

Встреча лаборатории автоматизации  
программирования  
ИПС им. А.К. Айламазяна с экспертами  
Санкт-Петербургского Филиала  
Российского Исследовательского Института

Докладчик: Непейвода А.Н.  
12.03.2024

Переславль-Залесский, Санкт-Петербург

## Пример отображения

Здесь  $\text{prefix}(x,y)$  — проверка, что  $y$  начинается с  $x$ .

$z = \xi$	$z \rightarrow \xi$
$x = \varepsilon$	$x \rightarrow \varepsilon$
$y = \varepsilon$	$y \rightarrow \varepsilon$
while (cond1)	while (cond1)
$x+=z$	$x \rightarrow \xi x = x\xi$
while (cond2)	while (cond2)
$y+=z$	$y \rightarrow \xi y = y\xi$
while (true)	while (true)
if ( $\text{prefix}(x,y)$ )	if ( $ x  \leq  y $ )
$y-=x$	$y \rightarrow \xi y = y\xi$
elif ( $\text{prefix}(y,x)$ )	elif ( $ y  \leq  x $ )
$x-=y$	$x \rightarrow \xi x = x\xi$
else break	else break

Из анализа доменов становится возможно заменить условия  $\text{prefix}(x,y)$  и  $\text{prefix}(y,x)$  на неравенства длин, одно из которых всегда выполнено. Дальнейший статический анализ способен указать на недостижимость ветви, содержащей `break`.



## Соответствие Галуа

Введём отношение  $\alpha$  между множествами конкретных (строковых) значений  $S$  и абстрактных значений  $\Delta$ .

А именно, скажем, что  $s \alpha \rho$ , если строка  $s$  удовлетворяет рестрикции (условию)  $\rho$ .

Антимонотонное соответствие Галуа, задаваемое отношением  $\alpha$ , будет определять операции абстракции и конкретизации относительно домена абстрактных значений  $\Delta$ .

- $\phi : 2^S \rightarrow 2^\Delta; \quad \phi(A) = \{\rho \mid \forall a \in A(a \alpha \rho)\}$
- $\psi : 2^\Delta \rightarrow 2^S; \quad \psi(\Gamma) = \{a \mid \forall \rho \in \Gamma(a \alpha \rho)\}$
- $A \subseteq A' \Rightarrow \phi(A') \subseteq \phi(A); \quad \Gamma \subseteq \Gamma' \Rightarrow \psi(\Gamma') \subseteq \psi(\Gamma)$




## Требуемые свойства домена $\Delta$

- У каждой двух рестрикций должен существовать точный супремум (для исключения «эффекта бабочки») и инфимум (для замыкания в решётку). А именно,  $\forall \phi_1, \phi_2 \exists \psi_1, \psi_2 (\phi_1 \vee \phi_2 = \psi_1 \ \& \ \phi_1 \wedge \phi_2 = \psi_2)$ .
- Высота строго возрастающих последовательностей должна быть конечной, желательно не больше 5.
- Свойство верхней полурешётки влечёт завершаемость (существование конечно вычислимых неподвижных точек).



## Общие замечания

- Абстрактный домен регулярных выражений удовлетворяет свойствам решётки (алгебраически замкнут относительно объединений и пересечений). Замкнут относительно гомоморфизмов и обратных гомоморфизмов. Однако высота этой решётки над бесконечным алфавитом бесконечна.



## Возможные сужения домена

Обозначение  $\tau^n$  — сокращение для  $\underbrace{\tau\tau\dots\tau}_n$

Слово  $\tau$  простое, если из  $\tau = \xi^n$  следует, что  $n = 1$  и  $\xi = \tau$ .

Т.е.  $aab$  — простое,  $abab$  — нет.

- Базовые уравнения (предикаты вида  $\text{ContAll}(s, \tau)$ ) и неравенства (вида  $\text{NCont}(s, \tau)$ ).
  - $\text{ContAll}(s, \tau) \equiv \tau s = s \tau$ , при этом  $\tau$  — простое слово;
  - $\text{NCont}(s, \tau) \equiv \forall z_1, z_2 (s \neq z_1 \tau z_2)$ .

Предикаты, специализированные строкой  $\tau$ , обозначаем  $\text{ContAll}_\tau$  и  $\text{NCont}_\tau$ . Абстрактными объектами решетки являются именно эти предикаты (вместе с предикатами «совпадать со строкой  $\tau$ », далее обозначаемыми просто  $\tau$ ).



# Вычисление супремума рестрикций

Скажем, что  $s_1 \ll s_2$ , если  $\neg \text{NCont}(s_2, s_1)$ .

Предикат  $\text{ContAll}_\varepsilon$  предполагаем некорректно заданным, поэтому всюду в случае определения предиката  $\text{ContAll}_\tau$  предполагаем, что  $\tau$  простое и не равно  $\varepsilon$ .

- $\text{ContAll}_\tau \vee \text{ContAll}_\xi = \begin{cases} \text{ContAll}_\tau, & \text{если } \xi = \tau \\ \top, & \text{иначе} \end{cases}$
- $\text{NCont}_\tau \vee \text{NCont}_\xi = \begin{cases} \text{NCont}_\tau, & \text{если } \xi \ll \tau \\ \text{NCont}_\xi, & \text{если } \tau \ll \xi \\ \top, & \text{иначе} \end{cases}$
- $\text{ContAll}_\tau \vee \xi = \begin{cases} \text{ContAll}_\tau, & \text{если } \exists n (\xi = \tau^n \ \& \ n \geq 0) \\ \top, & \text{иначе} \end{cases}$
- $\text{NCont}_\tau \vee \xi = \begin{cases} \text{NCont}_\tau, & \text{если } \neg(\tau \ll \xi) \\ \top, & \text{иначе} \end{cases}$



- $\text{NCont}_\tau \vee \text{ContAll}_\xi = \begin{cases} \text{NCont}_\tau, & \text{если } \forall n(\neg(\tau \ll \xi^n)) \\ \top, & \text{иначе} \end{cases}$

Если строка не содержит подстроки  $\tau$  или состоит из степеней строк, которые не могут содержать  $\tau$ , тогда эта строка не содержит подстроки  $\tau$ .





# Вычисление супремума строк

Зададим армейский (military) порядок на строках  $\preceq_{lex}^*$  относительно упорядочения букв  $\preceq$ . Определим функцию «не-делители»  $NFact(s) = \{s' \mid \neg(s' \ll s)\}$ .

Тогда  $\tau_1 \vee \tau_2 =$

$$\begin{cases} \varepsilon, & \text{если } \tau_1 = \tau_2 = \varepsilon \\ \text{ContAll}_{\tau'}, & \text{если } \exists \tau', n, m (\tau_1 = \tau'^n \ \& \ \tau_2 = \tau'^m \ \& \ n + m > 0) \\ \inf_{\preceq_{lex}^*} (NFact(\tau_1) \cap NFact(\tau_2)), & \text{иначе} \end{cases} .$$

Пусть  $a \preceq b$ . Пример упорядочения на  $\{a, b, aa, ab\}$ .

Армейский	Лексикографический
$a$	$a$
$b$	$aa$
$aa$	$ab$
$ab$	$b$



# Проблема инфинума

- Полученная модель — верхняя полурешётка (join-semilattice) конечной высоты. Теоретически, этого достаточно для вычисления неподвижных точек итерацией Клини за конечное время. Практически — зависит от деталей уже реализованного алгоритма.
- Полная решётка получается ограничением условий только на  $\text{ContAll}_\tau$ . Тогда


- $\text{ContAll}_\tau \wedge \text{ContAll}_\xi = \begin{cases} \text{ContAll}_\tau, & \text{если } \xi = \tau \\ \varepsilon, & \text{иначе} \end{cases}$

- $\text{ContAll}_\tau \wedge \xi = \begin{cases} \xi, & \text{если } \exists n(\xi = \tau^n \ \& \ n \geq 0) \\ \perp, & \text{иначе} \end{cases}$

- $\tau_1 \vee \tau_2 = \begin{cases} \varepsilon, & \text{если } \tau_1 = \tau_2 = \varepsilon \\ \text{ContAll}_{\tau'}, & \text{если } \exists \tau', n, m(\tau_1 = \tau'^n \ \& \ \tau_2 = \tau'^m \ \& \ n + m > 0) \\ \top, & \text{иначе} \end{cases}$



# Пример решётки



# Набросок алгоритма преобразования

Стандартно полагаем, что  $x \leq y \equiv x \vee y = y$

Конкатенация, удаление префикса и взятие подстроки с произвольной позиции:

- $x + y \approx x \vee y$

- $x - y \approx$

$$\left\{ \begin{array}{l} x - y, \text{ если } \exists \tau (x = y\tau) \\ \text{ошибка, если } x \text{ и } y \text{ константы, но } \forall \tau (x \neq y\tau) \\ \text{ошибка, если } x = \text{ContAll}_\tau \ \& \ \forall \tau', \tau'', n (y \neq \tau^n \tau' \text{ или } \tau \neq \tau' \tau'') \\ x, \text{ если } y = \text{ContAll}_\tau \text{ и либо } x \text{ константа и } \forall \xi' (x \neq \tau \xi'), \\ \quad \text{либо } x = \text{ContAll}_\xi \text{ и } \forall \xi' (\xi \neq \tau \xi') \\ x \vee y, \text{ иначе} \end{array} \right.$$

- $x = \text{infix}(y) \approx \left\{ \begin{array}{l} \text{ContAll}_a, \text{ если } y = a \text{ или } y = \text{ContAll}_a \\ \quad (a - \text{буква}) \\ \varepsilon, \text{ если } y = \varepsilon \\ \top, \text{ иначе} \end{array} \right.$



## Замена подстроки в строке

- $z = \text{replace}(y, z_1, z_2) \approx$   
 $\left\{ \begin{array}{l} \text{replace}(y, z_1, z_2), \text{ если } y, z_1, z_2 \text{ константы.} \\ \text{ошибка, если } z_1 = \varepsilon \\ \text{ContAll}_\tau, \text{ если хотя бы одно из } y, z_1, z_2 \text{ равно } \text{ContAll}_\tau \\ \quad \text{и при этом } y, z_1, z_2 \leq \text{ContAll}_\tau \\ \text{ContAll}_\tau, \text{ если } y = \text{ContAll}_\tau, \& (z_1 = \text{ContAll}_\xi \text{ или } z_1 = \xi), \\ \quad \text{причём } \forall n(\text{NCont}_\xi(\tau^n)) \\ \top, \text{ иначе} \end{array} \right.$

Четвертый случай соответствует невозможности найти хотя бы одну требуемую подстроку в первом аргументе. Если  $z_1 = \text{ContAll}_\xi$ , тогда последнее условие в четвертом случае вырождается в  $\text{NCont}_\xi(\tau)$ .



# Предикаты (на примере метода startsWith)

- $prefix(x, y)$  ( $x$  является префиксом  $y$ )  $\approx$   
$$\left\{ \begin{array}{l} (x = \tau \text{ OR } x = \varepsilon), \text{ если } y = \tau, x = \text{ContAll}_\tau \\ |x| \leq |y|, \text{ если } x = y = \text{ContAll}_\tau \\ x = \varepsilon, \text{ если } y = \varepsilon \\ true, \text{ если } \exists \xi (y = x\xi) \\ false, \text{ если } x, y \text{ константы и } \forall \xi (y \neq x\xi) \\ (x = \tau_1 \text{ OR } x = \varepsilon), \text{ если } x = \text{ContAll}_{\tau_1}, y = \text{ContAll}_{\tau_2}, \\ \quad \text{и } \exists \tau_3 (\tau_3 \neq \varepsilon \ \& \ \tau_2 = \tau_1 \tau_3) \\ x = \varepsilon, \text{ если } x = \text{ContAll}_{\tau_1} \ \& \ (y = \text{ContAll}_{\tau_2} \ \text{или} \ y = \tau_2) \\ \quad \& \ \forall \tau_3 (\tau_2 \neq \tau_1 \tau_3) \\ prefix(x, y), \text{ иначе} \end{array} \right.$$

Предикаты преобразуются в более широком языке, включающем преобразования между типами и булевские операции. Чтобы не путать операцию супремума и логическое «или», для второго здесь используем код OR.



# Разбор примера

$z = \xi$	$z \rightarrow \xi$
$x = \varepsilon$	$x \rightarrow \varepsilon$
$y = \varepsilon$	$y \rightarrow \varepsilon$
while (cond1)	while (cond1)
$x += z$	$x \rightarrow \xi x = x\xi$ ( $\varepsilon \vee \xi = \text{ContAll}_\xi = \text{ContAll}_\xi \vee \xi$ )
n while (cond2)	while (cond2)
$y += z$	$y \rightarrow \xi y = y\xi$ ( $\varepsilon \vee \xi = \text{ContAll}_\xi = \text{ContAll}_\xi \vee \xi$ )
while (true)	while (true)
if (prefix(x,y))	if ( $ x  \leq  y $ ) ( $x = y = \text{ContAll}_\xi$ )
$y -= x$	$y \rightarrow \xi y = y\xi$ ( $\text{ContAll}_\xi \vee \text{ContAll}_\xi = \text{ContAll}_\xi$ )
elif (prefix(y,x))	elif ( $ y  \leq  x $ ) ( $x = y = \text{ContAll}_{x_i}$ )
$x -= y$	$x \rightarrow \xi x = x\xi$ ( $\text{ContAll}_\xi \vee \text{ContAll}_\xi = \text{ContAll}_\xi$ )
else break	else break



# Специализация по гомоморфизму

- Операции  $\vee$ ,  $\wedge$  могут быть перенесены на гомоморфные образы строк и условий по гомоморфизму  $h$ . Например, это позволяет отделить абстрактное значение «строка, представляющая число», от прочих строк.
- Аналогичные свойства выполняются для обратного гомоморфизма. В частности, это позволяет отделить абстрактное значение «строка, представляющая ключевое слово», от прочих строк.
- Комбинация двух подходов позволит обрабатывать сложные случаи: число, которое является ключевым словом (и не состоит из цифр) (в JavaScript: Infinity, -Infinity).

