


El lenguaje natural como lenguaje formal

Natural language as a formal language

Franco Martín Luque¹  <https://orcid.org/0000-0002-5316-2500>

Universidad Nacional de Córdoba - Argentina
Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)
 francoq@unc.edu.ar

Resumen

La teoría de lenguajes formales es útil para el estudio de los lenguajes naturales. En particular, resulta de interés estudiar la adecuación de los formalismos gramaticales para expresar los fenómenos sintácticos presentes en el lenguaje natural. Primero, ayuda a trazar hipótesis acerca de la naturaleza y complejidad de las competencias lingüísticas de los hablantes oyentes del lenguaje, un interrogante fundamental de la lingüística y otras ciencias cognitivas. Además, desde el punto de vista de la ingeniería, permite conocer limitaciones prácticas de las aplicaciones basadas en dichos formalismos. En este artículo se hace una introducción al problema de la adecuación de los formalismos gramaticales para el lenguaje natural, introduciendo también algunos conceptos de la teoría de lenguajes formales necesarios para esta discusión. Luego, se hace un repaso de los formalismos que han sido propuestos a lo largo de la historia, y de los argumentos que se han dado para sostener o refutar su adecuación.

Palabras clave: lenguajes formales, lenguaje natural, gramática formal, análisis sintáctico, lingüística computacional, procesamiento de lenguaje natural, aprendizaje automático.

¹ Recibido: 04.02.2021 | Aceptado: 23.02.2021

Abstract

Formal languages theory is useful for the study of natural language. In particular, it is of interest to study the adequacy of the grammatical formalisms to express syntactic phenomena present in natural language. First, it helps to draw hypotheses about the nature and complexity of the speaker-hearer linguistic competence, a fundamental question in linguistics and other cognitive sciences. Moreover, from an engineering point of view, it allows for the knowledge of practical limitations of applications based on those formalisms. This article introduces the problem of adequacy of grammatical formalisms for natural language, also introducing some formal language theory concepts required for this discussion. Then, it reviews the formalisms that have been proposed through history, and the arguments that have been given to support or reject their adequacy.

Keywords: formal languages, natural language, formal grammar, parsing, syntactic analysis, computational linguistics, natural language processing, machine learning.

Introducción

*“One morning I shot an elephant
in my pajamas. How he got into
my pajamas I don’t know.”
Groucho Marx, Animal Crackers
(1930)*

*“Our three weapons are fear,
surprise, ruthless efficiency, and
an almost fanatical devotion
to the Pope.”
Monty Python, The Spanish Inquisition
(1970)*

En el siglo XX se dieron importantes avances en el estudio de la sintaxis del lenguaje utilizando herramientas matemáticas. Uno de sus protagonistas fue Noam Chomsky quien, en la década del 50, dio inicio a la discusión acerca del lugar en el que los lenguajes naturales se sitúan dentro de la

denominada jerarquía de lenguajes formales de Chomsky. Esta discusión continuó luego por varias décadas, provocando incluso la proposición de numerosos formalismos gramaticales nuevos.

En la década del 90, a partir de la irrupción del enfoque basado en datos del aprendizaje automático (*machine learning*), la discusión formalista pasó a un segundo plano. En los años siguientes, con la disponibilidad masiva de datos y el aumento exponencial del poder de computación, la investigación se centró en los métodos empíricos y la evaluación cuantitativa. Esto continuó, y se profundizó, con el auge de las redes neuronales de los últimos años. Sin embargo, también en los últimos años han surgido voces críticas del enfoque dominante en la actualidad dando pie, entre otras cosas, a cierto resurgimiento de un interés por el aspecto teórico de los modelos estudiados.

En este artículo se hace una introducción al problema de la adecuación de los formalismos gramaticales al lenguaje natural, introduciendo también algunos conceptos elementales de la teoría de lenguajes formales, necesarios para esta discusión. Luego, se hace un repaso de los diferentes formalismos gramaticales que han sido propuestos a lo largo de la historia, y de los argumentos que se han dado para sostener o refutar la adecuación de cada uno de éstos. Finalmente, se analiza brevemente la historia reciente de la lingüística computacional en relación al aspecto lingüístico formal.

El artículo se encuentra estructurado de esta forma: en la siguiente sección se hace una breve introducción a la teoría de lenguajes formales, a la notación a utilizar y a dos mecanismos gramaticales básicos para la definición de lenguajes. A continuación, en la sección 3, se define un marco metodológico de la discusión. En la sección 4, se aborda la discusión de la adecuación de los diferentes formalismos gramaticales, recorriendo la jerarquía de Chomsky en orden creciente de expresividad. La sección 5 finaliza el artículo con algunas reflexiones acerca de las implicancias para

las áreas de lingüística computacional y procesamiento de lenguaje natural.

1. Teoría de lenguajes formales

En la teoría de lenguajes formales, un *lenguaje* sobre un alfabeto Σ es un conjunto de secuencias, posiblemente infinito, en donde cada secuencia se compone de una cantidad finita de símbolos tomados del alfabeto Σ .

El conjunto de todas las posibles palabras que se pueden formar con un alfabeto Σ se denota Σ^* . La secuencia vacía también es un elemento posible de un lenguaje y se denota con la letra griega $\lambda \in \Sigma^*$. Usamos letras del comienzo del abecedario (a, b, c, \dots) para representar elementos de Σ , y del final del alfabeto (r, s, t, u, v, \dots) para representar elementos de Σ^* . Escribimos r^n , con $n \geq 0$, para representar la secuencia que resulta de repetir n veces la secuencia r .

Un lenguaje puede ser definido por extensión, como por ejemplo el lenguaje $L = \{a, aba, bab\}$, sobre $\Sigma = \{a, b\}$, o por comprensión, como por ejemplo $L = \{a^n b^n \mid n \geq 0\}$, que es el conjunto de todas las secuencias que tienen primero cierta cantidad de letras a , seguidas de la misma cantidad de letras b . Por supuesto, un lenguaje infinito no puede ser definido por extensión.

Existen diversos mecanismos formales para la definición de lenguajes por comprensión más allá de la notación clásica de conjuntos, que llamaremos *formalismos gramaticales*. Cada formalismo gramatical tiene asociada una *clase de lenguajes*, esto es, el conjunto de todos lenguajes que pueden ser definidos usando tal formalismo. A mayor *poder expresivo*, más grande es la clase de lenguajes asociada.

1.1. La jerarquía de Chomsky

Chomsky estudió diversos formalismos gramaticales desde una perspectiva lingüística. En Chomsky (1956), por primera vez, describió tres modelos formales de creciente expresividad, y estudió la adecuación de cada uno

de ellos para explicar la sintaxis de la lengua inglesa. Más tarde, en Chomsky (1959), abordó un cuarto modelo formal aún más expresivo, las máquinas de Turing, para luego definir los tres modelos anteriores como versiones cada vez más restringidas de estas máquinas.

Los cuatro modelos propuestos por Chomsky componen una jerarquía de formalismos llamada *jerarquía de Chomsky*¹. En la **tabla 1** se muestra la jerarquía, mientras que en la **figura 1** se puede ver la relación de inclusión que existe entre las clases de lenguajes correspondientes.

Tabla 1: Las cuatro clases de lenguajes de la jerarquía de Chomsky, y formalismos gramaticales representativos para cada una de ellas.

Clase de Lenguajes	Formalismo Gramatical
Recursivamente Enumerables (REs)	Máquinas de Turing
Sensibles al Contexto (CSLs)	Gramáticas Sensibles al Contexto (CSGs)
Libres de Contexto (CFLs)	Gramáticas Libres de Contexto (CFGs)
Regulares	Autómatas Finitos Deterministas (DFAs)




Figura 1: Relación de inclusión entre las cuatro clases de lenguajes de la jerarquía de Chomsky mostradas en la tabla 1.


1 A veces llamada jerarquía de Chomsky-Schützenberger, esta jerarquía no puede ser atribuida únicamente a Chomsky, ya que muchos autores participaron en el estudio y la proposición de los formalismos que la componen.

En las siguientes secciones se introducen los dos formalismos más simples dentro de la jerarquía: los autómatas finitos deterministas y las gramáticas libres de contexto.

1.2. Autómatas Finitos Deterministas

Un *Autómata Finito Determinista* (DFA, por sus siglas en inglés) es una máquina de estados que emite un símbolo del alfabeto cada vez que se realiza una transición de un estado a otro. Siempre comienza en un único estado denominado *estado inicial*, y termina en cualquier estado que pertenezca a un conjunto de *estados finales*. Luego, un DFA se define por los siguientes elementos:

- Un alfabeto finito Σ ,
- un conjunto finito de estados Q ,
- un estado inicial $q_0 \in Q$,
- un conjunto de estados finales $F \subseteq Q$ y
- una función de transición $\delta: Q \times \Sigma \rightarrow Q$, tal que $\delta(p, a) = q$ indica que la transición que parte del estado p emitiendo el símbolo a tiene como destino el estado q . Gráficamente:



El lenguaje definido por un DFA es el conjunto de secuencias que pueden ser generadas en cualquier recorrido del autómata que empiece en el estado inicial y termine en un estado final.

Un ejemplo gráfico de un DFA se muestra en la **figura 2**. Este DFA define un lenguaje de oraciones de un lenguaje natural de juguete, esto es, un

lenguaje simplificado que imita algunas características mínimas presentes en los lenguajes naturales. El estado inicial es q_0 , como se indica con la flecha que lo apunta, y los estados finales son aquellos que tienen doble contorno. Por simplicidad, se define un lenguaje sobre un alfabeto de categorías léxicas, con símbolos que representan pronombres (Prn), verbos (Verb), determinantes (Det), etc. En la **figura 3** puede verse el recorrido que muestra que la oración “Prn Verb Det Noun Prep Pos Noun” es aceptada por el DFA.




Figura 2: Ejemplo de autómata finito determinista (DFA) para un lenguaje natural de juguete. Por simplicidad, se describe un lenguaje sobre un alfabeto de categorías léxicas, en lugar de un lenguaje léxico, con símbolos que representan pronombres, verbos, determinantes, etc. No se dibujan aquellas transiciones que no pueden conducir a un estado final.




Figura 3: Recorrido de aceptación de la secuencia de ejemplo “Prn Verb Det Noun Prep Pos Noun”.

El conjunto de todos los lenguajes posibles que pueden ser generados por DFAs constituye la clase de *lenguajes regulares*. Existen otros formalismos con el mismo poder expresivo, como los autómatas finitos no-deterministas o las expresiones regulares.

Hay, por supuesto, muchos lenguajes que no son regulares, es decir, que no pueden ser generados por ningún DFA. Un ejemplo arquetípico de lenguaje no regular es el ya mencionado $L = \{a^n b^n \vee n \geq 0\}$.

Existe al menos una manera de demostrar que un lenguaje no es regular, utilizando el denominado *pumping lemma*. Este lema hace uso del hecho de que si un lenguaje es regular y al mismo tiempo infinito, el DFA que lo genera obligatoriamente debe tener un ciclo en un camino a un estado final. Haciendo uso de este ciclo se pueden generar infinitas secuencias que obligatoriamente deben pertenecer al lenguaje.

Por ejemplo, se puede probar que si $L = \{a^n b^n \vee n \geq 0\}$ es regular, usando el *pumping lemma* necesariamente debe ser posible generar una secuencia $a^n b^m$ con $n \neq m$, y por lo tanto esta secuencia debe pertenecer al lenguaje L . Como esto es absurdo, L no es regular.

1.3. Gramáticas Libres de Contexto

Una *Gramática Libre de Contexto* (CFG, por sus siglas en inglés) es un sistema que permite construir secuencias a partir de la aplicación repetida de reglas. Las reglas permiten reemplazar símbolos no-terminales por secuencias de terminales (símbolos del alfabeto) y no-terminales. Luego, una CFG se define por los siguientes elementos:

- un alfabeto finito Σ (terminales),
- un conjunto finito de no-terminales N (también llamados estados),
- un no-terminal inicial $S \in N$ y
- un conjunto de reglas R , que escribimos de la forma $X \rightarrow \alpha$, en donde $X \in N$ y $\alpha \in \Sigma^*$ es una secuencia de terminales y no-terminales.

El lenguaje definido por una CFG es el conjunto de secuencias de terminales que resulta de cualquier derivación que comience desde el no-terminal inicial S . Puede suceder que una misma secuencia sea derivada de maneras diferentes. En este caso, se dice que la CFG es ambigua.

Un ejemplo de CFG sobre el alfabeto $\Sigma = \{a, b\}$ es el que tiene un único no-terminal S y el conjunto de reglas


$$R = \{S \rightarrow \lambda, S \rightarrow aSb\}.$$

El lenguaje generado por esta CFG es $L = \{a^n b^n \vee n \geq 0\}$. Puede verse que la segunda regla es recursiva y por lo tanto puede ser aplicada cíclicamente.

Otro ejemplo de CFG se puede ver en la **figura 4**. Por brevedad, las reglas se muestran agrupadas por no-terminal del lado izquierdo, uniendo los diferentes lados derechos con el conector |. En la **figura 5** se pueden ver dos derivaciones diferentes para una misma secuencia, por lo que esta CFG es ambigua.

$S \rightarrow NP VP$	(oraciones)
$NP \rightarrow Prn \mid Det Noun \mid Pos Noun \mid NP PP$	(sintagmas nominales)
$VP \rightarrow Verb NP \mid VP PP$	(sintagmas verbales)
$PP \rightarrow Prep NP$	(sintagmas preposicionales)
$Prn \rightarrow \acute{E}l \mid \dots$	(pronombres)
$Det \rightarrow un \mid \dots$	(determinantes)
$Noun \rightarrow elefante \mid pijamas \mid \dots$	(sustantivos)
$Verb \rightarrow mató \mid \dots$	(verbos)
$Prep \rightarrow en \mid \dots$	(preposiciones)
$Pos \rightarrow sus \mid \dots$	(posesivos)

Figura 4 Ejemplo de gramática libre de contexto (CFG) para un lenguaje natural de juguete






Figura 5: Dos análisis posibles para la oración “Él mató un elefante en sus pijamas” de acuerdo a la CFG de la figura 4.

El conjunto de todos los lenguajes que pueden ser generados por CFGs se denomina la clase de *lenguajes libres de contexto* (CFLs). Esta clase incluye a todos los lenguajes regulares y también contiene lenguajes no-regulares. Es decir, las CFGs tienen un mayor poder expresivo que los DFAs.

Tal como en el caso de los lenguajes regulares, también para los lenguajes libres de contexto existe una versión del *pumping lemma* que se puede utilizar para demostrar que un lenguaje no es libre de contexto. Por ejemplo, se puede demostrar por el absurdo que $L = \{a^n b^n c^n \vee n \geq 0\}$ no es libre de contexto ya que, si lo fuera, por el *pumping lemma* también deberían pertenecer al lenguaje secuencias en las que la cantidad de letras a , b y c no coinciden.

2. Consideraciones metodológicas

El estudio del lenguaje natural como un lenguaje formal requiere de un conjunto de suposiciones y definiciones previas. La mayor parte de ellas se remontan a los orígenes de la lingüística generativa de Chomsky (Chomsky, 1957, pp. 13-17; Chomsky, 1965, pp. 3-4), y se sostienen hasta el día de hoy en las principales ramas de la lingüística formal. En esta sección se repasan brevemente las suposiciones y definiciones más relevantes.

2.1. Gramaticalidad vs. aceptabilidad

El primer conjunto de suposiciones se refiere a una idealización de las capacidades lingüísticas humanas. A la hora de discutir el lenguaje natural, se asume un *hablante-oyente ideal* sin limitaciones de memoria, distracciones o errores. Además, desde el generativismo se asume que los lenguajes naturales tienen un comportamiento estático en el tiempo y el espacio: No cambian ni evolucionan, ni varían dentro de la comunidad de hablantes.

En este marco, la *gramática generativa* de un lenguaje natural es la descripción de la competencia lingüística del hablante-oyente ideal de ese lenguaje. Así, podemos hablar de la *gramaticalidad* de una oración para indicar que ésta puede ser explicada por las reglas de la gramática. En este sentido, suponemos que se puede identificar a un lenguaje natural con el conjunto actual y potencial de oraciones gramaticales que la componen.

Siendo la gramática un objeto ideal e inasequible, solo se puede recurrir a métodos indirectos para determinar la gramaticalidad de las oraciones. Uno de los principales recursos metodológicos que se ha utilizado en la literatura es el juicio intuitivo de hablantes-oyentes competentes.

El concepto de gramaticalidad puede verse en contraste con el de *aceptabilidad*, que se refiere a cuán aceptable es una oración para un hablante-oyente no ideal al margen del estricto cumplimiento de reglas gramaticales. En la aceptabilidad intervienen otros factores como simplicidad, comprensibilidad, frecuencia, etc.

Un ejemplo clásico que permite ilustrar la diferencia entre gramaticalidad y aceptabilidad es la famosa oración de Chomsky (1957)

Colorless green ideas sleep furiously.

(Ideas verdes incoloras duermen furiosamente.)

Esta oración es inaceptable por carecer de significado pero se corresponde con las reglas gramaticales de la lengua inglesa y es consistentemente juzgada como gramatical por los hablantes-oyentes de la lengua.

Otros ejemplos ilustrativos pueden ser construidos a partir de las reglas gramaticales de subordinación. La repetición excesiva de subordinaciones permite construir oraciones gramaticales aunque inaceptables desde el punto de vista cognitivo. Se verán ejemplos de este tipo en la **sección 4.1**.

2.2. Adecuación débil vs. adecuación fuerte

Existe una distinción importante a la hora de considerar la adecuación de formalismos gramaticales para expresar el lenguaje natural (Chomsky, 1965, pp. 60-62).

La *adecuación débil* es la capacidad de un formalismo de expresar el conjunto de oraciones gramaticalmente correctas de los lenguajes naturales. Esta adecuación no garantiza que el formalismo sea capaz de dar las descripciones estructurales correctas de las oraciones. La *adecuación fuerte* refiere a esta última capacidad.

La relevancia lingüística de la distinción entre adecuación débil y adecuación fuerte puede ser apreciada con el siguiente ejemplo. Consideremos la gramática de la **figura 4**, que corresponde a una versión simplificada de la lengua inglesa. A pesar de que se trata de una CFG, el lenguaje generado es regular ya que también puede ser generado por el DFA de la **figura 2**.¹ Luego, tanto los DFAs como las CFGs son débilmente adecuadas para expresar este lenguaje de juguete. Sin embargo, en términos de adecuación fuerte, la representación que ofrece el DFA no es admisible, ya que no permite expresar algunas propiedades estructurales del inglés. Por ejemplo, para la oración

¹ La afirmación de que la CFG y el DFA generan el mismo lenguaje requiere de una demostración matemática, que se omite en este trabajo.

Él mató a un elefante en sus pijamas.

la adecuación fuerte requiere una manera de expresar la ambigüedad de que la frase preposicional “en sus pijamas” puede afectar o bien al verbo (matar) o bien al objeto (el elefante).¹ Las CFGs son capaces de hacer esta distinción permitiendo la asignación de estructuras ambiguas para la oración, tal como se muestra en la **figura 5**.

2.3. Tratabilidad y complejidad

Un criterio adicional surge ya desde Chomsky (1965), al incluir como requisito para la adecuación la existencia de un método para resolver el problema de obtener la descripción estructural de una oración dada. Nos referimos a este problema como el *problema del análisis (parsing)*. Un problema asociado al problema del parsing es el *problema de reconocimiento*, que se trata de decidir si una oración dada es gramatical.

En el ámbito de los lenguajes formales, denominamos *tratabilidad* a la existencia de soluciones algorítmicas para resolver estos problemas. Además de la *tratabilidad*, también nos interesa la *complejidad* de los algoritmos, esto es, la cantidad de tiempo y espacio de cómputo que se requieren para solucionar los problemas mencionados.

Para considerar adecuado un formalismo gramatical en cuanto a complejidad, deben existir algoritmos eficientes para la solución de estos problemas. En general, se considera aceptable una complejidad de *orden polinomial*, esto es, que el tiempo y el espacio requerido por los algoritmos sean funciones polinómicas en términos del tamaño de la gramática y del largo de la oración de entrada.

¹ Este ejemplo se deriva de la frase de Groucho Marx citada al comienzo del artículo. La gracia de la frase reside justamente en la ambigüedad explicada.

3. Modelos formales del lenguaje natural

La jerarquía de Chomsky es un buen punto de comienzo para determinar el lugar que le corresponde al lenguaje natural dentro del mundo de los lenguajes formales. En esta sección se hace una recorrida de la jerarquía, revisando los argumentos que se han dado en la literatura en cada caso para apoyar o refutar la adecuación de los diferentes formalismos gramaticales.

3.1. El lenguaje natural como lenguaje regular

La primera pregunta a responder, y aparentemente la más fácil, es si los lenguajes naturales son regulares. En términos de adecuación fuerte, ya se vio en la **sección 3.2** que al menos los DFAs no permiten ofrecer descripciones estructurales ambiguas como las que se presentan en el fenómeno de la adjunción de los sintagmas preposicionales. Sin embargo, esto no significa que no puedan existir otros mecanismos regulares que sean capaces de hacer esto, como por ejemplo los autómatas no-deterministas. De cualquier manera, la posibilidad de la adecuación fuerte de cualquier mecanismo regular queda descartada al comprobar que los lenguajes regulares no son ni siquiera débilmente adecuados.

Existen en la literatura muchas maneras de probar la no-regularidad del lenguaje natural. Chomsky (1957, pp. 21-22) presentó pruebas basadas en partes de la lengua inglesa que toman la forma de lenguajes no-regulares como $L = \{a^n b^n \vee n \geq 0\}$ o el lenguaje de las palabras capicúa $L = \{x \in \{a, b\}^* \vee x = reverse(x)\}$.

Partee (1990, pp. 480-482) elaboró una prueba basada en el fenómeno del *center-embedding* (subordinación central), que permite introducir oraciones subordinadas en el medio de otras oraciones. En el castellano,

por ejemplo, el *center-embedding* permite construir las siguientes oraciones gramaticales:¹

La chiva murió.

La chiva, que el lobo sacó, murió.

La chiva, que el lobo, que el palo golpeó, sacó,
murió.

La chiva, que el lobo, que el palo, que el fuego,
quemó, golpeó, sacó, murió.²

En general, podemos decir que son gramaticales todas las oraciones de la forma

La chiva (, que X)ⁿ (Y ,)ⁿ murió.

Aquí, $X \in \{\text{el lobo, el palo, el fuego, ...}\}$ son sintagmas nominales (NPs), e $Y \in \{\text{sacó, golpeó, quemó, ...}\}$ son verbos transitivos.

Si el lenguaje que incluye todas estas oraciones fuera regular, por el *pumping lemma* para lenguajes regulares sería posible también construir oraciones en donde la cantidad de NPs no coincida con la cantidad de verbos. Es decir, el lenguaje obligatoriamente debería contener algunas oraciones de la forma

La chiva (, que X)^p (Y ,)^q murió.

1 Ejemplo basado en la canción infantil tradicional “Sal de ahí, chivita, chivita”.

2 Esta triple subordinación y subordinaciones de orden mayor, son ejemplos claros de oraciones gramaticales, de acuerdo a la metodología adoptada, pero juzgadas como no aceptables (ver **sección 3.1**).

con $p \neq q$. Sin embargo, sabemos que estas oraciones son no-gramaticales. Por ejemplo, son no gramaticales¹

(*) La chiva sacó, murió. ($p = 0, q = 1$)

(*) La chiva, que el lobo murió. ($p = 1, q = 2$)

Luego, el lenguaje no puede ser regular, ya que de serlo debería incluir oraciones que no incluye.

3.2. El lenguaje natural como lenguaje libre de contexto

La siguiente pregunta es acerca de la adecuación de los lenguajes libres de contexto. En términos de adecuación fuerte, Chomsky afirmó que las gramáticas libres de contexto pueden expresar solo torpemente algunas estructuras sintácticas simples del inglés, como por ejemplo las conjunciones, los verbos auxiliares y la voz pasiva (Chomsky, 1957, pp. 34–43).

Un argumento más concluyente se dio muy posteriormente, entre los años 70 y 80, en torno al fenómeno de las *interdependencias seriales no acotadas* presente, por ejemplo, en el holandés y el alemán suizo² (Bresnan et al., 1982). Este tipo de construcciones tienen la forma general $X^n Y^n$, parecida a la subordinación central discutida en la sección anterior, pero a diferencia de ésta, la estructura sintáctica asocia los elementos de manera intercalada, como se muestra en la figura 6. Las gramáticas libres de contexto pueden expresar lenguajes de la forma $X^n Y^n$, pero no pueden hacerlo utilizando una estructura intercalada como la que requiere este fenómeno sintáctico. Solo pueden hacerlo utilizando reglas con recursividad central, forzando una asociación de los elementos desde el centro hacia afuera, como se muestra en la figura 7.

1 En la literatura se acostumbra marcar con un asterisco (*) los ejemplos de oraciones no gramaticales.

2 El alemán suizo abarca los dialectos del alemán hablados en Suiza y no debe ser confundido con el alemán estándar. En particular, las particularidades gramaticales discutidas en esta sección no valen para el alemán estándar.




Figura 6: Esquema general de la estructura sintáctica de las interdependencias seriales no acotadas presentes en el holandés y el alemán suizo. Se puede ver cómo los elementos se asocian de manera intercalada.




Figura 7: Esquema general de la estructura sintáctica forzada por las gramáticas libre de contexto. Los elementos obligatoriamente deben asociarse desde el centro hacia afuera.

La discusión acerca de la adecuación débil de las gramáticas libres de contexto ha sido mucho más complicada. Luego de que Chomsky planteara la pregunta en 1956, existieron muchos intentos de demostrar la inadecuación débil, varios de ellos refutados por Pullum y Gazdar (1982). Las fallas expuestas de las pruebas van desde errores matemáticos, como un uso incorrecto del *pumping lemma*, pasando por desacuerdos lingüísticos, como la confusión entre fenómenos sintácticos y semánticos, hasta discusiones metodológicas, como la manera en la que se decide la gramaticalidad de las oraciones.

Un ejemplo de argumento fallido es el que elaboró Elster (1978) en torno a oraciones de la forma

Los primeros dos millones (de millones)^{*p*}

de decimales de π son Y^q

a donde Y es un dígito. Según Elster, estas oraciones son gramaticales si y sólo si p y q son tales que la cantidad de decimales en el predicado se corresponde con la indicada en el sujeto ($q = 2 \times 10^{6(p+1)}$). Si este

lenguaje fuera libre de contexto, el *pumping lemma* para CFLs permitiría construir oraciones en las que p y q no se corresponden, es decir, oraciones no gramaticales. Luego, concluye Elster que el lenguaje natural no es libre de contexto.

Pullum y Gazdar (1982) rechazaron de plano este argumento, sosteniendo que la correspondencia entre p y q nada tiene que ver con la gramaticalidad, así como tampoco presentan problemas de gramaticalidad las siguientes oraciones:

A continuación hay seis números al azar: 3, 17, 8, 9, 41.

Nuestras tres armas son miedo, sorpresa,

eficiencia despiadada, y una devoción casi fanática por el Papa.¹

No fue hasta 1985 que se propuso un argumento fuerte en contra de la adecuación débil, dado por Shieber (1985). Shieber construyó un contraejemplo tomado del dialecto alemán suizo que combina interdependencias seriales, como las mencionadas anteriormente para el holandés, con el marcado de casos (*case-marking*) en los objetos, también presente en el alemán. En el *case-marking* del alemán y del alemán suizo, los objetos se pueden marcar en caso acusativo o dativo, y los verbos se dividen en subcategorías dependiendo del caso que requieran para su objeto.

Por ejemplo, en la **figura 8** observamos una triple interdependencia con un correcto marcado de casos. Cada verbo en este ejemplo está asociado con un objeto del caso que le corresponde. En cambio, la oración

* ... mer d'chind **de** Hans es huus lönd hälfe aasriiche

¹ Traducción al castellano de la frase de los Monty Python citada al comienzo del artículo.

no es gramatical, ya que el sintagma “de Hans” está en caso acusativo pero el verbo “hälfe” requiere un objeto de caso dativo (“em Hans”).

En general, una oración con interdependencias seriales es gramatical si y sólo si cada sintagma nominal está marcado con el caso que requiere el verbo que le corresponde. En particular, podemos agrupar todos los casos acusativos primero y luego todos los casos dativos, para obtener oraciones con la forma general

... mer $X^n Y^m$ es huus $Z^n W^m$ asstriiche

a dónde X son NPs de caso acusativo (“d'chind”), Y son NPs de caso dativo (“em Hans”), Z son verbos acusativos (“laa”), y W son verbos dativos (“hälfe”). Si este lenguaje natural fuera libre de contexto, podría aplicarse el *pumping lemma* para CFLs para construir a partir de oraciones gramaticales de este tipo, otras oraciones en las que la cantidad de objetos de cada caso no se corresponde con la cantidad de verbos de cada subcategoría, es decir, oraciones no gramaticales. De esto se desprende la conclusión de que este lenguaje natural no es libre de contexto.




Figura 8: Ejemplo en alemán suizo de interdependencias seriales y marcado de casos, para el fragmento de oración “... nosotros dejamos a los chicos ayudar a Hans a pintar la casa”. ACC indica caso acusativo (artículos “de” y “es”) y DAT caso dativo (artículo “em”).

3.3. El lenguaje natural como lenguaje sensible al contexto, y más allá

Los argumentos a favor de la inadecuación de los lenguajes libres de contexto exigieron buscar un formalismo gramatical más expresivo para el

lenguaje natural. Yendo al siguiente escalón en la jerarquía de Chomsky, encontramos los *lenguajes sensibles al contexto* (CSLs).

Los lenguajes sensibles al contexto son capaces de describir los fenómenos sintácticos utilizados para probar la inadecuación libre de contexto, incluyendo las interdependencias seriales del holandés, y las del alemán suizo en combinación con el marcado de casos.

En principio, no existen argumentos en la literatura que hablen en contra de la adecuación débil o fuerte de los CSLs.

Sin embargo, los CSLs son inadecuados desde el punto de vista de complejidad, una noción adicional de adecuación, ya que se sabe que el problema de reconocimiento es PSPACE-complete para las gramáticas sensibles al contexto (Hopcroft et al., 2000). Esto significa que no se conocen, y posiblemente no existan, algoritmos eficientes para determinar si una oración es gramatical o no¹, tarea que los humanos pueden hacer rápidamente con el lenguaje natural.

Formalismos aún más expresivos han sido propuestos como adecuados para el lenguaje natural, como por ejemplo las gramáticas de unificación (*unification grammars*) (Francez y Wintner, 2011), que pueden expresar la clase entera de lenguajes recursivamente enumerables, al tope de la jerarquía de Chomsky. La altísima expresividad de estos formalismos indica que las adecuaciones débil y fuerte no son un problema, pero sí se presenta un grave problema de tratabilidad. Los problemas de reconocimiento y análisis son en este caso indecidibles, esto es, se sabe que no existen algoritmos que permitan resolverlos.

1 A no ser que $P = PSPACE$ sea verdadero, uno de los problemas abiertos más importantes de las ciencias de la computación. La creencia mayoritaria de la comunidad científica es que $P \neq PSPACE$ (Aaronson, 2016).

4.4 El lenguaje natural como lenguaje moderadamente sensible al contexto

El problema de la excesiva expresividad de los CSLs llevó a la búsqueda de una nueva clase de lenguajes que se ubique en un paso intermedio entre los libres de contexto y los sensibles al contexto. La dificultad histórica que hubo para encontrar ejemplos de fenómenos sintácticos genuinamente sensibles al contexto en el lenguaje natural, hizo evidente que la expresividad requerida estaba apenas por encima de los CSLs.

Es por esto que en la literatura se propusieron nuevos formalismos gramaticales que pudieran ser ligeramente más expresivos que las CFGs. Joshi (1985) introdujo las *Tree Adjoining Grammars* (TAGs), y mostró que éstas son capaces de expresar fenómenos como las interdependencias seriales, y que lo hacen dando descripciones estructurales adecuadas. Al mismo tiempo, las TAGs tienen buenas propiedades de complejidad, parecidas a las de las CFGs, ya que existen algoritmos polinomiales para los problemas de reconocimiento y análisis.

Joshi definió vagamente el concepto de *gramáticas moderadamente sensibles al contexto* (MCSGs) como aquellas gramáticas que tienen la capacidad simultánea de describir interdependencias seriales y de tener *parsing* polinomial.¹ Los TAGs, entonces, son una instancia particular de MCSG. Varios mecanismos formales de aparición en la década de los 80 fueron encontrados débilmente equivalentes a los TAGs (Vijay-Shanker y Weir, 1994). Por ejemplo, las *Gramáticas Catoriales Combinatorias* (CCGs) (Steedman, 2000), las *Gramáticas Indexadas Lineales* (LIGs) (Gazdar, 1988), las *Head Grammars* (HG) (Pollard, 1984) y las *Head-driven Phrase Structure Grammar* (HPSGs) (Pollard y Sag, 1994).

¹ Existe además la propiedad de crecimiento constante (*constant growth*), sobre la que hay cierta polémica y que por cuestiones de espacio prefiero dejar fuera de la discusión. Ver Radzinski (1991), Groenink (1997) y Kallmeyer (2010, p. 2).

Trabajos posteriores dieron argumentos en contra de la adecuación de los TAGs. Por ejemplo, para el holandés, Manaster-Ramer (1987) propuso una construcción sintáctica que usa interdependencias seriales y conjunciones. Las conjunciones permiten agregar a la estructura básica de interdependencias seriales $X^n Y^n$ nuevas series de verbos para obtener oraciones de la forma

... $X^n Y^n, U^n, V^n$ en (y) W^n .

Un lenguaje con estas características no puede ser expresado por un TAG. Sí existen otros formalismos MCS que logran expresar estas quintuplas interdependencias, como por ejemplo los *Linear Context-Free Rewriting Systems* (LCFRSs) (Vijay-Shanker et al., 1987) y sus equivalentes *Multiple Context-Free Grammars* (MCFGs) (Kasami et al., 1989). Estos formalismos son considerados los más representativos de los lenguajes MCS, ya que no se han identificado hasta el momento otros formalismos *mildly context-sensitive* de mayor expresividad (Kallmeyer, 2010).

Una versión extendida del argumento de Manaster-Ramer con interdependencias seriales propuso la inadecuación débil de los LCFRS (Groenink, 1997). También se dieron argumentos contra la adecuación de los LCFRS tomados del alemán (mezclado de larga distancia) (Becker et al., 1992), del chino (nombres de números) (Radzinski, 1991) y del georgiano antiguo (apilado de casos) (Michaelis y Kracht, 1997), no sin algo de polémica. En algunos de estos casos se afirma incluso que los argumentos de inadecuación se aplican a todos los lenguajes MCS en general.

En vista de la posible inadecuación de los lenguajes MCS, también se propusieron formalismos menos restrictivos, aunque siempre manteniendo la condición de *polinomial parsing*. Entre ellos, se encuentran los *Parallel MCFGs* (PMCFGs) (Kasami et al., 1989), los *Simple Literal Movement Grammars* (Simple LMGs) (Groenink, 1997) y sus equivalentes *Range Concatenation Grammars* (RCGs) (Boullier, 1998). Los Simple LMGs y los RCGs generan exactamente la clase completa de lenguajes con *polinomial parsing*, denominada PTIME, por lo que son considerados los

formalismos más expresivos para ser considerados adecuados para el lenguaje natural.

La relación entre los diferentes formalismos mencionados en esta sección puede verse en el detalle de la jerarquía de Chomsky de la **figura 9**. Obsérvese que no se conoce exactamente la relación entre PTIME y CSL.




Figura 9: Detalle de la jerarquía de Chomsky entre los CFLs y los CSLs. Se muestran algunos formalismos gramaticales discutidos en la literatura, y la relación entre ellos en cuanto a poder expresivo. La frontera moderadamente *context-sensitive* (MCS) es difusa ya que no existe una definición precisa. No se conoce exactamente la relación entre PTIME y CSL, por lo que las áreas punteadas no se sabe si son vacías o no.

4. Discusión

“But it must be recognized that the notion ‘probability of a sentence’ is an entirely useless one, under any known interpretation of this term.”
 Noam Chomsky
 (1969, p. 57)¹

“Anytime a linguist leaves the group the recognition rate goes up.”
 Fred Jelinek
 (1988)²

La discusión de la relación entre el lenguaje natural y los lenguajes formales permitió el desarrollo de una base teórica en donde se propusieron y estudiaron numerosos formalismos gramaticales. De estos, solo se mencionaron los más relevantes en las secciones anteriores. Esta discusión fue convergiendo hacia mediados de los 90, luego de haberse llegado a cierto consenso acerca de la adecuación de los formalismos moderadamente sensibles al contexto.

En esa época también hubo un fuerte viraje de la lingüística computacional hacia los métodos empíricos basados en datos, que supuso una pérdida de protagonismo de temas más teóricos como los tratados en este artículo. Este nuevo enfoque tuvo un fuerte impulso a partir de la disponibilidad de conjuntos de datos anotados y del aumento del poder computacional disponible para procesarlos y entrenar modelos. En el caso del análisis sintáctico, el Penn Treebank (Marcus et al., 1994) se convirtió en un estándar de facto para el desarrollo y la evaluación de parsers, y la

1 Cita tomada de Jurafsky y Martin (2008).

2 Cita tomada de Jurafsky y Martin (2008).

investigación se centró principalmente en lograr modelos cada vez más efectivos para analizar este conjunto de datos.

Muchos de los modelos empíricos propuestos se basaron en los formalismos revisados en este trabajo, o tomaron elementos de ellos (Jurafsky y Martin, 2008). Sin embargo, también ganaron protagonismo ideas de otras tradiciones lingüísticas, especialmente aquellas provenientes de la teoría de dependencias (Tésniere, 1959). Entre las ventajas de los modelos de dependencias, se destacan su adecuación para las lenguas con cierto grado de orden libre de palabras (e.g. el checo), y la cercanía de sus representaciones con aquellas necesarias para el análisis semántico del lenguaje. Por ser sus fundamentos muy distintos a los de la escuela generativa, ha sido más difícil vincular las gramáticas de dependencias con los lenguajes formales. En Rambow y Joshi (1994) se puede encontrar una discusión respecto de este tema.

Con el auge de los modelos neuronales, y posteriormente de las redes neuronales profundas, la investigación se distanció aún más de la línea teórica, profundizando la carrera por la obtención de mejores resultados cuantitativos sobre los conjuntos de datos existentes. Si bien las redes neuronales revolucionaron el área de PLN en la última década, la particular opacidad de estos modelos ha dificultado la interpretación de los resultados en términos de la capacidad de estos modelos para representar los fenómenos lingüísticos. Afortunadamente, existe una reciente tendencia a estudiar el vínculo entre las diferentes arquitecturas neuronales y los lenguajes formales, realizando un acercamiento indirecto al problema de la adecuación para el lenguaje natural. Por ejemplo, en Eisner et al. (2019) se compilan los trabajos presentados en un workshop dedicado enteramente a este tema.

En resumen, la irrupción del aprendizaje automático en el campo de la lingüística computacional supuso un gran avance en términos de resultados empíricos y la posibilidad de desarrollar aplicaciones, pero al mismo tiempo contribuyó a un progresivo divorcio de este campo con el

de la lingüística teórica. En Baldwin y Kordoni (2009) se encuentran artículos que reflexionan acerca de la situación de la relación entre estas dos disciplinas. Trabajos recientes proponen una crítica respecto del vínculo entre los resultados exitosos de los modelos actuales y el objetivo último de alcanzar la comprensión del lenguaje natural (*natural language understanding*) (Bender et al., 2020).

Es posible observar en la lingüística computacional cierto agotamiento de los enfoques estrictamente cuantitativos para la evaluación del progreso científico, por no ser lo suficientemente informativos respecto de las capacidades subyacentes de los modelos propuestos. Esto da lugar a la necesidad de incorporar criterios más cualitativos que permitan apreciar el nivel de complejidad de los fenómenos lingüísticos que los sistemas son capaces de capturar. De esta manera, es de esperar que la discusión sobre la adecuación de los formalismos gramaticales vuelva a tomar impulso los próximos años en las agendas de investigación de la lingüística computacional y el procesamiento de lenguaje natural.

Referencias bibliográficas

- Aaronson, S. (2016). P =? NP. In Jr., J. F. N. y Rasiias, M. T., editors, *Open Problems in Mathematics*, pp. 1–122. Springer.
- Baldwin, T. y Kordoni V. (eds.). (2009). *Proceedings of the EACL 2009 Workshop on the Interaction between Linguistics and Computational Linguistics: Virtuous, Vicious or Vacuous?*. ACL.
- Becker, T., Rambow, O., y Niv, M. (1992). The derivational generative power of formal systems or scrambling is beyond LCFRS. Informe técnico, Institute for Research in Cognitive Science, University of Pennsylvania, Pennsylvania, PA.
- Bender E. M. y Koller A. (2020). Climbing towards NLU: On Meaning, Form, and Understanding in the Age of Data. En *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pp. 5185–5198. ACL.
- Boullier, P. (1998). Proposal for a natural language processing syntactic backbone. Informe técnico 3342, INRIA.
- Bresnan, J., Kaplan, R. M., Peters, S., y Zaenen, A. (1982). Cross-Serial dependencies in Dutch. *Linguistic Inquiry*, 13(fall):613–635+.

Chomsky, N. (1956). Three models for the description of language. *IRE Transactions on Information Theory*, 2(3):113–124.

Chomsky, N. (1957). *Syntactic Structures*. Mouton (2ª ed.).

Chomsky, N. (1959). On certain formal properties of grammars. *Information and Control*, 2(2):137–167.

Chomsky, N. (1965). *Aspects of the Theory of Syntax*, vol. 119. The MIT press.

Eisner J., Gallé M., Heinz J., Quattoni A. y Rabusseau G (eds.). (2019). *Proceedings of the Workshop on Deep Learning and Formal Languages: Building Bridges*. ACL.

Elster, J. (1978). *Logic and Society: Contradictions and Possible Worlds*. John Wiley & Sons Ltd (1ª ed.).

Francez, N. y Wintner, S. (2011). *Unification Grammars*. Cambridge University Press, New York, NY.

Gazdar, G. (1988). Applicability of indexed grammars to natural languages. En Reyle, U. and Rohrer, C., editores, *Natural Language Parsing and Linguistic Theories*, pp. 69–94. Reidel, Dordrecht.

Groenink, A. (1997). Mild Context-Sensitivity and Tuple-Based generalizations of Context-Grammar. 20(6):607–636.

Hopcroft, J. E., Motwani, R., y Ullman, J. D. (2000). *Introduction to Automata Theory, Languages, and Computation* (2ª ed.). Addison Wesley.

Joshi, A. K. (1985). Tree adjoining grammars: how much context-sensitivity is required to provide reasonable structural descriptions? En Dowty, D. R., Karttunen, L., and Zwicky, A., editores, *Natural Language Parsing*. Cambridge University Press, Cambridge.

Jurafsky, D., Martin, J. H. (2008). *Speech and language processing*. Upper Saddle River: Prentice Hall.

Kallmeyer, L. (2010). *Parsing Beyond Context-Free Grammars (Cognitive Technologies)*. Springer.

Kasami, T., Seki, H., y Fujii, M. (1989). Generalized context-free grammars and multiple context-free grammars. *Systems and Computers in Japan*, 20(7):43–52.

Manaster-Ramer, A. (1987). Dutch as a formal language. *Linguistics and Philosophy*, 10(2):221–246.

Marcus, M. P., Kim, G., Marcinkiewicz, M. A., MacIntyre, R., Bies, A., Ferguson, M., Katz, K., y Schasberger, B. (1994). The Penn Treebank: Annotating predicate argument structure. *ARPA Human Language Technology Workshop*. Morgan Kaufmann.

- Michaelis, J. y Kracht, M. (1997). Semilinearity as a syntactic invariant. In Retoré, C., editor, *Logical Aspects of Computational Linguistics*, vol. 1328, *Lecture Notes in Computer Science*, pp. 329–345. Springer Berlin Heidelberg.
- Partee, B. H., Meulen, T. A. G., y Wall, R. (1990). *Mathematical Methods in Linguistics*. Studies in Linguistics and Philosophy (1ª ed.). Springer.
- Pollard, C. (1984). *Generalized Phrase Structure Grammars, Head Grammars, and Natural Languages*. Tesis doctoral, Universidad de Stanford.
- Pollard, C. y Sag, I. A. (1994). *Head-Driven Phrase Structure Grammar*. University of Chicago Press.
- Pullum, G. K. y Gazdar, G. (1982). Natural languages and context-free languages. *Linguistics and Philosophy*, 4(4):471–504.
- Radzinski, D. (1991). Chinese number-names, tree adjoining languages, and mild context-sensitivity. *Comput. Linguist.*, 17(3):277–299.
- Rambow O. y Joshi A. K. (1994). A formal look at dependency grammars and phrase-structure grammars, with special consideration of word-order phenomena. En Leo Wanner, editor, *Recent Trends in Meaning-Text Theory*, Amsterdam and Philadelphia, pp. 167–190.
- Shieber, S. M. (1985). Evidence against the context-freeness of natural language. *Linguistics and Philosophy*, 8(3):333–343.
- Steedman, M. (2000). *The syntactic process*. MIT Press, Cambridge, MA, USA.
- Tesnière, L. (1959). *Éléments de Syntaxe Structurale*. Librairie C. Klincksieck, Paris.
- Vijay-Shanker, K. y Weir, D. (1994). The equivalence of four extensions of Context-Free grammar. *Mathematical Systems Theory*, 27:511–546.
- Vijay-Shanker, K., Weir, D., y Joshi, A. (1987). Characterizing structural descriptions produced by various grammatical formalisms. En *Proceedings of the 25th Annual Meeting of the Association for Computational Linguistics*, Stanford, pp. 104–11. ACL.

Nota biográfica

Franco Martín Luque

Franco M. Luque es Licenciado y Doctor en Ciencias de la Computación (FAMAF, Universidad Nacional de Córdoba, Argentina). Se desempeña como Profesor Adjunto en la Facultad de Matemática, Astronomía, Física y Computación (FAMAF), Universidad Nacional de Córdoba. Es Investigador Asistente en Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET). Investiga en las áreas de Procesamiento de

Lenguaje Natural y Aprendizaje Automático. Realizó su tesis de doctorado en los temas de análisis sintáctico no supervisado y aprendizaje espectral. Actualmente participa en proyectos de investigación sobre diversos temas como análisis del discurso de odio en redes sociales, aprendizaje multimodal para diálogo visual y extracción de información en informes médicos.