



KYUSHU UNIVERSITY 100th 2011
知の新世紀を拓く

形式言語理論

Formal Language Theory

3. 正規表現



九州大学
KYUSHU UNIVERSITY

本日の内容

- 準備
- 正規表現
- ε -NFAと正規表現の等価性

準備

言語の接続

- アルファベット Σ 上の言語 L_1, L_2 に対し,
$$L_1 \cdot L_2 = \{ xy \mid x \in L_1, y \in L_2 \}$$
を L_1, L_2 の**接続**と呼ぶ.
- 演算子「 \cdot 」を略して $L_1 \cdot L_2$ を L_1L_2 と書くことが多い.

言語の冪乗

- アルファベット Σ 上の言語 L と非負整数 n に対し、言語 L^n を次で定める.

$$L^n = \begin{cases} \{\varepsilon\}, & \text{if } n = 0 \\ L^{n-1} \cdot L, & \text{if } n > 0 \end{cases}$$

- アルファベット Σ 上の言語 L に対し、言語 L^* , L^+ を次で定める.

$$L^* = \bigcup_{n=0}^{\infty} L^n$$

$$L^+ = \bigcup_{n=1}^{\infty} L^n$$

正規表現

正規表現の例

- 0,1から成る文字列のうち0で始まるもの.

$0(0+1)^*$ 0, 00, 01, 000, 001, ...

- 0,1から成る文字列のうち00 で終わるもの.

$(0+1)^* 00$ 00, 000, 100, 0000, 0100, ...

- 0,1から成る文字列のうち途中に011を含むもの.

$(0+1)^* 011 (0+1)^*$ 011, 0011, 1011, 00110, 00111, ...

正規表現の例

- 0,1から成る文字列のうち偶数個の0を含むもの.

$$1^*(01^*01^*)^*$$

1111, 110101, 10111010011, ...

正規表現の例

- 非負整数の十進表現.

$$(1+2+3+4+5+6+7+8+9)(0+1+2+3+4+5+6+7+8+9)^*+0$$

- 2の倍数である非負整数の十進表現.


$$((1+2+3+4+5+6+7+8+9)(0+1+2+3+4+5+6+7+8+9)^* + \varepsilon)(0+2+4+6+8)$$

正規表現(regular expression)

【定義】 Σ をアルファベットとする. $A = \{ \}, (, \varepsilon, \emptyset, \cdot, +, * \}$ は $\Sigma \cap A = \emptyset$ を満たすとする. Σ 上の**正規表現**とは, 次の(1)-(5)から導かれる $\Sigma \cup A$ 上の文字列をいう.

- (1) Σ の要素は正規表現である.
- (2) ε は正規表現である.
- (3) \emptyset は正規表現である.
- (4) α と β が正規表現ならば $(\alpha \cdot \beta)$ は正規表現である.
- (5) α と β が正規表現ならば $(\alpha + \beta)$ は正規表現である.
- (6) α が正規表現ならば α^* は正規表現である.

$\Sigma = \{a, b\}$ のとき



正規表現の「意味」

【定義】 Σ 上の正規表現を Σ^* の部分集合に写す写像 $\|\cdot\|$ を次で定める.

- (1) すべての $a \in \Sigma$ に対して $\|a\| = \{a\}$.
- (2) $\|\varepsilon\| = \{\varepsilon\}$.
- (3) $\|\emptyset\| = \emptyset$.
- (4) 正規表現 α と β に対して $\|(\alpha \cdot \beta)\| = \|\alpha\| \cdot \|\beta\|$.
- (5) 正規表現 α と β に対して $\|(\alpha + \beta)\| = \|\alpha\| \cup \|\beta\|$.
- (6) 正規表現 α に対して $\|\alpha^*\| = \|\alpha\|^*$.

$$\begin{aligned}
 \|(\mathbf{a} \cdot (\mathbf{a} + \mathbf{b})^*)\| &= \|\mathbf{a}\| \cdot \|(\mathbf{a} + \mathbf{b})^*\| = \{\mathbf{a}\} \cdot \|(\mathbf{a} + \mathbf{b})\|^* = \{\mathbf{a}\} \cdot (\|\mathbf{a}\| \cup \|\mathbf{b}\|)^* \\
 &= \{\mathbf{a}\} \cdot (\{\mathbf{a}\} \cup \{\mathbf{b}\})^* = \{\mathbf{a}\} \cdot \{\mathbf{a}, \mathbf{b}\}^* \\
 &= \{\mathbf{a}x \mid x \in \{\mathbf{a}, \mathbf{b}\}^*\}
 \end{aligned}$$

正規表現の簡略化

- 正規表現 α に対し $(\alpha \cdot \alpha^*)$ の省略形として α^+ を用いることがある.
- 演算の強さを
 $* > \cdot > +$
と定めることにより, $(,)$ の省略を許す.

$$((0(1^*)) + 0) \Rightarrow 01^+ + 0$$

ε -NFAと正規表現の等価性

ε -NFAと正規表現の等価性

【定理2.3】 L を任意の言語とする. このとき, 次の(1)(2)は等価である.

- (1) ある正規表現 r が存在して $L = \|r\|$.
- (2) ある ε -NFA M が存在して $L = L(M)$ となる.

定理2.3の証明

- 定理2.1, 2.2より, 次の2つの補題を示せばよい.

【補題2.1】 すべての正規表現 r に対して $L(M) = \|r\|$ となり次の(1)(2)を満たす ε -NFA $M = (Q, \Sigma, \delta, q_0, F)$ が存在する.

- (1) M はただ一つの最終状態 f をもつ. すなわち $F = \{f\}$.
- (2) すべての $a \in \Sigma \cup \{\varepsilon\}$ に対して $\delta(f, a) = \emptyset$.


【補題2.2】 すべての **DFA** M に対して $L(M) = \|r\|$ となる正規表現 r が存在する.

補題2.1の証明: アイデア (1 / 3)


- 正規表現 r に含まれる演算子の個数 m に関する帰納法で証明する.
 - $m=0$ となるのは、次の3つの場合のいずれかである.
 - ◆ $r = a \in \Sigma$.
 - ◆ $r = \varepsilon$.
 - ◆ $r = \emptyset$.
 - $m>0$ となるのは、次の3つの場合のいずれかである.
 - ◆ $r = r_1 \cdot r_2$ (r_1, r_2 は正規表現).
 - ◆ $r = r_1 + r_2$ (r_1, r_2 は正規表現).
 - ◆ $r = r_1^*$ (r_1 は正規表現).

補題2.1の証明: アイデア (2 / 3)


■ $m=0$ のとき.



$r = a \in \Sigma$ に対する ε -NFA



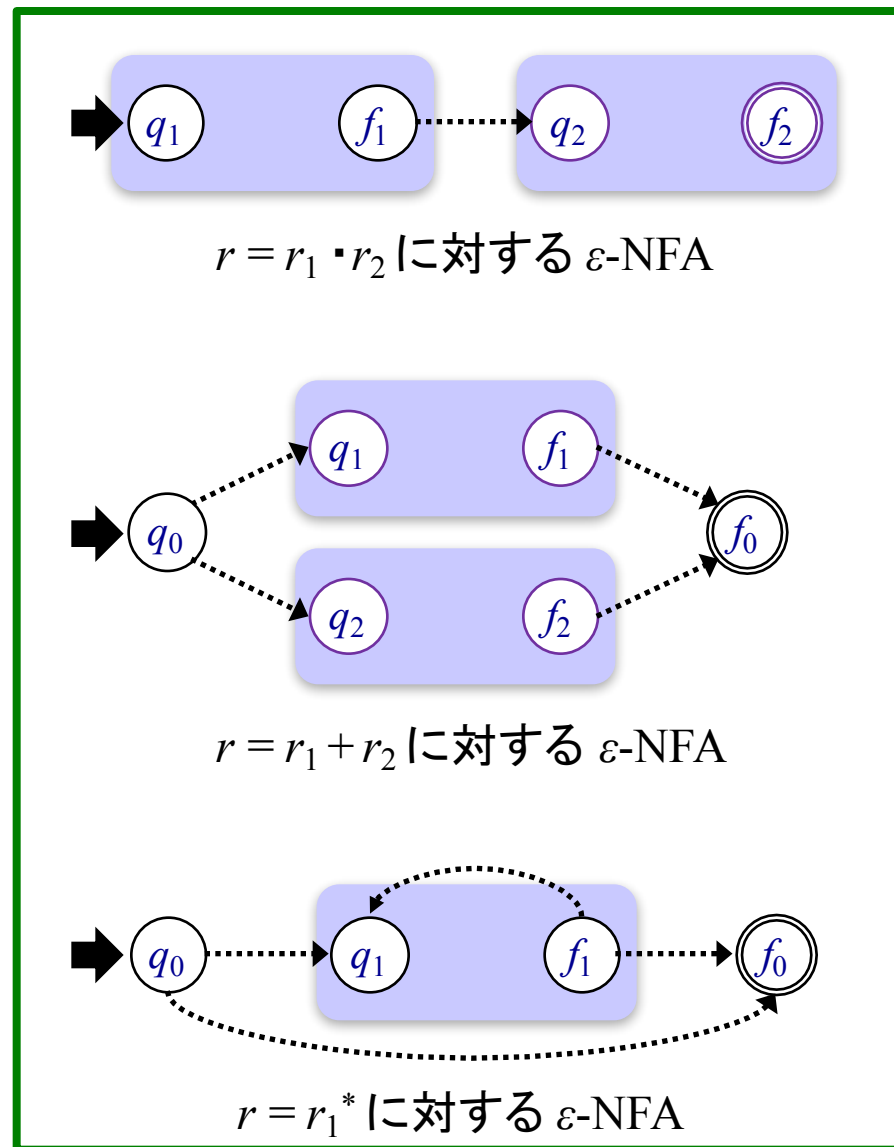

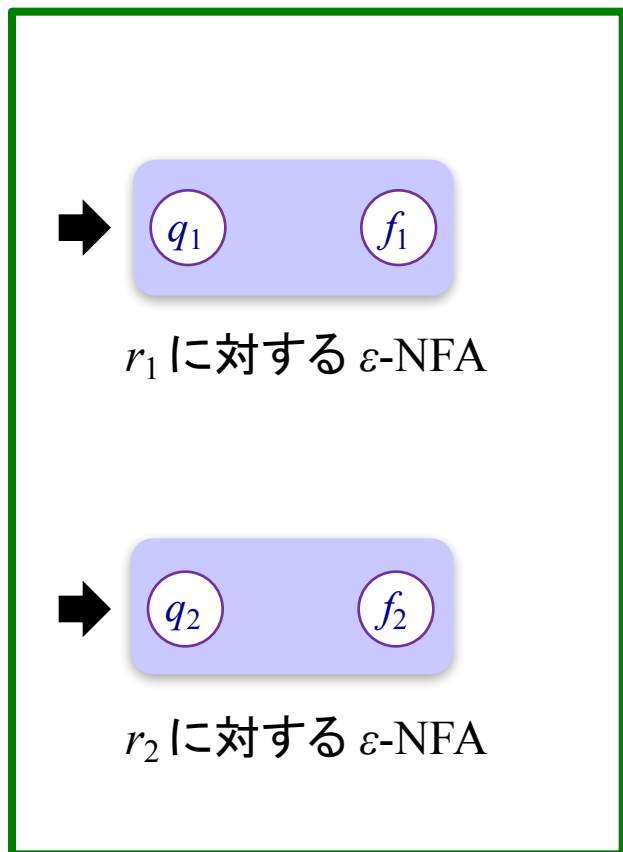
$r = \varepsilon$ に対する ε -NFA



$r = \emptyset$ に対する ε -NFA


補題2.1の証明: アイデア (3 / 3)

■ $m > 0$ のとき.




例 正規表現 ab^*+c に対する ϵ -NFAの構成


ab^*+c に対する ϵ -NFA




ab^* に対する ϵ -NFA




b^* に対する ϵ -NFA




a に対する ϵ -NFA



b に対する ϵ -NFA



c に対する ϵ -NFA



補題2.1の証明(1/4)

- 正規表現 r に含まれる演算子の個数 m に関する帰納法で証明する.
- $m=0$ のとき. 補題の条件を満たす ε -NFA M を次のように構成できる.
 1. $r = a \in \Sigma$ ならば, $M = (\{q_0, q_1\}, \Sigma, \delta, q_0, \{q_1\})$ s.t.
$$\delta(q, c) = \begin{cases} \{q_1\}, & \text{if } (q, c) = (q_0, a) \\ \emptyset, & \text{otherwise.} \end{cases}$$
 2. $r = \varepsilon$ ならば, $M = (\{q_0\}, \Sigma, \delta, q_0, \{q_0\})$ s.t.
$$\delta(q_0, c) = \emptyset \quad (\forall c \in \Sigma \cup \{\varepsilon\}).$$
 3. $r = \emptyset$ ならば, $M = (\{q_0, q_1\}, \Sigma, \delta, q_0, \{q_1\})$ s.t.
$$\delta(q, c) = \emptyset \quad (\forall (q, c) \in \{q_0, q_1\} \times (\Sigma \cup \{\varepsilon\})).$$

補題2.1の証明(2/4)

■ $m > 0$ のとき. 補題の条件を満たす ε -NFA を次のように構成できる.

1. $r = r_1 \cdot r_2$ (r_1, r_2 は正規表現) ならば, 帰納法の仮定より, r_1, r_2 に対する ε -NFA M_1, M_2 が存在する.

$M_1 = (Q_1, \Sigma, \delta_1, q_1, \{f_1\})$, $M_2 = (Q_2, \Sigma, \delta_2, q_2, \{f_2\})$ とする.

一般性を失わず, $Q_1 \cap Q_2 = \emptyset$ としてよい.

このとき, $M = (Q_1 \cup Q_2, \Sigma, \delta, q_1, \{f_2\})$ は補題の条件を満たす ε -NFA である. ここに, δ は次で定義される.

$$\delta(q, c) = \begin{cases} \delta_1(q, c), & \text{if } (q, c) \in Q_1 \times (\Sigma \cup \{\varepsilon\}) - \{(f_1, \varepsilon)\} \\ \delta_2(q, c), & \text{if } (q, c) \in Q_2 \times (\Sigma \cup \{\varepsilon\}) \\ \{q_2\}, & \text{if } (q, c) = (f_1, \varepsilon) \end{cases}$$

補題2.1の証明(3/4)

2. $r = r_1 + r_2$ (r_1, r_2 は正規表現)ならば、帰納法の仮定より、 r_1, r_2 に対する ε -NFA M_1, M_2 が存在する。

$M_1 = (Q_1, \Sigma, \delta_1, q_1, \{f_1\})$, $M_2 = (Q_2, \Sigma, \delta_2, q_2, \{f_2\})$ とする。

一般性を失わず、 $Q_1 \cap Q_2 = \emptyset$ としてよい。

このとき、 $M = (Q_1 \cup Q_2 \cup \{q_0, f_0\}, \Sigma, \delta, q_0, \{f_0\})$ は補題の条件を満たす ε -NFAである。ここに、 δ は次で定義される。

$$\delta(q, c) = \begin{cases} \{q_1, q_2\}, & \text{if } (q, c) = (q_0, \varepsilon) \\ \delta_1(q, c), & \text{if } (q, c) \in Q_1 \times (\Sigma \cup \{\varepsilon\}) - \{(f_1, \varepsilon)\} \\ \delta_2(q, c), & \text{if } (q, c) \in Q_2 \times (\Sigma \cup \{\varepsilon\}) - \{(f_2, \varepsilon)\} \\ \{f_0\}, & \text{if } (q, c) \in \{(f_1, \varepsilon), (f_2, \varepsilon)\} \\ \emptyset, & \text{otherwise} \end{cases}$$

補題2.1の証明(4/4)

3. $r = r_1^*$ (r_1 は正規表現)ならば, 帰納法の仮定より,
 r_1 に対する ε -NFAが存在する.

$M_1 = (Q_1, \Sigma, \delta_1, q_1, \{f_1\})$ とする.

このとき, $M = (Q_1 \cup Q_2 \cup \{q_0, f_0\}, \Sigma, \delta, q_0, \{f_0\})$ は補題の条件を満たす ε -NFAである. ここに, δ は次で定義される.

$$\delta(q, c) = \begin{cases} \{q_1\}, & \text{if } (q, c) = (q_0, \varepsilon) \\ \delta_1(q, c), & \text{if } (q, c) \in Q_1 \times (\Sigma \cup \{\varepsilon\}) - \{(f_1, \varepsilon)\} \\ \{q_1, f_0\}, & \text{if } (q, c) = (f_1, \varepsilon) \\ \emptyset, & \text{otherwise} \end{cases}$$

QED

補題2.2の証明(1 / 3)

- DFAを $M = (\{q_1, \dots, q_n\}, \Sigma, \delta, q_1, F)$ とする.
- 各 $i, j \in \{1, \dots, n\}$ と各 $k \in \{0, \dots, n\}$ に対して $R_{i,j}^k$ を次の①②を満たす文字列 x 全体の集合と定める.
 - ① $\delta(q_i, x) = q_j$.
 - ② x の任意の接頭辞 y ($0 < |y| < |x|$) に対して $\delta(q_i, y) \in \{q_1, \dots, q_k\}$.

状態 q_i を出発して、途中 q_1, \dots, q_k の状態のみを經由しながら状態 q_j へ至る状態遷移を引き起こす文字列の集合.

補題2.2の証明(2/3)

- すべての i, j, k について, $R_{i,j}^k$ は正規表現で表せることを帰納法で証明する.
- $k=0$ のとき.
 - $R_{i,j}^0 = \{a \mid a \in \Sigma, \delta(q_i, a) = q_j\} \cup \{\varepsilon \mid i = j\}$ が成り立つ.
 - $R_{i,j}^0$ は $\Sigma \cup \{\varepsilon\}$ の部分集合であるから有限集合であり, 正規表現で表わせる.

補題2.2の証明(3/3)

■ $k > 0$ のとき.

- $R_{i,j}^k = R_{i,k}^{k-1} (R_{k,k}^{k-1})^* R_{k,j}^{k-1} \cup R_{i,j}^{k-1}$ ($k > 0$) が成り立つ.
- 帰納法の仮定より, $R_{i,k}^{k-1}$, $R_{k,k}^{k-1}$, $R_{k,j}^{k-1}$, $R_{i,j}^{k-1}$ は正規表現で表すことができる. その正規表現を, 順に, $r_{i,k}^{k-1}$, $r_{k,k}^{k-1}$, $r_{k,j}^{k-1}$, $r_{i,j}^{k-1}$ とすると, $R_{i,j}^k$ は以下の正規表現で表せる.


$$r_{i,k}^{k-1} (r_{k,k}^{k-1})^* r_{k,j}^{k-1} + r_{i,j}^{k-1}$$

- $L(M) = \bigcup_{q_j \in F} R_{1,j}^n$ であるから, $F = \{j_1, \dots, j_p\}$ とすると, $L(M)$ は以下の正規表現で表せる.

$$r_{1,j_1}^n + \dots + r_{p,j_p}^n$$

QED

例



	$k=0$	$k=1$	$k=2$	$k=3$
$r_{1,1}^k$	ϵ	ϵ	$(00)^*$	
$r_{1,2}^k$	0	0	$0(00)^*$	
$r_{1,3}^k$	1	1	0^*1	
$r_{2,1}^k$	0	0	$0(00)^*$	
$r_{2,2}^k$	ϵ	$\epsilon + 00$	$(00)^*$	
$r_{2,3}^k$	1	$1+01$	0^*1	
$r_{3,1}^k$	\emptyset	\emptyset	$(0+1)(00)^*0$	
$r_{3,2}^k$	$0+1$	$0+1$	$(0+1)(00)^*$	
$r_{3,3}^k$	ϵ	ϵ	$\epsilon + (0+1)0^*1$	

$$r_{1,2}^3 = r_{1,3}^2 (r_{3,3}^2)^* r_{3,2}^2 + r_{1,2}^2 = 0^*1(\epsilon + (0+1)0^*1)^*(0+1)(00)^* + 0(00)^*$$

$$= 0^*1((0+1)0^*1)^*(0+1)(00)^* + 0(00)^*$$

$$r_{1,3}^3 = r_{1,3}^2 (r_{3,3}^2)^* r_{3,3}^2 + r_{1,3}^2 = 0^*1(\epsilon + (0+1)0^*1)^*(\epsilon + (0+1)0^*1) + 0^*1$$

$$= 0^*1((0+1)0^*1)^*$$

$$r_{1,2}^3 + r_{1,3}^3 = 0^*1((0+1)0^*1)^*(\epsilon + (0+1)(00)^*) + 0(00)^*$$