De l'intérêt de la notion de *chaîne de référence* par rapport à celles d'*anaphore* et de *coréférence*

The virtues of the notion of referential chain when compared to the notions of anaphora and coreference

Catherine Schnedecker

Édition électronique

URL : <http://journals.openedition.org/praxematique/5339>

ISSN : 2111-5044

Éditeur

Presses universitaires de la Méditerranée

Référence électronique

Catherine Schnedecker, « De l'intérêt de la notion de *chaîne de référence* par rapport à celles d'*anaphore* et de *coréférence* », *Cahiers de praxématique* [En ligne], 72 | 2019, mis en ligne le 26 juin 2019, consulté le 08 septembre 2020. URL : <http://journals.openedition.org/praxematique/5339>

Ce document a été généré automatiquement le 8 septembre 2020.

Tous droits réservés

De l'intérêt de la notion de *chaîne de référence* par rapport à celles d'*anaphore* et de *coréférence*

The virtues of the notion of referential chain when compared to the notions of anaphora and coreference

Catherine Schnedecker

Introduction

- 1 La notion de *chaîne de référence* (désormais CR)¹ est une notion plus récente que celle d'*anaphore*, puisqu'elle est apparue en 1975, sous la plume de Chastain (1975), et a été relayée par Corblin (1985, 1995) puis Charolles (1988) pour qui :

Les chaînes sont constituées par des suites d'expressions coréférentielles [...]. Seules peuvent appartenir (donner lieu à) une chaîne des expressions employées référentiellement, c'est-à-dire toutes et rien que les expressions nominales (ou pronominales) permettant d'identifier un individu (un objet de discours) quelle que soit sa forme d'existence (personne humaine, événement, entité abstraite). (Charolles, 1988 : 8)

- 2 C'est ce qui explique que, à la différence de notions déjà plus anciennement ancrées dans l'outillage linguistique, comme celles d'*anaphore* ou de *coréférence*, définies d'ailleurs par la plupart des grammaires dites d'usage, la notion de CR reste absente de la plupart des index.

(...) une expression est anaphorique si son interprétation référentielle dépend nécessairement d'une autre expression qui figure dans le texte. (Riegel *et al.*, 2009 : 1029)

- 3 C'est ainsi que la *Grammaire Méthodique du Français* évoque la notion d'*anaphore* qui rend compte de ce que, dans [1] :

[1] « (p1) Depuis trois jours la seule distraction de Mme de Rênal avait été de tailler et de faire faire en toute hâte par Elisa **une robe d'été**, d'une jolie

petite étoffe fort à la mode. (p2) A peine **cette robe** put-**elle** être terminée quelques instants après l'arrivée de Julien ; (p3) Mme De Rênal **la** mit aussitôt. » (Riegel et al., 2009 : 1029, chapitre 24, « Texte et discours »)

- 4 les SN *cette robe* et *la* ne peuvent s'interpréter sans la mention de *une robe d'été* :

Dans cet extrait de Stendhal, deux termes sont anaphoriques : le référent du groupe nominal *cette robe* et du pronom personnel *la* s'identifient à partir d'une robe d'été. (Riegel et al., *ibid.*)

- 5 Il n'est pas précisé, en revanche, que ce court extrait évoque en fait la fameuse robe plus longuement, par le biais de quatre mentions (*une robe d'été*, *cette robe*, *elle*, *la*), unies non seulement par la relation d'anaphore mais également par un lien de coréférence², de sorte qu'on peut considérer que ces quatre expressions référentielles constituent une chaîne de référence permettant de suivre durant cette brève portion de texte le « devenir » discursif de la robe. C'est ce qui explique qu'on ait pu, comme Charolles, schématiser ce suivi par une série de points espacés figurant la réinstanciation d'un référent dans le texte (cf. figure 1) :

Figure 1 : Schématisation des chaînes de référence selon Charolles (1988)

- 6 Autrement dit, la notion de CR sert à appréhender le déroulement ou encore le suivi de l'expression référentielle dans sa *continuité textuelle ou discursive*. Ce qui suppose, comme le dit Corblin (1995), que :

Chaîne permet de dépasser les contextes de simple succession de deux termes auxquels se limite le plus souvent le linguiste qui sort du domaine phrastique. (Corblin, 1995 : 173).

- 7 La notion de CR se distingue ainsi, en première instance, de celle d'*anaphore* ou de *coréférence* par le nombre-plancher d'expressions référentielles impliquées dans la relation qui, pour les CR, suppose d'être supérieur à deux.
- 8 Cette différence « numérique » est beaucoup moins triviale qu'elle n'en a l'air, car elle draine tout un ensemble de questions que ne prennent pas en compte les notions d'*anaphore* ou de *coréférence*. Ce sont ces aspects que le présent article va passer en revue. Nous commencerons par rappeler les définitions et différences établies pour ces trois notions. Dans un second temps, nous montrerons en quoi une approche des CR doit prendre en compte la linéarité des textes ainsi que leur genre discursif d'occurrence, ce qui suppose la mise en œuvre de paramètres particuliers. Ainsi espérons-nous faire valoir l'idée que la notion de CR n'est pas une notion linguistique « gadget » de plus, mais qu'elle est à même de capter véritablement la référence discursive.

1. Anaphore/coréférence/chaîne de référence : rappels théoriques et aspects formels

- 9 Compte tenu du fait que les notions d'*anaphore* et de *coréférence* continuent à poser des difficultés :

The notions of coreference and anaphora are difficult to define precisely and to operationalize consistently. Furthermore, the connections between them are extremely complex. (Stoyanov et al., 2009 : 657)

nous commencerons par passer en revue leurs principales différences.

- 10 La première, fondamentale, tient à la teneur référentielle des expressions et, partant, aux mécanismes interprétatifs qu'elles sont susceptibles de déclencher. Elle est due également au fait que les relations anaphoriques et coréférentielles présentent des propriétés formelles différentes que nous allons rappeler dans cette section.

1.1. La nature des expressions référentielles en cause

- 11 En effet, la relation anaphorique suppose la mise en relation d'une expression non autonome du point de vue de la référence et d'une expression référentielle susceptible de la « saturer » pour reprendre ici les termes de Corblin (1995)³. De sorte que, suivant la conception de Milner (1982),

il y a relation d'anaphore entre deux unités A et B quand **l'interprétation de B dépend crucialement de l'existence de A**, au point que l'on peut dire que l'unité B n'est interprétable que dans la mesure où elle reprend entièrement ou partiellement A. (Milner, 1982, souligné par nous)

- 12 Par ailleurs, comme l'ont démontré bon nombre d'études (Charolles, 1991 ; Kleiber, 1991), la relation d'anaphore ne suppose pas, loin s'en faut, la coréférence et diverses typologies font état de tout un ensemble de relations anaphoriques sans coréférence, parfois fédérées sous le terme hyperonyme d'*anaphore indirecte* (Erkù & Gundel, 1987), qui recouvre de nombreuses sous-catégories comme celles d'anaphore conceptuelle (« lexicale », chez Milner, 1982 : *Paul a tué trois lions. Pierre en a tué cinq*)⁴, associative (*l'église...les vitraux... l'autel*, d'après Guillaume, 1919, in Riegel et al., 2009 : 1039), générique (*Paul a acheté une Toyota, car elles/ces voitures sont robustes* in Webber, 1983 cité par Kleiber, 1991), possessive (*Paul... son chien...*), collective (*A Strasbourg, ils roulent comme des fous*, Kleiber, 1991), etc.

- 13 Par contraste, les notions de *coréférence* et de *chaîne de référence* supposent une forme d'identité référentielle⁵ entre les référents évoqués par les expressions référentielles, qui ne repose, ni nécessairement ni exclusivement, sur la relation d'*anaphore*, comme l'illustre [2] où les trois premiers « maillons » (ou mentions) sont des expressions référentiellement autonomes, qui donnent, si l'on peut dire, « directement » accès au référent visé, tandis que le pronom établit une relation d'anaphore coréférentielle avec les mentions antérieures (cf. *infra*) :

[2] « Barak Obama... Le 44^{ième} président des Etats-Unis.... L'époux de Michelle Robinson Il...

- 14 « On confond souvent les deux notions de *coréférence* et d'*anaphore*. Elles sont pourtant distinctes. Il y a relation de coréférence entre deux unités référentielles A et B quand

elles se trouvent avoir la même référence – ce qui peut arriver sans que l'interprétation de l'une soit affectée par l'interprétation de l'autre. » (Milner, 1982 : 32)

- 15 Notons au passage que, à la différence de la notion d'*anaphore*, les termes métalinguistiques visant à appréhender celle de *chaîne de référence* restent encore très fluctuants dans la plupart des travaux qu'ils soient d'obédience linguistique ou taliste : on parle ainsi de *cohesive chains*, de *coreferential chains*, de *coréférences* au pluriel.

1.2. Nature formelle des relations d'anaphore et de coréférence

- 16 À Milner (1982 : 32-33), on doit d'avoir tiré des deux relations d'anaphore et de coréférence deux propriétés en miroir, si l'on peut dire⁶. D'une part, la relation de coréférence entre deux unités est symétrique (i) et transitive (ii) :
- 17 Si A est coréférent à B alors B est coréférent à A
- 18 Si A est coréférent à B et B est coréférent à C alors A est coréférent à C
- 19 Par contraste, « la relation d'anaphore est une relation asymétrique » selon Milner (*op. cit.* 32)⁷ qui illustre son propos par une série d'exemples :
- 3a) Un livre... il... il... le ...
- 3b) Un livre... le livre ... le livre...
- 3c) Un livre... il... le livre...
- 3d) Un livre... le livre ... il...
- 20 Les expressions ne sont pas autonomes dans ces exemples (cf. ex. 2-4-5-6, de Milner, 1982 : 33) où, dit Milner, « il est clair que chaque pronom *il* ou *le* reprend *un livre*. En revanche, il n'est pas vrai que *le*, par exemple, reprenne le pronom *il* immédiatement précédent ». D'où le principe suivant :
- Un pronom anaphorique ne peut jamais fonctionner comme le premier terme d'une relation d'anaphore. (Milner, *op. cit.*, 33).
- 21 Il en irait de même pour (3b et 3c). Il n'y a que dans les cas de (3d) que Milner renonce à l'application du principe de non transitivité arguant du fait que « le livre peut être considéré comme anaphorisé par *il* ».
- 22 Ces propos ont suscité de nombreuses réactions de la part de linguistes, voire de psycholinguistes, critiquant une conception de l'anaphore considérée comme « antécédentiste » trop liée à une source localisée en amont du texte et déniait à l'anaphore pronominale la possibilité de remonter indéfiniment à une expression non anaphorique, avec force contre-exemples linguistiques et psycholinguistiques⁸.

1.3. Incidences méthodologiques

- 23 Ce rappel sur les notions d'*anaphore* et de *coréférence* paraît d'autant plus utile que celles-ci fondent en quelque sorte des méthodes d'investigation dans le domaine du TAL (Landragin, 2011, 2016a et b, 2017). En effet, il est d'usage d'invoquer, dans ces travaux, deux approches.
- 24 La première, appelée "*pairwise (or mention-pair) model*"⁹ se rapprocherait d'une tendance héritée des modes d'approche de l'anaphore qui consistent pour l'essentiel à analyser des couples, généralement contigus, d'expressions référentielles :

work in terms of pairs of mentions, classifying two mentions as either coreferent or non-coreferent, and then combining all the pairwise decisions to partition the document mentions into coreference chains. (Recasens Potau, 2010 : 7)¹⁰

- 25 La seconde, fondée sur les entités (“*entity-based model*” ou “*entity mention model*”), se rattacherait davantage à une visée coréférentialiste appréhendant des lots, ensembles, etc. d’expressions référentielles entretenant une relation de coréférence. Ces modèles “are meant to improve the classification by determining not the probability that a mention corefers with a previous mention but the probability that a mention refers to a previous entity, i.e., a set of mentions already classified as coreferent. Thus, the latter often employ clustering strategies.” (Recasens Potau, 2010 : 7)
- 26 Ces modèles ont fait et continuent à faire l’objet de nombreux débats, qui insistent unanimement sur les limites du premier, dont les faiblesses (évoquées par la revue de Ng, 2010 : 1400) tiennent, d’une part, à ce que l’antécédent d’une expression donnée est sélectionné uniquement en vertu de ses propriétés intrinsèques et non pas par comparaison avec d’autres antécédents possibles. D’autre part, – et l’on touche les limites de la relation de transitivité telle qu’appliquée dans ce type de travaux – les erreurs d’appariement induites par l’application de la relation de transitivité ne sont pas inenvisageables :

Consider an example (...), where a document consists of three NPs: « Mr. Clinton », « Clinton » and « she ». The mention-pair model may determine that « Mr. Clinton » and « Clinton » are coreferent using string matching features, and that « Clinton » and « she » are coreferent based on proximity and lack of evidence for gender and number disagreement. However, these two pairwise decisions together with transitivity imply that « Mr. Clinton » and « she » will end up in the same cluster, which is incorrect due to the gender mismatch » (Ng, art. cit., 1400)¹¹

- 27 Cela étant, la plupart des travaux actuels, d’inspiration TAL et/ou linguistique travaillant sur la question de la coréférence, exploitent la notion de *chaîne de référence* comme une virtualité. En effet, dans ces travaux, les expressions coréférentielles sont d’abord et avant tout – et souvent même exclusivement – des classes d’expressions référentielles équivalentes, conséquence directe des propriétés formelles de la relation de coréférence¹², au point que l’on peut parler d’une conception des chaînes de référence « paradigmatique » ou « paradigmaticiste »¹³ :

De façon plus concrète, le fait que les relations de coréférence soient des relations d’équivalence implique qu’il est possible de partager les éléments référentiels d’un texte en chaînes coréférentielles (classes d’équivalence) telles que toutes les expressions coréférentielles appartenant à une même chaîne de coréférence soient plus ou moins interchangeables (ou équivalentes) entre elles. (Boudreau, 2004 : 6. 21)

- 28 Cette conception, que nous nommons « paradigmatique », est appuyée par les propos soulignés dans les citations qui suivent :

(...) the outputs of coreference resolution are *collections of mentions* of different types (referential pronouns and their antecedents, proper nouns, definite NPs, discourse segments, etc.) that refer to the same discourse entity. (Recasens Potau, 2010: 26, souligné par nous)

By building the coreference chains present in a text, we can identify all the information about one entity. From a computational perspective, the identification of coreference links is crucial for a number of applications such as information extraction, text summarization, question answering, and machine translation (McCarthy and Lehnert, 1995; Steinberger *et al.*, 2007; Morton, 1999). From a linguistic point of view, capturing the way a discourse entity is repeatedly referred

to throughout a discourse makes it possible to obtain the different ways an entity can be linguistically expressed. (Recasens Potau, 2010: 47)

The point of departure for this thesis was the problem of coreference resolution, one of the challenging tasks for Natural Language Processing (NLP). It is usually defined as either “the problem of identifying which noun phrases (NPs) or mentions refer to the same real-world entity in a text or dialogue” (Ng, 2009; Stoyanov *et al.*, 2009; Finkel and Manning, 2008) or, in slightly different terms, “the task of grouping all the mentions of entities in a document into equivalence classes so that all the mentions in a given class refer to the same discourse entity”. (Bengtson & Roth, 2008 ; Denis & Baldridge, 2009). (Recasens Potau, 2010 :1)

- 29 Ces propos montrent bien que la coréférence est assimilée à une classe de mentions équivalentes.

2. Conception « syntagmatisante » de la notion de chaîne de référence

- 30 Or, dès l'instant où l'on admet que la notion de *chaîne de référence* rend compte non seulement d'un ensemble d'expressions coréférentielles équivalentes, mais que celles-ci sont également assujetties à la linéarité de leur (con-)texte d'occurrence, apparaît tout un ensemble de facteurs que les approches évoquées ci-dessus ne prennent pas toujours en considération¹⁴.

2.1. Un ensemble de mesures permettant d'appréhender les chaînes de référence dans leur déroulement linéaire

- 31 Soit les trois séries de symboles suivantes, destinées à matérialiser les maillons/mentions de trois chaînes distinctes figurant dans un même texte :

Figure 2 : Matérialisation des maillons/mentions de trois chaînes de référence distinctes

- 32 Pour décrire les trois chaînes et mettre au jour leurs différences, il faut adopter un système de mesures permettant de rendre compte de la manière la plus objective possible d'un certain nombre de facteurs¹⁵ relatifs aux « maillons » de ces CR :
- 33 - leur nombre rapporté au nombre de référents et à ceux qui font l'objet d'une CR,
- 34 - leur *longueur* – et, corollairement, leur complexité syntaxique – qui peut, selon les genres de discours (on aura l'occasion d'y revenir) se révéler parfois substantielle comme le montre la mention en gras de l'exemple ci-dessous, qui illustre une expression référentielle qui s'étend sur trois lignes et demie et comprend de multiples enchâssements dûs aux expansions de diverses natures (relative, compléments du nom) :

[3] « Convention médicale juillet 2016 14

(...)

Article 4.2 Bénéficiaires du contrat d'installation

Ce contrat est proposé aux médecins remplissant les conditions cumulatives suivantes :

1. s'installer en exercice libéral dans une zone caractérisée par une insuffisance de l'offre de soins ou des difficultés d'accès aux soins définies au 1° de l'article L. 1434-4 du code de la santé publique ou dans **[des zones où les besoins en implantation de professionnels de santé ne sont pas satisfaits définies conformément au cinquième alinéa de l'article L. 1434-7 du code de la santé publique dans sa rédaction antérieure à la loi n° 2016-41 du 26 janvier 2016 de modernisation de notre système de santé,]** (...). » (Convention Nationale organisant les rapports entre les médecins libéraux et l'assurance maladie, signée le 25 août 2016. *Journal Officiel de la République*, 23 octobre 2016, p. 10)

- 35 - leur coefficient de stabilité que Perret (2000) définit comme suit :

on proposera le concept de *coefficient de stabilité*, obtenu en divisant, pour un référent donné (un personnage), le nombre total d'anaphores nominales par le nombre de désignations différentes. (Par exemple, dans la *Mélusine* de Jean d'Arras, pour la désignation de l'héroïne on rencontre 164 anaphores nominales, et 17 désignations différentes ; le coefficient de stabilité est donc $164/17 = 9,64$) (Perret, 2000 : 17)

- 36 Ainsi l'extrait [4] comprend-il cinq SN et quatre désignations différentes. D'où un coefficient de stabilité¹⁶ très faible de 1,25, résultat du nombre de mentions total divisé par le nombre de mentions différentes, qui reflète la diversité des SN utilisés pour construire la chaîne désignant Catherine Ringer :

[4] *Catherine Ringer*, c'est comme ça

Par Florian Bardou — 21 février 2018

A fleur de peau, **la chanteuse** part en tournée et tente d'apprendre à vieillir. Elle dit qu'elle « *ne raconte rien d'intéressant* » et qu'elle préférerait qu'on fasse « *une critique* » de son album, *Chroniques et Fantaisies*. **Catherine Ringer**, coiffée d'une longue tresse sous un béret rouge de feutrine, coupe court à notre discussion fébrile et décousue. Ce n'est pas personnel : c'est juste qu'elle n'aime pas parler d'elle. Qui plus est, elle sort d'une bronchite et elle a l'impression de ressasser « *des banalités* ». Des confrères nous ont averti que l'interview ne serait pas facile à conduire, que **la chanteuse sexagénaire**, diva pop que l'on adule depuis les après-midi adolescentes à écouter RTL2, a son tempérament et qu'elle veut garder « *une part de mystère* ». Autrement dit, que **l'ex-moitié des Rita Mitsouko** ne se laisse pas malmener et se protège derrière une définition extensive de la notion de « vie privée ». (<http://>

next.liberation.fr/musique/2018/02/21/catherine-ringer-c-est-comme-ca_1631366)

- 37 Les mesures doivent appréhender également les paramètres suivants :
- 38 - *le nombre de chaînes* dans le texte, qui ne coïncide pas nécessairement avec le nombre de référents qui y sont instanciés (par exemple, dans le texte [4], les mentions *une longue tresse* et *un béret rouge de feutrine* ne font pas l'objet d'une reprise) ;
- 39 - *la longueur* des chaînes, variable ici, qui se calcule généralement en nombre de maillons/mentions (dans la figure 2, respectivement 6, 10 et 3) ;
- 40 - *la distance inter-maillonnaire*, popularisée par les travaux d'Ariel (1990) comme facteur corrélé à la saillance référentielle et abondamment reprise dans de nombreux travaux. Cette mesure, qui paraît simple, pose en soi tout un ensemble de questions relatives : i) aux modalités de calcul : faut-il appréhender la distance en nombre de syllabes (Lust, 1981), de mots (Gernsbacher, 1990 ; Kibrik, 2011), de SN (Boudreau & Kittredge, 2005), de phrases (Givón, 1983), de nœuds rapportés à la structure rhétorique des textes (Kibrik, 2011) ? ii) aux termes du calcul : faut-il entamer le décompte à partir du premier mot de la mention ? de la tête du SN (Oberlé, 2016) qui permet de prendre en compte les SN enchâssés ([5]) ?

[5] [Le petit chat [**que** la voisine a acheté hier]] [l'animal]....-

- 41 - *la portée* des chaînes, entendue par Boudreau & Kittredge (2005) comme le pourcentage de texte couvert par chaque chaîne, qu'on appréhende concrètement par le nombre de paragraphes couverts par une même chaîne (Oberlé, 2016 ; Oberlé *et al.*, 2018) ainsi que par la relation de contiguïté que ces paragraphes entretiennent les uns avec les autres ;
- 42 - *la persistance des CR*, définie par Givón (1983) par le nombre de mentions antérieures et subséquentes à un point référentiel donné ;
- 43 - les unités typo-dispositionnelles qu'elles couvrent : paragraphes, domaines sémantiques, etc.
- 44 - la composition des CR : catégories et fonctions grammaticales des maillons ;
- 45 - l'ordre d'apparition des CR dans le texte ;
- 46 - le mode de cohabitation des chaînes les unes avec les autres (succession, entrecroisement, fusion, dissociation, parallélisme).
- 47 Exception faite de la distance, ces mesures ne sont pas toujours toutes prises en compte dans les travaux sur la référence en discours (Kibrik, 2011) ou sur l'annotation de la coréférence (Recasens, 2010 ; Swanson, 2003) alors qu'elles aident à mettre au jour bon nombre de facteurs qui rendent effectivement compte des effets de la linéarisation des expressions coréférentielles d'un texte, autrement dit de la spécificité des chaînes de référence.

2.2. La question des limites

- 48 Les chaînes de référence, dans la mesure où elles appréhendent la coréférence sur du long terme et au long cours, constituent de ce fait, par essence, une forme de suivi référentiel (certaines études parlent de *participant tracking* ou de *reference tracking*) qui invite à s'interroger sur leur délimitation ou encore leur borne initiale et/ou finale.

Cette question semble également triviale lorsque les contextes d'analyse des chaînes de référence se constituent de résumés de films permettant de capter les formes de suivi référentiel dans leur intégralité où la borne finale coïncide avec la fin du texte comme dans [6] :

[6] 1976. Après l'échec de **son** mariage, **Agnès Le Roux** rentre d'Afrique et retrouve **sa** mère, Renée, propriétaire du casino Le Palais de la Méditerranée à Nice. **La jeune femme** tombe amoureuse de l'homme de confiance de Renée, Maurice Agnelet, un avocat de dix ans **son** aîné. Maurice a d'autres liaisons. **Agnès** l'aime à la folie. Actionnaire du Palais de la Méditerranée, **Agnès** veut vendre **sa** part de l'héritage familial pour voler de **ses** propres ailes. Une partie truquée siphonne les caisses de la salle de jeux. On menace Renée. Derrière ces manœuvres guerrières plane l'ombre de la mafia et de Fraton le patron du casino concurrent qui veut prendre le contrôle du Palais de la Méditerranée. Tombé en disgrâce auprès de Renée, Maurice met en relation **Agnès** avec Fraton qui **lui** offre trois millions de francs pour qu'**elle** vote contre **sa** mère. **Agnès** accepte le marché. Renée perd le contrôle du casino. **Agnès** supporte mal **sa** propre trahison. Maurice s'éloigne. Après une tentative de suicide, **la jeune femme** disparaît à la Toussaint 1977. On ne retrouvera jamais **son** corps. Trente ans après, Maurice Agnelet demeure l'éternel suspect de ce crime sans preuve ni cadavre. Convaincue de sa culpabilité, Renée se bat pour qu'**il** soit condamné... (résumé du film *L'homme qu'on aimait trop* : http://www.allocine.fr/film/fichefilm_gen_cfilm=218308.html)

- 49 Cependant, à l'heure où l'on essaie de modéliser les CR sur de grands corpus¹⁷, il paraît nécessaire de se demander si la chaîne d'un référent donné dans un long texte, que ce soit un roman, par exemple celle d'E. Lantier dans *Germinal*, ou un essai, couvre sans interruption l'ensemble du texte¹⁸.
- 50 En effet, les CR constituent l'un des plans de l'organisation textuelle (Charolles, 1988 ; cf. la figure 1 *supra*) ou de la textualité (opérations de liage, selon Adam, 2015). De ce fait, elles interagissent avec les autres plans de la structuration textuelle, comme le découpage du texte en paragraphes ou en domaines sémantiques marqués par des expressions cadratives (Charolles, 1995). Dans l'extrait [7], le découpage du texte en paragraphes et en domaines temporels (expressions grisées) coïncide systématiquement avec le nom propre au point que certains auteurs (Marslen-Wilson *et al.*, 1982 ; Tomlin, 1987), parlent de *réinstanciation* ou de *ré-introduction* du référent¹⁹.

[7] Indépendance

Fin 1816, **Schubert** quitte l'école de son père et l'enseignement de Salieri. **Il** est hébergé en 1817 par **son** ami Franz von Schober, chez qui **il** logera à plusieurs reprises par la suite. Cette année-là **il** entreprend six sonates pour piano et **0** compose de nombreux lieder, dont *Der Tod und das Mädchen* (« La Jeune Fille et la Mort ») et *Die Forelle* (« La Truite »), op. 32, D.550.

À cette époque, l'horizon de **Schubert** s'élargit. Au quatuor familial et à l'église de la paroisse se substitue un public composé de jeunes intellectuels. **Ses** amis du Konvikt **lui** font connaître des personnalités comme le baryton Johann Michael Vogl, soliste de l'Opéra, et **lui** ouvrent les portes de salons bourgeois comme celui de la famille Sonnleithner, qui aidera à **le** faire connaître en programmant **ses** œuvres dans des soirées musicales et en organisant les premières publications, ou de la noblesse des Esterházy.

En 1818, après avoir repris provisoirement l'enseignement, **Schubert** devient le maître de musique des enfants du comte Esterházy et **0** accompagne la famille dans sa villégiature d'été à Zselíz en Hongrie (aujourd'hui Želiezovce

en Slovaquie), où **il** compose de nombreuses œuvres pour piano à quatre mains, dont la Sonate no 1 pour piano à 4 mains en si bémol, D.617 et les Huit variations sur un chant français, D.624, qui seront **sa** première œuvre instrumentale publiée (en 1822 comme op.10). De retour à Vienne, **il** emménage dans un logement qu'il partage avec le poète Mayrhofer. En été 1819, **il** accompagne Johann Michael Vogl dans un voyage en Haute-Autriche, notamment à Linz et Steyr, où naît l'idée de la composition du Quintette pour piano et cordes « La Truite », D. 667.

Dans les lieder de cette époque, **Schubert** s'ouvre à la poésie romantique, avec la mise en musique de poèmes de Novalis et de Friedrich Schlegel.

La première œuvre de **Schubert** à être publiée sera, en janvier 1818, le lied Erlafsee, D.586 sur un texte de Mayrhofer, en supplément d'une anthologie illustrée sur les régions et paysages d'Autriche. La première exécution publique d'un de **ses** lieder, *Schäfers Klagelied*, D.121, aura lieu le 28 février 1819. (Wikipédia 2019, article « Franz Schubert ». http://fr.wikipedia.org/wiki/Franz_Schubert)

2.3. La nécessité de prendre en considération les genres de discours

- 51 Si la plupart des travaux sur l'anaphore sont « hors sol » en ce sens que, par leur méthodologie, ils peuvent travailler – voire travaillent – sur des énoncés fabriqués²⁰, la description des chaînes de référence a pour corollaire incontournable la prise en considération de leur genre discursif d'occurrence. Même si de nombreux travaux sur l'anaphore et la coréférence ont œuvré dans ce sens (notamment Tutin, 2002 ; Condamines, 2005 ; Baumer, 2012 ; 2015 ; Schnedecker, 2005 ; 2014 ; Schnedecker & Landragin, 2014 ; Swanson, 2003²¹), la plupart s'en tiennent à une approche paradigmatique de la coréférence – ce qui est déjà en soi un apport extrêmement précieux – ou ont une conception des genres trop globalisante pour être opératoire (voir les nombreux travaux appuyés sur la presse (Recasens, 2010), le narratif (Kibrik, 2011), etc.) dont la granularité n'est peut-être pas assez fine pour capter les spécificités des CR en fonction de leur genre d'occurrence. Un exemple permettra d'illustrer notre propos. Il est admis que le genre des « règles du jeu » et « des recettes de cuisine » participent, comme le suggère Adam (2001a et b), des textes dits procéduraux ou d'incitation à l'action. Effectivement, le regroupement de ces textes au sein d'un même genre est motivé par un ensemble de ressemblances formelles aux niveaux macro- et micro-structurel : des caractéristiques typo-dispositionnelles similaires (découpage important correspondant à des contenus similaires (matériel, processus), titraille, forte hiérarchisation de l'information), listes d'objets exprimées souvent par des SN quantifiés, important taux de prédicats d'action, etc.

[8] Mikado

Règle du jeu

Âge : à partir de 4 ans

Nombre de joueurs : 2 à 6 joueurs

Matériel :

41 baguettes en bambou

- 1 baguette bleue, la baguette Mikado : 20 points

- 5 baguettes avec 3 rayures roses et 2 rayures bleues : 10 points

- 5 baguettes avec 2 rayures bleues et une rayure rose : 5 points

- 15 baguettes vertes, roses et bleues : 3 points

- 15 baguettes avec 1 rayure rose et 1 rayure bleue : 1 point

But du jeu : Essayez de récupérer le plus de baguettes.

Début de la partie : Le plus jeune joueur commence la partie. Ensuite, les joueurs jouent dans le sens des aiguilles d'une montre. Le joueur qui commence à jouer tient les baguettes serrées dans son poing et les laisse tomber, en éventail, sur une table ou sur le sol.

Déroulement : Chaque joueur doit alors retirer une baguette de son choix. Il ne doit en aucun cas faire bouger ou déplacer une autre baguette. Si le joueur parvient à prendre une baguette sans en bouger ni déplacer une autre, il la met devant lui, et il peut continuer à retirer d'autres baguettes. Dès qu'il déplace une autre baguette par inadvertance, il cède son tour au joueur suivant.

Le joueur qui a récupéré la baguette Mikado, a le droit de s'aider de la baguette Mikado pour en retirer une autre. Ce droit est réservé seulement à la baguette Mikado.

Fin de la partie : Le gagnant est celui qui a cumulé le plus de points.

<http://images.eveiletjeux.net/photo/PDF/128447.pdf>

[9] Far breton aux pruneaux

Temps de préparation : 15 minutes

Temps de cuisson : 30 minutes

Ingrédients (pour 6 personnes) :

200 g de farine

200 g de sucre

4 œufs

2 paquets de sucre vanillé

75 cl de lait

20 pruneaux

Préparation de la recette :

Préparer la pâte en mélangeant le farine, le lait, le sucre, les œufs, le sucre vanillé.

Laisser reposer une heure.

Préchauffer le four à 200°C. Faire fondre un morceau de beurre dans un plat (si possible en terre), puis bien répartir la matière grasse dans le fond et sur les côtés.

Verser la pâte dans le plat.

Y ajouter les pruneaux (roulés auparavant dans la farine pour qu'ils ne tombent pas au fond).

Faire cuire une demi-heure dans le four à 200°C.

Puis éteindre le four et laisser à nouveau une demi-heure.

Important : à partir du moment où le plat est enfourné, ne pas ouvrir la porte du four pendant une heure.

http://www.marmiton.org/recettes/recette_far-breton-aux-pruneaux_19101.aspx

- 52 Toutefois, l'annotation des textes en mentions, coréférences ainsi que l'annotation des catégories grammaticales des différents maillons et de leur fonction syntaxique *via* l'outil SACR permet de montrer le nombre de CR des textes ainsi que leur composition (cf. figures (3) et (4)) et la fonction syntaxique qu'occupent leurs maillons, ce que représentent les figures (5) et (6). Celles-ci montrent, en effet, que les catégories grammaticales instanciées sont plus diversifiées dans les règles du jeu (RJ) que dans les recettes (RC), que les fonctions grammaticales des mentions se répartissent différemment : les compléments d'objet dominant dans les recettes alors que les sujets le font dans les règles du jeu (44 %). Ces genres de textes sont par ailleurs tellement routiniers que les observations réalisées sur un corpus minime ont une portée généralisante aisée.

Figure 3 : Catégories grammaticales RC

Figure 4 : Catégories grammaticales RJ

Figure 5 : Fonctions grammaticales RC

Figure 6 : Fonctions grammaticales RJ

- 53 Par ailleurs, un certain nombre de mesures appliquées déterminées par l'outil CRviewer²² montrent que les CR sont un peu moins nombreuses dans les recettes que dans les règles du jeu, qu'elles sont également plus courtes et que la distance entre leurs maillons est plus grande que dans les CR des règles du jeu, avec un taux de stabilité plus fort dans les recettes que dans les règles du jeu.

Tableau 1 : Récapitulatif des mesures RC/RJ d'après CR viewer.

	RC	RJ
Distance moyenne entre mention	36.8	22.28
Longueur moyenne des mentions	1.8	2

Longueur Moyenne CR	3.4	3.57
Nbre de CR	5	7
Nombre de mentions	17	25
Coefficient de stabilité	0.7	0.4

- 54 De sorte que, associées aux critères macro-et micro structurels énoncés plus haut, les chaînes de référence des recettes de cuisine et règles du jeu révèlent de nettes disparités (catégories grammaticales instanciées et fonctions syntaxiques des maillons, d'une part ; composition des CR, d'autre part) qui peuvent aider à différencier ces deux sous-genres.

Pour terminer sans conclure

- 55 Au terme de cet article, nous espérons avoir montré que les chaînes de référence constituent un moyen d'accès privilégié à ce qu'on nomme la référence discursive. Cette notion, loin de se superposer à ou de faire « double emploi » avec celle d'*anaphore* ou de *coréférence*, est dotée d'une consistance qui fait que, au plan théorique et empirique, elle présente une réelle spécificité : un objet bien circonscrit, appréhendable avec des mesures propres à même de lui conférer une robustesse plus forte encore, des questions théoriques et empiriques propres et un domaine d'application vaste, qui va de la sémantique référentielle à la linguistique textuelle avec des applications qui concernent là aussi des disciplines diversifiées (didactique de la lecture/écriture, TAL, traduction, ...). Qui plus est, elle manifeste des vertus heuristiques indéniables que nous avons illustrées ici à travers sa capacité à caractériser les genres discursifs.

Tableau 2 : Récapitulatif des différences entre anaphore, coréférence et chaîne de référence.

	Anaphore ²³	Coréférence	Chaîne de référence
Nombre d'expressions référentielles (ER)	2	2 ou n	≥ 3
Nature des ER	au moins une expression non autonome référentiellement	expressions référentielles autonomes et ou non autonomes	
Relation référentielle	Identité et non identité	identité	identité
Propriétés de la relation	Asymétrie, atransivité	Symétrie, transivité	toutes
Domaines linguistiques couverts	Linguistique phrastique et interphrastique		Linguistique discursive & linguistique des genres
Approche	+ paradigmatique		+linéaire donc mesures <i>ad hoc</i>

Mesures	% de catégories & fonctions grammaticales Distance	% de catégories & fonctions grammaticales Distance Longueur mentions/CR Nbre de CR Portée des CR Persistance Cohabitation Coefficient de stabilité ...
---------	---	--

BIBLIOGRAPHIE

ADAM J.-M., 2015 (éd.), *La linguistique textuelle*, Paris, A. Colin.

ADAM J.-M., 2001a, « Entre conseil et consigne : les genres de l'incitation à l'action », *Pratiques* 111/112, 7-38.

ADAM J.-M., 2001b, « Types de textes ou genres de discours ? Comment classer les textes *qui disent de et comment faire* ? », *Langages* 141, 10-27.

ARIEL M., 1990, *Accessing Noun-Phrase Antecedents*, Londres, Routledge, Theoretical Linguistics Series.

BAUMER E., 2015, *Noms propres et anaphores nominales en anglais et en français : étude comparée des chaînes de référence*, Paris, L'Harmattan.

BAUMER E., 2012, *Noms propres et anaphores nominales en anglais et en français : étude comparée des chaînes de référence*, Thèse de doctorat, Université Paris Diderot.

BOUDREAU S., 2004, *Résolution d'anaphores et identification des chaînes de coréférence selon le type de texte*, Mémoire de Maîtrise, Université de Montréal.

BOUDREAU S. & KITTREDGE R., 2005, « Résolution des anaphores et détermination des chaînes de coréférences. Différences entre variétés de textes », *Traitement Automatique des Langues* 46(1), 41-70.

CHAROLLES M., 1995, « Cohésion, cohérence et pertinence du discours », *Travaux de Linguistique* 29, 125-151.

CHAROLLES M., 1991, « L'anaphore : problèmes de définition et de classification », *Verbum* 14, 1991, 203-215.

CHAROLLES M., 1988, « Les plans d'organisation textuelle : périodes, chaînes, portées et séquences », *Pratiques* 57, 3-15.

- CHASTAIN C., 1975, "Reference and context", in K. Gunderson (ed.), *Language, Mind and Knowledge*, University of Minnesota Press, Minneapolis, 194-269.
- CONDAMINES A., 2005, « Anaphore nominale infidèle et hyperonymie : le rôle du genre textuel », *Revue de sémantique et pragmatique* 18, 33-52.
- CORBLIN F., 1995, *Les formes de reprise dans le discours : anaphores et chaînes de référence*, Rennes, Presses Universitaires de Rennes.
- CORBLIN F., 1985, « Les chaînes de référence : analyse linguistique et traitement automatique », *Intellectica* 1/1, 123-143.
- ERKU F. & GUNDEL J. K., 1987, "The pragmatics of indirect anaphors", in J. Verschuren & M. Bertucelli-Papi (eds), *The Pragmatic Perspective*, Amsterdam, John Benjamins Publishing Company, 533-545.
- GERNSBACHER, M.-A., 1990, *Language Comprehension as Structure Building*, Hillsdale, NJ, L. Erlbaum.
- GIVON T., 1983, "Topic continuity in discourse: An introduction", in T. Givón (ed.), *Topic Continuity in Discourse. A Quantitative Cross Language Study*, Amsterdam, John Benjamins Publishing Company, 1-42.
- GUILLAUME, G., 1919, *Le problème de l'article et sa solution dans la langue française*, Paris, Hachette.
- KIBRIK A. A., 2011, *Reference in Discourse*, Oxford, Oxford University Press.
- KLEIBER G., 1991, « Anaphore-deixis : où en sommes-nous ? », *L'information grammaticale* 51, 3-18.
- LANDRAGIN F., 2017, « Analyse, visualisation et identification automatique des chaînes de coréférences : des questions interdépendantes ? », *Langue française* 195, 17-34.
- LANDRAGIN F., 2016a, « Description, modélisation et détection automatique des chaînes de référence (DEMOCRAT) », *Bulletin de l'AFIA* 92, 11-15.
- LANDRAGIN F., 2016b, « Conception d'un outil de visualisation et d'exploration de chaînes de coréférences », in D. Mayaffre, C. Poudat, L. Vanni, V. Magri & P. Follette (eds), *Journées internationales d'Analyse statistique des Données Textuelles (JADT)*, Jun 2016, Nice, France. 1, 109-120.
- LANDRAGIN F., 2011, « Une procédure d'analyse et d'annotation des chaînes de coréférence dans des textes écrits », *Corpus* 10, <http://corpus.revues.org>
- LUST, B., 1981, "Constraint on anaphora in child language: A prediction for a universal", in S. Tavakolian (ed.), *Language Acquisition and Linguistic Theory*, MIT Press, Cambridge, Mass., 74-96.
- MARSLIN-WILSON W. & KOMISARJEVSKY TYLER L., 1982, "Producing Interpretable Discourse: The Establishment and Maintenance of Reference", in R.J. Jarvella (ed.), *Speech, Place and Action*, Wiley & Sons, 339-378.
- MILNER J.-C., 1982, *Ordre et raisons de langue*, Paris, Seuil.
- NG V., 2010, "Supervised Noun Phrase Coreference Research: The First Fifteen Years" in S.C. Satapathy, P.S. Avadhani, S.K. Udgata, S. Lakshminarayana (eds), *Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics*, Uppsala, Sweden, 11-16 July 2010, 1396-1411.
- B
- OBERLÉ B. 2018, « Les chaînes de référence dans les textes encyclopédiques du 12^{ième} au 21^{ième} siècle : étude longitudinale », *Travaux de linguistique* 77, 67-141.

- OBERLÉ B., 2017a, *ODACR : un Outil de Détection Automatique des Chaînes de Référence à base de règles linguistiques ?* Mémoire de Master 2 Linguistique Informatique Traduction, option Informatique, Université de Strasbourg.
- OBERLÉ B., 2017b, "Coreference annotation with SACR, a new drag-and-drop based tool", ECLAVIT Workshop, 24-25 November 2017.
- OBERLÉ B., 2016, *Étude des chaînes de référence dans les articles de recherche de format IMRaD : problèmes d'annotation, analyse quantitative et qualitative*, Mémoire de Master 2 Sciences du langage, Université de Strasbourg.
- PERRET M., 2000, « Quelques remarques sur l'anaphore nominale aux 14^e et 15^e siècles », *L'information grammaticale* 87, 17-23.
- RECASENS POTAU M., 2010, *Coreference: Theory, Annotation, Resolution and Evaluation*, PhD, Barcelona, Universitat de Barcelona.
- RIEGEL M., PELLAT J.-C., RIOUL R., 2009, *Grammaire méthodique du français*, Paris, PUF/Quadrige.
- SCHNEDECKER C., 2017, Les chaînes de référence : une configuration d'indices pour distinguer et identifier les genres textuels, *Langue française* 195, 53-72.
- SCHNEDECKER C., 2014, Chaînes de référence et variations selon le genre, *Langages* 195, 23-42.
- SCHNEDECKER C., 2005, Les chaînes de référence dans les portraits journalistiques : éléments de description, *Travaux de linguistique* 51, 2005/2, 85-133.
- SCHNEDECKER C., 1997, *Nom propre et chaînes de référence*, Paris, Klincksieck.
- SCHNEDECKER C. & LANDRAGIN F., 2014, Les chaînes de référence. Présentation. *Langages* 195, 3-22.
- STOYANOV, V., GILBERT, N., CARDIE, C., & RIOLFF, E., 2009, "Conundrums in noun phrase coreference resolution: Making sense of the state-of-the-art", *Proceedings of ACL-IJCNLP 2009*, Singapour: Suntec, 656-664.
- SWANSON W., 2003, *Modes of Co-reference as Indicator of Genre*, Bern, Peter Lang.
- TOMLIN R.S., 1987, "Linguistic Reflections of Cognitive events", in R.S. Tomlin (ed.) *Coherence and Grounding in Discourse*, NYC, J. Benjamins, 455-479.
- TUTIN A., 2002, "A corpus-based study of pronominal anaphoric expressions in French", *Proceedings of DAARC 2002 (Discourse Anaphora and Anaphora Resolution)*, Lisbon.

NOTES

1. Cette étude s'inscrit dans le cadre du projet ANR DEMOCRAT (<http://www.agence-nationale-recherche.fr/Projet-ANR-15-CE38-0008>).
2. Ce qui n'est pas automatique. Dans *Marie promène son chat*, le déterminant possessif renvoie à Marie, mais la tête lexicale du SN et donc le SN à une autre entité : le chat.
3. Point systématiquement ignoré par les approches TAL.
4. Assimilée par la *Grammaire Méthodique du Français* (Riegel et al., 2009) et de façon discutable à l'anaphore résomptive.
5. Qui n'a rien de simple au vu des problèmes posés notamment (et non exhaustivement) par la résolution des anaphores dites résomptives, les cas de fusion/dispersion (*split antecedents*), des référents évolutifs, etc.

6. Ces propriétés sont abondamment exploitées dans la littérature TAL sur les questions d'anaphore et de coréférence.
7. Cela étant, la plupart des travaux d'observance TAL sur ces questions considèrent la relation d'un point de vue mathématique plus que linguistique : « Les anaphores sont aussi des relations transitives, mais elles sont asymétriques car la relation de dépendance oriente la relation. De plus, elles sont irréflexives car un élément référentiel ne peut pas être anaphorique à lui-même » (Boudreau, 2004 :21).
8. Cf. de manière plus détaillée, Schnedecker (1997 : 16 sq.)
9. "Under this conception, the coreference task is modeled as a two-step procedure: 1. A classification phase that decides whether two mentions corefer or not. It is a binary classification problem in which the probability of mention m_i and mention m_j having a coreferential outcome can be calculated by estimating the probability that: $P_c(m_i;m_j) = P(\text{COREFERENT}|m_i;m_j)$; 2. A clustering phase that converts the set of pairwise classifications into clusters of mentions, creating one cluster for each entity. This phase requires coordinating the possibly contradictory coreference classification decisions from the first phase" (Recasens, 2010 : 14).
10. Cf. également Ng (2010 : 1397 sq.).
11. « For example, Mr. Clinton may be correctly coreferred with Clinton, but then particular pairwise features may make the model incorrectly believe that Clinton is coreferent with a nearby occurrence of she, and since the clustering stage is independent from the pairwise classification, the incompatibility between the gender of Mr. Clinton and that of she will be ignored in building the final cluster. This is what marks the divide between local and global or entity-based model. » (Recasens, 2010 : 14).
12. « Il est à remarquer que puisque les relations coréférentielles sont des relations symétriques, transitives et réflexives, elles sont donc des relations d'équivalence » (Boudreau, 2004 : 20).
13. Cf. également Schnedecker (2017).
14. Ce qui n'est évidemment pas un reproche.
15. Actuellement en discussion au sein du projet Democrat.
16. B. Oberlé (2016) a perfectionné de manière très judicieuse ce mode de calcul pour l'élargir aux pronoms, d'une part, et le normaliser, d'autre part.
17. Cf. le projet Democrat évoqué plus haut.
18. Cf. Schnedecker (1997).
19. Pour une synthèse de ces questions, cf. Schnedecker (1997, chap. 3 et 5).
20. Cela n'exclut pas que bon nombre d'approches actuelles travaillent à partir de corpus.
21. Pour une revue de ces travaux, voir Schnedecker (2017).
22. Cf. Oberlé (2017a ; 2017b) pour le détail des calculs.
23. Nous parlons ici de *relation anaphorique* et de *relation de coréférence*, relations qui sont duelles comme nous l'avons montré ci-dessus. Il va de soi qu'une chaîne anaphorique ou qu'une chaîne de coréférence(s) peut comporter un nombre d'unités supérieur à 2.

RÉSUMÉS

Nous montrons que la notion de *chaîne de référence*, loin de se superposer à celle d'*anaphore* ou de *coréférence*, est dotée d'une consistance qui fait que, au plan théorique et empirique, elle présente une réelle spécificité : un objet bien circonscrit, appréhendable avec des mesures propres à même de lui conférer une robustesse plus forte encore, des questions théoriques et empiriques propres et un domaine d'application vaste, qui va de la sémantique référentielle à la linguistique textuelle. Qui plus est, elle manifeste des vertus heuristiques indéniables que nous illustrons ici à travers sa capacité à caractériser les genres discursifs.

We show that the notion of *reference chain*, far from being superimposed on that of *anaphora* or of *coreference*, is endowed with a consistency that makes it truly specific in theoretical and empirical terms: it is a well-circumscribed object, which can be grasped with measures capable of conferring on it even greater strength, specific theoretical and empirical questions, and a wide field of application, ranging from referential semantics to textual linguistics. Moreover, it shows undeniable heuristic virtues, which we illustrate here through its ability to characterize genres.

INDEX

Mots-clés : chaîne de référence, anaphore, coréférence, genre de discours

Keywords : referential chain, anaphora, coreference, discourse genre

AUTEUR

CATHERINE SCHNEDECKER

Université de Strasbourg, Fonctionnements Discursifs & Traduction, LiLPa/EA 1339