

# ショートコードによる 大規模近似最近傍探索

2016/12/2 @大阪大学

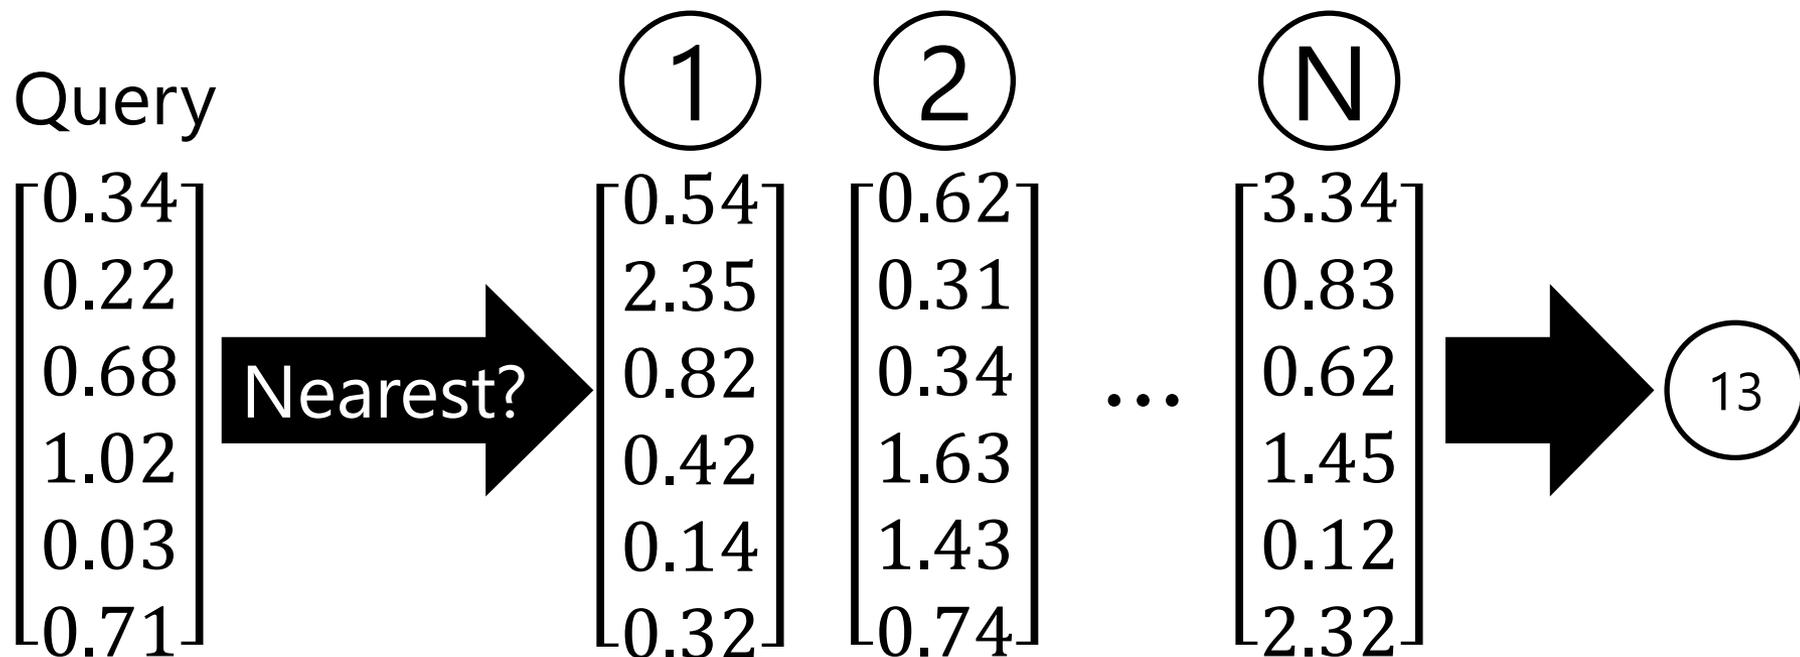
松井勇佑

国立情報学研究所



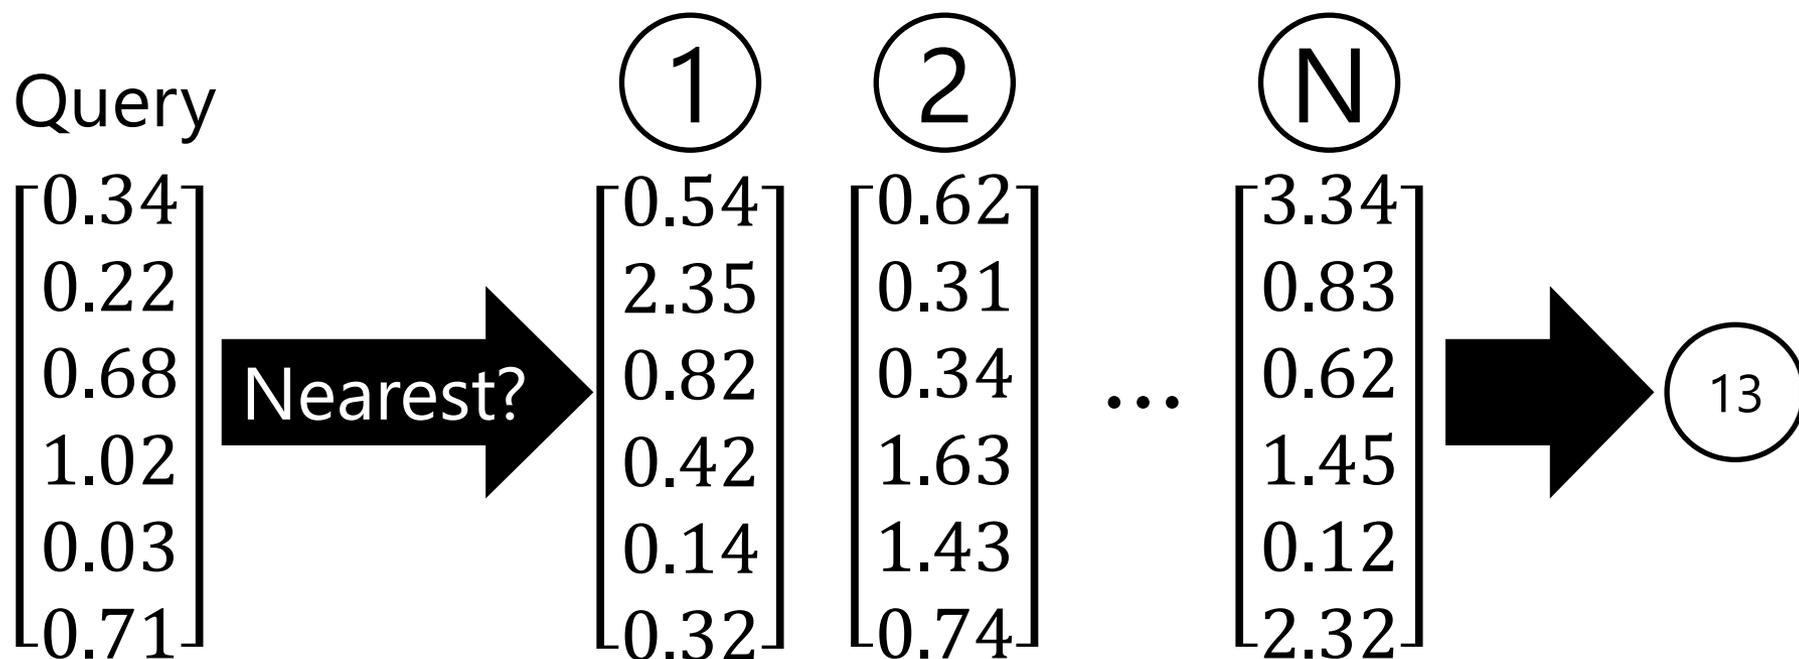
大学共同利用機関法人 情報・システム研究機構  
国立情報学研究所  
National Institute of Informatics

# 最近傍探索



- $N$ 個のベクトルがある
- クエリベクトルが与えられたとき、一番近いベクトルを探す
- 計算機科学における基本的な問題

# 最近傍探索



$$n^* = \arg \min_{1 \leq n \leq N} \|q - x_n\|^2$$

- 真面目に線形に全探索： $O(DN)$
- 遅い

# 近似最近傍探索

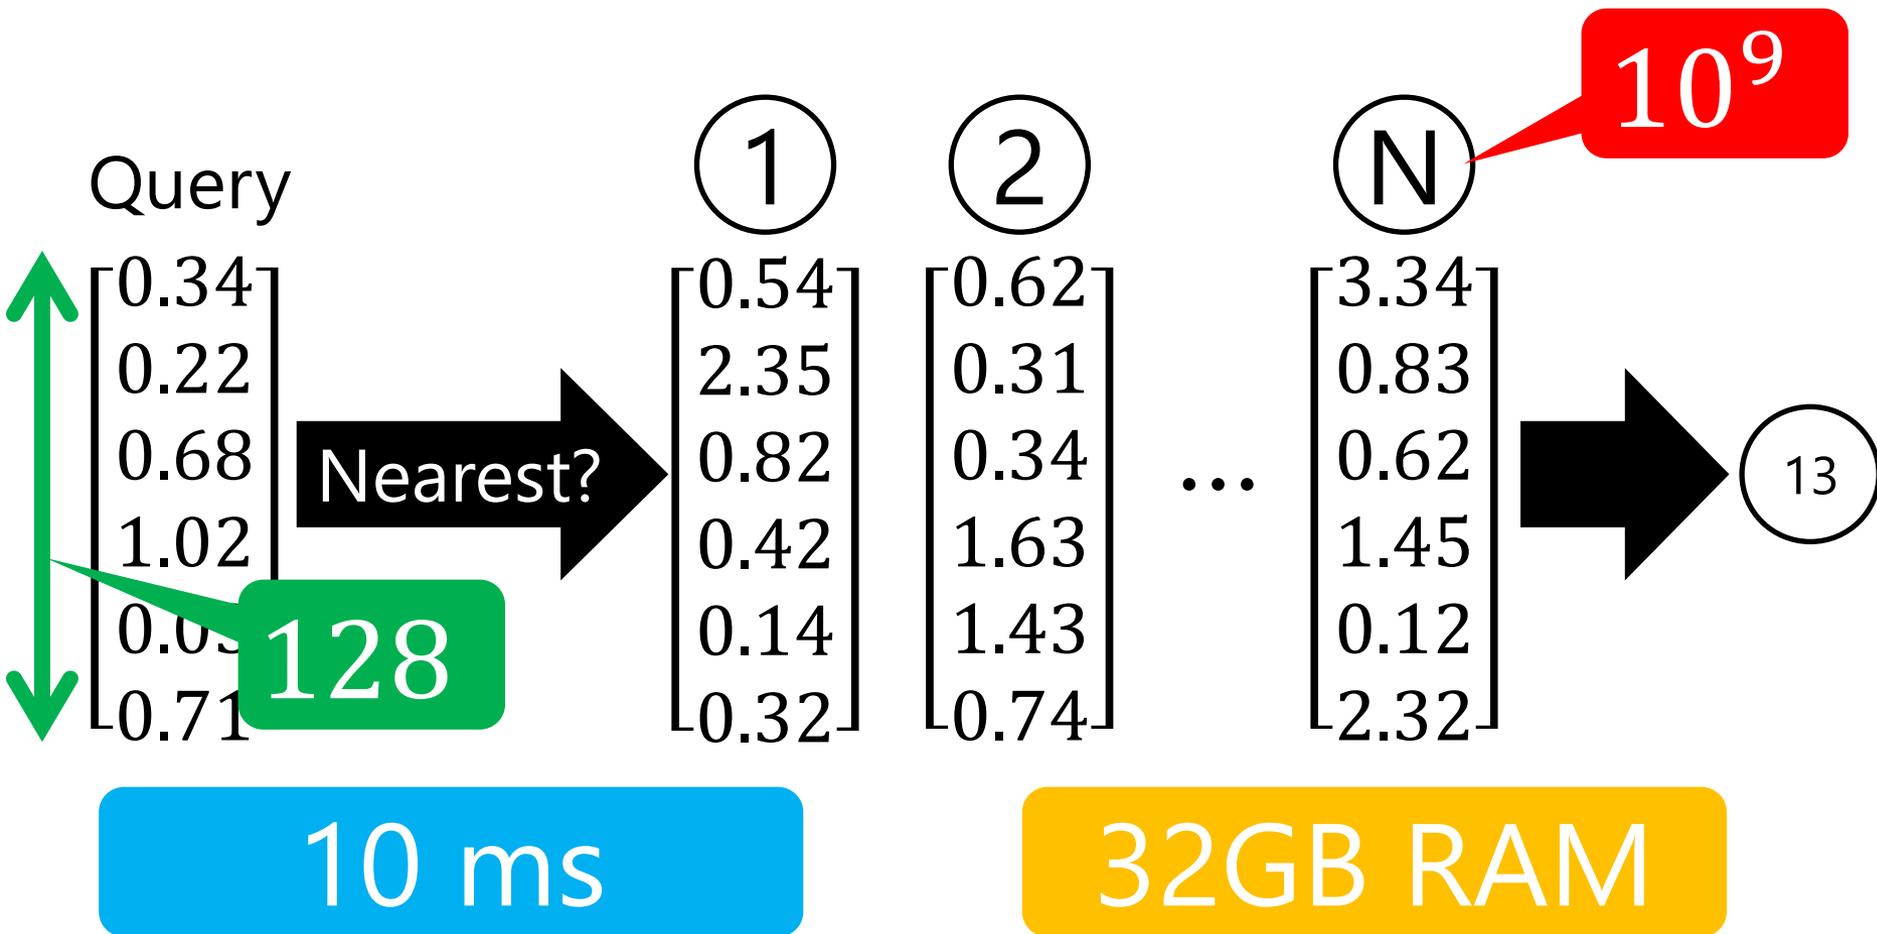


## ➤ 近似最近傍探索

➤ 厳密に最近傍でなくてもよいので、  
高速に解を求める

➤ 速度, メモリ, 精度のトレードオフ

# 近似最近傍探索



- 今日紹介する手法の規模感
- **大規模**な近似最近傍探索を扱う

# 近似最近傍探索

Locality Sensitive Hashing (LSH)系

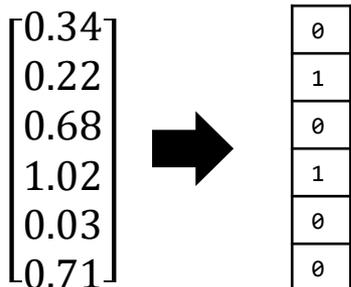
Tree系

(e.g., FLANN [Muja, PAMI 14])

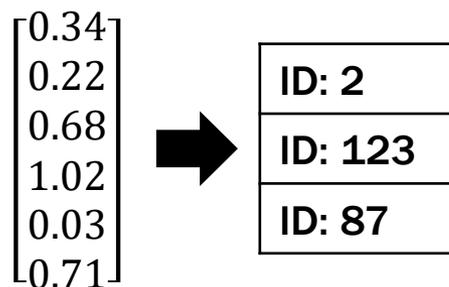
etc.

ショートコード系

ハミング系



ルックアップ系

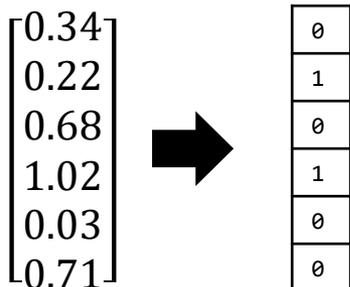


# 近似最近傍探索

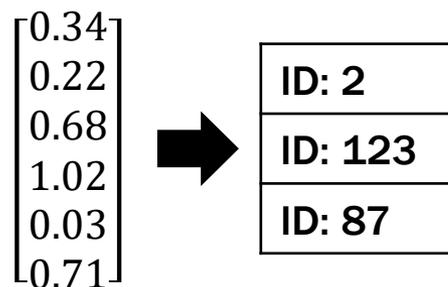
Locality Sensitive Hashing (LSH)系 (eg, PLANN) etc. **メモリ消費大**

ショートコード系

ハミング系



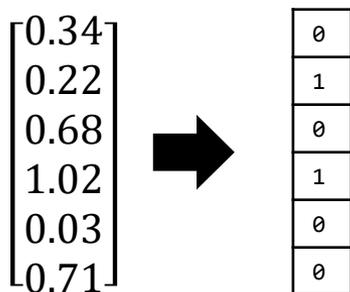
ルックアップ系



# ショートコードによる近似最近傍探索

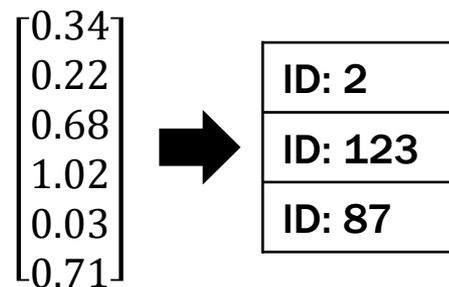
## ➤ 基本的な考え方

ハミング系



- 原理
- 手法の例
- 高速計算

ルックアップ系

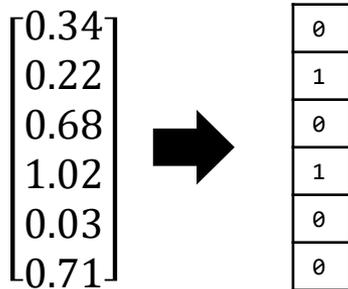


- 原理
- 探索システム

# ショートコードによる近似最近傍探索

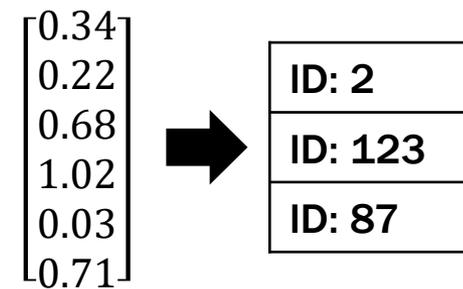
## ➤ 基本的な考え方

ハミング系



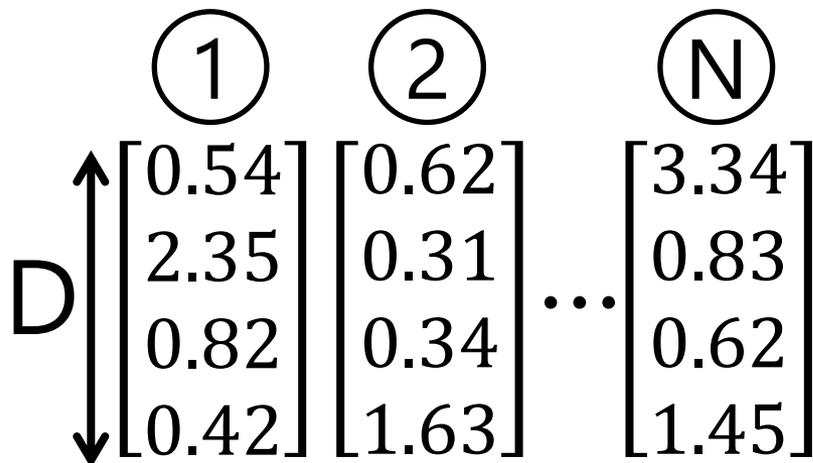
- 原理
- 手法の例
- 高速計算

ルックアップ系

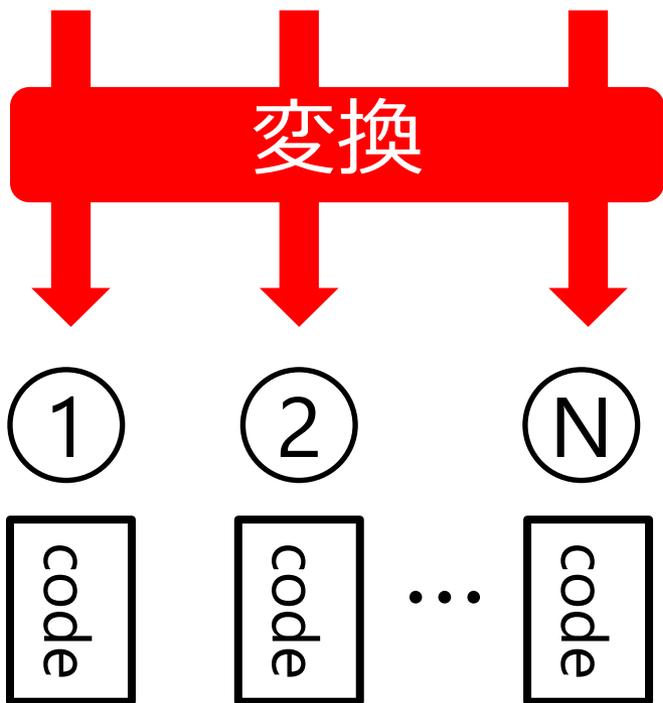


- 原理
- 探索システム

# 基本的な考え方



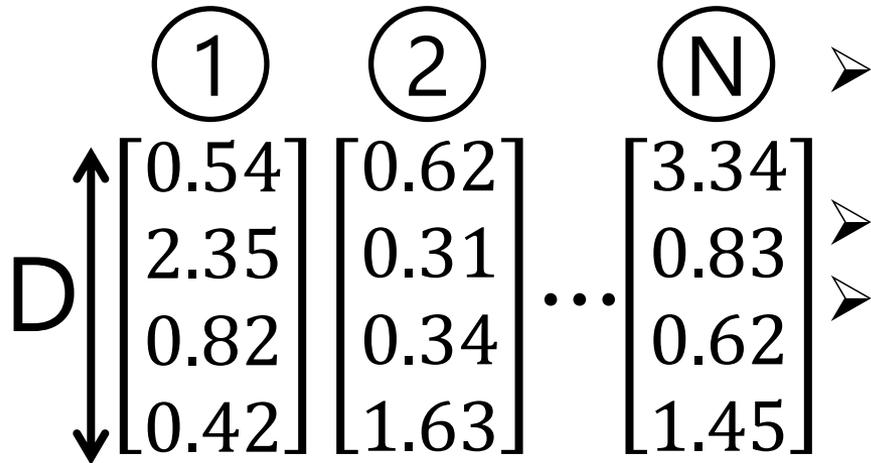
- $N$ 個の実数値ベクトルを表現するにはfloatを用いて $4ND$  byte 必要
- $N$ や $D$ が大きいとメモリに載らない
- 例： $D = 128, N = 10^9$ の時, 512 GB



- 各ベクトル「変換」し  
「ショートコード」に圧縮する

- ショートコードはメモリ効率が良い
- 例：上のデータを32bitコードに圧縮すると, わずか4GB
- 以降, ショートコードの世界で探索を考える

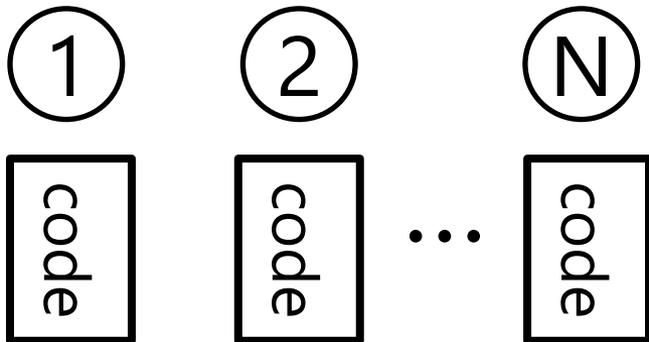
# 基本的な考え方



どのような変換がいいか？

1. コード間の「距離」が計算できる. その距離は元のベクトル間の距離を近似する
2. コード間距離は高速に計算できる
3. 上の二つを, 十分に小さいコードで実現できる

変換

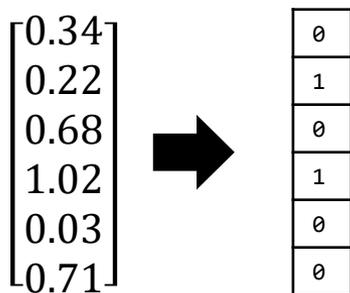


- メモリ効率が良い
- 例：上のデータを32bitコードに圧縮すると, わずか4GB
- 以降, ショートコードの世界で探索を考える

# ショートコードによる近似最近傍探索

## ➤ 基本的な考え方

ハミング系

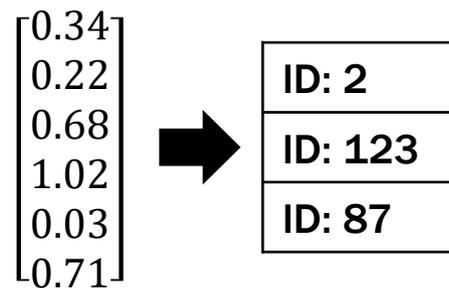


### ➤ 原理

➤ 手法の例

➤ 高速計算

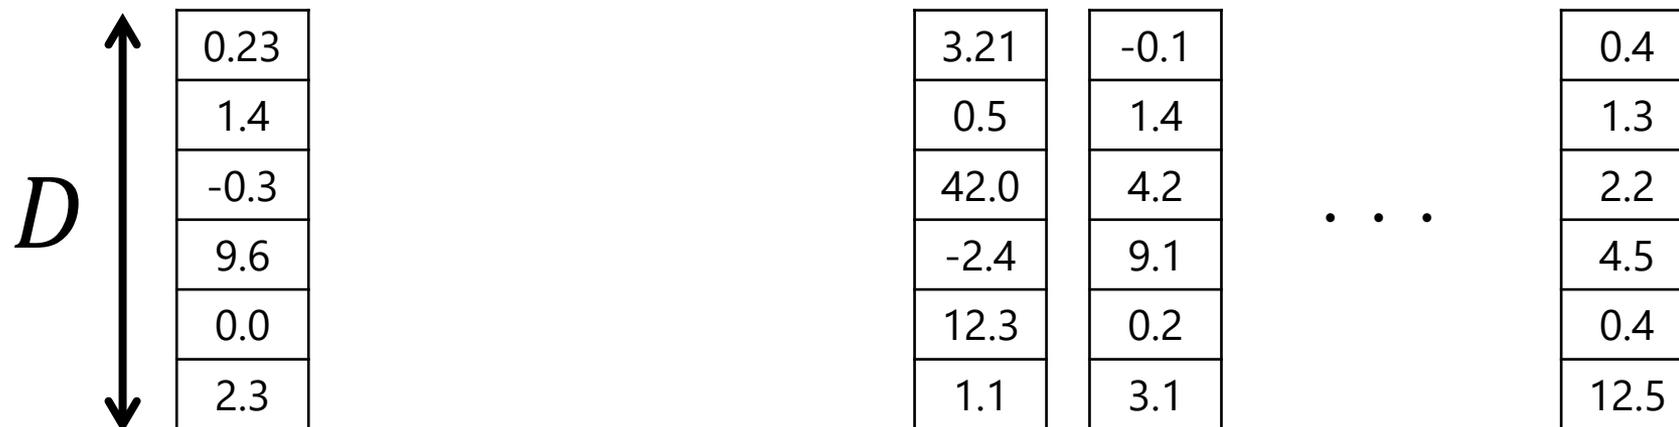
ルックアップ系



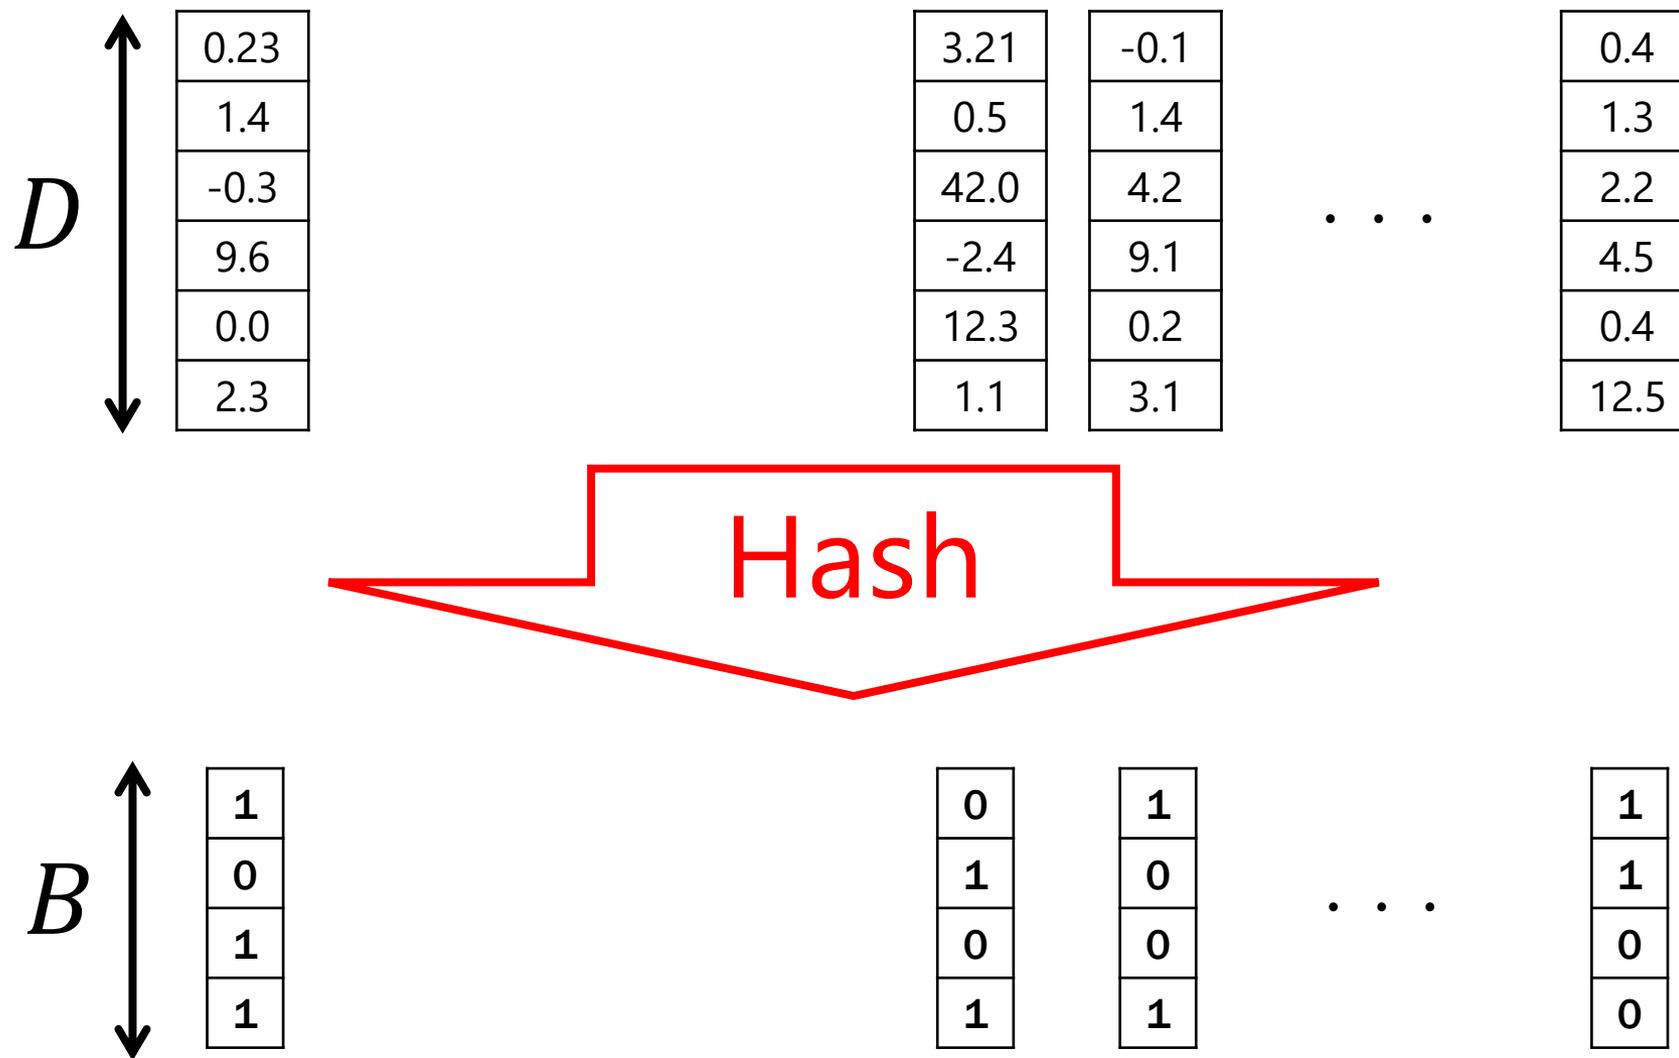
### ➤ 原理

➤ 探索システム

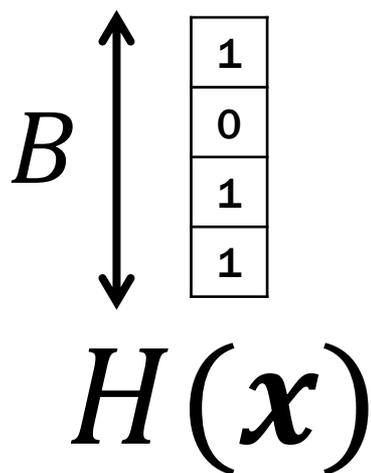
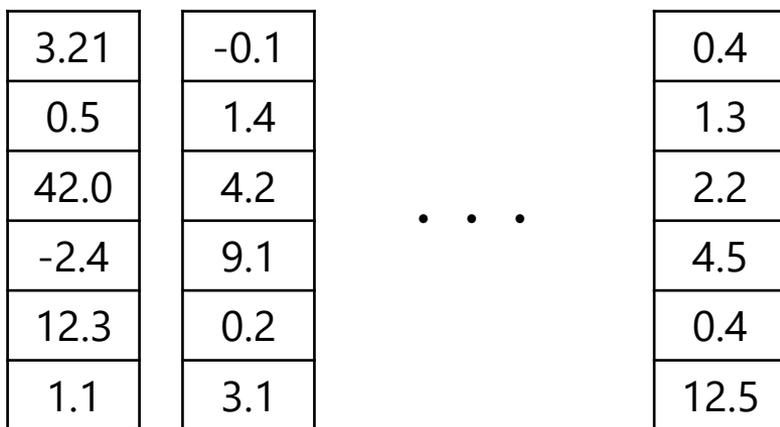
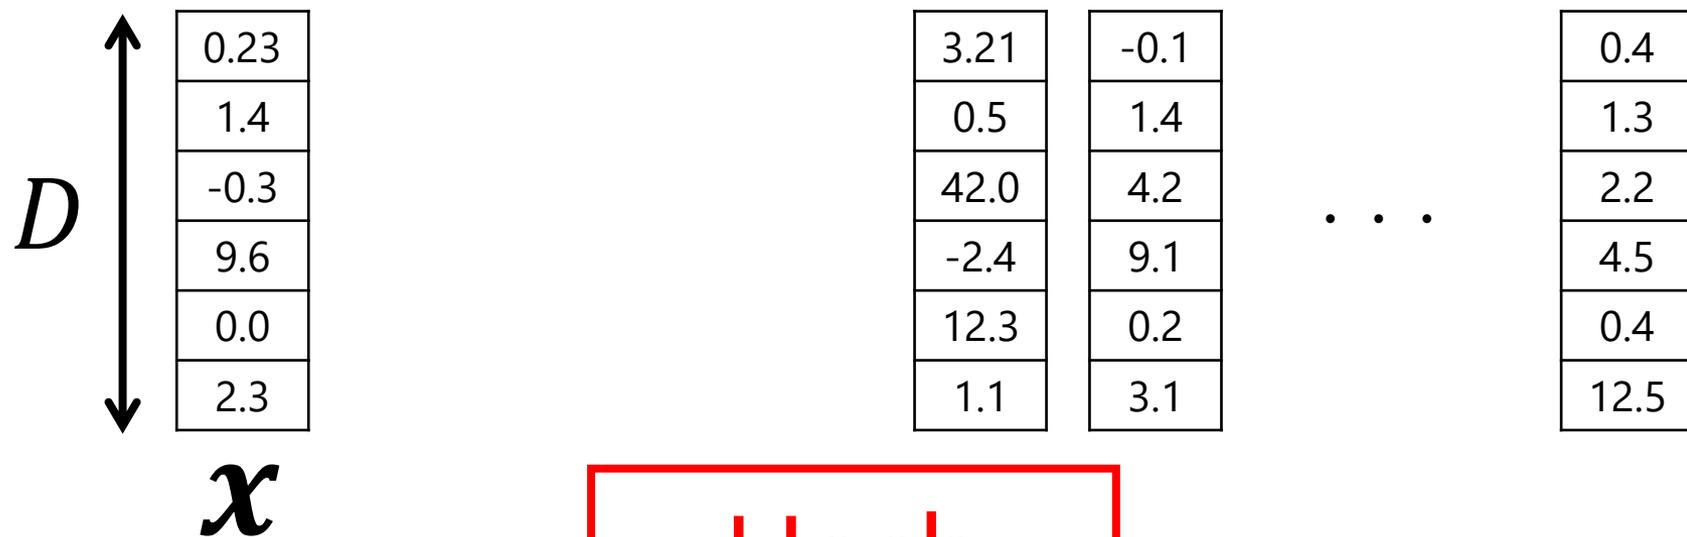
# ハミング系手法：原理



# ハミング系手法：原理

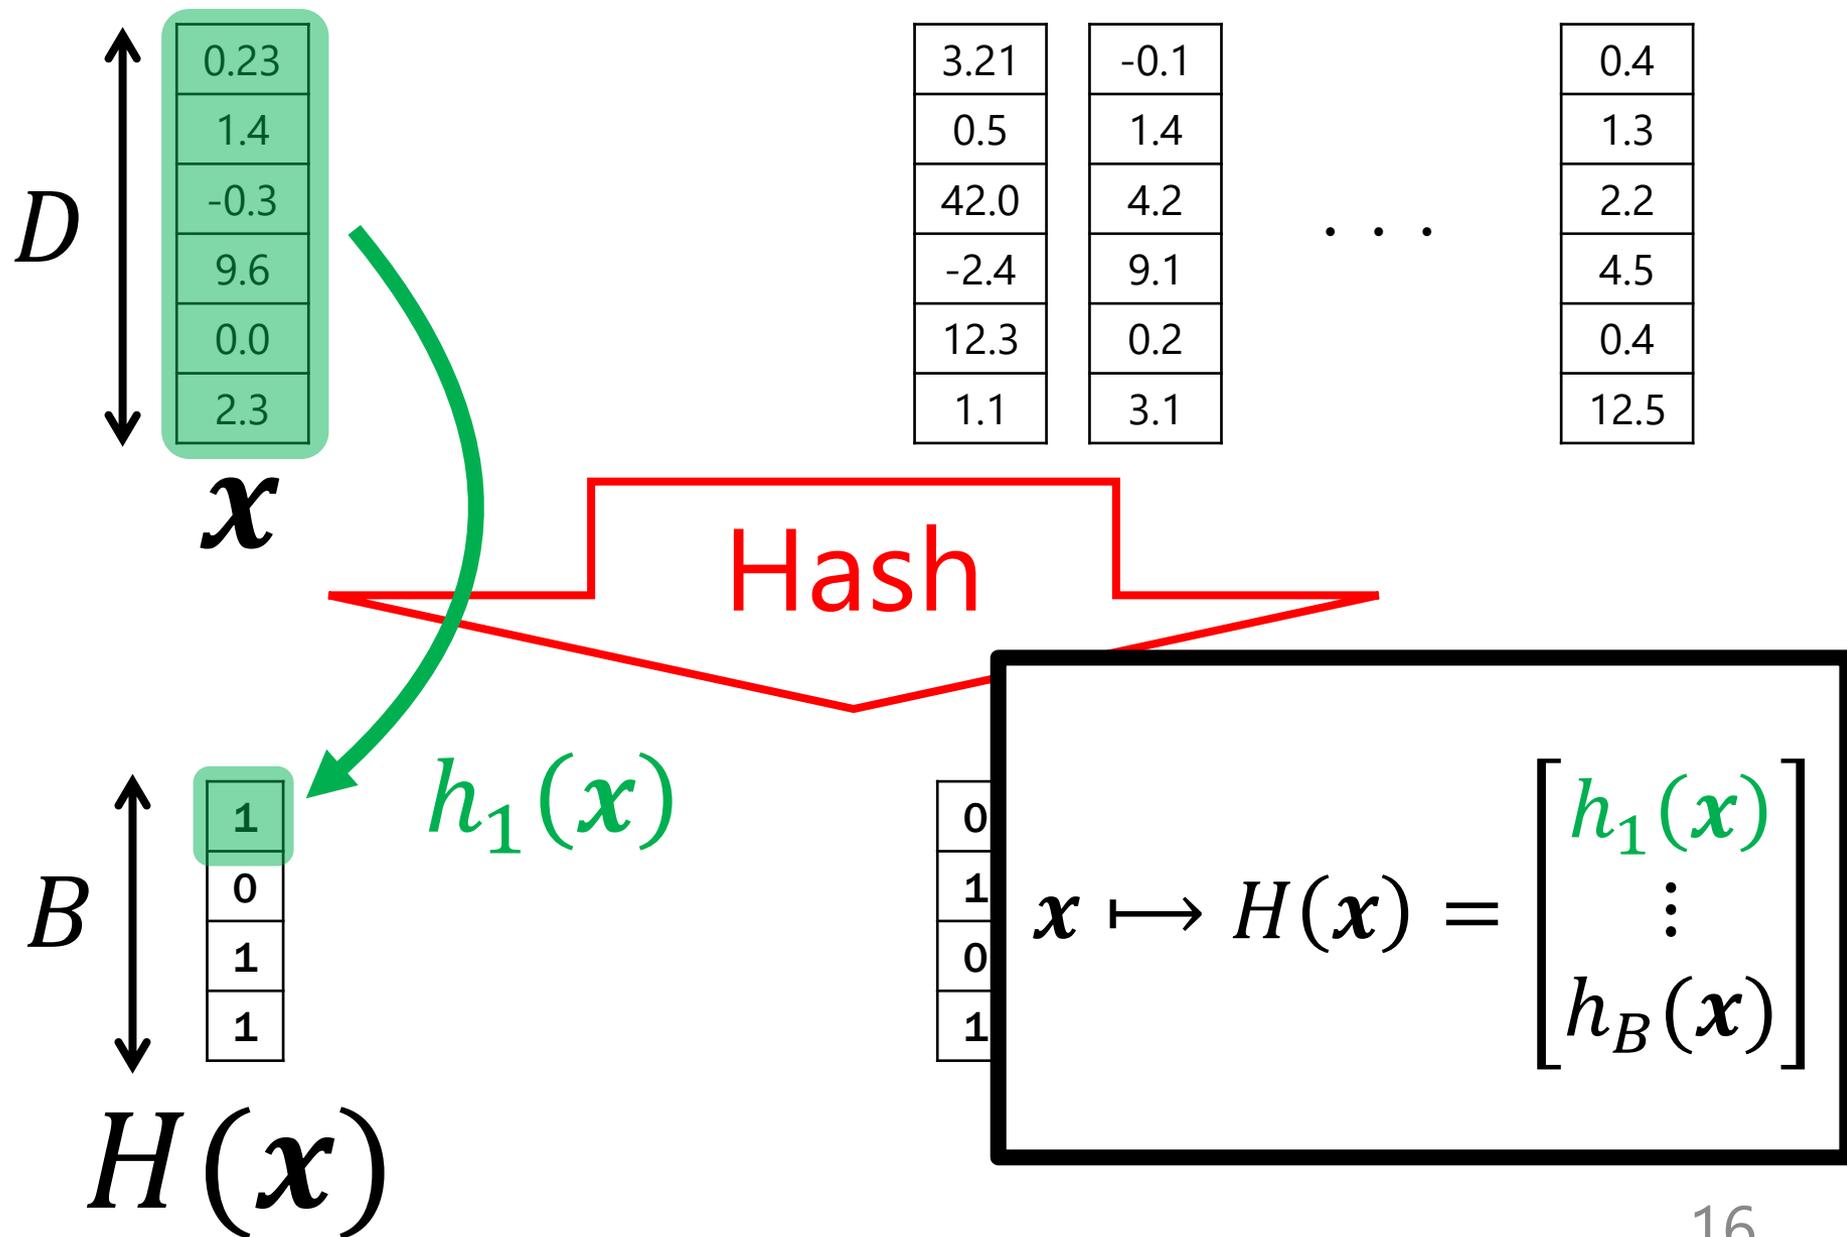


# ハミング系手法：原理

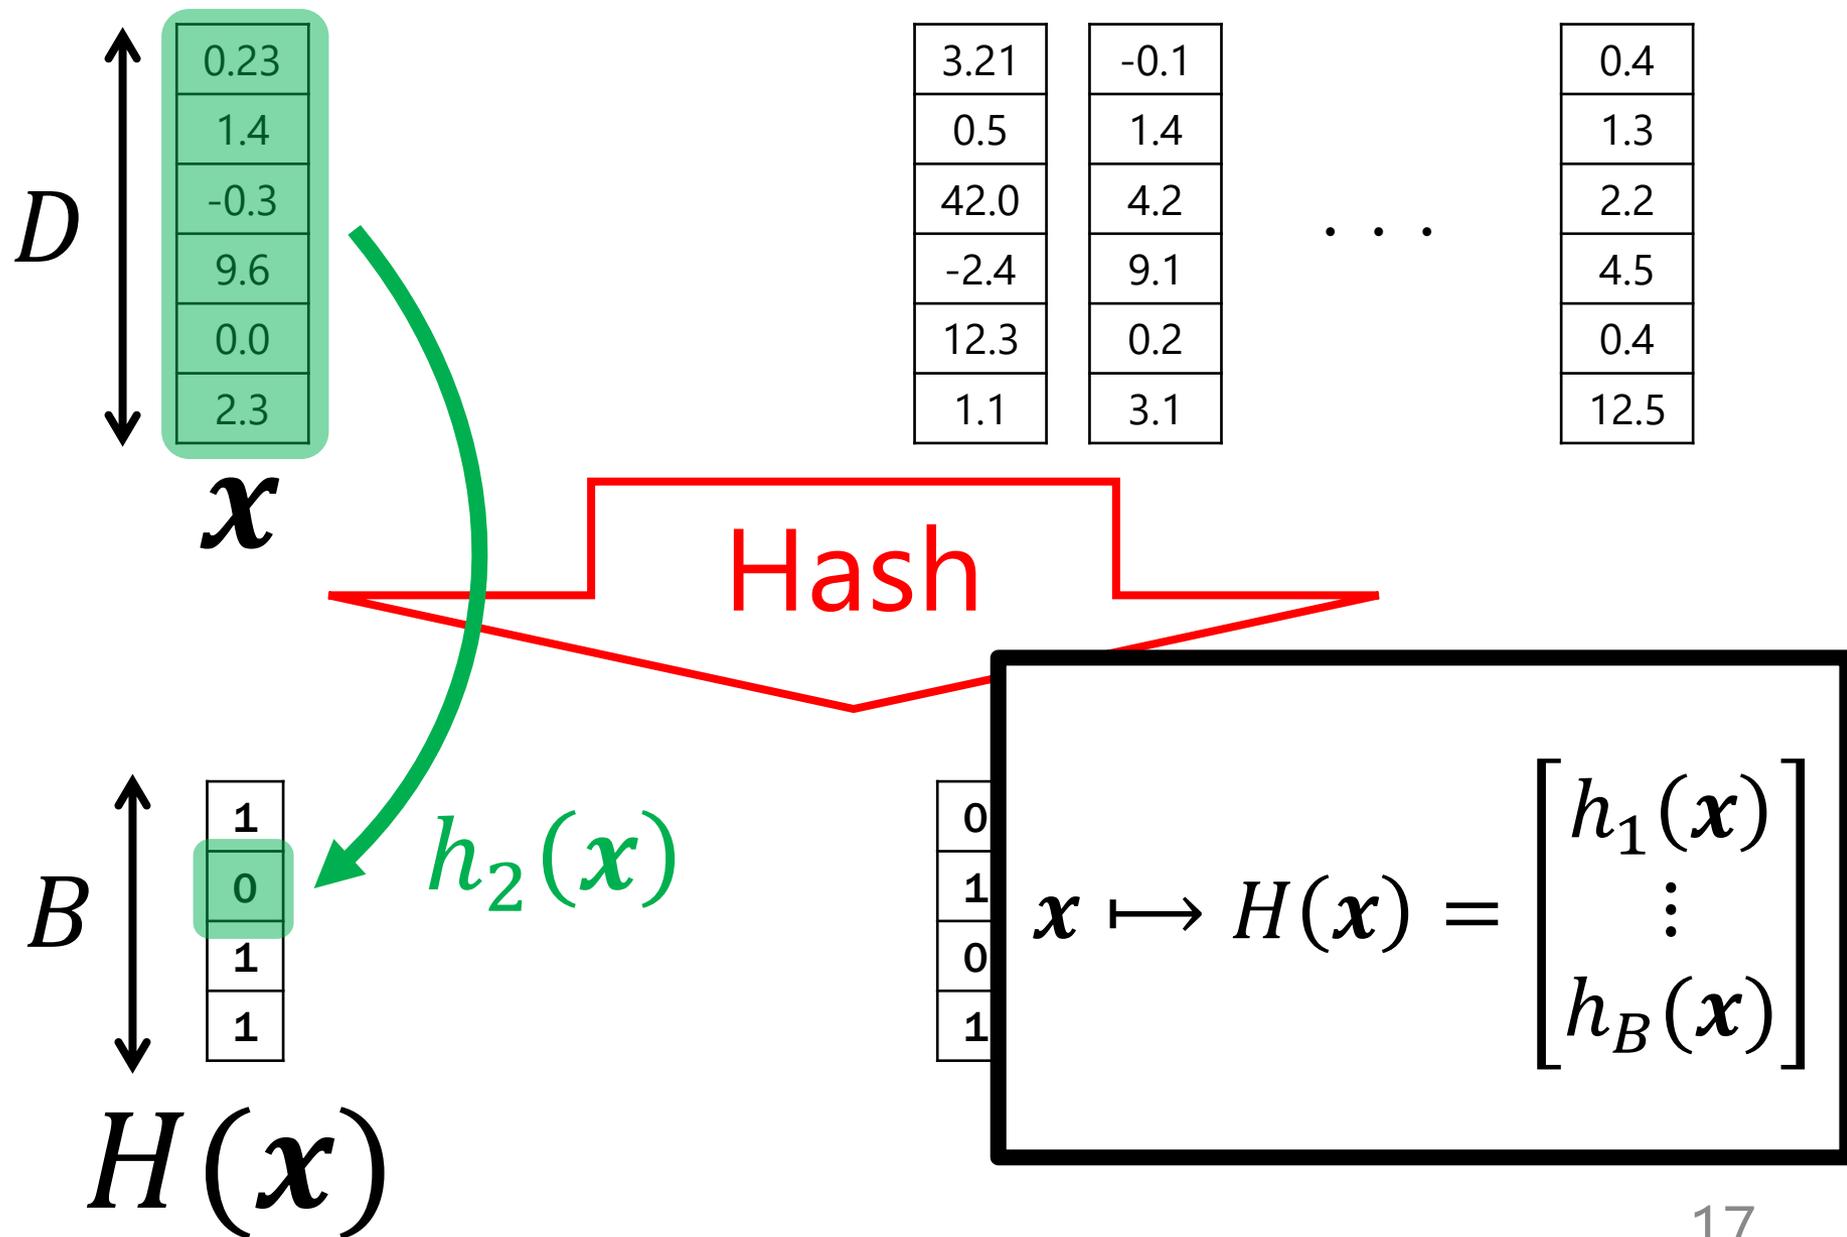


A box containing the hash function equation and a binary vector. The equation is  $\mathbf{x} \mapsto H(\mathbf{x}) = \begin{bmatrix} h_1(\mathbf{x}) \\ \vdots \\ h_B(\mathbf{x}) \end{bmatrix}$ . To the left of the equation is a vertical column of four boxes containing the binary values 0, 1, 0, and 1.

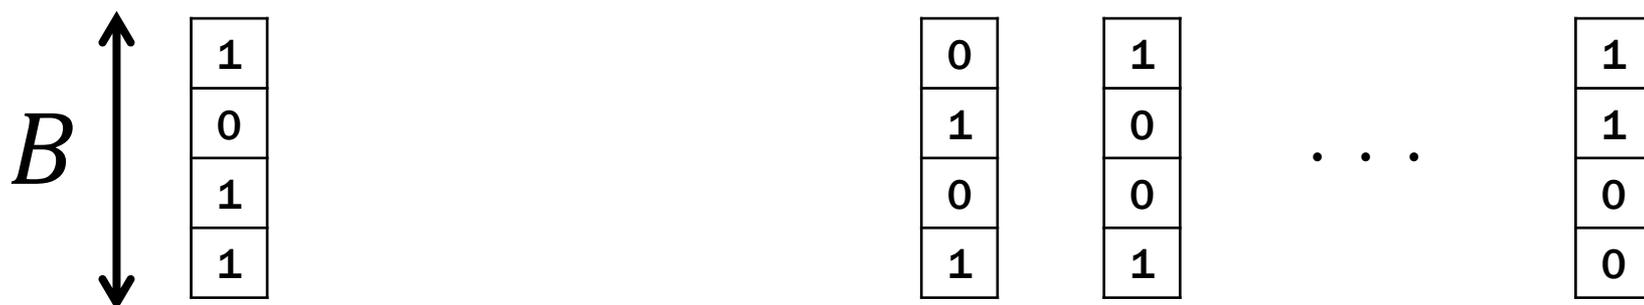
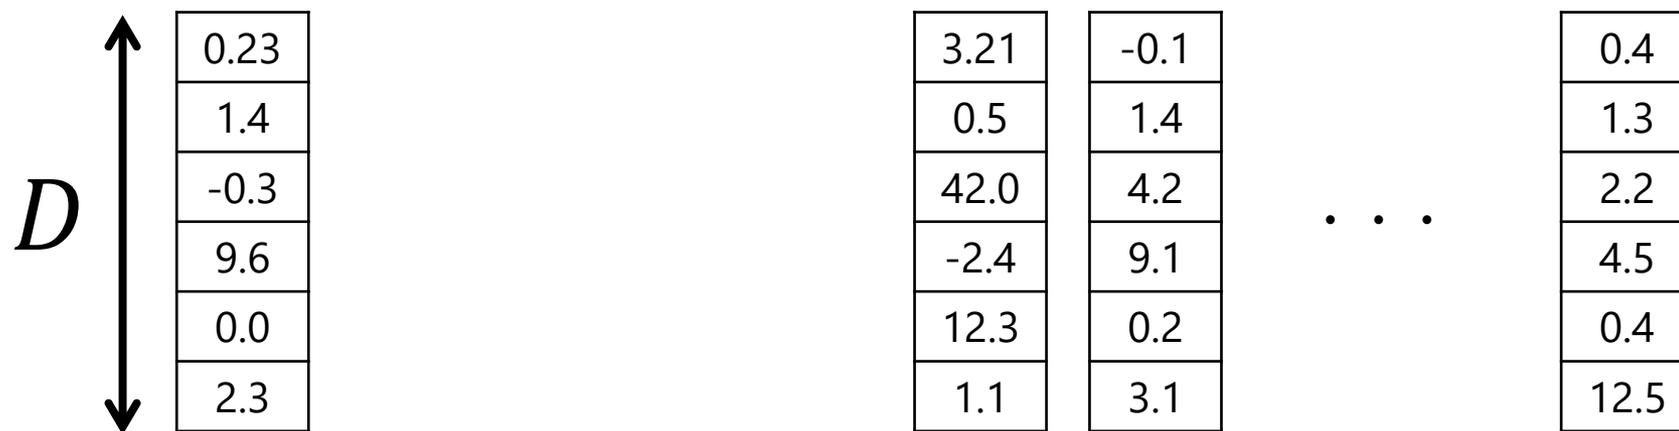
# ハミング系手法：原理



# ハミング系手法：原理

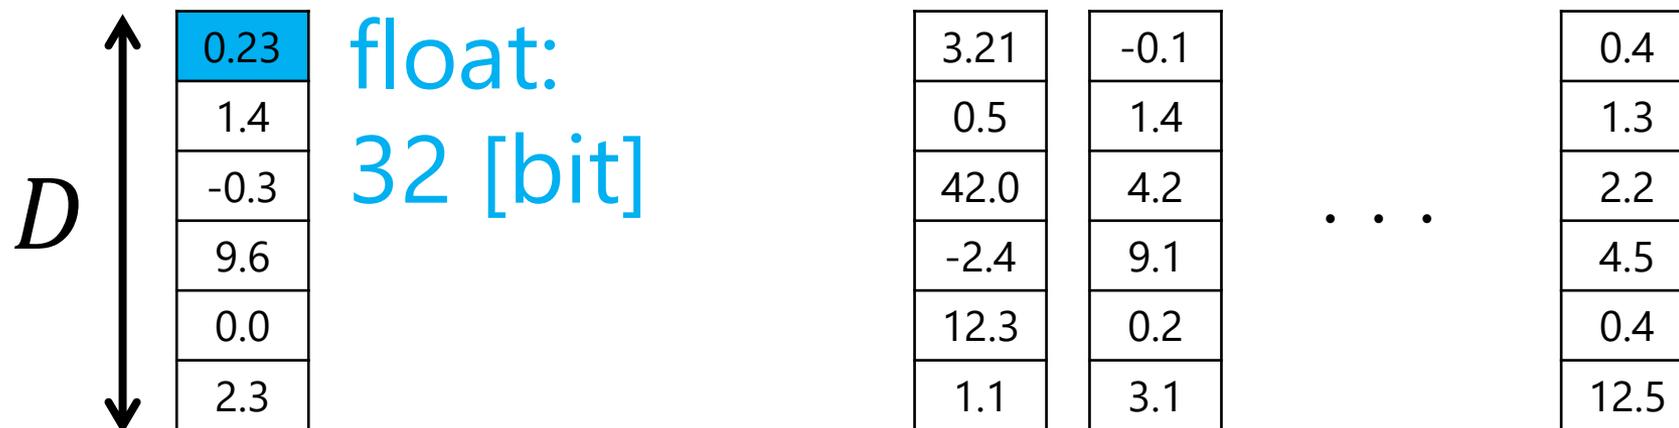


# ハミング系手法：メモリ効率

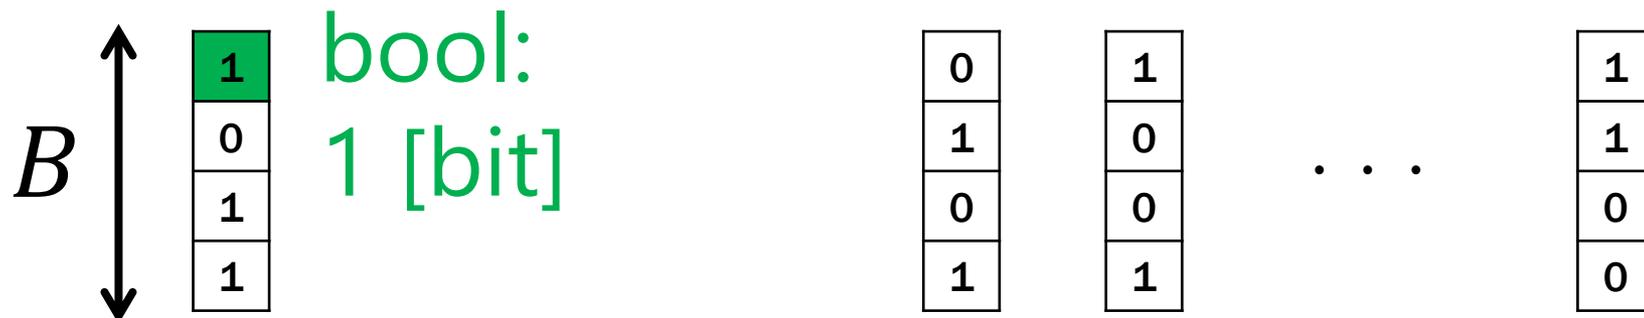


$H(x)$

# ハミング系手法：メモリ効率

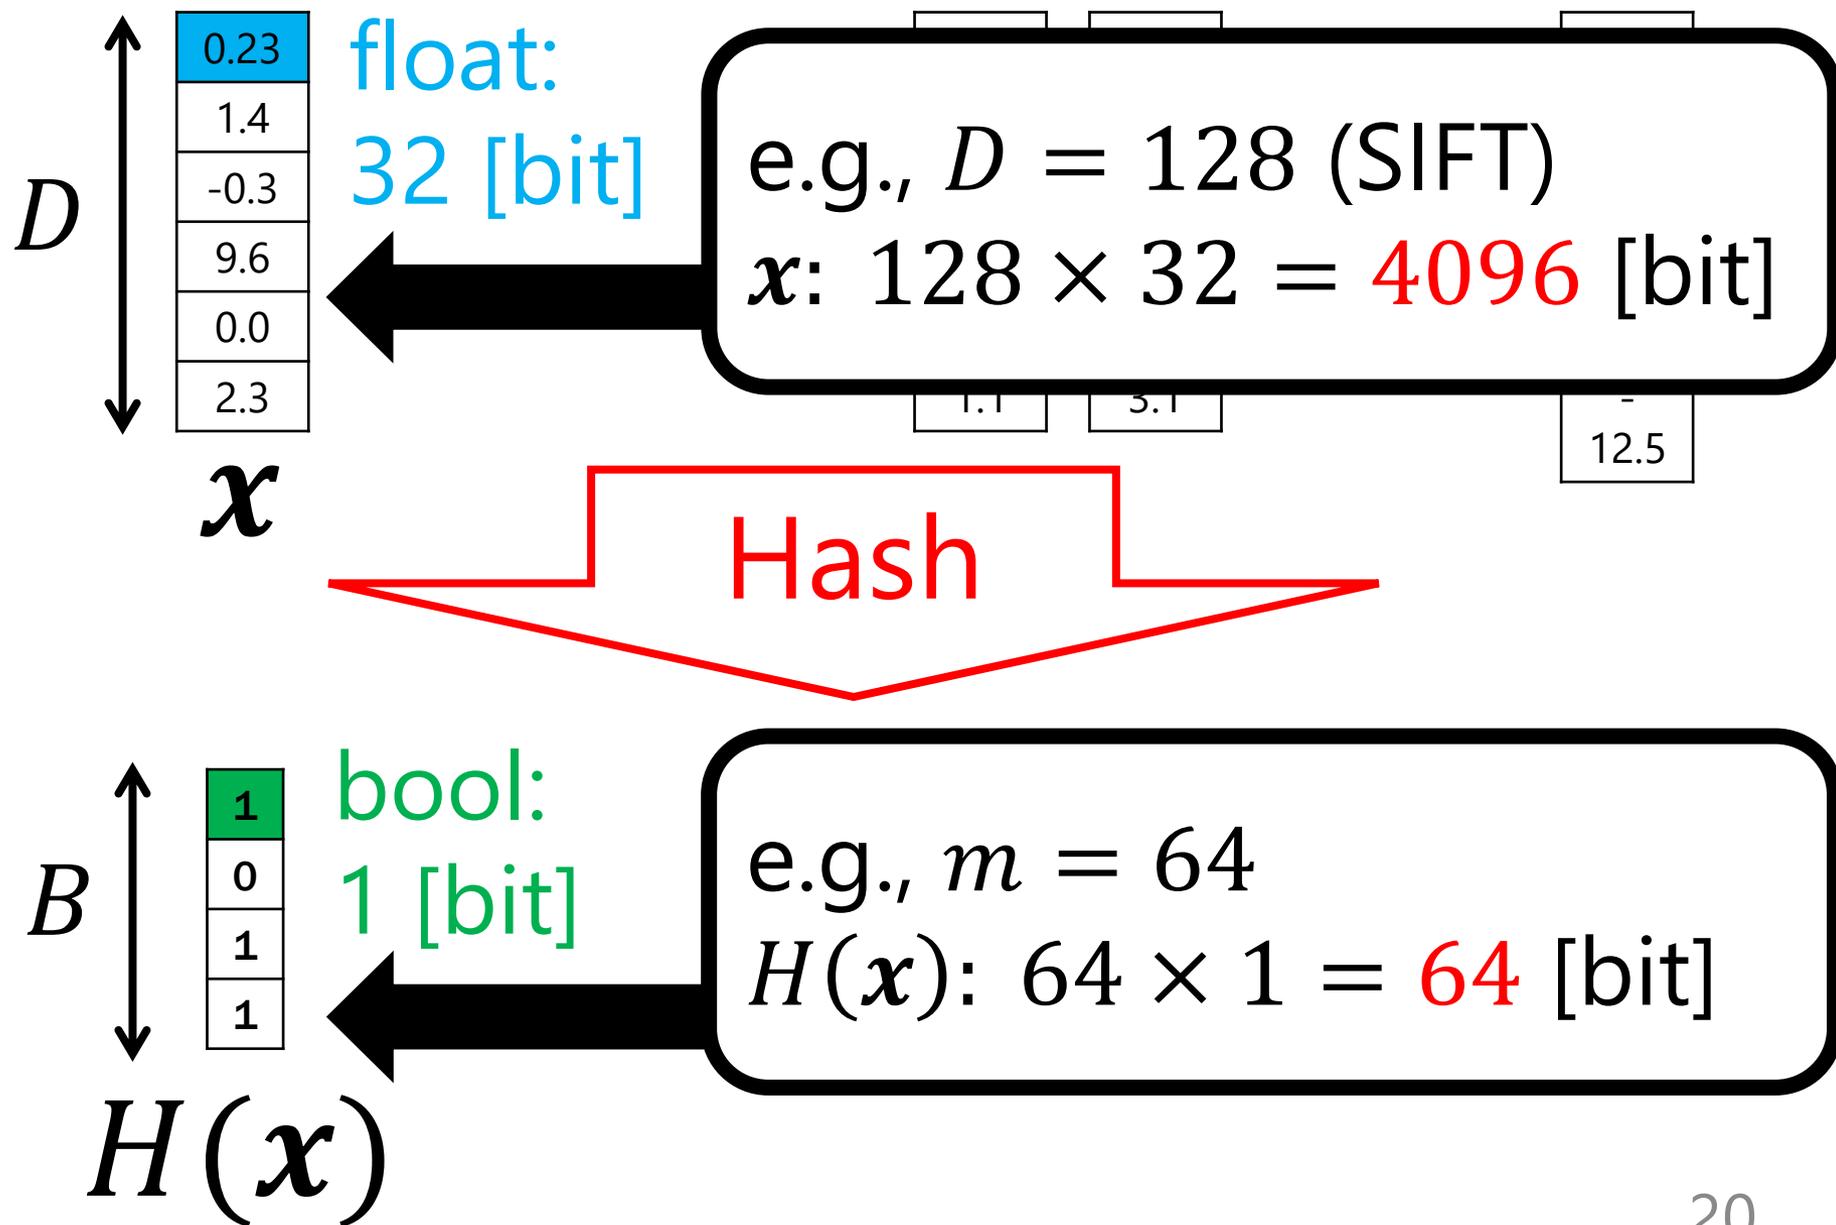


$x$

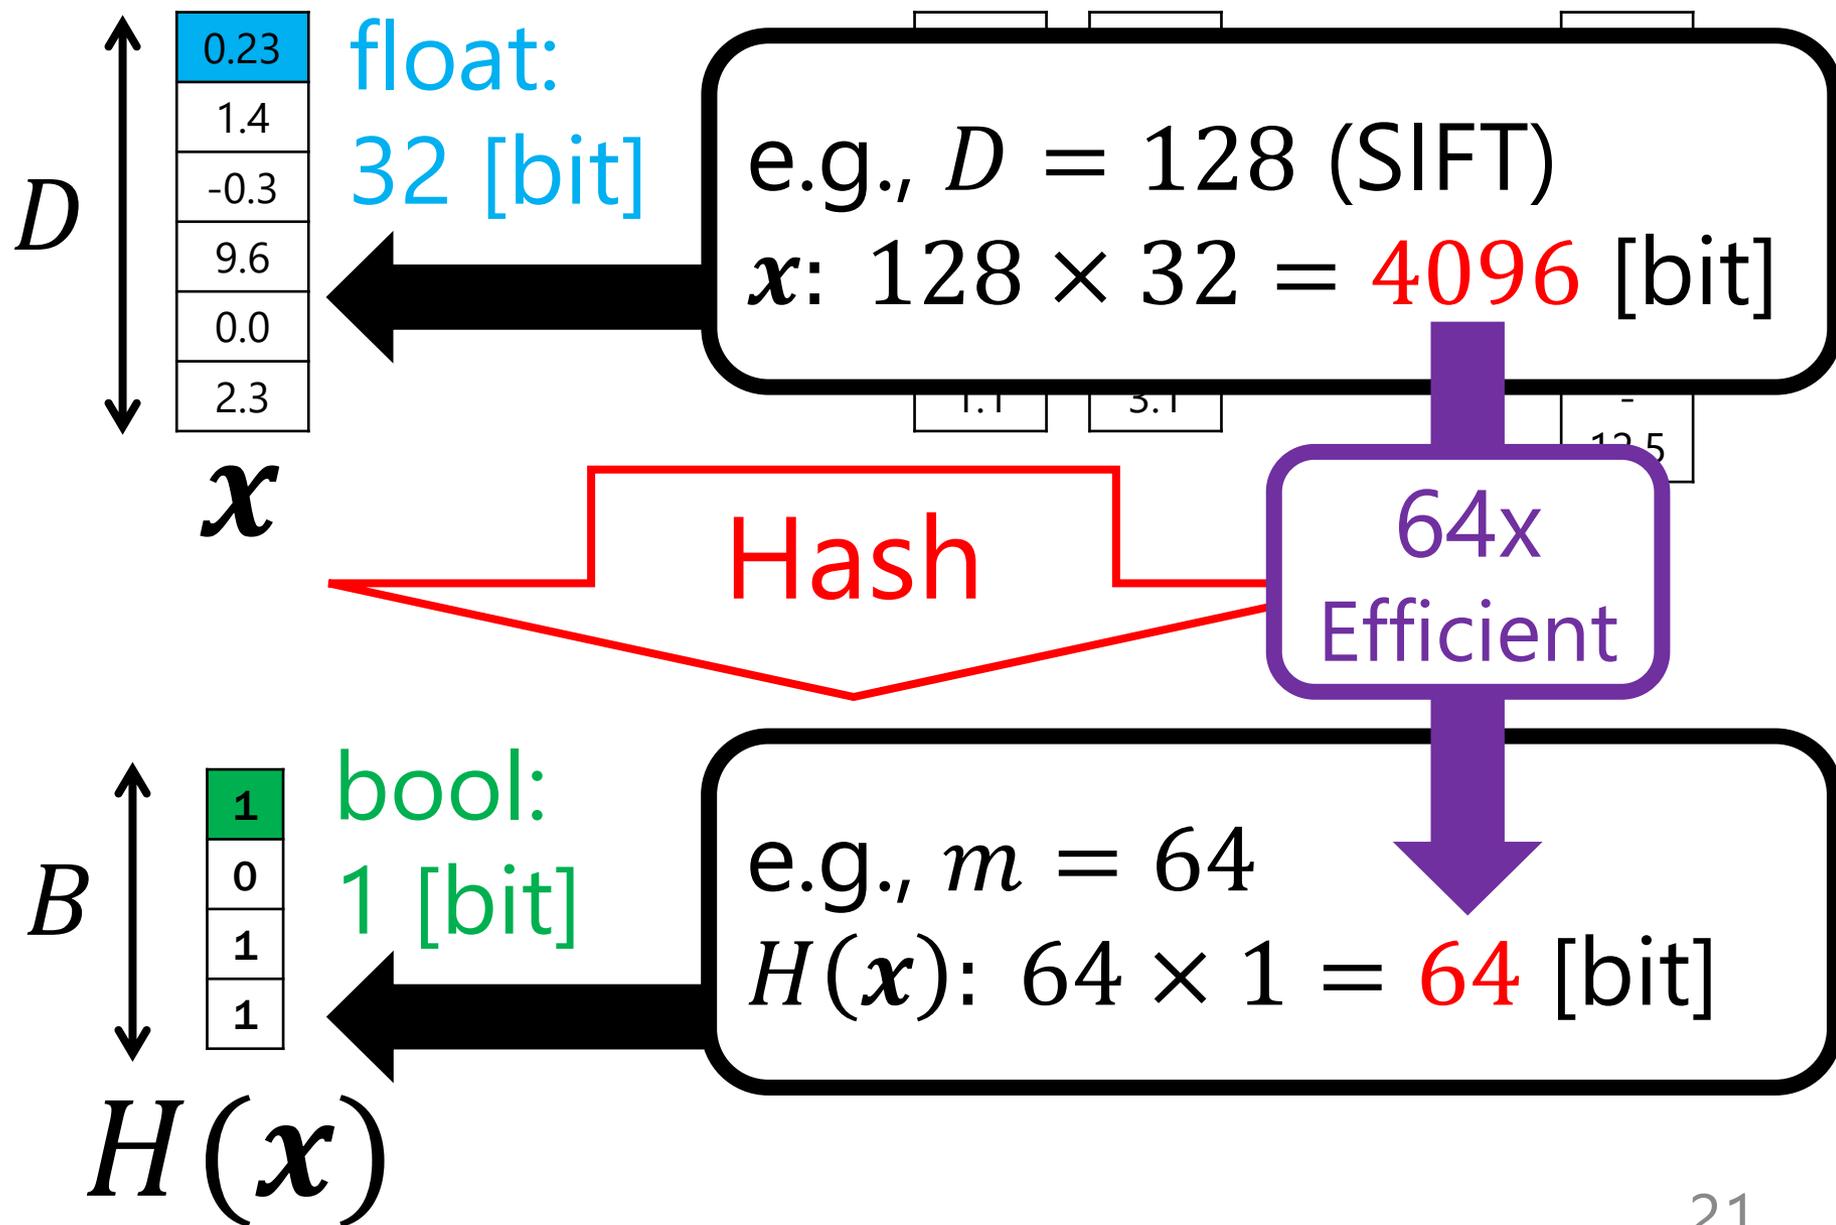


$H(x)$

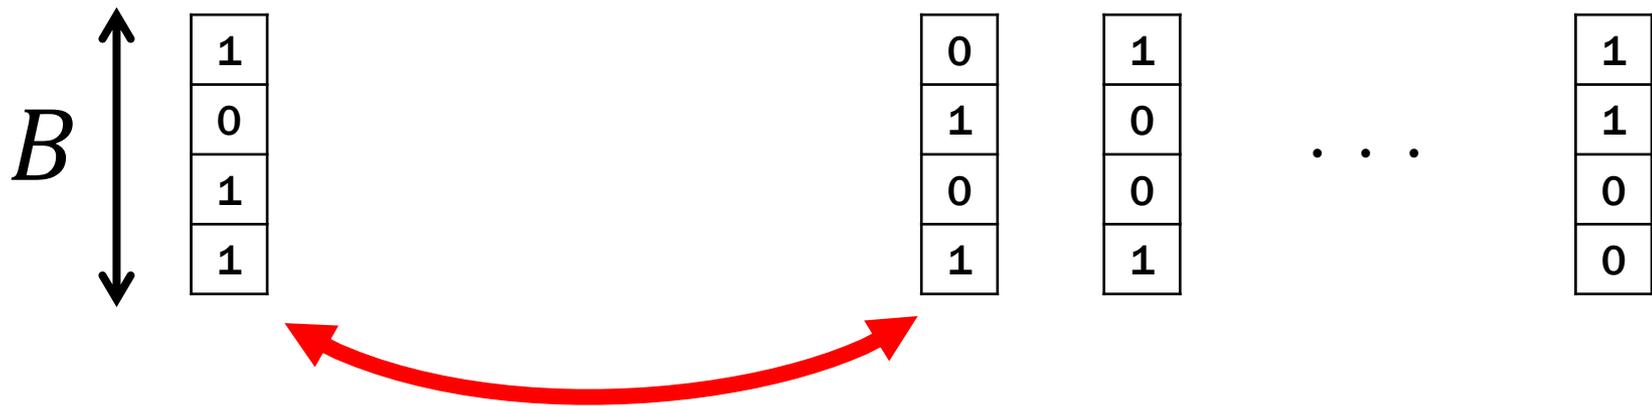
# ハミング系手法：メモリ効率



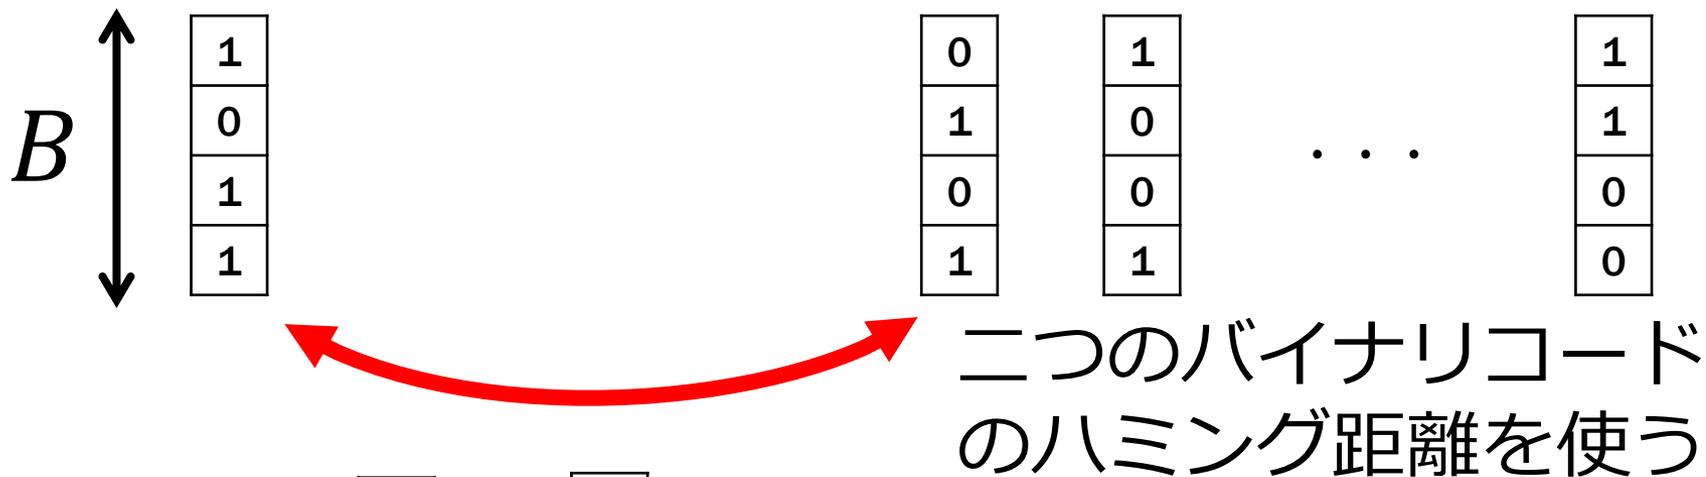
# ハミング系手法：メモリ効率



# ハミング系手法：距離計算

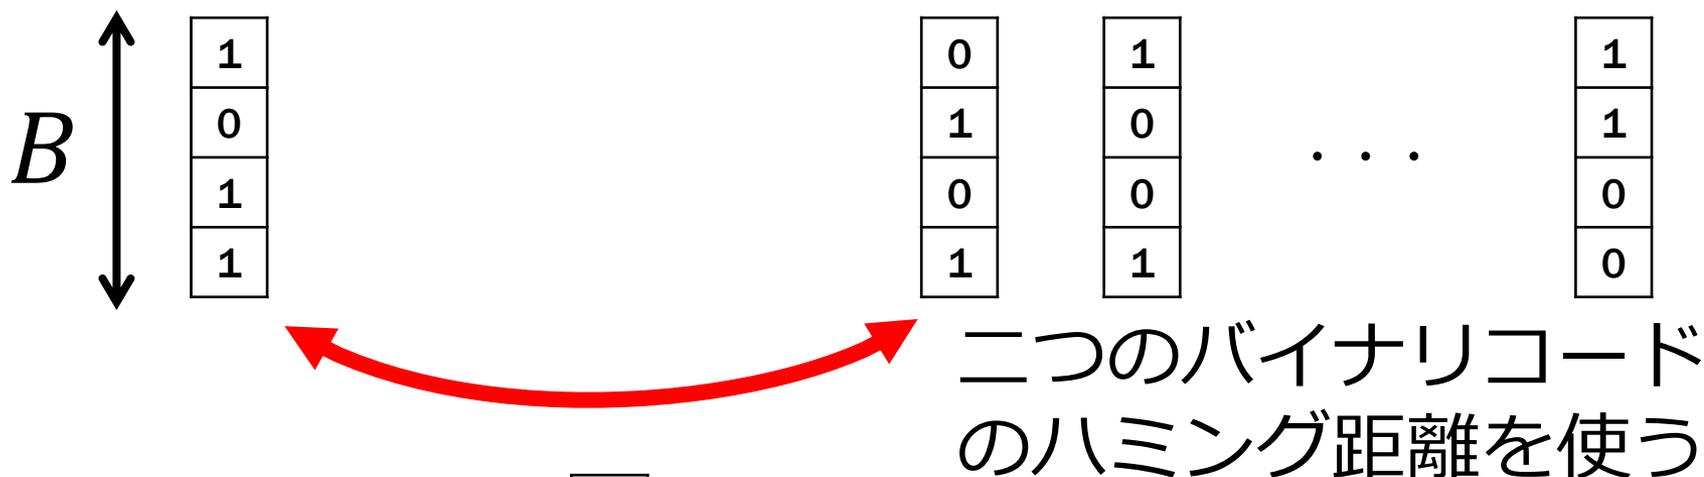


# ハミング系手法：距離計算



$$d_H \left( \begin{array}{|c|} \hline 1 \\ \hline 0 \\ \hline 1 \\ \hline 1 \\ \hline \end{array}, \begin{array}{|c|} \hline 0 \\ \hline 1 \\ \hline 0 \\ \hline 1 \\ \hline \end{array} \right) = 3$$

# ハミング系手法：距離計算



$$d_H \left( \begin{array}{c} 1 \\ 0 \\ 1 \\ 1 \end{array}, \begin{array}{c} 0 \\ 1 \\ 0 \\ 1 \end{array} \right) = 3$$

➡ `_mm_popcnt(`  $\begin{array}{c} 1 \\ 0 \\ 1 \\ 1 \end{array}$  `xor`  $\begin{array}{c} 0 \\ 1 \\ 0 \\ 1 \end{array}$  `)`  $\sim 10$  [ns]

$d_H(\cdot, \cdot)$  は専門の演算命令を使うことで  
高速に計算できる

# ハミング系手法：ハッシュの設計

$$d\left(\begin{array}{|c|} \hline 0.23 \\ \hline 1.4 \\ \hline -0.3 \\ \hline 9.6 \\ \hline 0.0 \\ \hline 2.3 \\ \hline \end{array}, \begin{array}{|c|} \hline -0.1 \\ \hline 1.4 \\ \hline 4.2 \\ \hline 9.1 \\ \hline 0.2 \\ \hline 3.1 \\ \hline \end{array}\right) = 4.61$$

Hash

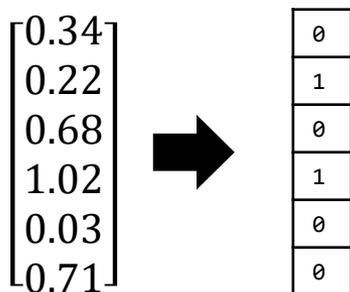
- もし元の距離尺度 $d$ が小さければ, ハミング距離 $d_H$ も小さくなる
- そのようなハッシュを設計したい

$$d_H\left(\begin{array}{|c|} \hline 1 \\ \hline 0 \\ \hline 1 \\ \hline 1 \\ \hline \end{array}, \begin{array}{|c|} \hline 0 \\ \hline 1 \\ \hline 0 \\ \hline 1 \\ \hline \end{array}\right) = 3$$

# ショートコードによる近似最近傍探索

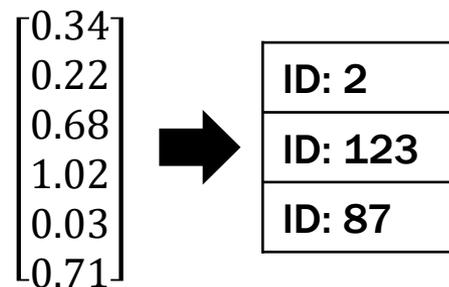
## ➤ 基本的な考え方

ハミング系



- 原理
- 手法の例
- 高速計算

ルックアップ系



- 原理
- 探索システム

# ハミング系手法の分類

データ非依存：訓練データを用いない

ランダム射影

データ依存：訓練データを用いる

➤ 教師無し：ラベル無し訓練データを用いる

例：訓練画像

Spectral Hashing

➤ 教師あり：ラベル付き訓練データを用いる

例：猫の画像，犬の画像，etc

ユークリッド距離ではなく，意味を考慮した距離を表現する

➤ 半教師あり：ラベル無しおよびラベル付き訓練データを用いる

# ハミング系手法の例：ランダム行列

0.23
1.4
-0.3
9.6
0.0
2.3

# ハミング系手法の例：ランダム行列

$$\begin{bmatrix} 1.2 & 0.3 & 0.2 & 4.1 & 2.8 & 34.1 \\ -3.1 & 7.5 & -0.2 & 3.4 & 12.3 & -9.6 \\ -5.6 & -4.3 & 12.3 & -5.6 & 7.1 & 5.6 \\ 7.8 & 9.6 & 0.5 & 2.3 & -9.9 & 2.3 \end{bmatrix} \begin{array}{|c|} \hline 0.23 \\ \hline 1.4 \\ \hline -0.3 \\ \hline 9.6 \\ \hline 0.0 \\ \hline 2.3 \\ \hline \end{array}$$

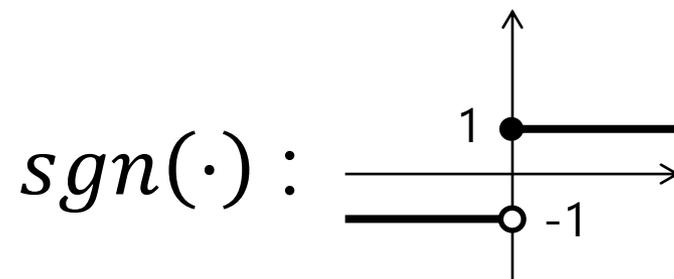
## (1) ランダム射影

# ハミング系手法の例：ランダム行列

$$\text{sgn}\left(\begin{bmatrix} 1.2 & 0.3 & 0.2 & 4.1 & 2.8 & 34.1 \\ -3.1 & 7.5 & -0.2 & 3.4 & 12.3 & -9.6 \\ -5.6 & -4.3 & 12.3 & -5.6 & 7.1 & 5.6 \\ 7.8 & 9.6 & 0.5 & 2.3 & -9.9 & 2.3 \end{bmatrix} \begin{array}{|c|} \hline 0.23 \\ \hline 1.4 \\ \hline -0.3 \\ \hline 9.6 \\ \hline 0.0 \\ \hline 2.3 \\ \hline \end{array}\right) = \begin{array}{|c|} \hline 1 \\ \hline -1 \\ \hline 1 \\ \hline 1 \\ \hline \end{array}$$

(1) ランダム射影

(2) 閾値処理



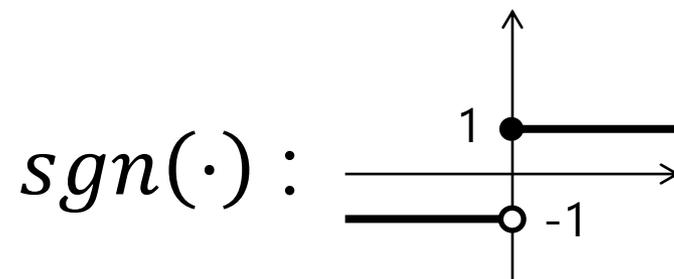
注：バイナリコードの値として{1, -1}を採用するか{1, 0}を採用するかは任意（変換可能）

# ハミング系手法の例：ランダム行列

$$\text{sgn} \left( \begin{bmatrix} 1.2 & 0.3 & 0.2 & 4.1 & 2.8 & 34.1 \\ -3.1 & 7.5 & -0.2 & 3.4 & 12.3 & -9.6 \\ -5.6 & -4.3 & 12.3 & -5.6 & 7.1 & 5.6 \\ 7.8 & 9.6 & 0.5 & 2.3 & -9.9 & 2.3 \end{bmatrix} \begin{bmatrix} 0.23 \\ 1.4 \\ -0.3 \\ 9.6 \\ 0.0 \\ 2.3 \end{bmatrix} \right) = \begin{bmatrix} 1 \\ -1 \\ 1 \\ 1 \end{bmatrix}$$

(1) ランダム射影

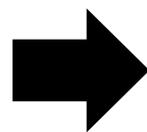
(2) 閾値処理



注：バイナリコードの値として{1, -1}を採用するか{1, 0}を採用するかは任意（変換可能）

😊 シンプル

😞 精度が低い



「データの分布」  
を利用しよう

# ハミング系手法の分類

データ非依存：訓練データを用いない

ランダム射影

データ依存：訓練データを用いる

➤ 教師無し：ラベル無し訓練データを用いる

例：訓練画像

Spectral Hashing

➤ 教師あり：ラベル付き訓練データを用いる

例：猫の画像，犬の画像，etc

ユークリッド距離ではなく，意味を考慮した距離を表現する

➤ 半教師あり：ラベル無しおよびラベル付き訓練データを用いる

# ハミング系手法の例：Spectral Hashing

原則：

- 元の距離尺度 $d$ が小さければ、ハミング距離 $d_H$ も小さくなる
- そのような「変換」を設計したい

+

無駄のないコードを作成したいという意図から条件を追加：

- 変換後の各ビットがバランスしている
  - 各ビットは $\{-1, +1\}$ を半々ずつもつ
- 各ビットには相関が無い

既知：元のベクトル

$$\begin{bmatrix} 0.54 \\ 2.35 \\ 0.82 \\ 0.42 \end{bmatrix} \begin{bmatrix} 1.34 \\ 0.99 \\ 1.47 \\ 0.34 \end{bmatrix} \dots \begin{bmatrix} 0.76 \\ 0.45 \\ 1.62 \\ 1.42 \end{bmatrix}$$

$\boldsymbol{x}_1$     $\boldsymbol{x}_2$     $\boldsymbol{x}_N$



未知：ショートコード

$$\begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix} \dots \begin{bmatrix} -1 \\ 1 \\ 1 \end{bmatrix}$$

$\boldsymbol{b}_1$     $\boldsymbol{b}_2$     $\boldsymbol{b}_N$

$B$

既知：元のベクトル

$$\begin{array}{ccc}
 \begin{bmatrix} 0.54 \\ 2.35 \\ 0.82 \\ 0.42 \end{bmatrix} & \begin{bmatrix} 1.34 \\ 0.99 \\ 1.47 \\ 0.34 \end{bmatrix} & \dots & \begin{bmatrix} 0.76 \\ 0.45 \\ 1.62 \\ 1.42 \end{bmatrix} \\
 \mathbf{x}_1 & \mathbf{x}_2 & & \mathbf{x}_N
 \end{array}$$



未知：ショートコード

$$\begin{array}{ccc}
 \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} & \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix} & \dots & \begin{bmatrix} -1 \\ 1 \\ 1 \end{bmatrix} \\
 \mathbf{b}_1 & \mathbf{b}_2 & & \mathbf{b}_N
 \end{array}
 \begin{array}{c} \updownarrow \\ B \end{array}$$

元のベクトル間の類似度行列：

$$W \in \mathbb{R}^{N \times N}, \quad W_{ij} = e^{\frac{-\|x_i - x_j\|^2}{\epsilon^2}}$$

既知：元のベクトル

未知：ショートコード

元のベクトル間の類似度行列：

$$\begin{bmatrix} 0.54 \\ 2.35 \\ 0.82 \\ 0.42 \end{bmatrix} \begin{bmatrix} 1.34 \\ 0.99 \\ 1.47 \\ 0.34 \end{bmatrix} \cdots \begin{bmatrix} 0.76 \\ 0.45 \\ 1.62 \\ 1.42 \end{bmatrix}$$

$\mathbf{x}_1 \quad \mathbf{x}_2 \quad \mathbf{x}_N$

変換

$$\begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix} \cdots \begin{bmatrix} -1 \\ 1 \\ 1 \end{bmatrix}$$

$\mathbf{b}_1 \quad \mathbf{b}_2 \quad \mathbf{b}_N$

$B$

$$W \in \mathbb{R}^{N \times N}, \quad W_{ij} = e^{\frac{-\|x_i - x_j\|^2}{\epsilon^2}}$$

次の最適化問題を解くことで、未知のショートコードを求める

$$\min_{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_N} \sum_{i,j} W_{ij} \|\mathbf{b}_i - \mathbf{b}_j\|^2$$

$\mathbf{b}_i$ と $\mathbf{b}_j$ を近くする（と、この最適化問題の良い解になる）

$x_i$ と $x_j$ の類似度が大きいときは・・・

s.t.

$$\sum_i \mathbf{b}_i = \mathbf{0}$$

ビットは  
バランス

$$\frac{1}{N} \sum_i \mathbf{b}_i \mathbf{b}_i^T = I$$

ビットは  
無相関

$$\mathbf{b}_i \in \{-1, 1\}^B, \forall i$$

ビットは  
バイナリ

既知：元のベクトル

未知：ショートコード

元のベクトル間の類似度行列：

$$\begin{bmatrix} 0.54 \\ 2.35 \\ 0.82 \\ 0.42 \end{bmatrix} \begin{bmatrix} 1.34 \\ 0.99 \\ 1.47 \\ 0.34 \end{bmatrix} \cdots \begin{bmatrix} 0.76 \\ 0.45 \\ 1.62 \\ 1.42 \end{bmatrix}$$

$\mathbf{x}_1 \quad \mathbf{x}_2 \quad \mathbf{x}_N$



$$\begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix} \cdots \begin{bmatrix} -1 \\ 1 \\ 1 \end{bmatrix}$$

$\mathbf{b}_1 \quad \mathbf{b}_2 \quad \mathbf{b}_N$

$B$

$$W \in \mathbb{R}^{N \times N}, \quad W_{ij} = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\epsilon^2}}$$

次の最適化問題を解くことで、未知のショートコードを求める

$$\min \sum_{i,j} W_{ij} \|\mathbf{b}_i - \mathbf{b}_j\|^2$$

ビットはバイナリであるという条件を取り除く  
 (スペクトラル緩和) と、グラフラプラシアン  
 の一般化固有値問題として解ける [Weiss+, NIPS08]

$$\sum_i \mathbf{b}_i = \mathbf{0}$$

ビットは  
バランス

$$\frac{1}{N} \sum_i \mathbf{b}_i \mathbf{b}_i^T = I$$

ビットは  
無相関

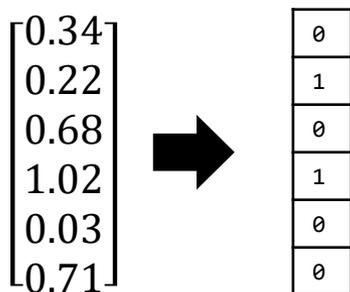
$$\mathbf{b}_i \in \{-1, 1\}^B, \forall i$$

ビットは  
バイナリ

# ショートコードによる近似最近傍探索

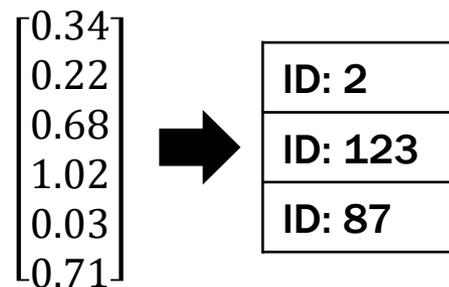
## ➤ 基本的な考え方

ハミング系



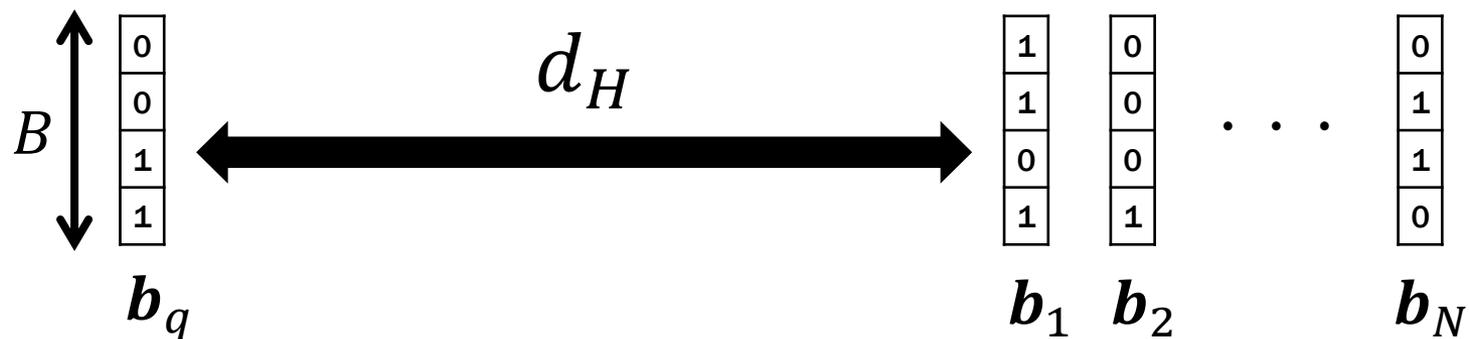
- 原理
- 手法の例
- 高速計算

ルックアップ系



- 原理
- 探索システム

# ハミング系手法の高速計算

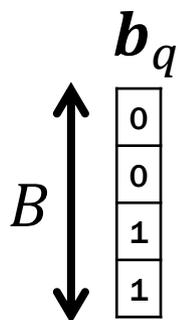
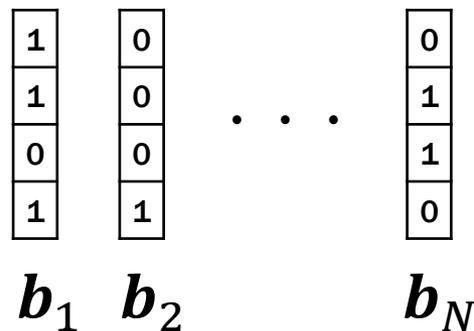


`uint4 query`

`vec<uint4> codes`

- ハミング距離による線形探索は高速だが、計算量は $O(BN)$
- 依然 $N$ に対し線形であり、 $N$ が大きいと遅い
- **ハッシュテーブル**を用いて、全く同様の結果を高速に計算出来る

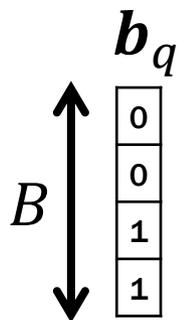
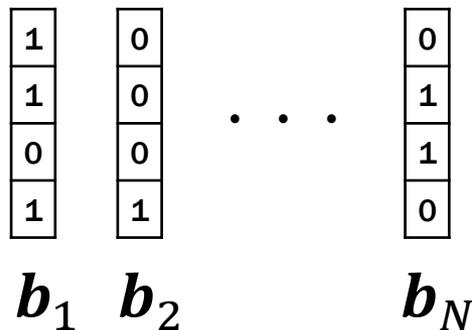
# ハミング系手法の高速計算：データ登録



uint4 query

# ハミング系手法の高速計算：データ登録

[0000]から[1111]までの値を持つ  
エントリを用意しておく



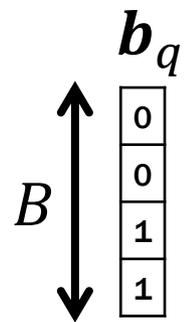
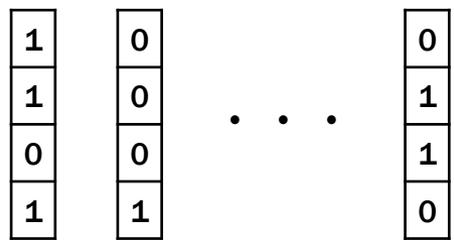
uint4 query

$B$

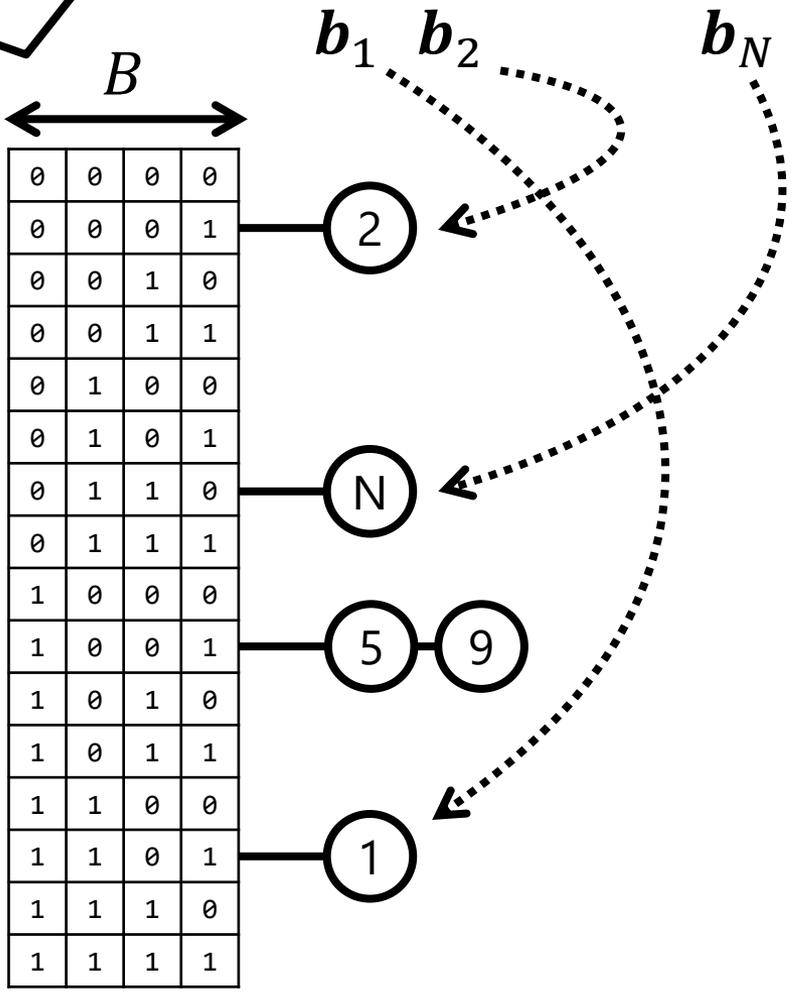
0	0	0	0
0	0	0	1
0	0	1	0
0	0	1	1
0	1	0	0
0	1	0	1
0	1	1	0
0	1	1	1
1	0	0	0
1	0	0	1
1	0	1	0
1	0	1	1
1	1	0	0
1	1	0	1
1	1	1	0
1	1	1	1

# ハミング系手法の高速計算：データ登録

[0000]から[1111]までの値を持つ  
エントリを用意しておく



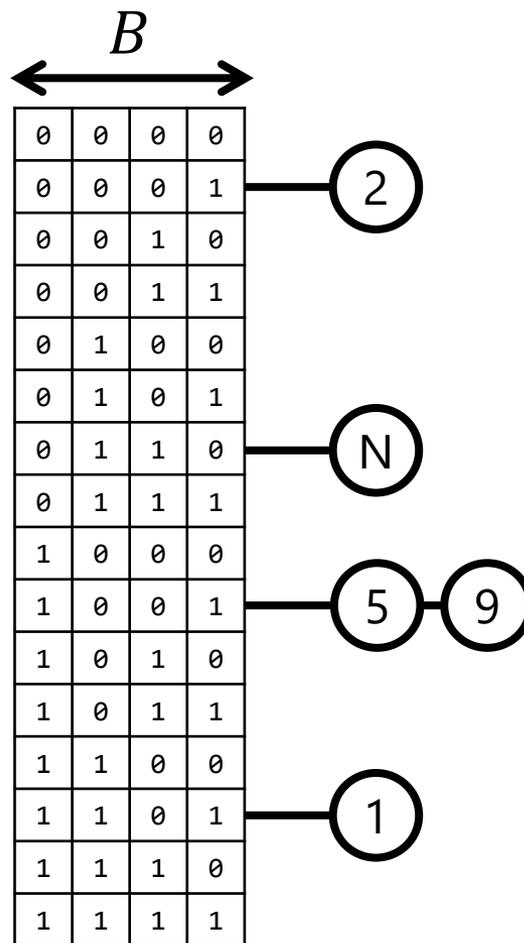
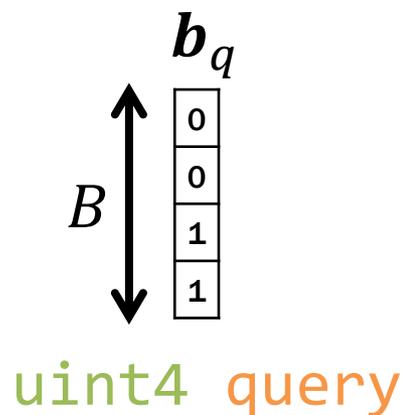
uint4 query



各コードについて、それ  
自身をエントリとして、  
番号を挿入

# ハミング系手法の高速計算：探索

`vec<list<int>> table`

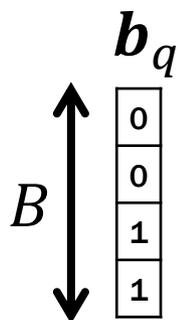


# ハミング系手法の高速計算：探索

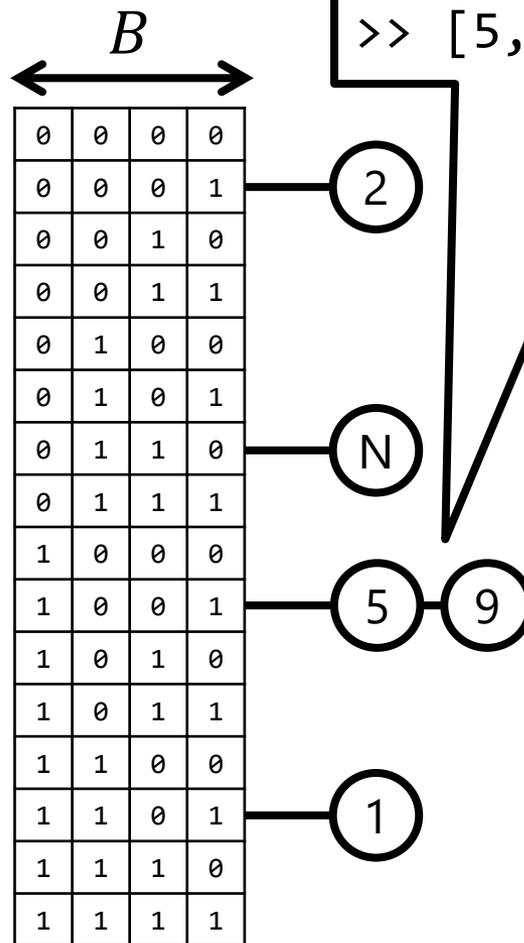
`vec<list<int>> table`

例：

```
list<int> v = table[9];  
Print(v);  
>> [5, 9]
```



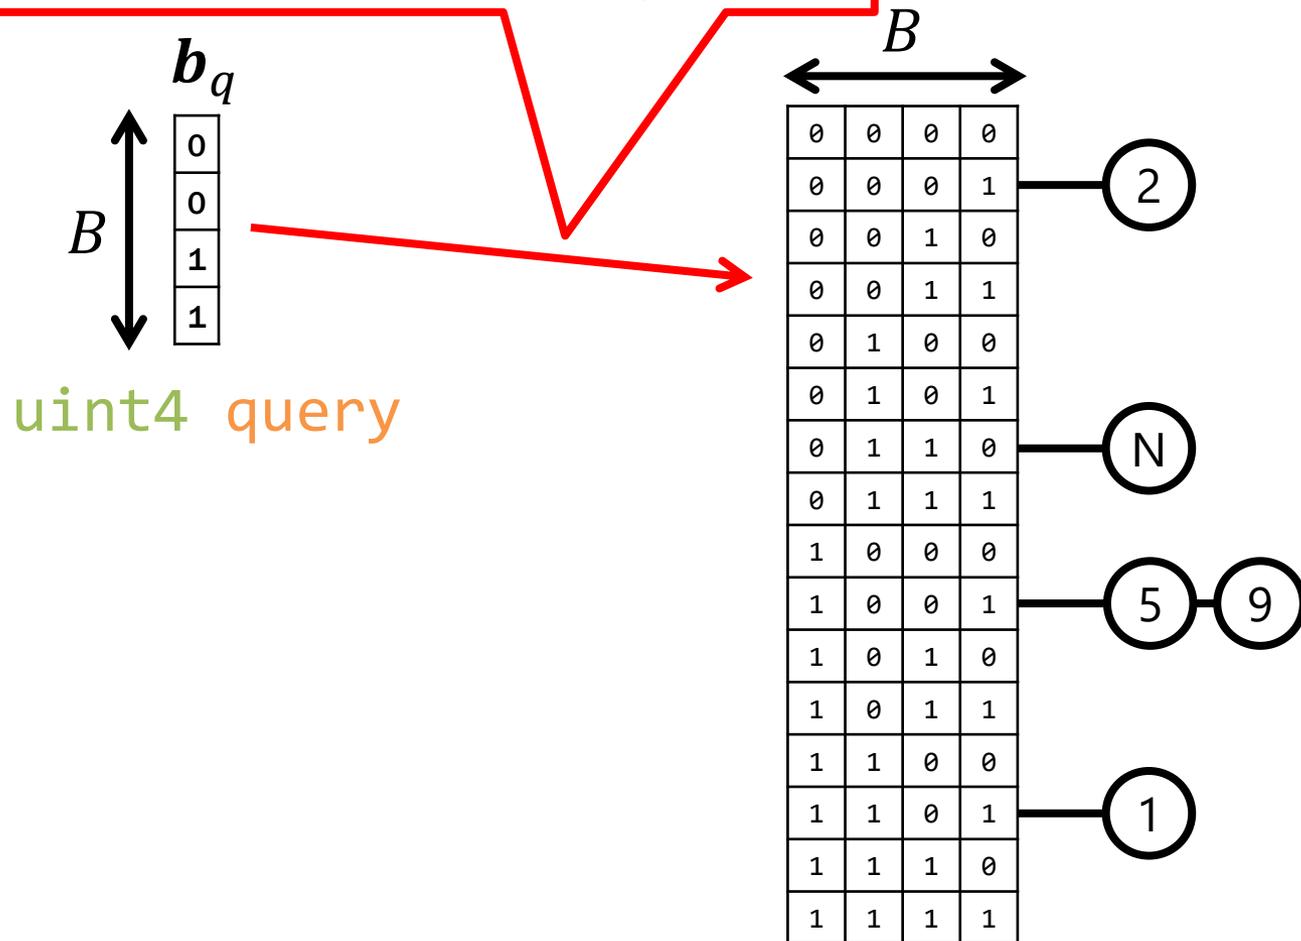
`uint4 query`



# ハミング系手法の高速計算：探索

`vec<list<int>> table`

(1) クエリと同じコードがあるか？  
配列アクセスなので,  $O(1)$ .  
すなわち, `table[query]`

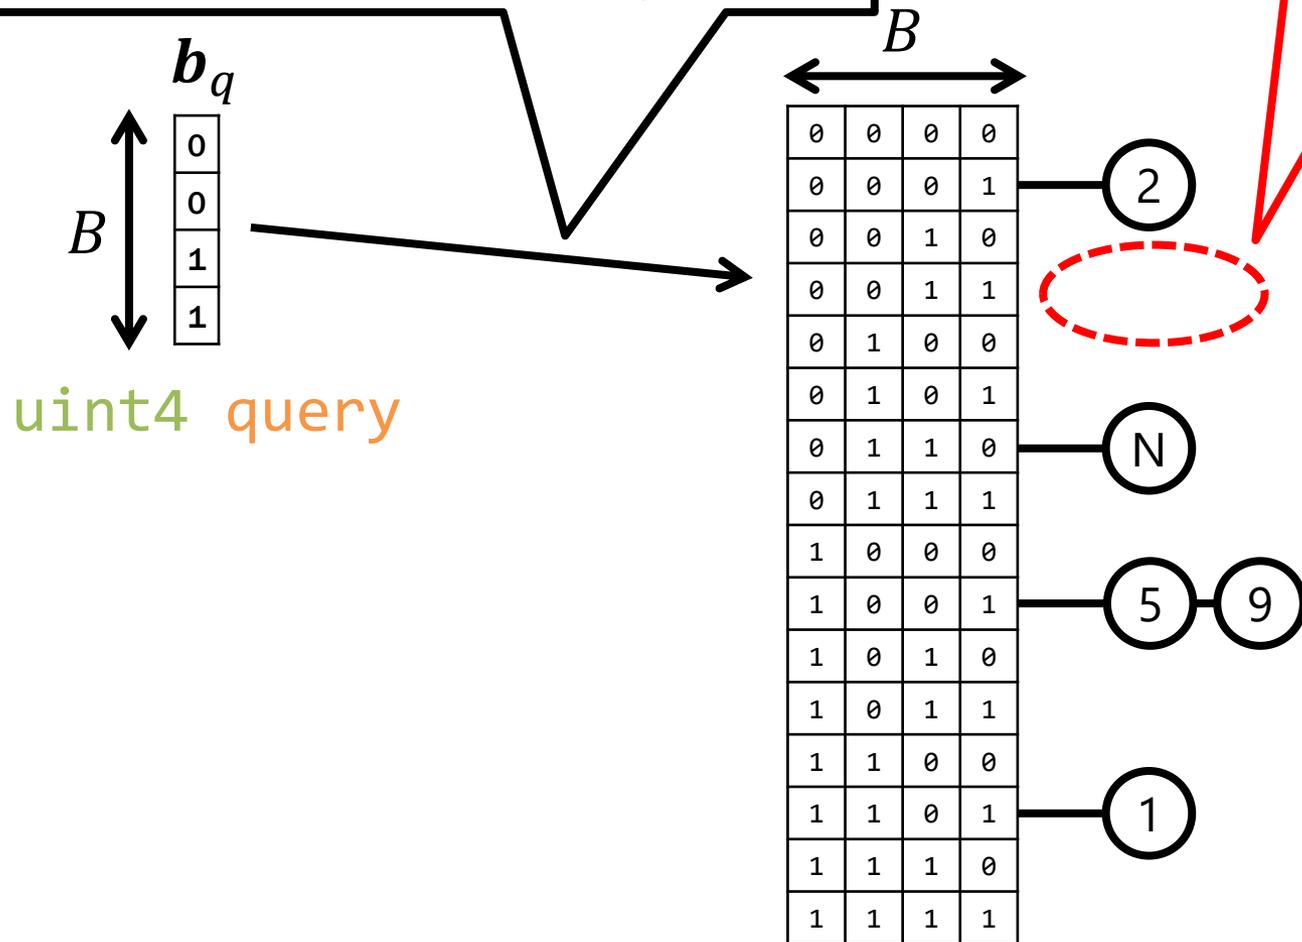


# ハミング系手法の高速計算：探索

`vec<list<int>> table`

(1) クエリと同じコードがあるか？  
配列アクセスなので， $O(1)$ .  
すなわち，`table[query]`

(2) ここでは，該当なし

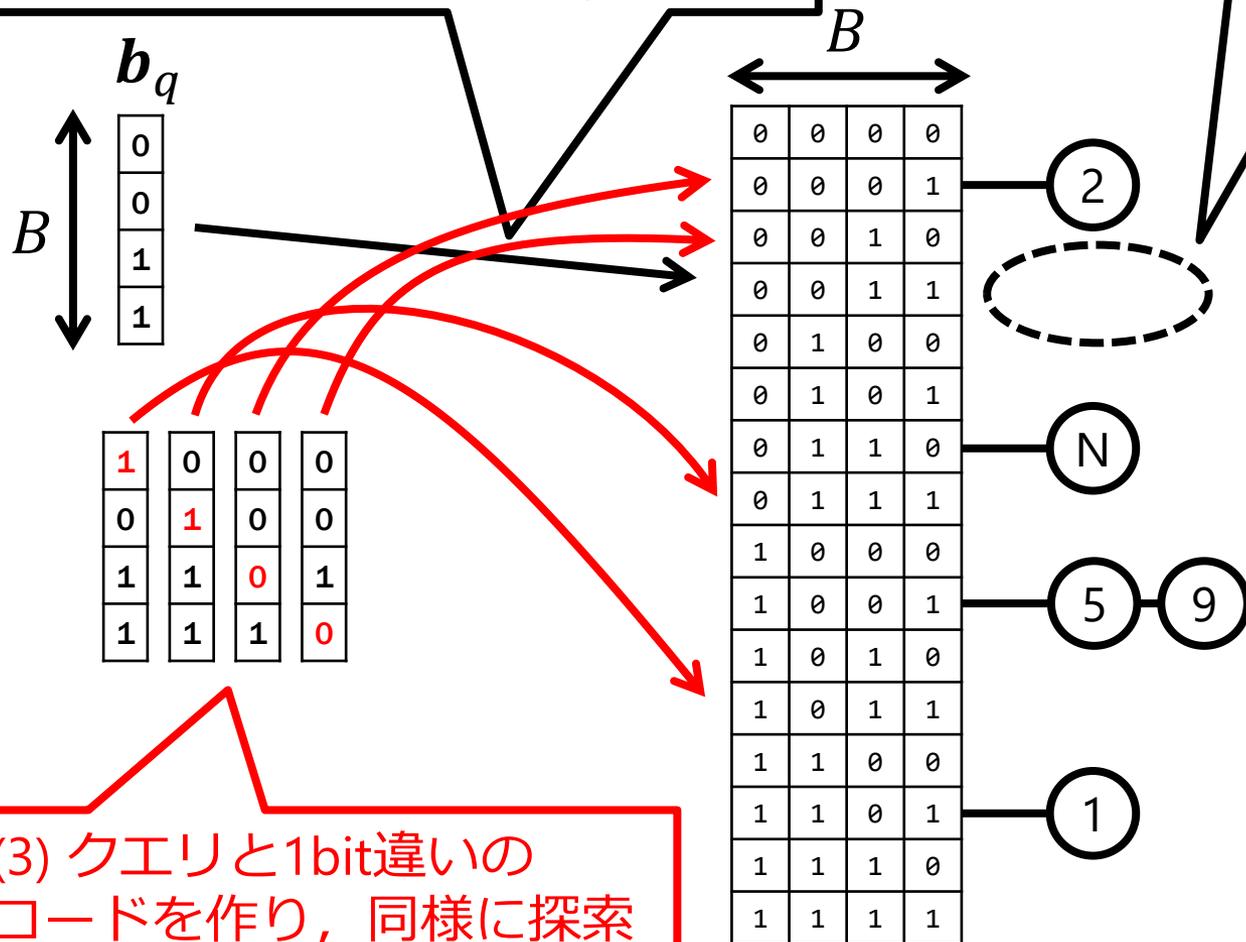


# ハミング系手法の高速計算：探索

`vec<list<int>> table`

(1) クエリと同じコードがあるか？  
配列アクセスなので， $O(1)$ .  
すなわち，`table[query]`

(2) ここでは，該当なし



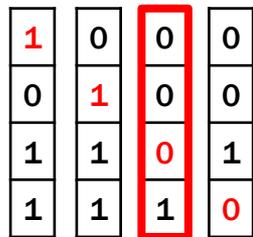
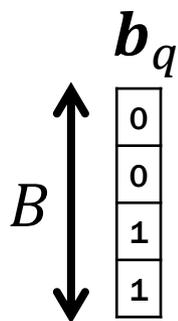
(3) クエリと1bit違いの  
コードを作り，同様に探索

# ハミング系手法の高速計算：探索

`vec<list<int>> table`

(1) クエリと同じコードがあるか？  
配列アクセスなので， $O(1)$ .  
すなわち，`table[query]`

(2) ここでは，該当なし



$B$

0	0	0	0
0	0	0	1
0	0	1	0
0	0	1	1
0	1	0	0
0	1	0	1
0	1	1	0
0	1	1	1
1	0	0	0
1	0	0	1
1	0	1	0
1	0	1	1
1	1	0	0
1	1	0	1
1	1	1	0
1	1	1	1

2

N

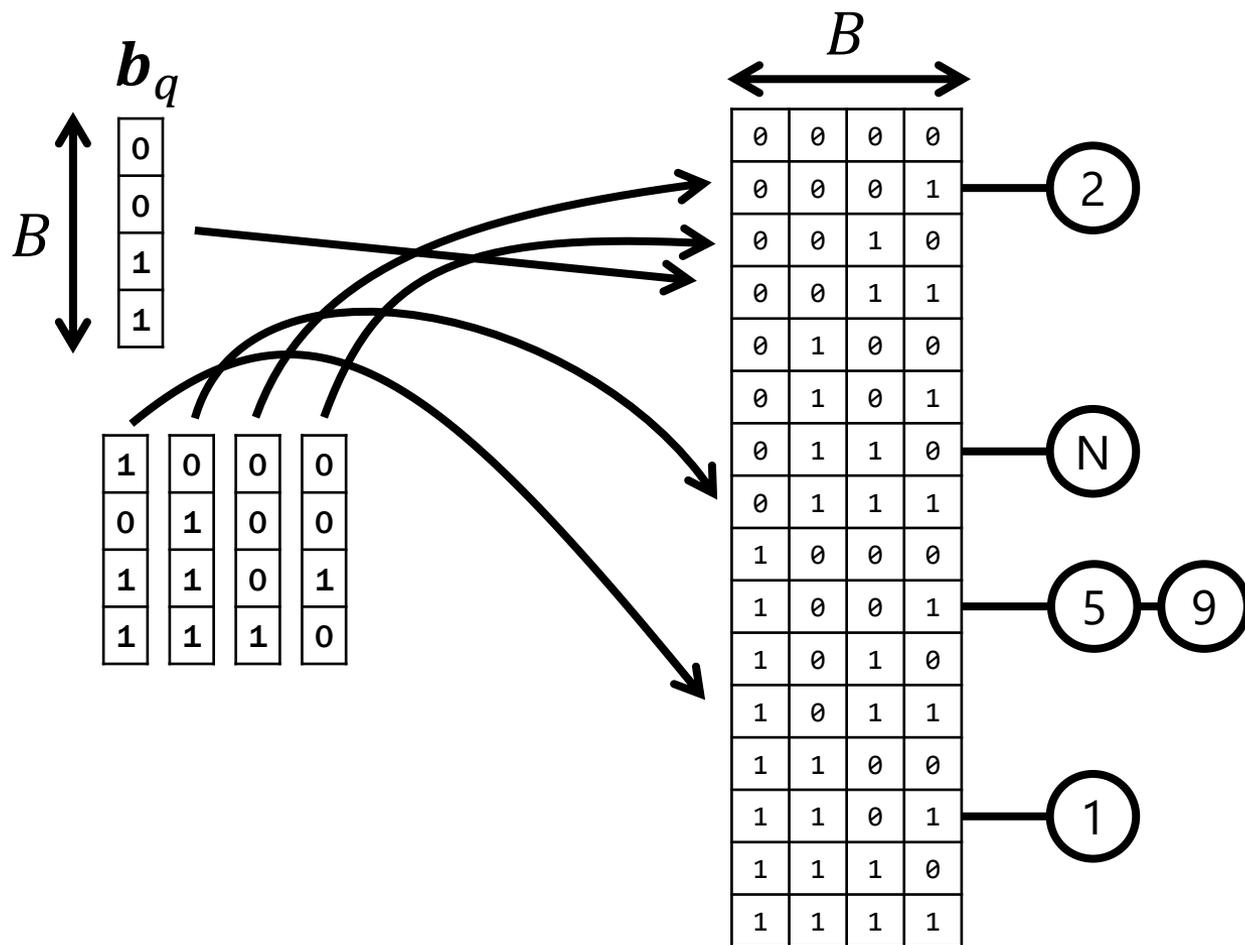
5

1

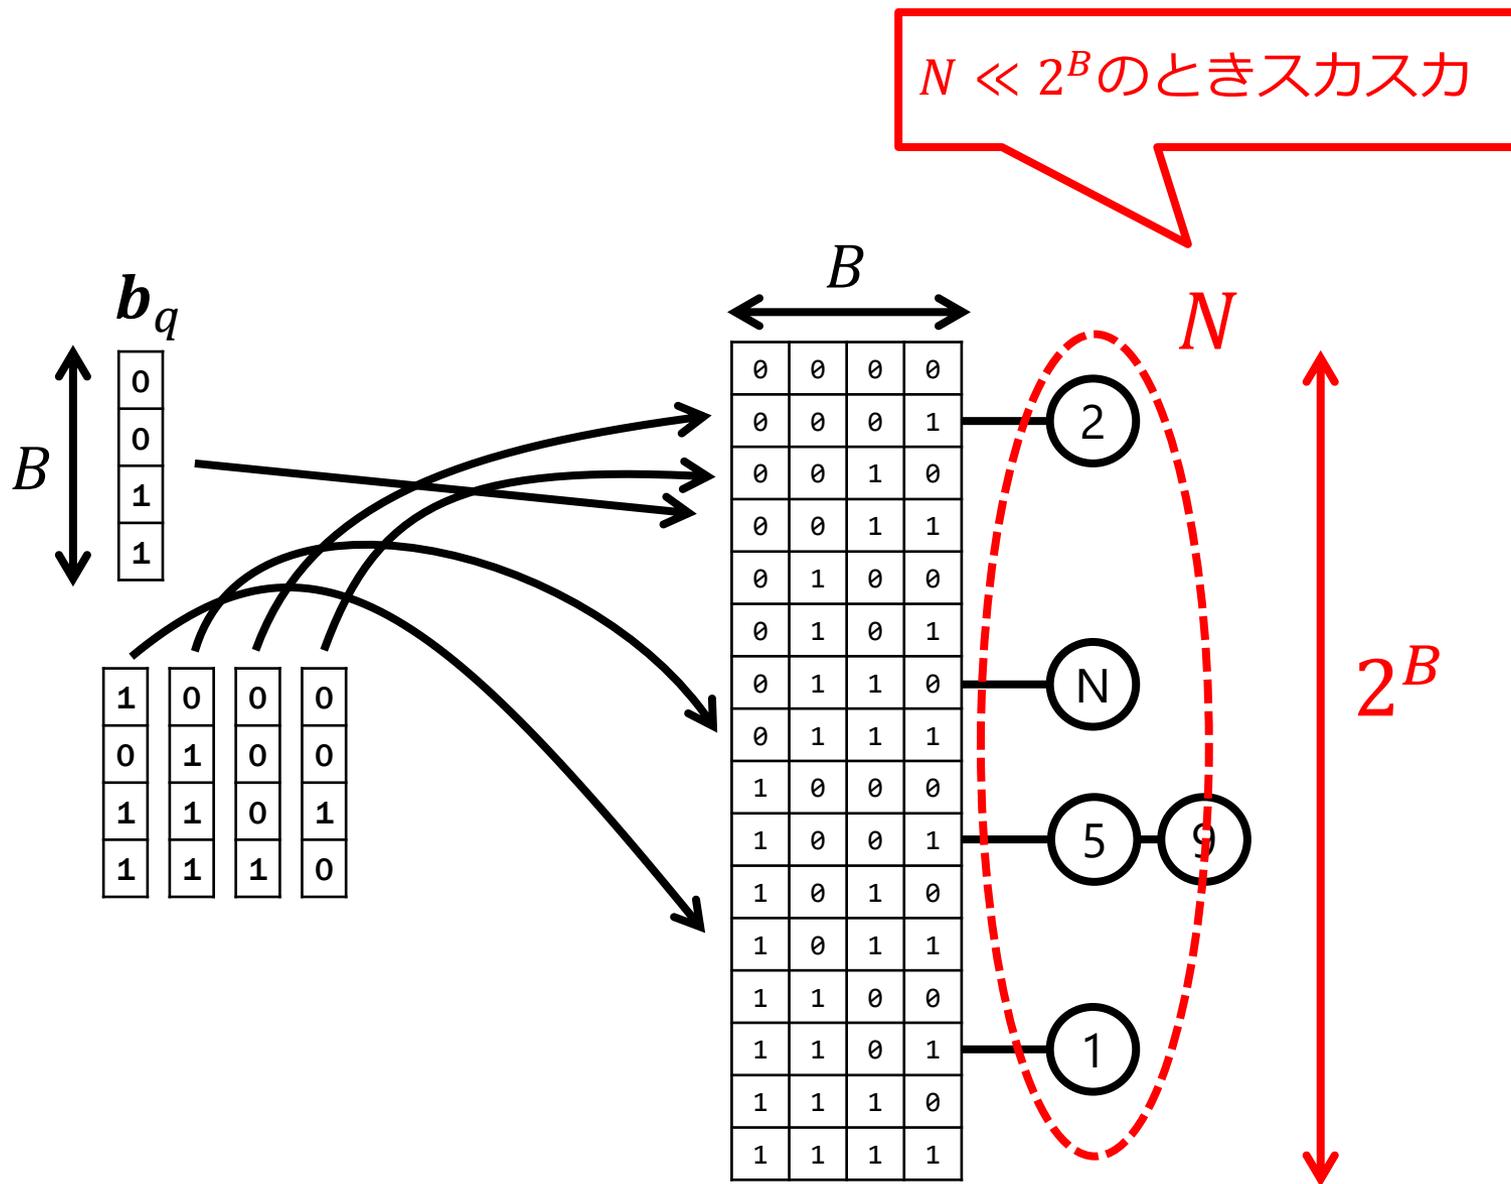
(3) クエリと1bit違いの  
コードを作り，同様に探索

(4) クエリに最も近いのは②

# ハミング系手法の高速計算：問題と発展

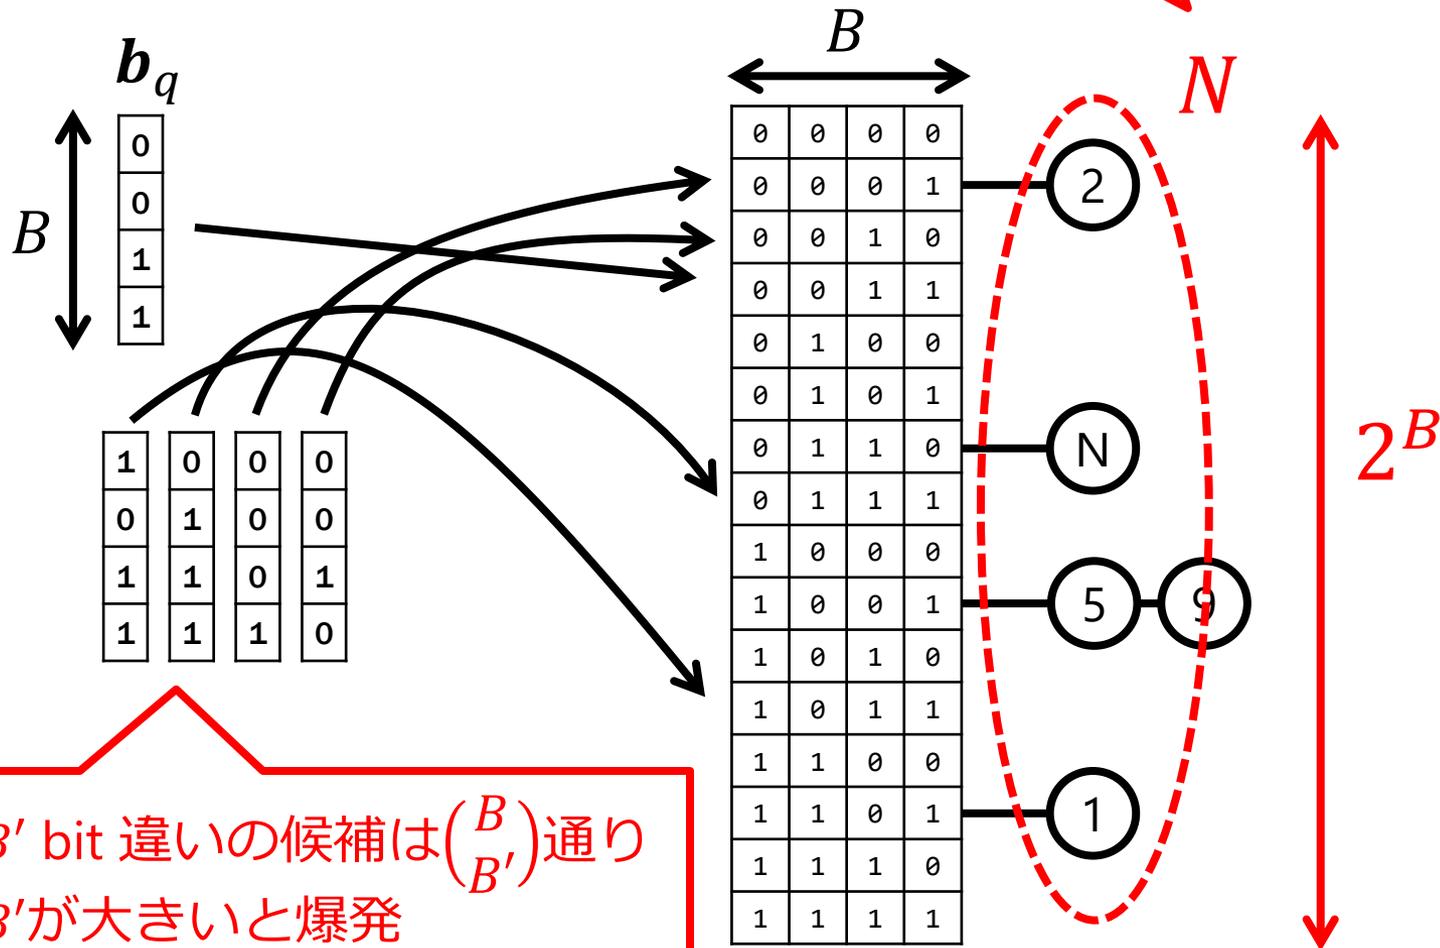


# ハミング系手法の高速計算：問題と発展



# ハミング系手法の高速計算：問題と発展

$N \ll 2^B$  のときスカスカ



# ハミング系手法の高速計算：問題と発展

$N \ll 2^B$  のときスカスカ

$b_q$   
↑  
0

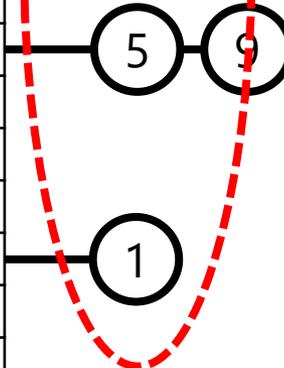
$B$   
←→  
0 0 0 0

$N$

- テーブルを分割することでこれらの問題を解決する手法が知られている [Norouzi+, TPAMI 14]
- $N$  が大きい時はこれらのテーブルを用いる手法を検討すると良い

1	1	0	1
1	1	1	0

1	0	0	0
1	0	0	1
1	0	1	0
1	0	1	1
1	1	0	0
1	1	0	1
1	1	1	0
1	1	1	1

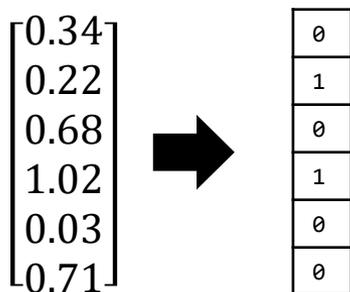


$B'$  bit 違いの候補は  $\binom{B}{B'}$  通り  
 $B'$  が大きいと爆発

# ショートコードによる近似最近傍探索

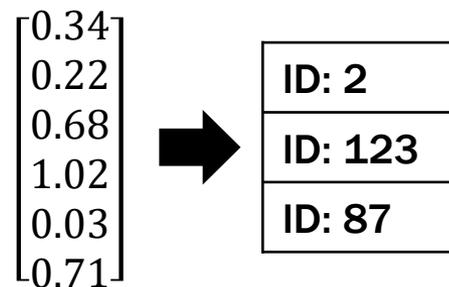
## ➤ 基本的な考え方

ハミング系



- 原理
- 手法の例
- 高速計算

ルックアップ系



- 原理
- 探索システム

# PQそのものの発展

**元論文**  
[Jégou, TPAMI 11]

**PQそのもの**

**PQを使った探索システム**

**事前変換**

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数  
コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenko, CVPR 15]

**一般化**

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

**新しい問題設定**

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化：  
k-means

リランキング：  
残差PQコード

**疎量子化の工夫**

複数k-means [Xia, ICCV 13]

PQ [Babenko, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenko, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

**リランキングの工夫**

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

# PQを使った探索システムの発展

**その他トピック**

余分ビット [Heo, CVPR 14]

ハッシュテーブル [Matsui, ICCV 15]

GPU [Wieschollek, CVPR 16]

キャッシュ [André, VLDB 15]

画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

# PQそのものの発展

元論文 [Jégou, TPAMI 11]

**PQそのもの**

PQを使った探索システム

### 事前変換

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenko, CVPR 15]

### 一般化

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

### 新しい問題設定

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化 : k-means

リランキング : 残差PQコード

### 疎量子化の工夫

複数k-means [Xia, ICCV 13]

PQ [Babenko, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenko, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

### リランキングの工夫

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

## PQを使った探索システムの発展

### その他トピック

余分ビット [Heo, CVPR 14]

ハッシュテーブル [Matsui, ICCV 15]

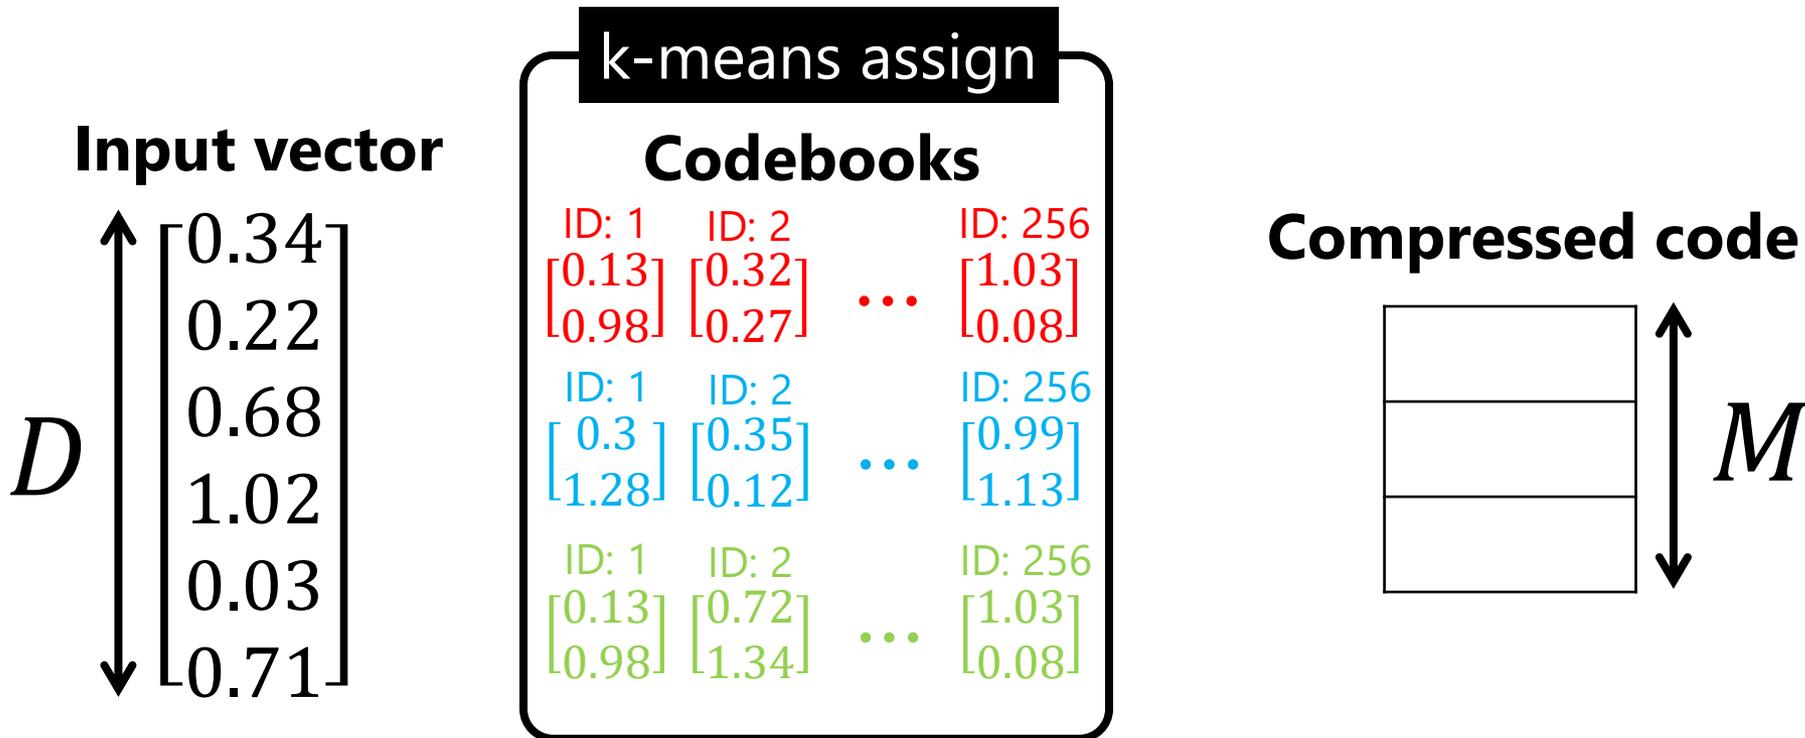
GPU [Wieschollek, CVPR 16]

キャッシュ [André, VLDB 15]

画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

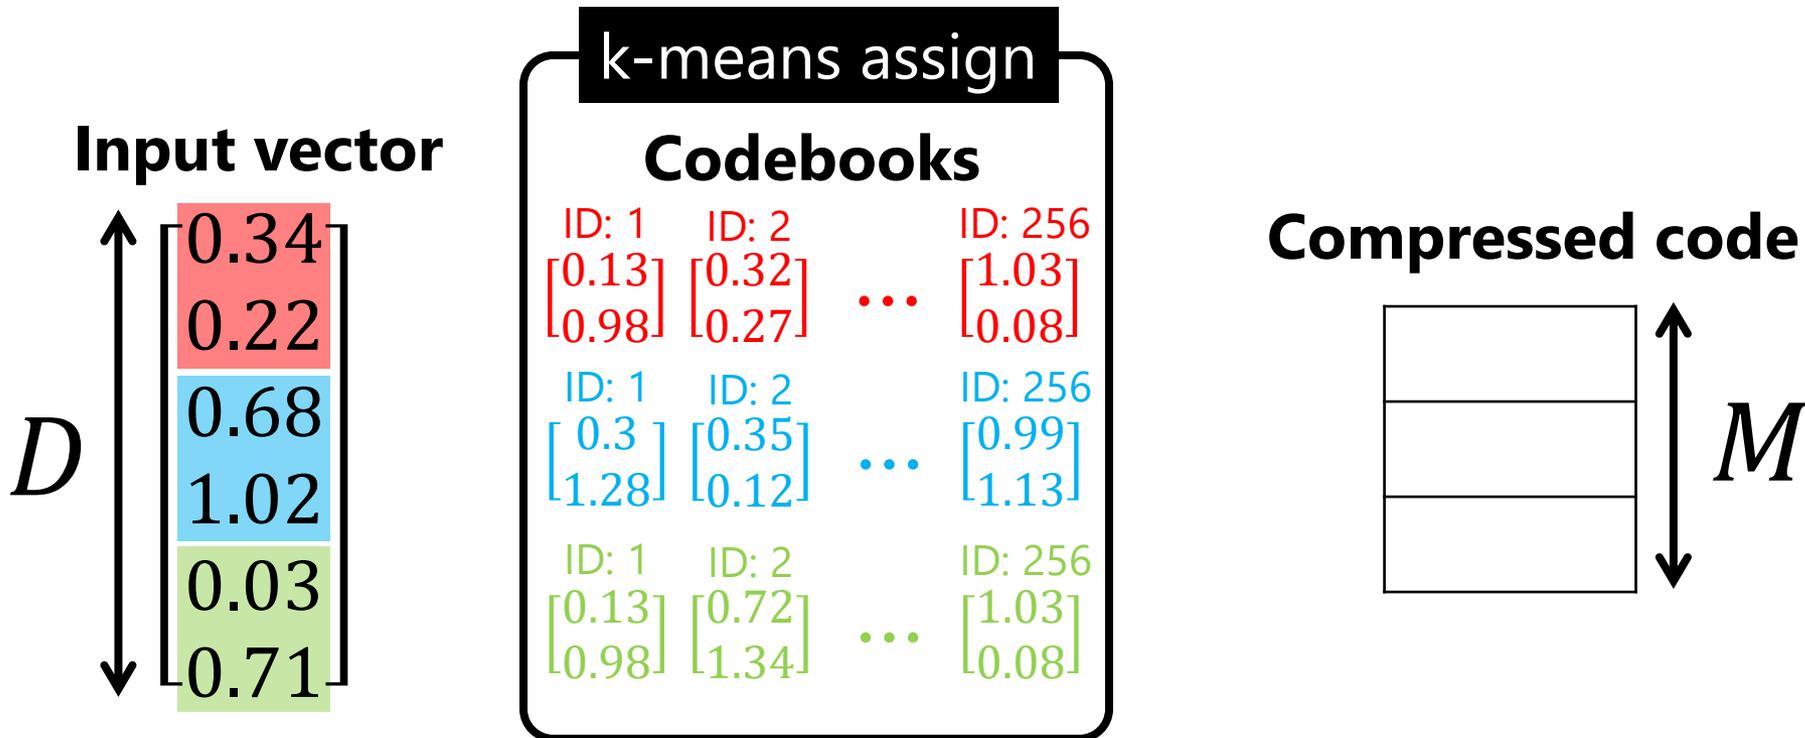
# Product Quantization [Jégou, TPAMI 2011]

➤ ベクトルを分割してk-meansする



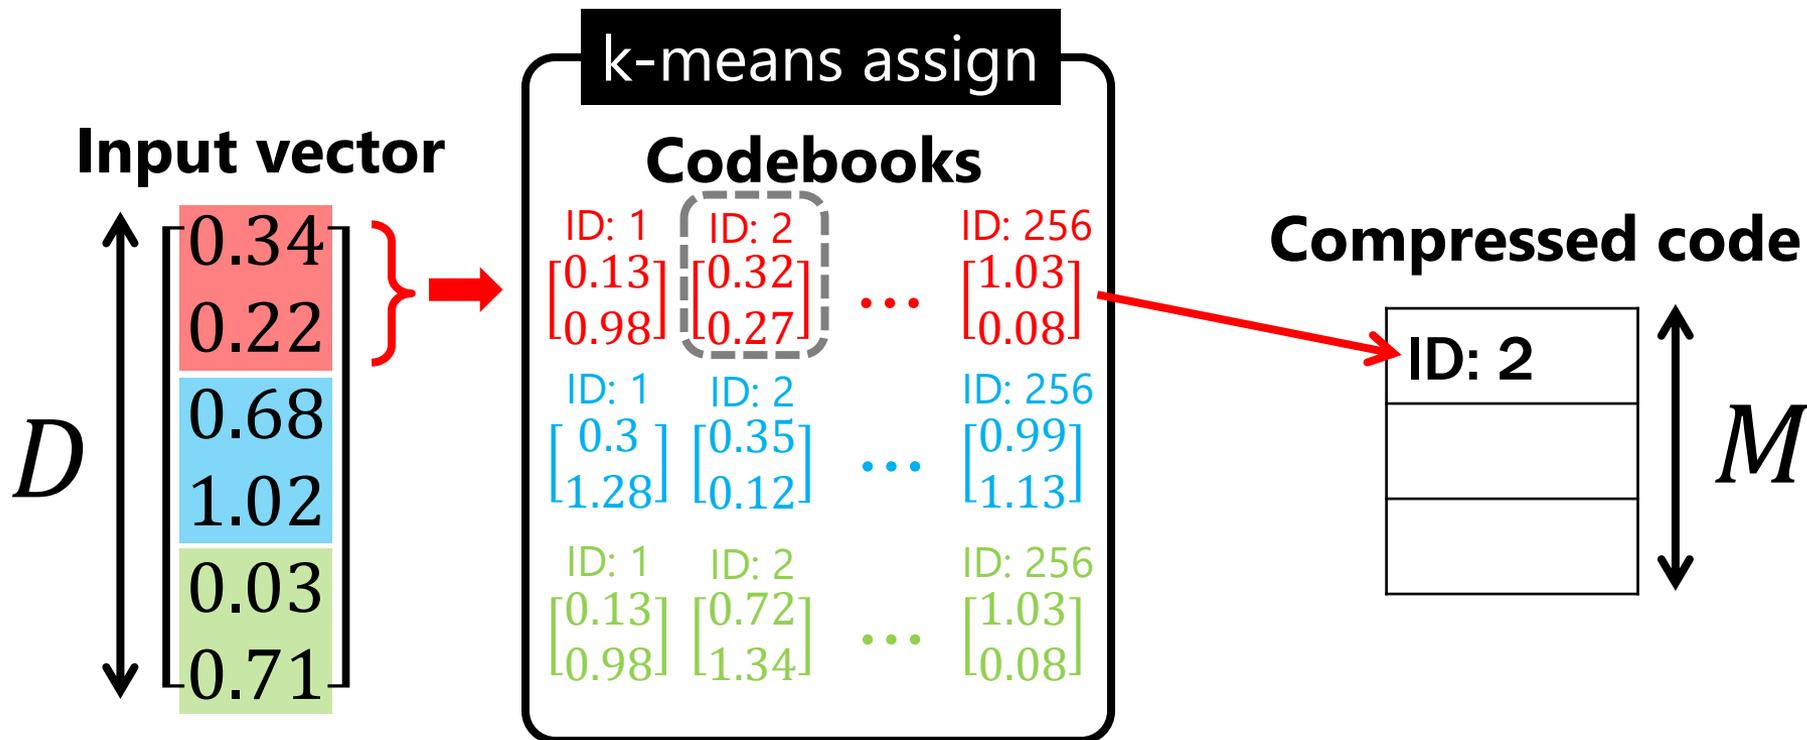
# Product Quantization [Jégou, TPAMI 2011]

➤ ベクトルを分割してk-meansする



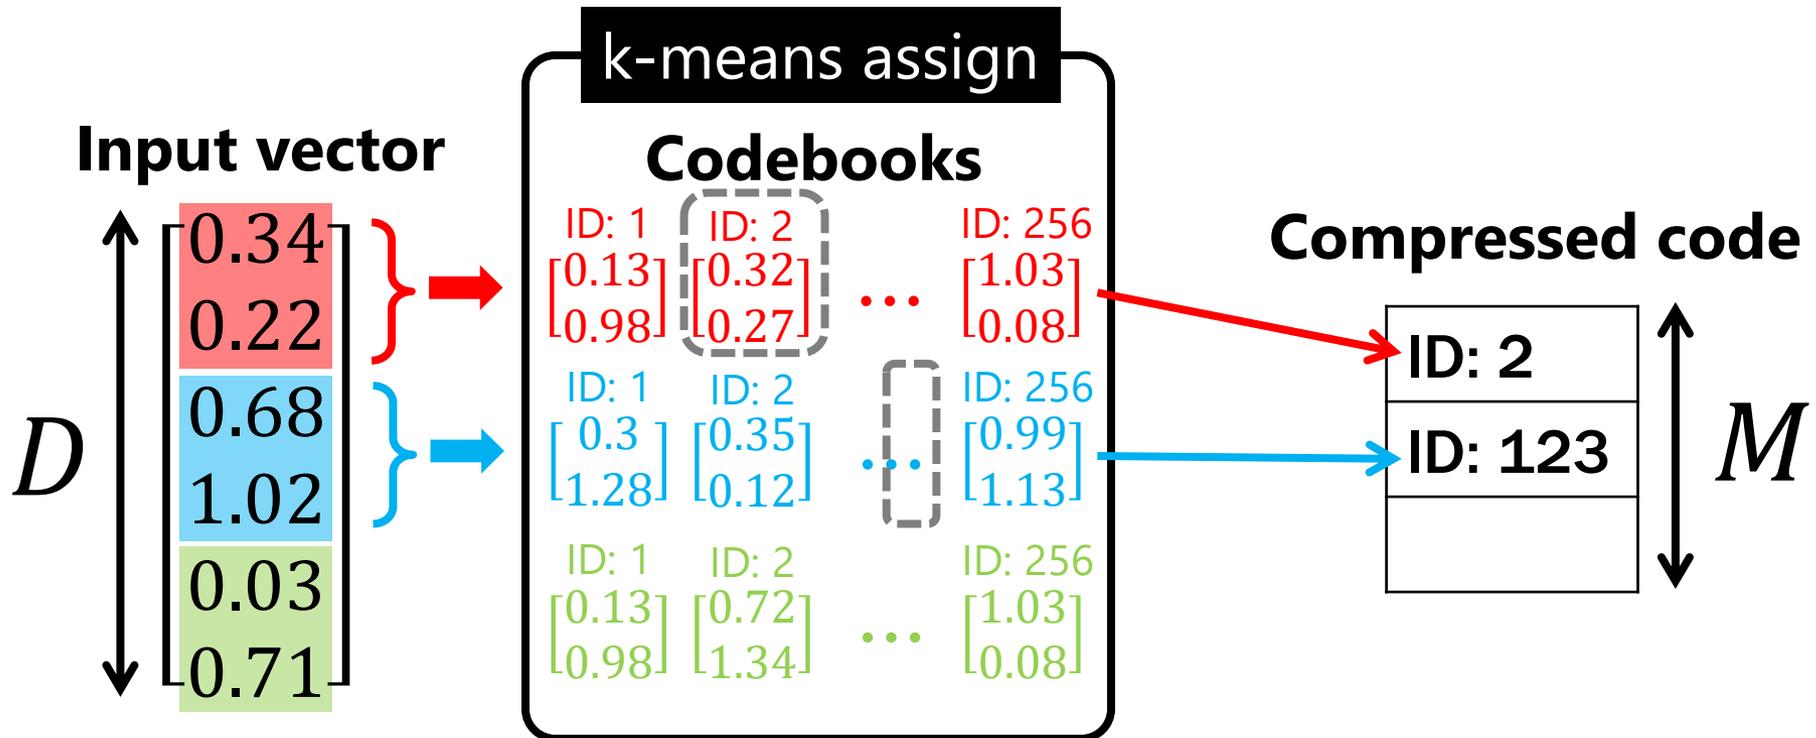
# Product Quantization [Jégou, TPAMI 2011]

➤ ベクトルを分割してk-meansする



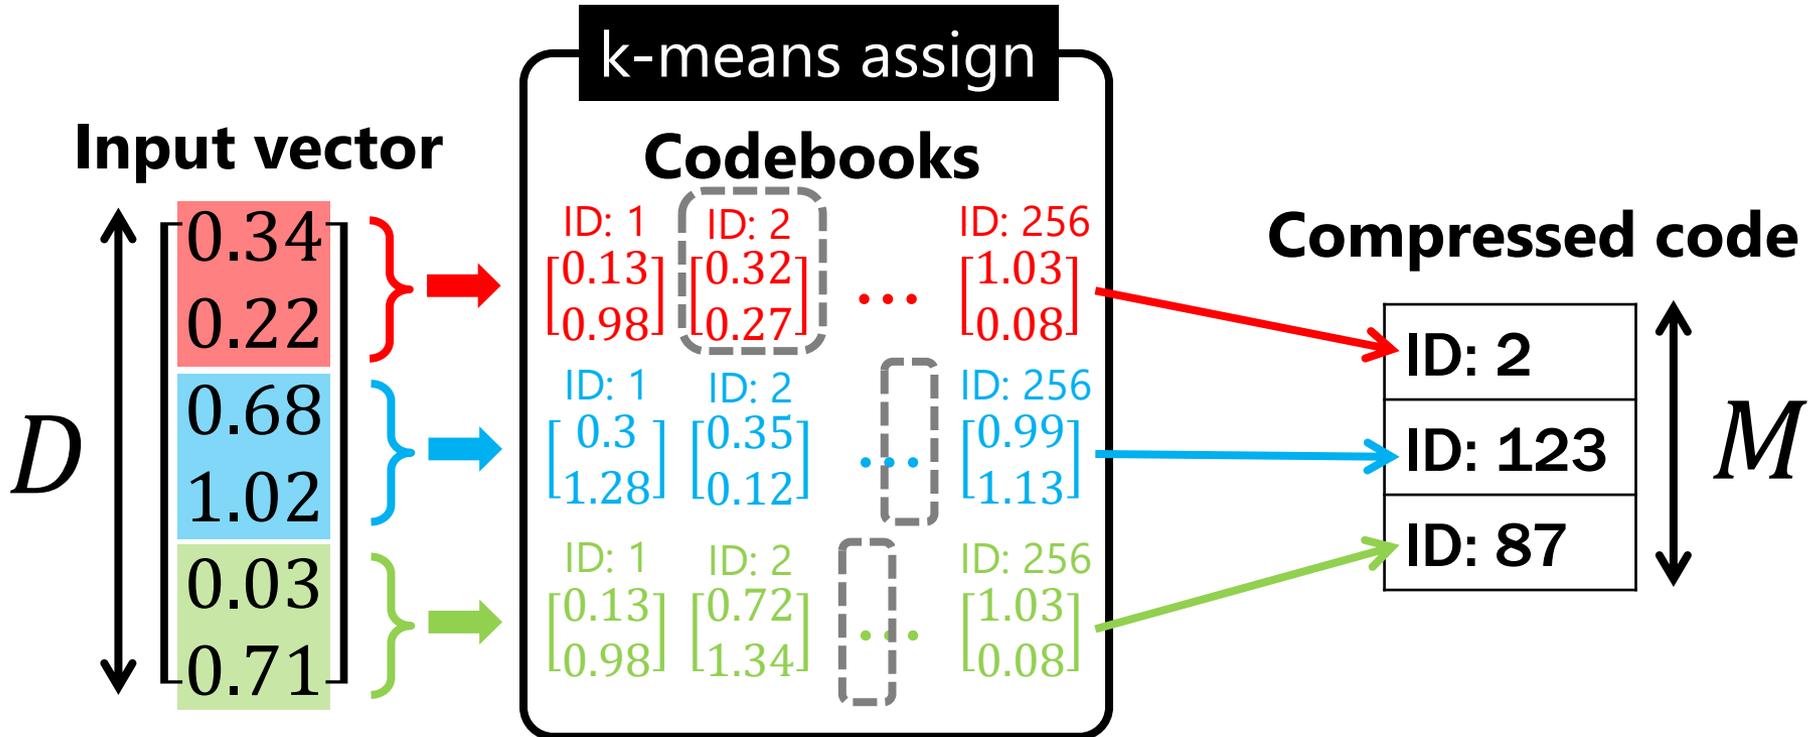
# Product Quantization [Jégou, TPAMI 2011]

➤ ベクトルを分割してk-meansする



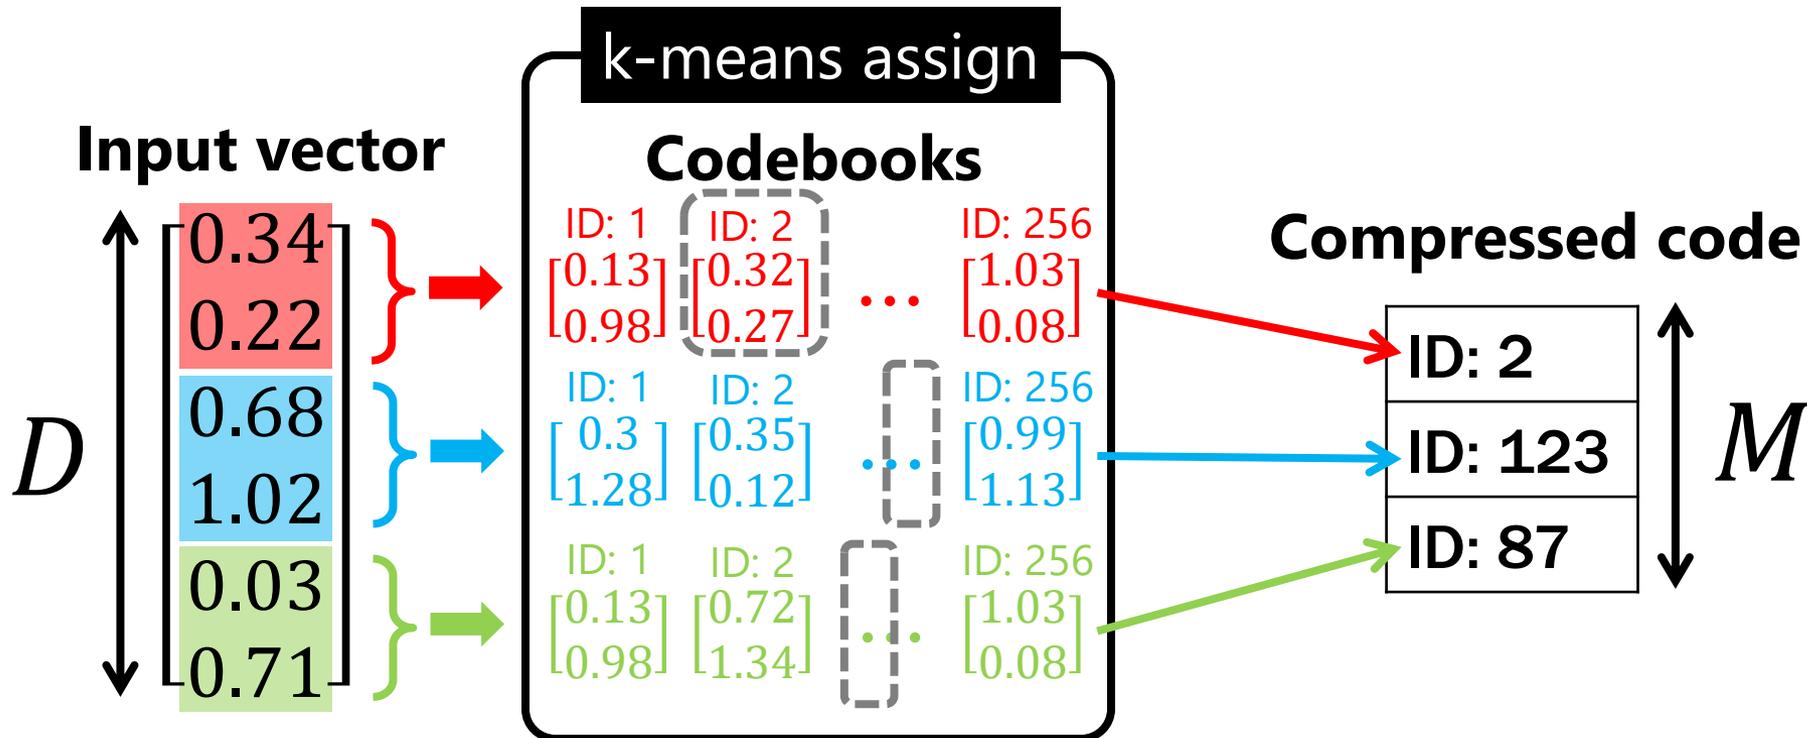
# Product Quantization [Jégou, TPAMI 2011]

➤ ベクトルを分割してk-meansする



# Product Quantization [Jégou, TPAMI 2011]

➤ ベクトルを分割してk-meansする

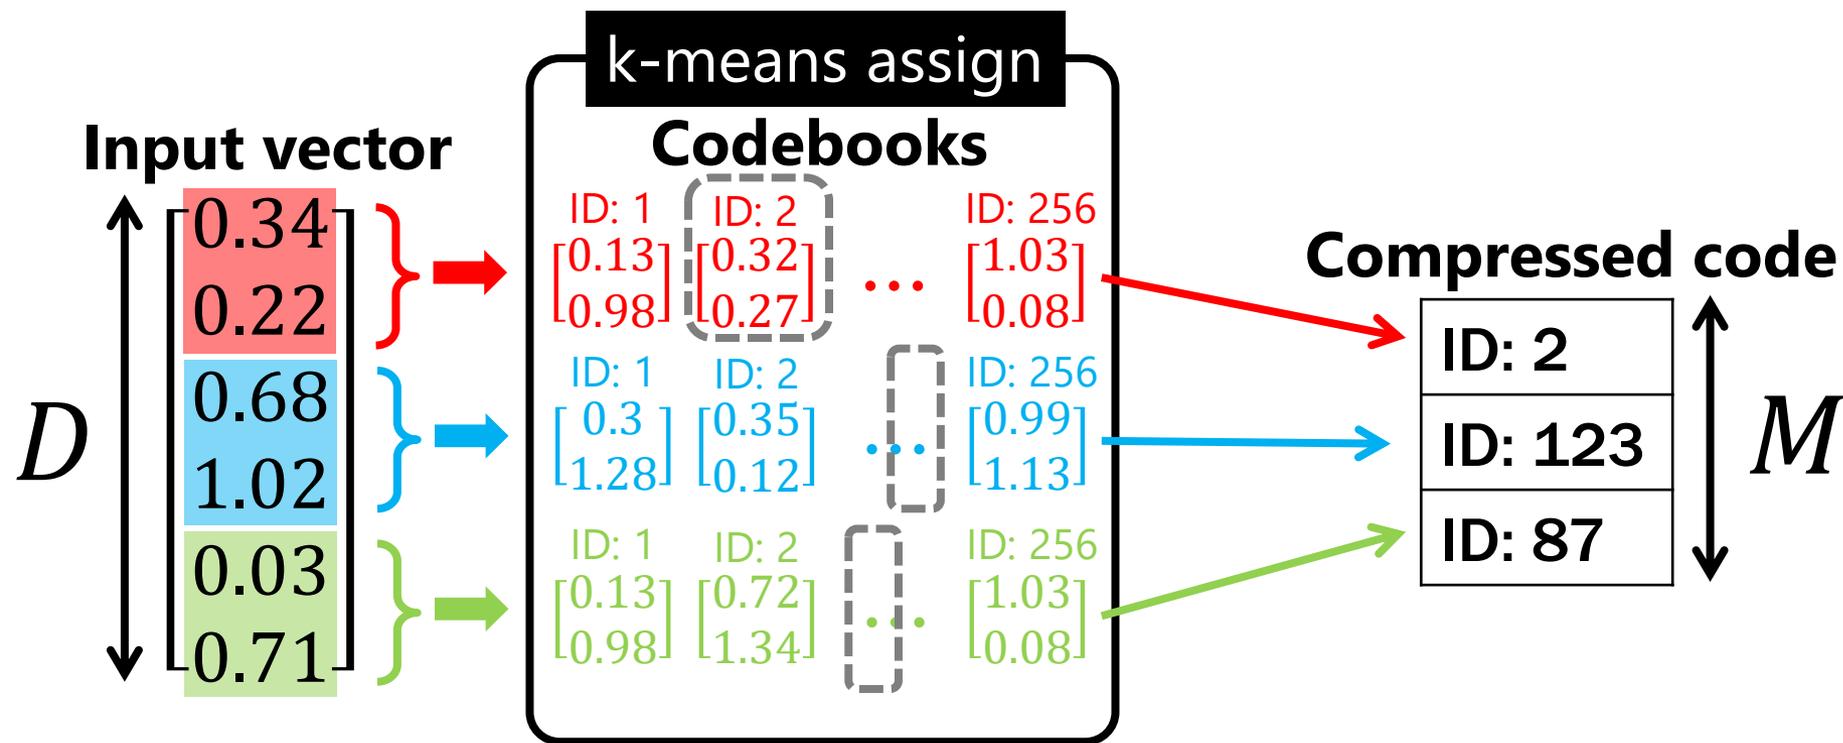


➤ 単純

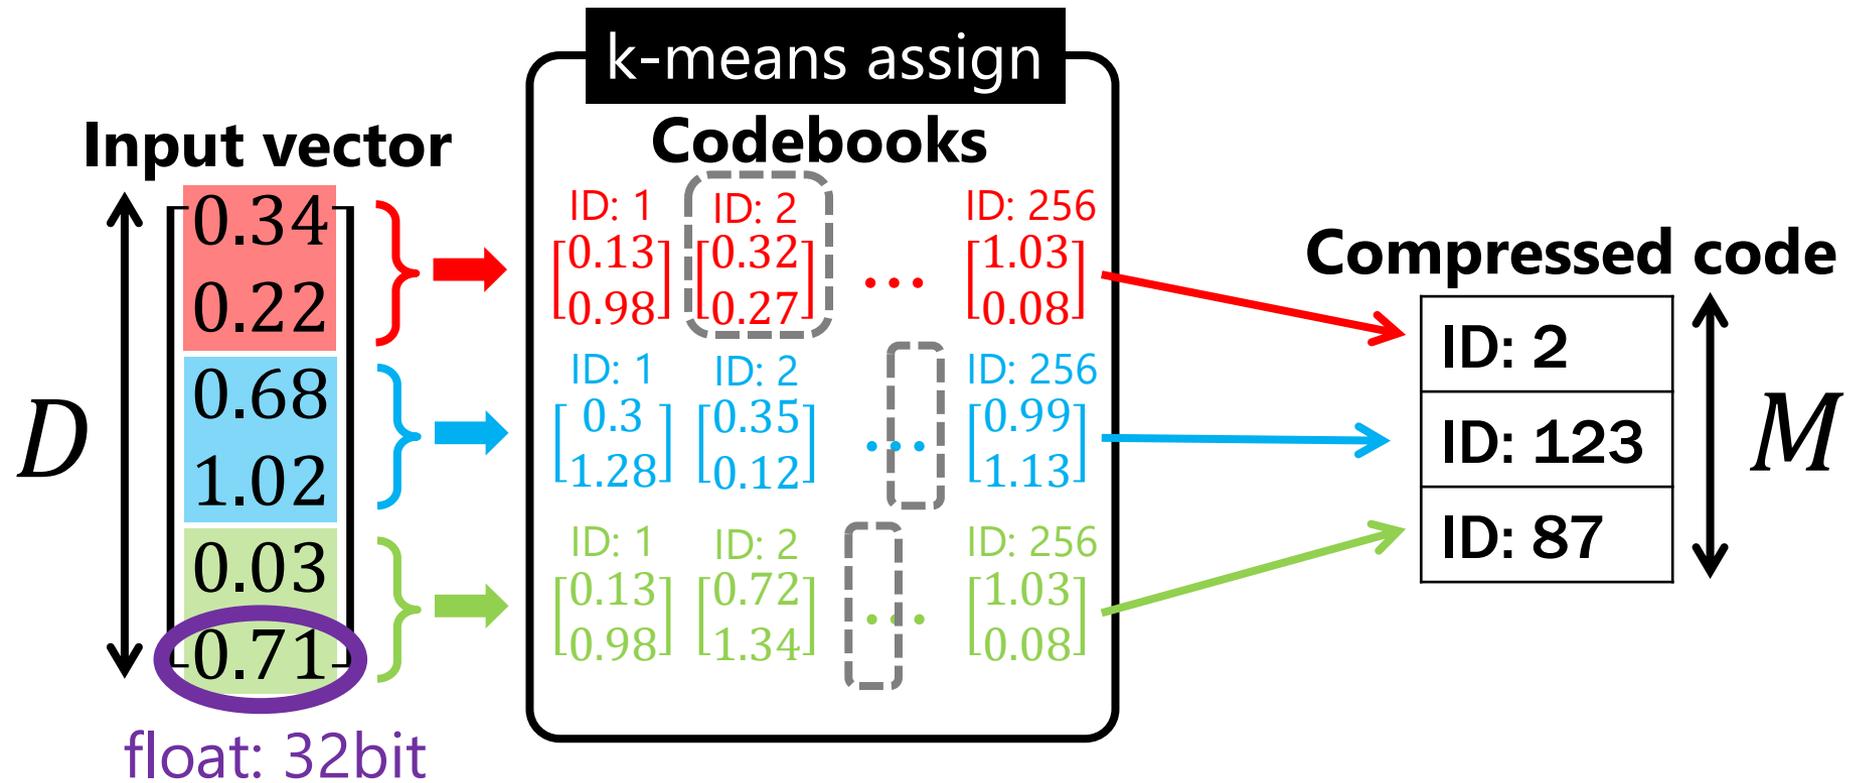
➤ メモリ効率良い

➤ 距離  $d(input, code)^2$  を近似計算可能

# Product Quantization: メモリ効率良



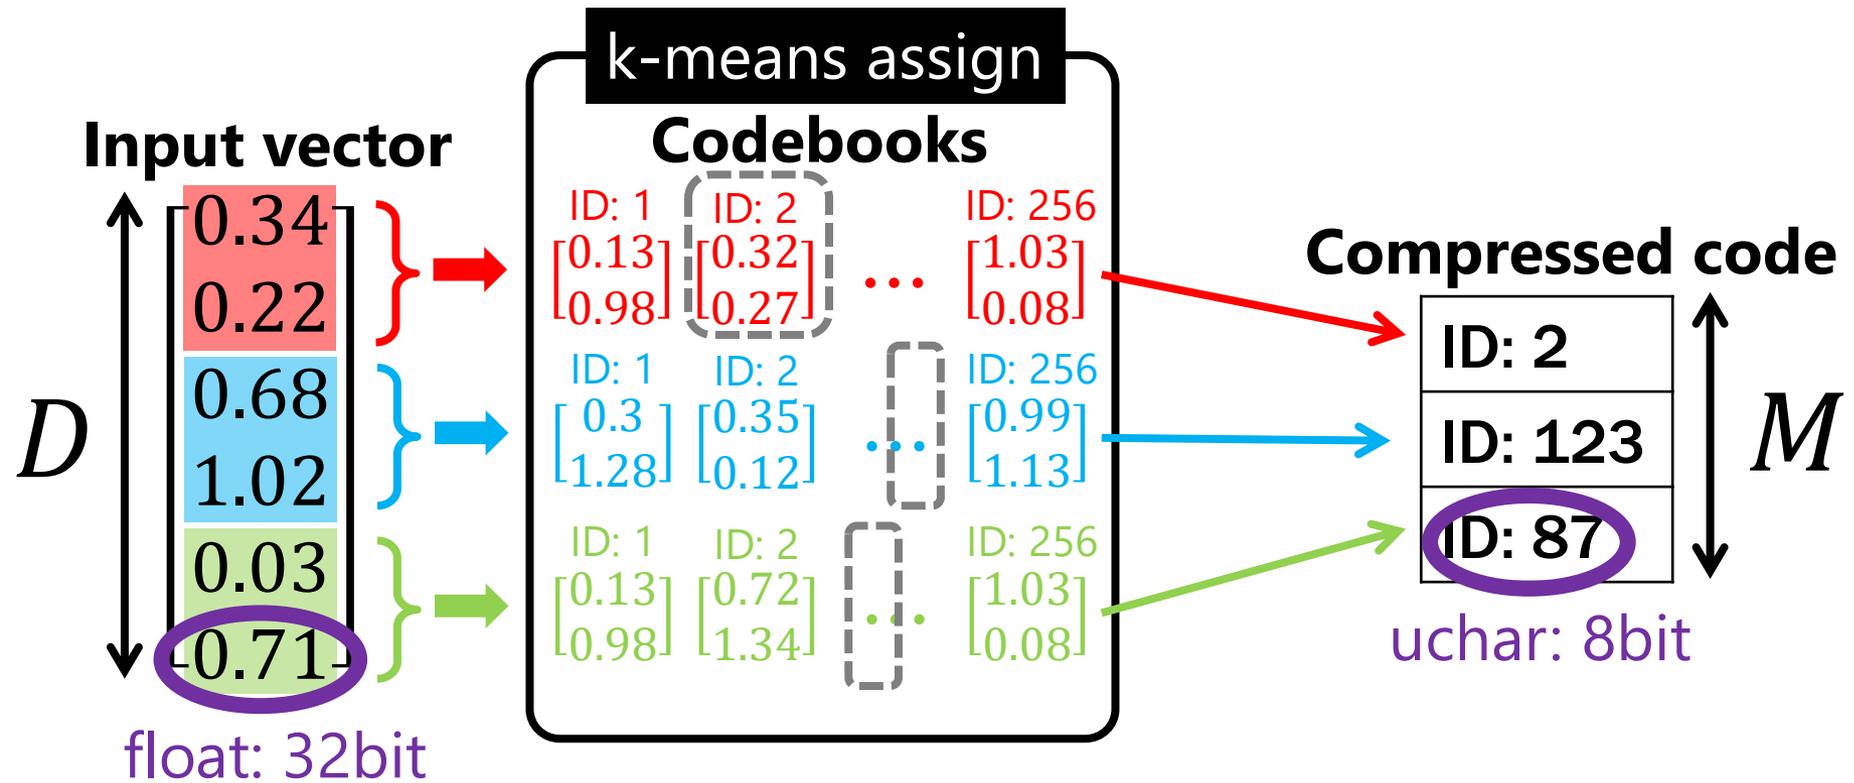
# Product Quantization: メモリ効率良



e.g.,  $D = 128$

$$128 \times 32 = 4096 \text{ [bit]}$$

# Product Quantization: メモリ効率良



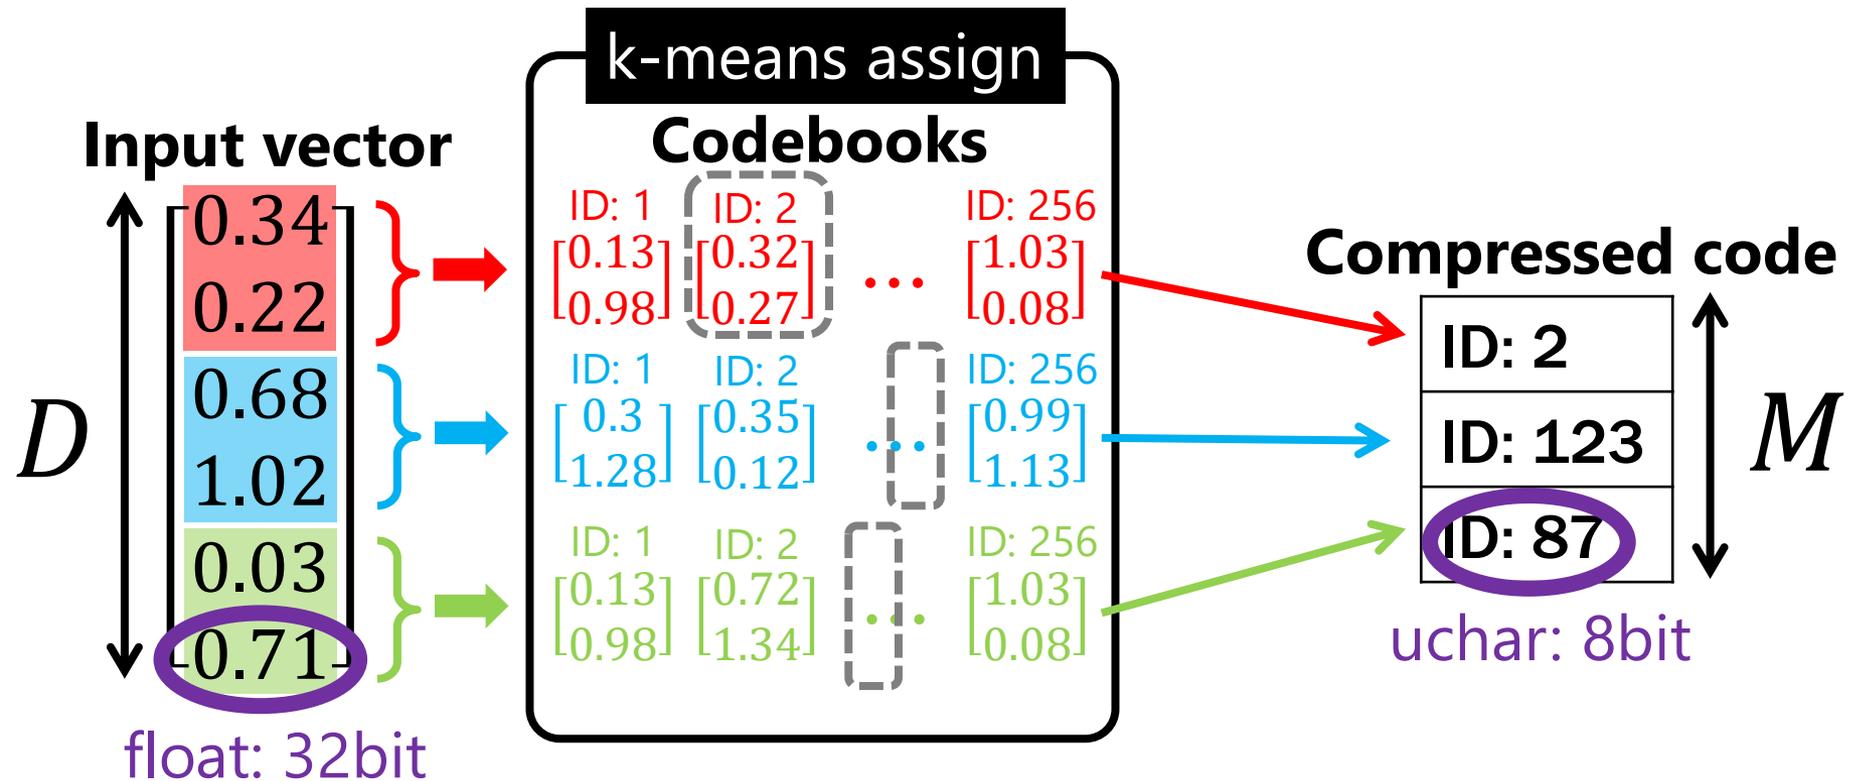
e.g.,  $D = 128$

$$128 \times 32 = 4096 \text{ [bit]}$$

e.g.,  $M = 8$

$$8 \times 8 = 64 \text{ [bit]}$$

# Product Quantization: メモリ効率良



e.g.,  $D = 128$

$$128 \times 32 = 4096 \text{ [bit]}$$

e.g.,  $M = 8$

$$8 \times 8 = 64 \text{ [bit]}$$

1/64に圧縮

# Product Quantization: 距離近似

Query	①	②	...	①N
0.34	0.54	0.62		3.34
0.22	2.35	0.31		0.83
0.68	0.82	0.34		0.62
1.02	0.42	1.63		1.45
0.03	0.14	1.43		0.12
0.71	0.32	0.74		2.32

# Product Quantization: 距離近似

Query	①	②	...	①N
[0.34	[0.54	[0.62		[3.34
0.22	2.35	0.31		0.83
0.68	0.82	0.34	...	0.62
1.02	0.42	1.63		1.45
0.03	0.14	1.43		0.12
0.71]	0.32]	0.74]		2.32]

Product  
quantization

# Product Quantization: 距離近似

Query

[0.34  
0.22  
0.68  
1.02  
0.03  
0.71]

①

ID: 42
ID: 67
ID: 92

②

ID: 221
ID: 143
ID: 34

...

④

ID: 99
ID: 234
ID: 3

# Product Quantization: 距離近似

Query

[0.34  
0.22  
0.68  
1.02  
0.03  
0.71]

線形  
探索

①

ID: 42
ID: 67
ID: 92

②

ID: 221
ID: 143
ID: 34

...

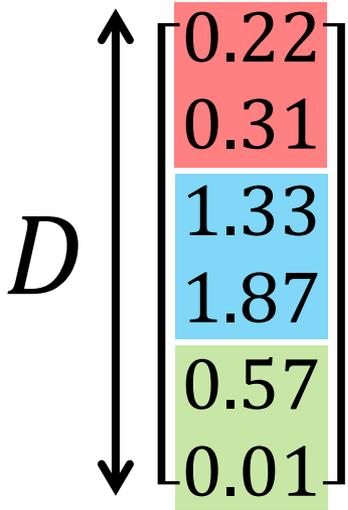
④

ID: 99
ID: 234
ID: 3

(近似的距離で) 線形探索が出来る

# Product Quantization: 距離近似

Query vector



k-means assign

Codebooks

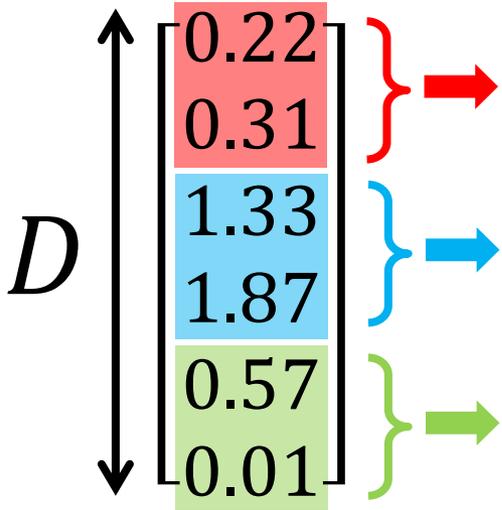
ID: 1	ID: 2	...	ID: 256
[0.13]	[0.32]		[1.03]
[0.98]	[0.27]		[0.08]
ID: 1	ID: 2	...	ID: 256
[0.3]	[0.35]		[0.99]
[1.28]	[0.12]		[1.13]
ID: 1	ID: 2	...	ID: 256
[0.13]	[0.72]		[1.03]
[0.98]	[1.34]		[0.08]

Compressed database codes

①	②	...	④
ID: 2	ID: 45		ID: 42
ID: 12	ID: 8	...	ID: 65
ID: 87	ID: 72		ID: 7

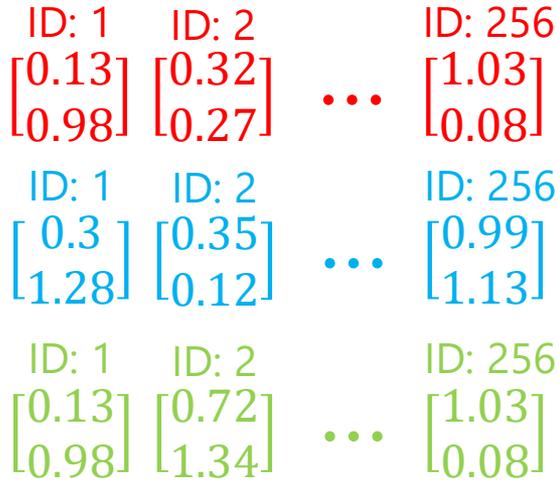
# Product Quantization: 距離近似

Query vector

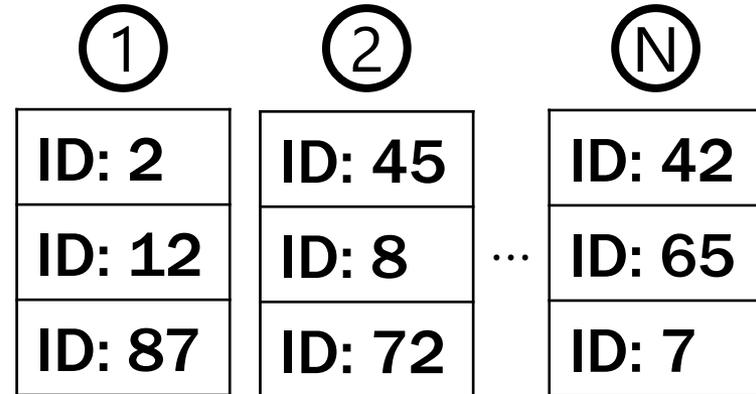


k-means assign

Codebooks

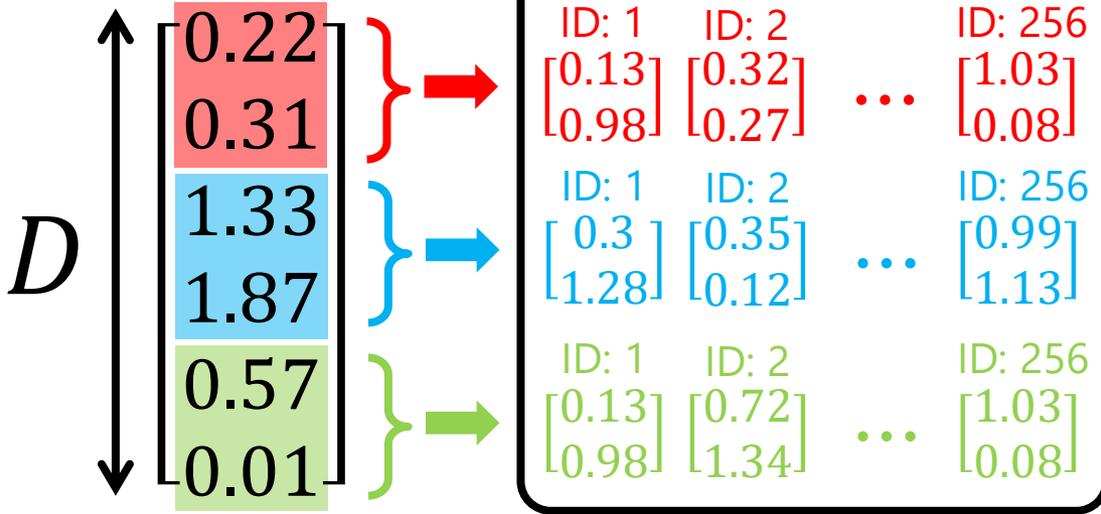


Compressed database codes

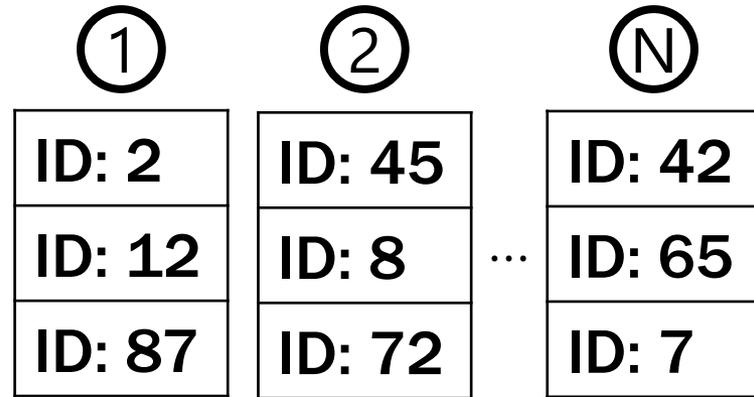


# Product Quantization: 距離近似

Query vector



Compressed database codes

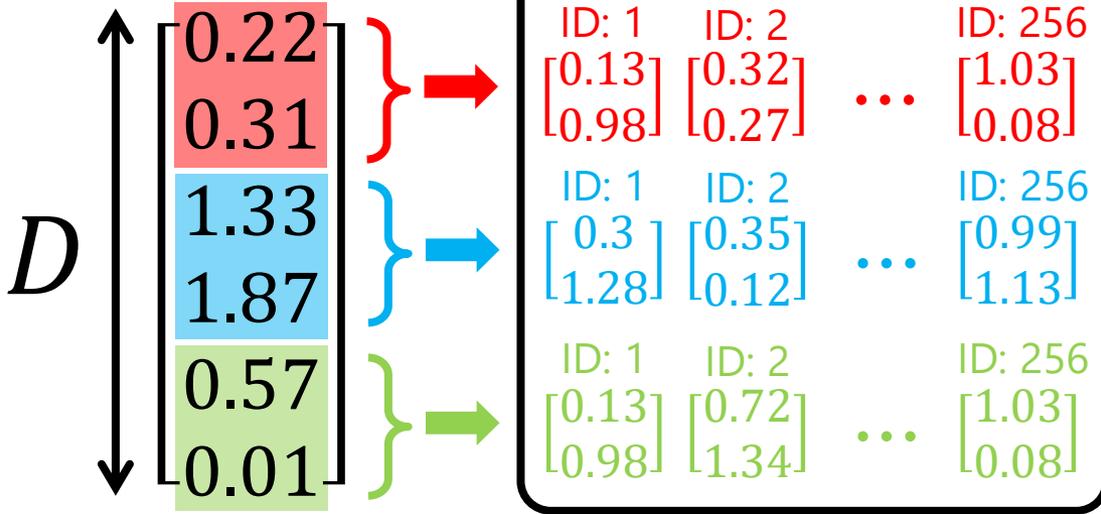


Distance table

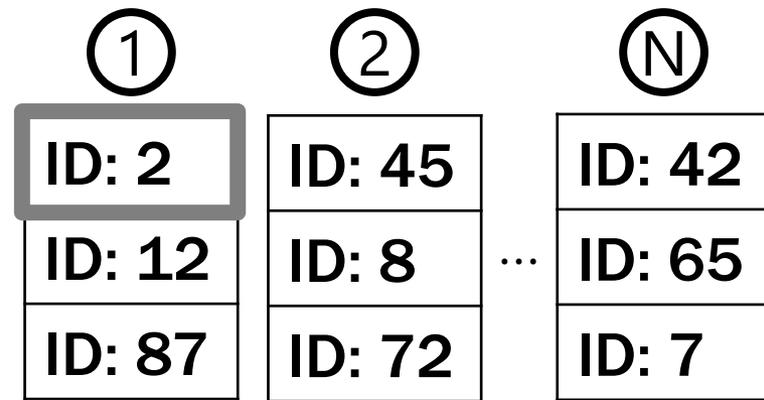
	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

# Product Quantization: 距離近似

Query vector



Compressed database codes



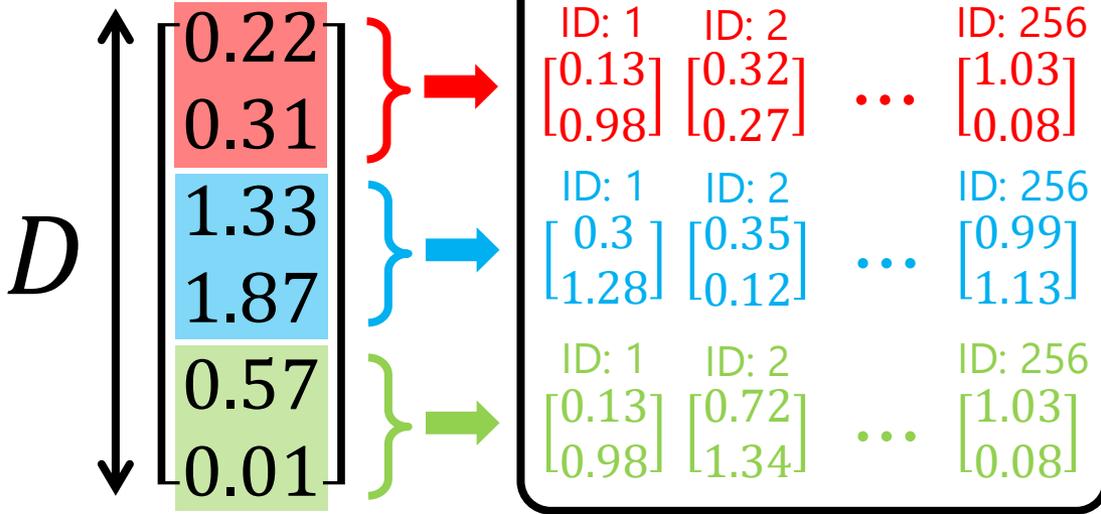
Distance:  
0.04

Distance table

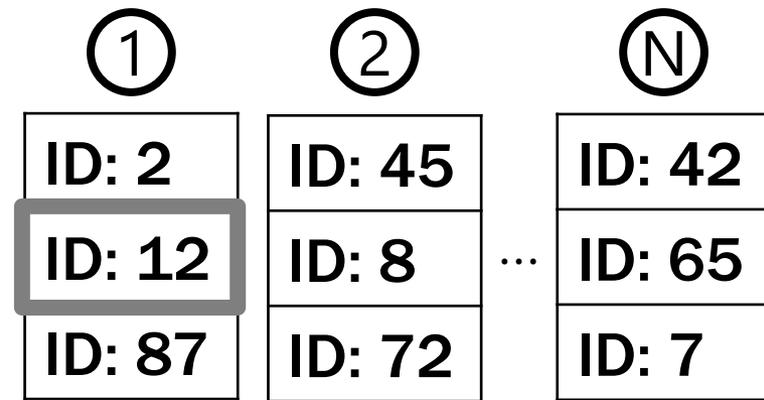
	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

# Product Quantization: 距離近似

Query vector



Compressed database codes



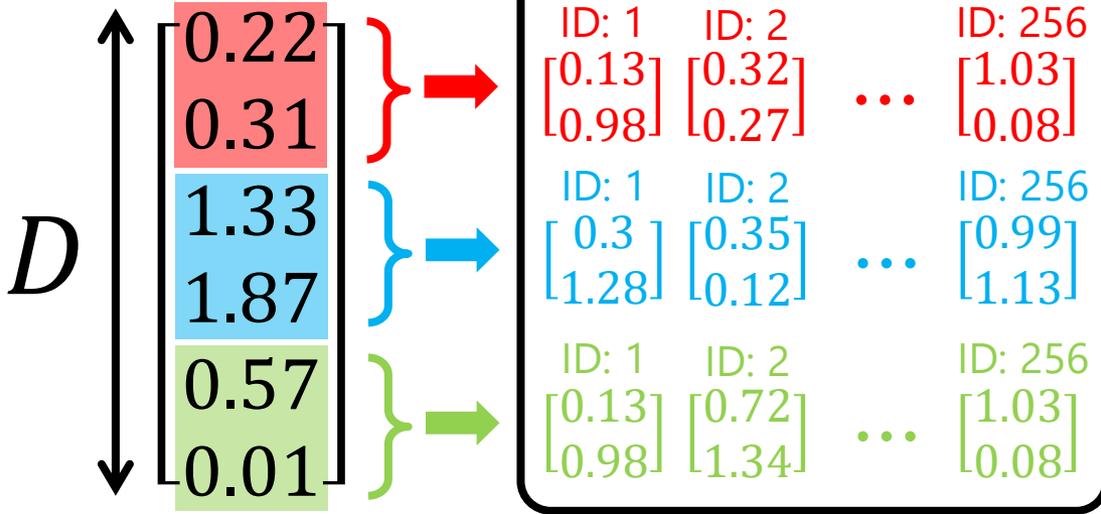
Distance:  
0.04 + 0.23

Distance table

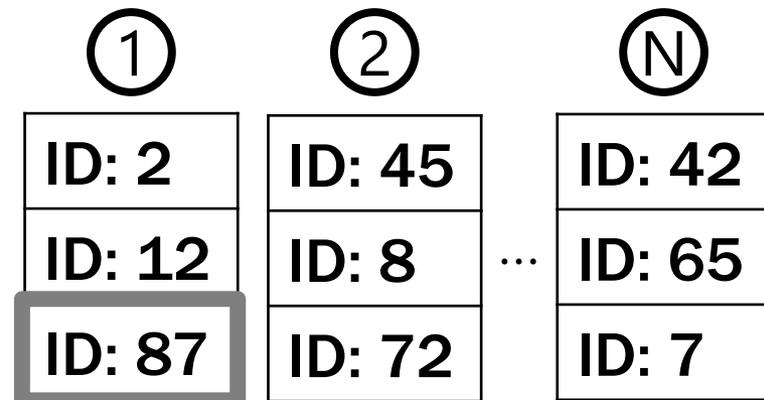
	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

# Product Quantization: 距離近似

Query vector



Compressed database codes



Distance:

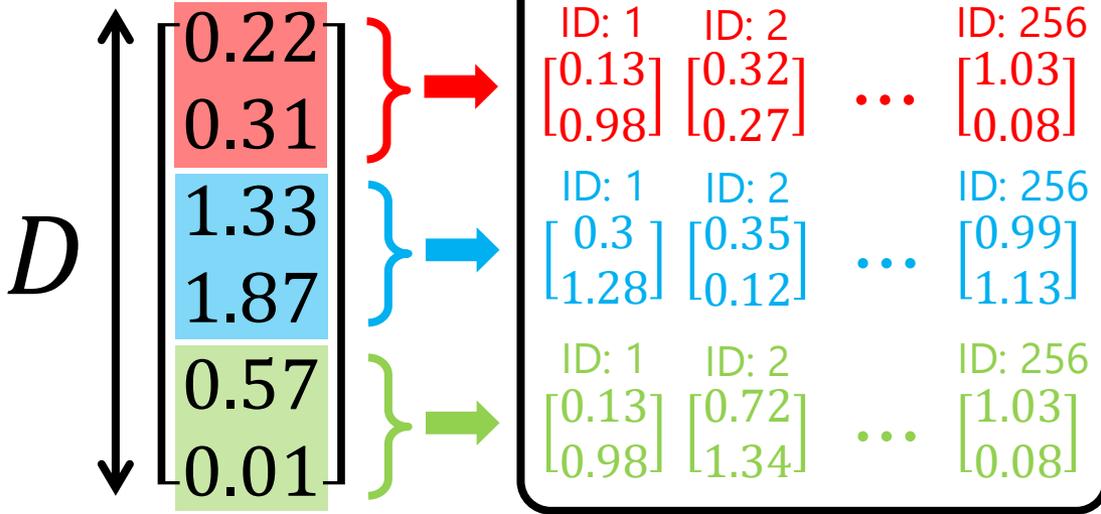
$$0.04 + 0.23 + 1.02$$

Distance table

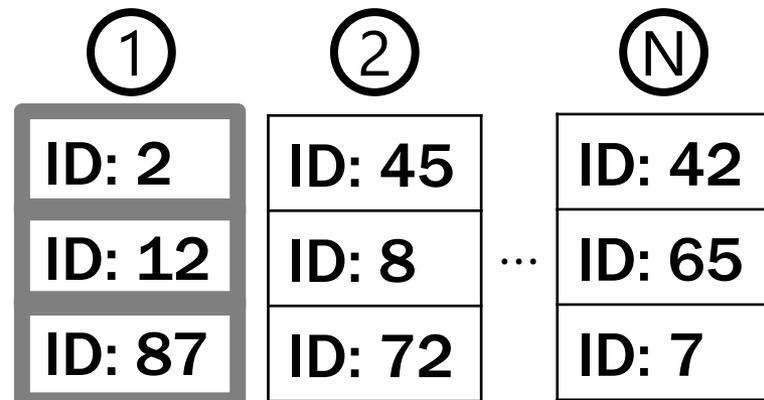
	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

# Product Quantization: 距離近似

Query vector



Compressed database codes



Distance table

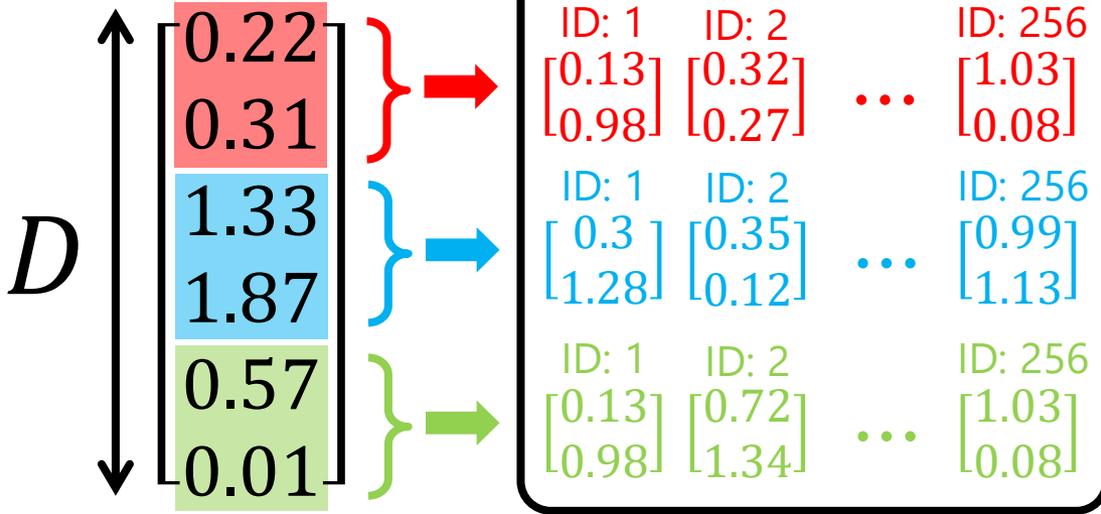
	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

Distance:

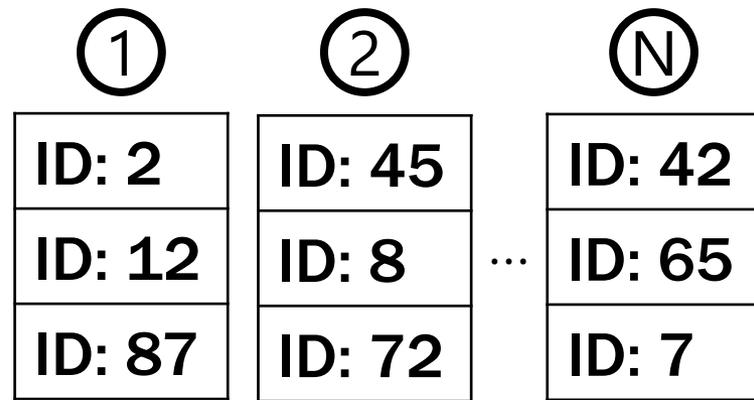
$$0.04 + 0.23 + 1.02 = 1.29$$

# Product Quantization: 距離近似

Query vector



Compressed database codes



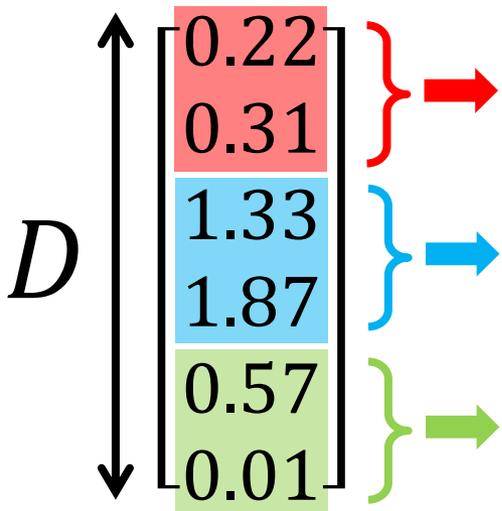
Distance:  
1.29      0.03      7.34

Distance table

	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

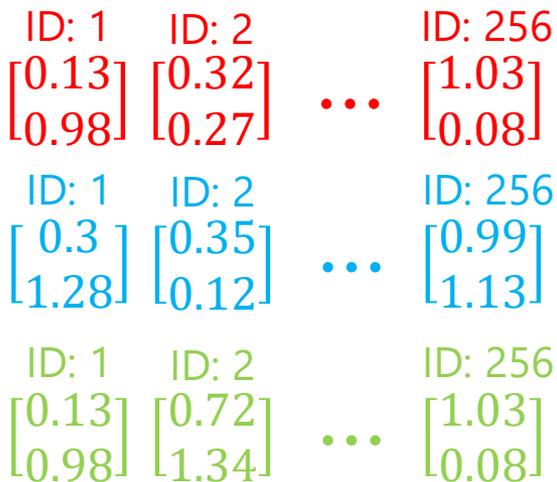
# Product Quantization: 距離近似

Query vector

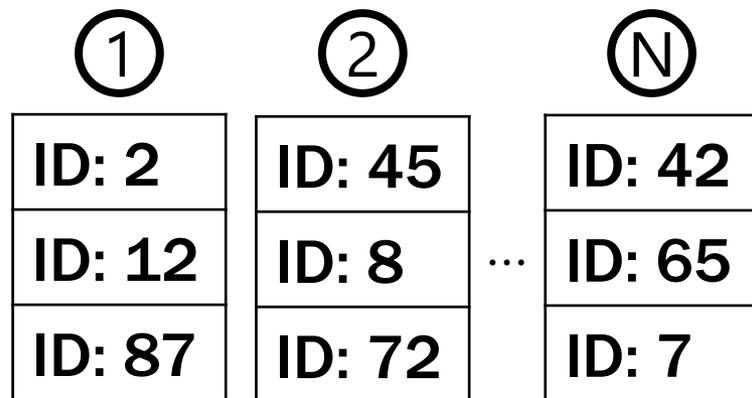


k-means assign

Codebooks



Compressed database codes



Distance:

1.29    0.03    7.34

Distance table

	1	2	...	256
1	8.2	0.04		2.1
2	3.4	11.2		5.5
3	0.31	1.1		2.4

早い:

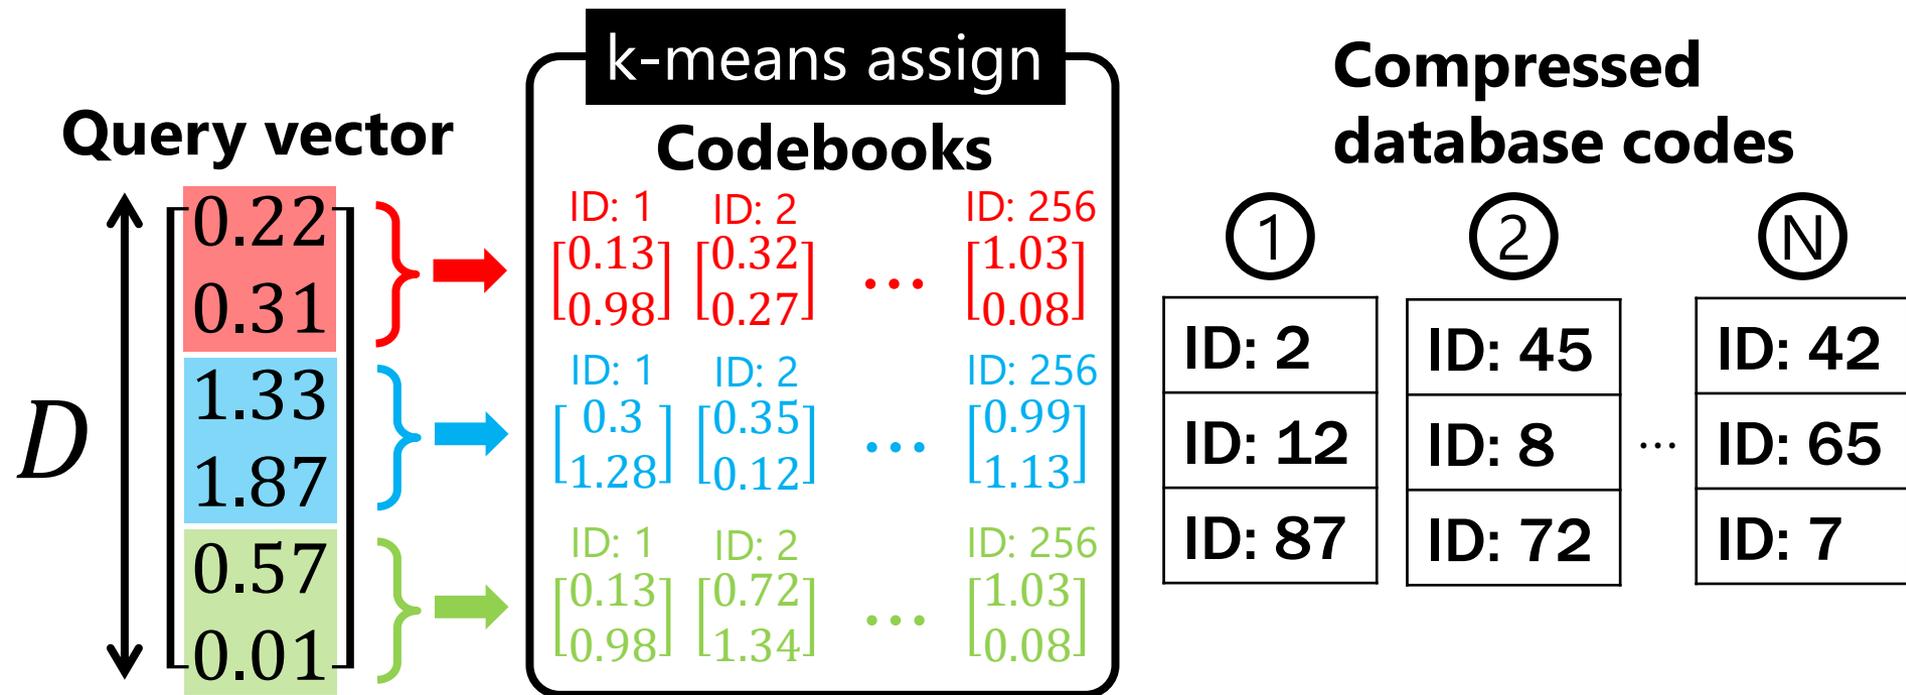
- Table lookup

計算量:  
 $O(DK + MN)$

正確に近似:

- 空間を  $2^{8M}$  に分割 78

# Product Quantization



- 単純
- メモリ効率良い
- 距離  $d(input, code)^2$  を近似計算可能

# Product Quantization

```
import numpy as np
from scipy.cluster.vq import vq, kmeans2
from scipy.spatial.distance import cdist

def train(vec, M):
    Ds = int(vec.shape[1] / M) # Ds = D / M
    # codeword[m][k] =  $c_k^m$ 
    codeword = np.empty((M, 256, Ds), np.float32)

    for m in range(M):
        vec_sub = vec[:, m * Ds : (m + 1) * Ds]
        codeword[m], label = kmeans2(vec_sub, 256)

    return codeword

def encode(codeword, vec): #  $vec = \{x_n\}_{n=1}^N$ 
    M, _K, Ds = codeword.shape
    # pqcode[n] =  $i(x_n)$ , pqcode[n][m] =  $i^m(x_n)$ 
    pqcode = np.empty((vec.shape[0], M), np.uint8)

    for m in range(M): # Eq. (2) and Eq. (3)
        vec_sub = vec[:, m * Ds : (m + 1) * Ds]
        pqcode[:, m], dist = vq(vec_sub, codeword[m])

    return pqcode
```

```
def search(codeword, pqcode, query):
    M, _K, Ds = codeword.shape
    # dist_table =  $D(m, k)$ 
    dist_table = np.empty((M, 256), np.float32)

    for m in range(M):
        query_sub = query[m * Ds : (m + 1) * Ds]
        dist_table[m, :] = cdist([query_sub],
            ↪ codeword[m], 'sqeuclidean')[0] # Eq. (5)

    # Eq. (6)
    dist = np.sum(dist_table[range(M), pqcode], axis=1)

    return dist

if __name__ == "__main__":
    # Read vec_train, vec ( $\{x_n\}_{n=1}^N$ ), and query (y)
    M = 4
    codeword = train(vec_train, M)
    pqcode = encode(codeword, vec)
    dist = search(codeword, pqcode, query)
    print(dist)
```

➤ 非常に単純

# PQそのものの発展

**元論文**  
[Jégou, TPAMI 11]

**PQそのもの**

**PQを使った探索システム**

**事前変換**

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数  
コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenko, CVPR 15]

**一般化**

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

**新しい問題設定**

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化 : k-means

リランキング : 残差PQコード

**疎量子化の工夫**

複数k-means [Xia, ICCV 13]

PQ [Babenko, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenko, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

**リランキングの工夫**

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

# PQを使った探索システムの発展

**その他トピック**

余分ビット [Heo, CVPR 14]

ハッシュテーブル [Matsui, ICCV 15]

GPU [Wieschollek, CVPR 16]

キャッシュ [André, VLDB 15]

画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

# PQそのものの発展

元論文 [Jégou, TPAMI 11]

PQそのもの

PQを使った探索システム

事前変換

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenko, CVPR 15]

一般化

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

新しい問題設定

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化 : k-means

リランキング : 残差PQコード

疎量子化の工夫

複数k-means [Xia, ICCV 13]

PQ [Babenko, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenko, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

リランキングの工夫

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

# PQを使った探索システムの発展

その他トピック

余分ビット [Heo, CVPR 14]

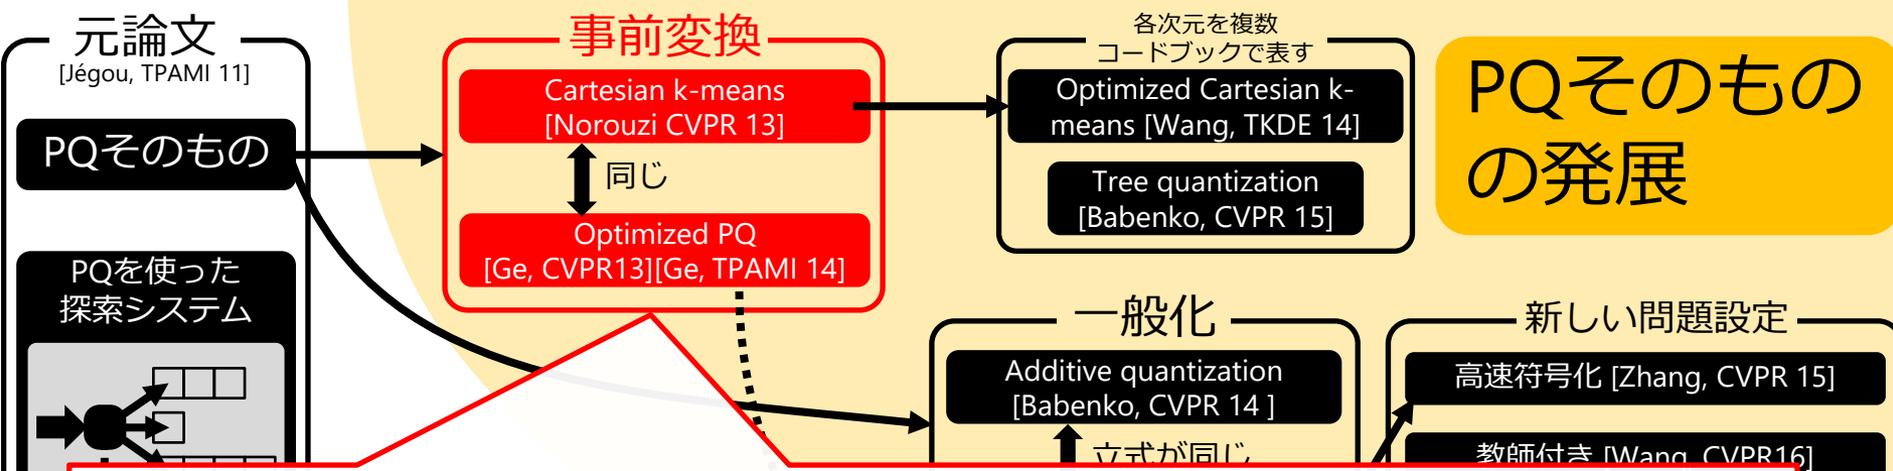
ハッシュテーブル [Matsui, ICCV 15]

GPU [Wieschollek, CVPR 16]

キャッシュ [André, VLDB 15]

画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

# PQそのものの発展



➤ 「ベクトルの分割」が単純すぎないか？

➤ 事前にベクトルを“回転”させ、分割したときのエラーを最小にする

1)  $x \leftarrow Rx$

2)  $x \rightarrow PQ$

このときの誤差が最小となるように

回転行列  $R$  を求める

探索システムの発展

# PQそのものの発展

元論文 [Jégou, TPAMI 11]

PQそのもの

PQを使った探索システム

事前変換

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenco, CVPR 15]

一般化

Additive quantization [Babenco, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

新しい問題設定

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化 : k-means

リランキング : 残差PQコード

疎量子化の工夫

複数k-means [Xia, ICCV 13]

PQ [Babenco, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenco, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenco, CVPR 16]

リランキングの工夫

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

# PQを使った探索システムの発展

その他トピック

余分ビット [Heo, CVPR 14]

ハッシュテーブル [Matsui, ICCV 15]

GPU [Wieschollek, CVPR 16]

キャッシュ [André, VLDB 15]

画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

➤ PQはxをM個のD/M次元  
コードワードで表した

$$\begin{bmatrix} 0.22 \\ 0.31 \\ 1.33 \\ 1.87 \\ 0.57 \\ 0.01 \end{bmatrix} \sim \begin{bmatrix} 0.32 \\ 0.27 \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} + \begin{bmatrix} \mathbf{0} \\ 1.19 \\ 1.66 \\ \mathbf{0} \end{bmatrix} + \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ 0.32 \\ 1.10 \end{bmatrix}$$

➤ AQ・CQはM個のD次元  
コードワードで表す

$$\begin{bmatrix} 0.22 \\ 0.31 \\ 1.33 \\ 1.87 \\ 0.57 \\ 0.01 \end{bmatrix} \sim \begin{bmatrix} 0.02 \\ 0.13 \\ 0.42 \\ 0.33 \\ 0.12 \\ 0.00 \end{bmatrix} + \begin{bmatrix} 0.19 \\ 0.02 \\ 0.31 \\ 0.01 \\ 0.23 \\ 0.01 \end{bmatrix} + \begin{bmatrix} 0.02 \\ 0.20 \\ 0.56 \\ 1.02 \\ 0.66 \\ 0.10 \end{bmatrix}$$

PQの一般化. 表現能力高い

各次元を複数  
コードブックで表す

- Optimized Cartesian k-means [Wang, TKDE 14]
- Tree quantization [Babenko, CVPR 15]

# PQそのものの発展

一般化

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

新しい問題設定

- 高速符号化 [Zhang, CVPR 15]
- 教師付き [Wang, CVPR16]
- マルチモーダル [Zhang, CVPR16]

OPQ+local codebook [Babenko, TPAMI 15]

その他トピック

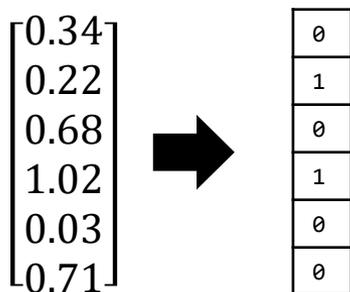
- 余分ビット [Heo, CVPR 14]
- ハッシュテーブル [Matsui, ICCV 15]
- GPU [Wieschollek, CVPR 16]
- キャッシュ [André, VLDB 15]
- 画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

PQを使った  
探索システムの発展

# ショートコードによる近似最近傍探索

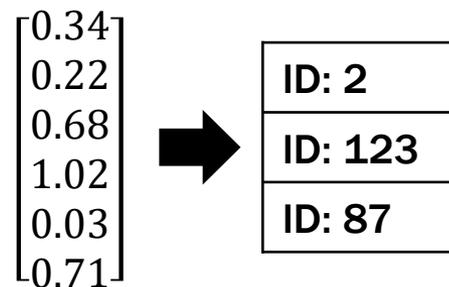
## ➤ 基本的な考え方

ハミング系



- 原理
- 手法の例
- 高速計算

ルックアップ系



- 原理
- 探索システム

# PQそのものの発展

元論文 [Jégou, TPAMI 11]

**PQそのもの**

PQを使った探索システム

事前変換

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenko, CVPR 15]

一般化

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

新しい問題設定

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化 : k-means

リランキング : 残差PQコード

疎量子化の工夫

複数k-means [Xia, ICCV 13]

PQ [Babenko, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenko, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

リランキングの工夫

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

# PQを使った探索システムの発展

その他トピック

余分ビット [Heo, CVPR 14]

ハッシュテーブル [Matsui, ICCV 15]

GPU [Wieschollek, CVPR 16]

キャッシュ [André, VLDB 15]

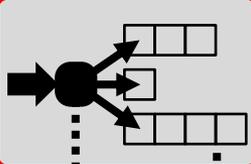
画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

# 元論文

[Jégou, TPAMI 11]

PQそのもの

PQを使った  
探索システム



疎量子化：  
k-means

リランキング：  
残差PQコード

疎量子

複数k-means [Xu, ICCV 13]

PQ [Babenko, CVPR 12]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

ジャーナル版

OPQ+local codebook  
[Babenko, TPAMI 15]

リランキングの工夫

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

PQを使った  
探索システムの発展

- PQと転置インデクスを組み合わせた探索システム
- 高精度, 高速, 省メモリ
- この探索システムの発展形が, ユークリッド距離を用いる近似最近傍探索のstate-of-the-art
- 最も単純なIVFADCについて解説する

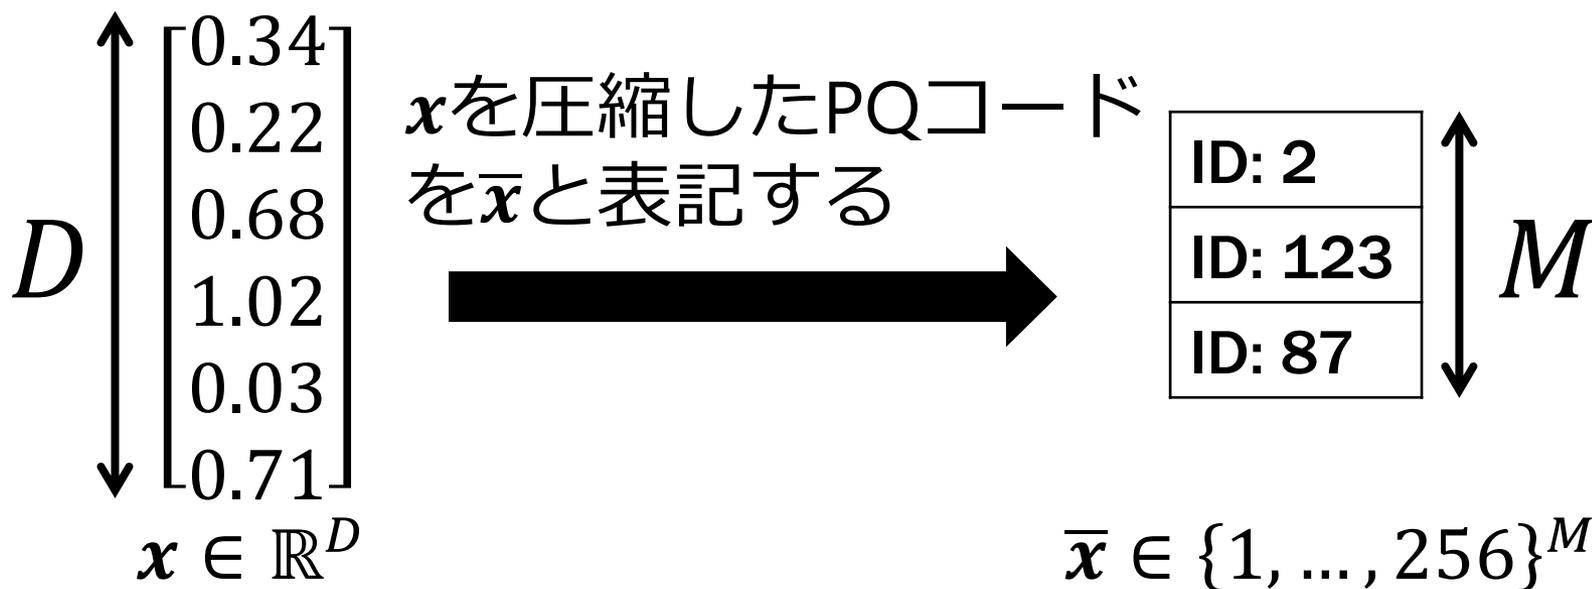
ハッシュテーブル  
[Matsui, ICCV 15]

GPU  
[Wieschollek, CVPR 16]

キャッシュ  
[André, VLDB 15]

画像検索システム  
[Jégou, PAMI 12]  
[Spyromitros-Xioufis, TMM 14]

# PQを用いた探索システム：復習と表記



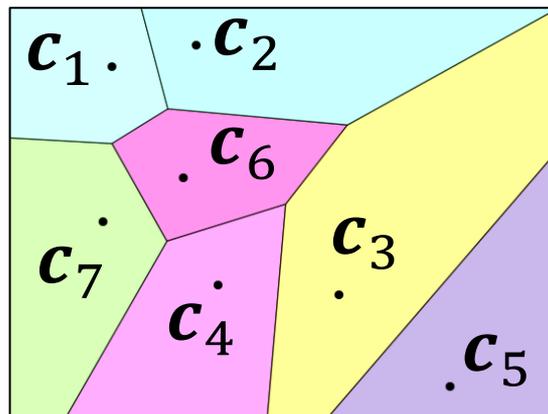
$x, y \in \mathbb{R}^D$  として,  $x$  が圧縮されて  $\bar{x}$  となっているとき, 二乗距離  $d(y, x)^2$  はコード  $\bar{x}$  を用いて高速近似計算出来る

$$d(y, x)^2 \sim d_A(y, \bar{x})^2$$

ベクトルとベクトル  
の二乗距離は・・・

ベクトルとコードで  
近似出来る

# PQを用いた探索システム：データ登録



粗量子化

$k = 1$

$k = 2$

⋮

$k = K$

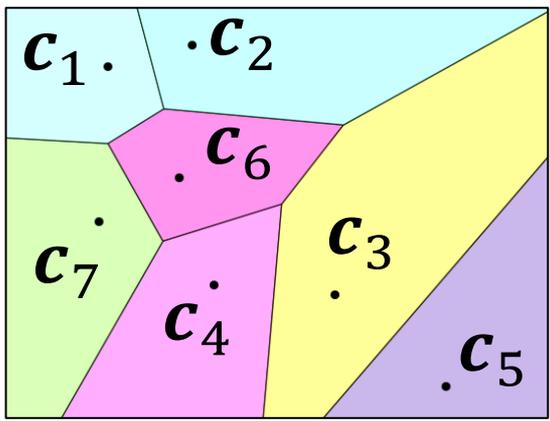
- 空間を $K$ 分割する「粗量子化器」を用意しておく．ここでは単純なボロノイ空間分割（k-means割り当てそのもの）
- 各 $\{c_k\}_{k=1}^K$ は訓練データに単純にk-meansを適用し作る

# PQを用いた探索システム：データ登録

➤ ベクトル $x_1$ の登録を考える

$\begin{bmatrix} 1.02 \\ 0.73 \\ 0.56 \\ 1.37 \\ 1.37 \\ 0.72 \end{bmatrix}$

$x_1$



粗量子化

$k = 1$

$k = 2$

$\vdots$

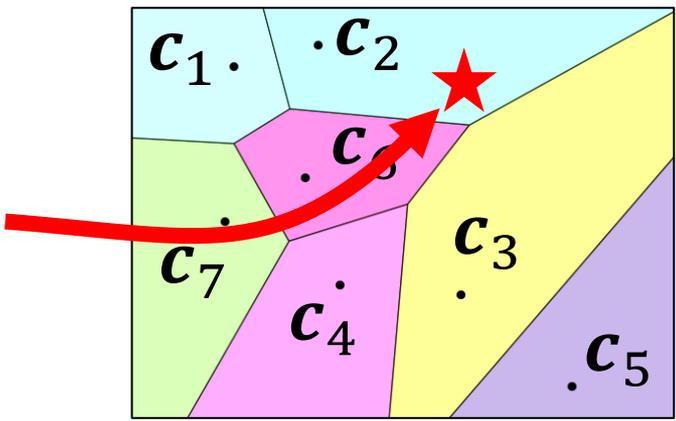
$k = K$

# PQを用いた探索システム：データ登録

➤ ベクトル  $x_1$  の登録を考える

$\begin{bmatrix} 1.02 \\ 0.73 \\ 0.56 \\ 1.37 \\ 1.37 \\ 0.72 \end{bmatrix}$

$x_1$



粗量子化

$k = 1$

$k = 2$

$\vdots$

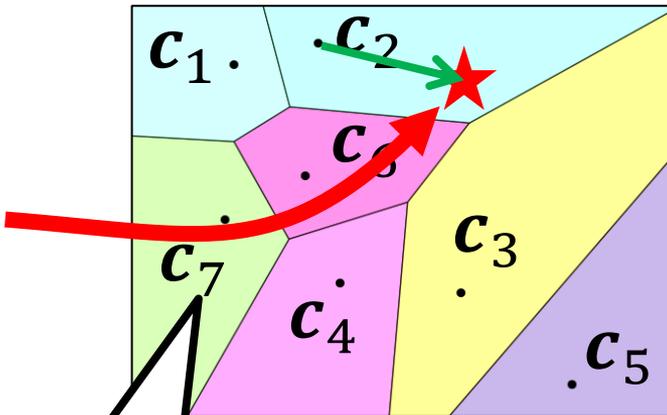
$k = K$

# PQを用いた探索システム：データ登録

➤ ベクトル  $x_1$  の登録を考える

$\begin{bmatrix} 1.02 \\ 0.73 \\ 0.56 \\ 1.37 \\ 1.37 \\ 0.72 \end{bmatrix}$

$x_1$



粗量子化

$k = 1$

$k = 2$

$\vdots$

$k = K$

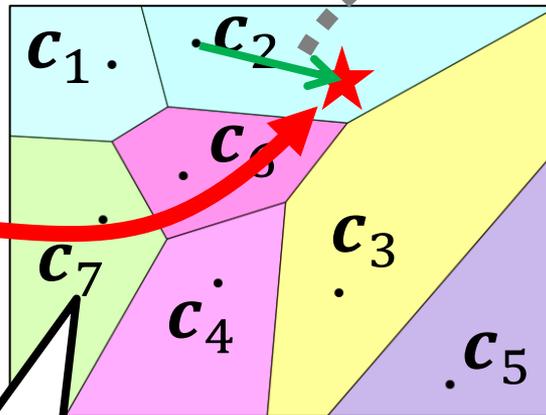
- $x_1$  に一番近いものは  $c_2$
- $x_1$  と  $c_2$  の残差  $r_1 = x_1 - c_2$  (  $\rightarrow$  ) を計算する

# PQを用いた探索システム：データ登録

➤ ベクトル  $x_1$  の登録を考える

$\begin{bmatrix} 1.02 \\ 0.73 \\ 0.56 \\ 1.37 \\ 1.37 \\ 0.72 \end{bmatrix}$

$x_1$



粗量子化

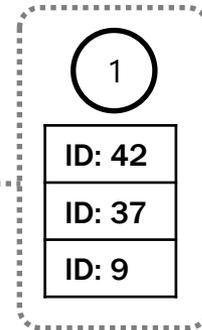
- $x_1$  に一番近いものは  $c_2$
- $x_1$  と  $c_2$  の残差  $r_1 = x_1 - c_2$  (→) を計算する

$k = 1$

$k = 2$

⋮

$k = K$

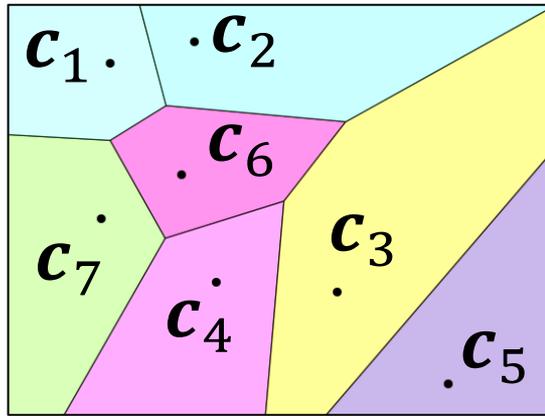


$\bar{r}_1$

- 残差  $r_1$  をPQで圧縮し, コード  $\bar{r}_1$  を作り, 番号「1」とともに記録する
- すなわち,  $(i, \bar{r}_i)$  を記録する

# PQを用いた探索システム：データ登録

- 全データに関して、「番号+残差」をリストとして保存



粗量子化

$k = 1$

245	12	1932	1721
ID: 42	ID: 25	ID: 38	ID: 16
ID: 37	ID: 47	ID: 49	ID: 72
ID: 9	ID: 32	ID: 72	ID: 95

$k = 2$

1	3721
ID: 42	ID: 18
ID: 37	ID: 4
ID: 9	ID: 96

⋮

$k = K$

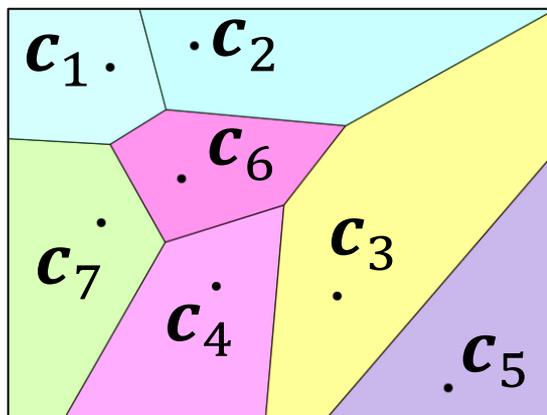
8621	145	324
ID: 24	ID: 77	ID: 32
ID: 54	ID: 21	ID: 11
ID: 23	ID: 5	ID: 85

# PQを用いた探索システム：探索

クエリ $q$ に近い  
データを探す

0.54  
2.35  
0.82  
0.42  
0.14  
0.32

$q$



粗量子化

$k = 1$

245	12	1932	1721
ID: 42	ID: 25	ID: 38	ID: 16
ID: 37	ID: 47	ID: 49	ID: 72
ID: 9	ID: 32	ID: 72	ID: 95

$k = 2$

1	3721
ID: 42	ID: 18
ID: 37	ID: 4
ID: 9	ID: 96

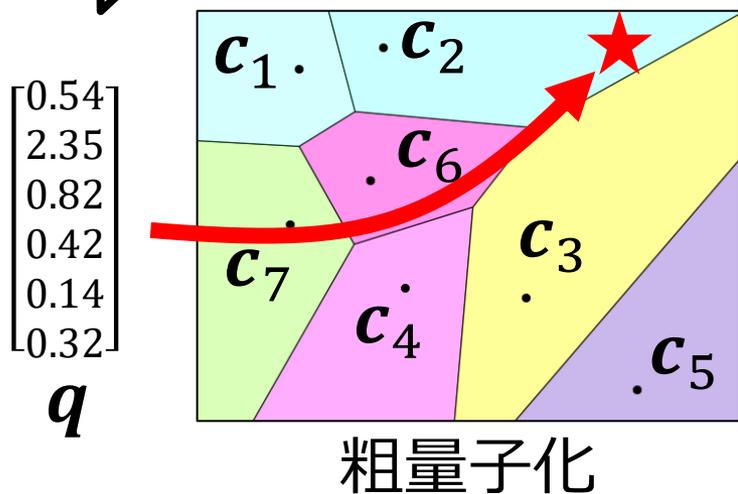
⋮

$k = K$

8621	145	324
ID: 24	ID: 77	ID: 32
ID: 54	ID: 21	ID: 11
ID: 23	ID: 5	ID: 85

# PQを用いた探索システム：探索

クエリ $q$ に近い  
データを探す



$k = 1$

245	12	1932	1721
ID: 42	ID: 25	ID: 38	ID: 16
ID: 37	ID: 47	ID: 49	ID: 72
ID: 9	ID: 32	ID: 72	ID: 95

$k = 2$

1	3721
ID: 42	ID: 18
ID: 37	ID: 4
ID: 9	ID: 96

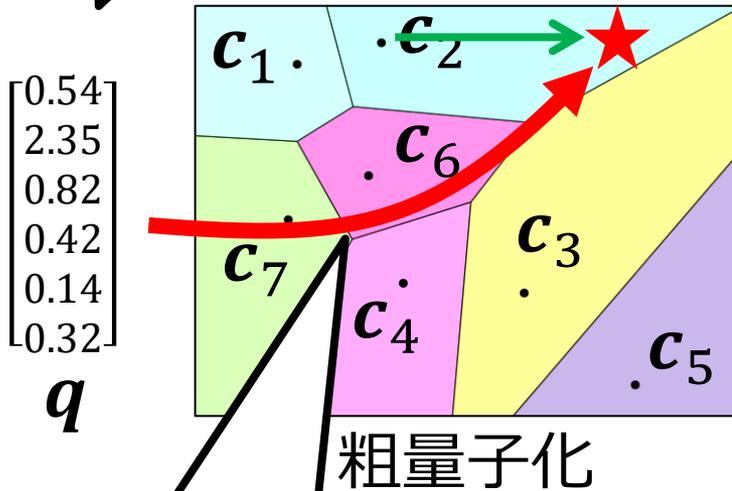
⋮

$k = K$

8621	145	324
ID: 24	ID: 77	ID: 32
ID: 54	ID: 21	ID: 11
ID: 23	ID: 5	ID: 85

# PQを用いた探索システム：探索

クエリ $q$ に近いデータを探す



$q$ に一番近いものは $c_2$   
 $q$ と $c_2$ の残差  $r_q = q - c_2$  を計算する

$k = 1$

245	12	1932	1721
ID: 42	ID: 25	ID: 38	ID: 16
ID: 37	ID: 47	ID: 49	ID: 72
ID: 9	ID: 32	ID: 72	ID: 95

$k = 2$

1	3721
ID: 42	ID: 18
ID: 37	ID: 4
ID: 9	ID: 96

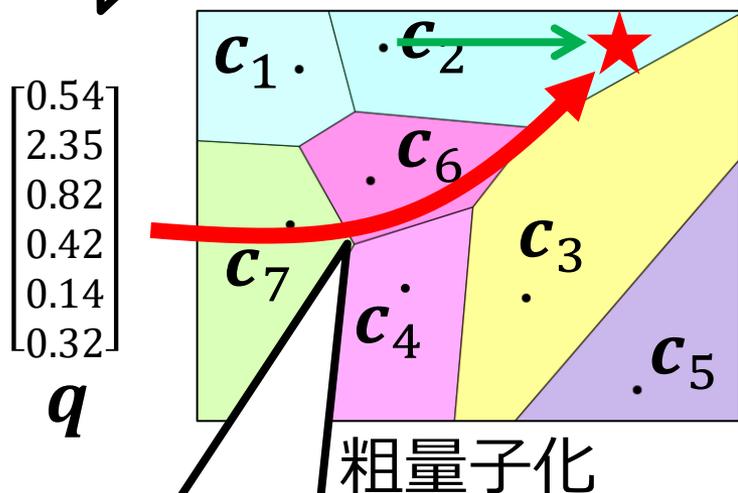
⋮

$k = K$

8621	145	324
ID: 24	ID: 77	ID: 32
ID: 54	ID: 21	ID: 11
ID: 23	ID: 5	ID: 85

# PQを用いた探索システム：探索

➤ クエリ $q$ に近いデータを探す



➤  $q$ に一番近いものは $c_2$   
 ➤  $q$ と $c_2$ の残差  $r_q = q - c_2$ を計算する

$k = 1$

245	12	1932	1721
ID: 42	ID: 25	ID: 38	ID: 16
ID: 37	ID: 47	ID: 49	ID: 72
ID: 9	ID: 32	ID: 72	ID: 95

$k = 2$

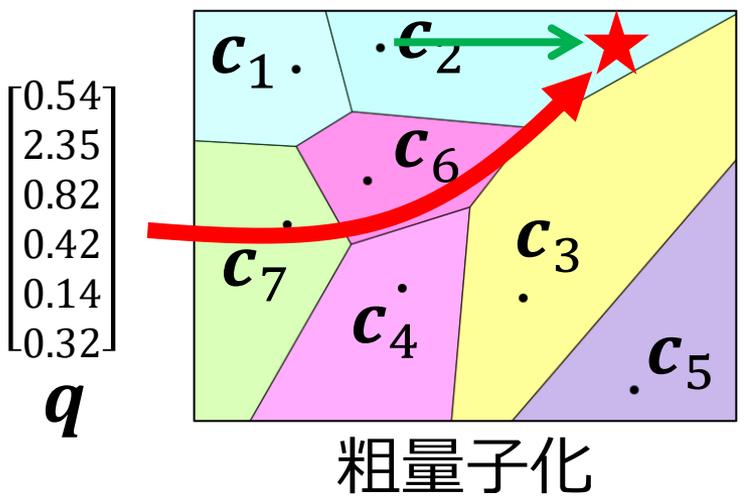
1	3721
ID: 42	ID: 18
ID: 37	ID: 4
ID: 9	ID: 96

➤  $k = 2$ に登録されている各 $(i, \bar{r}_i)$ について,  $r_q$ と比べる  

$$d(q, x_i)^2 = d(q - c_2, x_i - c_2)^2$$

$$= d(r_q, r_i)^2 \sim d_A(r_q, \bar{r}_i)^2$$
 ➤ 最も近いものを選ぶ  
 (リランキング. 戦略色々)

# PQを用いた探索システム：探索



- 粗量子化のコスト+リランキングのコストを調整することで、高速な探索を実現
- 残差に注目することで、近似精度を高めた

$k = 1$

245	12	1932	1721
ID: 42	ID: 25	ID: 38	ID: 16
ID: 37	ID: 47	ID: 49	ID: 72
ID: 9	ID: 32	ID: 72	ID: 95

$k = 2$

1	3721
ID: 42	ID: 18
ID: 37	ID: 4
ID: 9	ID: 96

⋮

$k = K$

8621	145	324
ID: 24	ID: 77	ID: 32
ID: 54	ID: 21	ID: 11
ID: 23	ID: 5	ID: 85

# PQそのものの発展

**元論文**  
[Jégou, TPAMI 11]

**PQそのもの**

**PQを使った探索システム**

**事前変換**

Cartesian k-means [Norouzi CVPR 13]

↑ 同じ ↓

Optimized PQ [Ge, CVPR13][Ge, TPAMI 14]

各次元を複数  
コードブックで表す

Optimized Cartesian k-means [Wang, TKDE 14]

Tree quantization [Babenko, CVPR 15]

**一般化**

Additive quantization [Babenko, CVPR 14]

↑ 立式が同じ ↓

Composite quantization [Zhang, ICML 14]

**新しい問題設定**

高速符号化 [Zhang, CVPR 15]

教師付き [Wang, CVPR16]

マルチモーダル [Zhang, CVPR16]

疎量子化：  
k-means

リランキング：  
残差PQコード

**疎量子化の工夫**

複数k-means [Xia, ICCV 13]

PQ [Babenko, CVPR 12] → ジャーナル版 → OPQ+local codebook [Babenko, TPAMI 15]

列挙の高速化 [Iwamura, ICCV 13]

残差量子化 [Babenko, CVPR 16]

**リランキングの工夫**

二段階 [Jégou, ICASSP 11]

local codebook [Kalantidis, CVPR 14]

リランキング側残差考慮 [Heo, CVPR 16]

# PQを使った探索システムの発展

**その他トピック**

余分ビット [Heo, CVPR 14]

ハッシュテーブル [Matsui, ICCV 15]

GPU [Wieschollek, CVPR 16]

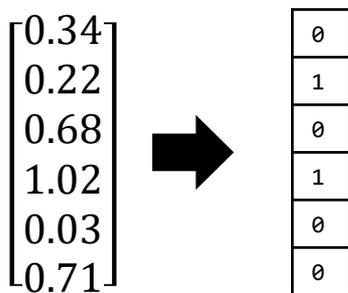
キャッシュ [André, VLDB 15]

画像検索システム [Jégou, PAMI 12] [Spyromitros-Xioufis, TMM 14]

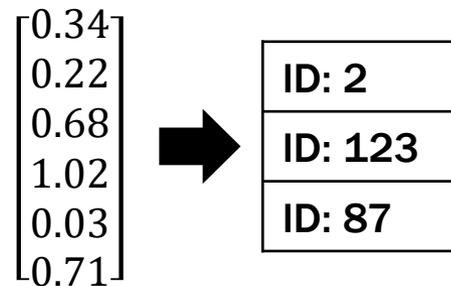
# ショートコードによる近似最近傍探索

➤ 基本的な考え方：ベクトルを省メモリ表現に圧縮し圧縮された世界で探索を行う

ハミング系



ルックアップ系



ベクトル表現

バイナリコード： $\{0, 1\}^B$

PQコード： $\{1, \dots, 256\}^M$

距離表現

ハミング距離

表参照距離

表現能力

○

◎

距離計算速度

◎

○

Pros

補助構造がいない

元のベクトルを  
近似再構成可能

Cons

近似再構成は出来ない

補助構造が必要  
(コードブック)

## 参考文献

- [Weiss, NIPS 08] Y. Weiss, A. Torralba, and R. Fergus: "Spectral Hashing", NIPS (2008).
- [Norouzi, TPAMI 13] M. Norouzi, A. Punjani, and D. F. Fleet: "Fast Exact Search in Hamming Space With Multi-Index Hashing", IEEE TPAMI (2013).
- [Muja, TPAMI 14] M. Muja and D. G. Lowe: "Scalable nearest neighbour algorithms for high dimensional data", IEEE TPAMI (2014).
- [Jégou, TPAMI 11] H. Jégou, M. Douze and C. Schmid: "Product quantization for nearest neighbor search", IEEE TPAMI (2011).
- [Norouzi, CVPR 13] M. Norouzi and D. J. Fleet: "Cartesian k-means", CVPR (2013).
- [Ge, CVPR 13] T. Ge, K. He, Q. Ke and J. Sun: "Optimized product quantization for approximate nearest neighbor search", CVPR (2013).
- [Ge, TPAMI 14] T. Ge, K. He, Q. Ke and J. Sun: "Optimized product quantization", IEEE TPAMI, (2014).
- [Wang, TKDE 14] J. Wang, J. Wang, J. Song, X.-S. Xu, H. T. Shen and S. Li: "Optimized cartesian k-means", IEEE TKDE (2014).
- [Babenko, CVPR 15] A. Babenko and V. Lempitsky: "Tree quantization for large-scale similarity search and classification", CVPR (2015).
- [Babenko, CVPR 14] A. Babenko and V. Lempitsky: "Additive quantization for extreme vector compression", CVPR (2014).
- [Zhang, ICML 14] T. Zhang, C. Du and J. Wang: "Composite quantization for approximate nearest neighbor search", ICML (2014).
- [Zhang, CVPR 15] T. Zhang, G.-J. Qi, J. Tang and J. Wang: "Sparse composite quantization", CVPR (2015).
- [Wang, CVPR16] X. Wang, T. Zhang, G.-J. Qi, J. Tang and J. Wang: "Supervised quantization for similarity search", CVPR (2016).
- [Zhang, CVPR 16] T. Zhang and J. Wang: "Collaborative quantization for cross-modal similarity search", CVPR (2016).
- [Xia, ICCV 13] Y. Xia, K. He, F. Wen and J. Sun: "Joint inverted indexing", ICCV (2013).
- [Babenko, CVPR 12] A. Babenko and V. Lempitsky: "The inverted multi-index", CVPR (2012).
- [Iwamura, ICCV 13] M. Iwamura, T. Sato and K. Kise: "What is the most efficient way to select nearest neighbor candidates for fast approximate nearest neighbor search?", ICCV (2013).
- [Babenko, CVPR 16] A. Babenko and V. Lempitsky: "Efficient indexing of billion-scale datasets of deep descriptors", CVPR (2016).
- [Babenko, TPAMI 15] A. Babenko and V. Lempitsky: "The inverted multi-index", IEEE TPAMI, (2015).
- [Jégou, ICASSP 11] H. Jégou, R. Tavenard, M. Douze and L. Amsaleg: "Searching in one billion vectors: Re-rank with source coding", ICASSP (2011).
- [Kalantidis, CVPR 14] Y. Kalantidis and Y. Avrithis: "Locally optimized product quantization for approximate nearest neighbor search", CVPR (2014).
- [Heo, CVPR 16] J.-P. Heo, Z. Lin, X. Shen, J. Brandt and S. Eui Yoon: "Shortlist selection with residual aware distance estimator for k-nearest neighbor search", CVPR (2016).
- [Heo, CVPR 14] J.-P. Heo, Z. Lin and S.-E. Yoon: "Distance encoded product quantization", CVPR (2014).
- [Matsui, ICCV 15] Y. Matsui, T. Yamasaki and K. Aizawa: "Pqtable: Fast exact asymmetric distance neighbor search for product quantization using hash tables", ICCV (2015).
- [Wieschollek, CVPR 16] P. Wieschollek, O. Wang, A. Sorkine-Hornung and H. P. A. Lensch: "Efficient large-scale approximate nearest neighbor search on the gpu", CVPR (2016).
- [André, VLDB 15] F. André, A.-M. Kermarrec and N. L. Scouarnec: "Cache locality is not enough: High-performance nearest neighbor search with product quantization fast scan", VLDB (2015).
- [Jégou, PAMI 12] H. Jégou, F. Perronnin, M. Douze, J. Sánchez, P. Pérez and C. Schmid: "Aggregating local image descriptors into compact codes", IEEE TPAMI, (2012).
- [Spyromitros-Xioufis, TMM 14] E. Spyromitros-Xioufis, S. Papadopoulos, I. Y. Kompatsiaris, G. Tsoumakas and I. Vlahavas: "A comprehensive study over vlad and product quantization in large-scale image retrieval", IEEE TMM, (2014).