

**Об усилении хигманова
вложения при построении
регулярных приближений циклов**

**Антонина Н. Непейвода
Институт программных систем РАН
г. Переславль-Залесский**

**Объединенный семинар ИЦСА и ИЦПУ
26 февраля 2013 г., Переславль–Залесский**

Семантическое дерево программы — дерево путей исполнения программы на возможных входных данных.

Пример

Рекурсивное определение факториала в арифметике Пеано

$$f(0)=1;$$

$$f(x+1)=m(x+1, f(x));$$


$$m(0, y)=0;$$

$$m(x+1, y)=a(y, m(x, y));$$

$$a(0, y)=y;$$

$$a(x+1, y)=a(x, y)+1;$$


Начало развертки семантического дерева исполнения $f(x)$



Это дерево может содержать в себе пути сколь угодно большой длины (зависящей от x). Такие пути семантически соответствуют циклам.

Имеет смысл задача нахождения критериев для построения приближений циклов в программах. В частности, для семантических деревьев такой критерий должен сравнивать два узла $Node_1$, $Node_2$, таких, что $Node_1$ — предок $Node_2$, и строить аппроксимацию цикла, если структура $Node_2$ некоторым образом повторяет структуру $Node_1$.

Пример



$f(x)$ — подтерм $m(x'+1, f(x'))$ с точностью до переименования переменных. На основании этого наблюдения ветвь дерева сворачивается в граф.

Отношение R называется *почти полным* (*almost well*) на множестве последовательностей строк $S \subset \Sigma^*$ в некотором алфавите Σ , если всякая бесконечная последовательность строк $\{a_n\}$ содержит a_i, a_j , такие, что $i < j$ и $R(a_i, a_j)$.


Это свойство гарантирует, что аппроксимация цикла будет построена на всех бесконечных ветвях семантического дерева программы.

Последовательность $\{a_n\}$, обладающая свойством $\forall i, j (i < j \Rightarrow (a_i, a_j) \notin R)$, называется *плохой последовательностью*.

Если отношение транзитивно и почти полно, оно называется *полным квазипорядком* (wqo).

Пример

Пусть дан конечный алфавит Σ . $A = a_1a_2\dots a_m$, $B = b_1b_2\dots b_n$, $\forall i, j (i \geq 1 \ \& \ j \geq 1)$. Если $\forall i (i < m \Rightarrow \exists j, k (b_j = a_i \ \& \ b_k = a_{i+1} \ \& \ k > j))$, то A вкладывается в B в смысле Хигмана ($A \trianglelefteq B$).



\trianglelefteq — почти полное отношение на произвольных последовательностях слов в конечном алфавите (Хигман, 1952).

В 1995 году М.Г. Серенсен предложил использовать хигманово вложение термов в узлах деревьев для построения аппроксимаций циклов в семантическом дереве программы.

Ранее, в 1988 году, В.Ф. Турчин предложил использовать для построения аппроксимаций циклов отношение над стеками функциональных вызовов, сходное с хигмановым вложением.

Набор $\langle \Sigma, \mathbf{R}, \Gamma_0 \rangle$, где Σ — алфавит $\Gamma_0 \in \Sigma^+$ — начальное слово и $\mathbf{R} \subset \Sigma^+ \rightarrow \Sigma^*$ — правила переписывания, называется *системой переписывания префиксов* (СПП), если правило $R : R_l \rightarrow R_r$ может применимо лишь к словам вида $R_l\Phi$ и порождает слова вида $R_r\Phi$.


Пример

$aabab$ после применения правила $a \rightarrow bb$ превращается в $bbabab$, но не в $abbbab$ или $aabbbb$.

Если $|R_l| = 1$ для всех $R : R_l \rightarrow R_r$, то система переписывания префиксов называется *алфавитной* (АСПП).


Пусть последовательность слов $\{\Phi_i\}_{i=1}^n$ порождена СПП $G = \langle \Sigma, \mathbf{R}, \Gamma_0 \rangle$. Пометим все Φ_i индексами времени:

1. $\Phi_1[i]$ помечается индексом $|\Gamma_0| - i$;
2. Пусть наибольший индекс времени в отрезке последовательности $\{\Phi_i\}_{i=1}^k$ ($k < n$) равен M и Φ_{k+1} порождено из Φ_k правилом $R : R_l \rightarrow R_r$. Тогда $\Phi_{k+1}[i]$ ($i \leq |R_r|$) получает временной индекс $M + |R_r| - i + 1$. Остальные буквы в Φ_{k+1} сохраняют прежние временные индексы.



Определение отношения Турчина

$$\Gamma \preceq \Delta \Leftrightarrow \Gamma = \Phi_1 \Theta_0 \ \& \ \Delta = \Phi_2 \Psi \Theta_0 \ \& \ \Phi_1 \approx \Phi_2$$



Теорема Турчина

\preceq — почти полное отношение на последовательностях, порожденных АСПП над конечным алфавитом.

Пример

G_F :

$$R_1 : f \rightarrow \Lambda \quad R_3 : m \rightarrow \Lambda \quad R_5 : a \rightarrow \Lambda$$

$$R_2 : f \rightarrow fm \quad R_4 : m \rightarrow ma \quad R_6 : a \rightarrow a$$

Начальное слово Γ_0 — fa . Начальный отрезок порождаемой последовательности может выглядеть следующим образом

$$\begin{array}{c} \Gamma_0 : \mathbf{f}_{(1)}a_{(0)} \\ \downarrow R_2 \\ \Gamma_1 : \mathbf{f}_{(3)}m_{(2)}a_{(0)} \\ \downarrow R_2 \\ \Gamma_2 : \mathbf{f}_{(5)}m_{(4)}m_{(2)}a_{(0)} \\ \downarrow R_1 \\ \Gamma_3 : \mathbf{m}_{(4)}m_{(2)}a_{(0)} \\ \downarrow R_4 \\ \Gamma_4 : \mathbf{m}_{(7)}a_{(6)}m_{(2)}a_{(0)} \end{array}$$

$$\Gamma_0 \preceq \Gamma_1, \Gamma_0 \preceq \Gamma_2, \Gamma_1 \preceq \Gamma_2, \text{ и } \Gamma_3 \preceq \Gamma_4.$$

Верхняя оценка на длину слова в плохой последовательности, порожденной АСПП

$$|\Gamma_i| \leq |\Gamma_0| + \sum (|(R_i)_r| - 1)$$

$\sum (|(R_i)_r| - 1)$ пробегает все правила с $|R_r| \neq \Lambda$.

Обозначим Γ^- слово Γ без первой буквы. Правило R неукорачивающее, если $R_r \neq \Lambda$.

Пусть R — неукорачивающее правило, $R(\Theta_0[1])\Theta_0^-$ предшествует $R(\Theta_1[1])\Theta_1^-$ и $\exists i(\Theta_1^-[i] = \Theta_0^-[1])$, тогда $R(\Theta_0[1])\Theta_0^- \preceq R(\Theta_1[1])\Theta_1^-$.

Ограниченность длины слова в плохой последовательности доказывает почти полноту отношения \preceq в конечном алфавите.

Грубая верхняя оценка на длину плохой последовательности относительно \preceq

$$C_{Max} = \text{card}(\Sigma)^{|\Gamma_0| + \sum (|(R_i)_r| - 1)}.$$

АСПП $G = \langle \Sigma, \mathbf{R} \subset \Sigma \rightarrow \Sigma^*, \Gamma_0 \rangle$ называется *обогащенной* или *ϑ-системой*, если

1. Для всяких двух правил $R : a \rightarrow R_r, R' : b \rightarrow R'_r \exists i, j (R_r[i] \approx R'_r[j]) \Rightarrow i = j \ \& \ |R| = |R'| \ \& \ \forall i (i < |R| \Rightarrow R_r[i] \approx R'_r[i])$;
2. Если $R^a \in \mathbf{R}, R^a : a \rightarrow R_r$ и $b \in \Sigma$, то $R^b : b \rightarrow R_r \in \mathbf{R}$.

Рассмотрим следующее преобразование АСПП G в обогащенную G' .

1. Пусть $a = R_r[i]$, $a \in \Sigma$. Заменяем a на пару $(a, 2^r * 3^{i-1})$. Начальное слово считаем правилом номер 0.
2. К каждой паре правил $a_1 \rightarrow \Phi$, $a_2 \rightarrow \Psi$ добавим правила $a_1 \rightarrow \Psi$ и $a_2 \rightarrow \Phi$ ($a_i \in \Sigma$).
3. Пусть $(a_i, n_i) = R'_r[i]$. Для каждого $a_i \rightarrow \Phi$ добавим в R правила $(a_i, n_i) \rightarrow \Phi$.

Если в \mathcal{G} -системе $\exists R(R : (a, n) \rightarrow R_r)$, то для всякого (b, m) $\exists R(R : (b, m) \rightarrow R_r)$, поэтому правила переписывания в \mathcal{G} -системах будут записываться в общем виде: $R : x \rightarrow R_r$.

Пример

Переведем АСПП G_F в \mathfrak{G} -форму.

G'_F :

$$R_0 : x \rightarrow f^1 a^3 \quad R_2 : x \rightarrow m^4 a^{12}$$

$$R_1 : x \rightarrow f^2 m^6 \quad R_3 : x \rightarrow a^8$$

$$R_4 : x \rightarrow \Lambda$$


Порожденная последовательность после преобразования:

$$\begin{array}{c} \Gamma_0 : \mathbf{f}_{(1)}^1 a_{(0)}^3 \\ \downarrow R_1 \\ \Gamma_1 : \mathbf{f}_{(3)}^2 m_{(2)}^6 a_{(0)}^3 \\ \downarrow R_1 \\ \Gamma_2 : \mathbf{f}_{(5)}^2 m_{(4)}^6 m_{(2)}^6 a_{(0)}^3 \\ \downarrow R_4 \\ \Gamma_3 : \mathbf{m}_{(4)}^6 m_{(2)}^6 a_{(0)}^3 \\ \downarrow R_2 \\ \Gamma_4 : \mathbf{m}_{(7)}^4 a_{(6)}^{12} m_{(2)}^6 a_{(0)}^3 \end{array}$$

Теперь $\Gamma_0 \not\leq \Gamma_1$.


Самая первая пара вложенных по Турчину слов в последовательности, порожденной \mathfrak{G} -системой, имеет вид $R(a)\Theta_0, R(b)\Psi\Theta_0$.

Рассмотрим первую пару $\Phi_1\Theta_0, \Phi_2\Psi\Theta_0$, такую, что $\Phi_1\Theta_0 \preceq \Phi_2\Psi\Theta_0$ ($\Phi_1 \approx \Phi_2$), обрывающую плохую последовательность. $\Phi_1[1]$ и $\Phi_2[1]$ должны порождаться различными применениями R , и если $\Phi_1[1] \approx R_r[i]$, то $\Phi_2[1] \approx R_r[i]$. Обозначим слово $R_r[1]R_r[2]\dots R_r[i-1]$ как $R^{(i-1)}$ и рассмотрим моменты применения R . Первый имеет вид $R_{(k_1)}^{(i-1)}\Phi_1\Theta_0$, второй — $R_{(k_2)}^{(i-1)}\Phi_2\Psi\Theta_0$.



Они образуют турчинскую пару, следовательно, совпадают с $\Phi_1\Theta_0$ и $\Phi_2\Psi\Theta_0$.

Итак, $\Phi_1 = R(a)\Phi'_1$, $\Phi_2 = R(b)\Phi'_2$ ($\Phi'_1 \approx \Phi'_2$). Пусть $\Phi'_1 \neq \Lambda$. Тогда $\exists R', j (\Phi'_1[1] \approx R'_r[j] \ \& \ \Phi'_2[1] \approx R'_r[j])$ и $\Phi'_1[1] \neq \Phi'_2[1]$. Обозначим слово $R'[1]R'[2]\dots R'[j-1]$ как $R'^{(j-1)}$ и рассмотрим моменты применения R' к предшественникам $\Phi_1\Theta_0$ и $\Phi_2\Psi\Theta_0$.



Они выглядят как $R'_{(l_1)}{}^{(j-1)}\Phi'_1\Theta_0$ и $R'_{(l_2)}{}^{(j-1)}\Phi'_2\Psi\Theta_0$ и образуют турчинскую пару. Следовательно, $\Phi_1\Theta_0 = R(a)\Theta_0$ и $\Phi_2\Psi\Theta_0 = R(b)\Psi\Theta_0$.


Применение правила $R(\Delta[1])$ отменено в $\Delta_2 \Leftrightarrow \Delta_2[1] = \Delta_1^- [1] \vee \forall i(\Delta_2[i] \neq \Delta_1^- [1])$.

Если некоторое неукорачивающее правило R никогда не применялось при порождении слова Γ либо все его применения были отменены (назовем такие правила *свободными*), то применение R позволит построить более длинную плохую последовательность, чем стирание первой буквы Γ .

Если неукорачивающие правила применяются к начальному слову длины 1 в порядке R_0, R_1, \dots, R_N (то есть R_i всегда приоритетнее, чем R_{i+j} , если оба эти правила применимы без образования турчинской пары), то наибольшая длина плохой последовательности, которая может быть построена этими правилами

$$C'_{Max} = 1 + |(R_0)_r| * (1 + |(R_1)_r| * (\dots * (1 + |(R_N)_r|) \dots))$$

Пусть в момент Θ_0 осталось только одно свободное неукорачивающее правило R_0 . Длина наибольшего сегмента плохой последовательности, построенном на Θ_0 и заканчивающегося Θ_0^- , равна $|(R_0)_r| + 1$.



Пусть осталось $N + 1$ свободных неукорачивающих правил.

Применим самое приоритетное правило R_k , получим $R_k(\Theta_0[1])\Theta_0^-$. На нем построим самую длинную плохую последовательность, сохраняющую $R_k^-(\Theta_0[1])\Theta_0^-$ (длину этого сегмента будем считать известной и обозначим за $C(N)$). Сегмент завершится словом $R_k^-(\Theta_0[1])\Theta_0^-$. На нем построим самую длинную плохую последовательность, сохраняющую $R_k^{--}(\Theta_0[1])\Theta_0^-$, и т.д. до момента Θ_0^- . Каждая буква в $(R_k)_r$ породит $C(N)$ элементов плохой последовательности. Итоговое увеличение длины равно $1 + |(R_k)_r| * C(N)$.

Пример

Построим самую длинную плохую последовательность в \mathcal{G} -системе G'_F . Ее длина равна $2 * (1 + 2 * (1 + 2 * (1 + 1))) = 22$.

$$\begin{aligned} G'_F: \\ R_0 : x \rightarrow ab \quad R_2 : x \rightarrow ef \\ R_1 : x \rightarrow cd \quad R_3 : x \rightarrow g \\ R_4 : x \rightarrow \Lambda \end{aligned}$$

$$\begin{array}{ll} \Gamma_0 : & a_{(1)}b_{(0)} \\ \Gamma_1 : & c_{(3)}d_{(2)}b_{(0)} \\ \Gamma_2 : & e_{(5)}f_{(4)}d_{(2)}b_{(0)} \\ \Gamma_3 : & g_{(6)}f_{(4)}d_{(2)}b_{(0)} \\ \Gamma_4 : & f_{(4)}d_{(2)}b_{(0)} \\ \Gamma_5 : & g_{(7)}d_{(2)}b_{(0)} \\ \Gamma_6 : & d_{(2)}b_{(0)} \\ \Gamma_7 : & e_{(9)}f_{(8)}b_{(0)} \\ \Gamma_8 : & g_{(10)}f_{(8)}b_{(0)} \\ \Gamma_9 : & f_{(8)}b_{(0)} \\ \Gamma_{10} : & g_{(11)}b_{(0)} \\ \Gamma_{11} : & b_{(0)} \\ \Gamma_{12} : & c_{(13)}d_{(12)} \\ \Gamma_{13} : & e_{15}f_{(14)}d_{(12)} \\ \Gamma_{14} : & g_{16}f_{(14)}d_{(12)} \\ \Gamma_{15} : & f_{(14)}d_{(12)} \\ \Gamma_{16} : & g_{(17)}d_{(12)} \\ \Gamma_{17} : & d_{(12)} \\ \Gamma_{18} : & e_{(19)}f_{(18)} \\ \Gamma_{19} : & g_{(20)}f_{(18)} \\ \Gamma_{20} : & f_{(18)} \\ \Gamma_{21} : & g_{(21)} \end{array}$$

Применение любого из R_1 – R_4 к Γ_{21} породит турчинскую пару.

\preceq не является транзитивным, но существует транзитивное отношение T , $T \subset \preceq$, являющееся почти полным на всех последовательностях, порожденных АСПП.

G_{ABC} :

$$\begin{aligned} R_1 &: a \rightarrow \Lambda & R_3 &: d \rightarrow \Lambda \\ R_2 &: a \rightarrow ad & R_4 &: b \rightarrow fbe \\ R_5 &: f \rightarrow ad \end{aligned}$$

$$\begin{array}{c} \Gamma_0 : \mathbf{a}_{(2)}\mathbf{b}_{(1)}\mathbf{c}_{(0)} \\ \downarrow R_2 \\ \Gamma_1 : \mathbf{a}_{(4)}\mathbf{d}_{(3)}\mathbf{b}_{(1)}\mathbf{c}_{(0)} \\ \downarrow R_1 \\ \Gamma_2 : \mathbf{d}_{(3)}\mathbf{b}_{(1)}\mathbf{c}_{(0)} \\ \downarrow R_3 \\ \Gamma_3 : \mathbf{b}_{(1)}\mathbf{c}_{(0)} \\ \downarrow R_4 \\ \Gamma_4 : \mathbf{f}_{(7)}\mathbf{b}_{(6)}\mathbf{e}_{(5)}\mathbf{c}_{(0)} \\ \downarrow R_5 \\ \Gamma_5 : \mathbf{a}_{(9)}\mathbf{d}_{(8)}\mathbf{b}_{(6)}\mathbf{e}_{(5)}\mathbf{c}_{(0)} \end{array}$$

$\Gamma_0 \preceq \Gamma_1$ и $\Gamma_1 \preceq \Gamma_5$, но $\Gamma_0 \not\preceq \Gamma_5$.

Рассмотрим все порожденные последовательности $\{\Phi_i\}_{i=1}^{\infty}$, такие, что $\exists N \forall i \exists j (i < j \ \& \ |\Phi_j| \leq N)$.

Для каждой такой последовательности выберем наименьшее N , удовлетворяющее этому свойству. Существует конечное число классов эквивалентности Q' слов длины не больше N , таких, что $\forall i, j (|\Phi_i| \leq N \Rightarrow (\Phi_i \in Q' \ \& \ \Phi_j \in Q' \Leftrightarrow \Phi_i \approx \Phi_j))$. Хотя бы один из них содержит бесконечное число элементов — обозначим его $\{\Phi'_i\}$. Если для некоторых i, j, k $\Phi'_i[k] \neq \Phi'_j[k]$, то моменты, в которые $\Phi'_i[k]$ и $\Phi'_j[k]$ были порождены — результаты применения неукорачивающих правил. Значит, какое-то из них применяется бесконечное число раз.

Все прочие порожденные последовательности удовлетворяют условию $\forall N \exists i_N \forall j (j > i_N \Rightarrow |\Phi_j| > N)$.

Для каждого N выберем такое первое i_N , что $\forall j (j < i_N \Rightarrow \exists k (k \geq j \ \& \ |\Phi_k| < N))$. Итак, $|\Phi_{i_N-1}| < N$ и $|\Phi_{i_N}| \geq N$, и Φ_{i_N} порождено из предыдущего слова применением неукорачивающего правила R , $|R| \geq 2$: $\Phi_{i_N} = R(\Phi_{i_N-1}[1])\Phi_{i_N-1}^-$. $\Phi_{i_N-1}^-$ неизменно, поскольку $|\Phi_{i_N-1}| < N$. Все элементы последовательности $\{\Phi_{i_N}\}_{i=1}^\infty$ начинаются с правой части некоторого неукорачивающего правила, значит, существует бесконечная подпоследовательность $\{\Phi_{i_N}\}_{i=1}^\infty$, такая, что все ее элементы начинаются с правой части одного и того же правила.

Следствие

Пусть R — квазипорядок, полный на произвольных последовательностях. $R \cap \preceq$ — почти полное отношение.

Все турчинские пары в T являются результатами применения одного и того же неукорачивающего правила без его отмены. Поэтому турчинское отношение можно сузить до отношения $\preceq' = \{(\Gamma, \Delta) \mid \Gamma = R(a)\Theta_0 \ \& \ \Delta = R(b)\Psi\Theta_0\}$ без потери почти полноты.

Рассмотрим правило $a_1a_2 \dots a_n \rightarrow b_1b_2 \dots b_m$ неалфавитной СПП. Его действие эквивалентно композиции действий:

$$a_1 \rightarrow \Lambda$$

...

$$a_{n-1} \rightarrow \Lambda$$


$$a_n \rightarrow b_1b_2 \dots b_m.$$

Отношение \preceq' почти полно на последовательностях, порожденных АСПП. Значит, \preceq почти полно на последовательностях, порожденных произвольными СПП с конечным набором правил в конечном алфавите.

Первая хигманова пара в последовательности, порожденной \mathfrak{G} -системой, является турчинской парой.

Рассмотрим такие Φ_1 и Φ_2 , что $\Phi_1 \trianglelefteq \Phi_2$, причем последовательность вплоть до Φ_2 представляет собой плохую последовательность в смысле \trianglelefteq .

$\Phi_1 = A_1 A_2 \dots A_n \Theta$ и $\Phi_2 = B_0 A'_1 B_2 A'_2 \dots B_{n-1} A'_n B_n \Theta$, и $\forall i (i \geq 1 \ \& \ i \leq n \Rightarrow A_i \approx A'_i)$. Вернемся к моментам порождения $A_l[1]$ и $A'_l[1]$ правилом $R : x \rightarrow R_r$ (пусть $A_l[1] \approx R_r[i]$).



В эти моменты имеем $R_{(k_1)}^{(i-1)} A_l A_{l+1} \dots A_n \Theta$ и $R_{(k_2)}^{(i-1)} A'_l B_l \dots B_{n-1} A_n B_n \Theta$ ($R_{k_j}^{(i-1)}$ обозначает префикс $R_r[1]_{(k_j+i-2)} \dots R_r[i-1]_{(k_j)}$). Они образуют хигманову пару, следовательно, $l = 1 = n$. Тогда $\Phi_1 = A_1 \Theta$ и $\Phi_2 = A'_1 B_n \Theta$, и $\Phi_1 \preceq \Phi_2$.

Выводы

1. \preceq является почти полным над последовательностями, порожденными конечными СПП над конечным алфавитом. Верхняя оценка длины плохой последовательности по \preceq экспоненциальна от размера исходной грамматики.
2. Плохие последовательности по \trianglelefteq и по \preceq совпадают на множестве последовательностей, порожденных обогащенными конечными СПП.

Направление развития

Поиск аналога \preceq для деревьев функциональных вызовов.

Спасибо за внимание!