in Cognitive Sciences*, 6, 421-425.
- Popper, K. (1959). *The Logic of Scientific Discovery*. New York: Routledge.
- Proulx, R. et Hélie, S. (2005). Adaptive categorization and neural networks. Dans C. Lefebvre et H. Cohen (Éds.) *Handbook of Categorization in Cognitive Science* (pp. 793-815). Amsterdam, NL: Elsevier.
- Reber, A.S. (1967). Implicit learning of artificial grammars. *Journal of Verbal Learning and Verbal Behavior*, 6, 855-863.
- Reber, A.S. (1989). Implicit learning and tacit knowledge. *Journal of Experimental Psychology: General*, 118, 219-235.
- Robert, M. (1988). Validité, variables et contrôle. Dans M. Robert (Éd.) *Fondements et Étapes de la Recherche Scientifique en Psychologie. Troisième Édition* (pp. 79-118). St-Hyacinthe, QC: Edisem.
- Roberts, S. et Pashler, H. (2000). How persuasive is a good fit? A comment on theory testing. *Psychological Review*, 107, 358-367.
- Ross, S.M. (1998). *A First Course in Probability. Cinquième Édition*. Upper Saddle River, NJ: Prentice-Hall.
- Rumelhart, D.E. et McClelland, J.L. (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Cambridge, MA: MIT Press.
- Rumelhart, D.E. et Zipser, D. (1986). Feature discovery by competitive learning. Dans D.E. Rumelhart et J.L. McClelland (Éds.) *Parallel Distributed Processing: Exploration in the Microstructure of Cognition* (pp. 151-193). Cambridge, MA: MIT Press.
- Shiffrin, R.M. et Steyvers, M. (1997). A model for recognition memory: REM – Retrieving Effectively from Memory. *Psychonomic Bulletin & Review*, 4, 145-166.

- Siegler, R. (2006). From unconscious to conscious insight. Dans R. Sun et N. Miyake (Éds.) *Proceedings of the 28th Annual Meeting of the Cognitive Science Society* (pp. 4-9). Mahwah, NJ: Lawrence Erlbaum Associates.
- Simon, H.A. (1972). Theories of bounded rationality. Dans C.B. McGuire et R. Radner (Éds.) *Decision and Organization: A Volume in Honor of Jacob Marschak* (pp. 161-176). Amsterdam, NL: North-Holland.
- Sloutsky, V.M. et Fisher, A.V. (2004). Induction and categorization in young children: A similarity-based model. *Journal of Experimental Psychology: General*, 133, 166-188.
- Smolensky, P. (1988). On the proper treatment of connectionism. *Behavioral and Brain Sciences*, 11, 1-74.
- Smolensky, P. (1990). Tensor product variable binding and the representation of symbolic structures in connectionist systems. *Artificial Intelligence*, 46, 159-216.
- Smolensky, P. et Legendre, G. (2006). *The Harmonic Mind: From Neural Computation to Optimality-Theoretic Grammar*. Cambridge, MA: MIT Press.
- Spirtes, P., Glymour, C., et Scheines, R. (1993). *Causation, Prediction, and Search*. New York: Springer-Verlag.
- Stadler, M.A. (1992). Statistical structure and implicit serial learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 18, 318-327.
- Stanley, W.B., Mathews, R.C., Buss, R.R., et Kotler-Cope, S. (1989). Insight without awareness: On the interaction of verbalization, instruction and practice in a simulated process control task. *The Quarterly Journal of Experimental Psychology*, 41A, 553-577.
- Steyvers, M., Tenenbaum, J.B., Wagenmakers, E.-J., et Blum, B. (2003). Inferring causal networks from observations and interventions. *Cognitive Science*, 27, 453-489.
- Sun, R. (2000). Symbol grounding: A new look at old ideas. *Philosophical Psychology*, 13, 149-172.
- Sun, R. (2003). A tutorial on CLARION 5.0. *Rapport Technique*, Cognitive Science Department, Rensselaer Polytechnic Institute.
- Sun, R. (2004). Desiderata for cognitive architectures. *Philosophical Psychology*, 17, 341-373.
- Sun, R., Merrill, E., et Peterson, T. (2001). From implicit to explicit knowledge: A bottom-up model of skill learning. *Cognitive Science*, 25, 203-244.
- Sun, R. et Peterson, T. (1998_a). Autonomous learning of sequential tasks: Experiments and analyzes. *IEEE Transactions on Neural Networks*, 9, 1217-1234.

- Sun, R. et Peterson, T. (1998_b). Some experiments with a hybrid model for learning sequential decision making. *Information Sciences*, 111, 83-107.
- Sun, R., Slusarz, P., et Terry, C. (2005). The interaction of the explicit and the implicit in skill learning: A dual-process approach. *Psychological Review*, 112, 159-192.
- Sun, R. et Zhang, X. (2006). Accounting for a variety of reasoning data with a cognitive architecture. *Journal of Experimental and Theoretical Artificial Intelligence*, 18, 169-191.
- Sun, R., Zhang, X., et Mathews, R. (2006). Modeling meta-cognition in a cognitive architecture. *Cognitive Systems Research*, 7, 327-338.
- Turing, A.M. (1936). On computable numbers with an application to the Entscheidungsproblem. *Proceedings of the Mathematical Society: Série 2*, 42, 230-265.
- Tversky, A. et Kahneman, D. (1983). Extensional versus intuitive reasoning: the conjunction fallacy in probability judgement. *Psychological Review*, 90, 293-315.
- Vere, S.A. (1992). A cognitive process shell. *Behavioral and Brain Sciences*, 15, 460-461.
- Wasserman, E.A. (1990). Detecting response-outcome relations: Toward an understanding of the causal texture of the environment. *The Psychology of Learning and Motivation*, 26, 27-82.
- Wasserman, E.A., Elek, S.M., Chatlosh, D.L., et Baker, A.G. (1993). Rating causal relations: Role of probability in judgments of response – outcome contingency. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 19, 174-188.
- Watkins, C. (1989). *Learning From Delayed Rewards*. Thèse Doctorale, Cambridge University, Cambridge, UK.
- Watkins, C. et Dayan, P. (1992). Q-learning. *Machine Learning*, 8, 279-292.
- Zemel, R.S. (1994). *A Minimum Description Length Framework for Unsupervised Learning*. Thèse Doctorale, University of Toronto, Toronto, CA.