

W3.1: アラインメントの場合の数

以下の2つのアミノ酸配列のアラインメントを考える。

K S A L T I Q L I
K S T L A N I F E Q V

例えば、以下のアラインメントの配列類似度および配列一致度は

K S A L T I Q L I - -
K S T L A N I F E Q V
+5+4-1+4-1-3-3+0-3-8-8 配列類似度 -14 配列一致度 27.3%

K S A L - T I - - Q L I
K S T L A N I F E Q V -
+5+4-1+4-8+0+4-8-8+5+1-8 配列類似度 -4 配列一致度 41.7%

K S A L - T I - Q L I
K S T L A N I F E Q V
+5+4-1+4-8+0+4-8+2-2+3 配列類似度 +2 配列一致度 36.4%

このように、アラインメントのとり方は何通りもあり、それぞれ、配列類似度と配列一致度が異なる。

一般に、長さ m と長さ n の2つの配列のアラインメントの数は以下の式で与えられる。

$$f(m, n) = \sum_{k=0}^{\min\{m, n\}} 2^k {}_m C_k {}_n C_k = \sum_{k=0}^{\min\{m, n\}} \frac{(m+n-k)!}{k!(m-k)!(n-k)!}$$

これは、ギャップと対応する部分の文字を k として、どちらの配列にギャップが対応づけられるかで 2^k 通り、さらに k を m, n からどう選ぶかで ${}_m C_k {}_n C_k$ 通りが考えられる。

例えば、具体的に計算すると、以下のように膨大な数になることがわかる。

$$f(1, 2) = f(2, 1) = 5$$

$$f(4, 2) = f(2, 4) = 41$$

$$f(8, 4) = f(4, 8) = 3649$$

$$f(16, 8) = f(8, 16) = 39490049$$

$$f(100, 100) \approx 2 \times 10^{74}$$