

---

# Modularité et processus cognitifs de mémorisation

## Introduction

L'essentiel des travaux que nous avons réalisés dans le cadre du projet « Perception intelligente et traitement cognitif des odeurs » ont été présentés au précédent chapitre. Cependant, nous avons également participé à la thématique des « mécanismes cognitifs ». Cet axe de recherche porte principalement sur les processus de mémorisation humains, cette problématique est introduite dans la prochaine section. Le travail déjà réalisé porte sur la simulation du phénomène d'amorçage de répétition, ce sujet est traité dans la section 7.2. Mais la modélisation des processus de mémorisation a de nombreux développements informatiques potentiels. Aussi, la dernière section du chapitre (section 7.3) présente la perspective de l'implémentation d'une mémoire associative hétérogène.

## 7.1 Un modèle des processus de mémorisation humains

La mémoire humaine diffère fondamentalement d'une mémoire informatique classique. Cette remarque reste vraie en considérant qu'un ordinateur utilise aussi des mémoires associatives (aussi appelées « mémoires adressables par le contenu [CD89] »). À titre d'exemples : le cerveau peut mémoriser des informations hétérogènes ; la notion de contexte joue un rôle important ; les souvenirs n'ont pas tous la même intensité, ils sont le fruit d'un apprentissage, ou d'observations, ou d'une réflexion ; l'homme contrôle difficilement sa mémoire. On peut ne pas réussir à se souvenir, on peut aussi ne pas pouvoir oublier. Même la simple présence de l'information n'est pas toujours évidente, il est nécessaire de se tester.

La modélisation des processus de mémorisation humains est un sujet sur lequel travaillent Koenig et son équipe de l'UNPC. L'approche de Koenig est fonctionnelle [KK92]. Cette démarche est équivalente à l'approche computationnelle initiée

*Approche  
fonctionnelle*

par D. Marr [Mar82] : un point de vue algorithmique des phénomènes mentaux. En faisant abstraction de la complexité sous-jacente, cette approche algorithmique permet une meilleure compréhension entre les multiples disciplines impliquées dans les sciences cognitives, notamment l'informatique.

*Mémoire  
perceptive et  
mémoire  
associative*

Les travaux de Koenig décrivent précisément les processus de mémorisation humains. Nous présentons une version volontairement simplifiée à l'extrême d'un schéma fonctionnel de la mémoire humaine, figure 7.1.

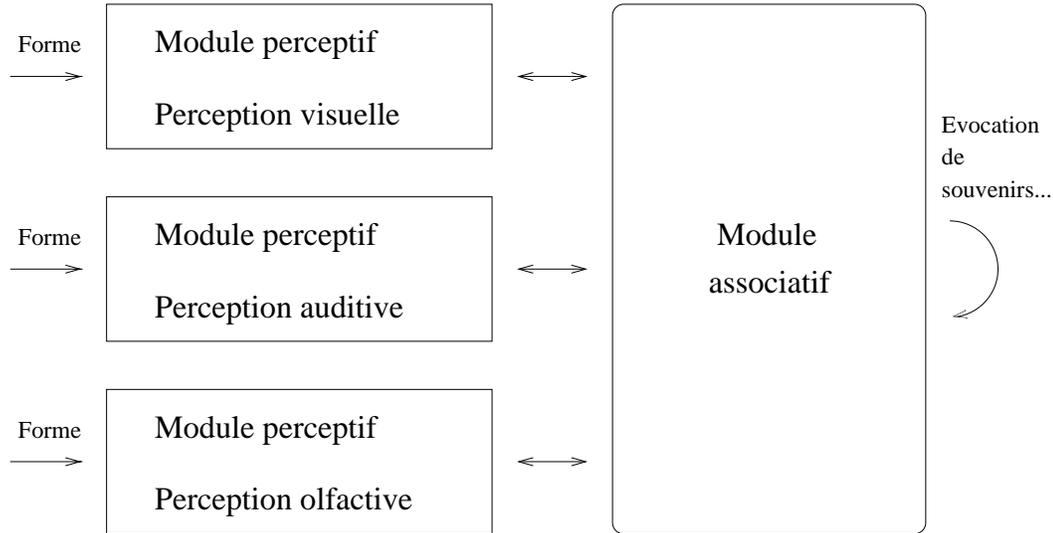


FIG. 7.1 – Schéma fonctionnel, simplifié à l'extrême, de la mémoire humaine

*Présentation  
des modules*

On distingue des modules dits « perceptifs » qui traitent les informations visuelles, auditives ou olfactives ; ainsi qu'un module dit « associatif » lié aux modules perceptifs par des connexions entrantes mais également sortantes.

La mémoire perceptive est spécialisée, « modale ». Elle est adaptée à un type d'information particulier. En d'autres termes, le système perceptif mémorise et reconnaît une information spécifique. Par exemple, la mémoire perceptive visuelle va reconnaître une forme (sans pour autant posséder d'informations sur la classe de la forme). Un éventuel prétraitement se situe encore en amont (c'est-à-dire qu'il serait sur la gauche de la figure 7.1) du système perceptif. Notons qu'une modélisation plus poussée peut intégrer une « rétroaction » du module perceptif sur le prétraitement, par exemple pour prendre en compte la modification de la « fenêtre attentionnelle » [KK92].

Le deuxième niveau est une mémoire associative qui relie les informations stockées dans les mémoires perceptives. Ce module stocke aussi une information de classe. La mémoire associative permet de relier ces informations hétérogènes. Elle est le lieu d'une activité qui va évoquer d'autres informations (des souvenirs) de divers types. Par exemple, une odeur peut évoquer un visage, un lieu, une autre odeur, *etc.*

La prochaine section présente la simulation du phénomène « d'amorçage de répétition ». Nous verrons notamment comment l'amorçage de répétition peut être mis à contribution afin de confirmer l'existence des deux niveaux de mémoire (c'est-à-dire un niveau perceptif et un niveau associatif).

## 7.2 Simulation d'un amorçage de répétition

Nous allons étudier une application du classifieur incrémental en sciences cognitives. Notre but est de simuler un amorçage de répétition, c'est-à-dire la capacité de répondre plus rapidement, ou plus facilement, à un *stimulus* qui vient d'être rencontré ([KK92] page 374). Nous commençons par motiver le travail réalisé au travers d'un exemple d'utilisation du classifieur amorcé. Le principe de la simulation et la notion de « fonction d'amorçage » sont décrits dans la section 7.2.1 et mis en œuvre sur l'application de reconnaissance de dessins au trait (section 7.2.3). Enfin, la section 7.2.4 étudie deux paramètres de la fonction d'amorçage, et leur influence sur l'amplitude du phénomène et sur les capacités du classifieur amorcé en généralisation.

L'amorçage de répétition est souvent utilisé, notamment dans le contexte de la neuropsychologie, pour étudier l'architecture d'un système neuronal. Disposer d'un modèle connexionniste ayant cette caractéristique peut être utile à de nombreuses tâches de validation d'hypothèses. À titre d'exemple, nous allons décrire une expérience proposée par Koenig dans le cadre du projet. Le but est de valider l'hypothèse d'un double stockage de l'information (mémoires perceptives et associatives) en détectant le double stockage grâce au phénomène d'amorçage. On effectue deux expériences indépendantes, chacune composée de deux phases successives.

*Motivations  
de l'étude*

Dans la première expérience (figure 7.2) : (i) lors de la première phase, on présente une série d'images (dont, par exemple, une fleur), les mémoires perceptives et associatives sont sollicitées ; (ii) dans la deuxième phase de l'expérience, certaines de ces images sont de nouveau présentées au sujet, sa réponse est facilitée par un amorçage perceptif et associatif.

*Amorçage  
perceptif et  
associatif*

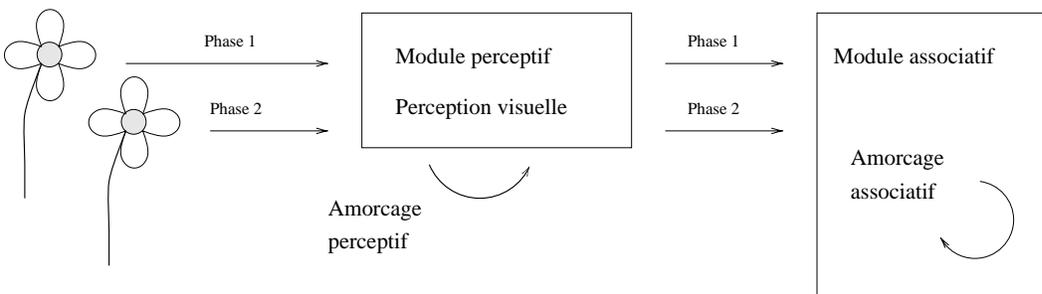


FIG. 7.2 – Un double amorçage grâce à deux passages dans le module perceptif visuel

*Amorçage  
exclusive-  
ment  
associatif*

Dans la seconde expérience (figure 7.3), la première phase est inchangée, mais la deuxième phase consiste à présenter l'odeur de la fleur. Cette fois, l'amorçage n'est qu'associatif puisque les modules perceptifs n'ont été activés qu'une seule fois. Evidemment, cette expérience suppose qu'il existe une association entre l'image et son odeur chez le sujet.

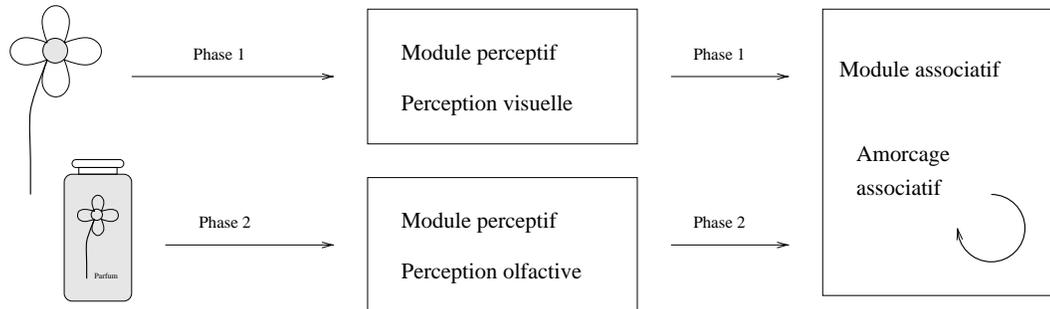


FIG. 7.3 – Un simple amorçage dû à un passage dans deux modules perceptifs

*Résultats  
attendus*

Lors de la deuxième phase de chacune des deux expériences, on utilise les formes déjà présentées ainsi que de nouvelles formes. La contribution du phénomène d'amorçage est calculée en faisant la différence des temps obtenus avec les formes connues et avec les nouvelles. L'hypothèse que l'on désire valider est que cette contribution doit être supérieure dans le cas d'un double amorçage.

Cette expérience est proposée à titre d'exemple. Sa réalisation effective demanderait une recherche du protocole nécessaire à une absence d'interférence. En tout état de cause, elle est difficile à réaliser sur des sujets humains car il est délicat de séparer le temps passé dans le module perceptif et dans le module associatif. Cette mesure est nécessaire pour comparer les gains d'amorçage entre les deux expériences. Avec le modèle simulé, cette mesure ne pose pas de problème.

### 7.2.1 Hypothèse de la confiance

Nous désirons que le classifieur réponde facilement si l'exemple présenté appartient à une classe dont un exemple a été présenté récemment. Une solution pour simuler l'amorçage consiste à promouvoir les prototypes des classes récemment rencontrées. Le soutien apporté au prototype doit être d'autant plus important que la dernière présentation est récente. Ce principe est implémenté par l'ajout d'un « bonus » aux classes présentées récemment.

*Fonction  
d'amorçage*

Afin de préciser la méthode mise en œuvre, notons  $t_C(P_j)$  le temps écoulé (mesuré en nombre d'exemples présentés au classifieur) depuis qu'un exemple de la classe  $C(P_j)$  a été présenté. Le « score »  $S_{P_j}$  d'un prototype est calculé en ajoutant une fonction d'amorçage  $f$  à l'activation du prototype. Dans le cas du problème de reconnaissance de dessins au trait, nous avons appelé cette activation « similarité » (section 1.2.2). Dans ce contexte d'OCR, l'équation 7.1 donne le score d'un prototype ( $S$ ) en fonction

de sa similarité ( $s$ ) avec l'exemple traité :

$$S_{P_j} = s_{P_j} + f(t_C(P_j)) \quad \forall j \in [1, n] \quad (7.1)$$

Pour répondre à nos besoins, c'est-à-dire pour implémenter notre bonus, la fonction d'amorçage  $f$  doit être positive et strictement décroissante. La figure 7.4 présente une bonne candidate pour  $f$ . Cette fonction assure la promotion des classes rencontrées depuis les 10 derniers exemples (figure 7.5).

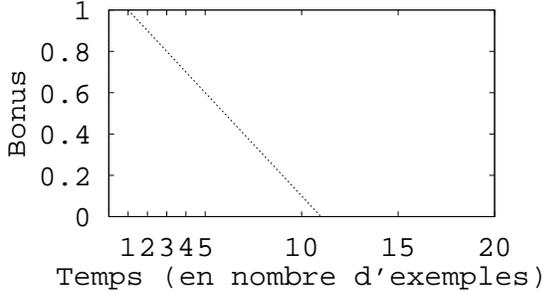


FIG. 7.4 – Fonction d'amorçage  $f$

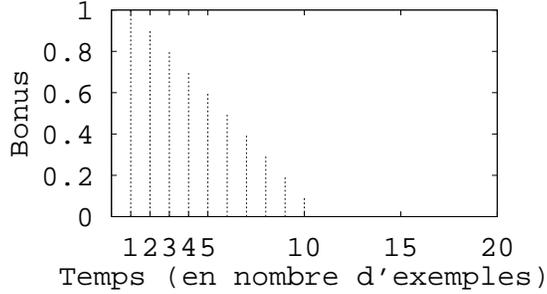


FIG. 7.5 – Fonction  $f$  discrétisée

### 7.2.2 Détection et mesure de l'amorçage

Pour que le classifieur « amorçable » nous soit utile, il est nécessaire de pouvoir détecter (et si possible mesurer) la présence d'un amorçage. Or notre classifieur, comme la plupart des modèles connexionnistes, répond en un temps constant (du moins en phase de reconnaissance, c'est-à-dire avec un nombre fixe de prototypes). Cependant, il y a correspondance entre une réponse rapide et une réponse « facile à donner ». En effet, plus le système a confiance en une réponse, plus vite il peut répondre. Ainsi, l'amorçage est mesuré en suivant la confiance que le classifieur a dans ses réponses.

Avant d'aller plus loin, il est bon de préciser ce que nous appelons « la confiance du classifieur en ses réponses ». La confiance du réseau est un réel que nous notons  $T$  et qui est fonction des meilleurs scores obtenus par les prototypes :

$$T = S_{meilleur} \Leftrightarrow S_{second} = \underbrace{s_{meilleur} \Leftrightarrow s_{second}}_{\Delta_s} + f(t_C(P_{meilleur})) \Leftrightarrow f(t_C(P_{second})) \quad (7.2)$$

La simulation d'un amorçage influe sur la confiance. La table 7.1 présente l'influence de l'amorçage sur la confiance. L'algorithme étant du type *winner takes all*,  $C(P_i) \neq C(P_j) \Rightarrow t_C(P_i) \neq t_C(P_j)$ , donc  $t_C(P_{meilleur}) \neq t_C(P_{second})$ .

$$\begin{cases} t_C(P_{meilleur}) < t_C(P_{second}) & \Rightarrow & f(t_C(P_{meilleur})) \Leftrightarrow f(t_C(P_{second})) > 0 \\ t_C(P_{meilleur}) > t_C(P_{second}) & \Rightarrow & f(t_C(P_{meilleur})) \Leftrightarrow f(t_C(P_{second})) < 0 \end{cases} \quad (7.3)$$

*Principe de la mesure de l'amorçage*

*Une définition de la confiance*

*Variation de la confiance*

Confiance $T$	$t_{C(P_{meilleur})} < t_{C(P_{second})}$	$t_{C(P_{meilleur})} > t_{C(P_{second})}$
$\Delta_s > 0$	L'amorçage confirme le classifieur dans son choix. La confiance est <b>forte</b> .	L'amorçage conduit au choix d'une autre classe. La confiance en ce nouveau choix est <b>faible</b> .
$\Delta_s < 0$	L'amorçage aide le second meilleur choix, la confiance dans le premier choix est <b>faible</b> .	<b>Impossible</b> puisque $T > \Theta_{confusion}$ (équation 1.4), on a $T > 0$ .

TAB. 7.1 – Analyse de l'influence de l'amorçage sur l'algorithme de classification

Signe d'un phénomène d'amorçage

Une analyse quantitative du niveau de confiance est difficile. Cependant, le point capital est de remarquer que dans tous les cas, un temps  $t_{C(P_{meilleur})}$  plus court conduit à plus de confiance. Ainsi, il est possible de détecter et de mesurer l'amorçage en analysant le sens de variation de la confiance en fonction des « délais réalisés ». Une décroissance de la confiance est le signe révélateur d'un amorçage.

Notion de délais réalisés

De manière plus formelle, on peut définir un délai réalisé comme le nombre d'exemples présentés entre la présentation de deux exemples de la même classe. Cette information n'est pas connue du classifieur, ce serait trop facile et peu réaliste. Les délais réalisés sont calculés et utilisés afin de détecter l'amorçage, à partir de la trace de l'ordre dans lequel les formes ont été présentées lors d'une expérience donnée.

Exemples

À titre d'exemple, dans la séquence de chiffres « 1, 4, 3, 4, 4, 1 », les délais réalisés pour le chiffre « 4 » sont de 2 et 1 exemples. Pour le chiffre « 1 », le seul délai réalisé que l'on peut extraire de cette même séquence est de 5 exemples.

### 7.2.3 Expérience d'amorçage du classifieur

Les expériences présentées sont réalisées sur l'application de reconnaissance de caractères manuscrits. Rappelons que 500 chiffres sont appris. Le classifieur est testé (phase de généralisation) sur 500 autres chiffres. Chaque exemple est présenté une seule fois, suivant un ordre aléatoire. La forme manuscrite présentée passe par le prétraitement déjà étudié, le résultat obtenu (c'est-à-dire les petits segments orientés extraits des chiffres manuscrits) est l'entrée du classifieur. La généralisation est correcte pour 95 % des exemples de l'ensemble de test. Seul l'amorçage en généralisation est expérimenté.

Suivi de l'amorçage

Afin de détecter et de mesurer le phénomène d'amorçage de répétition, nous suivons l'évolution de la confiance au fur et à mesure de la présentation des exemples. La confiance du classifieur doit être confrontée aux délais réalisés expérimentalement, c'est-à-dire aux délais réalisés extraits *a posteriori* de la séquence donnée par l'ordre de présentation des exemples durant l'expérimentation considérée.

La figure 7.6 présente donc la confiance pour chaque exemple classifié en fonction des délais réalisés, triés par ordre croissant. Pour résumer, un point du graphique de coordonnées  $(x, y)$  signifie qu'un exemple a conduit à une réponse accréditée d'une confiance  $y$ , sachant que le précédent exemple de la même classe a été présenté depuis  $x$  exemples. La figure 7.7 reprend ces résultats et donne la confiance moyenne pour chaque délai (courbe au trait épais). Les mêmes expériences et les mêmes calculs, réalisés sans la simulation de l'amorçage donnent la courbe au trait fin. Bien que ces deux courbes soient difficiles à lire, on constate nettement qu'elles diffèrent.

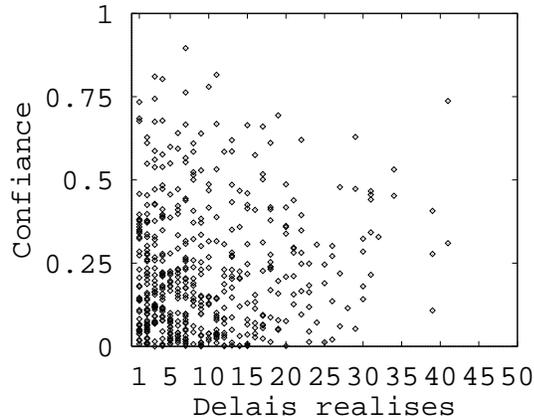


FIG. 7.6 – *Évolution de la confiance en fonction des délais réalisés*

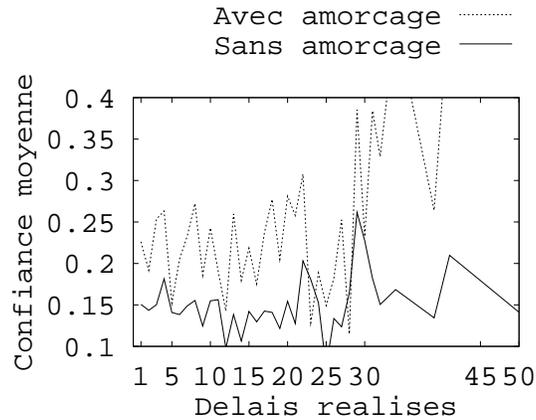


FIG. 7.7 – *Confiance moyenne avec et sans amorçage*

Une éventuelle évolution de la confiance peut être évaluée en calculant une régression linéaire sur les délais. Cependant, la recherche du nombre d'occurrences observées pour chaque délai, présentée sur la figure 7.8, montre qu'une grande partie des délais sont trop rares pour être significatifs. Aussi, il est préférable de ne pas prendre en compte les délais apparaissant dans moins de 5 % des cas (figure 7.9).

*Délais significatifs*

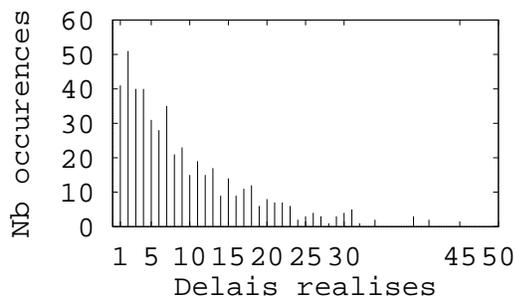


FIG. 7.8 – *Occurrence des délais*

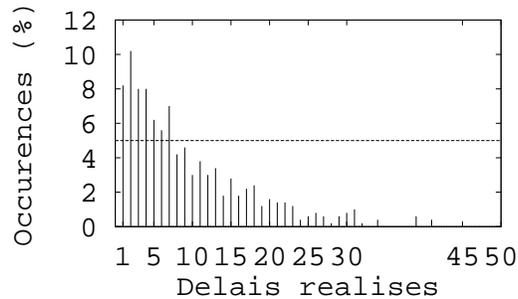


FIG. 7.9 – *Pourcentage d'occurrence de chaque délai*

Régression  
linéaire sur  
les délais

Le calcul d'une régression linéaire sur les délais dont le pourcentage d'apparition est supérieur à 5 % est donné par les équations de droites (7.4) :

$$\begin{cases} \text{Avec amorçage} & : & y = \approx 0.000789x + 0.222 \\ \text{Sans amorçage} & : & y = \approx 0.000377x + 0.152 \end{cases} \quad (7.4)$$

Droites de  
régression  
significatives

On constate que la pente de la droite de régression de la confiance avec amorçage est plus faible. Cependant, les résultats ne sont pas suffisamment tranchés pour conclure. De plus, la variance n'est pas négligeable, en fonction de l'ordre de présentation des exemples. Ce problème peut être éliminée en calculant la droite de régression sur plusieurs expériences. Nous mettons en œuvre une solution équivalente : la distribution des mesures de confiance (figure 7.6) est élargie en considérant plusieurs cycles apprentissage-généralisation. La figure 7.10 présente la confiance moyenne après les 150 cycles apprentissage-généralisation. Comme précédemment, la courbe au trait épais est calculée avec amorçage, alors que la courbe au trait fin est réalisée sans amorçage. La courbe 7.11 donne le pourcentage d'apparition de chaque délai et montre que seulement 7 valeurs sont significatives (soit 54.7 % de tous les délais).

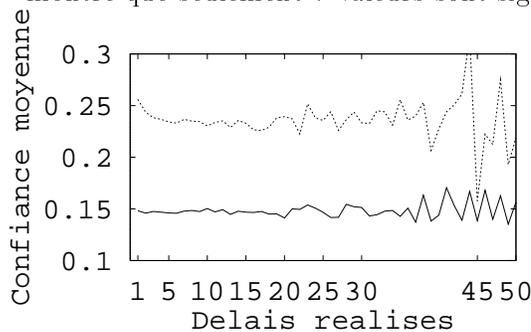


FIG. 7.10 – *Confiance moyenne sur 150 cycles apprentissage-généralisation*

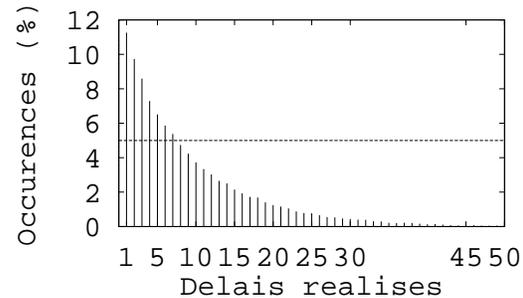


FIG. 7.11 – *Pourcentage d'apparition des délais*

Une mesure  
stable et  
précise

Nous pouvons à présent calculer une régression linéaire significative, le résultat est donné par l'équation 7.5. Les pentes des droites de régression sont le signe évident d'un phénomène d'amorçage. La mesure de la différence de pente entre les droites de régression calculées avec et sans amorçage donne une mesure quantitative de l'amorçage. Cette mesure est stable et précise. Notre but est atteint, cependant il est intéressant de déterminer le nombre minimum de cycles apprentissage-généralisation nécessaires à l'obtention d'un nombre de délais suffisant. L'évolution de la pente de la droite de régression en fonction du nombre de cycles est présentée par la figure 7.12.

$$\begin{cases} \text{Avec amorçage} & : & y = \approx 0.00341x + 0.253 \\ \text{Sans amorçage} & : & y = \approx 0.000147x + 0.147 \end{cases} \quad (7.5)$$

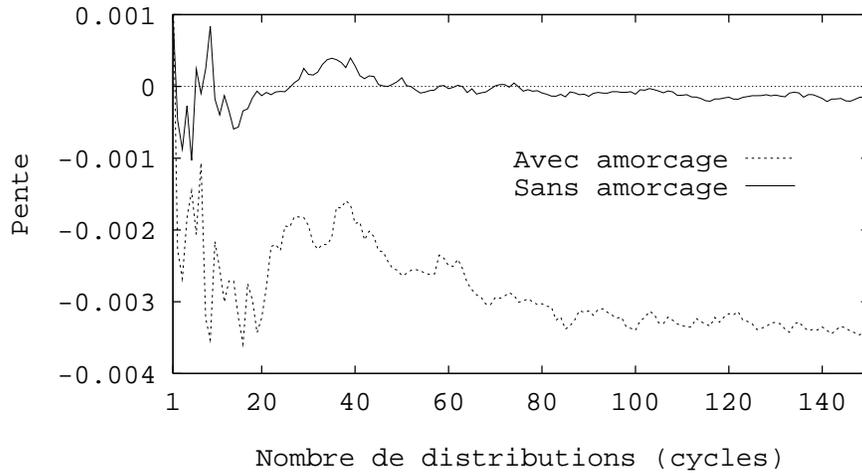


FIG. 7.12 – Évolution de la pente de la droite de régression

On constate que l'amorçage est facilement détectable après 5 cycles. Les résultats sont suffisamment significatifs pour permettre une mesure après environ 50 cycles. La pente atteint sa valeur définitive après environ 100 cycles.

#### 7.2.4 Étude de la fonction d'amorçage

Notre choix pour la forme de la fonction d'amorçage était arbitraire. Afin de compléter cette étude, il convient d'expérimenter différentes fonctions.

La figure 7.13 présente diverses formes obtenues en changeant la base de la fonction. On peut ainsi choisir de réagir aux 2, 5, 10, ou 15 derniers exemples présentés. La figure 7.14 donne l'évolution de la droite de régression correspondante. La meilleure pente est obtenue avec une base de 5 exemples. En d'autres termes, les 5 dernières présentations sont favorisées. Ce résultat peut être rapporté au nombre de délais significatifs (figure 7.11) : la meilleure fonction d'amorçage fait la promotion des délais les plus fréquents.

*Base de la  
fonction  
d'amorçage*

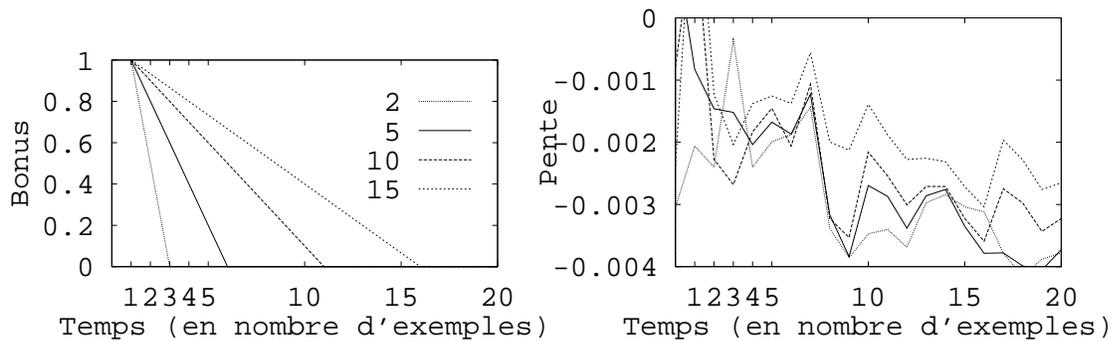
FIG. 7.13 – Différentes bases pour la fonction d'amorçage  $f$ 

FIG. 7.14 – Pentes de régressions pour les différentes bases

Hauteur de la fonction d'amorçage

Une autre façon d'accroître le phénomène d'amorçage consiste à augmenter la hauteur de la fonction  $f$ . Les expériences ont été faites avec une base de 5 exemples, pour les hauteurs 0.1, 0.5, 1, et 2. Les figures 7.15 et 7.16 montrent qu'augmenter la hauteur de la fonction d'amorçage accroît directement de phénomène d'amorçage.

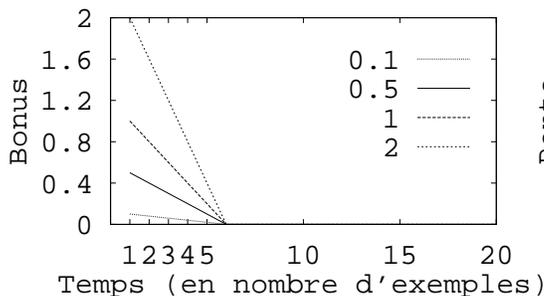


FIG. 7.15 – Différentes hauteurs pour la fonction d'amorçage  $f$

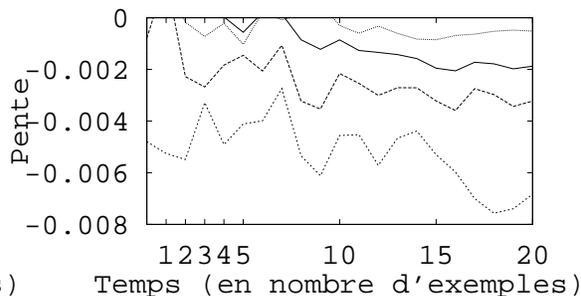


FIG. 7.16 – Pentes de régressions pour les différentes hauteurs

Performances du classifieur amorcé

Il semble donc qu'accroître la hauteur de la fonction d'amorçage  $f$  soit le meilleur moyen de provoquer le phénomène d'amorçage. Cependant, cette méthode a un coût. Comme le ferait le cerveau, le classifieur a tendance à classer les exemples comme appartenant aux dernières classes gagnantes. Le nombre d'erreurs en généralisation est donc plus élevé. Cet inconvénient peut ne pas être gênant pour la tâche à réaliser. Si les performances du classifieur doivent rester élevées, la hauteur de la fonction d'amorçage doit être maintenue à de faibles valeurs. La table 7.2 montre qu'une hauteur fixée à 0.1 est un bon compromis entre détectabilité et performance en classification.

Hauteur	Succès (%)	Pente (150 cycles)
0.1	93.3	-0.000526
0.5	80.5	-0.002045
1.0	58.6	-0.003674
2.0	41.7	-0.006570

TAB. 7.2 – Pourcentage d'exemples reconnus en généralisation

### 7.2.5 Conclusion sur l'amorçage

L'amorçage de répétition

Il est possible d'amorcer un classifieur incrémental en renforçant la reconnaissance des prototypes appartenant à une classe récemment rencontrée. Le classifieur donne plus facilement une réponse pour les exemples d'une classe déjà vue. De nombreux cycles sont nécessaires à l'étude précise du phénomène, particulièrement pour analyser l'influence de la forme de la fonction d'amorçage. Ce travail étant réalisé, il est aisé de choisir une fonction d'amorçage pour des résultats rapides. Les méthodes

décrites dans ce chapitre permettent de détecter facilement un phénomène d'amorçage de répétition, en calculant une simple régression linéaire sur quelques cycles apprentissage-généralisation. Un plus grand nombre de cycles rend possible une mesure quantitative de l'amorçage, en calculant la différence entre les pentes des droites de régression calculées avec et sans amorçage.

### 7.3 Perspective d'une mémoire associative hétérogène

Afin d'implémenter l'expérience de détection d'un double amorçage présenté au début de ce chapitre, nous avons besoin d'une modélisation informatique de la mémoire à deux niveaux (revoir la figure 7.1). Il nous manque donc une mémoire associative elle-même amorçable.

Par ailleurs, au chapitre précédent, nous avons utilisé les descripteurs choisis par les sujets en entrée du classifieur pour tenter de discriminer les odeurs. Nous avons ainsi pu étudier l'ensemble des descripteurs. Cependant, d'un point de vue modélisateur, la notion de descripteurs est clairement liée au module associatif et ne peut en aucun cas être l'entrée d'un module perceptif. Le classifieur ne peut donc à lui seul servir à modéliser les processus de mémorisation humains.

Dans la présente section, nous allons proposer une mémoire à deux niveaux compatible avec la figure 7.1. Notons qu'une approche hybride numérique-symbolique est étudiée par Sebban et Zighed [SZ96a] (laboratoire ÉRIC). Nous allons maintenant proposer une architecture purement connexionniste, une solution modulaire et parallèle.

Ce travail prépare une prochaine implémentation informatique d'une mémoire hétérogène associative. Nous nous basons sur la littérature du domaine, ainsi que les nombreuses discussions dans le cadre des réunions du projet « Perception intelligente et traitement cognitif des odeurs » ou à l'occasion de différentes manifestations (notamment la dernière réunion du Pôle Rhône-Alpes de Sciences Cognitives où ce travail a été présenté). Enfin, nos propositions sont bornées par ce que nous estimons actuellement faisable à partir de notre expérience connexionniste.

Nous désirons construire un réseau de neurones susceptible de modéliser le processus de mémorisation humain<sup>1</sup>. Les possibilités étant infinies, une bonne approche consiste à chercher le réseau le plus simple compatible avec le principe de la figure 7.1.

---

1. Cet objectif ne prétend nullement « égaler les processus humains ». De plus, nous ne cherchons pas une modélisation exhaustive, au même titre que la modélisation d'un neurone biologique par le neurone formel est extrêmement simplificatrice (voir si nécessaire l'annexe A.1). Notons que le dépouillement du neurone formel ne l'a pas empêché de donner naissance à un des domaines actuellement les plus intéressants de la recherche informatique.

*Besoin d'un  
modèle à  
deux niveaux  
pour la  
mémoire*

*Le réseau de  
neurones  
adapté le  
plus simple*

Le schéma 7.17 donne une telle structure connexionniste :

- les neurones de la mémoire perceptive, notés  $P_i$  sur notre schéma, réagissent à un influx provenant de cellules dédiées capables d'opérer un prétraitement spécifique à une modalité perceptive donnée (en amont de la figure) ;
- les neurones de la mémoire associative réagissent à une configuration de  $P_i$ .

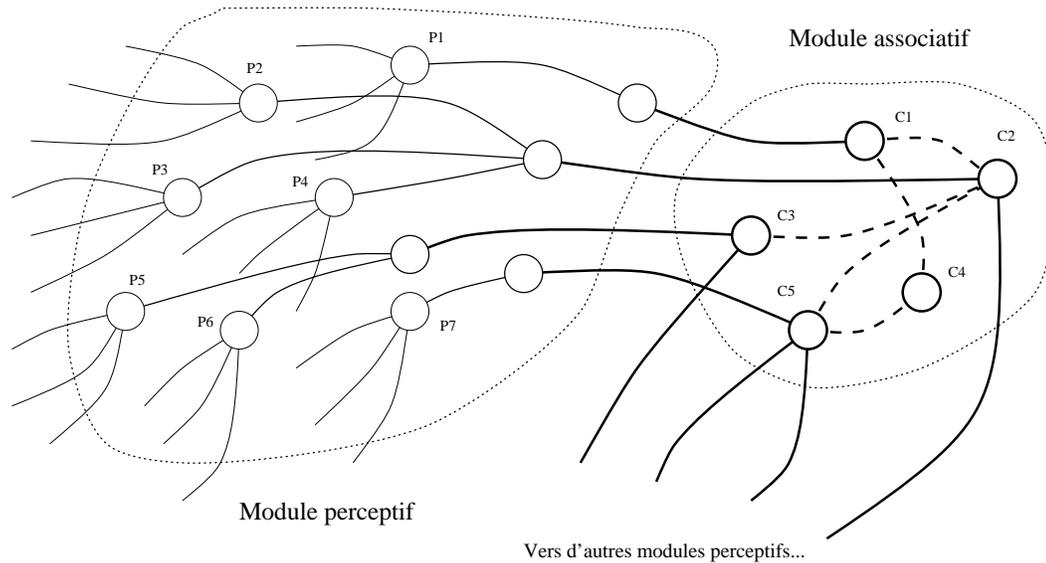


FIG. 7.17 – Architecture minimale compatible avec le modèle

### 7.3.1 Module perceptif

*Le classifieur neuronal comme mémoire perceptive*

Le classifieur incrémental prend tout naturellement sa place dans ce modèle connexionniste (figure 7.18), comme « module perceptif ». Le classifieur est bien adapté à la modélisation d'une mémoire perceptive, il implémente la reconnaissance de l'entrée et laisse au module associatif la tâche d'identification.

En effet, le classifieur incrémental a de nombreux points communs avec ce que l'on attend d'une modélisation de la mémoire perceptive.

- Le cerveau apprend constamment, tout ce qui arrive jusqu'à lui est susceptible d'être mémorisé. Le classifieur incrémental apprend lui aussi constamment : lorsqu'un exemple est présenté au classifieur, la classe à laquelle il appartient est systématiquement recherchée. Cet apprentissage peut se faire en mode supervisé ou non supervisé. De plus, le mode d'apprentissage peut changer d'une entrée à l'autre sans traitement particulier (simplement en fonction de la présence d'une étiquette). Enfin, le classifieur peut apprendre en-ligne.

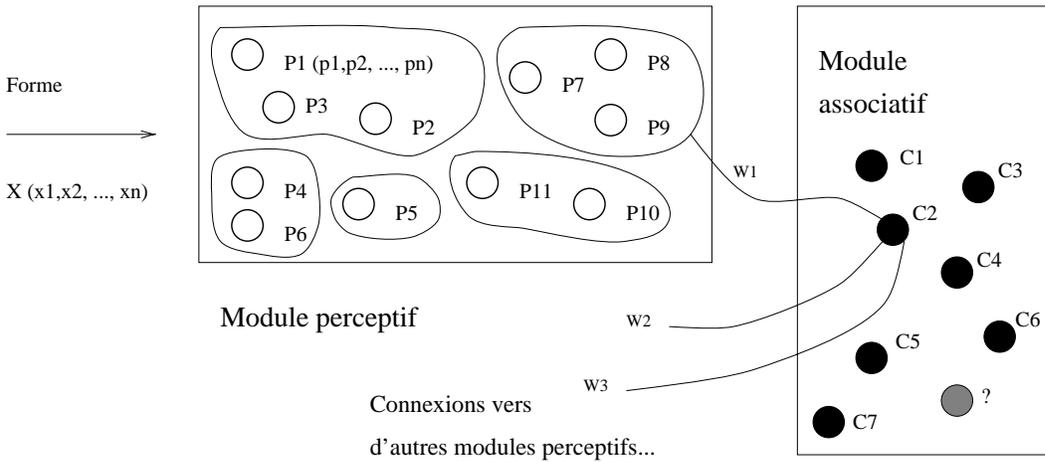


FIG. 7.18 – Une mémoire à deux niveaux : un niveau perceptif, et un niveau associatif

- D'un individu à l'autre, nous pouvons développer plus ou moins chacun de nos sens, par exemple en fonction de la profession exercée<sup>2</sup>, ou en fonction des langues parlées<sup>3</sup>. À l'extrême, un individu privé d'un de ses sens compensera avec les autres. Ces remarques militent en faveur d'une structure incrémentale.
- Nous pouvons reconnaître un visage, et nommer la personne ainsi reconnue. Mais nous pouvons aussi visualiser le visage. De même, un bon peintre est capable de reproduire sur la toile un visage de mémoire. Ces constatations sont en faveur de tout système à base de prototypes car il est possible d'extraire l'information. Au contraire, avec un modèle à base d'hyperplans, l'information est distribuée dans tout le réseau et ne peut être accédée.
- Un souvenir peut induire des sensations très réalistes, à la limite de la perception. Par exemple, la vue d'un plat carbonisé peut évoquer une odeur de brûlé. De même, un rêve n'est pas construit de vagues sensations, les images semblent bien réelles. Au niveau du classifieur, un souvenir mémorisé par la mémoire associative peut activer un prototype directement dans un module perceptif. Le même prototype étant activé lors d'une perception et lors de l'évocation d'un souvenir, le classifieur modélise parfaitement la sensation ressentie.
- Un module perceptif reçoit une entrée homogène. Le prétraitement est en général imperceptible<sup>4</sup> : nous rétablissons une image horizontale en inclinant la tête, nous effectuons constamment ce que les cinéastes appellent une « balance

2. Par exemple, un oenologue est capable de distinguer de très subtiles nuances de goût.

3. Un chilien a du mal à distinguer la différence entre le « é » et le « è » français et ainsi des mots tels que « été » et « était ». De même un français ne fera pas la nuance entre deux mots ne différant que par leur accentuation tonique. Heureusement, ces difficultés s'amenuisent avec la pratique.

4. L'existence d'un prétraitement peut être mise en évidence, par exemple à l'occasion « d'illusions d'optique ». L'étude de ces phénomènes a aidé à la modélisation des prétraitements humains.

des blancs », *etc.* De même, le classifieur incrémental n'est efficace qu'avec un bon prétraitement<sup>5</sup>.

*Exemple des segments orientés*

- Le prétraitement (humain ou informatique) est différent d'une modalité à l'autre. Considérons l'extraction de petits segments orientés utilisée pour la reconnaissance de dessins au trait. Un prétraitement similaire est effectué dans le cerveau, par les « cellules simples » du cortex [Azc93, BC69, BC70], et nous permet de reconnaître un texte manuscrit. Il est raisonnable de penser que ce filtrage n'est pas une conséquence mais l'origine de notre alphabet, la cause étant plus ancienne et probablement liée à notre survie dans un environnement donné. Une écriture sous forme de points ne nécessite que  $\lceil \log_2(26) \rceil = 5$  points (pour notre alphabet) et un simple poinçon (contre une plume et l'encre). Mais le prétraitement dont nous avons hérité est moins capable d'apprécier des *tas de points* que des courbes. Par ailleurs, le succès du Braille montre que, à l'opposé de la vision, la perception tactile est compatible avec un système de points. Cette constatation confirme la spécificité du prétraitement.

### 7.3.2 Module associatif

*Modèle connexionniste pour la mémoire associative*

Dans le modèle de Koenig [KK92], la mémoire associative contient une information propositionnelle indépendante de la nature de la perception. Cette information est une information de classe, c'est-à-dire une simple étiquette. Les connexions reliant les souvenirs mémorisés peuvent être de plusieurs types afin de coder des relations telles que la ressemblance, l'appartenance, ou encore la supériorité (ce qui permet de créer un ordre, une séquence). Toutefois, il est raisonnable de limiter notre modèle à une relation du type « correspond à ». On peut ainsi utiliser un réseau récurrent (voir si nécessaire la section A.3). Cette sémantique des connexions est par exemple suffisante pour modéliser l'expérience olfactive pour laquelle le classifieur seul est insuffisant.

Nous avons donc besoin d'une mémoire associative qui apprenne constamment et en-ligne, de façon supervisée ou non (en fonction de la présence d'une information de classe). De plus, le classifieur ayant été choisi pour modéliser les modules perceptifs, les cellules du réseau récurrent sont créées par le classifieur. En effet, ces cellules correspondent aux ex-cellules de sortie du classifieur. Le module associatif est donc lui aussi incrémental.

Il n'existe pas de réseau récurrent dont l'algorithmique corresponde à nos besoins.

---

5. Un réseau de type MLP avec un apprentissage par rétropropagation du gradient nécessite également un prétraitement. Cependant, l'utilisation de plusieurs couches peut permettre au réseau d'apprendre à effectuer ce prétraitement (au prix d'un temps d'activation plus important et d'une vitesse de convergence plus lente).

Aussi, nous en proposons un, sans pour autant l'implémenter. Ce travail constitue une perspective de recherche qui s'inscrit déjà dans plusieurs projets de sciences cognitives, tant la notion d'interactions multimodales est présente à de nombreux niveaux dans le cerveau.

1. Les influx arrivant des classifieurs activent ou créent des cellules dans la mémoire associative. L'activation initiale de ces cellules dépend de la confiance du classifieur en sa réponse.
2. Les liens reliant les cellules activées sont créés ou renforcés.
3. L'influx se propage de cellule en cellule en suivant les connexions, chaque cellule fait la somme pondérée de ses entrées et propage le résultat aux cellules suivantes (sans seuillage). La valuation des liens parcourus par l'influx est augmentée afin de « rapprocher » les souvenirs évoqués par un même jeu d'entrées.

Notons que même faible, l'influx peut considérablement augmenter en passant sur une connexion fortement valuée. Une information importante, mais très rarement rappelée, peut être retrouvée dans toute son intensité dans un certain contexte. Cette capacité, que l'on peut nommer « force de rappel » vise à prendre en compte la force que peut avoir un souvenir apparemment oublié si on trouve la bonne « clé ». Engen évoque cet aspect de la mémoire [Eng89] en prenant l'exemple de la madeleine de Proust [Pro13].

### 7.3.3 Processus d'évocation

L'algorithme proposé ne prévoit pas de condition d'arrêt. L'influx circule donc dans le réseau, passant éventuellement plusieurs fois sur les mêmes cellules (et augmentant constamment les poids). Une solution est « d'épuiser » l'influx à chaque passage par une cellule, en diminuant sa valeur plus fortement à chaque cellule.

Nous n'avons pas parlé de la sortie du réseau. Il convient au préalable de définir une notion d'évocation : un souvenir est évoqué si la somme pondérée des entrées d'une cellule traversée par l'influx dépasse un seuil donné. Pratiquement, l'évocation d'un souvenir peut conduire à répondre par l'éventuelle étiquette de la cellule. On peut aussi répondre par l'intermédiaire des prototypes connectés à la cellule : un prototype visuel peut être affiché et un prototype sonore peut être joué.

La sortie peut donc être la succession des souvenirs évoqués, ou le souvenir évoqué avec la plus grande intensité entre l'activation initiale et la disparition de l'influx.

Une solution biologiquement plus plausible consiste à ne pas chercher à arrêter l'évocation. Le système évolue de façon chaotique [Fre91] jusqu'à ce qu'une entrée soit suffisamment importante pour influencer le processus d'évocation en cours dans le module associatif. On peut donc laisser le système en « veille », attendant qu'une entrée suffisamment importante (une image, un son, *etc.*) provoque un changement

*Évocation  
d'un  
souvenir*

significatif du cheminement de l'influx. Enfin, en l'absence totale d'entrée, le système peut consolider les souvenirs enregistrés. Ainsi, des informations insignifiantes peuvent être atteintes et faire évoluer le système, alors qu'elles étaient masquées de l'influx provenant des modules perceptifs « en mode éveillé ».

## Conclusion sur une mémoire associative hétérogène

Nous avons présenté le principe d'une mémoire associative hétérogène. L'implantation des modules perceptifs ne pose pas de problème grâce à l'expertise accumulée sur le classifieur incrémental.

Cependant, la mise en œuvre de la mémoire associative est bien plus complexe. De nombreux choix sont possibles et doivent être évalués. Un long travail de recherche serait encore nécessaire pour réaliser cette perspective.

Ce modèle est également très intéressant pour l'ingénieur connexionniste, tout d'abord parce qu'il est modulaire. Lorsque l'on veut résoudre un problème connexionniste, la méthode consiste souvent à utiliser toutes les données disponibles en entrée d'un réseau classique (c'est-à-dire souvent un MLP). Ce travail se termine généralement par la recherche d'un prétraitement complexe pour atteindre de bonnes performances. L'utilisation d'une mémoire associative hétérogène apporte au moins 4 avantages. En effet, une fois les composantes du vecteur d'entrée regroupées en autant de modalités possibles, (i) le prétraitement de chaque modalité est facilité ; (ii) l'acquisition, le prétraitement et la classification perceptive sont parallélisés de fait ; (iii) l'apprentissage a toutes les chances d'être meilleur car le classifieur peut utiliser les meilleurs paramètres pour chaque modalité ( $\Theta_{confusion}$  et  $\Theta_{influence}$ ) ; (iv) les prototypes créés sont simples et peuvent être utilement interprétés.

À titre d'exemple, une application de prévision des conditions météorologiques peut avoir un module dédié à l'image satellite, un autre pour l'image infrarouge, un troisième pour la répartition des températures, un quatrième pour les pressions, *etc.* Chaque module peut fonctionner sur une station de travail à la puissance adaptée à la tâche à accomplir. On parallélise ainsi le prétraitement et une partie de la classification (le niveau perceptif). Les stations pouvant être équipées d'équipements spécialisés (récepteur satellite ou radio, modem, *etc.*), l'acquisition des données est également parallélisée. Enfin, notons que cette technique de parallélisation n'est pas incompatible avec les stratégies déjà présentées. Aussi, dans notre exemple météorologique, un module très lourd peut être confié à une machine parallèle.

La notion de contexte est également suffisamment intéressante pour sortir du laboratoire. Parmi les applications appelées à un grand avenir et pouvant profiter d'un traitement du contexte, citons la reconnaissance de visage, ou encore la traduction automatique et la « dictée automatique ».

Même des notions originales comme la possibilité d'une veille peut avoir des utilisations pratiques dans toutes les tâches de surveillance. On pense bien sûr immédiatement à des systèmes équipés de caméras et de micros et surveillant par exemple le trafic automobile en ne dérangeant l'opérateur que si un danger est détecté. Mais l'entrée peut être moins « humaine », on peut par exemple utiliser des modules perceptifs liés à des capteurs et ainsi surveiller de nombreux phénomènes.

