

Соотношение между грамматиками Ламбека и иерархией формальных грамматик Хомского

Александр Грефенштейн

НИУ ВШЭ

1 марта 2023 г.

AB грамматики

Исторически первым математическим формализмом, придуманным для моделирования естественных языков, в которых порядок слов имеет ключевое значение, стали **классические категориальные грамматики** или *AB грамматики*.¹

Выражения (формулы) или **синтаксические типы** для *AB грамматик* строятся следующим образом:

$$L ::= P \mid (L \backslash L) \mid (L / L),$$

где *P* — заранее фиксированный список примитивных синтаксических типов, среди которых есть выделенный тип *S*.

¹Bar-Hillel, Y.: A quasi arithmetical notation for syntactic description. Language 29, 47-58 (1953).

AB грамматики

Пусть Σ — конечное множество терминалов (слов). Функция Lex будет присваивать каждому $\sigma \in \Sigma$ конечное множество синтаксических типов. Итак, AB грамматика — это тройка (Σ, Lex, S) .

Будем говорить, что предложение $\sigma_1 \dots \sigma_n$, составленное из слов из Σ имеет тип u , если для каждого терминала σ_i существует тип t_i из $\text{Lex}(\sigma_i)$ такой, что $t_1 \dots t_n \rightarrow u$ в соответствии со следующими правилами редукции:

$$(\backslash_e) \quad u(u\backslash v) \rightarrow v;$$

$$(/_e) \quad (v/u)u \rightarrow v.$$

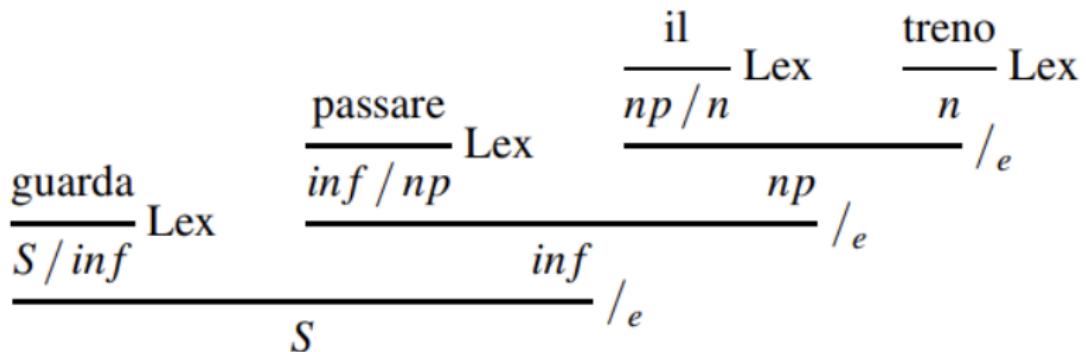
Тогда языком, порождаемым AB грамматикой, называется множество предложений, имеющих тип S .

Пример *AB* грамматики и дерева разбора

Word	Type(s)	Translation
<i>cosa</i>	$(S / (S / np))$	<i>what</i>
<i>guarda</i>	(S / inf)	<i>he/she watches</i>
<i>passare</i>	(inf / np)	<i>passing by</i>
<i>il</i>	(np / n)	<i>the</i>
<i>treno</i>	<i>n</i>	<i>train</i>

Пример *AB* грамматики и дерева разбора

Word	Type(s)	Translation
<i>cosa</i>	$(S / (S / np))$	<i>what</i>
<i>guarda</i>	(S / inf)	<i>he/she watches</i>
<i>passare</i>	(inf / np)	<i>passing by</i>
<i>il</i>	(np / n)	<i>the</i>
<i>treno</i>	n	<i>train</i>



Контекстно-свободные грамматики

Другим способом описания синтаксиса естественных языков является **контекстно-свободная грамматика**, т.е. **формальная грамматика** (T, NT, P, S), в которой правила продукции имеют следующий вид:

$$X \longrightarrow W,$$

где $X \in NT$, $W \in (NT \cup T)^+$.²

²В рамках данного доклада мы не рассматриваем грамматики, допускающие пустое слово.

Контекстно-свободные грамматики

Другим способом описания синтаксиса естественных языков является **контекстно-свободная грамматика**, т.е. **формальная грамматика** (T, NT, P, S), в которой правила продукции имеют следующий вид:

$$X \longrightarrow W,$$

где $X \in NT$, $W \in (NT \cup T)^+$.²

Простой пример:

$$S \rightarrow (S \wedge S) \mid \neg S \mid p \mid q \mid r.$$

²В рамках данного доклада мы не рассматриваем грамматики, допускающие пустое слово.

AB грамматики v.s. контекстно-свободные

Оказывается, что два рассмотренных выше формализма по существу описывают одно и то же:

Теорема(от *CFG* к *AB*)

Каждая контекстно-свободная грамматика без пустого слова слабо эквивалентна некоторой *AB* грамматике, содержащей только типы вида X , X/Y или $(X/Y)/Z$.

Схема доказательства

Сначала приведём грамматику к сильной нормальной форме Грейбах. Далее построим по этой нормальной форме G_C подходящую *AB* грамматику.

AB грамматики v.s. контекстно-свободные

AB грамматика G будет такая:

- Терминалы G будут такие же, как и у G_C ;
- Примитивными типами G будут нетерминальные символы G_C .
- Если в G_C было правило $X \rightarrow aX_1 \dots X_n$, то $((\dots((X/X_n)/X_{n-1})/\dots)/X_2)/X_1 \in \text{Lex}(a)$.

Можно убедиться в том, что деревья разбора у G_C и G изоморфны и действительно используются только заявленные типы.

Обратное утверждение так же будет верно, но уже не понадобится нам в дальнейшем.

От *AB* грамматик к грамматикам Ламбека

Забегая вперёд, известно, что *AB* грамматики и грамматики Ламбека порождают **один и тот же** класс языков.

Однако у грамматик Ламбека есть **важное преимущество**: они позволяют выражать некоторые языковые феномены более **естественно и компактно**.

Так, в лексиконе, приведенном несколько слайдов назад, рассмотрим предложение **«cosa guarda passare?»**. Оно имеет тип

$$(S / (S / np)) (S / inf) (inf / np) ,$$

и, очевидно, **не лежит** в порожденном такой *AB* грамматикой языке. Однако в исчислении Ламбека с тем же лексиконом это предложение будет иметь тип *S*. За это ответственно **наличие выводов из гипотез** — правые правила для каждого из делений.

Категориальные грамматики Ламбека

Синтаксические типы для **грамматик Ламбека** расширяют типы для *AB* грамматик следующим образом:

$$Lp ::= P \mid (Lp \backslash Lp) \mid (Lp / Lp) \mid (Lp \cdot Lp).$$

Как и *AB* грамматики, **грамматики Ламбека** определяются как соответствующая тройка (Σ, Lex, S) . Однако порождающий язык определяется уже совсем иначе.

Предложение $\sigma = \sigma_1 \dots \sigma_n$ лежит в порожденным грамматикой **Ламбека языке**, если для каждого терминала σ_i существует тип t_i из $\text{Lex}(\sigma_i)$ такой, что секвенция $t_1, \dots, t_n \vdash S$ выводима в секвенциальном исчислении Ламбека.

Секвенциальное исчисление Ламбека

$$\frac{\Gamma, B, \Gamma' \vdash C \quad \Delta \vdash A}{\Gamma, \Delta, A \setminus B, \Gamma' \vdash C} \setminus_h$$

$$\frac{A, \Gamma \vdash C}{\Gamma \vdash A \setminus C} \setminus_i \quad \Gamma \neq \varepsilon$$

$$\frac{\Gamma, B, \Gamma' \vdash C \quad \Delta \vdash A}{\Gamma, B / A, \Delta, \Gamma' \vdash C} /_h$$

$$\frac{\Gamma, A \vdash C}{\Gamma \vdash C / A} /_i \quad \Gamma \neq \varepsilon$$

$$\frac{\Gamma, A, B, \Gamma' \vdash C}{\Gamma, A \bullet B, \Gamma' \vdash C} \bullet_h$$

$$\frac{\Delta \vdash A \quad \Gamma \vdash B}{\Delta, \Gamma \vdash A \bullet B} \bullet_i$$

$$\frac{\Gamma \vdash A \quad \Delta_1, A, \Delta_2 \vdash B}{\Delta_1, \Gamma, \Delta_2 \vdash B} cut$$

$$\frac{}{A \vdash A} axiom$$

Секвенциальное исчисление Ламбека: немного фактов

- Можно рассматривать только те выводы, где аксиомы состоят только из примитивных типов;
- Число позитивных и негативных вхождений всякого примитивного типа p в доказуемую секвенцию одинаково;
- Сечение устранимо;
- Выполнено свойство подформульности;
- При отказе от конкатенации типов и ограничения единицей порядка присваиваемых типов словам, выводимость секвенции $t_1, \dots, t_n \vdash u$ будет эквивалентна $t_1, \dots, t_n \rightarrow u$ в смысле AB грамматики. Следовательно, язык, задаваемый грамматикой Ламбека $G = (\Sigma, \text{Lex}, S)$ будет совпадать с языком, генерируем грамматикой G в смысле AB грамматики.

Грамматики Ламбека v.s. контекстно-свободные

По модулю последнего факта с предыдущего слайда от контекстно-свободных грамматик прийти к грамматикам Ламбека **довольно просто**: поскольку мы уже знаем, что контекстно-свободные грамматики сводятся к AB грамматикам, используя даже ограниченный вид типов, то **заметим, что эти типы порядка не больше 1**. Следовательно, имеет место

Теорема(от CFG к Ламбеку)

Каждая свободная от пустого слова контекстно-свободная грамматика G слабо эквивалентна некоторой грамматике Ламбека.

Грамматики Ламбека v.s. контекстно-свободные

Идея доказательства обратной теоремы примерно следующая: пусть мы можем сформулировать исчисление Ламбека используя только **конечный набор аксиом** и правило **cut**. Поскольку мы имеем **свойство подформульности**, то для выводимости секвенции $t_1, \dots, t_n \vdash S$ нам стоит заботиться только о типах, которые появляются в аксиомах.

Переписывая **каждую аксиому** $X_1, \dots, X_n \vdash X$ в виде правила продукции

$$X \longrightarrow X_1, \dots, X_n,$$

мы относительно легко получим, что этой грамматикой задаётся тот же самый язык. Причём о **cut** даже думать не надо — это просто **правило подстановки**, которое и так неявно присутствует в формальных грамматиках. Однако так просто это не сработает.

Грамматики Ламбека v.s. контекстно-свободные

Пусть A — формула, через $|A|$ будем обозначать количество примитивных типов, входящих в A и называть $|A|$ размером формулы A .

Наша главная цель теперь в том, чтобы показать, что для фиксированного натурального m существует конечное множество доказуемых секвенций $AX(m)$ такое, что всякая доказуемая секвенция, в которой формулы имеют размер меньше m , выводимы из $AX(m)$ используя только правило *cut*.

Неформально говоря, доказав нашу главную цель мы сразу получим, что язык, задаваемый некоторой грамматикой Ламбека G генерируется подходящей контекстно-свободной грамматикой с правилами редукции из $AX(m)$.

Грамматики Ламбека v.s. контекстно-свободные

Обозначим через $\rho_p(\Delta)$ число вхождений примитивного типа p в формулы из Δ .

Первым шагом к реализации этой идеи будет

Интерполяция

Пусть секвенция $\Gamma, \Delta, \Theta \vdash C$ доказуема и $\Delta \neq \varepsilon$. Тогда существует такая формула I , называемая интерполянтом, что:

- 1 $\Delta \vdash I$;
- 2 $\Gamma, I, \Theta \vdash C$;
- 3 $\rho_p(I) \leq \rho_p(\Delta)$;
- 4 $\rho_p(I) \leq \rho_p(\Gamma, \Theta, C)$,

для любого примитивного типа p .

Грамматики Ламбека v.s. контекстно-свободные

Набросок доказательства

Индукция по выводу без сечений. Случай аксиомы тривиален.

Далее рассматриваем последнее применённое правило.

Ограничимся рассмотрением правила

$$\frac{\Pi \vdash X \quad \Phi, Y, \Psi \vdash C}{\Phi, \Pi, X \setminus Y, \Psi \vdash C} \setminus_h$$

- Пусть Δ включено либо в Π , либо в Φ , либо в Ψ и по И.П. имеем интерполянт I для Δ в соответствующей посылке. Тогда он нам и подходит.
- Пусть Δ включено в Φ, Π , т.е. $\Delta = \Delta', \Delta''$; $\Phi = \Phi', \Delta'$; $\Pi = \Delta'', \Pi''$. По И.П. I' будет интерполянтом для Δ' в $\Phi', \Delta', Y, \Psi \vdash C$, а I'' для Δ'' в $\Delta'', \Pi'' \vdash X$. Тогда $I' \cdot I''$ искомый интерполянт для Δ .



Грамматики Ламбека v.s. контекстно-свободные

- Пусть Δ включено в $\Pi, X \setminus Y, \Psi$, т.е. $\Pi = \Pi', \Pi'';$
 $\Psi = \Psi', \Psi'';$ $\Delta = \Pi'', X \setminus Y, \Psi'$. По И.П. I' будет
интерполянтом для Π' в $\Pi', \Pi'' \vdash X$, а I'' для Y, Ψ' в
 $\Phi, Y, \Psi', \Psi'' \vdash C$. Тогда $I' \setminus I''$ искомый интерполянт для Δ .
- Пусть Δ включено в $\Phi, \Pi, X \setminus Y, \Psi$, т.е. $\Phi = \Phi', \Phi'';$
 $\Psi = \Psi', \Psi'';$ $\Delta = \Phi'', \Pi, X \setminus Y, \Psi'$. По И.П. I будет
интерполянтом для Φ'', Y, Ψ' в $\Phi', \Phi'', Y, \Psi', \Psi'' \vdash C$. Тогда
сам I является искомым интерполянтом для Δ .

Грамматики Ламбека v.s. контекстно-свободные

Для второго шага нам понадобится **интерпретация** типов исчисления Ламбека в свободной группе и **корректность** доказуемых секвенций относительно такой интерпретации.

Пусть $G = (M, \circ)$ — свободная группа **над P** , т.е. множество несократимых слов в алфавите P . **Стандартная интерпретация** $[\cdot]_{Lp}$ в G определяется индукцией по построению типа:

- $[p] = p$;
- $[A \cdot B] = [A] \circ [B]$;
- $[A \setminus B] = [A]^{-1} [B]$;
- $[A / B] = [A] [B]^{-1}$.

Теорема

Если секвенция $\Gamma \vdash \Delta$ доказуема, то $[\Gamma] = [\Delta]$.

Грамматики Ламбека v.s. контекстно-свободные

Пора начинать второй шаг!

Говорим, что секвенция $\Gamma \vdash C$ **тонкая**, если она **доказуема** и для всякого примитивного типа p $\rho_p(\Gamma, C)$ равно либо 0, либо 2.

Следующее утверждение очевидно по модулю **удаления сечения и использованию примитивных аксиом**.

Утверждение 1

Каждая доказуемая секвенция может быть получена из тонкой путём замены примитивных типов.

Грамматики Ламбека v.s. контекстно-свободные

Теперь докажем, что для тонких секвенций мы можем найти интерполянт фиксированного размера.

Утверждение 2

Пусть $\Gamma, \Delta, \Theta \vdash C$ — тонкая секвенция. Тогда существует формула B такая, что

- 1 Секвенции $\Delta \vdash B$ и $\Gamma, B, \Theta \vdash C$ тонкие;
- 2 $|B| = ||[\Delta]||$.

Доказательство

Проводя обычную интерполяцию, мы имеем интерполянт B такой, что

- 1 $\Delta \vdash B$ и $\Gamma, B, \Theta \vdash C$ доказуемы;
- 2 $\rho_p(B) \leq \min(\rho_p(\Gamma, \Theta, C), \rho_p(\Delta))$.

Грамматики Ламбека v.s. контекстно-свободные

Докажем оценки на количество примитивных типов в секвенциях. Имеем:

$$0 \text{ или } 2 = \rho_p(\Gamma, \Delta, \Theta, C) = \rho_p(\Gamma, \Theta, C) + \rho_p(\Delta).$$

Тогда $\rho_p(B)$ равно 0 или 1 и мы имеем:

$$\rho_p(\Delta, B) = \rho_p(\Delta) + \rho_p(B) \leq \rho_p(\Gamma, \Delta, \Theta, C) + \rho_p(B) \leq 2 + 1.$$

Но так как $\Delta \vdash B$ доказуема, то $\rho_p(\Delta, B)$ чётно. Значит, не равно 3 и меньше 2.

Аналогичное рассуждение для $\rho_p(\Gamma, B, \Theta, C)$:

$$\rho_p(\Gamma, B, \Theta, C) = \rho_p(\Gamma, \Theta, C) + \rho_p(B) \leq \rho_p(\Gamma, \Delta, \Theta, C) + \rho_p(B).$$

Последнее не превосходит 3, откуда всё и получается.

Грамматики Ламбека v.s. контекстно-свободные

Докажем, что $|B| = ||[\Delta]|$.

Если p не входит в Δ , то его очевидно нет ни в B , ни в $[\Delta]$.

Если p входит в Δ один раз, то p также входит в $[\Delta]$ один раз, ибо ни с кем не может сократиться. Поскольку секвенция $\Delta \vdash B$ тонкая, p входит в B единожды.

Если p входит дважды в Δ , то p не входит в Γ, Θ, C , а, значит, и в B . По корректности в свободной группе $[\Gamma, \Delta, \Theta] = [C]$. Отсюда получаем, что $[\Delta] = [\Gamma]^{-1}[C][\Theta]^{-1}$. Но так как p не входит в Γ, Θ, C , p не входит в $[\Delta]$.

Наконец, из утверждения 2 можно получить

Следствие 1

Пусть секвенция $A_1, \dots, A_n \vdash A_{n+1}$ тонкая и для каждого i $|A_i| \leq m$. Тогда выполнено одно из следующих двух условий.

- 1 существует k и формула B такие, что $|B| \leq m$ и следующие секвенции тонкие:
 - $A_1, \dots, A_{k-1}, B, A_{k+2}, \dots, A_n \vdash A_{n+1}$;
 - $A_k, A_{k+1} \vdash B$.
- 2 существует формула B такая, что $|B| \leq m$ и следующие секвенции тонкие:
 - $B, A_n \vdash A_{n+1}$;
 - $A_1, \dots, A_{n-1} \vdash B$.

Грамматики Ламбека v.s. контекстно-свободные

Теперь пора доказывать **основную лемму** и **теорему Пентуса** об эквивалентности всякой грамматики Ламбека некоторой контекстно-свободной грамматике.

Основная лемма

Пусть $A_1, \dots, A_n \vdash A_{n+1}$ такая доказуемая секвенция, что $|A_i| \leq m$ для каждого i . Тогда эта секвенция доказуема, используя только правило *cut*, из доказуемых секвенций вида $U, V \vdash X$ или $U \vdash X$ таких, что $|U|, |V|, |X| \leq m$.

Доказательство

Индукция по n . При $n \leq 2$ доказывать нечего. По утверждению 1 наша секвенция получена из некоторой тонкой секвенции $A'_1, \dots, A'_n \vdash A'_{n+1}$. При этом очевидно, что $|A'_i| \leq m$ для всех i .

Грамматики Ламбека v.s. контекстно-свободные

Обозначим эту подстановку примитивных типов через σ . По следствию 1 существует $|B'| \leq m$ такая, что:

1 Секвенции $A'_1, \dots, A'_{k-1}, B', A'_{k+2}, \dots, A'_n \vdash A'_{n+1}$ и $A'_k, A'_{k+1} \vdash B'$ тонкие. Пусть $B = \sigma(B')$. Тогда $|B| \leq m$.

Возвращаясь к предыдущим примитивным типам, мы получаем, что секвенции

$A_1, \dots, A_{k-1}, B, A_{k+2}, \dots, A_n \vdash A_{n+1}$ и $A_k, A_{k+1} \vdash B$ доказуемы. По И.П. получаем, что секвенция

$$A_1, \dots, A_{k-1}, B, A_{k+2}, \dots, A_n \vdash A_{n+1}$$

доказуема только с помощью правила *cut* из доказуемых секвенций правильного вида. Поскольку секвенция $A_k, A_{k+1} \vdash B$ уже имеет правильный вид, применяя *cut*, мы получаем заключение леммы.



Грамматики Ламбека v.s. контекстно-свободные

- 2 Секвенции $B', A'_n \vdash A'_{n+1}$ и $A'_1, \dots, A'_{n-1} \vdash B'$ тонкие. Далее рассуждения аналогичны пункту 1.

Теорема(от грамматик Ламбека к *CFG*)

Пусть Lex — лексикон некоторой грамматики Ламбека G_L и пусть t максимальный размер типов, присваиваемых словам G_L . Тогда язык, генерируемый G_L , совпадает с языком, генерируемым контекстно-свободной грамматикой G_C следующего вида:

Грамматики Ламбека v.s. контекстно-свободные

- Терминалы — все слова G_L ;
- Нетерминалы — все типы A грамматики G_L такие, что $|A| \leq m$;
- Стартовый символ такой же, как и у G_L ;
- $X \rightarrow a$, если $a \in \text{Lex}(a)$;
- $X \rightarrow A$, если секвенция $A \vdash X$ доказуема;
- $X \rightarrow AB$, если секвенция $A, B \vdash X$ доказуема.

Доказательство

Пусть $a_1 \dots a_n$ допускается грамматикой G_C . Тогда существуют типы $X_i \in \text{Lex}(a_i)$ такие, что $S \rightarrow X_1 \dots X_n$. Легко видеть, что вывод в G_C можно перестроить в вывод в G_L (обратить \rightarrow в \vdash), используя только правило *cut*.

Грамматики Ламбека v.s. контекстно-свободные

Пусть $a_1 \dots a_n$ допускается грамматикой G_L . Тогда существуют типы $X_i \in \text{Lex}(a_i)$ такие, что секвенция $X_1, \dots, X_n \vdash S$ доказуема. По основной лемме эта секвенция доказуема из доказуемых секвенций, соответствующих правилам продукции грамматики G_C , используя только правило *cut*. Индукцией по данному «*cut-only*» выводу можно убедиться, что он соответствует выводу в G_C .

Заключительные комментарии

- Сведение грамматики Ламбека к подходящей контекстно-свободной не полиномиально и особых надежд на полиномиальное сведение нет. Однако есть полиномиальное сведение для случая одного деления.
- Для грамматик Ламбека с пустым словом аналогичный теореме Пентуса результат также верен.