

## Modélisation du principe d’ancrage pour la robustesse des systèmes de dialogue homme-machine finalisés

Alexandre Denis    Matthieu Quignard  
UMR 7503 LORIA/CNRS – Campus scientifique  
56 506 Vandoeuvre-lès-Nancy Cedex  
alexandre.denis@loria.fr, matthieu.quignard@loria.fr

**Résumé.** Cet article présente une modélisation du principe d’ancrage (grounding) pour la robustesse des systèmes de dialogue finalisés. Ce principe, décrit dans (Clark & Schaefer, 1989), suggère que les participants à un dialogue fournissent des preuves de compréhension afin d’atteindre la compréhension mutuelle. Nous explicitons une définition computationnelle du principe d’ancrage fondée sur des jugements de compréhension qui, contrairement à d’autres modèles, conserve une motivation pour l’expression de la compréhension. Nous déroulons enfin le processus d’ancrage sur un exemple tiré de l’implémentation du modèle.

**Abstract.** This paper presents a grounding model for robustness in dialogue systems. The grounding process (Clark & Schaefer, 1989) suggests that dialogue participants provide evidence of understanding in order to reach mutual understanding. We propose here a computational definition of the grounding criterion based on understanding judgments that keeps a motivation for providing evidence of understanding, as opposed to some existing models. Eventually, we detail the grounding process on a dialogue generated by the actual implementation.

**Mots-clés :** dialogue homme-machine, robustesse, ancrage, compréhension mutuelle.

**Keywords:** human-machine dialogue, robustness, grounding, mutual understanding.

### 1 Introduction

La campagne EVALDA-MEDIA du projet Technolangues (Bonneau-Maynard *et al.*, 2006) a permis d’évaluer différents systèmes de dialogue élaborés dans des laboratoires français (LIMSI, LORIA, LIA, VALORIA). Cette évaluation consistait à mesurer la capacité des systèmes à produire une représentation sémantique correcte hors et en contexte d’énoncés naturels, recueillis dans un protocole de Magicien d’Oz. Le problème d’une telle évaluation sur corpus réside dans le fait qu’il n’est pas possible de tirer des conclusions sur la robustesse des systèmes lorsqu’ils seront engagés dans des situations réelles. Même si un système atteint un score de compréhension de 80% de couverture sémantique ou référentielle, il n’est pas possible de savoir si les erreurs commises sont critiques ou non vis-à-vis de la réussite du dialogue<sup>1</sup>.

La campagne MEDIA revenait à évaluer la robustesse *interne* des systèmes, c’est-à-dire leur capacité à comprendre l’énoncé sans faire appel à l’utilisateur. Le caractère critique ou non

---

<sup>1</sup>Au mieux, on peut faire l’hypothèse qu’un concept est d’autant plus critique pour la tâche que sa fréquence est élevée dans le corpus, mais est-ce vraiment le cas ?

d'une erreur de compréhension rejoint la problématique de la robustesse *externe* : étant donnée une erreur de compréhension (détectée ou non), le système est-il capable grâce au dialogue d'atteindre la bonne interprétation, par exemple en posant des questions de clarification ?

La gestion de la compréhension mutuelle des participants d'un dialogue constitue le cœur des travaux de Clark, notamment (Clark, 1996), dans la théorie du *grounding* (que nous traduirons par la suite par le terme « ancrage »). Il s'agit du processus par lequel les participants manifestent leur compréhension tout en surveillant, consolidant ou corrigeant l'interprétation que fait leur interlocuteur des énoncés qu'ils produisent.

Nous présentons cette théorie et les différents modèles computationnels qui en découlent dans la section suivante. Nous proposerons ensuite un modèle qui présente l'avantage de définir un critère d'ancrage qui ne requiert pas de croyances *mutuelles* de compréhension tout en motivant le besoin de manifester des preuves de compréhension. Enfin, nous déroulerons le modèle sur un exemple de mauvaise compréhension d'une expression référentielle.

## 2 Modèles d'ancrage computationnels

Le terrain commun est l'ensemble des informations mutuelles qui sert de support aux participants d'un dialogue pour l'interprétation et la production de leurs énoncés. Chaque énoncé provoque la mise à jour de ce terrain commun (Lewis, 1969; Clark, 1996; Stalnaker, 1998).

### Modèle des contributions.

Le modèle des contributions (Clark & Schaefer, 1989) critique les modèles dans lesquels le contenu d'un énoncé est automatiquement ajouté au terrain commun. Il souligne que la mise à jour du terrain commun requiert au préalable l'établissement d'une compréhension de l'énoncé. Clark critique également les modèles qui conditionnent la mise à jour à l'absence de preuve négative de compréhension, car ces modèles ne rendent pas compte de la manifestation *positive* de compréhension tels les *acknowledgements*. Le modèle des contributions suppose alors que pour contribuer au dialogue, les participants cherchent à atteindre une croyance mutuelle de compréhension, modélisée sous la forme d'un critère d'ancrage (*grounding criterion*) : un énoncé est ancré lorsque « *le locuteur et ses interlocuteurs croient mutuellement que les interlocuteurs ont compris suffisamment le locuteur pour les buts courants* ». La volonté d'atteindre ce critère d'ancrage fournit une motivation à la manifestation (positive ou négative) de la compréhension.

Une contribution au dialogue est un acte collaboratif réalisé en deux phases : la présentation d'un énoncé et son acceptation par le partenaire. Lorsque *A* présente un énoncé  $A_i$ , il fait l'hypothèse que s'il reçoit une preuve de compréhension de son partenaire *B*, il peut légitimement croire que *B* a compris  $A_i$ . Lorsque *B* accepte  $A_i$ , il produit une preuve de compréhension en supposant qu'une fois que *A* reçoit cette preuve, *A* croit que *B* comprend l'énoncé. La coordination de ces deux phases constitue le processus d'ancrage. Le critère d'ancrage n'est atteint que lorsque ces deux phases sont terminées, et le cas échéant elles forment une base partagée pour inférer la croyance mutuelle de compréhension (Clark, 1996). Le modèle des contributions n'est toutefois qu'un modèle descriptif, non computationnel.

### Modèle des échanges.

Le modèle des échanges (Cahn & Brennan, 1999) critique le modèle des contributions car

son manque de formalisme le rend inadapté pour le dialogue homme-machine. Celui-ci pose en outre deux problèmes : il ne représente que le résultat final du processus d'ancrage et pas ses étapes intermédiaires, et le fait avec une perspective omnisciente. Le modèle des échanges donne alors une formalisation du processus d'ancrage d'un point de vue interne et incrémental en rajoutant la structure d'échange. Les échanges sont simplement des paires adjacentes de contributions plus à même de modéliser la structure du dialogue homme-machine.

Le modèle des échanges est une version très fidèle du modèle des contributions qui en donne une version computationnelle mais n'en résout pas les principaux problèmes (Denis *et al.*, 2007). Le plus important est sans doute celui posé par le processus d'ancrage, soulevé dans (Traum, 1999) sous le nom de problème de l'*acceptation récursive* : si une contribution a besoin d'être acceptée pour jouer son rôle d'acceptation alors aucune phase d'acceptation ne peut être close. En effet pour que l'énoncé soit ancré, *B* doit savoir si oui ou non *A* a bien reçu sa preuve de compréhension et attendre alors une nouvelle contribution de *A*. Mais comment savoir si cette nouvelle contribution est bien comprise ? *B* doit effectuer un nouvel énoncé, qui lui-même nécessitera d'être accepté avant que l'énoncé initial puisse être ancré, etc.

### Solutions au problème de l'acceptation récursive.

Dans (Clark & Schaefer, 1989), le problème de l'acceptation récursive est résolu par un principe de diminution de preuve de compréhension : pour accepter une preuve il suffit de fournir une preuve moins forte, l'ensemble des preuves pouvant être ordonné. Bien que cette classification soit discutable (Traum, 1999), ce principe n'explique pas pourquoi on peut initier une nouvelle contribution sans manifester explicitement sa compréhension de la preuve.

La solution généralement adoptée est alors de *supposer* la bonne compréhension de cette preuve. Ainsi dans le modèle des *grounding acts* (Traum, 1999), la fonction d'acceptation n'a pas à être acceptée. Dès lors, le problème de l'acceptation récursive ne se pose plus puisque *B* considère que *A* reçoit *correctement* la preuve de compréhension. Cette solution a deux conséquences : d'abord elle entraîne dans ce modèle une structure plate du dialogue, les *discourse units*, qui rassemblent les énoncés qui peuvent être ancrés ensemble. Cette structure est simple à manipuler mais difficile à réinterpréter. Ensuite elle implique que les énoncés qui n'ont qu'une fonction d'acceptation sont automatiquement compris (par exemple les *acknowledgements*). Ce modèle ne peut donc pas expliquer pourquoi on peut observer deux *acknowledgements* d'affilée.

L'approche de (Larsson, 2002) va encore plus loin en supposant la bonne compréhension des énoncés. Ce modèle les considère ancrés par défaut tout en autorisant une possibilité de révision (stratégie prudente). Mais cette stratégie élimine le besoin de fournir des preuves de compréhension : pourquoi le faire puisque l'énoncé est ancré *par défaut* ?

Nous pensons qu'un bon modèle *ne doit pas* ancrer les énoncés par défaut afin de conserver une motivation pour la manifestation positive de leur compréhension. Ces preuves de compréhension jalonnent les dialogues homme-homme ; il nous faut conserver un principe motivant leur emploi. Le problème d'acceptation récursive doit alors être résolu autrement. Nous suggérons de relâcher l'hypothèse forte que le critère d'ancrage n'est atteint qu'avec la croyance *mutuelle* de compréhension. Comme Taylor (1996), nous pensons qu'une croyance *partagée* peut suffire<sup>2</sup>.

---

<sup>2</sup>La croyance mutuelle est la conjonction d'une infinité de croyances réciproques (je crois *p*, tu crois *p*, je crois que tu crois *p*, tu crois que je crois *p*, je crois que tu crois que je crois *p*, etc.), tandis que la croyance partagée est une conjonction finie (jusqu'à un rang *n*).

### 3 Modélisation de l’ancrage

Avant tout il est nécessaire de rappeler que le critère d’ancrage d’un point de vue interne ne requiert qu’une *croyance* de compréhension et non la compréhension *effective*. Dès lors, l’ancrage peut être réalisé à tort. Notre hypothèse est qu’un énoncé joue sa fonction d’acceptation lorsque celui-ci est cru compris ; l’acceptation ne dépend donc pas d’une acceptation ultérieure. Lorsque  $A$  reçoit la preuve de compréhension fournie par  $B$  en  $B_{i+1}$ , il peut estimer si  $B$  a correctement compris son énoncé  $A_i$  et juger de son ancrage. La seule condition est que  $A$  croit avoir compris cette preuve. Son interprétation peut être divergente et entraîner le cas échéant un ancrage *erroné* de  $A_i$ .

Nous proposons alors un principe d’ancrage capable de rendre compte de ce fait, motivant la manifestation de preuve de compréhension tout en considérant que leur interprétation peut être erronée et qu’alors la réinterprétation des preuves de compréhension est nécessaire. Ce principe a été implémenté dans un module adjoint à un système d’interprétation. Son rôle est de spécifier les preuves de compréhension que le système doit manifester afin d’ancrer les énoncés antérieurs.

#### 3.1 Formulation en logique épistémique

Le principe d’ancrage que nous proposons est décrit à l’aide d’une croyance partagée au lieu d’une croyance mutuelle et il est formulé de manière unilatérale afin de rendre compte d’une perspective interne.

**Définition** : « un énoncé est ancré *pour un participant* ssi ce participant entretient la croyance que le locuteur et l’interlocuteur *partagent la croyance* (au rang  $n$ ) que l’interlocuteur a compris suffisamment le locuteur pour les buts courants. »

Cette définition à l’aide d’une croyance partagée unilatérale présente plusieurs avantages. Elle résout le problème de l’acceptation récursive car il n’y a pas de nécessité d’avoir une chaîne infinie de croyances et d’énoncés. Ensuite, elle conserve le besoin de manifester sa compréhension puisqu’elle ne suppose pas que les énoncés sont ancrés *a priori*. De plus, elle autorise la possibilité de construire ces croyances sur la seule base de la rationalité et ainsi de modéliser la stratégie prudente<sup>3</sup> (Larsson, 2002), ou d’autres stratégies qui ne font pas partie du modèle collaboratif. Enfin, elle présente un intérêt computationnel indéniable de par son caractère fini.

Une formulation du principe d’ancrage en logique épistémique permet de mettre en évidence les croyances de compréhension nécessaires à l’ancrage. Au rang deux, que nous supposons suffisant (Taylor *et al.*, 1996), le principe d’ancrage du point de vue des participants  $A$  et  $B$  à propos d’un énoncé  $A_i$  peut être formulé par :

$$Bel_B \text{ Grounded } A_i = Bel_B Und_B A_i \wedge Bel_B Bel_A Und_B A_i$$

$$Bel_A \text{ Grounded } A_i = Bel_A Und_B A_i \wedge Bel_A Bel_B Und_B A_i$$

Le premier intérêt pratique de cette définition est qu’elle met en lumière les deux *modes d’acquisition* de la croyance de compréhension : l’évaluation de sa propre interprétation ( $Bel_B Und_B A_i$ ),

<sup>3</sup>Il suffit de prendre  $n = 1$  pour l’interlocuteur et  $n = 0$  pour le locuteur.

et l'extraction de la preuve de compréhension ( $Bel_B Bel_A Und_B A_i$ ). De plus, étant donné qu'elle distingue l'auteur du jugement ( $Bel_X$ ) et l'auteur de l'interprétation ( $Und_Y$ ), elle permet une représentation unifiée de la non-compréhension et de la mauvaise compréhension (McRoy & Hirst, 1993). La non-compréhension est alors un jugement négatif d'un participant sur sa propre interprétation ( $Bel_X \neg Und_X Y_i$ ), et la mauvaise compréhension un jugement négatif d'un participant sur l'interprétation de son partenaire ( $Bel_X \neg Und_Y X_i$ ).

### 3.2 Modélisation des jugements

Lorsqu'un participant  $S$  reçoit un énoncé  $O_n$  de son partenaire  $O$  il se pose alors les questions de compréhension suivantes, destinées à établir le critère d'ancrage de  $O_n$  et d'énoncés antérieurs ; nous appelons  $S$  (*Self*) le participant dont on adopte le point de vue et  $O$  son partenaire (*Other*) :

$SS$  Est-ce que je juge avoir suffisamment compris l'énoncé de mon partenaire ? ( $Bel_S Und_S O_n$ )

$SO$  Est-ce que je juge que mon partenaire a suffisamment compris mon énoncé antérieur ? ( $Bel_S Und_O S_k$ )

$OO$  Est-ce que (je crois que) mon partenaire juge avoir suffisamment compris mon énoncé antérieur ? ( $Bel_S Bel_O Und_O S_k$ )

$OS$  Est-ce que (je crois que) mon partenaire juge que j'ai suffisamment compris son énoncé antérieur ? ( $Bel_S Bel_O Und_S O_i$ )

Ces quatre types de questions découlent de la combinatoire *auteur du jugement / auteur de l'interprétation* et on notera  $XY$  le jugement de  $X$  sur l'interprétation de  $Y$ . Par exemple  $SO$  est le jugement de  $S$  sur l'interprétation de  $O$  ou  $OO$  le jugement de  $O$  sur sa propre interprétation (mais toujours du point de vue de  $S$ ). Nous utilisons la terminologie du modèle des échanges pour nommer les valeurs de ces jugements. Les jugements positifs et négatifs de  $OO$  ou de  $SS$  seront appelés respectivement  $U$  (UNDERSTOOD) et  $\bar{U}$  (NOTUNDERSTOOD). Les jugements positifs et négatifs de  $SO$  ou  $OS$  seront appelés  $R$  (RELEVANT) et  $\bar{R}$  (NOTRELEVANT). On dira par exemple qu'un énoncé  $O_n$  est  $UR$  lorsque  $SS$  est  $U$  et  $SO$  est  $R$ , et qu'il manifeste  $UR$  lorsque  $OO$  est  $U$  et  $OS$  est  $R$ . Enfin nous noterons dans ce cas  $UR/UR$  pour représenter à la fois la compréhension de l'énoncé et la compréhension qu'il manifeste.

Les jugements négatifs permettent de représenter des catégories globales de problème. Ils ne peuvent être utilisés tels quels et doivent être raffinés par niveau, type et localisation du problème. Le niveau et le type de problème font l'objet de nombreux travaux qui visent à établir une taxonomie d'erreurs, voir par exemple (Paek, 2003; Schlangen, 2004). La localisation du problème doit permettre d'identifier l'unité problématique, différente en fonction du niveau du problème : les mots au niveau lexical, les sens au niveau sémantique, les référents au niveau référentiel, etc.

### 3.3 Acquisition des jugements

La première étape pour déterminer si un énoncé est ancré est d'*acquérir* ces jugements et nous faisons l'hypothèse qu'ils sont acquis lors de la phase d'interprétation. Ces jugements sont d'abord construits, puis utilisés dans un second temps pour produire l'énoncé suivant. Nous ne nous attachons pas ici à élaborer une théorie ou des algorithmes d'acquisition des jugements mais donnons quelques pistes en ce sens.

Les jugements *SS* et *SO* peuvent être modélisés comme des attentes vis à vis de l'interprétation. Le jugement *SS* correspond à l'attente d'une interprétation unique et certaine : une interprétation vide, ambiguë ou incertaine conduit alors à un  $\bar{U}$ . En général le calcul du jugement *SS* s'appuie sur un score de confiance issu de la reconnaissance de la parole ou d'une combinaison de scores à différents niveaux d'analyse (Purver *et al.*, 2006). Si le score est inférieur à un seuil donné, alors l'énoncé est considéré non compris (le jugement *SS* est  $\bar{U}$ ). Le jugement *SO* peut être acquis par la satisfaction d'attentes vis à vis du contenu de l'énoncé d'autrui. Par exemple (Danieli, 1996) repère les occurrences de mauvaise compréhension par la déviation du comportement de l'utilisateur vis à vis des prédictions du système, ou (McRoy & Hirst, 1993) utilise l'abduction pour inférer la cause de la mauvaise compréhension. Pour les jugements *OO* et *OS*, le contenu propositionnel peut expliciter l'existence d'un problème d'interprétation, par exemple « je ne comprends pas » qui manifeste un  $\bar{U}$  ou encore « non, c'est l'hôtel Ibis » qui manifeste un  $UR$ . Mais la prosodie, les marqueurs de discours, les attitudes gestuelles ou le regard sont également des indices sur lesquels on peut fonder la construction de ces jugements (Krahmer *et al.*, 1999; Nakano *et al.*, 2003).

### 3.4 Gestion de la structure du dialogue

Une fois que les jugements de compréhension ont été construits, il est nécessaire de vérifier l'état courant du dialogue afin de déterminer si ces jugements modifient le statut d'ancrage d'un énoncé antérieur. Nous reprenons la proposition du modèle des échanges de représenter explicitement la composante structurelle du processus d'ancrage en maintenant une structure de dialogue. De manière analogue au modèle des échanges, Luzzati (Luzzati, 1995) suggère que le dialogue s'oriente en deux axes : un axe régissant lorsqu'il n'y a pas de problème de compréhension, et un axe incident en cas de phase de clarification. La structure de dialogue du modèle des échanges est très proche des Unités Minimales d'Interaction de Coala (Lehuen, 1997) : un échange initié dans l'acceptation d'une contribution correspond à une UMI incidente.

**Règles de mise à jour.** La structure de dialogue est une structure incrémentale, construite ou révisée en fonction des jugements de compréhension. Nous proposons de représenter les mises à jour comme des opérations sur la structure, déclenchées en fonction des jugements de et portés par l'énoncé courant  $O_n$ . Il existe deux types de règles. Les règles de  $\bar{U}$  ou de  $UR$  impliquent que la réaction du système est entièrement déterminée par la résolution de la divergence, par exemple grâce à l'initiation d'un échange incident. Les règles de  $UR$  impliquent que la réaction du système est déterminée par l'ancrage d'autres énoncés et/ou par la gestion de la tâche (Denis *et al.*, 2007). En effet lorsqu'un énoncé  $O_n$  est  $UR/UR$  et clôt un échange incident, il provoque la *réinterprétation* de l'énoncé accepté  $O_i$ , entraînant alors le besoin d'effectuer un nouveau jugement de compréhension sur  $O_i$  et alors de décider en fonction de ce nouveau jugement les opérations à effectuer. Le cas échéant, le processus d'ancrage s'applique sur  $O_i$  et sur  $O_n$ . Le modèle des *grounding acts* ne considère pas la réinterprétation des jugements puisque les preuves de compréhension sont supposées ancrées par défaut.

**Réinterprétation.** La réinterprétation consiste à effectuer de nouveau l'interprétation d'un énoncé  $O_i$  grâce à de nouvelles informations apportées par un énoncé  $O_n$ , soit qu'il s'agit d'une réponse à un  $\bar{U}$  initié par  $S$ , ou soit qu' $O_n$  manifeste un  $UR$ . La différence principale tient au fait que dans le premier cas l'interprétation est jugée problématique *a priori* et dans le second elle

l'est *a posteriori*. Dans les deux cas l'altération de l'ancienne interprétation et du contexte peut conduire à réviser la structure du dialogue (voir l'effet de l' $UR$  dans le modèle des échanges) ainsi que les jugements de compréhension de et portés par  $O_i$ . L'acquisition de nouveaux jugements permet alors de réagir à l'évolution de la compréhension. Par exemple le fait qu'un énoncé  $\bar{U}$  demeure  $\bar{U}$  malgré l'emploi d'une stratégie donnée suggère que le problème doit être abordé avec une stratégie différente. Le fait que *plusieurs* interprétations se produisent lorsqu'on reçoit un énoncé entraîne que la sortie du module d'ancrage est une *liste* de jugements de compréhension.

### 3.5 Production des preuves de compréhension

Enfin, lorsque les jugements de compréhension ont été calculés et recalculés, la structure de dialogue mise à jour et toutes les réinterprétations effectuées, il est nécessaire de produire l'énoncé suivant. Une stratégie naïve du type « Je ne comprends pas. Veuillez reformuler. » n'a que peu de chances de parvenir à la convergence essentiellement parce que la manifestation de la non-compréhension est trop pauvre : elle n'indique que l'existence d'un problème. Par exemple « Je ne comprends pas "cet hôtel". C'est vide. Quel hôtel ? » contient quatre indices permettant à l'utilisateur d'inférer le problème :

- « Je ne comprends pas » qui manifeste l'*existence* d'un problème d'interprétation,
- « "cet hôtel" » qui désigne la *couverture lexicale* du problème,
- « C'est vide. » qui présente l'*état* dans lequel se trouve le système (ici le *type de problème* rencontré),
- « Quel hôtel ? » qui correspond à la requête destinée à résoudre le problème.

Ces indices sont construits lorsque le système établit les jugements  $SS$  et  $SO$ . Leur manifestation dans le dialogue en fait des *preuves* de compréhension, traduisant l'état des participants relativement à l'ancrage.

Enfin, le système doit être capable d'exprimer l'ensemble des jugements qu'il effectue à l'aide de *plusieurs* preuves de compréhension dans un même énoncé. Nous proposons de coordonner ces preuves au moyen de connecteurs discursifs, afin de manifester explicitement le résultat de la réinterprétation (Byron & Heeman, 1997). Ces marqueurs fournissent un compte-rendu des raisonnements effectués et de l'état dans lequel se trouve le système : si la réinterprétation aboutit à un jugement  $UR$  de l'énoncé, alors utiliser « donc », si elle aboutit à un jugement  $\bar{U}$  ou  $UR$ , alors utiliser « mais ».

## 4 Exemple détaillé

L'exemple que nous proposons (figure 4), issu de l'implémentation du modèle, illustre la gestion de deux phénomènes : une mauvaise interprétation suivie d'un échec de réinterprétation. Le dialogue ne s'applique pas sur une tâche extra-linguistique, le seul but du système  $S$  est ici d'ancrer l'interprétation des expressions référentielles de l'utilisateur  $O$ . Pour cet exemple, les jugements sont calculés de manière très simple :  $SS$  ne s'appuie que sur le résultat de la résolution de la référence,  $SO$  n'est pas calculé,  $OO$  et  $OS$  sont déduits de la force illocutoire et du contenu propositionnel (par exemple, un « non » qui n'est pas précédé d'une question fermée manifeste un  $UR$ ).



sion de  $O_4$ , de  $O_2$ , traduites par des « OK » et de  $O_0$ , traduite par une paraphrase, coordonnant les deux dernières par un « donc ».  $S_5$  clôt l’échange initié par  $O_0$  (voir figure 2-c).

## 5 Conclusion et perspectives

Le modèle d’ancrage que nous avons présenté a pour avantage de s’appuyer sur des croyances de compréhension finies tout en motivant le besoin de fournir des preuves de compréhension. Ces preuves sont la manifestation des jugements de compréhension que chaque participant élabore lorsqu’il interprète les énoncés de son partenaire. Le modèle permet de rendre compte de la non-compréhension ou de la mauvaise compréhension, qu’elle soit issue de l’interprétation ou de la réinterprétation. Il souffre toutefois de nombreuses limitations : la plus importante est qu’il ne considère que les tours de parole *mono-contributifs*. En effet, un locuteur peut fournir *plusieurs* preuves de compréhension, et si nous avons rendu compte de leur *production*, l’*interprétation* de ces preuves multiples soulève des problèmes difficiles quant à la gestion de la structure du dialogue. La seconde limitation est que le modèle se limite à la non-compréhension de ces dernières (Denis *et al.*, 2007) et pas à leur mauvaise compréhension en raison de la complexité de la réinterprétation des preuves. Il s’agit pourtant d’un enjeu majeur étant donné la difficulté des systèmes à percevoir qu’ils ne comprennent pas.

Pour évaluer si ces limitations ont un impact sur la robustesse du système, l’évaluation MEDIA ne saurait être suffisante en raison de sa nature statique. Il est nécessaire, afin d’évaluer la robustesse externe de pouvoir évaluer le système dans l’interaction. Nous nous orientons vers le paradigme SIMDIAL (Allemandou, 2007) qui permet d’évaluer un système en simulant un utilisateur de manière déterministe. Le but du dialogue est alors l’ancrage des énoncés proposés par l’utilisateur simulé. L’évaluation consiste à déterminer si le système *peut* atteindre l’interprétation de l’utilisateur par le dialogue et *comment* il peut l’atteindre. Nous espérons en particulier retirer de cette évaluation des indices fins quant aux meilleures stratégies à employer pour la convergence de l’interprétation.

## Références

- ALLEMANDOU J. (2007). *SIMDIAL, un paradigme d’évaluation automatique de systèmes de Dialogue homme-machine par simulation déterministe d’utilisateurs*. PhD thesis, Université Paris Sud, Orsay.
- BONNEAU-MAYNARD H., AYACHE C., BÉCHET F., DENIS A., KHUN A., LEFÈVRE F., MOSTEFA D., QUIGNARD M., ROSSET S., SERVAN C. & VILLANEAU J. (2006). Results of the french evalda-media evaluation campaign for literal understanding. In *Proceedings of the Language Resources and Evaluation Conference*, Gênes, Italie.
- BYRON D. & HEEMAN P. (1997). Discourse marker use in task-oriented spoken dialog. In *Proceedings of Eurospeech’97*, p. 2223– 2226, Rhodes, Grèce.
- CAHN J. & BRENNAN S. (1999). A psychological model of grounding and repair in dialog. In *AAAI Fall Symposium on Psychological Models of Communication in Collaborative Systems*, Sea Cliff, MA.
- CLARK H. (1996). *Using Language*. Cambridge University Press.

- CLARK H. & SCHAEFER E. (1989). Contributing to discourse. *Cognitive Science*, **13**, 259–294.
- DANIELI M. (1996). On the use of expectations for detecting and repairing human-machine miscommunication. In *AAAI-96 Workshop on Detecting, Preventing, and Repairing Human-Machine Miscommunications*, Portland, OR.
- DENIS A., PITEL G., QUIGNARD M. & BLACKBURN P. (2007). Incorporating asymmetric and asynchronous evidence of understanding in a grounding model. In *Proceedings of DECA-LOG, the 11th International Workshop on the Semantics and Pragmatics of Dialogue*, Trento, Italie.
- KRAHMER E., SWERTS M., THEUNE M. & WEEGELS M. (1999). Problem spotting in human-machine interaction. In *Eurospeech 1999*, p. 1423–1426, Budapest, Hongrie.
- LARSSON S. (2002). *Issue-based Dialogue Management*. PhD thesis, Goteborg University.
- LEHUEN J. (1997). *Un modèle de dialogue dynamique et générique intégrant l'acquisition de sa compétence linguistique - Le système Coala*. PhD thesis, Université du Maine - Le Mans.
- LEWIS D. (1969). *Convention: A Philosophical Study*. Harvard University Press.
- LUZZATI D. (1995). De l'erreur en DHM. *Cahiers de Linguistique Française*, **16**, 175–192.
- MCROY S. & HIRST G. (1993). Abductive explanations of dialogue misunderstanding. In *6th Conference of the European Chapter of the Association for Computational Linguistics*, p. 277–286, Utrecht, Pays-Bas.
- NAKANO Y., REINSTEIN G., STOCKY T. & CASSELL J. (2003). Towards a model of face-to-face grounding. In *Proceedings of Association for Computational Linguistics*, Sapporo, Japon.
- PAEK T. (2003). Toward a taxonomy of communication errors. In *ISCA Workshop on Error Handling in Spoken Dialogue Systems*, p. 53–58, Château d'Oex, Vaud, Suisse.
- PURVER M., RATIU F. & L.CAVEDON (2006). Robust interpretation in dialogue by combining confidence scores with contextual features. In *INTERSPEECH: International Conference on Spoken Language Processing*, Pittsburgh, PA.
- SCHLANGEN D. (2004). Causes and strategies for requesting clarification in dialogue. In *Proceedings of SIGDial, Workshop on Discourse and Dialogue*, Boston, MA.
- STALNAKER R. (1998). On the representation of context. *Journal of Logic, Language and Information*, **7**(1), 3–19.
- TAYLOR J. A., CARLETTA J. & MELLISH C. (1996). Requirements for belief models in cooperative dialogue. *User Modeling and User-Adapted Interaction*, **6**(1), 23–68.
- TRAUM D. R. (1999). Computational models of grounding in collaborative systems. In *Working Papers of the AAI*, p. 124–131, Menlo Park, California: AAI.