

# Anzahl globaler Alignments

## APPENDIX B

### Pairwise Sequence Alignment (Extended Material)

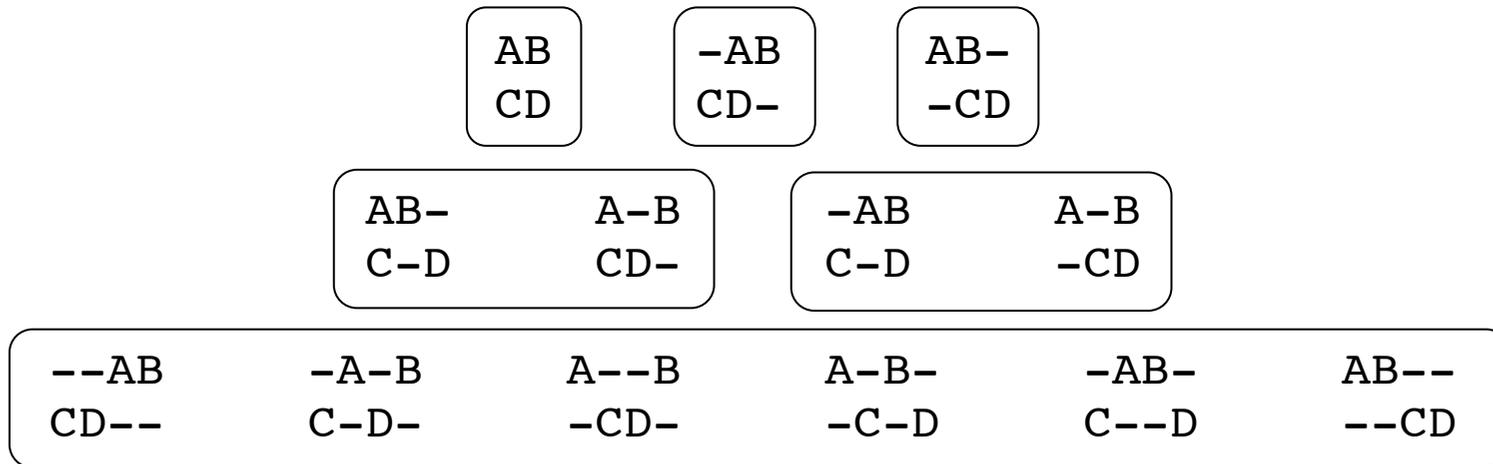
#### B.1 The Number of Global Alignments

Roland Wittler

13. April 2015

# Motivation

Können wir alle globalen Alignments zweier Sequenzen aufzählen?



$$N(2,2) = 13$$

$$N'(2,2) = 6$$

# Übersicht

1. Motivation
2. Algorithmischer Ansatz
3. Kombinatorischer Ansatz
4. Vernachlässigung der Reihenfolge von InDels
5. Zusammenfassung

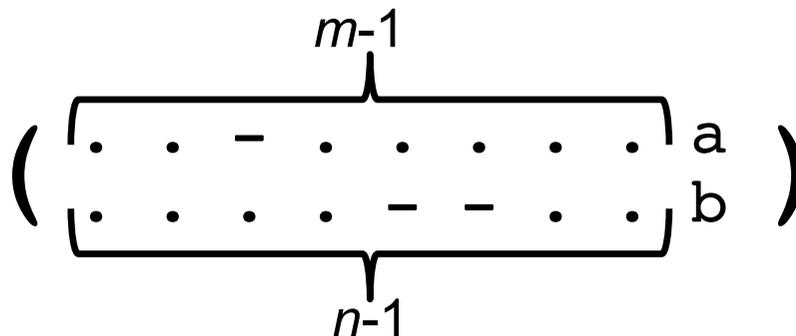
# Übersicht

1. Motivation
- 2. Algorithmischer Ansatz**
3. Kombinatorischer Ansatz
4. Vernachlässigung der Reihenfolge von InDels
5. Zusammenfassung

## Algorithmischer Ansatz

Anzahl an Möglichkeiten einen leeren String mit einem anderen zu alignieren:  $N(m,0) = N(0,n) = 1$

Match/Mismatch:  $N(m-1,n-1)$  Möglichkeiten die Präfixe zu alignieren

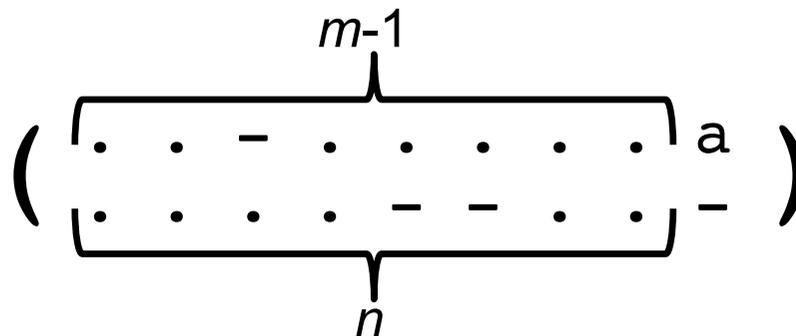


## Algorithmischer Ansatz

Anzahl an Möglichkeiten einen leeren String mit einem anderen zu alignieren:  $N(m,0) = N(0,n) = 1$

Match/Mismatch:  $N(m-1,n-1)$  Möglichkeiten die Präfixe zu alignieren

Deletion:  $N(m-1,n)$  Möglichkeiten ...



## Algorithmischer Ansatz

Anzahl an Möglichkeiten einen leeren String mit einem anderen zu alignieren:  $N(m,0) = N(0,n) = 1$

Match/Mismatch:  $N(m-1,n-1)$  Möglichkeiten die Präfixe zu alignieren

Deletion:  $N(m-1,n)$  Möglichkeiten ...

Insertion:  $N(m,n-1)$  Möglichkeiten ...

Rekursion:  $N(m,n) = N(m-1,n-1) + N(m-1,n) + N(m,n-1)$

# Algorithmischer Ansatz

1	1	1	1	1	...
1	3	5	7	9	...
1	5	13	25	41	...
1	7	25	63	...	
1	9	41	...		
....	...	...			

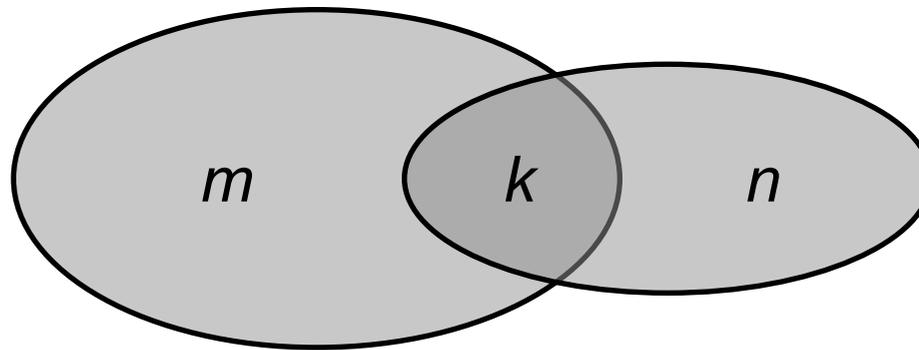
# Übersicht

1. Motivation
2. Algorithmischer Ansatz
- 3. Kombinatorischer Ansatz**
4. Vernachlässigung der Reihenfolge von InDels
5. Zusammenfassung

## Kombinatorischer Ansatz

$N(m,n)$  symmetrisch  $\rightarrow$  Annahme:  $n \leq m$

Anzahl  $k$  an Match/Mismatch-Spalten:  $0 \leq k \leq n$



$\rightarrow n - k$  Insertionen,  $m - k$  Deletionen

$\rightarrow n + m - k$  Spalten insgesamt

## Kombinatorischer Ansatz

$\binom{m+n-k}{k}$  Möglichkeiten Match/Mismatch-Spalten zu positionieren

$\binom{m+n-2k}{n-k}$  Möglichkeiten InDel-Spalten zu positionieren

$$r := n - k$$

$$N(m, n) = \sum_{r=0}^{n-k} \binom{m+r}{n-r} \binom{m-k}{r}$$

*(n-k Insertionen, m-k Deletionen insgesamt)*

# Kombinatorischer Ansatz

Werte auf der Diagonalen:

$$N(n,n) = \sum_{r=0}^n \binom{n+r}{n-r} \cdot \binom{2r}{r}$$

$$N(m,n) = \sum_{r=0}^n \binom{m+r}{n-r} \cdot \binom{m-n+2r}{r}$$

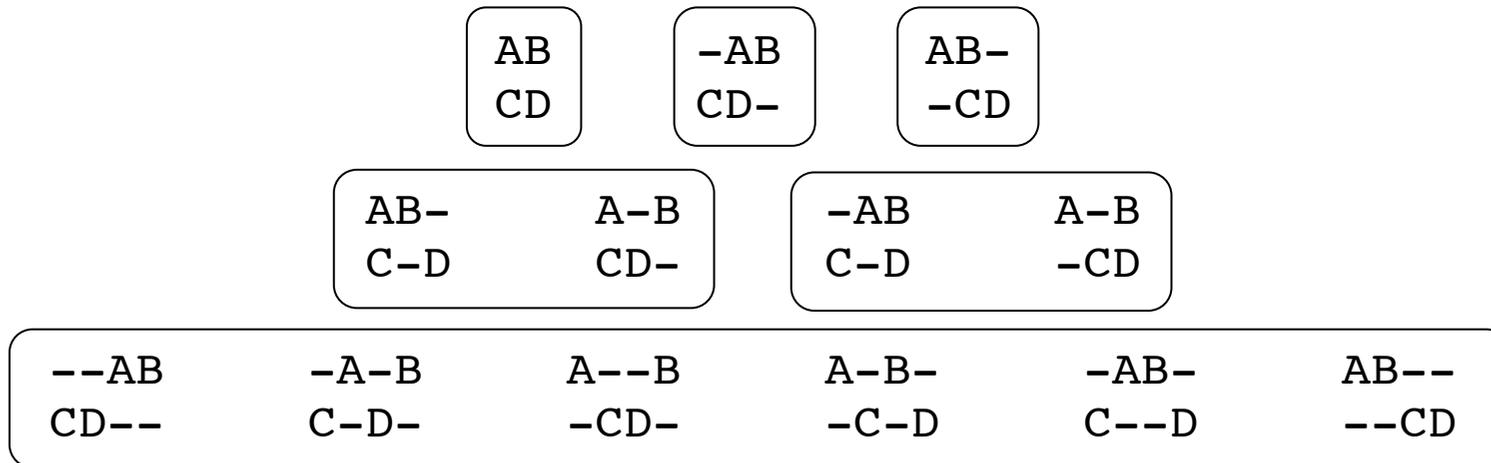
$$\approx \binom{1}{n} / \sqrt{n} (1 + \sqrt{2})^{2n+1}$$

→ exponentiell

# Übersicht

1. Motivation
2. Algorithmischer Ansatz
3. Kombinatorischer Ansatz
4. **Vernachlässigung der Reihenfolge von InDels**
5. Zusammenfassung

# Vernachlässigung der Reihenfolge von InDels



$$N''(2,2) = 6$$

## Vernachlässigung der Reihenfolge von InDels

$\binom{n}{k}$  Möglichkeiten Match/Mismatch-Positionen in kurzer Seq.

$\binom{m}{k}$  Möglichkeiten Match/Mismatch-Positionen in langer Seq.

$$N'(m,n) = \sum_{k=0}^n \binom{n}{k} \cdot \binom{m}{k} = \binom{m+n}{k}$$

$$N'(n,n) = \binom{2n}{k} \approx \frac{4^n}{\sqrt{(\pi n)}} \exp(-3/24n) \quad \rightarrow \text{exponentiell}$$

# Übersicht

1. Motivation
2. Algorithmischer Ansatz
3. Kombinatorischer Ansatz
4. Vernachlässigung der Reihenfolge von InDels
5. **Zusammenfassung**

## Zusammenfassung

Rekursion:  $N(m,n) = N(m-1,n-1) + N(m-1,n) + N(m,n-1)$

$$N(m,n) = \sum_{r=0}^n \binom{m+r}{n-r} \cdot \binom{m-n+2r}{r}$$



→ exponentiell

$$N(n,n) \approx (1 / \sqrt{n}) (1 + \sqrt{2})^{2n+1}$$

→ exponentiell

$$N'(m,n) = \binom{m+n}{k}$$

→ exponentiell

$$N'(n,n) \approx \frac{4^n}{\sqrt{(\pi n)}} \exp(-3/24n)$$

→ exponentiell