

## **Capítulo 3. *Comprensión del lenguaje haciendo uso de N-grams y PCFG's***

### **3.1 Introducción**

Los sistemas conversacionales modernos necesitan de algún mecanismo para el análisis e interpretación de la señal de voz de entrada. El lenguaje hablado se comporta muy diferente al lenguaje escrito, y el comportamiento del primero continúa aún pobremente entendido. Por esto, aún no existe un consenso sobre la forma de optimizar el uso de gramáticas y del proceso de parsing. Aún las técnicas más completas de análisis de lenguaje escrito no funcionan con el lenguaje hablado. Lo que recientemente se ha tratado de implementar para lograr una buena comprensión de lenguaje es lo que se denomina “análisis robusto” (robust parsing).

#### **3.1.1 Análisis Robusto (Robust Parsing)**

En el uso del lenguaje hablado se presentan situaciones como, inicios de diálogo en falso, frases mal articuladas, tartamudeos, etc., cuando esto sucede; ¿Podrá existir alguna manera para que las interfaces conversacionales las manejen de una forma refinada y cooperativa?. Más aún, si un error de reconocimiento no ocurre, un locutor puede decir frases que no son completas. “Un parser robusto debe poder hacer frente a una entrada de información formada de manera fragmentada, o mal formada en el peor de los casos; pero la mayoría del trabajo del proceso de lenguaje natural hasta la fecha ha evitado este asunto” [Schmandt 1994].

#### **3.1.2 El proceso actual de reconocimiento/entendimiento del lenguaje Natural en las Interfaces Conversacionales**

Para muchos sistemas actuales el reconocedor está dado un modelo de lenguaje, en cualquier forma que este lo requiera, este entonces escucha la voz, y regresa una cadena de texto a la aplicación; la cual debe analizarse de nuevo para saber cómo interpretar estas palabras de la manera más significativa.

Con lo anterior, no solo la información sintáctica se pierde cuando se reporta el reconocimiento de voz, como una cadena de palabras, sino también puede ser perjudicial para mostrar la presentación de alguna evidencia acústica sobrante, como lo es el grado de certeza del reconocedor, o las posibles opciones de elección de los resultados de reconocimiento [Schmandt 1994].

Además como se había mencionado anteriormente el entendimiento de lenguaje escrito es muy diferente al lenguaje hablado. Parte de la dificultad con un proceso de parsing es el excesivo grado de aislamiento entre los componentes de una interfaz conversacional; su manejador de diálogo, el reconocedor de voz y el módulo de entendimiento de lenguaje natural.

“El conocimiento sintáctico y semántico debe ser incorporado simultáneamente cuando se procesa la entrada de voz al sistema” [Hacioglu & Ward 2001]. La construcción de oraciones fuera de la gramática, pausas, reinicios, complican esta tarea.

### **3.1.3 Alcance de los analizadores sintáctico/semánticos tradicionales**

Los humanos a menudo podemos describir un objeto parcialmente, identificando solo aquellas características sobresalientes. Este comportamiento implica que podemos hablar únicamente lo necesario, y sobresalimos en el uso del lenguaje hablado, porque podemos establecer un buen entendimiento a través de frases fragmentadas, por ejemplo: al decir “bien” y no decir “estoy de acuerdo”.

Sin embargo estas frases fragmentadas provocan que los analizadores semánticos tradicionales fallen, como consecuencia de esto, aparecen los analizadores conceptuales, estos operan basándose en la detección de palabras clave y organizándolas en frames que contienen slots, que definen el rol apropiado que juegan estas palabras, en el contexto de la descripción que se quiere realizar.

### 3.1.4 Perfeccionando el proceso de análisis sintáctico/semántico

“El proceso de análisis semántico convencional puede ser perfeccionado, asignando grados de probabilidad, a la selección de palabras. Bajo este enfoque una gramática tradicional puede ser aumentada con las probabilidades de secuencias de palabras, basadas en el análisis de un corpus<sup>9</sup> de frases hechas por usuarios inexpertos intentando realizar una tarea determinada” [Schmandt 1994].

Pero en el lenguaje hablado estas probabilidades son dinámicas y dependen del estado actual de la conversación, y es tanto como decir, qué es lo que se espera escuchar de alguien que va a comenzar a hablar. En un enfoque de modelo de lenguaje se puede sugerir que las probabilidades más altas de ciertas palabras se relacionan con atributos de entidades recientemente discutidas o mencionadas, ayudando a la solución de referencias anafóricas. Algunas restricciones son indudablemente necesarias para poder tener un buen entendimiento de un diálogo fluido, y además porque también son muy usadas por los humanos.

## 3.2 Modelos de Lenguaje

El modelado estadístico de la estructura del lenguaje hablado es crucial para los componentes de reconocimiento y entendimiento del habla de las interfaces de voz. Dentro de las restricciones lingüísticas más empleadas, son las reglas sintácticas y las que obtienen la probabilidad de la combinación de palabras, ya que limitan el espacio de búsqueda, en la tarea de reconocimiento.

“Con el uso de estas técnicas, se da lugar a dos logros notables, por una parte una precisión perceptiblemente mejorada en el reconocimiento, y el potencial suficiente para el manejo de vocabularios más grandes” [Schmandt 1994].

---

<sup>9</sup> Un *corpus* es una colección de datos lingüísticos organizados de tal manera que faciliten su investigación, y referencia a estos mismos datos.

### 3.2.1 Los N-grams

Este modelo de lenguaje para la predicción de palabras usa las N-1 palabras anteriores para predecir la siguiente. Como un modelo probabilístico se requiere de la estimación *a priori* de una secuencia de palabras  $W = w_1, w_2, \dots, w_n$  que pueden ser factorizadas en probabilidades condicionales como:

$$P(W) = P(w_1, w_2, \dots, w_n) = \prod_{i=2}^n P(w_i | w_{i-1}, \dots, w_1) \quad (1)$$

La estimación de un conjunto muy grande de probabilidades, a partir de otro conjunto de entrenamiento finito, no es posible. Tal desventaja puede ser superada haciendo uso de modelos N-grams. En este caso la probabilidad condicional de una palabra  $w_i$  en la posición  $i$  es evaluada considerando solo las N-1 palabras anteriores en la oración actual [Becchetti & Prina 2000].

Dado que la memoria N define el número de probabilidades a ser estimadas ( $= |V|^N$ ), valores bajos de N son requeridos para obtener suficiente precisión dado un conjunto limitado de entrenamiento. Únicamente modelos con memorias de una, dos y tres palabras, llamados, *unigram*, *bigram* y *trigram* son generalmente empleados.

#### 3.2.1.1 Modelo Unigram

La memoria de un modelo Unigram se restringe solo a una palabra, por lo tanto las palabras anteriores en la frase actual no son consideradas, la probabilidad de cada palabra se calcula por su frecuencia relativa:

$$P(w^{(i)}) = \frac{N(w^{(i)})}{N} \quad w^{(i)} \in V, i = 1, \dots, |V| \quad (2)$$

Donde  $N(w^{(i)})$  es el número de ocurrencias de la palabra  $w^{(i)}$  en el conjunto de entrenamiento. Este modelo es usado de manera aislada con poca frecuencia, debido a que la restricción de la probabilidad de una palabra no es muy útil por sí sola. En su lugar es más usual combinarlo con probabilidades *Bigram* y *Trigram*, y el uso de técnicas de palabras clave [Becchetti & Prina 2000].

### 3.2.1.2 Modelo *Bigram*

El modelo *Bigram* está basado en la aproximación de que una palabra es estadísticamente dependiente de la palabra temporal anterior. En el modelo *Bigram* tenemos:

$$P(W) \approx \prod_{i=2}^N P(w_i | w_{i-1}) \quad (3)$$

Donde la probabilidad de tener una palabra  $w^{(m)}$  en el índice genérico de tiempo  $i$  cuando la palabra previa es  $w^{(m')}$  está dada por:

$$P(w_i = w^{(m)} | w_{i-1} = w^{(m')}) \approx \frac{N(w_i = w^{(m)} | w_{i-1} = w^{(m')})}{N(w^{(m)})} \quad (4)$$

en la fórmula anterior  $N(w_i = w^{(m)} | w_{i-1} = w^{(m')})$  es el número de ocurrencias de la secuencia  $\langle w_i = w^{(m)}, w_{i-1} = w^{(m')} \rangle$  en el conjunto de entrenamiento.

### 3.2.1.3 El modelo *Trigram*

En el modelo *Trigram* la probabilidad estimada de una secuencia de palabras está dada por:

$$P(W) \approx P(w_1, w_2, \dots, w_N) \approx P(w_1) \prod_{i=2}^N P(w_i | w_{i-1}, w_{i-2}) \quad (5)$$

La probabilidad es estimada usando la aproximación de frecuencia relativa:

$$P(w_1, w^m | w_{i?1}, w_{i?2}, \dots, w_{i?n}) \approx \frac{N(w_i, w^m | w_{i?1}, w_{i?2}, \dots, w_{i?n})}{N(w_{i?1}, w_{i?2}, \dots, w_{i?n})} \quad (6)$$

### 3.2.2 Perplejidad

Un método muy útil para evaluar el impacto de un modelo de lenguaje en la precisión del reconocimiento es la perplejidad. ‘La perplejidad es de forma general, el número de opciones en un determinado punto de decisión’ [Lee 1989]. La definición de perplejidad se deriva de la teoría de la información y de la definición de *logprob*:

$$LP = \frac{1}{N} \sum_{i=1}^N \log_2 P(w_i | w_{i?1}) \quad (7)$$

Y la perplejidad esta definida como:

$$PP = 2^{LP} = P(w_1, w_2, \dots, w_N)^{1/N} \quad (8)$$

Para el modelo bigram anterior quedaria:

$$PP = 2^{LP} = 2^{\frac{1}{N} \sum_{i=1}^N \log_2 P(w_i | w_{i?1})} = \prod_{i=1}^N P(w_i | w_{i?1})^{\frac{1}{N}} \quad (9)$$

Obviamente la perplejidad depende de los datos usados para su evaluación y del modelo de lenguaje actual. Si deseamos conocer la calidad del modelo de lenguaje, se puede evaluar la perplejidad en los conjuntos de entrenamiento y de prueba, para una comparación posterior entre sus resultados. Valores bajos de perplejidad en los datos de entrenamiento, revelan una buena capacidad de modelado de lenguaje de estos datos, estos pueden no ser equivalentes a valores bajos de perplejidad cuando se esta evaluando el conjunto de prueba. En este caso estos resultados revelan una capacidad de generalización pobre del modelo de lenguaje, dado que el modelo es demasiado específico para los datos de entrenamiento [Becchetti & Prina 2000].

### 3.2.3 Ejemplo del uso de N-grams

Aquí mostraremos un pequeño ejemplo del uso de un modelo de lenguaje para el entendimiento del habla sobre una aplicación telefónica. Este es un pequeño modelo basado en un fragmento del *Proyecto de Restaurantes Berkeley* [Jurafsky & Martín 2000], el cual recupera información sobre restaurantes en el área metropolitana de Berkeley, California.

En la siguiente tabla mostraremos la probabilidad en un modelo bigram para la combinación de algunas palabras que pueden seguir a comer o comida.

Comer en	0.16	Comida Hindú	0.04
Comer algo	0.06	Comida Tailandesa	0.03
Comer un	0.04	Comida China	0.02
Comer postre	0.07	Comida Mexicana	0.02
Comer hoy	0.03	Comida Inglesa	0.001
Comer mañana	0.01		

Tabla 3.1: Indices de probabilidad modelo bigram para palabras comer y comida, tomadas como ejemplo del *Proyecto de Restaurantes Berkeley*.

Además agregando parte de la gramática que incluye otras probabilidades como son:

(el símbolo <s> indica “inicio de oración”)

<s>Yo	0.25	Yo quiero	0.32	Quierotomar	0.05	Comer a	0.26	Buen comer	0.06
<s>Opino	0.06	Yo podria	0.29	No comer	0.15	Un restaurante	0.14	Rest. ing.	0.15
<s>Por	0.04	Por que	0.04	Quiero algo	0.04	En un	0.09	Cosina ingl.	0.01
<s>Siento	0.02	Que no	0.008	Quierocomer	0.01	Alguna bebida	0.02	Bebida nal.	0.01

Tabla 3.2: Complemento de Gramática para el modelo de lenguaje basado en el *Proyecto de Restaurantes Berkeley*.

Dada las oraciones:

- a) *Yo quiero tomar alguna bebida Nacional.*
- b) *Por que no comer en un restaurante inglés.*

Para calcular su probabilidad de acuerdo a los índices de las tablas anteriores quedarían:

Para a)

$$\begin{aligned} P(\text{Yo quiero tomar alguna bebida Nacional}) &= P(\text{Yo} | \langle s \rangle) P(\text{quiero} | \text{Yo}) \\ & P(\text{tomar} | \text{quiero}) \\ & P(\text{alguna} | \text{tomar}) P(\text{bebida} | \text{alguna}) \\ & P(\text{nacional} | \text{bebida}) \\ &= .25 * .32 * .05 * .14 * .02 * .01 \\ &= .112 \times 10^{-6} \end{aligned}$$

Para b)

$$\begin{aligned} P(\text{Por que no comer en un restaurante inglés}) &= P(\text{Por} | \langle s \rangle) P(\text{que} | \text{Por}) P(\text{no} | \text{que}) \\ & P(\text{comer} | \text{no}) P(\text{en} | \text{comer}) P(\text{un} | \text{en}) \\ & P(\text{restaurante} | \text{un}) P(\text{inglés} | \text{restaurante}) \\ &= .04 * .04 * .008 * .15 * .16 * .09 * .14 * .15 \\ &= .00000580608 \times 10^{-6} \end{aligned}$$



### 3.3 Gramáticas libres de contexto probabilísticas (Probabilistic Context Free Grammars, PCFGs)

¿Cuál es la ventaja de usar gramáticas y parseo probabilísticos? Una contribución de importancia del parsing probabilístico es la desambiguación. El algoritmo de Earley (Earley 1970) puede prevenir las ambigüedades pero no resolverlas. Una gramática probabilística ofrece una solución al problema, escoger la interpretación más probable. Otro uso importante de las gramáticas probabilísticas es en el modelado de lenguaje para el reconocimiento de voz. Notamos que los modelos N-gram son muy útiles en la predicción de palabras, versiones probabilísticas de gramáticas más sofisticadas pueden agregar poder predictivo al reconocedor. Es cierto que se está encontrando evidencia psicológica acerca de que los humanos usan algo semejante a las gramáticas probabilísticas en las tareas de procesamiento de lenguaje.

#### 3.3.1 Definición de una PCFG

Recordando que una gramática libre de contexto está descrita por cuatro parámetros que son:

?

$$(N, \Sigma, P, S)$$

donde:

1.  $N$  es un conjunto de símbolos no terminales (o “variables”)
2.  $\Sigma$  un conjunto de símbolos terminales (disjunto de  $N$ )
3. Un conjunto de producciones  $P$ , cada una de la forma  $A \rightarrow \alpha$ , donde  $A$  es un símbolo no terminal y  $\alpha$  es una cadena de símbolos de un conjunto finito de cadenas ( $\alpha \in N^*$ )
4. Un símbolo determinado como inicio  $S$

Una gramática libre de contexto probabilística aumenta a cada regla un índice de probabilidad condicional:

$$A \rightarrow \alpha \mid p \quad (10)$$

Una gramática libre de contexto probabilística PCFG es entonces un 5-tupla  $G = (N, \Sigma, P, S, D)$  donde  $D$  es una función que asigna probabilidades a cada regla en  $P$ . Esta función expresa la probabilidad  $p$  que dado un símbolo terminal  $A$  puede expandirse hasta la secuencia  $\alpha$ , esto a menudo se refiere como

$$P(A \rightarrow \alpha) \quad (11)$$

O como:

$$P(A \rightarrow \alpha) \quad (12)$$

Una PCFG puede ser usada para estimar un número de probabilidades útiles concernientes a una oración y su árbol semántico. Por ejemplo una PCFG asigna una probabilidad a cada árbol semántico  $T$  de una oración  $S$ . Esta característica es muy útil para la desambiguación [Jurafsky & Martín 2000].

La probabilidad de un árbol semántico  $T$  esta definida como el producto de las probabilidades de todas las reglas  $r$  usadas para expandir cada nodo  $n$  en el árbol semántico:

$$P(T, S) = \prod_{n \in T} p(r(n)) \quad (13)$$

Los resultados de la probabilidad  $P(T, S)$  son en ambos la probabilidad conjunta de el análisis semántico y de la oración, así como también la probabilidad correspondiente a su árbol semántico. Es posible definir PCFGs a dos niveles: Al nivel de frase y al nivel de oración.

Al nivel de oración, una PCFG provee un análisis sintáctico completo de una oración considerando todas las palabras. De estas se espera un buen funcionamiento para las oraciones gramaticales (aquellas cubiertas por la gramática) pero fallan totalmente en oraciones sin una construcción gramatical permitida. Por lo cual su uso para aplicaciones de lenguaje es muy limitada. De la otra forma al nivel de frase las PCFGs se enfocan en la sintaxis de fragmento de oraciones. Estas permiten un análisis parcial de oraciones y son más apropiadas para el modelado de lenguaje [Hacioglu & Ward 2001a].

Las PCFGs tienen propiedades complementarias a los N-grams. Ellas son combinadas de varias maneras para obtener una mejor perplejidad y un mejor desempeño en los procesos de reconocimiento y entendimiento [Hacioglu & Ward 2001a].

Una PCFG se dice que es consistente si la suma de las probabilidades de todas las oraciones en un lenguaje da 1 [Jurafsky & Martín 2000]. Ciertos tipos de reglas recursivas causan que una gramática sea inconsistente, por que se presentan derivaciones cíclicas infinitas para algunas oraciones.

### 3.3.2 Ejemplo del uso de una PCFG

Consideremos dos análisis de la frase “El diario sale temprano”. La probabilidad de cada árbol semántico de la figura 3.1 puede ser calculada a través de la multiplicación de cada una de las reglas usadas para la derivación. Las probabilidades de cada regla se muestran en la tabla 3.3

O -> S P	[.80]	O -> S	[.50]	P -> Verb Adj.	[.45]
S -> NP. Adj.	[.20]	P -> Verb.	[.20]	OD -> NP Adj.	[.20]
S -> Art NP.	[.25]	P -> Verb. COMP.	[.65]	OD -> Art. NP	[.23]
NP. -> Nomb.	[.18]	COMP. -> OD	[.35]	OI -> Prep. NP	[.15]
NP. -> Pronom.	[.15]	COMP. -> OD OI	[.30]	OI -> Art. NP	[.10]

Tabla 3.3 Estas son las reglas de producción con sus respectivas probabilidades, hechas para una mera ejemplificación de su uso.

Si tomamos en cuenta dos posibles interpretaciones para la frase "El diario sale temprano", una puede referirse a una persona Juan por ejemplo, podríamos describirla como "Juan diario sale temprano" (P(I<sub>1</sub>)). La segunda, si nos referimos a una publicación podríamos describirla como "El universal sale temprano" (P(I<sub>2</sub>)). Para ambos casos formaremos sus árboles semánticos de acuerdo a reglas de producción propuesta dentro de una PCFG con sus respectivas probabilidades y agregando la probabilidad que se muestra para cada palabra (ver tabla 3.4) de acuerdo a la función que ejerce en la frase. En la figura 3.1 se pueden observar los árboles semánticos y el respectivo calculo para cada interpretación de la frase original.

Adj. -> diario	[.12]	Nomb. -> Juan	[.60]	Pronom -> ustedes	[.20]
Adj. -> temprano	[.18]	Nomb. -> Universal	[.30]	Pronom -> Yo	[.55]
Art. -> La	[.65]	Nomb. -> diario	[.25]	Verb -> sale	[.50]
Art. -> El	[.70]	Pronom. -> El	[.25]	Verb -> es	[.38]

Tabla3.4 Probabilidades de las palabras empleadas, en las interpretaciones de la frase "El diario sale temprano" para ejemplificar el uso de las PCFGs.

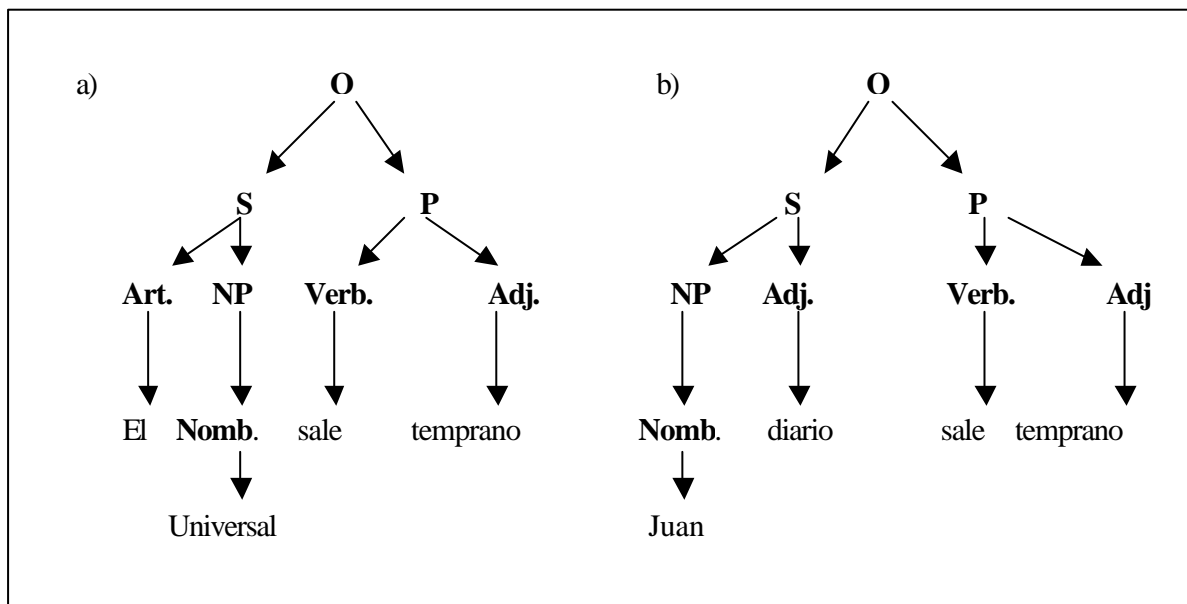


Figura 3.1 Árboles semánticos formados de acuerdo a las dos posibles interpretaciones para la frase "El diario sale temprano" y de acuerdo a sus respectivas reglas de producción.

Las reglas empleadas para cada árbol de acuerdo a las probabilidades de las tablas 3.3 y 3.4 son:

Para a)		Para b)	
O -> S P	[.80]	O -> S P	[.80]
S -> Art. NP	[.25]	S -> NP Adj.	[.20]
NP -> Nomb.	[.18]	NP -> Nomb.	[.18]
Art -> El	[.70]	Nomb -> Juan	[.60]
Nomb. -> Universal	[.30]	Adj. -> diario	[.25]
P -> Verb Adj	[.45]	P -> Verb. Adj.	[.45]
Verb -> sale	[.50]	Verb. -> sale	[.50]
Adj -> temprano	[.18]	Adj. -> temprano	[.18]

El calculo de las probabilidades para cada árbol de acuerdo a las mostradas en las tablas 3.3 y 3.4 serian:

Para  $P(I_1)$ :

$$P(I_1) = .80 * .25 * .18 * .70 * .30 * .45 * .50 * .18 \\ = 3.0618 \times 10^{-4}$$

para  $P(I_2)$ :

$$P(I_2) = .80 * .20 * .18 * .65 * .25 * .45 * .50 * .18 \\ = 1.8954 \times 10^{-4}$$

Si el contexto en el que se presenta esta frase, nos referimos a la relación que existe sobre la emisión de noticias en ciertos medios de información, entonces de acuerdo al resultado del calculo de la probabilidad de las posibles interpretaciones, con respecto a sus reglas de producción de la PCFG propuesta en las tablas anteriores, y tomando en cuenta el estado actual del contexto, la referencia hecha a la publicación es la correcta.

### **3.4 Entendimiento de Lenguaje basado en conceptos**

Como se había mencionado antes, la obtención de un modelo estadístico de un lenguaje, es una cuestión demasiado importante para los módulos de reconocimiento y entendimiento, integrantes de una interfaz de voz. Se han estudiado dos modelos de lenguaje los N-grams y las PCFG's, ahora podemos mostrar una implementación de la combinación de estos modelos para lograr una integración mayor para los módulos antes mencionados.

Esta implementación fue desarrollada por los doctores Kadri Hacioglu y Wayne Ward ambos investigadores del CSLR. Ellos consideran al modelado de lenguaje como un problema dentro de una estructura de trabajo que esta incluida como una decodificadora de conceptos, y que a su vez es un intento por lograr una mayor integración entre los procesos de reconocimiento y de entendimiento del lenguaje.

#### **3.4.1 Modelado de lenguaje combinando N-grams y PCFG's**

En esta implementación se divide al modelado de lenguaje en dos componentes, uno como modelador del diálogo dependiendo del concepto y el otro como un modelador sintáctico. Para el primero estructuran al lenguaje usando N-grams, y para el segundo como un conjunto de PCFG's, una para cada concepto.

Los conceptos son clases de frases con el mismo significado, dicho de otra forma una clase concepto es un conjunto de todas las frases que pueden ser usadas para expresar ese concepto. La estructura de secuencia de conceptos es capturada por probabilidades de modelos tipo *Trigram*, los cuales arrojan la probabilidad de esa secuencia dependiente del contexto del diálogo.

Cada clase es escrita como una CFG (Context Free Grammar) y compilada en una red de transición recursiva estocástica (STRN). Los arcos (o reglas) son etiquetados con probabilidades, después de un entrenamiento previo. En los casos cuando el parser falla, una frase puede descomponerse en secuencias de palabras etiquetándolas y usándolas como un conjunto de clases "filler" (rellenadoras).

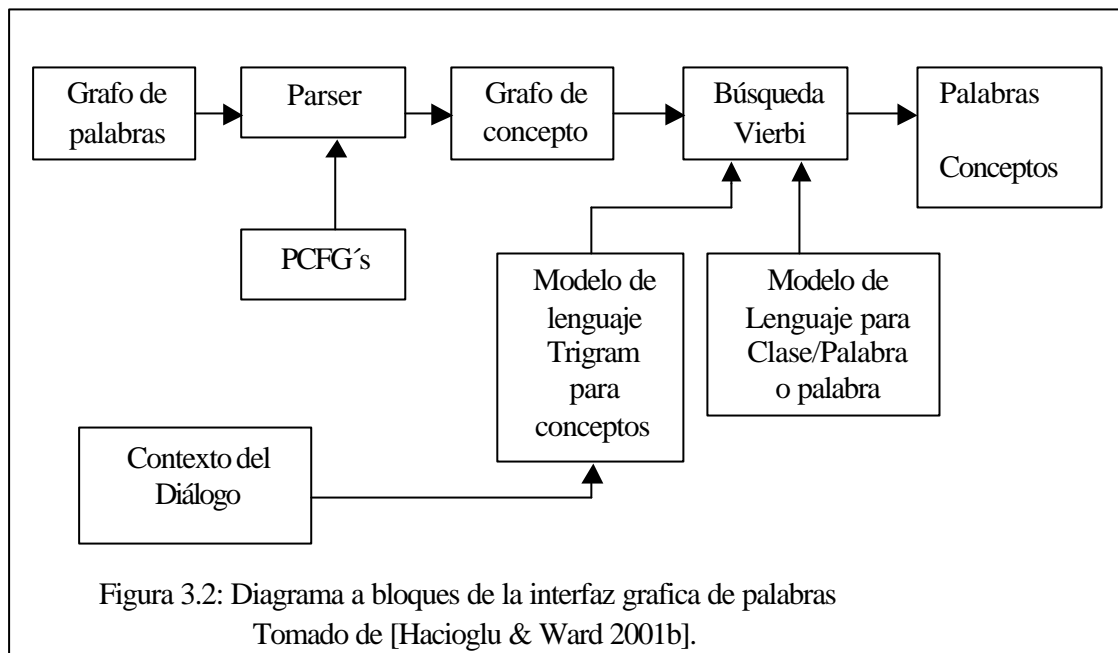
El modelo resultante fue evaluado con frases dentro del contexto del corpus del CU Communicator mostrando un 39% de mejora en la perplejidad y un 6.3% relativo del índice en el error de reconocimiento [Hacioglu & Ward 2001a].

### **3.4.2 La propuesta más reciente del CSLR para la integración del módulo de reconocimiento y de entendimiento de lenguaje**

La meta final de un sistema conversacional es el entender que se ha dicho y realizar la acción correspondiente. Esto sugiere un sistema que mapea esas entradas hechas por voz a acciones [Hacioglu & Ward 2001b]. A excepción de un número reducido de tareas, el estado presente de la tecnología, aún no ofrece una solución efectiva y confiable a este problema. Por lo mismo el CSLR ha tomado un enfoque en el cual descompone ha este problema como una parte que se dedica al entendimiento del habla y otra a la generación de las acciones correspondientes.

Enfocándose a la parte de entendimiento, el trabajo más reciente para la integración de estos los elementos de reconocimiento y entendimiento, en la interfaz conversacional del CSLR, el CU Communicator, han implementado lo que denominan como una *Word Graph Interface* (interfaz grafica de palabras) la cual desarrolla un entendimiento flexible del habla, basado en un modelado estocástico de conceptos, aumentado con un modelo “filler” (rellenador) de trasfondo.

En este nuevo sistema se da un enfoque de parser estocástico (o probabilístico) para convertir un grafo de palabras a un grafo de conceptos. El grafo de conceptos, es entonces sometido a una búsqueda Viterbi [Jurafsky & Martín 2000] para hallar la mejor secuencia usando un modelo de lenguaje basado en el contexto del diálogo (antes mencionado). La secuencia de conceptos detectados y sus respectivas secuencias de palabras son enviadas al Parser Phoenix para extraer sus significado. La secuencia de conceptos restringe el uso de gramáticas semánticas para analizar la secuencia de palabras.



Con lo anterior hemos presentado un enfoque para la comprensión de lenguaje hablado, como un intento de hallar un mayor acercamiento a la forma de entendimiento del lenguaje, usado por los humanos. En el siguiente capítulo presentaremos el procedimiento que se efectuó para hacer las modificaciones pertinentes, y poder lograr un funcionamiento que captara el análisis de intervenciones tomadas por usuarios inexpertos en esta tecnología, los que para este caso son alumnos de esta misma facultad, que con el fin de dar de alta materias para un semestre determinado, se intenta analizar las entradas producidas por ellos para acoplarlas en un contexto de diálogo y que estas sean analizadas por el módulo de Entendimiento de Lenguaje Natural del CU Communicator, de tal forma que los resultados obtenidos, puedan ser usados por otro módulo de esta interfaz (el Manejador de Diálogo) que forma parte de otro trabajo de Tesis de este mismo laboratorio.