

重み付き有限オートマトンに対する 曖昧性解消演算の一般化とその応用

†林 克彦 永田 昌明

NTT CS Lab

†hayashi.katsuhiko@lab.ntt.co.jp



オートマトンの曖昧性

決定化演算の問題



一般化曖昧性解消演算

重み付き木オートマトンへの一般化



実験

自然言語処理タスクへの適用



まとめ

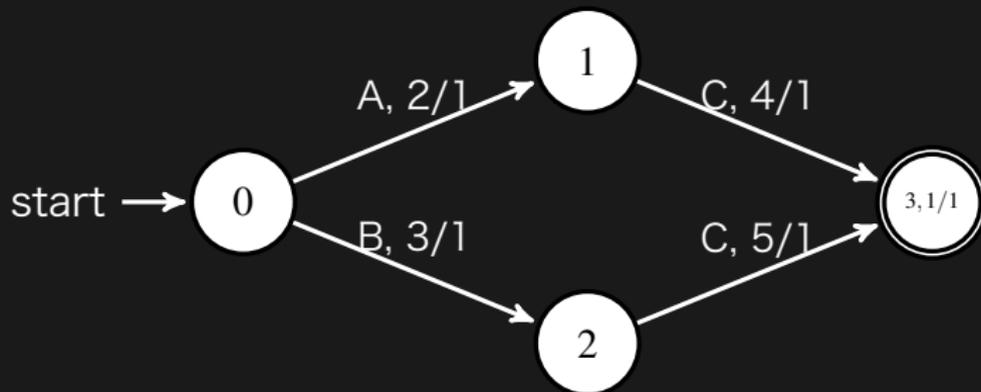
今後の課題



オートマトンの曖昧性

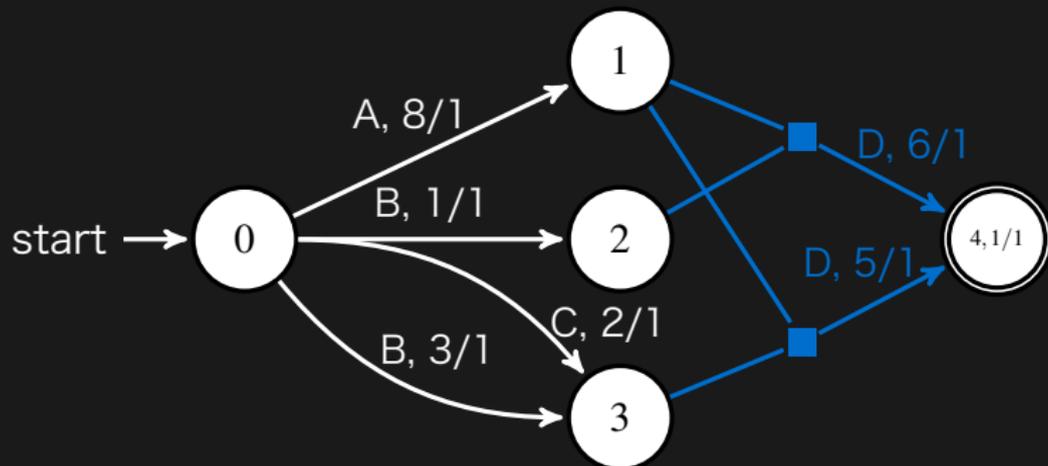
決定化演算の問題

重み付き有限オートマトン



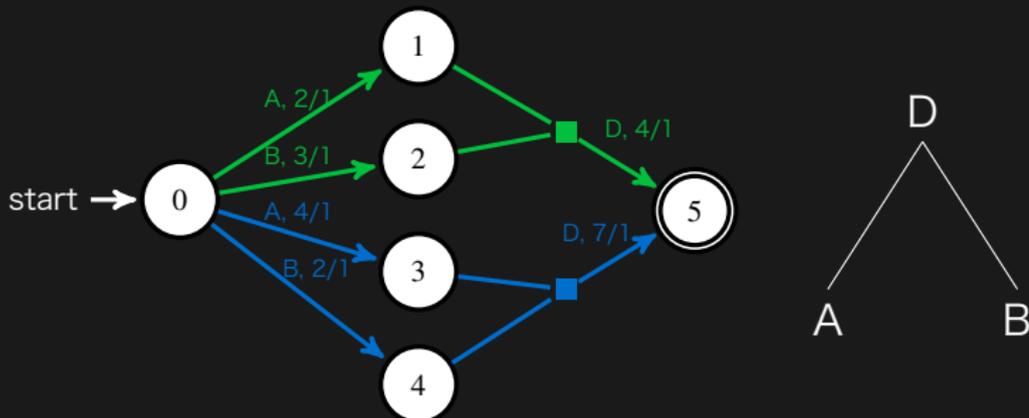
- $A = \{\Sigma, Q, i, F, E, \rho\}$
 - 記号集合 Σ : $\{A, B, C\}$
 - 状態集合 Q : $\{0, 1, 2, 3\}$, 初期状態 i : 0, 終了状態集合 F : $\{3\}$
 - 遷移集合 E : $\{A(0) \xrightarrow{2/1} 1, B(0) \xrightarrow{3/1} 2, C(1) \xrightarrow{4/1} 3, C(2) \xrightarrow{5/1} 3\}$
 - 終了重み関数 ρ : $\{\rho(3) = 1/1\}$
- 言語 $L(A)$: $\{AC, BC\}$

重み付き木オートマトン (Thatcher, 68)



- $A = \{\Sigma, Q, i, F, E, \rho\}$
 - ランク付き記号集合 $\Sigma : \{A^{(1)}, B^{(1)}, C^{(1)}, D^{(2)}\}$
 - 遷移集合 $E : \{A(0) \xrightarrow{8/1} 1, B(0) \xrightarrow{1/1} 2, B(0) \xrightarrow{2/1} 3, C(0) \xrightarrow{3/1} 3, D(1,2) \xrightarrow{6/1} 4, D(1,3) \xrightarrow{5/1} 4\}$
- 木言語 $L(A) : \left\{ \begin{array}{c} D \\ \swarrow \quad \searrow \\ A \quad B \end{array} , \begin{array}{c} D \\ \swarrow \quad \searrow \\ A \quad C \end{array} \right\}$

オートマトンが曖昧性を持つとは？



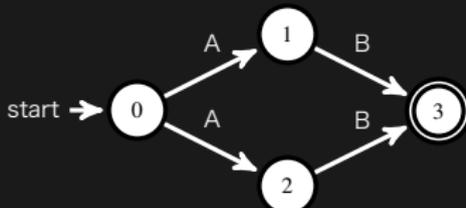
- ・ 同じ木に対応する2つ以上の受理経路が存在
 - ・ ある木に対する重みが複数の受理経路に分割
 - ・ 真の1-bestや K -best解を効率的に求められない (NP困難: Sima'an 96)
 - ・ K -best解に同じ木が存在 (疑似曖昧性の問題)

曖昧性解消の目的と従来のアプローチ

- ・ 曖昧性解消の目的
 - ・ ある木に対する 複数の受理経路を1つに統合
 - ・ その統合した受理経路に 各受理経路の重みを合計

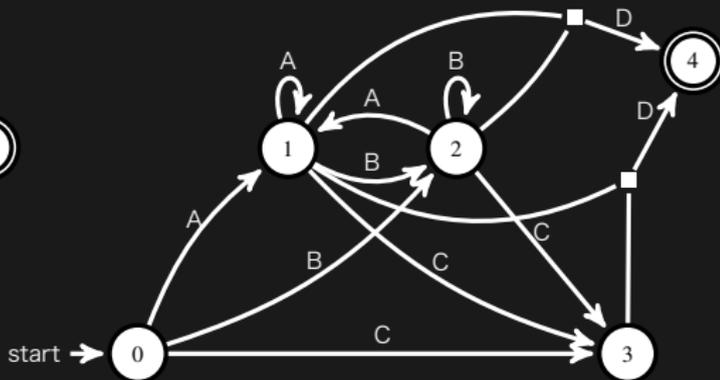
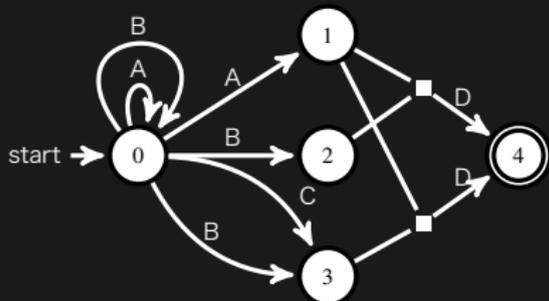
曖昧性解消の目的と従来のアプローチ

- 曖昧性解消の目的
 - ある木に対する **複数の受理経路を1つに統合**
 - その統合した受理経路に **各受理経路の重みを合計**
- 従来のアプローチ: **決定化演算** (Mohri 96, May 06)
 - ある状態(のベクトル)から同じ記号での遷移を許さない等価なオートマトンへ変換 ⇒ 決定性, **無曖昧性**



決定性オートマトンの問題

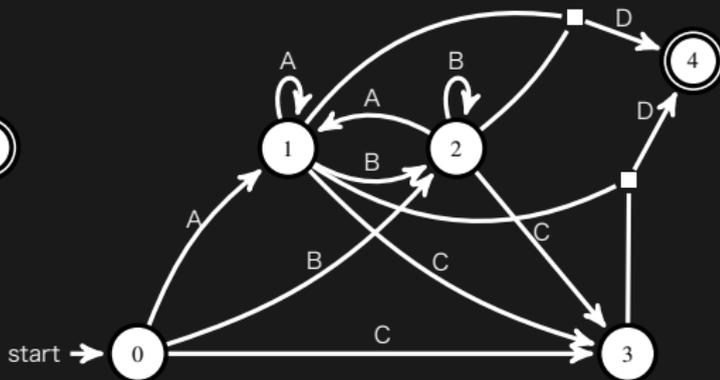
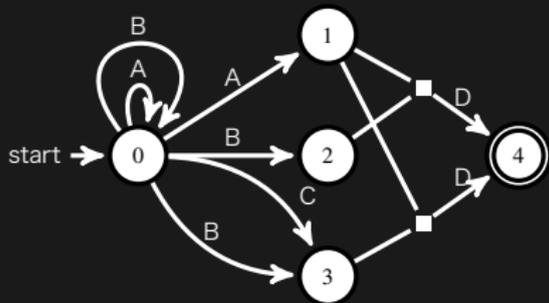
- 重み付き木オートマトンの決定化演算 (閉路無し: May 06, 閉路有り: Büchse 09)



- オートマトンのサイズが増大する
 - 元のオートマトンの状態数 n に対して, 最悪の場合 2^n

決定性オートマトンの問題

- 重み付き木オートマトンの決定化演算 (閉路無し: May 06, 閉路有り: Büchse 09)



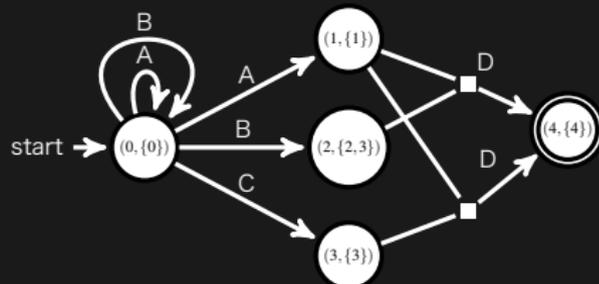
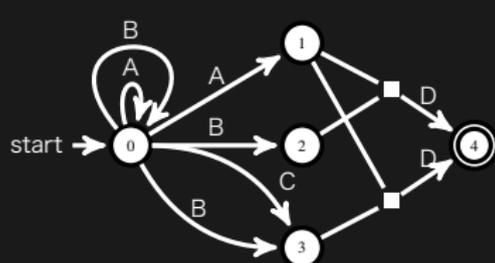
- オートマトンのサイズが増大する
 - 元のオートマトンの状態数 n に対して, 最悪の場合 2^n
- 無曖昧性の木オートマトンを直接構築する演算が必要



一般化曖昧性解消演算

重み付き木オートマトンへの一般化

木オートマトンに対する曖昧性解消演算

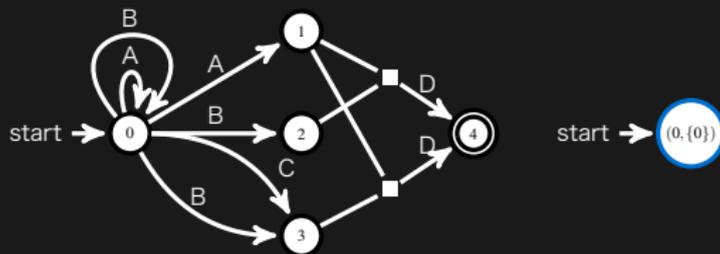


- 曖昧性解消演算の2つのキーポイント
 - 状態間の同値関係 (*key1*)
 - 初期状態から同じ木で到達可能
 - 2つの状態が将来を共有する (*key2*)
 - 同じ木で終了状態へ到達する経路を持つ $\Rightarrow trim(A \cap A)$ でチェック
- 新しい状態 $(p, \underline{s(p,t)})$: $p \in Q, t \in T_\Sigma$

$$\underline{s(p,t)} = \underbrace{\{q \mid q \in \delta(\{i\}, t)\}}_{key1} \wedge \underbrace{(p, q) \in trim(A \cap A)}_{key2}$$

実行例 (1/7)

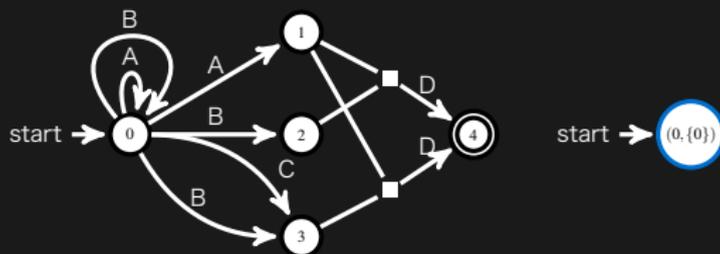
- 初期状態を構築



- 状態 $(0, \underline{\{0\}})$: $\underline{s(0, \varepsilon)} = \{q \mid q \in \delta(\{\}, \varepsilon) \wedge (0, q) \in \text{trim}(A \cap A)\} = \{0\}$

実行例 (1/7)

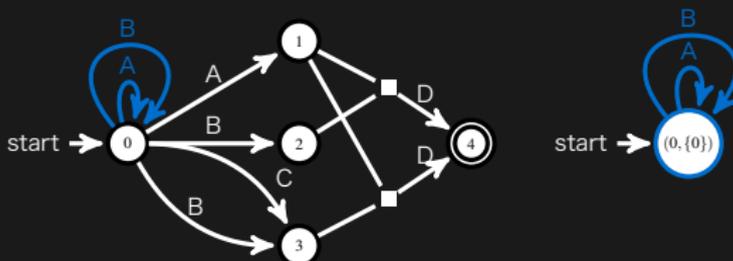
- 初期状態を構築



- 状態 $(0, \{0\})$: $s(0, \varepsilon) = \{q \mid q \in \delta(\{\}, \varepsilon) \wedge (0, q) \in \text{trim}(A \cap A)\} = \{0\}$
 - * 同じ木で到達できる状態同士の同値関係 R を構築 $(0, \{0\})R(0, \{0\})$

実行例 (1/7)

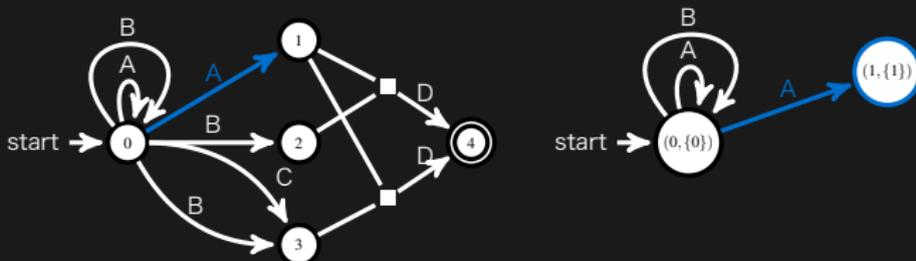
- 遷移 $A(0) \rightarrow 0$, $B(0) \rightarrow 0$ に対する遷移を構築



- 状態 $(0, \{0\})$: $s(0, \varepsilon) = \{q \mid q \in \delta(\{\}, \varepsilon) \wedge (0, q) \in \text{trim}(A \cap A)\} = \{0\}$
 - * 同じ木で到達できる状態同士の同値関係 R を構築 $(0, \{0\})R(0, \{0\})$

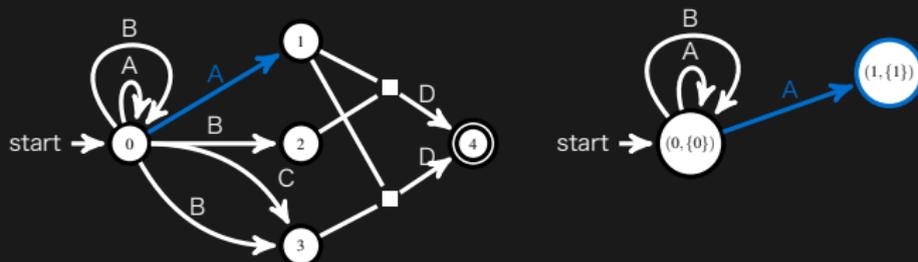
実行例 (2/7)

- 遷移A(0) \rightarrow 1に対する遷移と状態の構築



実行例 (2/7)

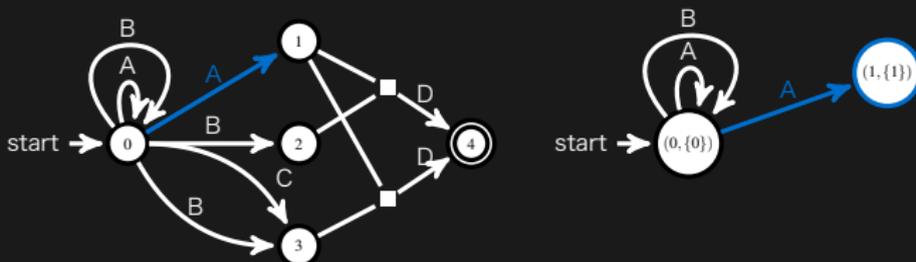
- 遷移A(0) → 1に対する遷移と状態の構築



- 状態 $(1, \{1\})$: $\underline{s(1, A)} = \{q | q \in \delta(\{0\}, A) \wedge (1, q) \in \text{trim}(A \cap A)\} = \{1\}$

実行例 (2/7)

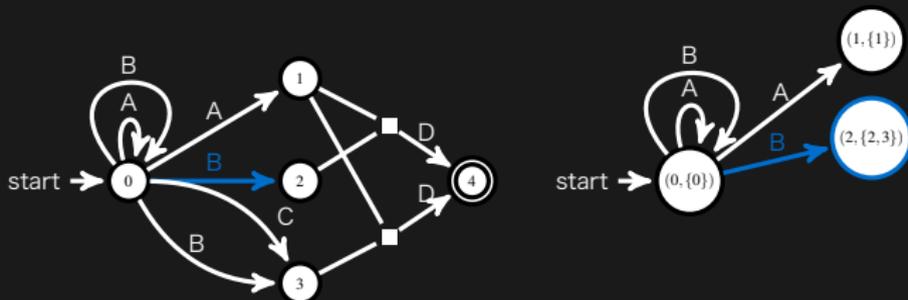
- 遷移A(0) → 1に対する遷移と状態の構築



- 状態 $(1, \{1\})$: $\underline{s(1, A)} = \{q \mid q \in \delta(\{0\}, A) \wedge (1, q) \in \text{trim}(A \cap A)\} = \{1\}$
- 関係: $(0, \{0\})R(0, \{0\}), (1, \{1\})R(1, \{1\})$

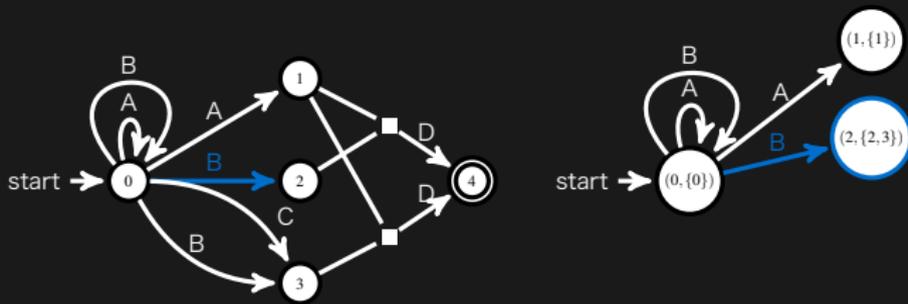
実行例 (3/7)

- 遷移B(0) → 2に対する遷移と状態の構築



実行例 (3/7)

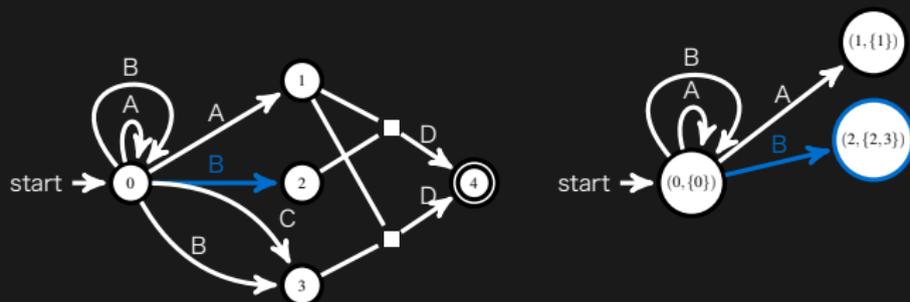
- 遷移B(0) → 2に対する遷移と状態の構築



- 状態 $(2, \{2, 3\})$: $s(2, B) = \{q \mid q \in \delta(\{0\}, B) \wedge (2, q) \in \text{trim}(A \cap A)\} = \{2, 3\}$

実行例 (3/7)

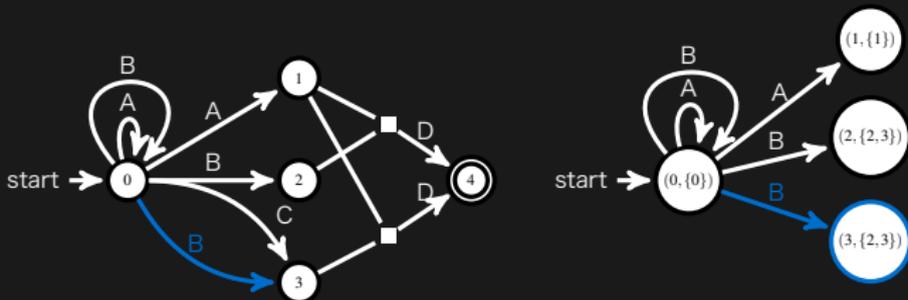
- 遷移B(0) → 2に対する遷移と状態の構築



- 状態 $(2, \{2, 3\})$: $s(2, B) = \{q \mid q \in \delta(\{0\}, B) \wedge (2, q) \in \text{trim}(A \cap A)\} = \{2, 3\}$
- 関係: $(0, \{0\})R(0, \{0\}), (1, \{1\})R(1, \{1\}), (2, \{2, 3\})R(2, \{2, 3\})$

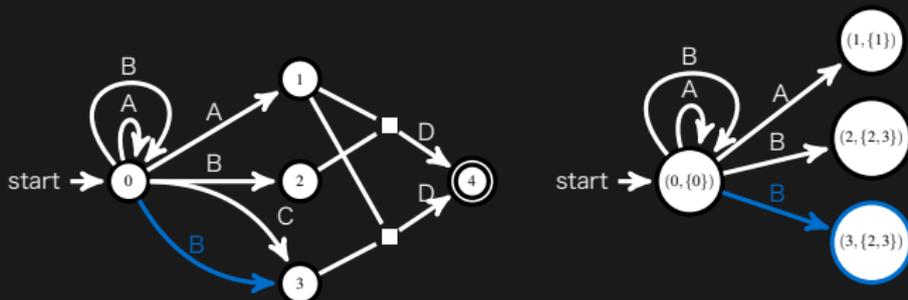
実行例 (4/7)

- 遷移B(0) → 3に対する遷移と状態の構築



実行例 (4/7)

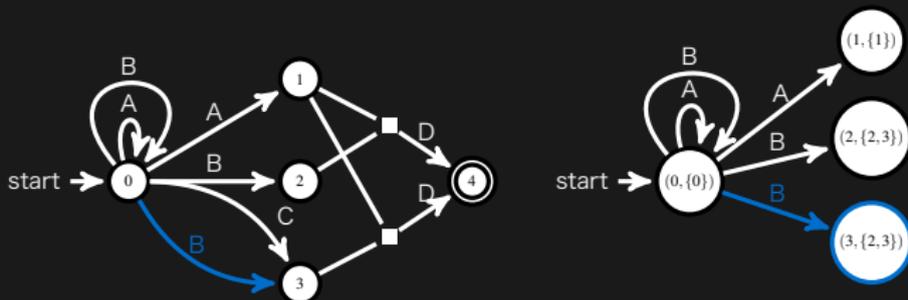
- 遷移B(0) → 3に対する遷移と状態の構築



- 状態(3, {2,3}): $s(3, B) = \{q \mid q \in \delta(\{0\}, B) \wedge (3, q) \in \text{trim}(A \cap A)\} = \{2, 3\}$

実行例 (4/7)

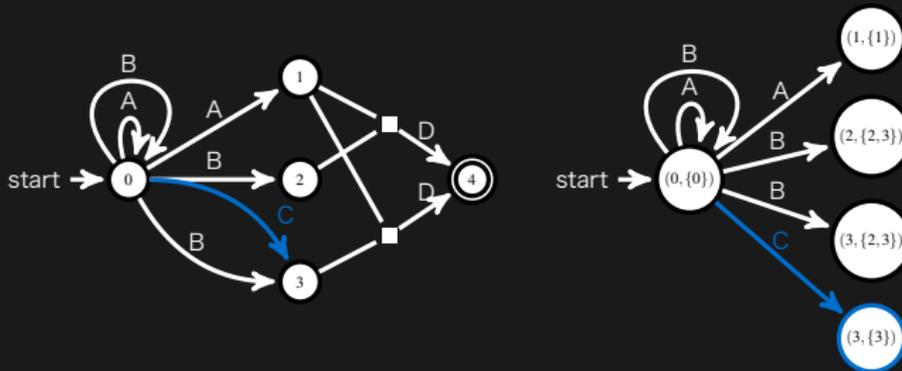
- 遷移B(0) → 3に対する遷移と状態の構築



- 状態(3, {2,3}): $\underline{s(3, B)} = \{q | q \in \delta(\{0\}, B) \wedge (3, q) \in \text{trim}(A \cap A)\} = \{2, 3\}$
- 関係: $(0, \{0\})R(0, \{0\}), (1, \{1\})R(1, \{1\}), (2, \{2,3\})R(2, \{2,3\}),$
 $(3, \{2,3\})R(3, \{2,3\}), (2, \{2,3\})R(3, \{2,3\})$

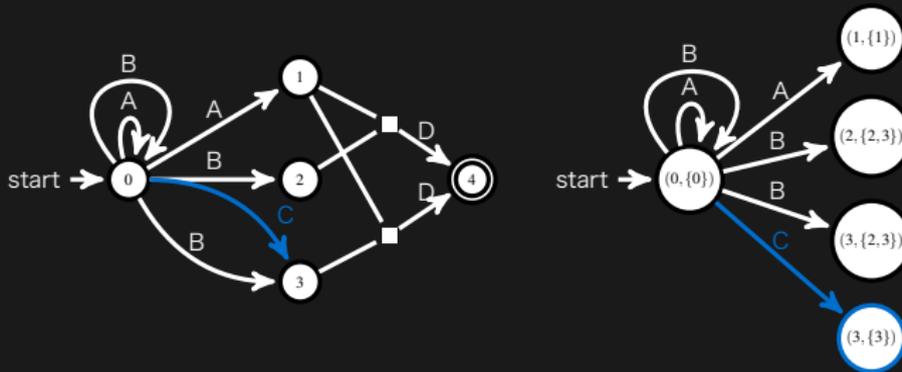
実行例 (5/7)

- 遷移C(0) → 3に対する遷移と状態の構築



実行例 (5/7)

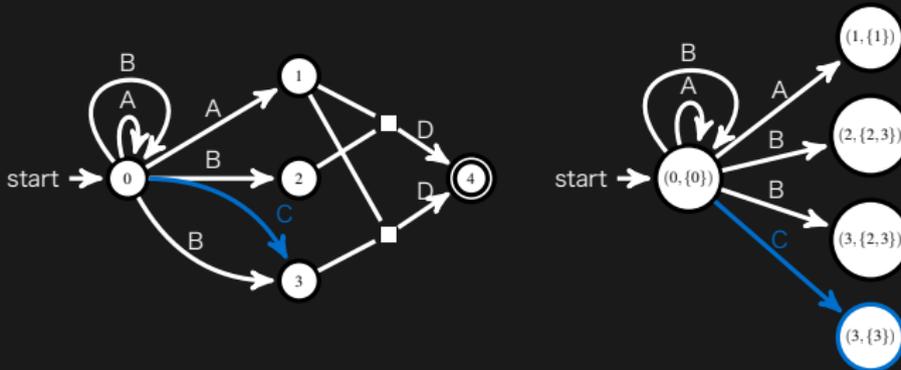
- 遷移C(0) → 3に対する遷移と状態の構築



- 状態(3, {3}): $\underline{s(3, C)} = \{q \mid q \in \delta(\{0\}, C) \wedge (3, q) \in trim(A \cap A)\} = \{3\}$

実行例 (5/7)

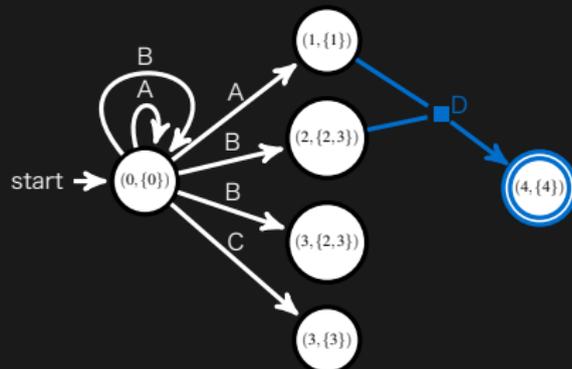
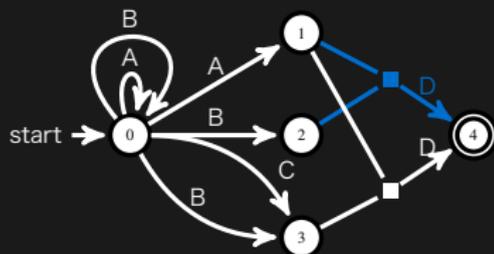
- 遷移C(0) → 3に対する遷移と状態の構築



- 状態(3, {3}): $\underline{s(3, C)} = \{q \mid q \in \delta(\{0\}, C) \wedge (3, q) \in trim(A \cap A)\} = \{3\}$
- 関係: $(0, \{0\})R(0, \{0\}), (1, \{1\})R(1, \{1\}), (2, \{2, 3\})R(2, \{2, 3\}), (3, \{2, 3\})R(3, \{2, 3\}), (2, \{2, 3\})R(3, \{2, 3\}), (3, \{3\})R(3, \{3\})$

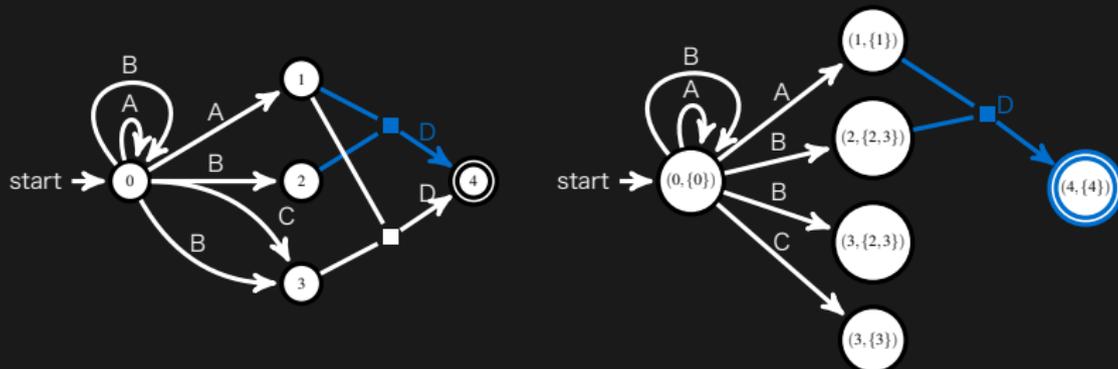
実行例 (6/7)

- 遷移D(1,2) → 4に対する遷移と状態の構築



実行例 (6/7)

- 遷移D(1,2) → 4に対する遷移と状態の構築

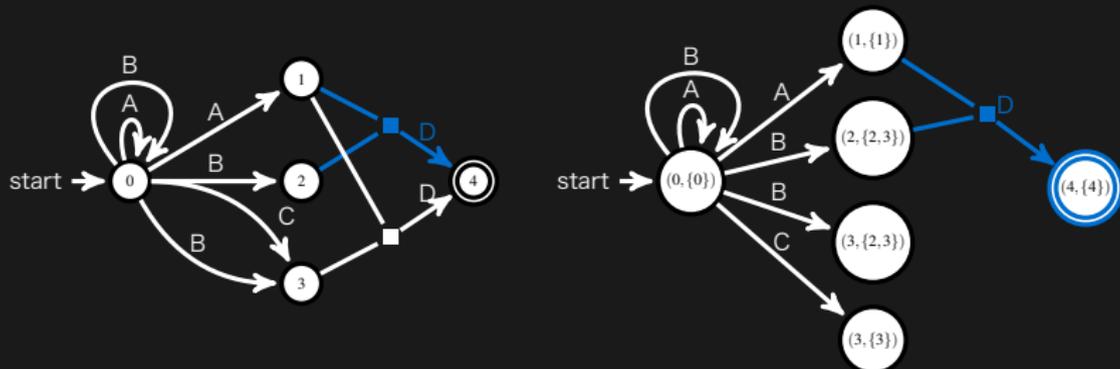


- 状態(4, {4}):

$$\underline{s(4, D(A \ B))} = \{q \mid q \in \delta(\{\{1,2\}, \{1,3\}\}, D) \wedge (4, q) \in \text{trim}(A \cap A)\} = \{4\}$$

実行例 (6/7)

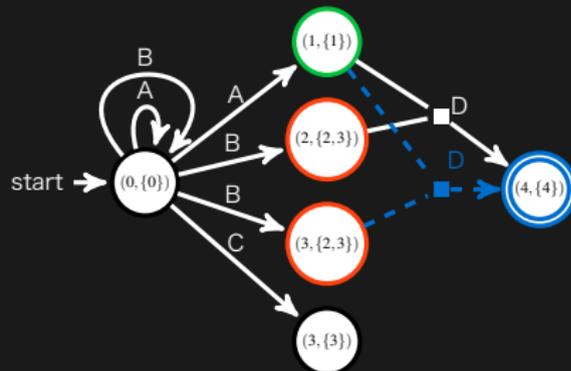
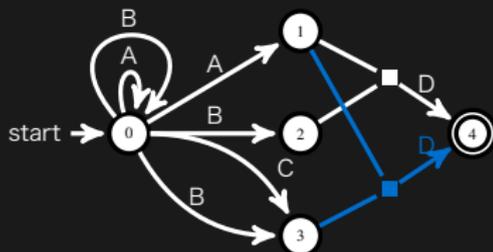
- 遷移D(1,2) → 4に対する遷移と状態の構築



- 状態 $(4, \{4\})$:
 $s(4, \overline{D(A\ B)}) = \{q \mid q \in \delta(\{\{1,2\}, \{1,3\}\}, D) \wedge (4, q) \in \text{trim}(A \cap A)\} = \{4\}$
- 関係: $(0, \{0\})R(0, \{0\}), (1, \{1\})R(1, \{1\}), (2, \{2,3\})R(2, \{2,3\}),$
 $(3, \{2,3\})R(3, \{2,3\}), (2, \{2,3\})R(3, \{2,3\}), (3, \{3\})R(3, \{3\}),$
 $(4, \{4\})R(4, \{4\})$

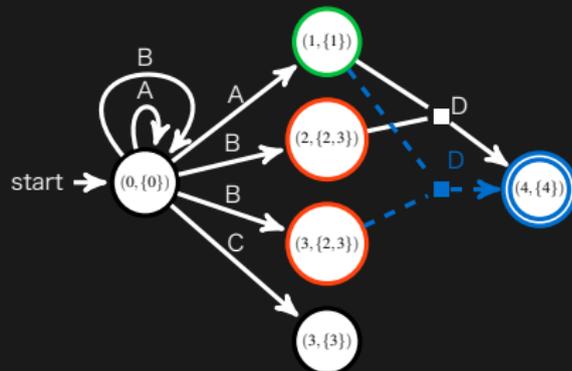
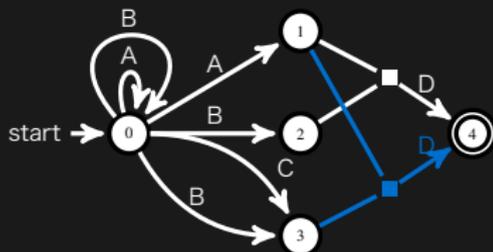
実行例 (7/7)

- 遷移 $D(1,3) \rightarrow 4$ に対する遷移と状態の構築



実行例 (7/7)

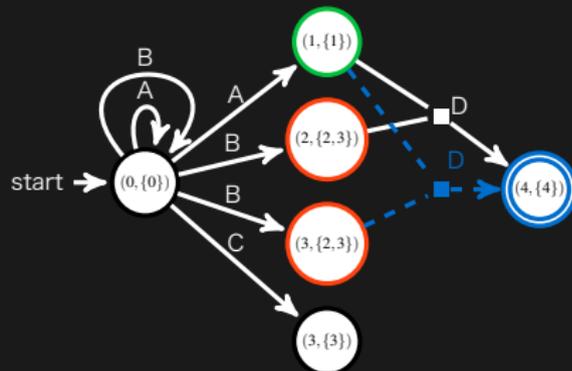
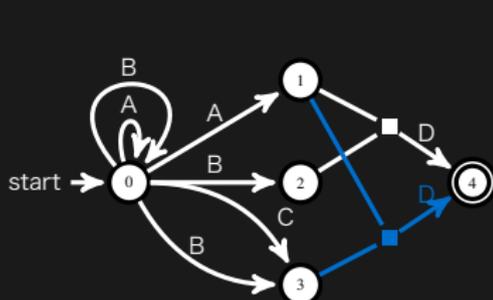
- 遷移 $D(1,3) \rightarrow 4$ に対する遷移と状態の構築



- 状態 $(4, \{4\})$:
 $\underline{s(4, D(A \overline{B}))} = \{q \mid q \in \delta(\{\{1,2\}, \{1,3\}\}, D) \wedge (4, q) \in \text{trim}(A \cap A)\} = \{4\}$

実行例 (7/7)

- 遷移D(1,3) → 4に対する遷移と状態の構築

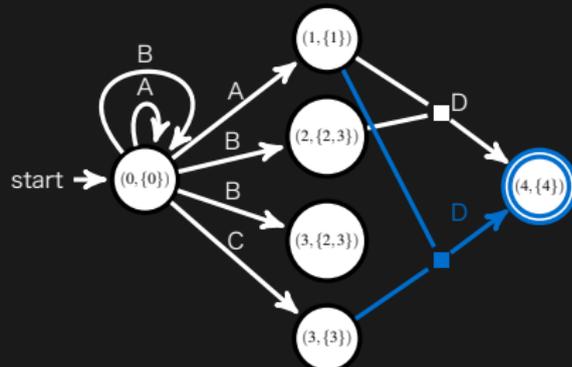
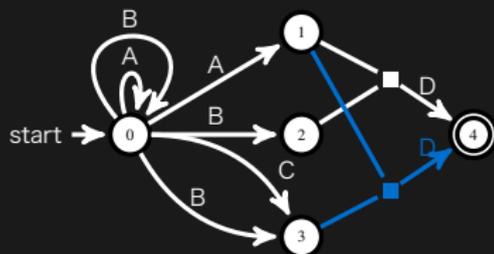


- 状態(4, {4}):

$$s(4, D(\overline{A \ B})) = \{q \mid q \in \delta(\{\{1,2\}, \{1,3\}\}, D) \wedge (4, q) \in trim(A \cap A)\} = \{4\}$$
- 関係(1, {1})R(1, {1}), (2, {2,3})R(3, {2,3})を持つ状態から(4, {4})への遷移はすでに存在するので、この遷移は構築されない

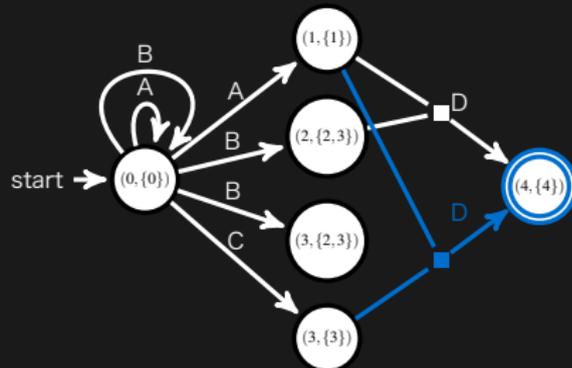
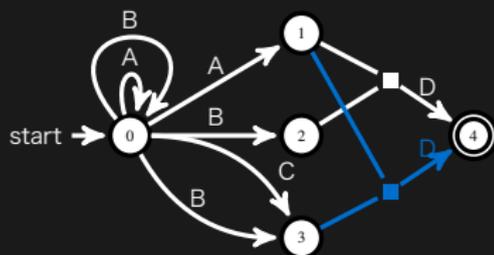
実行例 (7/7)

- 遷移 $D(1,3) \rightarrow 4$ に対する遷移と状態の構築



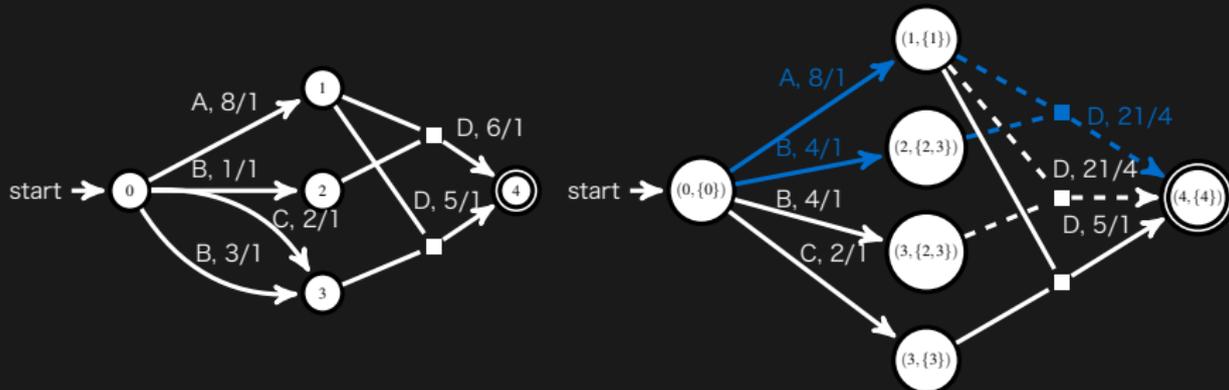
実行例 (7/7)

- 遷移 $D(1,3) \rightarrow 4$ に対する遷移と状態の構築



- 状態 $(4, \{4\})$:
 $s(4, \overline{D(A\ C)}) = \{q \mid q \in \delta(\{\{1,2\}, \{1,3\}\}, D) \wedge (4, q) \in \text{trim}(A \cap A)\} = \{4\}$

重み付きの場合の結果



♪ 同じ木に対応する全受理経路の重みの合計

例えば、 $w\left(\begin{array}{c} D \\ \swarrow \quad \searrow \\ A \quad B \end{array}\right) = 48 + 120 = 168$

提案法のいくつかの重要な性質

- ・ 一般化曖昧性解消演算の正当性
 - ・ 木オートマトン A に対する曖昧性解消演算の結果を A' とする.
そのとき, A' は無曖昧で, かつ, $L(A) = L(A')$ である.

提案法のいくつかの重要な性質

- 一般化曖昧性解消演算の正当性

- 木オートマトン A に対する曖昧性解消演算の結果を A' とする。
そのとき、 A' は無曖昧で、かつ、 $L(A) = L(A')$ である。

- 重み計算の正当性

- A によって受理可能な木 t に対して、その経路の集合を $Run(\{i\}, t, F)$ と書く。
また、 A' で木に対する受理経路を p' とするとき、

$$w(p') = \sum_{p \in Run(\{i\}, t, F)} w(p).$$

提案法のいくつかの重要な性質

- 一般化曖昧性解消演算の正当性

- 木オートマトン A に対する曖昧性解消演算の結果を A' とする。そのとき、 A' は無曖昧で、かつ、 $L(A) = L(A')$ である。

- 重み計算の正当性

- A によって受理可能な木 t に対して、その経路の集合を $Run(\{i\}, t, F)$ と書く。また、 A' で木に対する受理経路を p' とするとき、

$$w(p') = \sum_{p \in Run(\{i\}, t, F)} w(p).$$

- 適用十分条件 (閉路を含む場合)

- トロピカル半環 $(R_+^{+\infty}, \min, +, +\infty, 0)$ 上で定義された A が弱双子定理 (weak twins property) を満たすとき、演算は適用可能
 - 決定化は双子定理 (twins property) を満たすときに適用可能 (Büchse 09) \Rightarrow 決定化より適用範囲が広い



実験

自然言語処理タスクへの適用

実験設定

- ・ 自然言語処理の文圧縮 (Cohn 09)と機械翻訳 (Graehl 08)
 - ・ 拡張型木トランスデューサ (Graehl 08)でモデル化
 - ・ 入力された文の木構造を別の木構造へと変換
 - ・ **出力空間は重み付き木オートマトン** で表現
 - ・ 出力空間を決定化, 無曖昧化したときのオートマトンのサイズ ($|A| = |Q| + |E|$)を比較

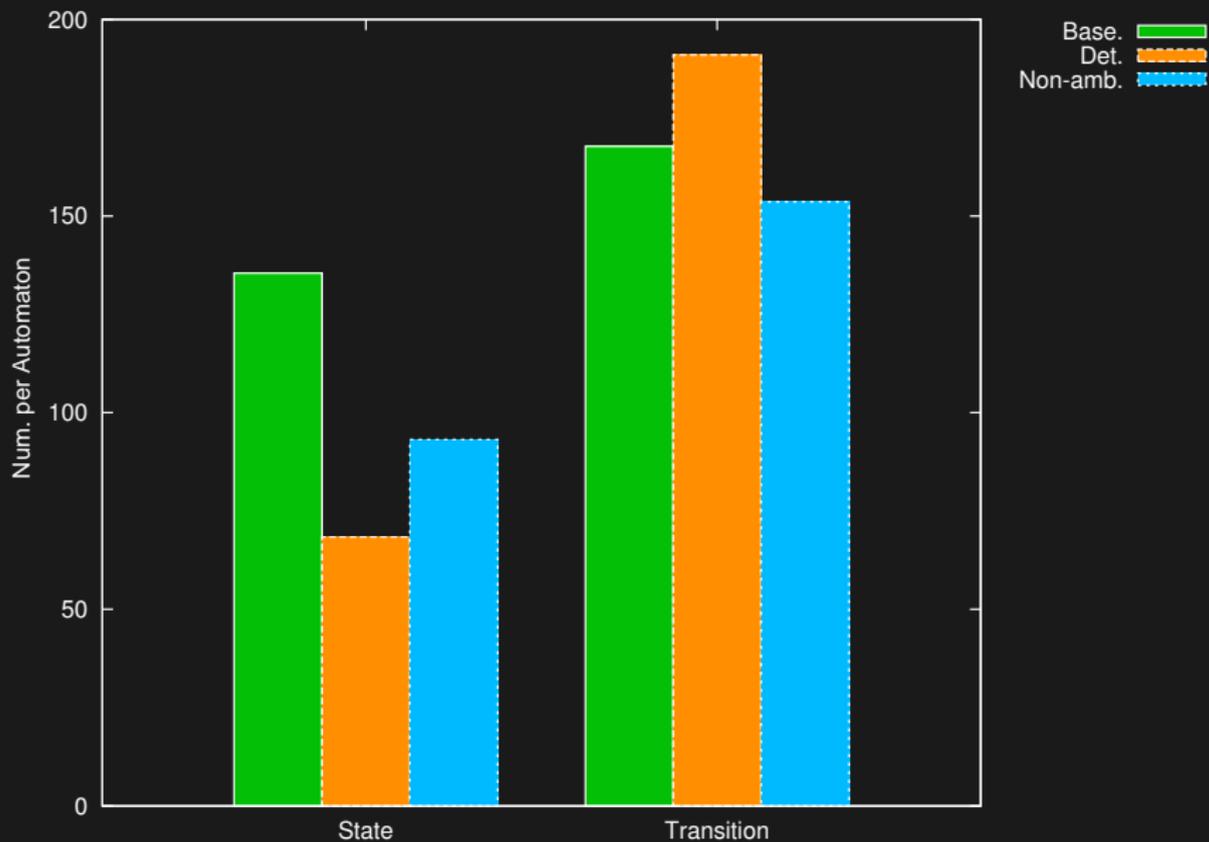
実験設定

- ・ 自然言語処理の文圧縮 (Cohn 09)と機械翻訳 (Graehl 08)
 - ・ 拡張型木トランスデューサ (Graehl 08)でモデル化
 - ・ 入力された文の木構造を別の木構造へと変換
 - ・ **出力空間は重み付き木オートマトン** で表現
 - ・ 出力空間を決定化, 無曖昧化したときのオートマトンのサイズ ($|A| = |Q| + |E|$)を比較
- ・ 実験データ, ツール

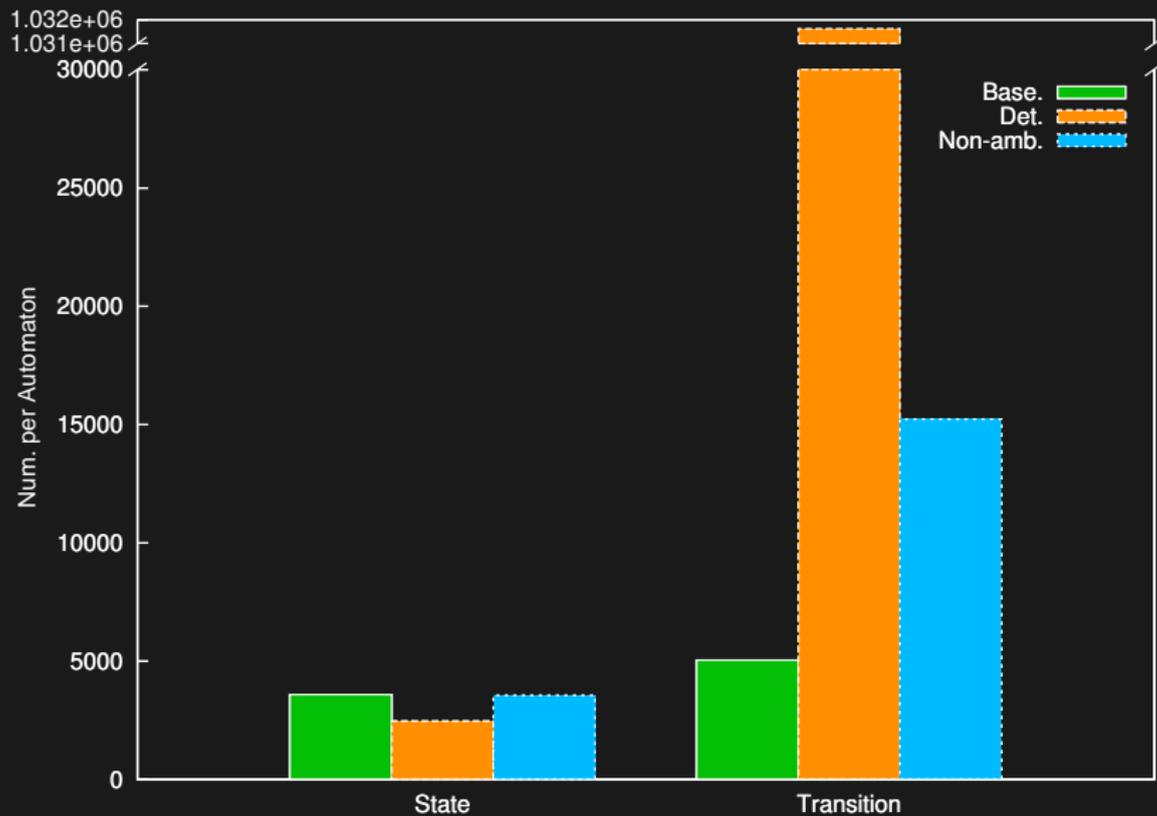
		文圧縮 (Cohn 08)	機械翻訳 (Goto 13)
データ	訓練サイズ	480文対	5,000文対
	テストサイズ	††480文対	278文対
ツール	木トランスデューサ	Tiburon	Tiburon
	規則抽出	T3	T3
	構文解析器	内製システム	内製システム
	単語アライメント	GIZA++	GIZA++

††データ量が少ないため, 訓練データと同じデータを使用


実験結果: 文圧縮タスク



実験結果: 機械翻訳タスク

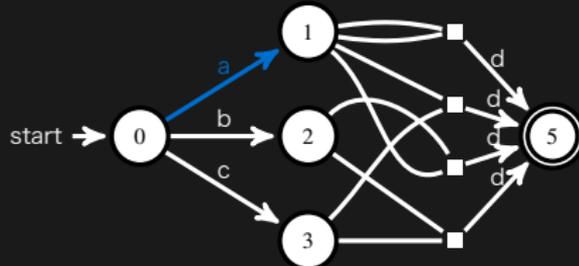
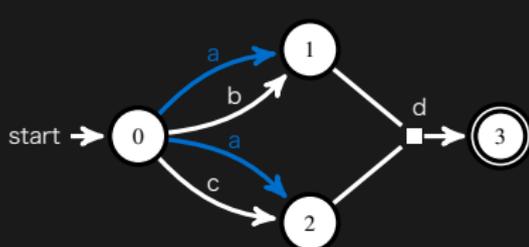


実験結果: 機械翻訳タスク



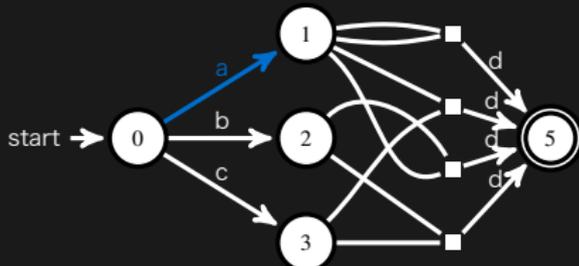
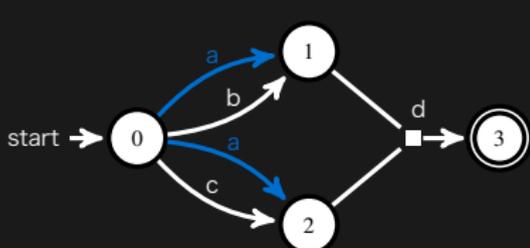
実験結果の分析

- なぜ、機械翻訳タスクで決定化の結果は遷移数が増大したか？

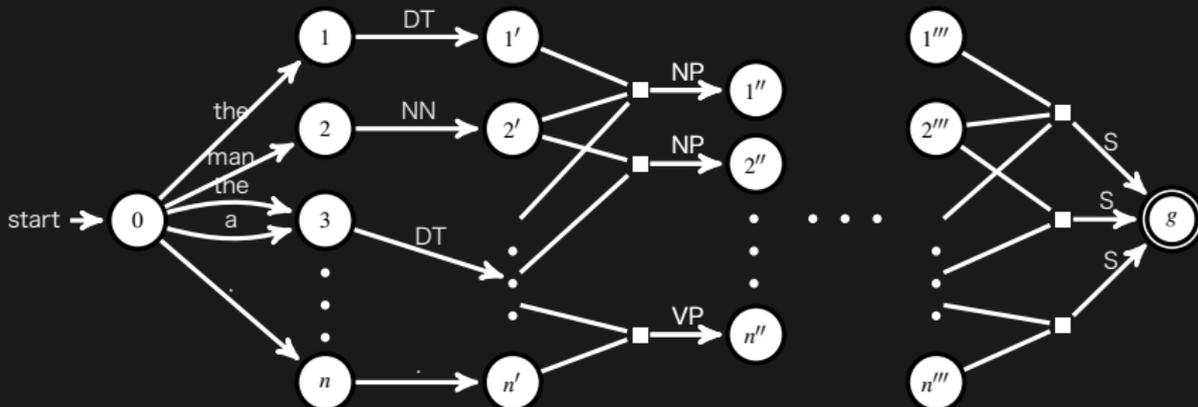


実験結果の分析

- なぜ、機械翻訳タスクで決定化の結果は遷移数が増大したか？

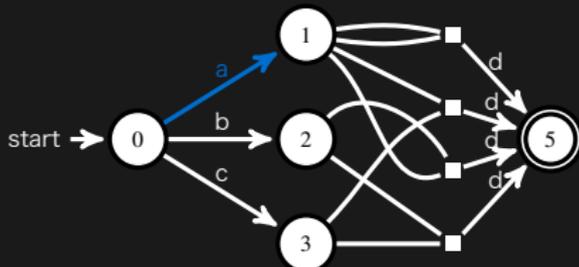
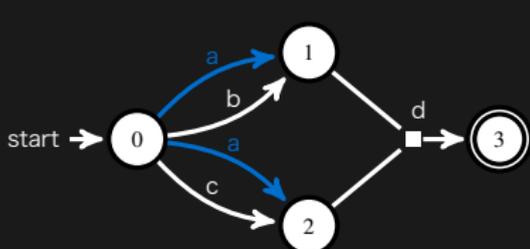


- 機械翻訳は語彙が多様かつ膨大

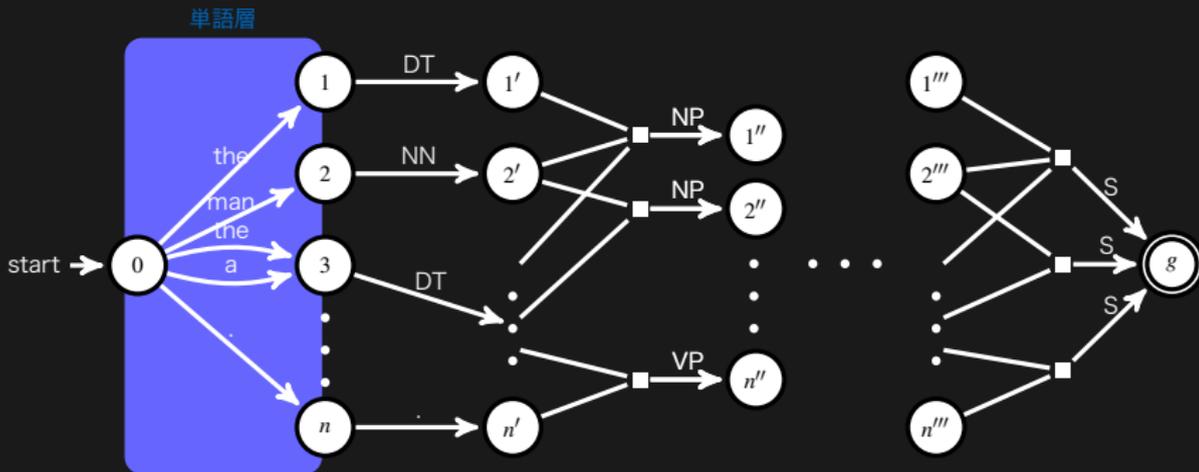


実験結果の分析

- なぜ、機械翻訳タスクで決定化の結果は遷移数が増大したか？

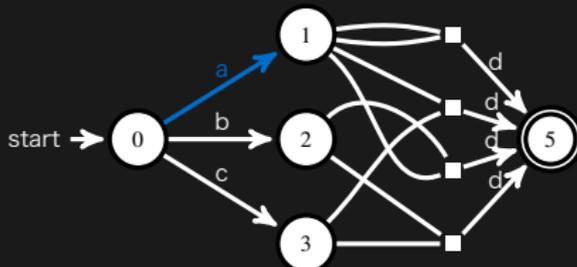
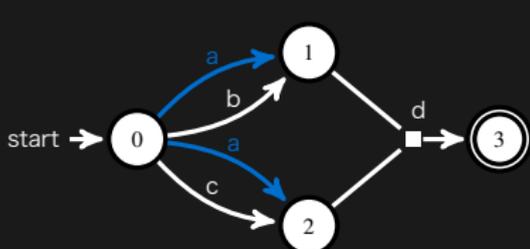


- 機械翻訳は語彙が多様かつ膨大

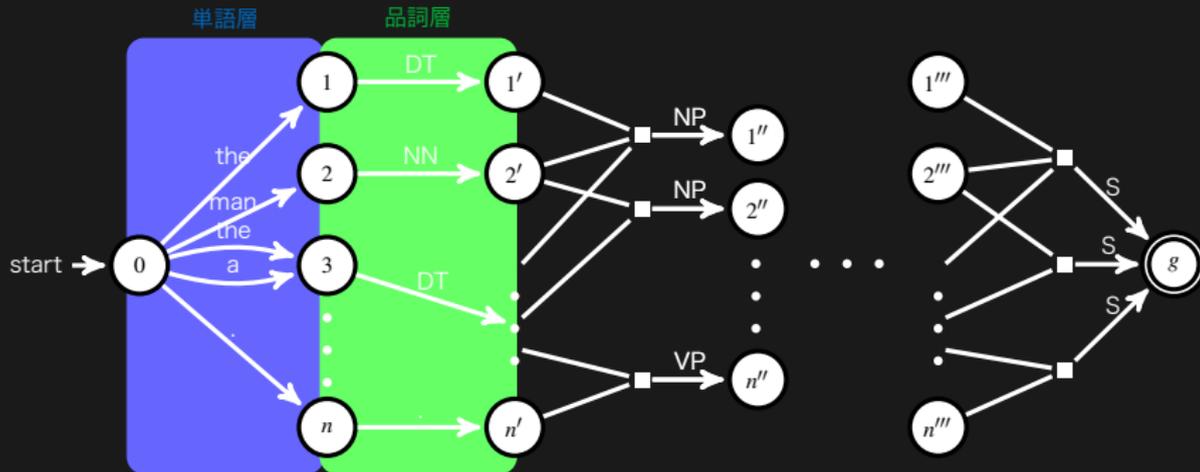


実験結果の分析

- なぜ、機械翻訳タスクで決定化の結果は遷移数が増大したか？

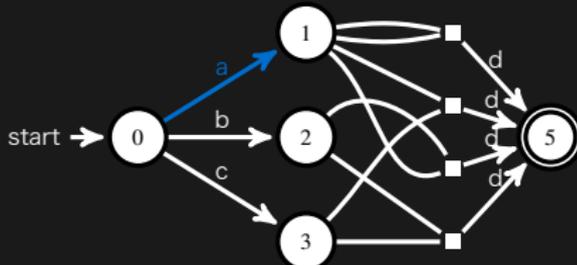
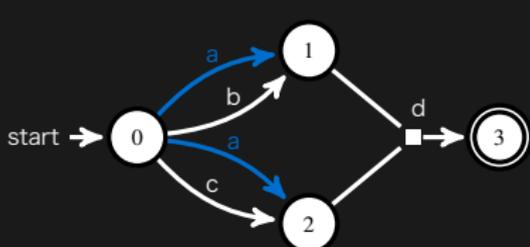


- 機械翻訳は語彙が多様かつ膨大

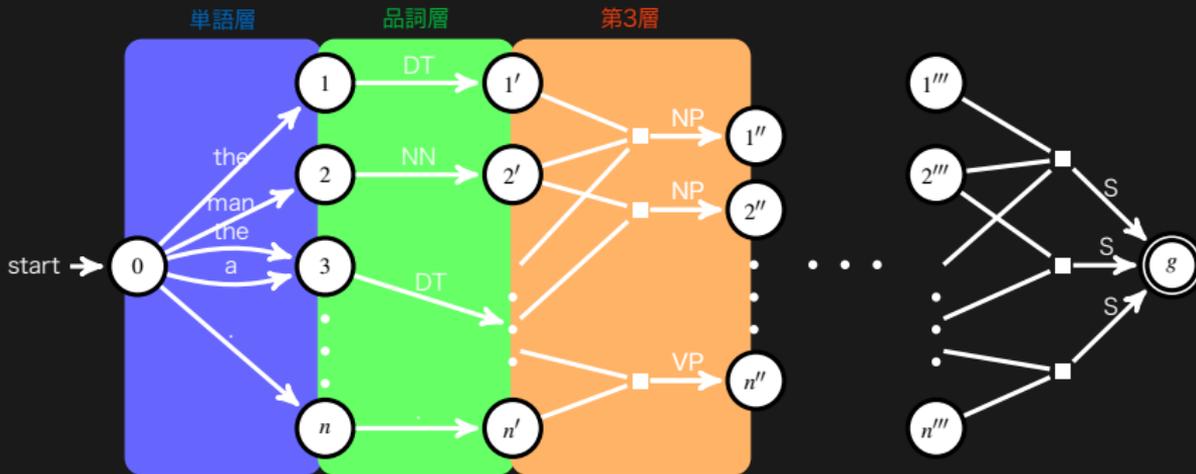


実験結果の分析

- なぜ、機械翻訳タスクで決定化の結果は遷移数が増大したか？

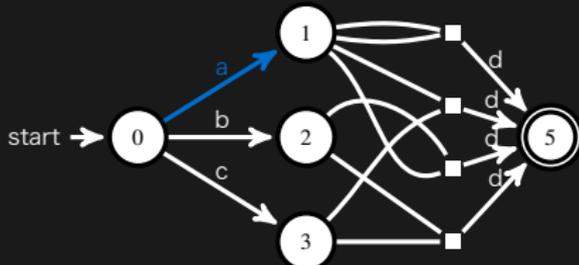
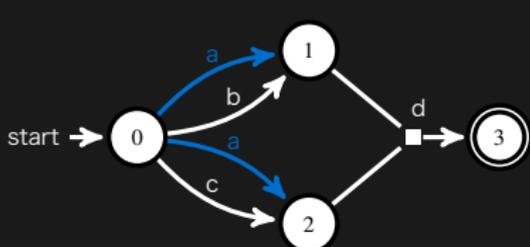


- 機械翻訳は語彙が多様かつ膨大

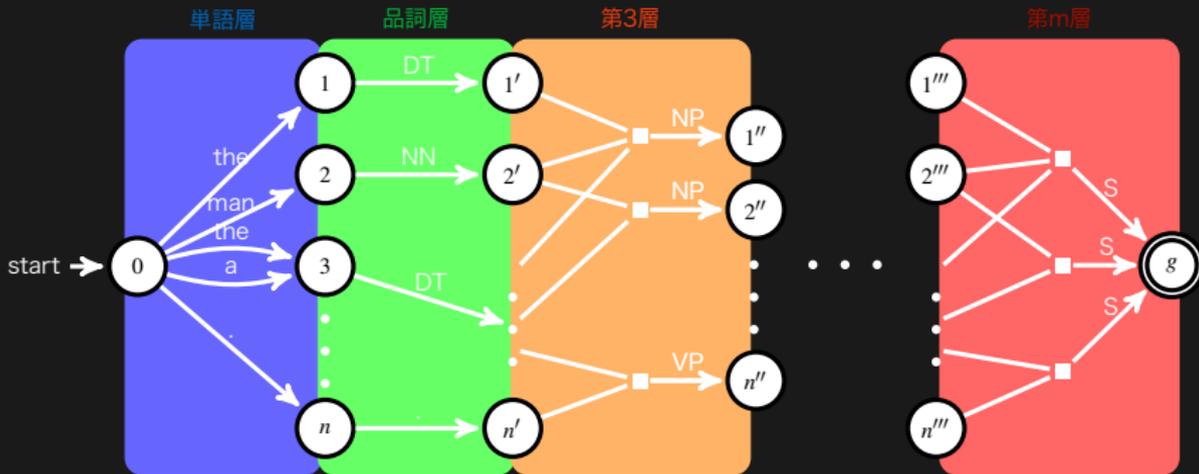


実験結果の分析

- なぜ、機械翻訳タスクで決定化の結果は遷移数が増大したか？



- 機械翻訳は語彙が多様かつ膨大



- 単語層, 品詞層, 第3層の遷移数

	単語層	品詞層	第3層

- 単語層, 品詞層, 第3層の遷移数

	単語層	品詞層	第3層
ベース	1,547	1,621	1,531

・ 単語層, 品詞層, 第3層の遷移数

	単語層	品詞層	第3層
ベース	1,547	1,621	1,531
決定化	462	497	593,222

・ 単語層, 品詞層, 第3層の遷移数

	単語層	品詞層	第3層
ベース	1,547	1,621	1,531
決定化	462	497	593,222
無曖昧化	1,476	1,534	10,020



まとめ

今後の課題

まとめと今後の課題

- ・ まとめ

- ・ 重み付き木オートマトンのための曖昧性解消演算を提案
- ・ アルゴリズムの正当性, 重み計算の正当性, 閉路を含む場合の適用十分条件などを証明
- ・ 決定化に比べ, **記憶容量の点で大きな利点**がある

- ・ 今後の課題

- ・ より詳細な実験結果の分析
- ・ より大規模なデータを使った実験
- ・ DAGオートマトン (Kamimura 81,82)に対する更なる一般化