Zusammenfassung zur Vorlesung Basismodul Computerlinguistik

Approximatives Matching & Levenshtein-Automaten

23.12.2021

Inhalte für heute

1. Levenshtein-Automaten
   - Approximatives Matching
   - Levenshtein-Abstand
   - Nicht-deterministische Levenshtein-Automaten

2. Aufgabenstellung des Abschlussprojekts

Motivation zu Approximativem Matching

Lookup → Approximatives Matching

- Anhand eines **Lexikonautomaten** wird das genaue Suchen durchgeführt. Es ist zu ermitteln, ob ein gegebenes Wort in der Sprache des Automaten existiert.
- In der Praxis wird jedoch Approximatives Matching häufiger angefordert.
- Für ein nicht im Lexikon existierendes Wort sollen möglichst **passende Korrekturkandidaten** gefunden werden.
  → nach **Levenshtein-Abstand**

Anwendungsbereiche des Approximativen Matchings

- Rechtschreibkorrektur bei Texteditoren
- Korrektur von Suchanfragen, Vorschlagssuche
- Ermittlung von Korrekturkandidaten für fehlerhaft digitalisierte Wörter (OCR)

Algorithmische Aufgabenstellung

Gegeben ein **Pattern** P, ein **Lexikon** D und ein kleiner **Grenzwert** k, soll auf effiziente Weise die Menge aller **Einträge** W in D ermittelt werden, sodass der Levenshtein-Abstand zwischen P und W nicht größer als k ist.

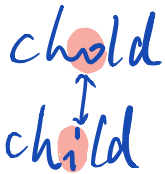

$d(\text{chold}, \text{child}) = 1 \leq 1$ ✓

Levenshtein-Abstand

Definition:
Der (Standard-)**Levenshtein-Abstand** zwischen zwei Wörtern P und W, geschrieben $d_L(P, W)$, ist die minimale Anzahl primitiver Editieroperationen die notwendig sind, um P in W umzuwandeln.

- Ersetzungen
- Löschungen
- Einfügungen

Berechnung mittels **dynamischer Programmierung**

- $d_L(\epsilon, W) = |W|$
- $d_L(P, \epsilon) = |P|$
- $d_L(Pa, Wb) =$

$$\begin{cases} d_L(P, W) & \text{falls } a = b \\ 1 + min(d_L(P, W), d_L(Pa, W), d_L(P, Wb)) & \text{falls } a \neq b \end{cases}$$

Nicht-deterministische Levenshtein-Automaten

Grundidee

Für jedes **Pattern** P wird ein nicht-deterministischer **Stockwerksautomat** $A_n(P)$ aufgebaut, der als Sprache alle Wörter W mit Levenshtein-Abstand $d_L(P, W) \leq n$ hat.

Z.B. Stockwerkautomat $A_2(chold)$ für das Pattern *chold* und maximalen Editierabstand 2

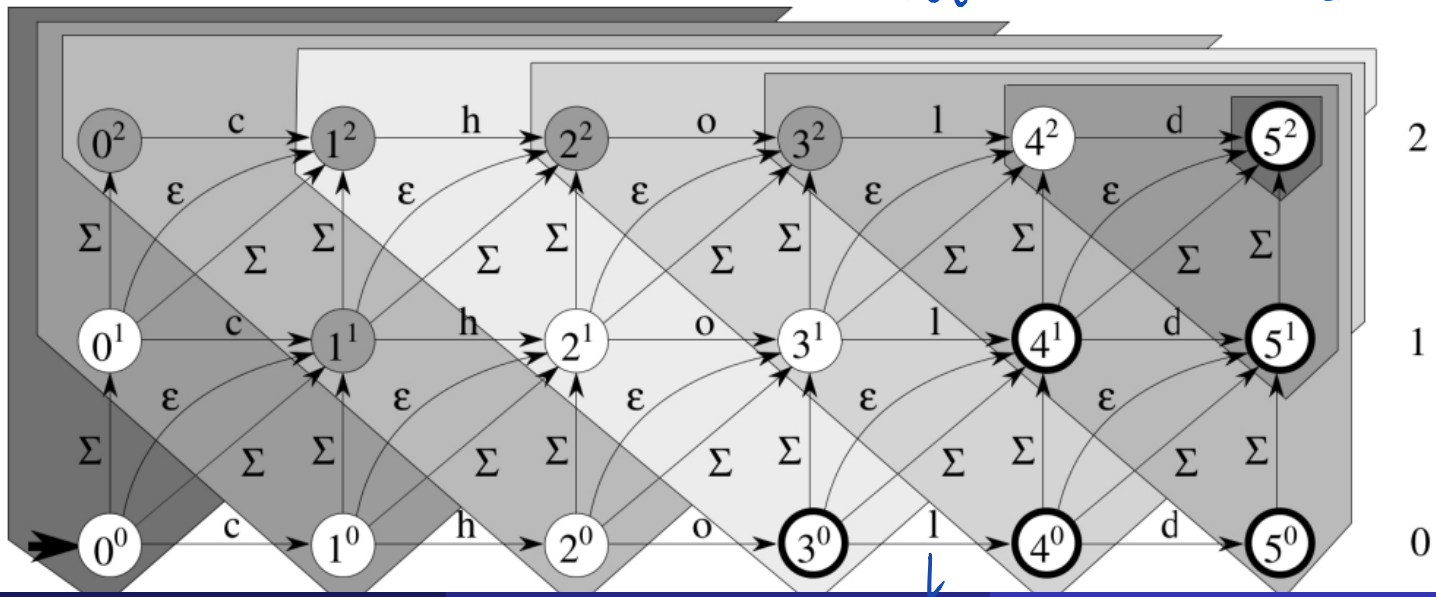

Dreieckbereich

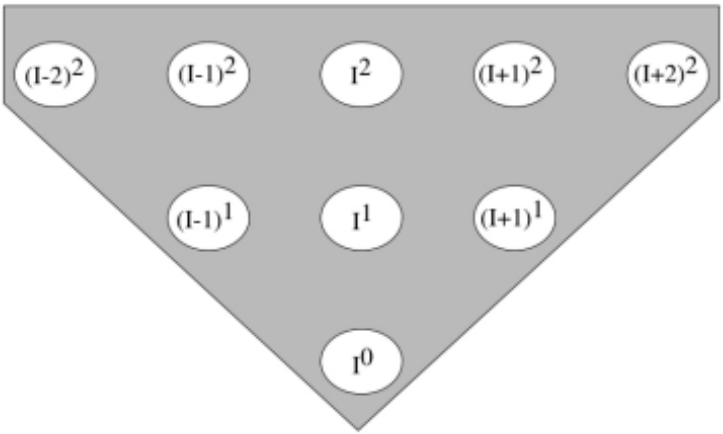

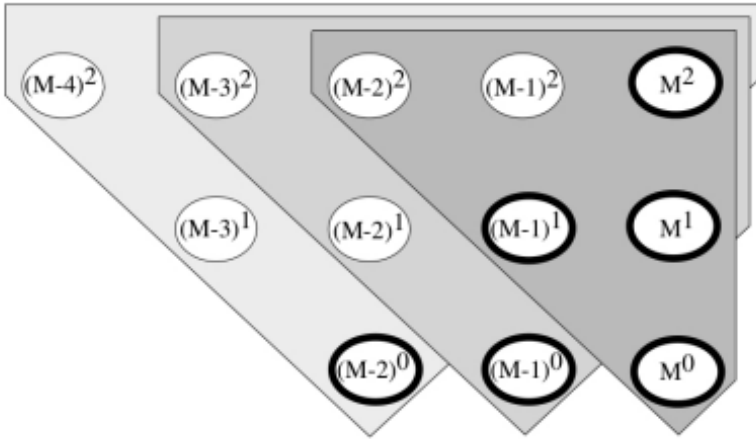

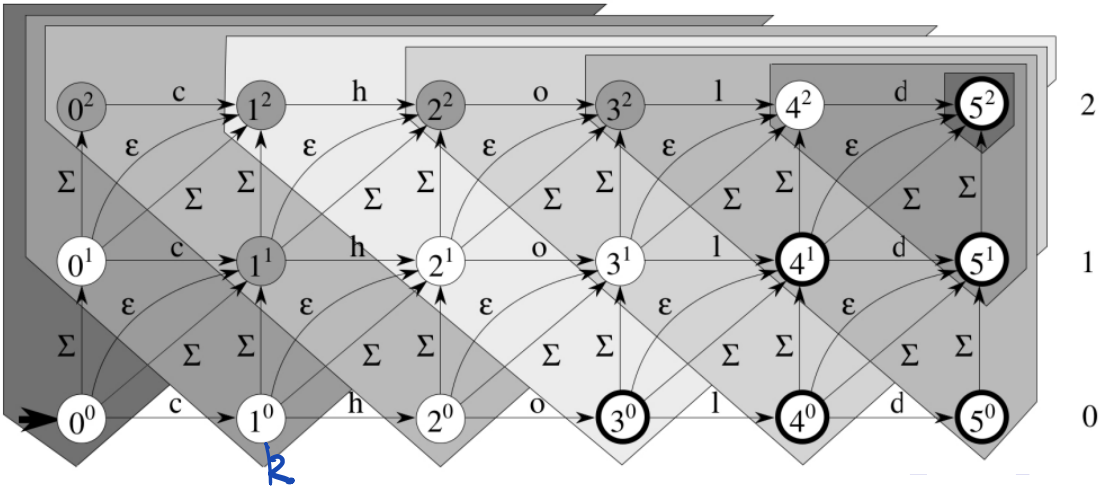

Vorgehensweise bei Übergängen

1. Aktualisieren der aktiven Zustände
2. Eliminieren aller überflüssigen Zustände

$\longrightarrow$ **bis:**

- Eingabewort komplett eingelesen wird **oder**
- es keinen passenden Übergang mehr gibt

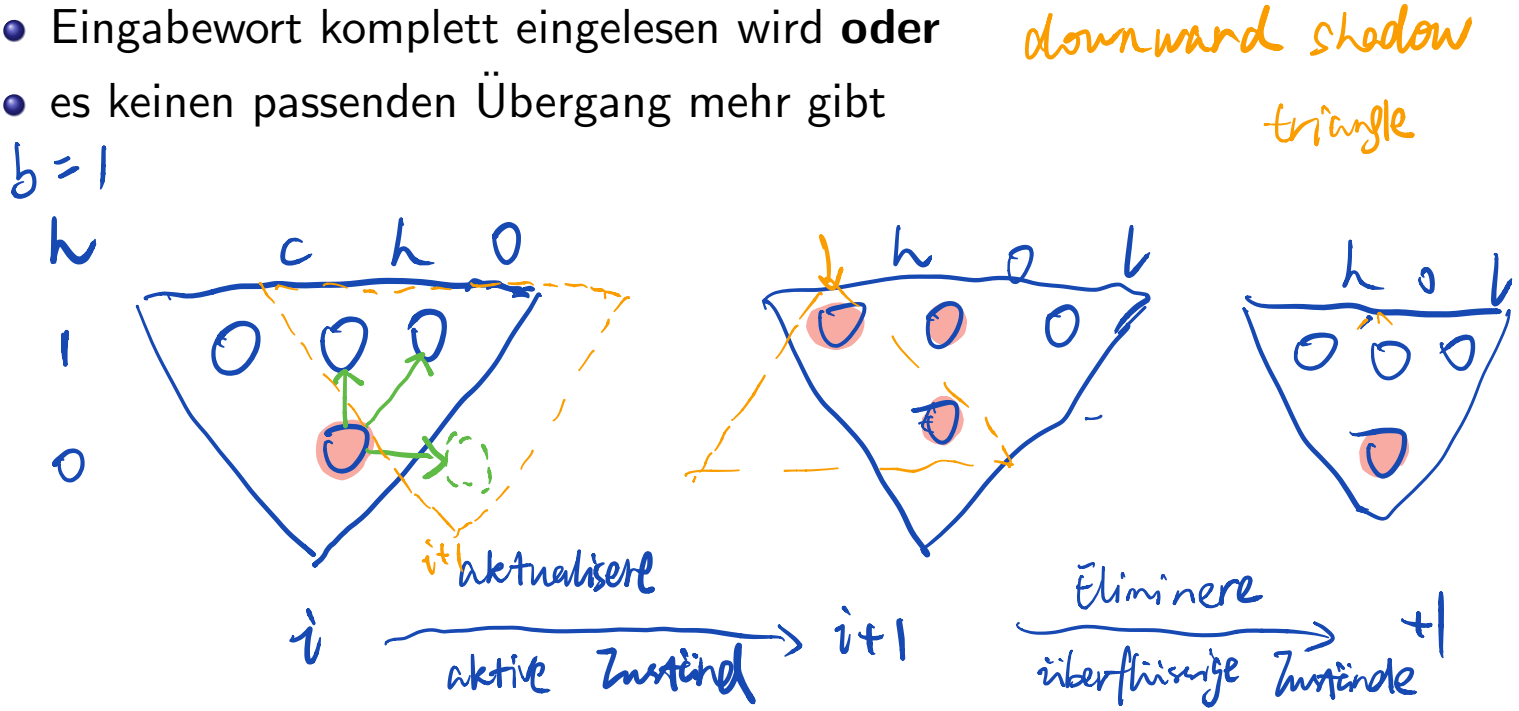

Charakteristischer Vektor

Definition

Der charakteritischer Vektor $\vec{\chi}(w, V)$ für ein Symbol $w \in \Sigma$ in einem Wort $V = v_1 \cdots v_n \in \Sigma^*$ ist der **Bitvektor** der Länge n, bei dem das i-te Bit auf 1 gesetzt ist, genau dann wenn $w = v_i$, sonst auf 0.

- Um die Länge der charakteristischen Vektoren zu standadisieren, wird an den Beginn des Patterns P eine Folge von n speziellen Symbolen '$' angefügt.
- Die **Länge** des Bitvektoren ist **2n+2** für $0 \leq i \leq |P| - n - 1$. Für alle späteren Positionen nehmen die Vektoren kontinuierlich ab.

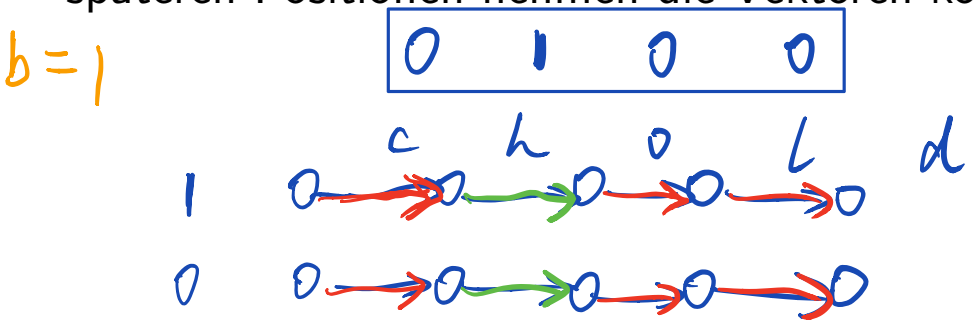

Tafelübung

$b = 2$ $P = child$ $L = 2b + 2 = 6$ input word = child

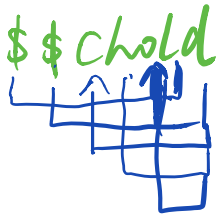

$\vec{x}(c, \$\$chil) = 001000$ 6

$\vec{x}(h, \$child) = 001000$ 6

$\vec{x}(i, child) = 00000$ 5

$\vec{x}(l, hild) = 0010$ 4

$\vec{x}(d, ild) = 001$ 3

Aufgabenstellung des Abschlussprojekts

Der Link zur Aufgabenstellung des Abschlussprojekts:
`https://www.cip.ifi.lmu.de/~nie/p1/Abschlussprojekt_de.html`