

# Algorithmen auf Sequenzen

## Exakte Mustersuche

Sven Rahmann

Genominformatik  
Universitätsklinikum Essen  
Universität Duisburg-Essen  
Universitätsallianz Ruhr

# Das Pattern Matching Problem (Exakte Mustersuche)



Gegeben sei ein endliches Alphabet  $\Sigma$ , ein Text  $T \in \Sigma^n$  und ein Muster (Pattern)  $P \in \Sigma^m$  i.d.R.  $m \ll n$ .

Gesucht sind alle Positionen  $i$ , für die gilt:  $T[i : i + m] = P$ .

# Das Pattern Matching Problem (Exakte Mustersuche)


Gegeben sei ein endliches Alphabet  $\Sigma$ , ein Text  $T \in \Sigma^n$  und ein Muster (Pattern)  $P \in \Sigma^m$  i.d.R.  $m \ll n$ .

Gesucht sind alle Positionen  $i$ , für die gilt:  $T[i : i + m] = P$ .


Varianten:

- Kommt  $P$  in  $T$  vor?
- Wie oft kommt  $P$  in  $T$  vor?


# Naiver Algorithmus




# Naiver Algorithmus




# Naiver Algorithmus




# Naiver Algorithmus




# Naiver Algorithmus



# Naiver Algorithmus




# Naiver Algorithmus



Insgesamt  $n - m + 1$  Verschiebungen.  
Pro Verschiebung bis zu  $m$  Vergleiche.  
Gesamte Laufzeit:  $\mathcal{O}(mn)$ .

# Naiver Algorithmus



Insgesamt  $n - m + 1$  Verschiebungen.  
 Pro Verschiebung bis zu  $m$  Vergleiche.  
 Gesamte Laufzeit:  $\mathcal{O}(mn)$ .

```

1 def naive(P, T):
2     m, n = len(P), len(T)
3     for i in range(n - m + 1):
4         if T[i:i+m] == P:
5             yield (i, i+m)
  
```

## Theorem (Erwartete Laufzeit)

*Sei  $|\Sigma| \geq 2$ . Seien ein Muster der Länge  $m$  und ein Text der Länge  $n$  zufällig gleichverteilt gewählt. Dann beträgt die Worst-case-Laufzeit des naiven Algorithmus  $\mathcal{O}(mn)$ , aber die erwartete Laufzeit lediglich  $\mathcal{O}(n)$ .*


Die Wahrscheinlichkeit  $p$ , dass jeweils ein zufällig gezogenes Zeichen aus  $P$  und  $T$  übereinstimmen, beträgt

$$p := \frac{|\Sigma|}{|\Sigma|^2} = \frac{1}{|\Sigma|}.$$

Die Wahrscheinlichkeit  $p$ , dass jeweils ein zufällig gezogenes Zeichen aus  $P$  und  $T$  übereinstimmen, beträgt

$$p := \frac{|\Sigma|}{|\Sigma|^2} = \frac{1}{|\Sigma|}.$$

- Die W'keit, dass alle Zeichen des Musters mit dem Text übereinstimmen, beträgt  $p^m$ .
- Die W'keit, dass das Muster erst an Stelle  $j$  mit dem Text nicht übereinstimmt, beträgt  $p^{j-1} \cdot (1 - p)$ .



Die erwartete Anzahl an Vergleichen für ein Muster der Länge  $m$  beträgt demnach:

$$E_m := mp^m + \sum_{j=1}^m jp^{j-1} \cdot (1 - p)$$

Die erwartete Anzahl an Vergleichen für ein Muster der Länge  $m$  beträgt demnach:

$$E_m := mp^m + \sum_{j=1}^m jp^{j-1} \cdot (1-p)$$

Und für beliebige Längen  $m \rightarrow \infty$ :

$$E_m < E_\infty := (1-p) \sum_{j=0}^{\infty} jp^{j-1}$$

Der Term  $\sum_{j=0}^{\infty} j\rho^{j-1}$  ist die Ableitung von  $\sum_{j=0}^{\infty} \rho^j = 1/(1 - \rho)$ .  
Somit gilt  $\sum_{j=0}^{\infty} j\rho^{j-1} = 1/(1 - \rho)^2$ .

Der Term  $\sum_{j=0}^{\infty} jp^{j-1}$  ist die Ableitung von  $\sum_{j=0}^{\infty} p^j = 1/(1-p)$ .  
Somit gilt  $\sum_{j=0}^{\infty} jp^{j-1} = 1/(1-p)^2$ .

Eingesetzt in  $E_{\infty}$  ergibt es

$$E_{\infty} = \frac{1-p}{(1-p)^2} = \frac{1}{1-p}.$$

Der Term  $\sum_{j=0}^{\infty} j\rho^{j-1}$  ist die Ableitung von  $\sum_{j=0}^{\infty} \rho^j = 1/(1 - \rho)$ .  
Somit gilt  $\sum_{j=0}^{\infty} j\rho^{j-1} = 1/(1 - \rho)^2$ .

Eingesetzt in  $E_{\infty}$  ergibt es

$$E_{\infty} = \frac{1 - \rho}{(1 - \rho)^2} = \frac{1}{1 - \rho}.$$

Aus der Definition  $\rho = 1/|\Sigma|$  folgt nun

$$E_m < \frac{|\Sigma|}{|\Sigma| - 1}.$$

Der Term  $\sum_{j=0}^{\infty} jp^{j-1}$  ist die Ableitung von  $\sum_{j=0}^{\infty} p^j = 1/(1-p)$ .  
Somit gilt  $\sum_{j=0}^{\infty} jp^{j-1} = 1/(1-p)^2$ .

Eingesetzt in  $E_{\infty}$  ergibt es

$$E_{\infty} = \frac{1-p}{(1-p)^2} = \frac{1}{1-p}.$$

Aus der Definition  $p = 1/|\Sigma|$  folgt nun

$$E_m < \frac{|\Sigma|}{|\Sigma| - 1}.$$

Für ein 2-buchstabiges Alphabet beträgt  $E_m < 2$ , für  $|\Sigma| \rightarrow \infty$  sogar nur  $E_m = 1$ . Die Laufzeit entspricht somit  $\mathcal{O}(nE_m) = \mathcal{O}(n)$ .

