Cálculo de la Estructura de un Texto en un Sistema de Procesamiento de Lenguaje Natural*

Horacio Saggion y Ariadne Carvalho
Departamento de Ciência da Computação
Universidade Estadual de Campinas
Caixa Postal 6065
13081-970 Campinas-SP-Brazil
Fax: (0192) 397470
{saggion,ariadne}@dcc.unicamp.br

Resumen

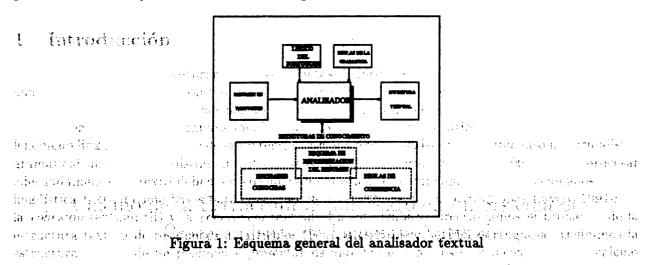
Calcular la estructura lingüística de un texto es fundamental en cualquier sistema de procesamiento de lenguaje natural. Para eso, fenómenos mas allá de la barrera de la sentencia deben ser considerados. En particular, dos estudios deben ser abordados en el procesamiento de un texto: la cohesión textual y la coherencia textual. En este trabajo definimos una representación para la estructura de un resumen en lengua portuguesa considerado como un fenómeno lingüístico. La representación fue obtenida a partir del estudio de resúmenes reales y de la verificación de relaciones entre sentencias en el texto. Consideramos que este tipo de representación puede ser utilizada para otros textos, ya que es definida en función de relaciones de cohesión y coherencia. El principal aspecto considerado en este trabajo para la construcción de la estructura textual es la cohesión a través de la resolución de anáforas definidas tanto pronominales como frases nominales definidas. Presentamos ejemplos de texto reales y su tratamiento en el marco teórico propuesto.

Palabras clave: Procesamiento de Lenguaje Natural. Resúmenes. Estructura Textual. Cohesión Textual. Anáfora Definida.

Cálculo de la Estructura de un Texto en un Sistema de Procesamiento de Lenguaje Natural

1 Introducción

Una gramática intenta capturar los conocimientos lingüísticos que un hablante tiene sobre su lengua y la lingüística tiene como objetivo el establecimiento de un conjunto de principios y reglas por medio de los cuales sea posible distinguir entre expresiones bien y mal formadas. Las aplicaciones en Linguística Computacional se han concentrado en los últimos años en el texto como fenómeno lingüístico diferente de la sentencia. Sin embargo no existe por el momento un formalismo gramatical que permita distinguir entre textos bien y mal formados [Hovy 1993]. Para procesar adecuadamente un texto deben ser considerados dos aspectos fundamentales direccionados por la lingüística textual como bases para el cálculo de la estructura de un texto [Lopes Fávero 1991]: (i) la cohesión textual; (ii) y la coherencia textual. En este trabajo direccionamos el problema de la estructura textual de resúmenes de artículos técnicos escritos en lengua portuguesa. Definimos la estructura textual de un resumen y presentamos uno de los procesos que hacen posible el cálculo de esa estructura. El sistema completo propuesto aparece representado en la Figura 1. El texto es procesado con el objetivo de construir una representación estructural.



El principal aspecto considerado en este trabajo es la cohesión textual como un factor determinante en el cálculo de la estructura de un texto [Halliday y Hasan 1976].

El artículo se organiza de la siguiente manera: en la Sección 2 introducimos los conceptos relativos a resúmenes de artículos técnicos; en la Sección 3 presentamos la estructura textual de

. และเมาะสมราช รากรั

los resúmenes; en la Sección 4 introducimos los conceptos de cohesión textual. En la Sección 5 presentamos los procesos computacionales para el cálculo de la cohesión textual y finalmente en la Sección 6 son presentadas las conclusiones de este trabajo.

2 Resúmenes

Un resumen es la primera parte de un reporte técnico; según la ciencia de la documentación tratase de un indicador del contenido del reporte [Weil et al. 1963a, Cleveland y Cleveland 1983]. Según la lingüística [Gopnik 1972, Hutchins 1985], a pesar de ser restricto a un único párrafo, tratase de un fenómeno textual y presenta todas las relaciones interesantes de textos mayores, en particular relaciones de cohesión y de coherencia.

La ciencia de la documentación distingue entre dos tipos básicos de resúmenes [Jordan 1991, Cleveland y Cleveland 1983]: (i) indicativo o descriptivo, considerado como una tabla de contenidos del reporte técnico pero escrito en lenguaje natural; indica el material que será encontrado en el documento original y jamás podrá transformarse en un substituto de este último; e (ii) informativo, considerado un verdadero texto ya que presenta datos e informaciones del propio reporte, contiene las ideas y los hechos principales del documento y muchas veces puede ser utilizado como substituto del documento original. En la práctica, un resumen será un híbrido entre los dos tipos considerados.

Resúmenes de los campos de conocimiento mas variados son escritos de manera similar; existen además publicaciones que establecen algunas guías sobre como este tipo de texto debe ser escrito y sobre el tipo de información a ser incluida [Weissberg y Buker 1990, Weil et al. 1963b].

Un resumen incluirá en general los siguientes ítems de información: (i) Contexto, donde información preliminar es incluida y el problema estudiado es definido; (ii) Objetivos y alcance del estudio realizado; (iii) Metodología empleada en la investigación, incluyendo materiales, equipamientos y procedimientos utilizados; (iv) Resultados obtenidos en la investigación; y (v) Conclusiones alcanzadas en el trabajo, incluyendo recomendaciones y sugestiones.

Además del tipo de información que aparecerá en un resumen, también pueden ser verificadas algunas normas de utilización de tiempos verbales que corresponden con una situación pragmática; el tiempo pasado es utilizado para describir informaciones relacionadas con el trabajo científico, dado que este fue realizado con anterioridad a la redacción del reporte y el tiempo presente es utilizado para describir las conclusiones y los objetivos del trabajo ya que son informaciones asociadas directamente con el documento.

Nuestro trabajo se basa en el análisis de un "corpus" de resúmenes reales publicados por la "Revista de Ensino de Engenharia". Escogimos estudiar textos de esa publicación, pues los resúmenes publicados deben seguir las normas de la "Associação Brasileira de Normas Técnicas" [ABNT 1987]. El estudio de textos reales permite la observación de fenómenos lingüísticos generales y particulares así como la comprobación de los aspectos teóricos estudiados. En la Figura 2, presentamos un resumen del corpus estudiado [Milanez 1987].

En este resumen podemos verificar la inclusión de los siguientes tipos de información: las sentencias (1) y (2) presentan información de tipo contextual. La sentencia (3) presenta información sobre el trabajo científico y la sentencia (4) presenta información sobre el objetivo del reporte técnico.

(1) Os programas de avaliação de docentes pelos alunos vêm sendo utilizados nos Estados Unidos desde a década de quarenta. (2) Este tipo de programa não é muito comum nas universidades brasileiras. (3) No Departamento de Engenharia Mecânica da UNICAMP foram feitas algumas tentativas de implantação destes programas. (1) O presente trabalho descreve a experiência da aplicação destes programas no Departamento de Engenharia Mecânica da UNICAMP.

Figura 2: Un resumen

3 La estructura textual

La estructura de un texto ha sido estudiada desde diversas perspectivas. [McKeown 1985] estudió la estructura de textos cortos producidos en respuesta a preguntas sobre la organización de un banco de datos. Ella notó que el tipo de texto producido en dicha situación sigue padrones muy estereotípicos. También notó que en textos científicos los autores utilizan conocimientos sobre el tipo de material que debe aparecer en la introducción y los datos a ser incluidos en la conclusión. Gopnik 1972] estudió la estructura de textos científicos interesada en reconocer las características sintácticas de las sentencias en el contexto textual. [Grosz y Sidner 1986] propusieron la estructura de un discurso de modo tal que el modelo actúa para restringir los posibles antecedentes para un pronombrets algumas tentateras as cambinaturas de cos recordinas. 🐔 O presente trabelho deservece :

Algunos autores reconocen que la estructura de un texto está dada por las relaciones que vinculan sentencias advacentes en la superfície lingüística. [Mann y Thompson 1987] estudiaron textos reales y definieron una teoría que permite describir la estructura de un texto en términos de relaciones entre las sentencias. La mayor parte de las relaciones tiene una palabra clave para facilitar su identificación. La teoría, por ellos propuesta, fue utilizada en el campo de generación de textos por computador [Hovy 1993, Moore y Paris 1994].

esc<u>u</u>ntum do gotescopha dae wagagety Wilson No 3.1 La estructura de un resumen

Definimos la estructura de un resumen como formada por tres partes fundamentales:

(i) una partición del texto en grupos de sentencias adyacentes en la superfície lingüística. Llamaremos a cada grupo segmento. El nombre de una Categoría de Información es asignado al antánsegmento: "afai on dallatar el el maneiro, describir. Cerceix y el lecer 1940 de cope electrocida estraterrales the an infrarestable through the appearance was trained as the force with a new later and black and black believes in

esdegentificas. Paraldén natá que en caros fendificas his or one atlante acesamientos sejas et

times. M.

SOME TO MEDICAL TO

- (ii) un conjunto de proposiciones y entidades producidas a partir del análisis sintáctico-semántico ande las sentencias a mais en a mort e montre en contrata de la come de distribuir de la come de la come de la
- (iii) un conjunto de relaciones proposicionales que vinculan las proposiciones.

Las Categorías de Información (CI) por nosotros utilizadas para identificar los segmentos son:

 $CI \equiv \{ Contexto, Objetivo, Método, Experimento, Resultado, Recomendación, Sugestión, Conclusión \}$

El nombre de la categoría indica el tipo de material contenido en el segmento dado que cada segmento en un texto debe servir a un propósito de información [Grimes 1975]. Para la determinación de los segmentos utilizamos dos tipos de información: (i) la categoría lingüística tiempo que es considerada el principal indicador de cambio de segmento y (ii) información semántica asignada a los ítems de la lengua que fueron identificados como indicadores de segmentos.

3.1.2 Entidades

Cada sintagma nominal con m modificadores será representado por una expresión de la forma (1).

$$p(i, e_1, ..., e_m, d, g, n)$$
 (1)

Donde p es un predicado nominal asociado a la cabeza nominal del sintagma; i es un índice que identifica el referente del sintagma nominal; e_k es una expresión que representa el k-ésimo complemento del sintagma nominal; y d, g y n son respectivamente expresiones asociadas a la información sobre determinación, género y número. Las expresiones de los complementos pueden ser $modificador = constante_{nominal}$, $calificador = constante_{adjetiva}$, especificador = indice dependiendo del complemento. La asociación de cada complemento nominal a un elemento del lenguaje de representación es definido en el léxico de la lengua.

La representación es obtenida por un algoritmo de análisis sintáctico-semántico para las frases nominales del portugués.

3.1.3 Proposiciones

Cada verbo con n argumentos será representado por una expresión del tipo (2).

$$p(i, papel_1 = e_1, ..., papel_n = e_n, t, a, m)$$
 (2)

3312

Donde p es un predicado asociado al verbo; $papel_k$ es el papel temático que el k-ésimo complemento desempeña en la estructura de la frase; e_k es el índice del k-ésimo complemento del verbo y t, a y m representan respectivamente las informaciones sobre tiempo, aspecto y modo asociados al verbo. Obtenemos las proposiciones utilizando un algoritmo de análisis sintáctico guiado por información sobre los posibles complementos de un verbo (información sobre el marco de sub-categorización del verbo).

3.1.4 Relaciones Proposicionales

14 14 1 Carlos

Estamos trabajando con el siguiente conjunto de Relaciones Proposicionales (RP);

 $RP \equiv \{ Elaboración, Paralelo, Secuencia, Causa Consecuencia, Contraste, Secuencia <math>Elaboración \}$

Las relaciones *Elaboración* y *Paralelo* son identificadas por los vínculos cohesivos entre entidades en proposiciones adyacentes. Las restantes relaciones son identificadas según las construcciones sintácticas de la lengua portuguesa, utilizadas en las sentencias.

Las relaciones asociadas a construcciones sintácticas son deducidas en la fase de análisis sintáctica de la sentencia y dependen de la forma de la frase.

La representación completa del resumen de la Figura 2 puede ser observada en la Figura 3.

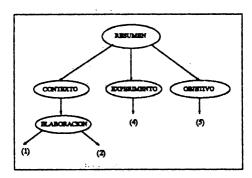


Figura 3: Estructura textual del resumen

Para calcular la relación de *Elaboración* que vincula las oraciones (1) y (2) es imprescindible verificar las relaciones cohesivas que existen entre estas sentencias. Por eso direccionamos en este trabajo el análisis de la cohesión textual como paso fundamental en el cálculo de la estructura de un texto.

4 La cohesión textual

Existen mecanismos que los escritores utilizan para señalar relaciones de sentido entre partes de enunciados. Es por medio de esos mecanismos que la estructura textual es construida. [Koch 1989] distingue para el portugués dos tipos de cohesión: (i) la cohesión referencial; y (ii) la cohesión secuencial. En este trabajo estaremos concentrados en la cohesión referencial como mecanismo de construcción de la estructura de un texto.

Cuando escribimos utilizamos expresiones para referirnos a entidades y situaciones del mundo real, el problema de determinar el referente de una expresión lingüística es el clásico problema de la referencia semántica (exófora). En portugués, las entidades con poder de referencia son los sintagmas nominales que designan entidades y objetos de la situación comunicativa y las oraciones que designan propiedades y eventos [Mateus et al. 1983].

Existen situaciones en las cuales los escritores utilizan formas abreviadas para referir a una entidad previamente introducida en el contexto discursivo [Hirst 1981]. La forma abreviada es llamada ítem remisivo y el elemento al cual este refiere es llamado antecedente. El proceso por el cual se determina el antecedente de un ítem remisivo se llama resolución. Cuando se establece una relación entre ambos se dice que esos elementos (remisivo y antecedente) son co-referentes. Dos tipos de co-referencia son identificados: (i) cuando el ítem remisivo aparece antes que su antecedente en la secuencia lingüística estamos en un caso de catáfora; (ii) cuando el ítem remisivo aparece después de su antecedente en la secuencia lingüística estamos en un caso de anáfora. En este trabajo consideraremos únicamente casos de co-referencia anafórica. En estos casos el ítem remisivo es también llamado anáfora.

El caso más evidente de anáfora es la de los pronombres personales de tercera persona 1, los

rest.

a comment

¹ ele(s)/ela(s)

pronombres reflexivos², los pronombres objeto³ y los pronombres demostrativos⁴. Estas formas abreviadas no tienen ninguna instrucción semántica que permita la determinación de su antecedente; apenas instrucciones de conexión son especificadas en el léxico de la lengua. No obstante, varias son las restricciones estructurales impuestas por la teoría gramatical [Raposo 1992, Lobato 1986] para la elección o exclusión de un antecedente para un pronombre. Consideremos por ejemplo la sentencia (a) de la Figura 4 y su representación en términos de categorías sintácticas.

- (á) a engenharia depende das ciências e de [técnicas n[elas] $_{NP_2}$ baseadas] $_{NP_1}$
- (b) a engenharia não prescinde d[a criatividade de quem $[\mathbf{a}]_{NP_2}$ usa $]_{NP_1}$

Figura 4: Filtro i sobre i para un pronombre

El pronombre personal elas (NP_2) no puede tener como antecedente el sintagma nominal completo cuya cabeza es $t\'{e}cnicas$ (NP_1) , a pesar del pronombre y el sintagma compartir concordancia en género y número. En este caso se impone la restricción gramatical: Filtro~i~sobre~i, por medio de la cual una expresión nominal A no puede ser co-referente con otra expresión nominal B de la cual A forma parte. Otro caso de esta restricción puede ser observado en la sentencia (b) de la Figura 4, donde el pronombre objeto a (NP_2) no puede ser co-referente con el sintagma cuya cabeza es criatividade (NP_1) , también por la misma restricción estructural. Las restricciones impuestas por la gramática hacen posible la exclusión de pares de expresiones nominales a nivel sentencial y también hacen posible la determinación de posibles referentes para ítems reflexivos. En el nivel textual la resolución de los pronombres se realiza considerando las entidades previamente introducidas en el texto y que concuerdan en género y número con el pronombre. Sin embargo, existen autores que consideran la propia estructura del discurso como determinante en la elección de un antecedente para un pronombre [Grosz y Sidner 1986, Brennan et al. 1987].

El segundo tipo de elemento anafórico es la frase nominal definida (FND). Una FND es aquel sintagma nominal al que han sido aplicadas operaciones de determinación por medio de los determinantes del portugués: {o, este, esse, aquele} y sus respectivos femeninos y plurales. No todas FND son consideradas como elementos anafóricos. Categorizamos las FND según el siguiente critério: (i) FND que refieren a la situación comunicativa y que son consideradas como únicas; (ii) FND con operaciones de especificación que refieren al contexto o están siendo introducidas por primera vez en el texto; y (iii) FND sin operaciones de complementación, pero consideradas incompletas. Las frases clasificadas como (i) y (ii) deben encontrar su referente en la base de conocimientos del sistema o debe crearse un referente en caso de ser introducidas por primera vez. Las frases clasificadas como (iii) deben encontrar un elemento co-referente en el propio texto, el cual debe anteceder al ítem remisivo.

En este trabajo estamos considerando referencias a elementos previamente introducidos considerando únicamente la cabeza nominal de la FND, otros casos de co-referencia no serán aquí tratados. Consideremos el segmento de texto de la Figura 5 [Gomide y Fernández 1985]. En la sentencia (1) la expresión "a disciplina Similitude em Engenharia" introduce una entidad en el entorno dis-

²se/si próprio/si própria

 $^{^3}$ o(s)/a(s)

⁴este(s)/esta(s),esse(s)/essa(s),aquele(s)/aquela(s)

(1) O presente trabalho tem como meta divulgar a disciplina Similitude em Engenharia ministrada no curso de Engenharia Mecânica da UFU. (2) Esta disciplina visa proporcionar aos alunos fundamentos básicos sobre a teoria de modelos.

Figura 5: Referencia anafórica en texto

cursivo. En la sentencia (2) esta entidad es anafóricamente retomada por medio de la expresión abreviada "esta disciplina". Para resolver esta referencia abreviada es utilizado el predicado nominal disciplina asociado con la cabeza nominal de la expresión abreviada.

Consideremos la expresión nominal "estes programas" en la sentencia (3) del resumen de la Figura 2. Esa frase nominal definida es una referencia abreviada que tiene como antecedente la expresión "os programas de avaliação de docentes pelos alunos" de la sentencia (1). La resolución de la referencia abreviada es realizada utilizando el predicador programa asociado a la cabeza nominal de la expresión abreviada.

5 Resolución de la cohesión referencial

Para resolver las referencias pronominales en el texto, nos hemos basado en una estructura de pila que mantiene las entidades introducidas en el discurso en el orden en que aparecieron: la más reciente será la más accesible. La resolución de las frases nominales definidas está basada en una base de conocimientos que contiene referentes, reglas de vinculación conceptual y referentes activos.

Resolución de los pronombres

los or proposer

En este trabajo estamos considerando únicamente los pronombres personales y los pronombres objeto de tercera persona, los pronombres reflexivos y recíprocos de la lengua portuguesa no serán tratados en este artículo. Un pronombre es considerado una referencia anafórica, por lo tanto su antecedente deberá ser una entidad introducida previamente en el texto. Utilizamos una pila AP para el almacenamiento de las entidades introducidas en el texto y que sirven de antecedentes para un pronombre. Cada elemento de la pila es una 3-upla de *índice*, *género* y *número*, y las operaciones sobre la pila son las usuales: apilar, desapilar y tope. Cuando una nueva entidad es introducida en el texto, y portanto producida una representación de la forma $p(i_e, ..., d, g, n)$, la pila AP es actualizada según (3). He water an anti-promissa.

$$AP \leftarrow apilar(AP, \langle i_e, g, n \rangle)$$
 (3)

 $AP \leftarrow apilar(AP, \langle i_e, g, n \rangle) \tag{3}$ Cuando un pronombre es encontrado en el texto se produce una expresión del tipo (4).

$$anafora(i_a, g_a, n_a)$$
 (4)

El antecedente del pronombre se buscará utilizando el esquema presentado en la Figura 6. Podemos observar dos procesos principales: (i) cálculo de las entidades no-coreferenciales aplicando restricciones estructurales; y (ii) búsqueda del antecedente.

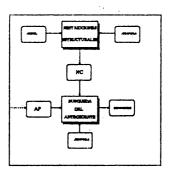


Figura 6: Resolución de pronombres

En el proceso (i) es obtenido el conjunto de índices que no pueden ser antecedentes para el pronombre; este paso es realizado considerando restricciones en el nivel sentencial aplicadas al árbol de análisis sintáctico. Para cada anáfora i_a es calculado el conjunto $NC(i_a)$ de pares no co-referenciales según la especificación (5).

$$NC(i_a) \equiv \{i_{a_1}, ..., i_{a_k}\}$$
 (5)

tal que i_{a_j} $(1 \le j \le k)$ es no co-referente con i_a

El paso (ii) de búsqueda del antecedente para el pronombre se basa en la especificación $(6)^5$. La pila AP es examinada hasta obtener un posible antecedente para el pronombre considerando trazos sintácticos.

$$X \in AP / \Pi_1(X) \notin NC(i_a) \wedge \Pi_2(X) = q_a \wedge \Pi_3(X) = n_a \tag{6}$$

Consideremos como ejemplo la resolución del pronombre elas de la sentencia (a) de la Figura 4. El estado de la pila en ese momento puede ser observado en la Figura 7. Asumimos que los referentes de "a engenharia", "as ciencias" y "técnicas" son respectivamente i_0 , i_1 e i_2 .

$$AP \left\{ \begin{array}{l} (i_2, fem, plu) \ (tope) \\ (i_1, fem, plu) \\ (i_0, fem, sin) \\ \vdots \end{array} \right.$$

Figura 7: Estado de la pila (a)

La representación del pronombre en el lenguaje de representación es (7) y el conjunto de pares no co-referenciales es (8).

$$anafora(i_a, fem, plu) \tag{7}$$

⁻ $anafora(i_a,fem,plu)$ 5 La operación $\Pi_k(1\leq k\leq 3)$ proyecta el k-ésimo componente de la upla X

$$NC(i_a) = \{i_2\} \tag{8}$$

El proceso de búsqueda del antecedente para el pronombre finaliza con la determinación de i_1 como co-referente con i_a .

Consideremos ahora la resolución del pronombre objeto a de la sentencia (b) de la Figura 4. El estado de la pila es mostrado en la Figura 8. Asumimos que los referentes de "a engenharia" y "a criatividade" son respectivamente i_0 e i_3 .

$$AP \begin{cases} (i_3, fem, sin) (tope) \\ (i_0, fem, sin) \\ \vdots \end{cases}$$

Figura 8: Estado de la pila (b)

La representación del pronombre a en el lenguaje de representación es (9) y el conjunto de pares no co-referenciales es (10).

$$anafora(i_b, fem, sin)$$
 (9)

$$NC(i_b) = \{i_3\} \tag{10}$$

El proceso de búsqueda del antecedente para el pronombre finaliza con la determinación de i_0 como co-referente con i_b .

5.2 Resolución de FND

Para la resolución de las FND utilizamos una base de conocimientos que contiene referentes para las FND consideradas completas y reglas para la vinculación conceptual de las entidades en el contexto discursivo. El referente de una FND de tipo (i) es buscado en la base de conocimientos, cuando el referente de la expresión definida es encontrado este es marcado como activo. El referente de una FND de tipo (ii) es buscado utilizando reglas que establecen relaciones entre entidades introducidas en el discurso, y por lo tanto activas, y entidades a ellas conceptualmente vinculadas. Una FND de tipo (iii) es considerada una referencia abreviada, el antecedente de esta expresión será buscado considerando el predicado asociado a la cabeza de la FND.

Así, por ejemplo considerando el segmento de texto de la Figura 5, la expresión "a disciplina Similitude em Engenharia" es considerada una FND de tipo (i), luego, su referente será buscado en la base de conocimiento del sistema utilizando la expresión de búsqueda (11).

$$disciplina(X, nome = similitude_em_engenharia)$$
 (11)

Supongamos que el índice de ese referente es i_0 , este índice será marcado como activo. La expresión "esta disciplina" es considerada una FND de tipo (iii), luego, su antecedente deberá ser buscado considerando el predicado disciplina. La búsqueda en la base de conocimiento se realiza utilizando una expresión del tipo (12).

$$disciplina(X) \wedge activa(X)$$
 (12)

La base de conocimientos responde a esa búsqueda con $X = i_0$. Considerando que el referente i_0 es introducido en la sentencia (1) del segmento y que este referente es retomado en la sentencia (2), podemos verificar la relación de *Elaboración* en el segmento.

Consideremos ahora la expresión definida "o plano de ensino" que es considerada una FND de tipo (ii). El referente de esta expresión será buscado en la base de conocimiento utilizando la regla (13) y la expresión de búsqueda (14).

$$plano(p(X), modificador = ensino) \Leftarrow$$

$$disciplina(X) \land activa(X)$$
 (13)

$$plano(X, modificador = ensino) (14)$$

La solución encontrada es $X = p(i_0)$. Este referente debe ser marcado como activo en la base de conocimiento.

Como último ejemplo consideremos la resolución de las frases nominales definidas del resumen de la Figura 2. En este texto observamos tres frases nominales definidas relacionadas: (a) 'os programas de avaliação de docentes pelos alunos" en la sentencia (1); (b) "este tipo de programa" en la sentencia (2); y (c) "estes programas" en las sentencias (3) y (4). Para la expresión (a) es encontrado en la base de conocimientos un referente i_p ; este referente será marcado como activo para una posible referencia posterior y también para activar las reglas que vinculan este referente con otras entidades. La expresión (b), dadas sus características de complementación y la información tomada del léxico, es buscada utilizando la regla (15) y la expresión de búsqueda (16).

$$tipo(X, modificador = programa) \Leftarrow$$

$$programa(X) \land activa(X)$$
 (15)

$$tipo(X, modificador = programa) (16)$$

La base de conocimientos responde con $X = i_p$. Finalmente la expresión (c) es considerada una referencia abreviada por lo tanto será buscada en la base de conocimiento utilizando la expresión (17).

$$programa(X) \land activa(X)$$
 (17)

La base de conocimientos responderá con $X = i_p$.

6 Conclusiones

En este trabajo hemos abordado la cohesión textual como un paso fundamental en el cálculo de la estructura de un texto. El tipo de texto considerado en este trabajo está restricto a resúmenes de artículos técnicos que, a pesar de ser restrictos a un único párrafo, son considerados por la lingüística como un fenómeno textual. Hemos definimos un formalismo para la representación de este tipo de texto y hemos presentado el proceso que hace posible la verificación de relaciones cohesivas. El formalismo de representación puede ser extendido para abarcar otros tipos de texto visto que las relaciones establecidas entre sentencias son de tipo lógico-semántico y de tipo cohesivo. En este

trabajo hemos direccionado un tipo de referencia anafórica conocido como anáfora definida y hemos presentado los mecanismos computacionales que posibilitan la resolución de algunos pronombres del portugués y de algunas frases nominales definidas. No hemos considerado el tratamiento de otros típos de pronombres como los pronombres substantivos demostrativos. En lo que concierne a la resolución de las frases definidas anafóricas consideramos únicamente el predicado asociado a la cabeza nominal de la frase definida, si bien en el "corpus" estudiado este es el mecanismo mas frecuente, no es el único, por lo tanto investigación adicional es necesaria para tratar este y otros tipos de referencia que aparecen en la literatura.

Bibliografía

- [ABNT 1987] ABNT-Associação Brasileira de Normas Técnicas. Resumos. 1987.
- [Brennan et al. 1987] Brennan, S., Friedman, M.W. y Pollard, C.J. A Centering Approach to Pronouns. 25th Annual Meeting of the ACL, 6-9 July 1987.
- [Cleveland y Cleveland 1983] Cleveland, D.B. y Cleveland A.D. Introduction to Indexing and Abstracting. Libraries Unlimited, Inc., 1983.
- [Gomide y Fernández 1985] Gomide, H.A. y Fernández, E.F. Curso de Similitude em Engenharia. Revista de Ensino de Engenharia, 4(2):125-132, São Paulo, 2^o Sem. 1985.
- [Gopnik 1972] Gopnik, M. Linguistic Structures in Scientific Texts. Mouton, 1972.
- [Grimes 1975] Grimes, J. The Thread of Discourse. Mouton and Company, The Hague, Netherlands, 1975.
- [Grosz y Sidner 1986] Grosz, B.J. y Sidner, C.L. Attention, Intentions and the Structure of Discourse. Computational Linguistics, Vol. 12, Num. 3, July-September 1986.
- [Halliday y Hasan 1976] Halliday, M.A. y Hasan, R. Cohesion in English. London, Longman Press, 1976.
- [Hirst 1981] Hirst, G. Anaphora in Natural Language Understanding: A Survey. Lecture Notes in Computer Science 119. Springer-Verlag, 1981.
- [Hovy 1993] Hovy, E. Automated Discourse Generation using Discourse Structure Relation. Artificial Intelligence, Vol. 63, Num. 1-2, October 1993.
- [Hutchins 1985] Hutchins, W.J. Information Retrieval and Text Analysis. In New Approaches to the Analysis of Mass, Media, Discourse and Communication. T.A. van Dijk (Ed.), Gruyter, Berlin, 1985.
- [Jordan 1991] Jordan, M.P. The Linguistic Genre of Abstracts. In A. Della Volpe (ed.), The Seventeenth LACUS Forum. Linguistics Association of Canada and the United States, 1991.
- [Koch 1989] Koch, I.V. A Coesão Textual. Editora Contexto, 1989.
- [Lobato 1986] Lobato, M.L.P. Sintaxe Gerativa do Português. Da Teoria Padrão à Teoria da Regência e Ligação. Vigilia, 1986.

- [Lopes Fávero 1991] Lopes Fávero, L. Coesão e Coerência Textuais. Editora Ática, 1991.
- [Mann y Thompson 1987] Mann, W.C. y Thompson S.A. Rhetorical Structure Theory: A Theory of Text Organization. ISI Reprint Series, ISI/RS-87-190, June 1987.
- [McKeown 1985] McKeown, K.R. Discourse Strategies for Generating Natural-Language Text. Artificial Intelligence, Vol. 27, 1985.
- [Milanez 1987] Milanez, L.F. Considerações sobre Programas de Avaliação de Docentes pelos Alunos. Revista de Ensino de Engenharia, 6(1):47-52, São Paulo, 1º Sem. 1987.
- [Mateus et al. 1983] Mateus, M.H.M., Brito, A.M., Duarte, I.S. y Faria, I.H. Gramática da Língua Portuguesa. Livraria Almedina, Coimbra, 1983.
- [Moore y Paris 1994] Moore, J.D. y Paris, C.L. Planning Text for Advisory Dialogues: Capturing Intentional and Rhetorical Information. Computational Linguistics, Vol. 19, Num. 4, 1994.
- [Raposo 1992] Raposo, E.P. Teoria da Gramática. A Faculdade da Linguagem. Ed. Caminho, Lisboa, 1992.
- [Weil et al. 1963a] Weil, B.H., Zarember, I. y Owen, H. Technical-Abstracting Fundamentals. Introduction. Journal of Chemical Documentation, Num 3, 1963.
- [Weil et al. 1963b] Weil, B.H., Zarember, I. y Owen, H. Technical-Abstracting Fundamentals. Writing Principles and Practices. Journal of Chemical Documentation, Num 3, 1963.
- [Weissberg y Buker 1990] Weissberg, R. y S. Buker. Writing UP Research. Prentice-Hall, Inc., 1990.