# ハードウェア化に適した近似文字列照合アルゴリズム

馬場, 謙介
九州大学大学院システム情報科学研究院



出版情報：SLRC プレゼンテーション, 2006-07-19. 九州大学システムLSI研究センター
バージョン：
権利関係：

# ハードウェア化に適した近似文字列照合アルゴリズム

馬場　謙介
九州大学
大学院システム情報科学研究院

# 研究紹介

私の研究経歴

1996-2002　古典論理に対するラムダ計算

2002-2004　数値演算的手法を用いた文字列処理

2004-　セキュアな認証のための論理

2005-　ハードウェア化に適した文字列処理

目標：文字列照合を（どんな手段を使ってでも）高速に行う

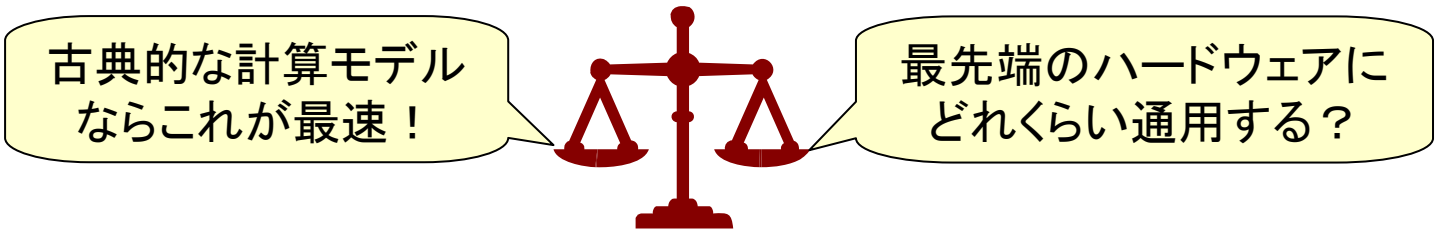

# 発表のあらすじ

- 近似文字列照合高速化の意義
  - アプリケーションの観点から
- 高速化の既存手法
  - 問題の定式化
  - 既存手法の特徴
- 我々のアプローチ
  - 基本アイデア
  - 効果の大まかな見積り

# 文字列照合のアプリケーション

- 「ぴったり」を探す
  - インターネットの検索
  - ウィルス検索
  - ID照合
  - など

- 「似てる」を探す
  - バイオインフォマティクス
  - 画像・動画検索
  - 異常検知
  - など

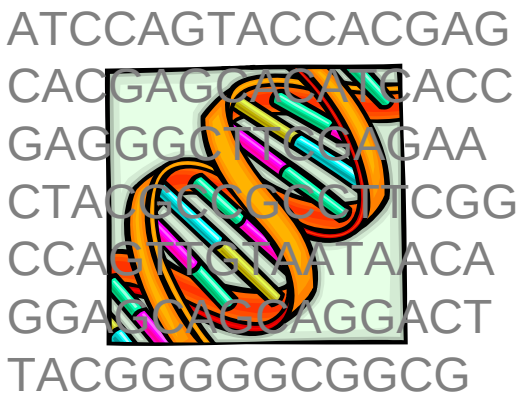

# アプリケーションからの要求（1）

- インターネットの検索
  - 検索のためのデータ構造を作成
  - 様々な観点からの検索対象の制限（速さの確保と感度の低下）
- ウィルス検索
  - 基本的に単純な文字列の照合
  - できるだけ高速にできた方が良く，感度は落とせない
- ID照合（ICカード等による個人の識別や認証）
  - 暗号化などにより，照合に複雑な処理を伴う場合がある
  - 時間が極端に制限される場合がある（改札など）
  - 基本的に感度は落とせない

# アプリケーションからの要求（2）

- バイオインフォマティクス
  - 一般に計算量が膨大
  - 感度を落とした高速化が一般的だが．．．
  - さらに複雑な構造の解析が求められる
- 画像・動画検索
  - 高次の文字列検索とみなせる
  - 量子化や低周波の除去による速さの確保と感度の低下
- 異常検知（防犯カメラ，医療画像など）
  - 過去のデータからのパターン抽出
  - 感度が落とせない場合が多い

# 文字列照合高速化の意義

今さら，まだ文字列照合？

- 現実に

  アプリケーションの中に

  – 速さと感度の更なる向上を求める
  – 速さ，または感度が落とせない

  もの（で重要なもの）が（まだまだ）ある

- 信念として

  – 基礎的な理論はより複雑な問題にも適用できるはずだ
  – いずれにせよ，コンピュータで扱うのは文字列だ
  – そもそも，人間が物事を記号の列によって理解しようするアプローチこそが本質的だ

# 文字列照合の種類

## 文字列照合

2つの文字列について，片方の（テキストと呼ばれる，長い）文字列中に，もう一方の（パターンと呼ばれる，短い）文字列の出現を見つけること

## 不一致を許した文字列照合

文字の置換を考慮した文字列照合．本質はテキストの各位置でのパターンとの一致の数を数えること

## 近似文字列照合

文字の置換や挿入・削除を考慮した文字列照合．本質は文字列間の距離を計算すること．重みを付けることで，さらに一般的な距離を考えることができる

# 文字列照合の例（1）

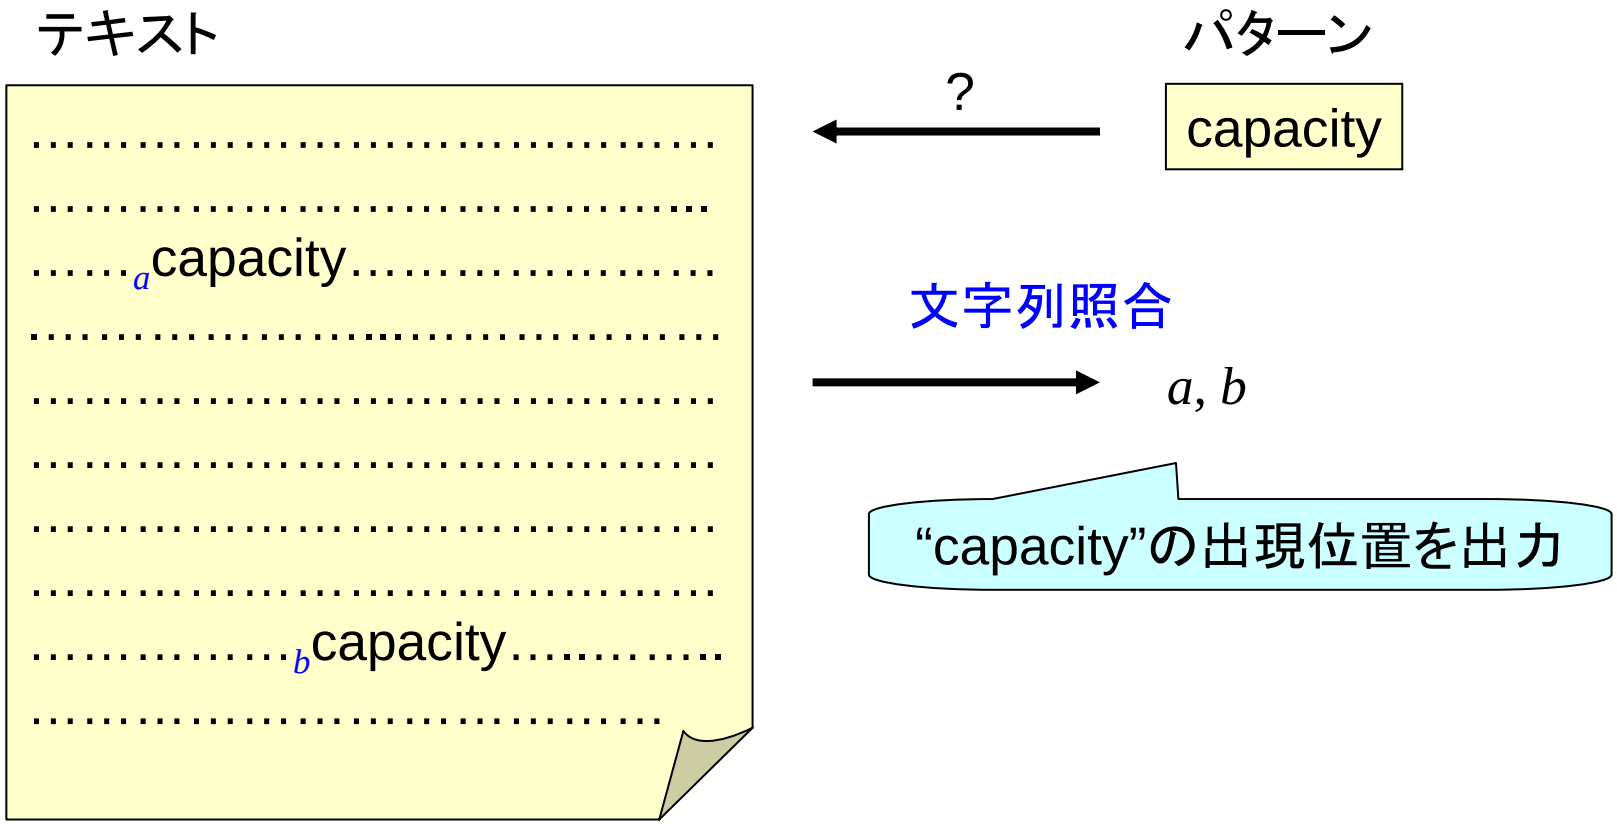
テキスト
パターン
?
capacity
……
……..
……acapacity……
……..……
……
……
……
……
……
……bcapacity……..
……
文字列照合
a, b
“capacity”の出現位置を出力

# 文字列照合の例（2）

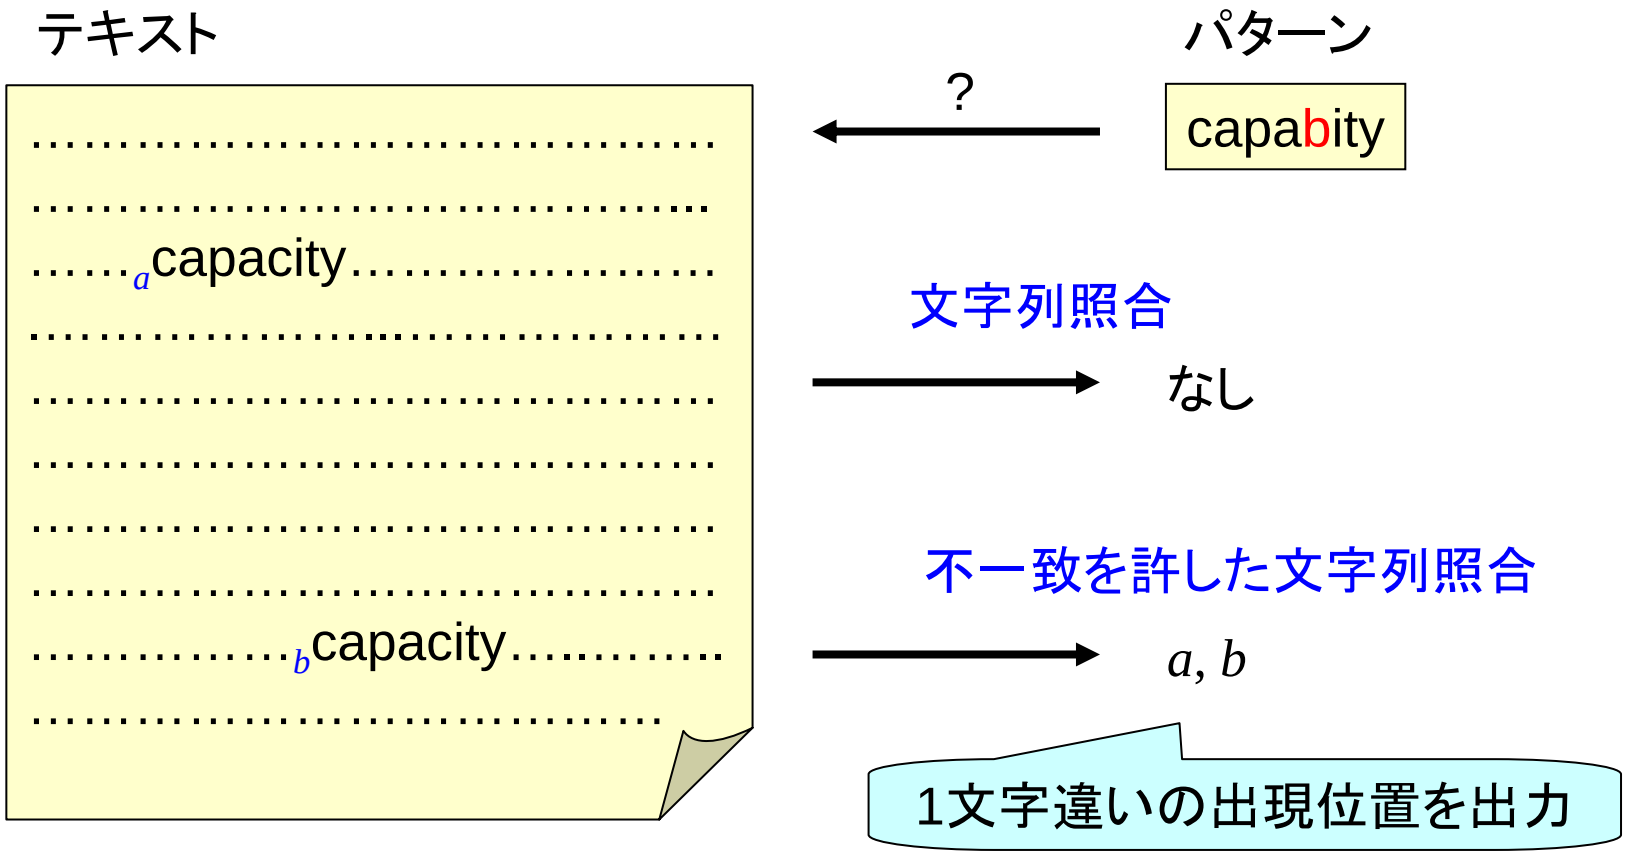
テキスト
……
……
……acapacity……
……
……
……
……
……
……bcapacity……
……
パターン
?
capability
文字列照合
なし
不一致を許した文字列照合
a, b
1文字違いの出現位置を出力

# 文字列照合の例（3）

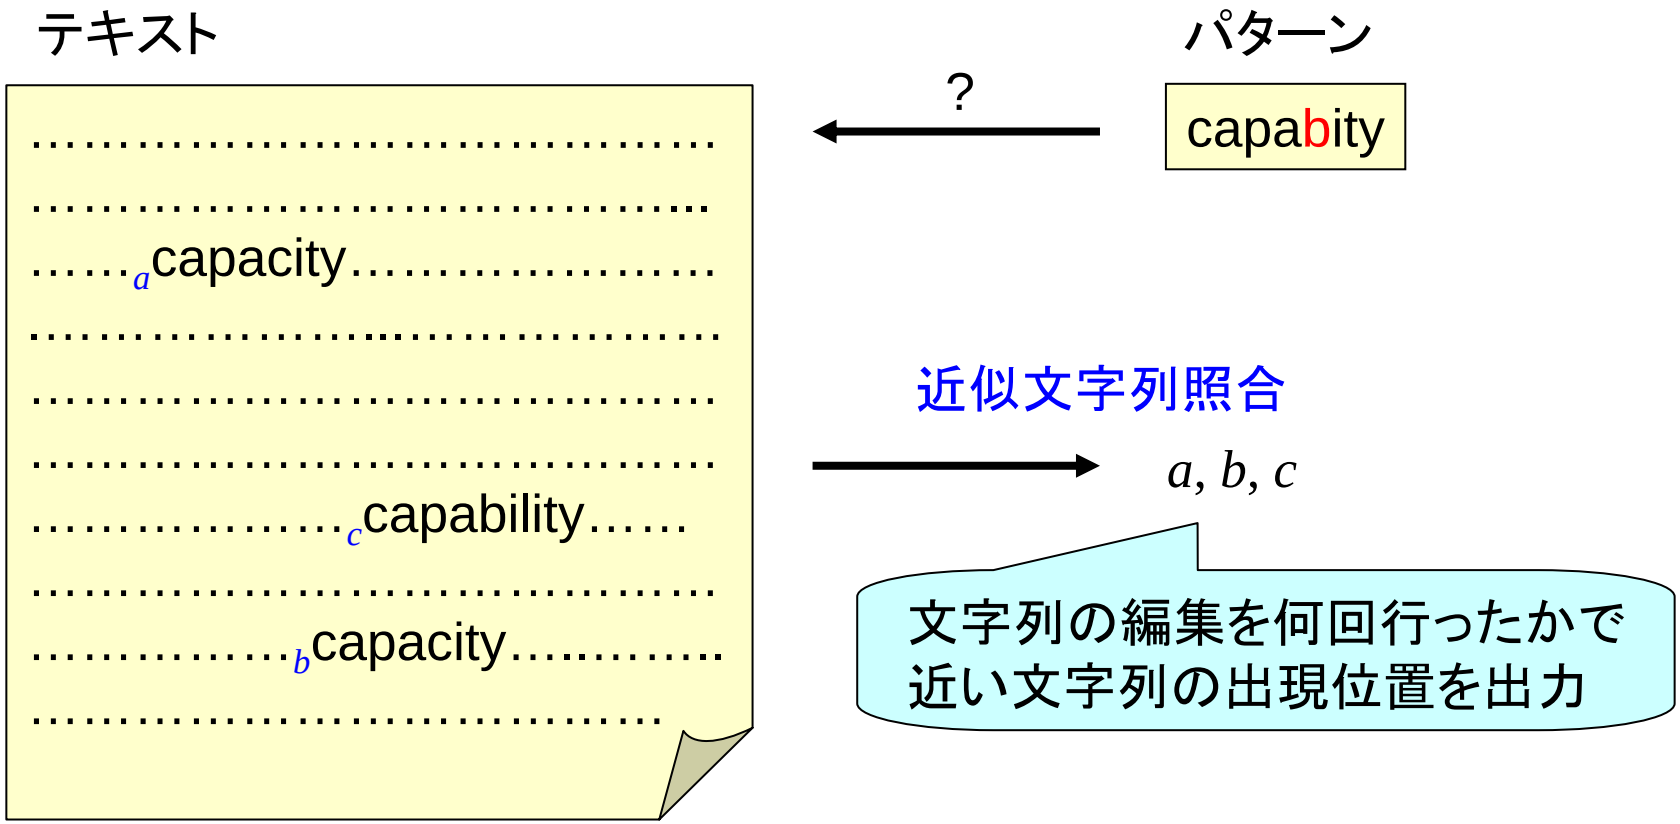
テキスト
パターン
?
capability
……
……..
……$_a$capacity……
……
……
……
……$_c$capability……
……
……$_b$capacity……..
……
近似文字列照合
$a, b, c$
文字列の編集を何回行ったかで
近い文字列の出現位置を出力

# 文字列間の距離の計算

$m$ : パターンの長さ

$n$ : テキストの長さ

- 単純なやり方
  - 考え得る全ての文字の比較の仕方について編集の回数を数え，最小のものを見つける
  - 膨大な計算量
- うまいやり方（動的計画法）
  - 短い部分文字列についての値を使って再帰的に計算
  - $O(mn)$ 時間

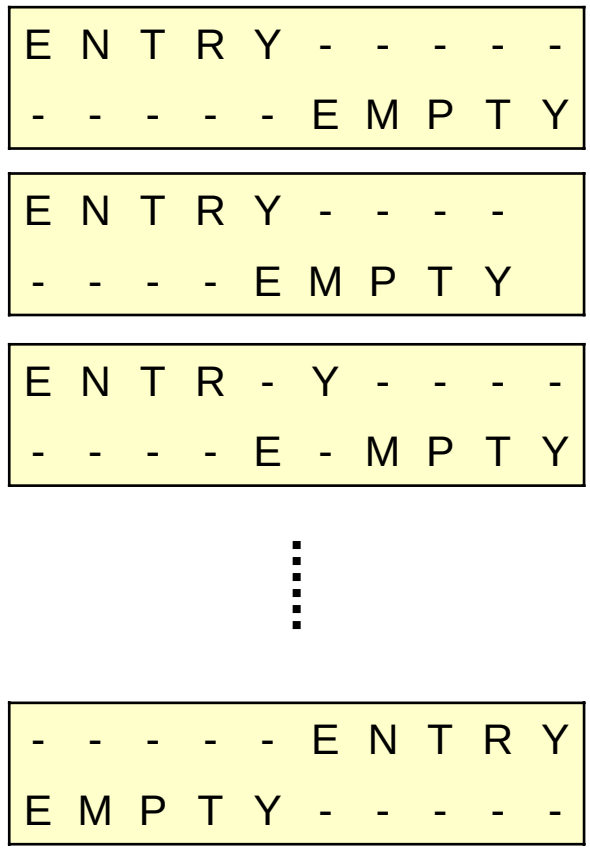

# 動的計画法（1）

- 与えられた文字列からグラフを作成
- 左上からの各パスが文字の比較の仕方に対応

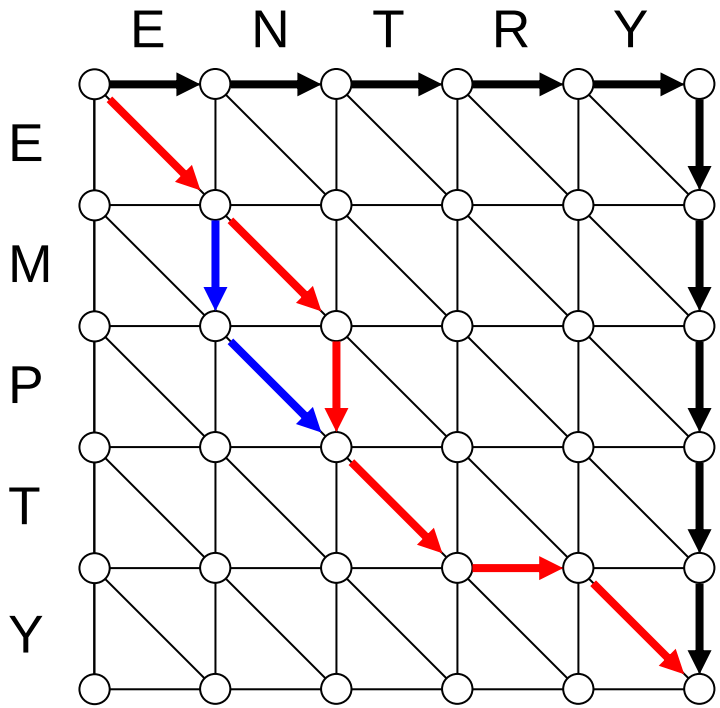


| | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|
| E | N | T | R | Y | - | - | - | - | - |
| - | - | - | - | - | E | M | P | T | Y |

| | | | | | |
|---|---|---|---|---|---|
| E | N | - | T | R | Y |
| E | M | P | T | - | Y |

| | | | | | |
|---|---|---|---|---|---|
| E | - | N | T | R | Y |
| E | M | P | T | - | Y |

# 動的計画法（2）

- グラフの各ノードに対応する値 $D_{m,n}$ を計算する
  - $W(a,b)$：文字 $a$ と $b$ の間に与えられる置換の重み
  - $d$：挿入・削除の重み
  - $p_i$：パターンの $i$ 番目の文字，$t_j$：テキストの $j$ 番目の文字

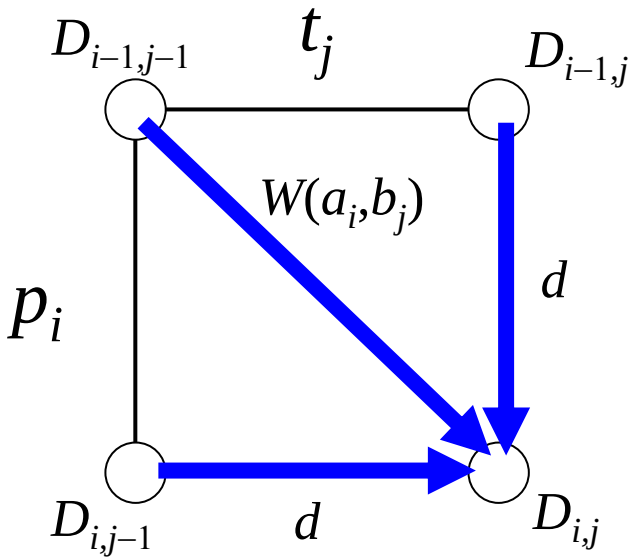


$$D_{i,0} = id \quad (1 \le i \le m)$$

$$D_{0,j} = jd \quad (1 \le j \le n)$$

$$D_{i,j} = \min \begin{cases} D_{i-1,j-1} + W(p_i, t_j) \\ D_{i-1,j} + d \\ D_{i,j-1} + d \end{cases}$$

# 近似文字列照合の高速化(1)

あるノードの値は，上，左，左上のノードの値に依存する

→ コンピュータの処理能力によって，
一度に計算できるノード数が
単純には増えない

## 単純な並列化

- 依存関係の無い斜めのライン上のノードの値を同時に計算
- 複数の演算器による実装としては一般的な手法
- 計算時間は $O(m+n)$
- ソフトウェア的な実装も可能

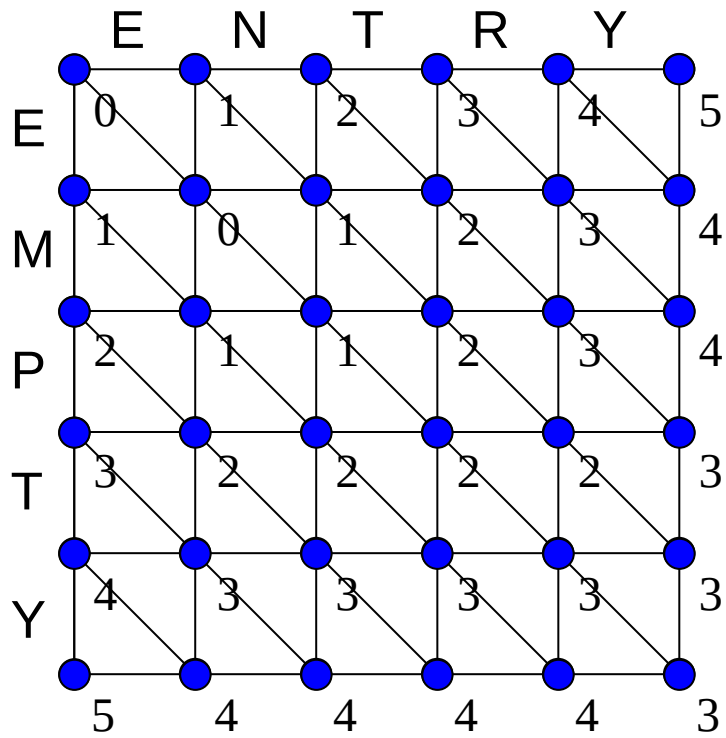

# 近似文字列照合の高速化(2)

## 事前の計算による高速化

- 長さ $t$ の2つの文字列と，行列の最初の行と列の値の組み合わせについて，最後の行と列の値のテーブルを事前に作成
- テーブルから値を $O(t)$ 時間で参照
- 計算時間は $O(mn/t)$
- テーブルのための領域が必要
- 値が計算されないノードがあるため，文字の正確な対応がわからない

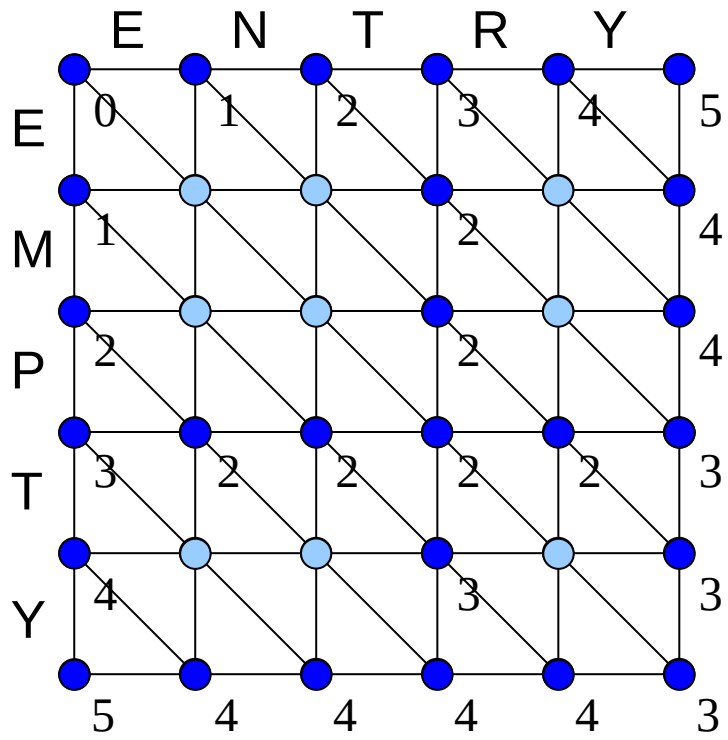

# 近似文字列照合の高速化(3)

## ビット・パラレル法

- 各行の値をビット列で表現し，値の関係を二値の論理式で表現
- ビット演算の繰り上がりによって，縦のノードの依存関係を表現
- 一度に $w$ 文字の処理ができるとき，計算時間は $O(n/w)$
- 最後の行のみ値を計算するため，文字の正確な対応がわからない
- 重み付きの距離の計算は困難

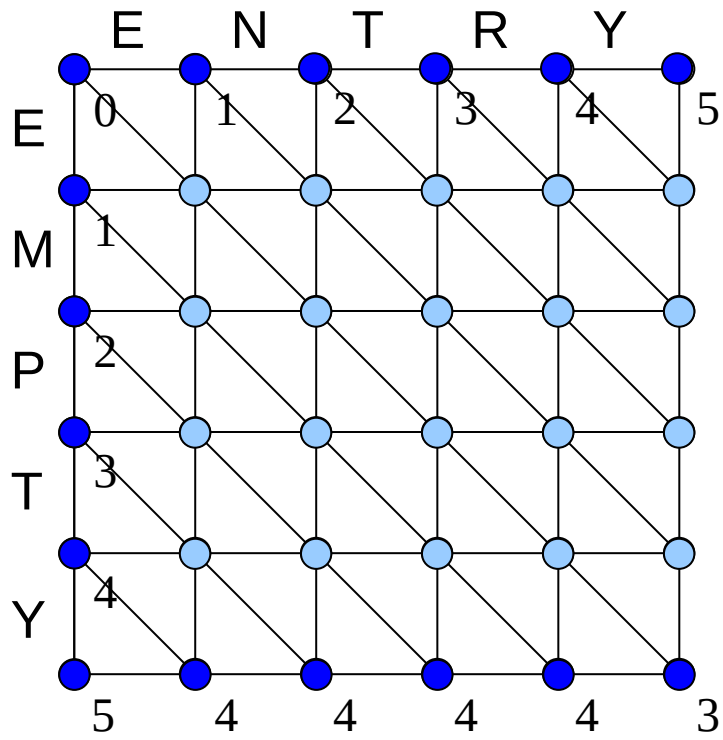

# 我々のアプローチ

メモリの参照よりも，なるべく演算を行うアルゴリズムの方が良さそうだ．．．

- ビット・パラレル法の適用可能性の検討
  - 単純な並列化との併用
  - 文字の正確な対応への拡張
  - 重み付き距離への一般化
- ハードウェアの性能をより反映する計算への置き換え
  - 長いテキストからパターンに似ている部分を探す場合
  - 少し簡単な問題を解けば，問題の一部を解いたことになる？
  - アプリケーションによっては効果がありそうだ！

# 不一致を許した文字列照合

近似文字列照合に比べて

- 根本的に計算量が少ない別の問題（挿入・削除が無い）
- テキストの分割による並列化が可能（結果の結合が容易）
- 文字の種類についての分割による並列化が可能

- 単純なやり方
  - 文字列照合と同様（加えて，一致の数をカウント）
  - 計算時間：$mn$ 回の文字の比較（及び，足し算）
- うまいやり方（FFTの利用）
  - 文字を数値に置き換えて，文字の比較を掛け算で表す
  - 計算時間：$n\log m$ 時間のFFT
  - ハードウェアによるFFTの高速化が期待できる

# FFTの利用

関数 $f$ と $g$ の畳み込み

$$h(x)=\sum_{i=1}^{n} f(i)\,\mathrm{o}\,g(x-i+1) \quad x=1,\ldots,n$$

は FFT によって $O(n\log n)$ で計算できる.

```
first entry into ...
empty
 empty
  →
```

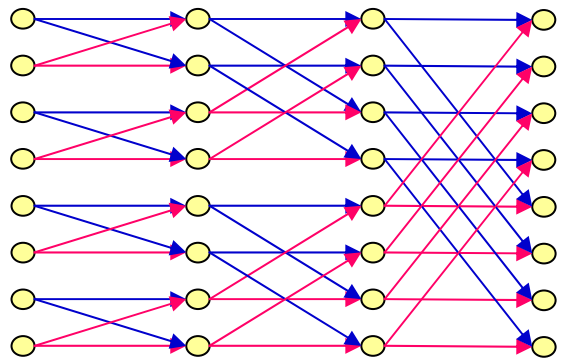

掛け算と足し算の繰り返しの
順番をうまく変えてやると. . .

# 一致の数による前処理の例

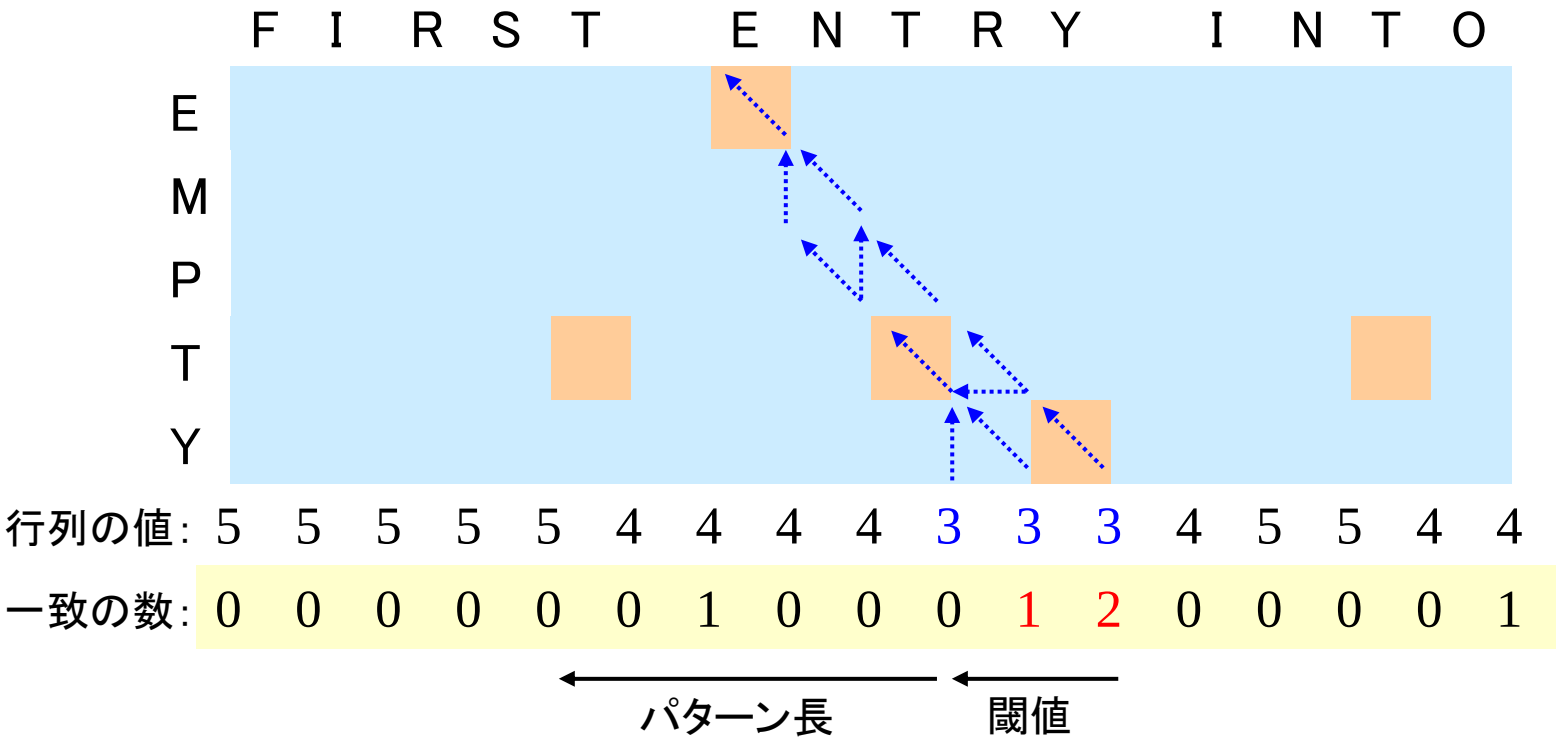


探索の候補を，一致の数がある程度以上の位置から，
高々パターン長と閾値分の長さに削減できる！

# 計算時間の見積もり

$m$=64, $n$=10,000

- 近似文字列照合
  - 単純な方法（$O(mn)$）: 30s
  - ビットパラレル法（$O(mn/w)$）: 1s
- 不一致を許した文字列照合
  - 単純な方法（$O(mn)$）: 10s
  - FFTによる方法（$O(n\log m)$）: ?（少しうまい法（$O(mn\log m/w)$）: 1s）

見積もり

- ビットパラレル法: 演算器の性能に応じた高速化
- FFTによる前処理: 1桁少ない程度（10倍の前処理ができる）

# まとめ

- 近似文字列照合高速化の意義
  - 速さ，感度ともに向上が求められるアプリケーションが存在
- 高速化の既存手法
  - ひとつの演算器について並列化するのが困難だ
  - 特別な場合については解決法がある
- 我々のアプローチ
  - ひとつの演算器についての並列化手法の一般化
  - 高速化が容易な計算による置き換えの実用性の考察