


大規模データセットに対する高速かつ省領域な類似度検索技術

ポイント

1. 高次元・大規模データの類似度検索技術
2. 類似データの高速・省メモリ検索
3. ベクトル、グラフ、移動軌跡等のデータ形式対応
4. コサイン、Jaccard、Min-Max等の類似度尺度対応

クエリに類似するデータをデータベースから検索する



ϵ : 閾値

類似度検索とは

類似度尺度:

類似度	データ
コサイン	画像、テキスト
Jaccard	化合物フィンガープリント
Min-Max	化合物フィンガープリント
ユークリッド距離	ベクトルデータ
Frechet距離	移動軌跡データ

応用例:

- ・ LLMの質問回答のヒント生成
- ・ テキスト、画像の重複除去
- ・ 移動軌跡データのデータマイニング
- ・ 創薬候補化合物のスクリーニング

手法の概要

入力データ

- ・ ベクトル
- ・ テキスト
- ・ 画像
- ・ 移動軌跡データ
- ・ 化合物
- など

ハッシュ:

- ・ LSH
- ・ LSBC
- ・ CWS


ID 整数列

x_1 : 1 1 3 4 5 6 7 8
 x_2 : 0 0 5 6 8 9 2 1
 x_3 : 0 3 3 7 5 4 2 1
 x_4 : 3 1 6 8 1 3 5 1
 x_5 : 3 3 6 8 9 1 2 3

データ間の距離は整数列間のハミング距離として保存

圧縮データ構造 (簡潔トライ)

Search for $y = 111020$ with $r = 1$



B: 111011001100000

A: $x_2 x_3 x_1 x_4 x_6$



パフォーマンス

実験データ



- ・ 2億の化合物データベクトル
- ・ Liらのb-bit MinHashによりスケッチに変換 [WWW10]

比較手法

HWT [IEEE-TPAMI19], GV [SIGIR16], HSD [SSDBM13]



バイナリスケッチに対する実験結果



整数スケッチに対する実験結果

公開ソフトウェア

手法	類似度	データ
gWT	コサイン	グラフ
SMBT	Jaccard	0/1ベクトル
bST	Min-Max	ベクトル
Dyft	Min-Max	ベクトル
Frechet_simsearch	Frechet距離	移動軌跡データ

ダウンロードURL



<https://x.gd/lu0H1>