



3. 多次元インデックス

(マルチメディアデータベース序論, 全6回)

<https://www.kkaneko.jp/de/multimediadb/index.html>

金子邦彦



空間データ



- 多次元の属性を持ったデータ
 (x, y) , (x, y, z) など
- しばしば、位相、幾何の情報も扱わねばならない

空間データの種類



- 点／ベクトルデータ
 - 位置情報のみ（「領域」がない）
- 図形データ
 - 位置，領域がある

特徴量



- 静止画像 → 1つの「多次元ベクトル」
- 動画像 → 複数個の「多次元ベクトル」の並び

特徴量は「ベクトル」のデータ

図形データの種類

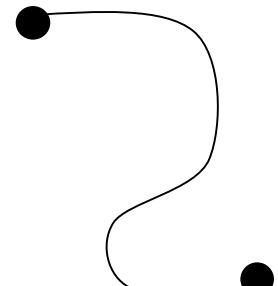
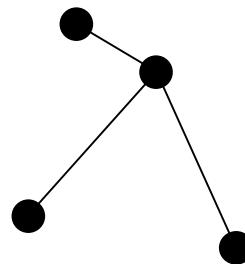
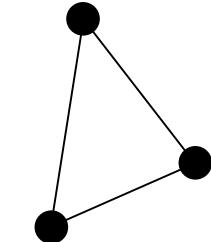
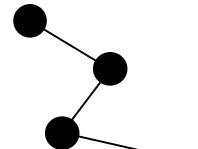
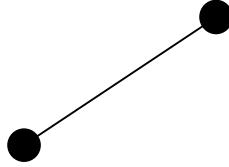


- ・図形データは、 2次元， 3次元

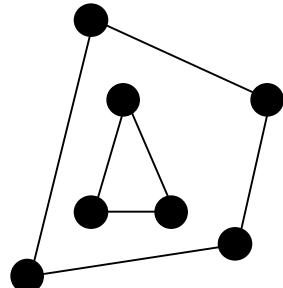
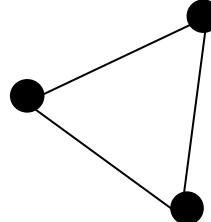
点



線



面

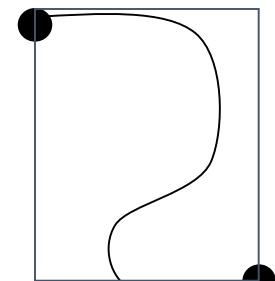
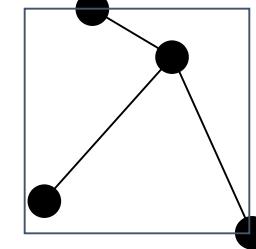
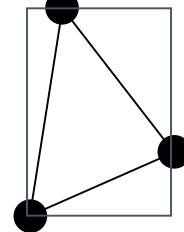
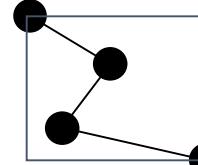
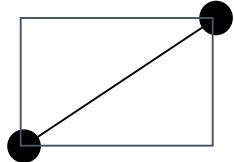


図形データは、近似表現（矩形など）し、
インデックスで管理

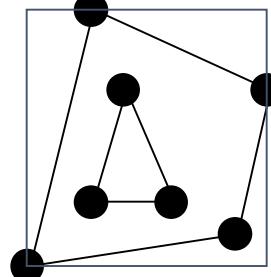
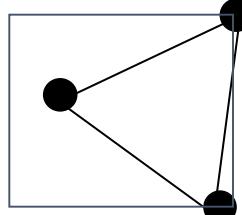
点



線



面



空間データ用のインデックスの種類



- ハッシュ

- ある規則で、データを分割
- Grid Files : メッシュ構造によるインデックス
- Multidimensional Trie : Trie の拡張
- Multikey hashing : ハッシュの拡張

- B-tree の利用

- データを、「1次元空間」上にマッピング
- 各種の空間充填曲線（Z曲線など）を利用

空間データ用のインデックスの種類



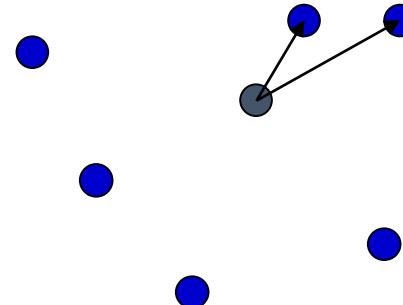
• 木構造

- データを階層的にクラスタ化
- 古典的な多次元データ構造
 - 2n tree, k-d Tree, MX-Quadtree
- R-Tree ファミリ
 - R-tree, R*-tree
- 最近接点探索用
 - SS-tree, SR-tree, VAM Split R-tree
- 多次元データ構造（ユークリッド空間）
 - X-tree, LSD –tree, Hybrid tree
- VA-File ファミリ（ベクトルの近似表現）
 - IQ-tree, A-tree 本来のVA-Fileは木構造でない
- metric tree ファミリ
 - metric tree, M-tree, MVP-tree

空間問い合わせの研究課題 — 最近接点探索 —



最も近い k 個を求めよ
(k と質問点はユーザが指定)



空間問い合わせの研究課題 — 次元ののろい —

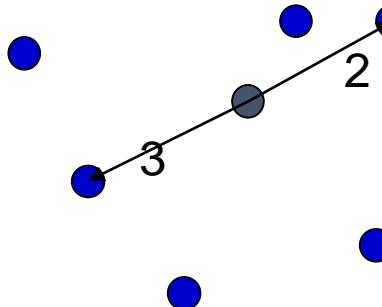


高次元のベクトルデータの「奇妙」な振る舞い

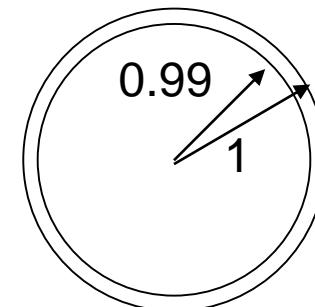
点がランダム分布しているとすると、
k 番目に近い点と k + 1 番目に近い点の比は

$$1 + 1/(kn) \quad (n \text{ は次元})$$

n が大きいと、この比は 1 に近づく



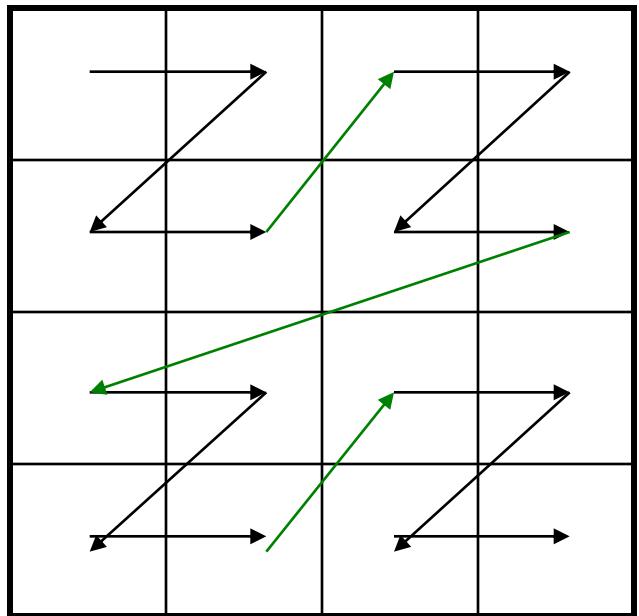
半径 0.99 と 半径 1 の超級の体積の比：
高次元では、体積の比が大きくなる





空間重点曲線による方法

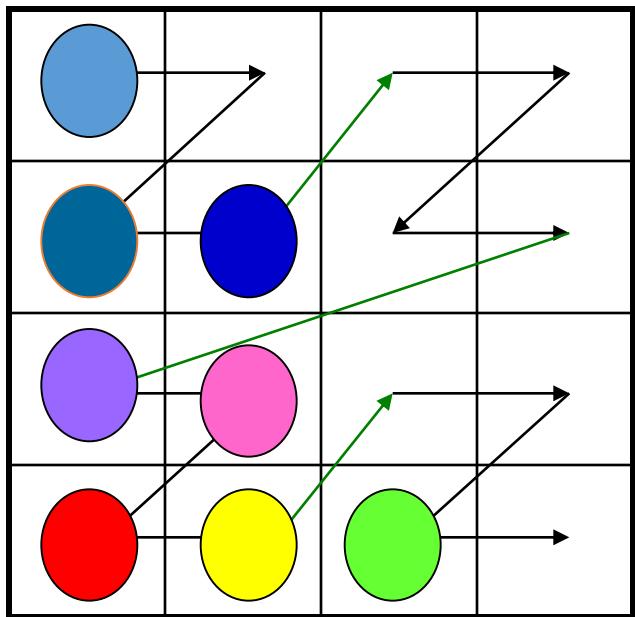
空間充填曲線の例



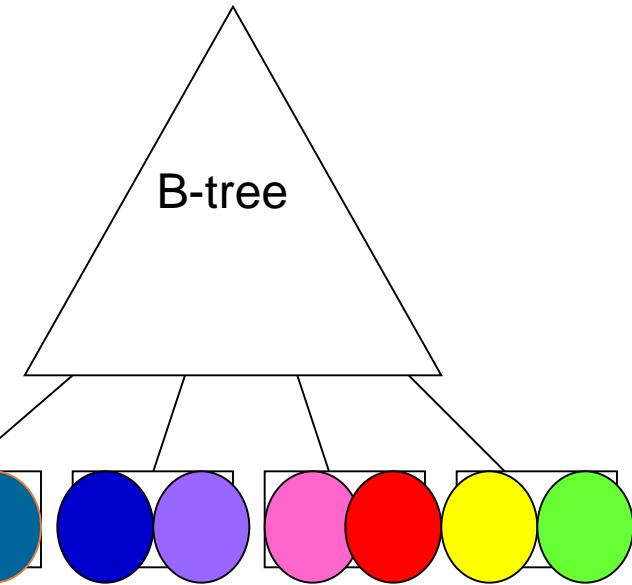
0	1	4	5
2	3	6	7
8	9	12	13
10	11	14	15

各領域の番号

空間充填曲線と B-tree



ページ
(ページ
数は 4)



B tree



- 木構造のインデックス
- 木の深さがバランスするよう、挿入、削除時に処理が行われる
- 各ノードは多数の分岐を持ち、結果として深さは少なくなる
 - 各ノードは、 $K + 1$ 個から $2K + 1$ 個までの分岐を持つ
(K はページサイズから決まる)

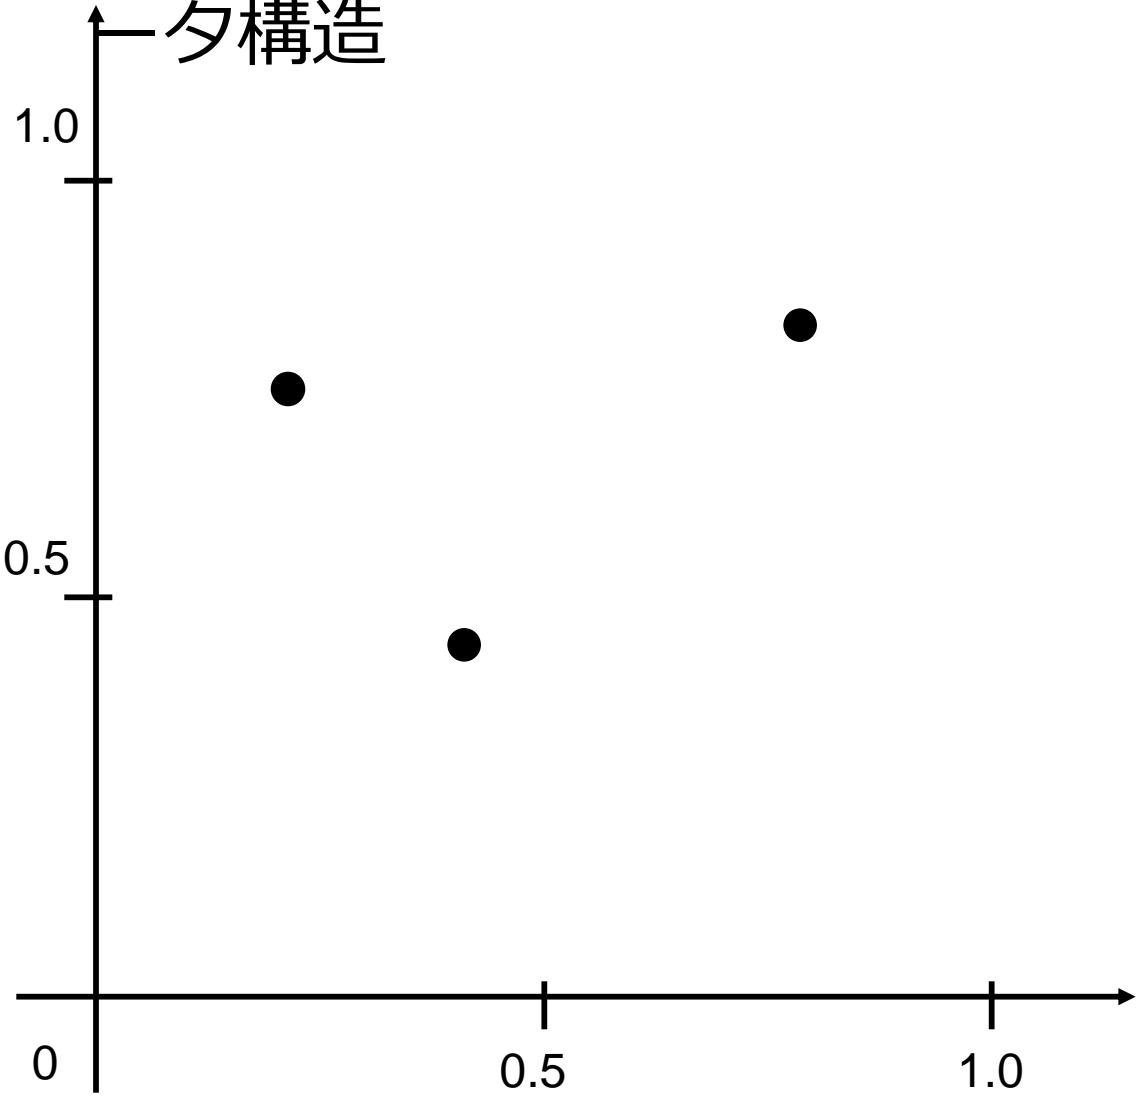


G-Tree

G-Tree データ構造 1/4



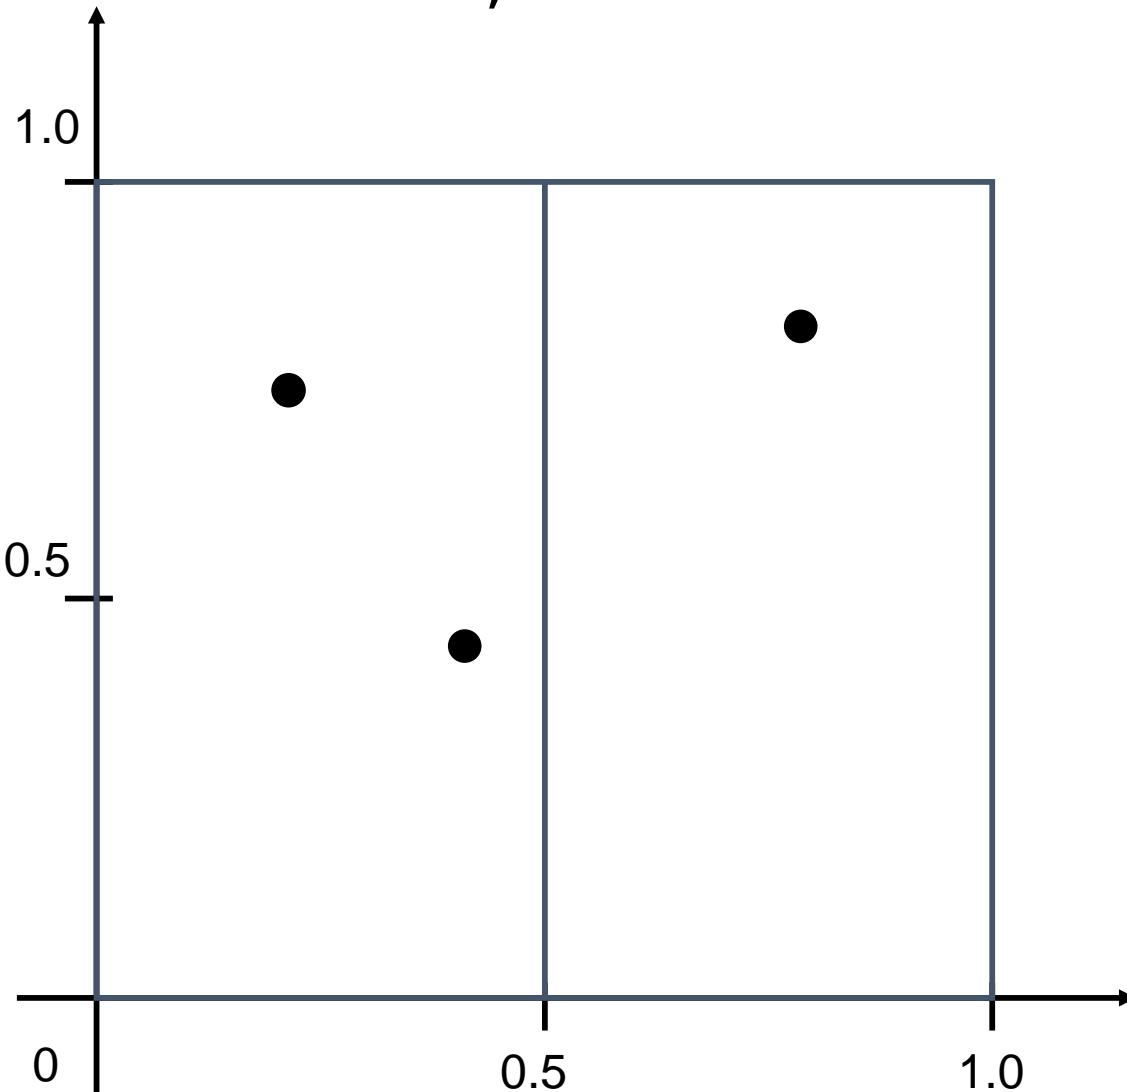
- G-tree は、多次元空間中の点の集まりのためのデータ構造



G-Tree データ構造 2/4



- 1つの区画内の点の数がある制限（ここでは2）を越えないように、空間分割が行われる

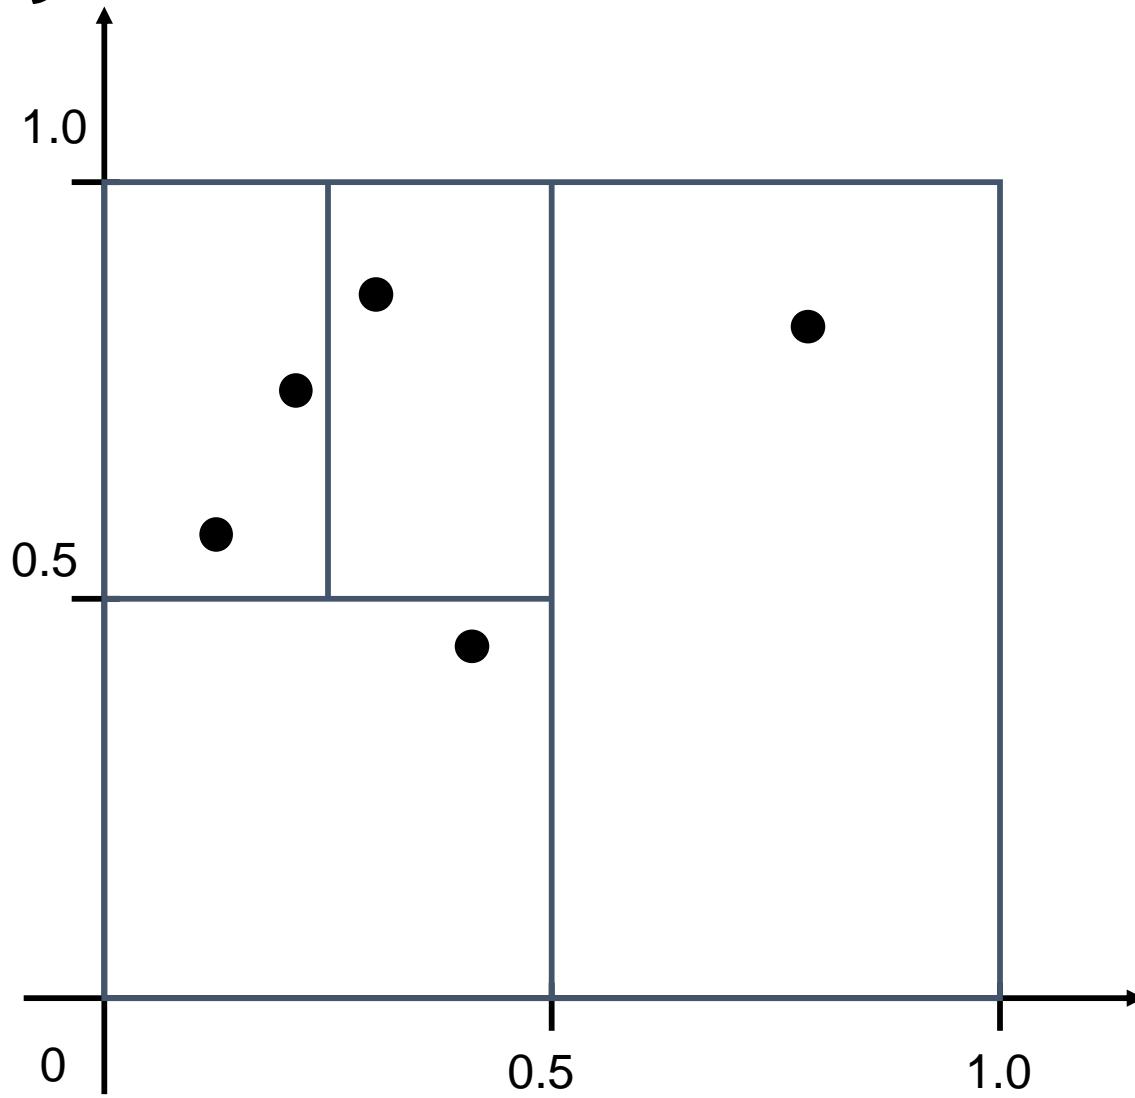


この例では：
点データ： 3 個
分割数： 2

G-Tree データ構造 3/4



- 空間分割は、区画を半分に分割することを繰り返す

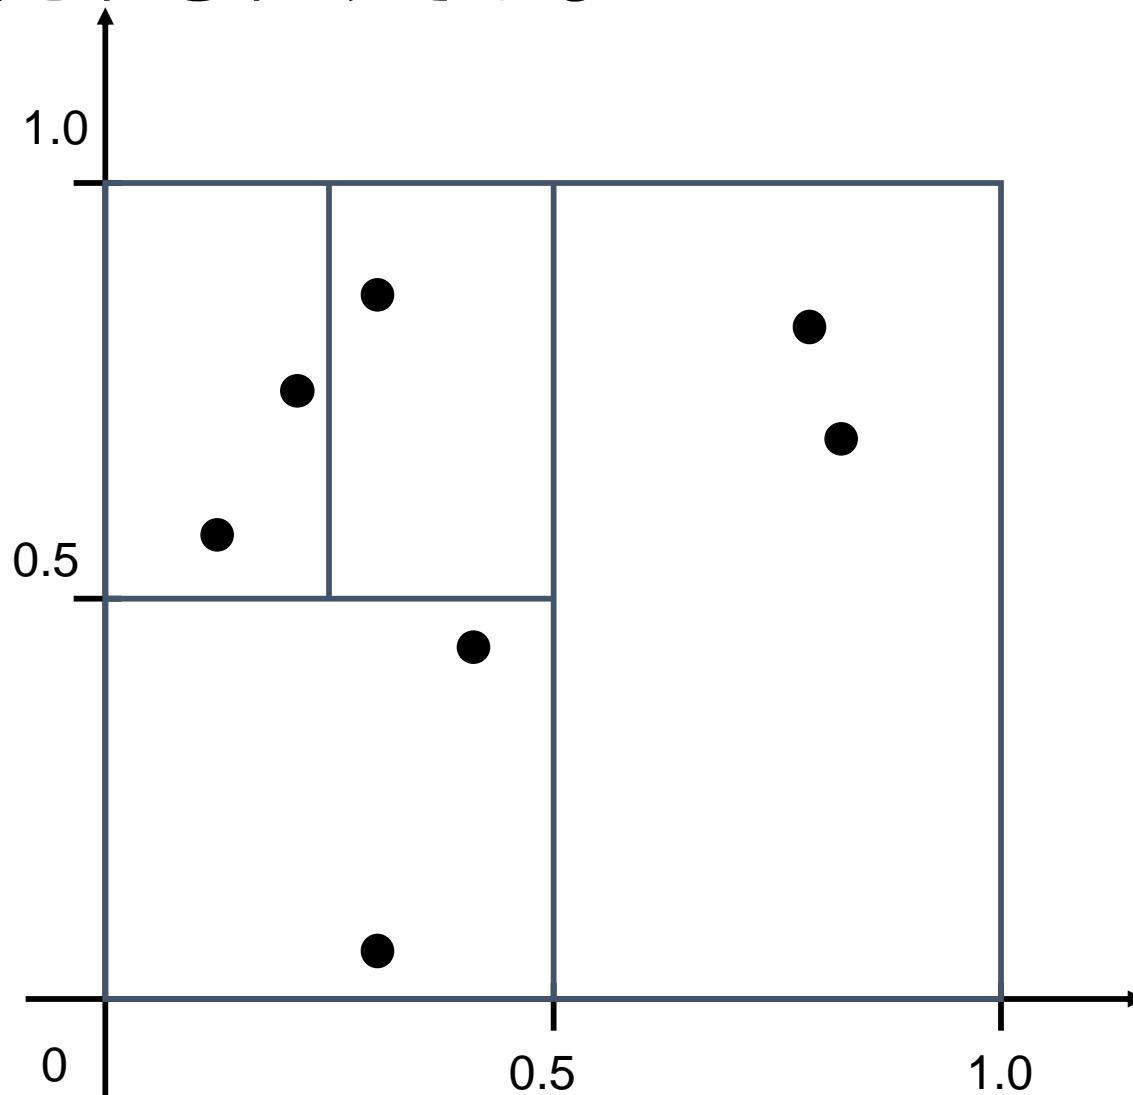


この例では：
点データ： 5 個
分割数： 4

G-Tree データ構造 4/4



- 点の数が増えたからといって、必ずしも区画が分割されるわけではない。



この例では：
点データ： 7 個
分割数： 4

G-Tree の考え方



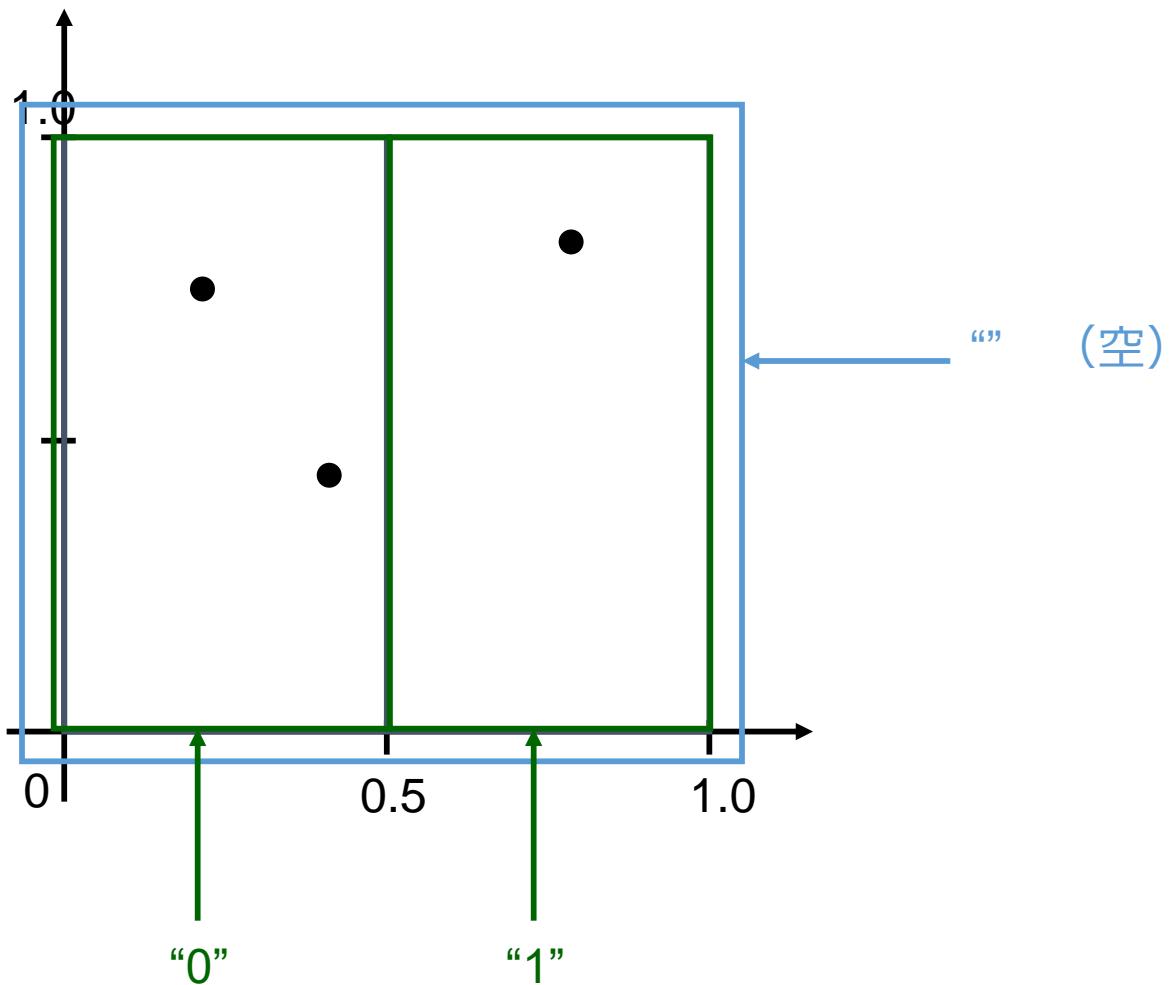
- データ格納の単位は「区画」
 - ある「区画」に含まれる点データの数は、ある「最大値」を超えない。
 - 「最大値」は、1 区画分のデータが 1 ページに収まるように決める
- ツリー構造
 - 「区画を、半分の面積に分割」することを繰り返す
 - 分割軸は $x \rightarrow y \rightarrow x \rightarrow y \dots$ のように交互に交代する

G-tree

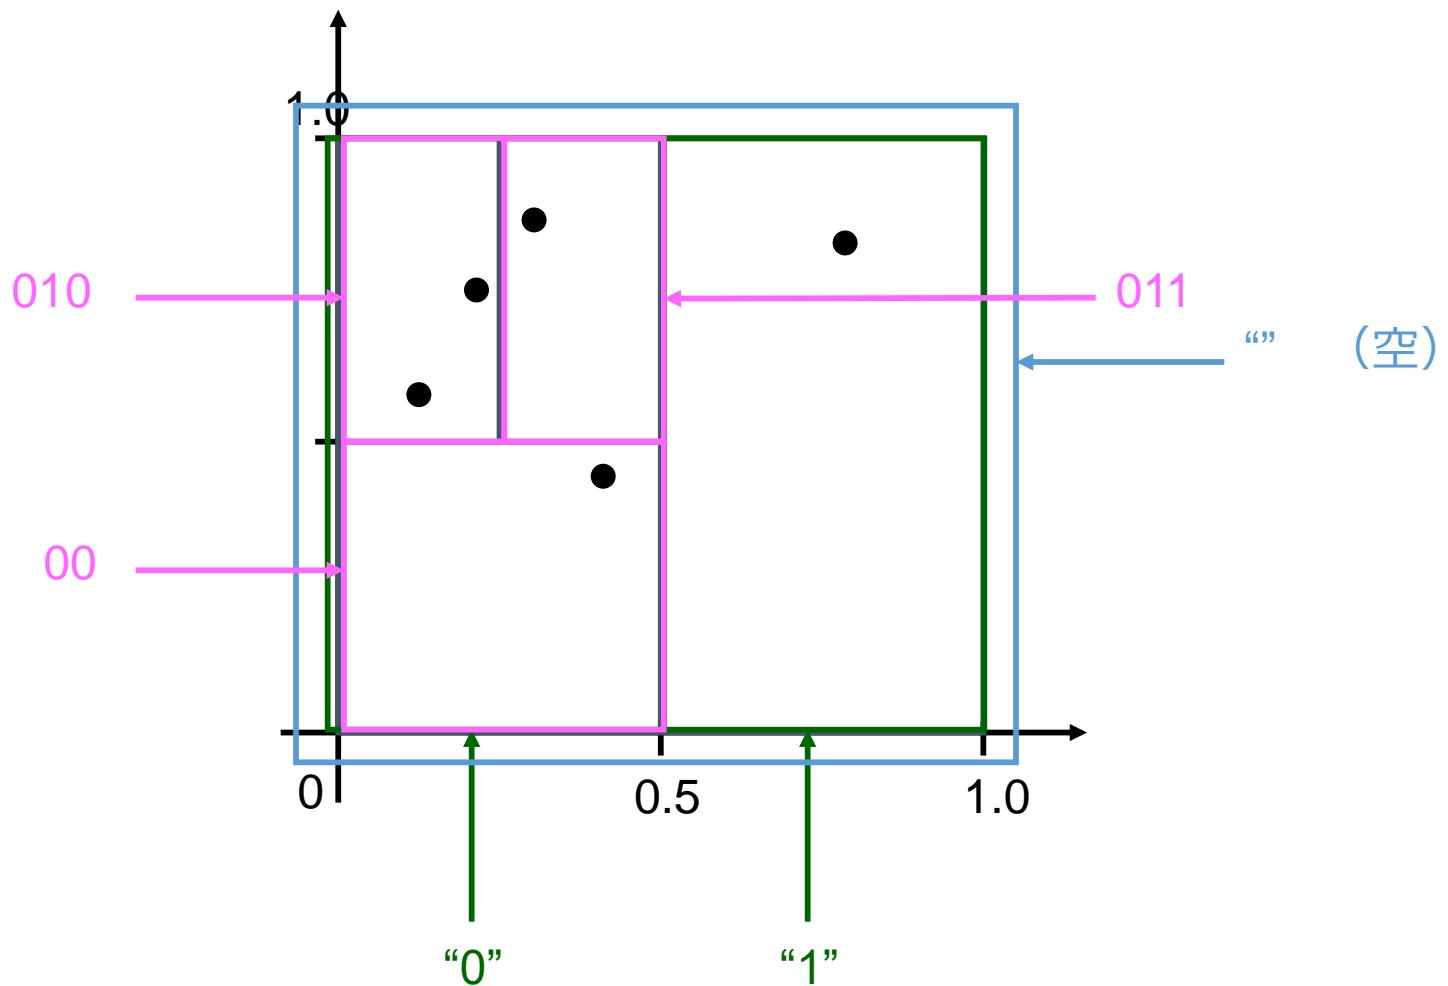


- 今までの説明では、次のことを仮定していた
 - 次元数： 2次元
 - データの範囲： 0から1
- しかし、本来の G-Tree は、次元数、データの範囲に制限は無い
 - 次元数： 2次元以上
 - データの範囲： 広い

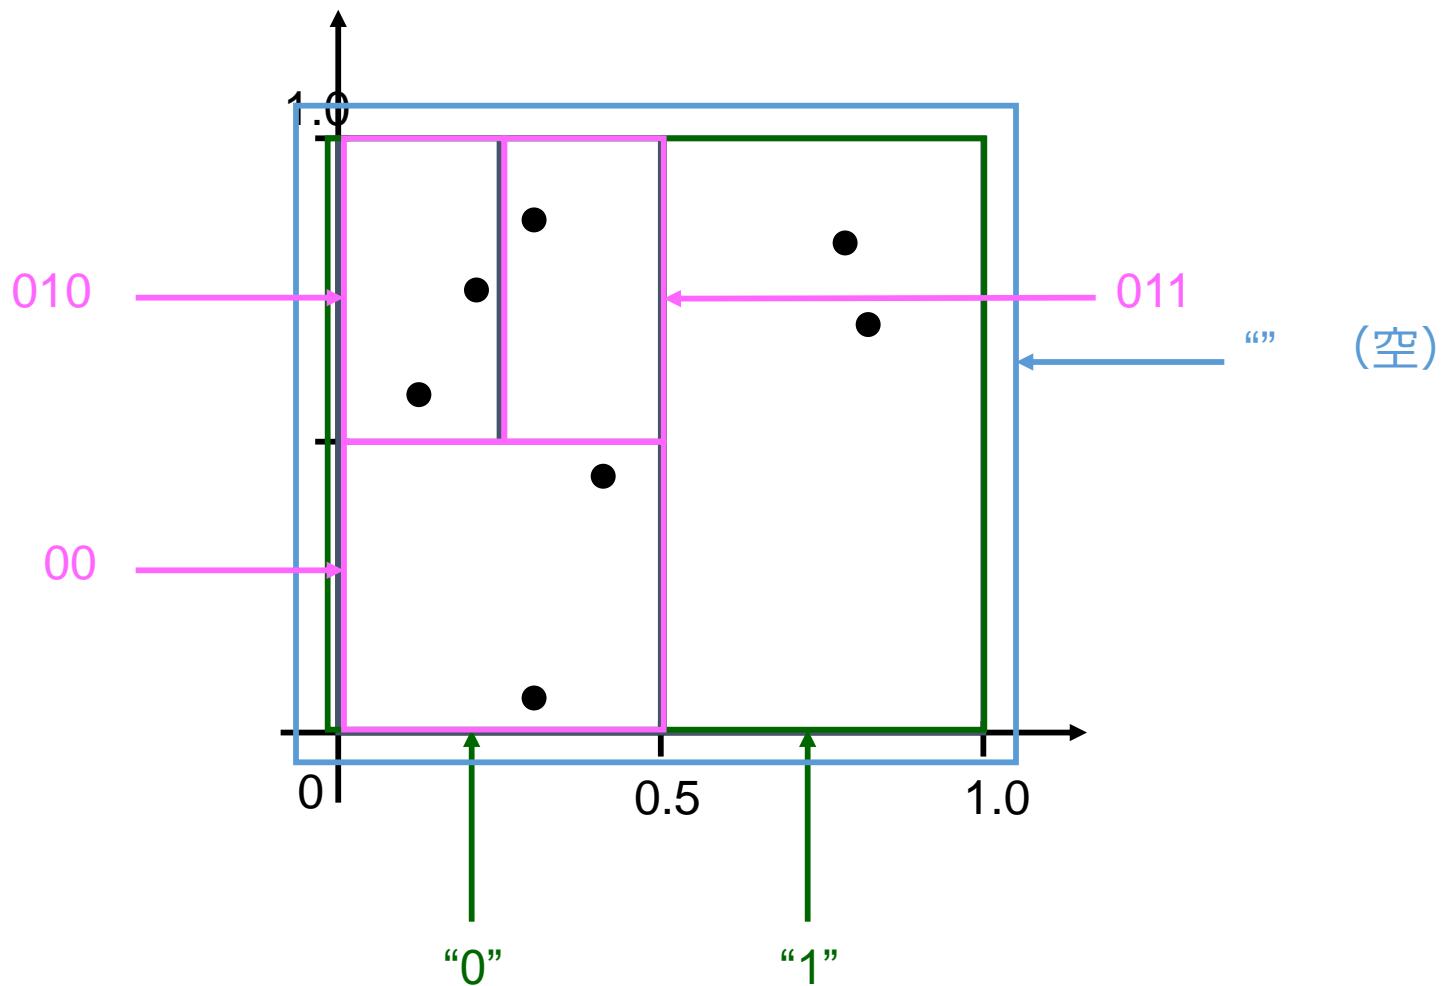
区画のビット列表現例 1/3



区画のビット列表現例 2/3



区画のビット列表現例 3/3

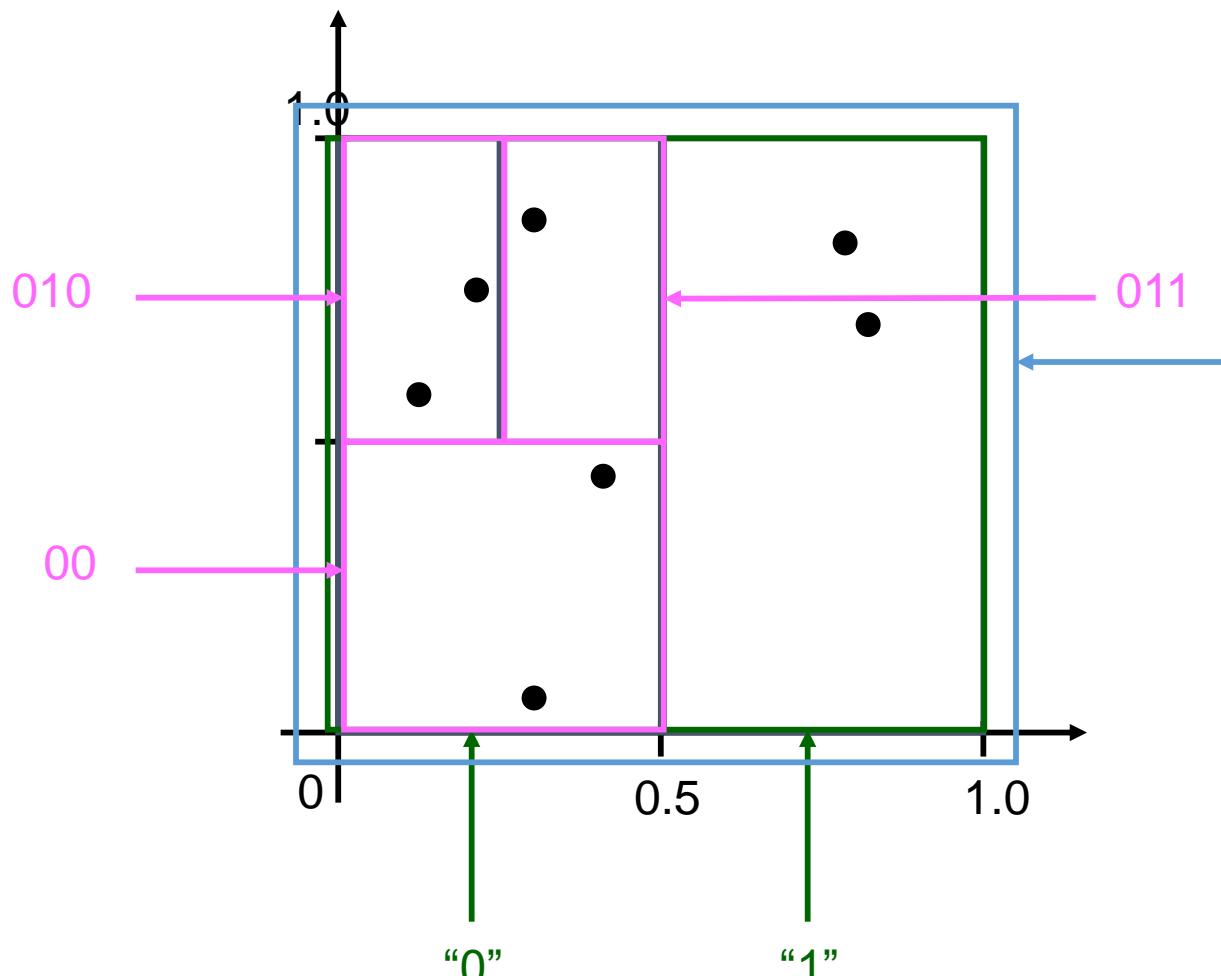


区画のビット列表現



- 区画を 0, 1 のビット列で表現
- 全空間は「空文字列」とする
- 区画が分割されると、ビット列の長さが 1 つ増える
- 最大ビット列長（前ページの例では 3）は、区画の分割回数で決まる

ビット列表現の性質

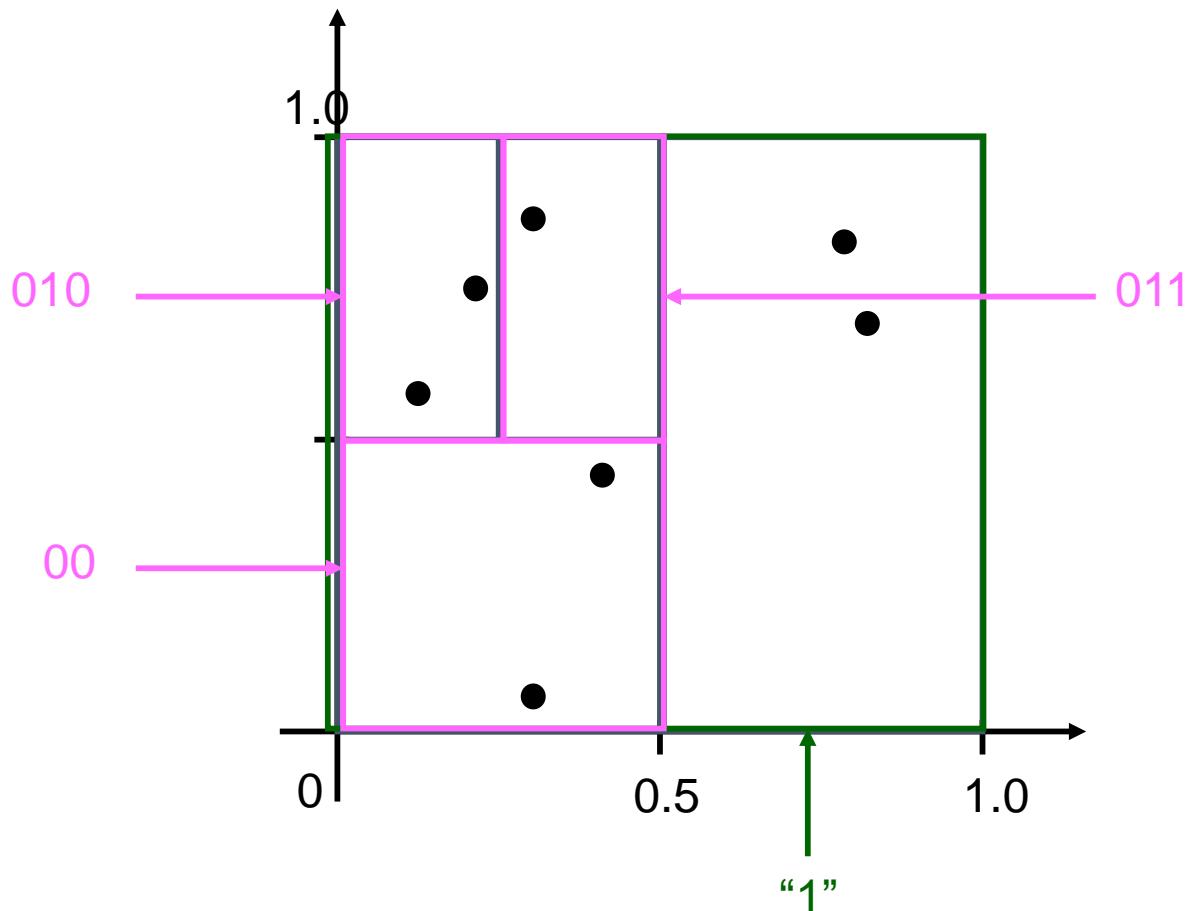


ある区画Rが別の区画Xを含むなら,
Xのビット列表現は S"0" 以上で, S"1"以下

ビット列表現による区画の順序付け



- この例では、順序は、 $00 \rightarrow 010 \rightarrow 011 \rightarrow 1$



区画を順序付けることの意味

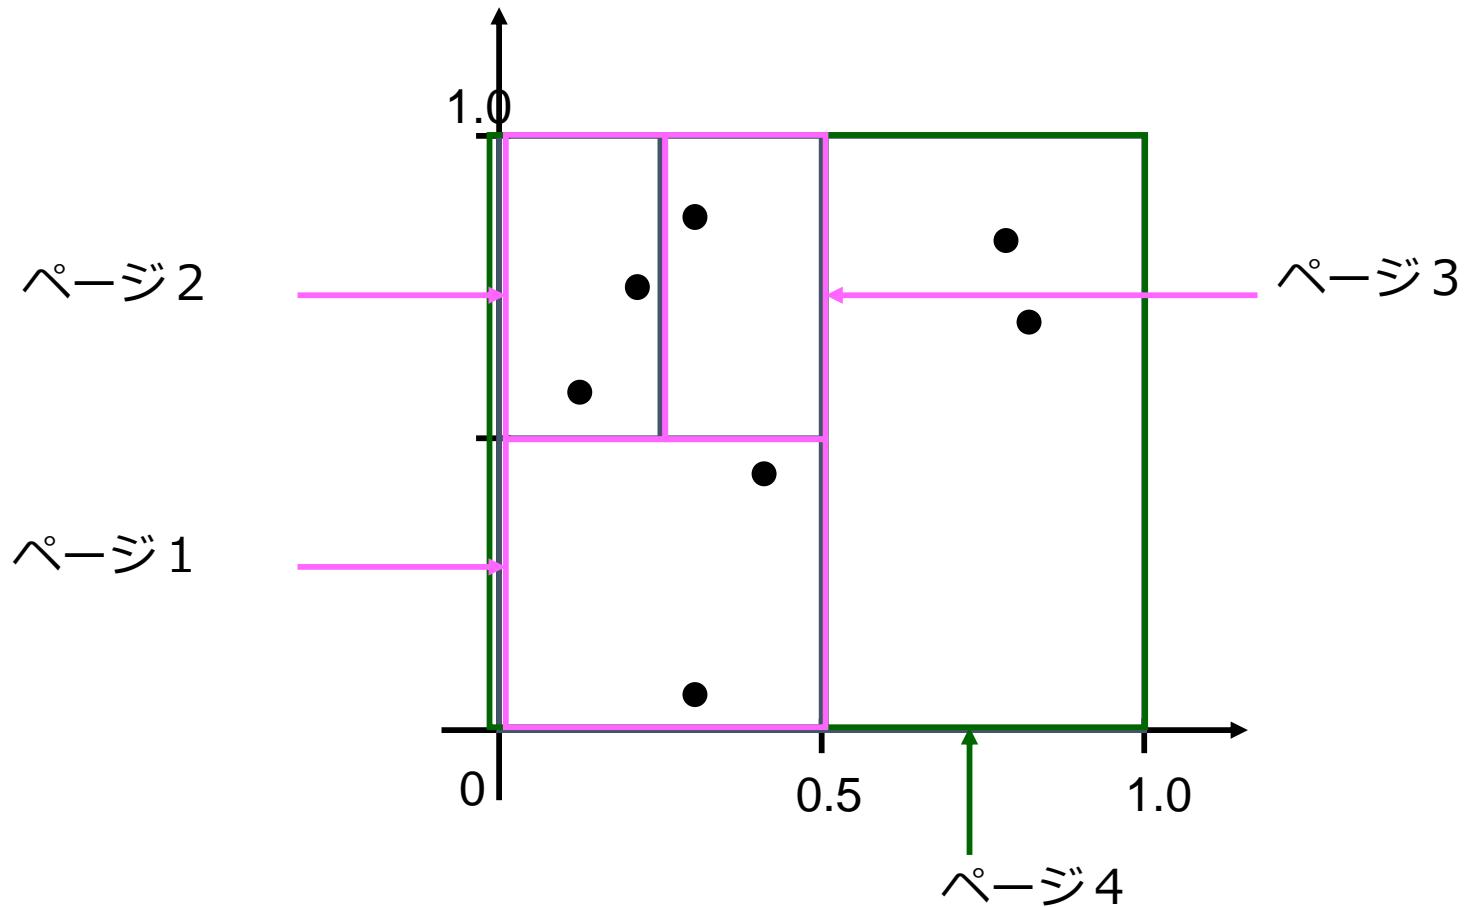


- 区画を，あらかじめ「ソート」でき，点データの各種の操作を高速化できる
- 区画の「ビット列」は，点データを検索するための「検索キー」と見立てることができる

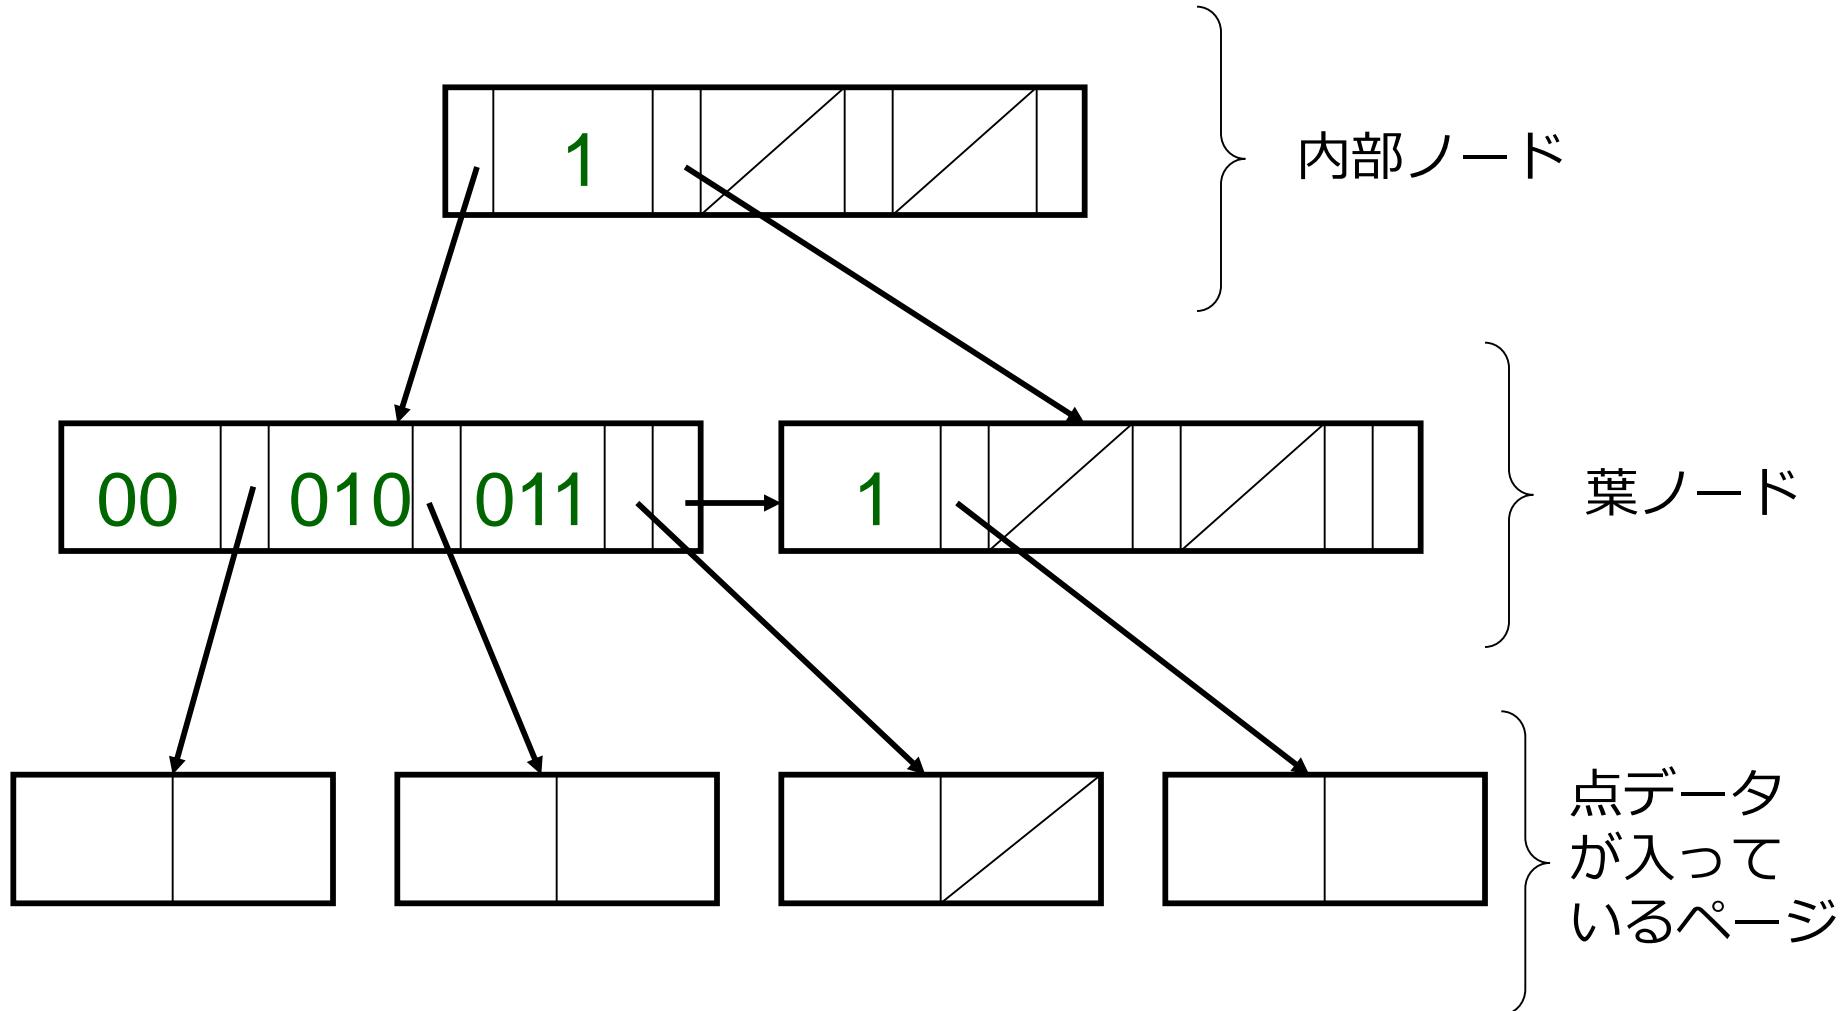
G-tree の格納構造 1/2



- 1つの区画で1ページ
- 各ページは順序付けられている



G-tree の格納構造 2/2



G-tree のノード



- 葉ノード
 - データページへのポインタを持つ
 - 「次」の葉ノードへのポインタを持つ
- 内部ノード
 - 下位レベルのノードへのポインタを持つ

G-Treeのオペレーション



- Searching for a Point
- Searching for All Points In a Region
(Range Query)
- Inserting a Point
- Deleting a Point

Searching for a Point

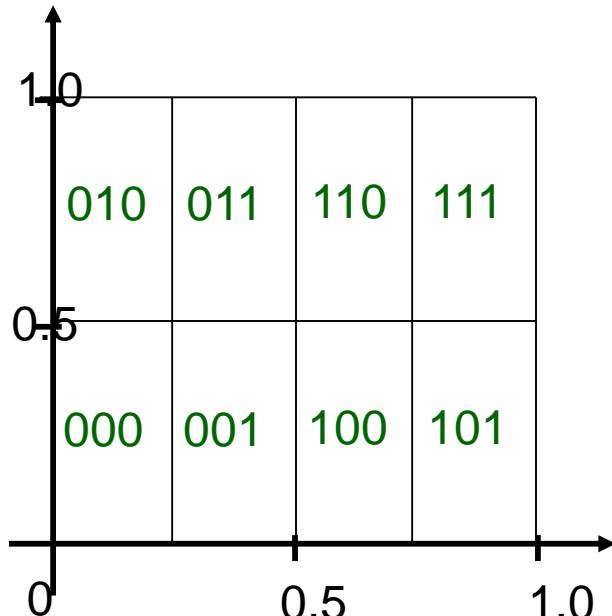


- 探したい点の座標値 (x,y) は分かっている
- 座標値 (x,y) を使って、当該データが存在するかしないかを調べたい
 - もし、インデックスが無ければ、データの全件を調べねばならない

Searching for a Pointの手順 1/2



- 最大ビット列長は、前もってどこかに覚えておく
例えば： 3
- 与えられた座標値と、最大ビット列長とから、ビット列を求める。
例えば： (0.8, 0.9) のビット列は，“111”

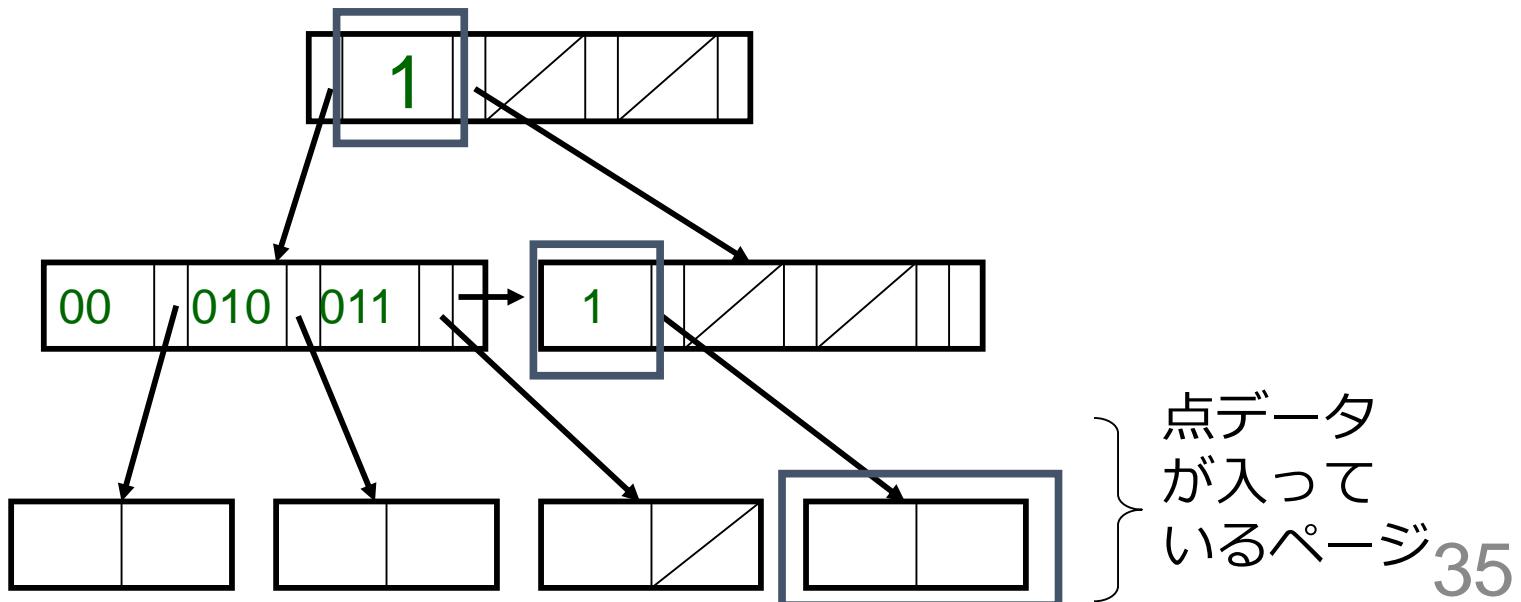


Searching for a Pointの手順 2/2



- 2で求めたビット列を使って、G-tree をたどり、探したい点を含むページ番号を求めたい

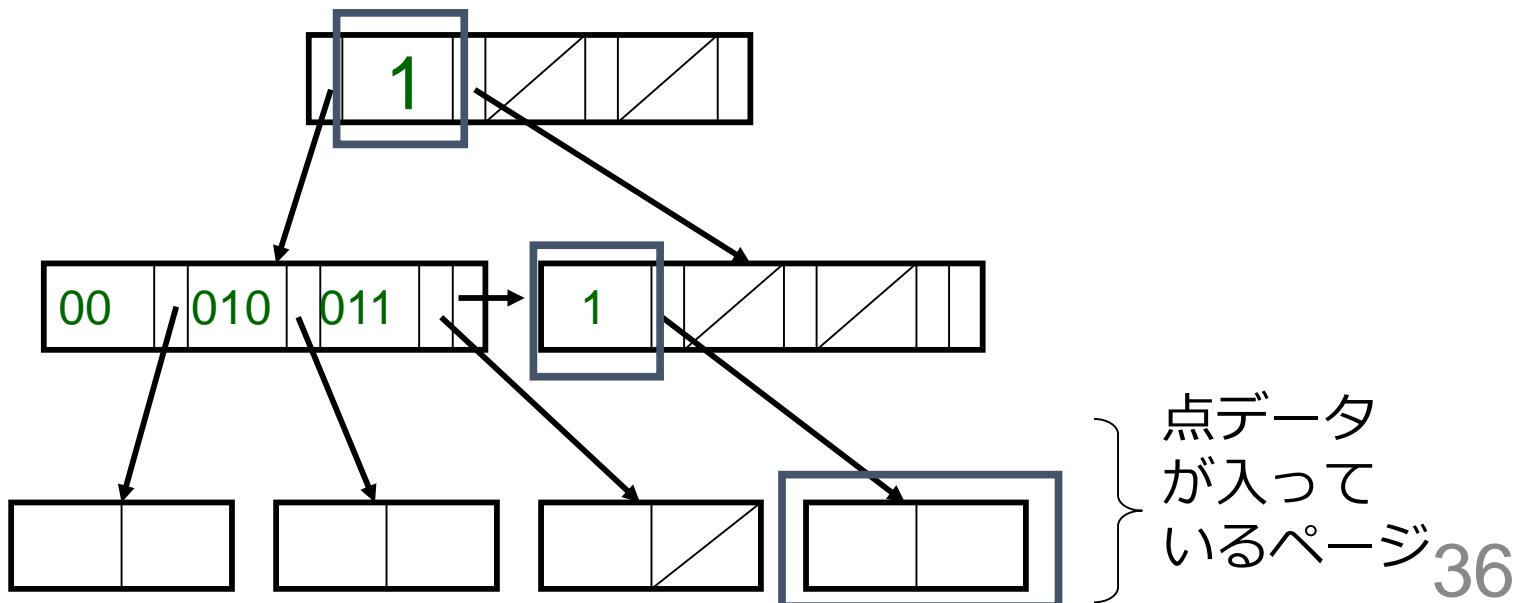
(例) “111”を使って、下の G-tree をたどる
G-tree に“111”は無いが、“1”はある



Searching for a Point について

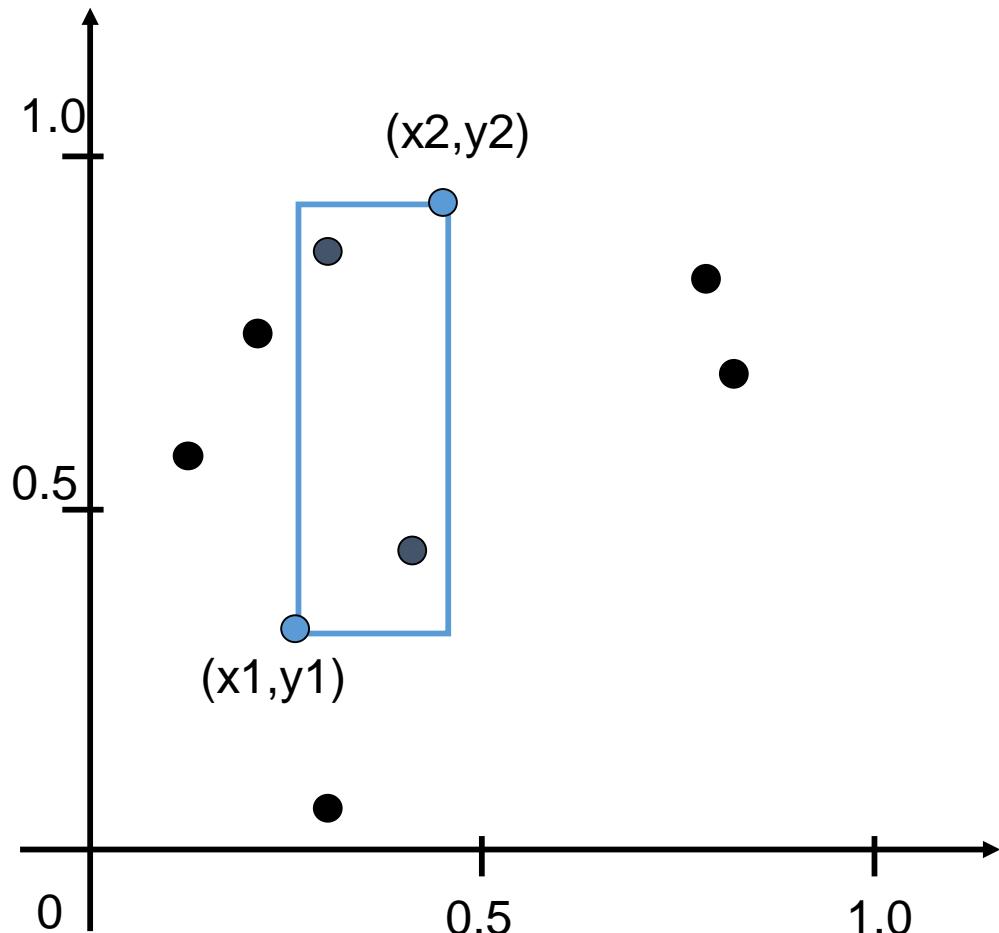


- G-tree を、ルートノードからたどり、与えられた「点」が入っているであろうページを得ることができた



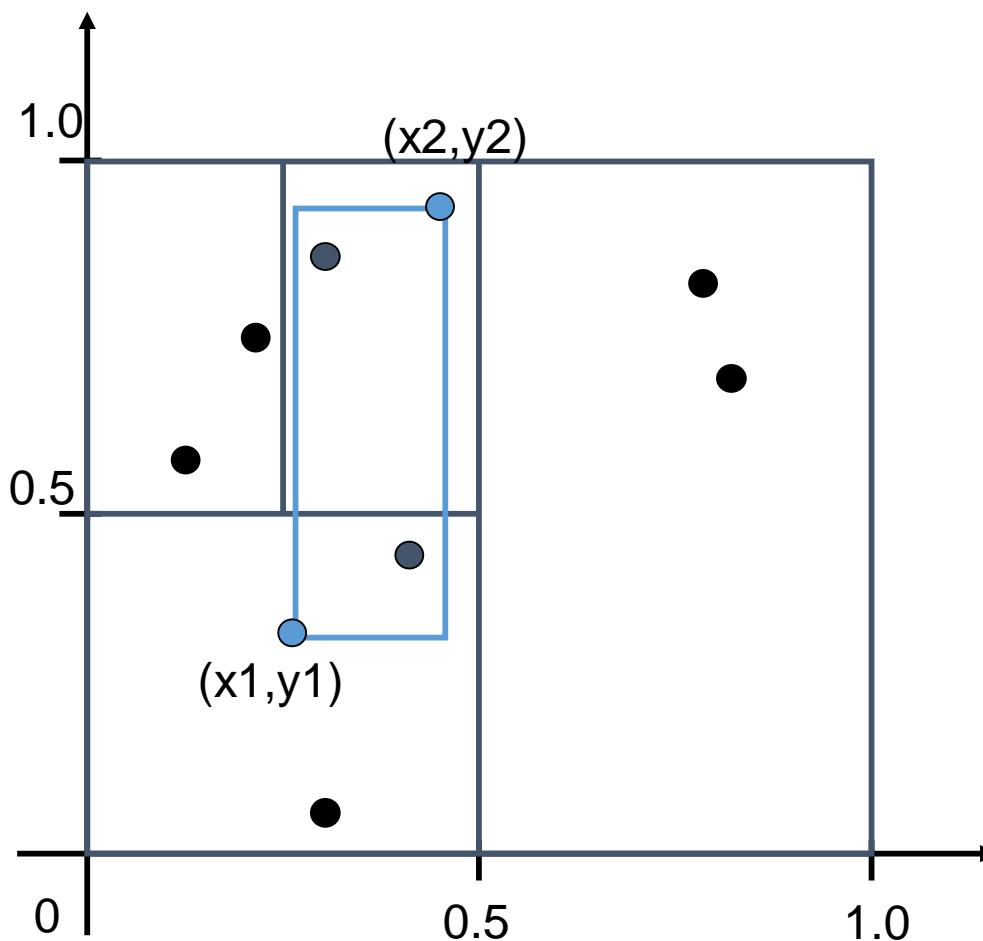
Range Query

- 矩形 $[x_1, y_1, x_2, y_2]$ による検索
- 矩形内のすべての点を求める



Range Query の手順 1/2

- (x_1, y_1) から、3ビット表現“0 0 1”を得る
 - (x_2, y_2) から、3ビット表現“0 1 1”を得る
- 解は 0 0 1, 0 1 0, 0 1 1 の範囲内だと分かる

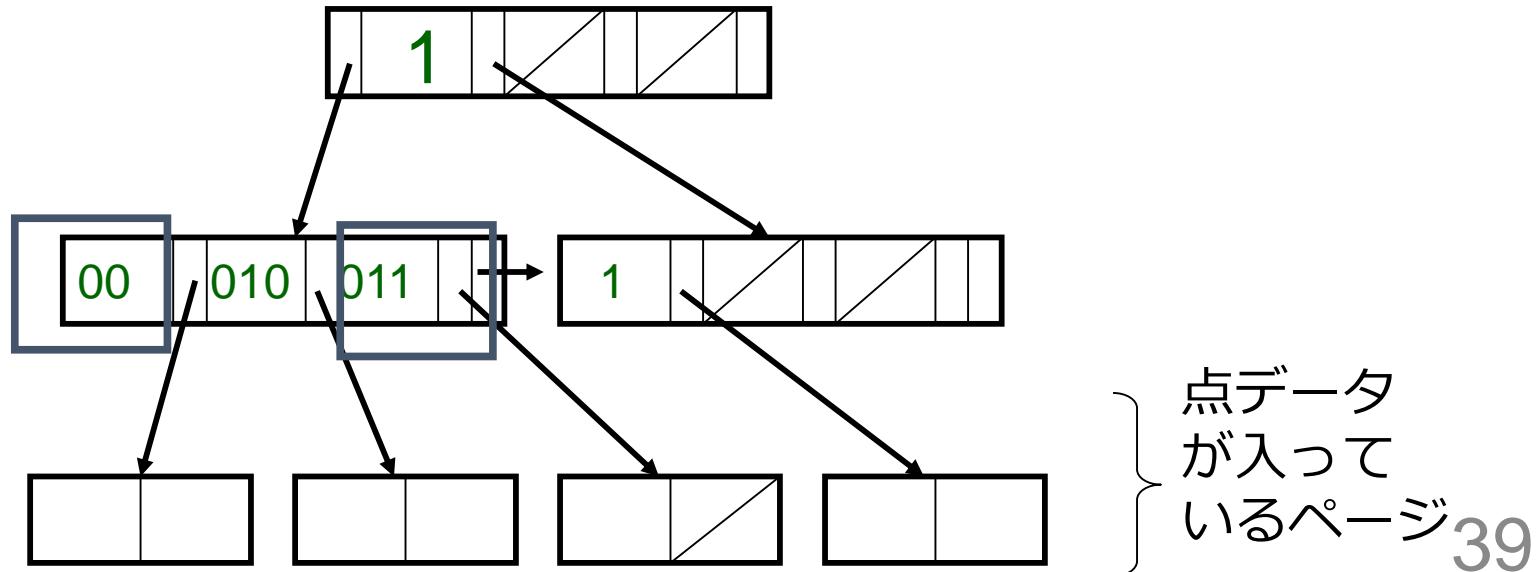


Region Query の手順 2/2



- G-tree の葉ノードをたどり、それぞれ矩形 $[x1,y1,x2,y2]$ の範囲と重なるかを調べる

(例) 00, 010, 011 を辿る。00 と 011 は重なる



Inserting a Point



- 挿入したい点(x,y)について

1. (x,y) を使って, Searching for a Point を実行.
ページ番号を得る
2. 1の結果, すでに, 点(x,y)が存在していることが分かれば, 何もしない
3. 点を挿入した結果, ある区画内の点の数が「制限」を超えそうなら, 区画を分割する
 - (1) データページを1つ増やす
 - (2) 必要なら, 葉ノード, 内部ノードを調整する

Deleting a Point



- 削除したい点(x,y)について

1. (x,y) を使って, Searching for a Point を実行.
ページ番号を得る
2. すでに, 点(x,y)が存在しているはず (無ければエラー)
3. 点を削除した結果, ある区画内の点の数が 0 になるなら,
区画を結合する。
 - (1) データページを 1 つ減らす
 - (2) 必要なら, 葉ノード, 内部ノードを調整する

G-tree と B-tree の違い



- B-tree は、数値、文字など「順序付け」可能なデータのためのデータ構造
- 点データは、（基本的には）順序付けできない
- G-tree では、「区画」をビット列表現し、順序を付ける
 - ある区画Rが別の区画Xを含むなら、Xのビット列表現は S"0" 以上で、S"1"以下
 - 点データに特徴的な検索として、Searching for All Points In a Region がある



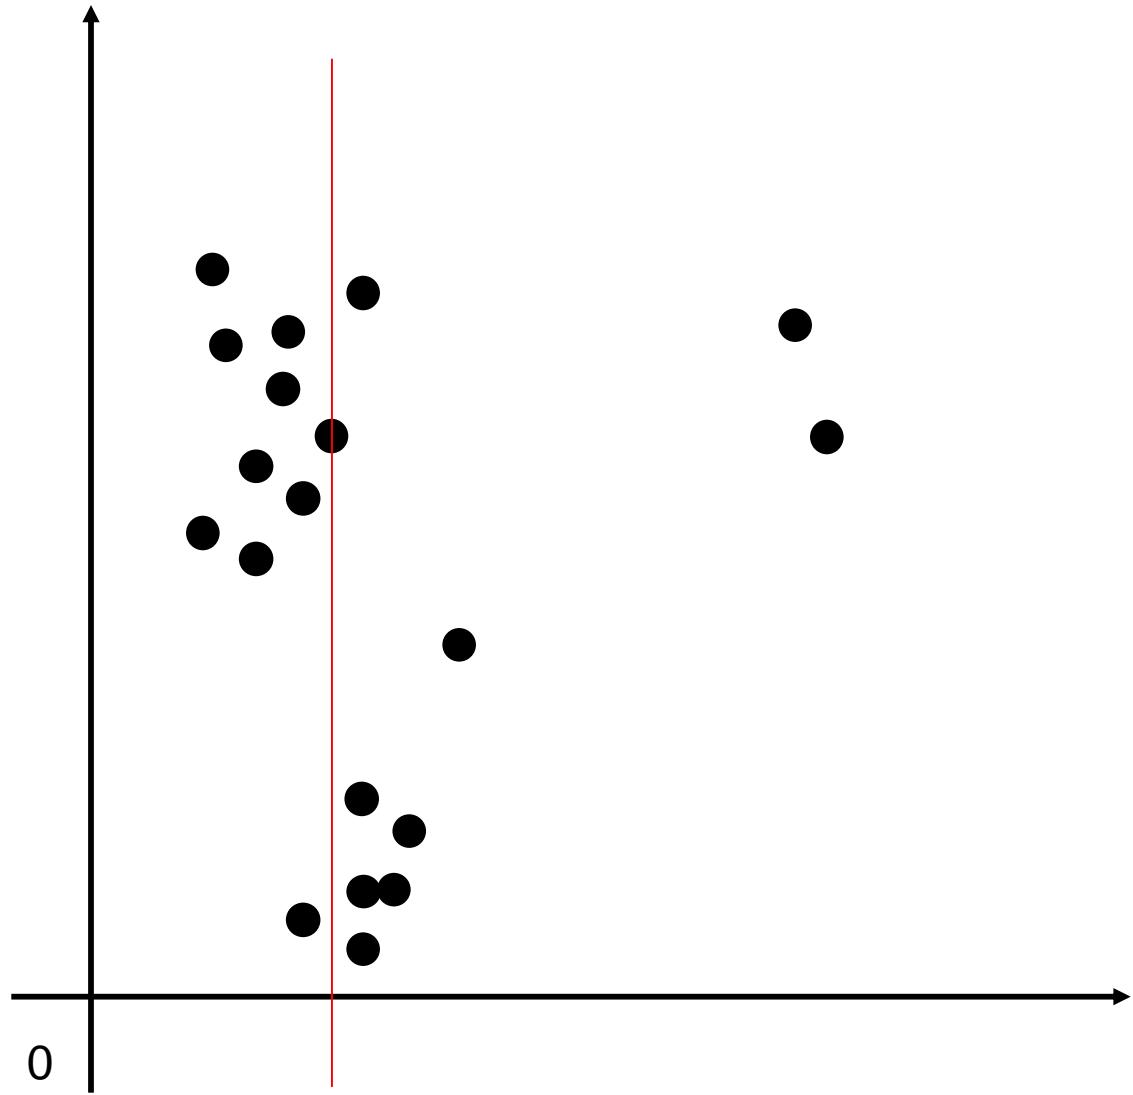
k-d Tree

k-d Tree

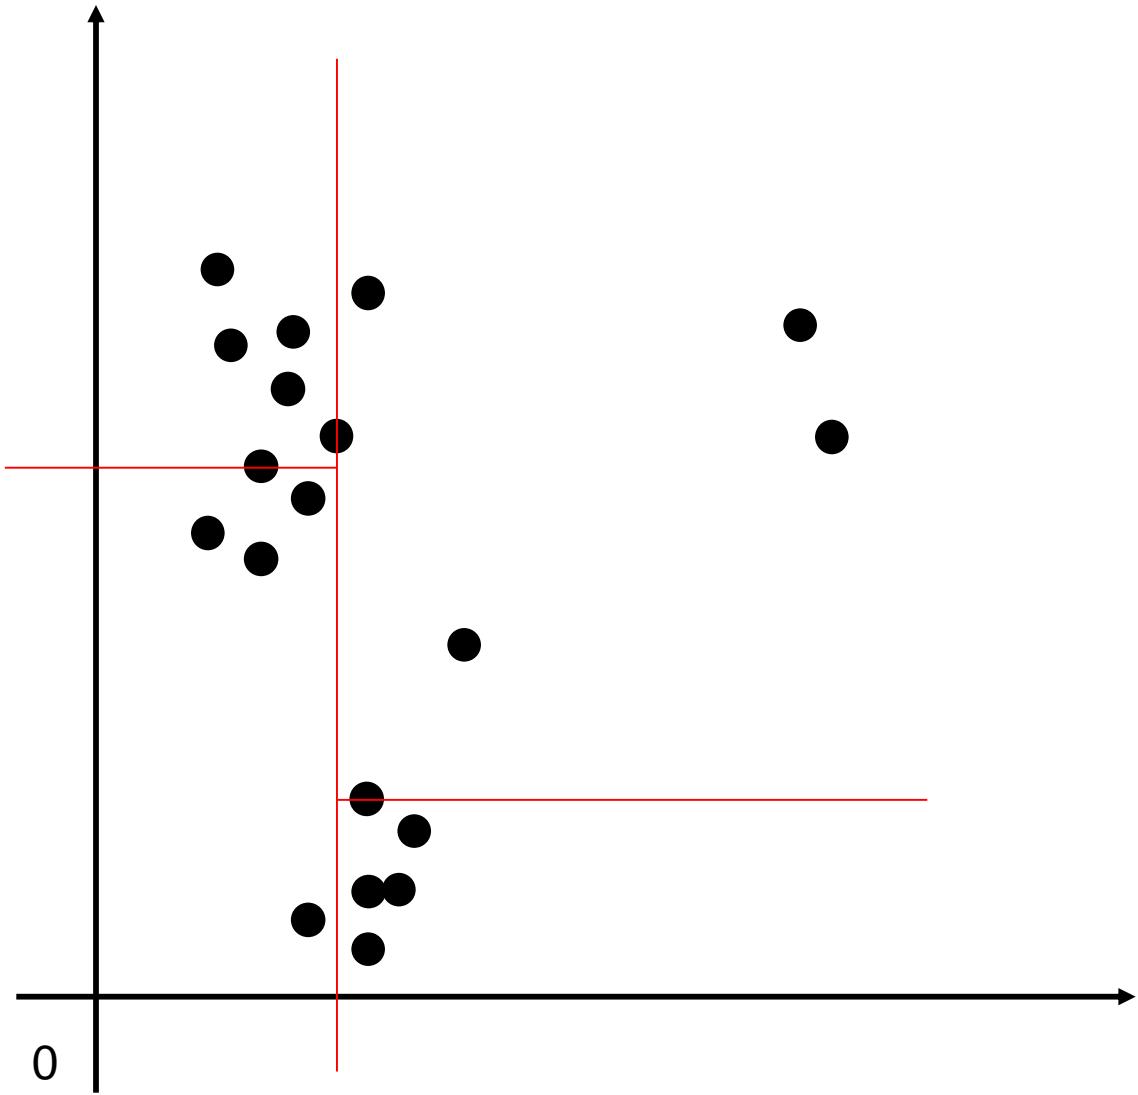


- 各座標値についてデータをソートし、その中央値で、データを2つに分割
- 分割する軸の選択法
 - 巡回： $x \rightarrow y \rightarrow z \rightarrow x \rightarrow y \rightarrow z \rightarrow \dots$
 - その他
- 2-d Tree は 2 次元の点の集まりを、
- 3-d Tree は 3 次元の点の集まりを扱う

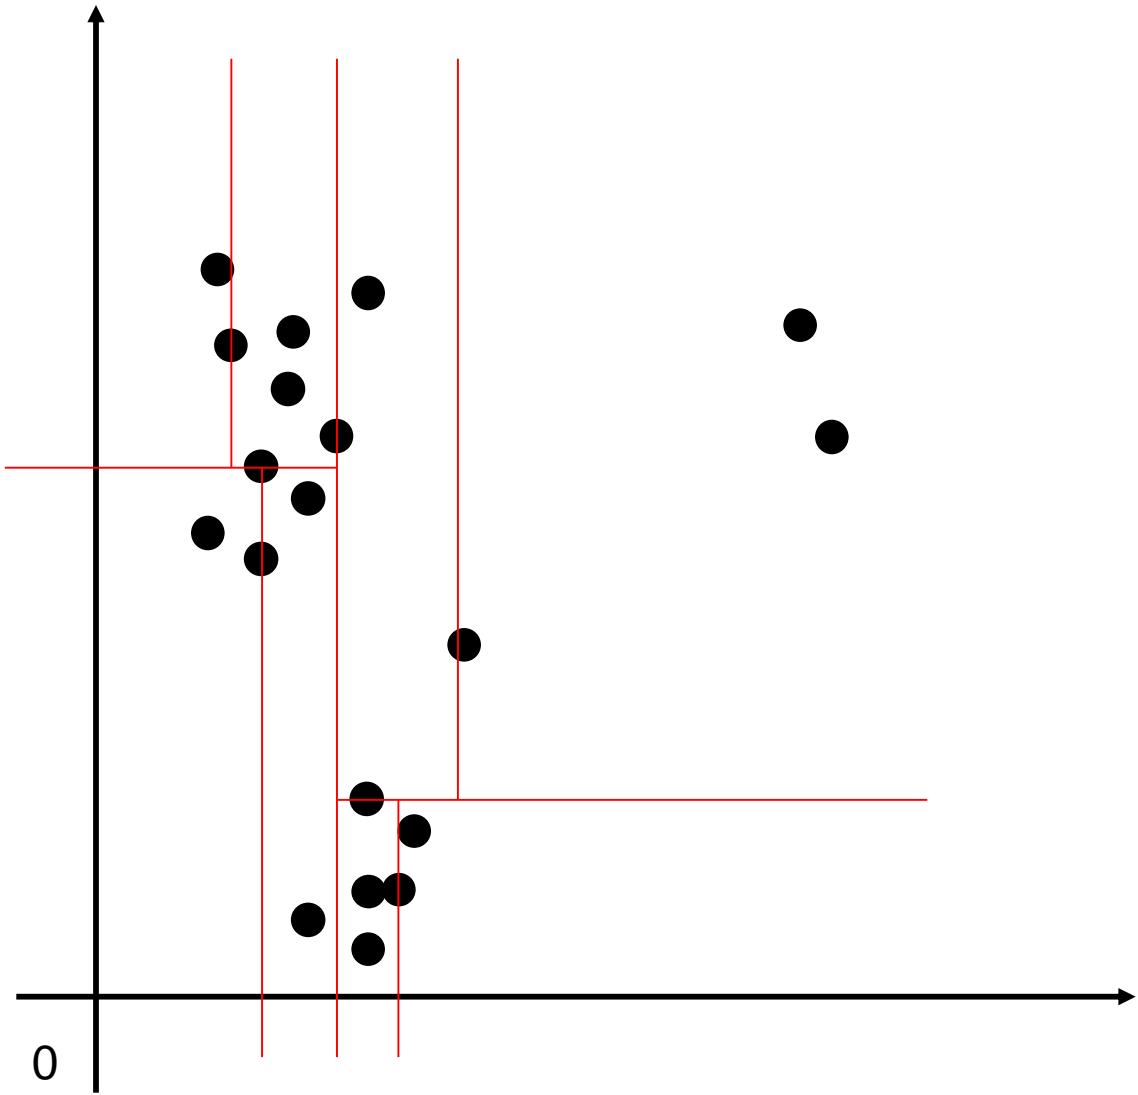
k-d Tree



k-d Tree



k-d Tree





2-d Tree

- x 軸で分割すると
N.LLINK が指すノードMは、
 $M.XVAL < N.XVAL$
N.RLINK が指すノードPは、
 $P.XVAL \geq N.XVAL$
- y 軸で分割すると
N.LLINK が指すノードMは、
 $M.YVAL < N.YVAL$
N.RLINK が指すノードPは、
 $P.YVAL \geq N.YVAL$

k-d tree の特徴



- データの集まりから, k-d tree の一括生成
 - k-d tree は完全にバランスする
- データを逐次, 追加, 削除する場合
 - k-d tree のバランスは崩れる

k-D Tree のデータ構造



- INFO: 利用者が好きなデータを格納
- XVAL, YVAL: 「点」の座標値
- LLINK, RLINK: 2つの子ノードへのポインタ
- 1ノードが1つの点に対応する

nodetype = record

 INFO: infotype;

 XVAL: real;

 YVAL: real;

 LLINL: pointer to nodetype;

 RLINK: pointer to nodetype;

end



2-d Tree を使った挿入



- ・挿入したいノードをN, 2-d Tree の根ノードをTとする
- ・NとTのXVAL, YVAL が同じなら、Tを上書きして終了
- ・さもなくば、次の手順で子ノードを探す
 - × 軸で分割しているとき
 - ・ $N.XVAL < T.XVAL$ なら左へ分岐
 - ・ $N.XVAL \geq T.XVAL$ なら右へ分岐
- 他の軸についても同様
- ・以上の手順を繰り返す

2-d Tree を使った削除



- ・ 削除したい点を (x,y) とする
- ・ 2-d Tree から点 (x,y) を探す (N とする)
- ・ N が根ノードなら：
 N の親ノードの、RLINK, LLINK のうち N を指している方を NIL に設定
- ・ N が根ノードでなければ：
 1. 「候補」 R として N のサブツリーの中から適当なノードを選ぶ
 2. R の INFO, XVAL, YVAL の値で、 N を書き換える
 3. R について、「ノード R の削除」を行う（再帰処理になる）

候補Rの選び方



- ・ノードNの削除では、「候補」Rは、次の条件を満たさねばならない
- ・Tの左側のサブツリー内の任意のノードMについて：

$M.XVAL < R.XVAL$ (x軸で分割のとき)

$M.YVAL < R.YVAL$ (y軸で分割のとき)

- ・Tの右側のサブツリー内の任意のノードMについて：

$M.XVAL \geq R.XVAL$ (x軸で分割のとき)

$M.YVAL \geq R.YVAL$ (y軸で分割のとき)

k-D Tree を使った範囲検索



- 範囲検索とは
範囲を指定して、その範囲内の点の集まりを求めること
- k-D Tree の各ノードN
Nと、そのサブツリー内の点の範囲が決まっている（RNとする）
- 指定された範囲と、あるノードNの範囲 RNが重なっていなければ、Nとそのサブツリー内には、範囲検索の解はない



範囲検索について

- 「範囲」の例

(1) 矩形

右上の点の座標値と、左下の点の座標値

(2) 円

中心の座標値を、半径

k-D Tree について



- k-D Treeでは、木の形は、データの挿入順で決まる
- k-D Treeでは、領域を 2 つあるいは 4 つに分割する
- 分割された領域の大きさは、おのずと不均等になる (XVAL, YVAL 値で決まる)



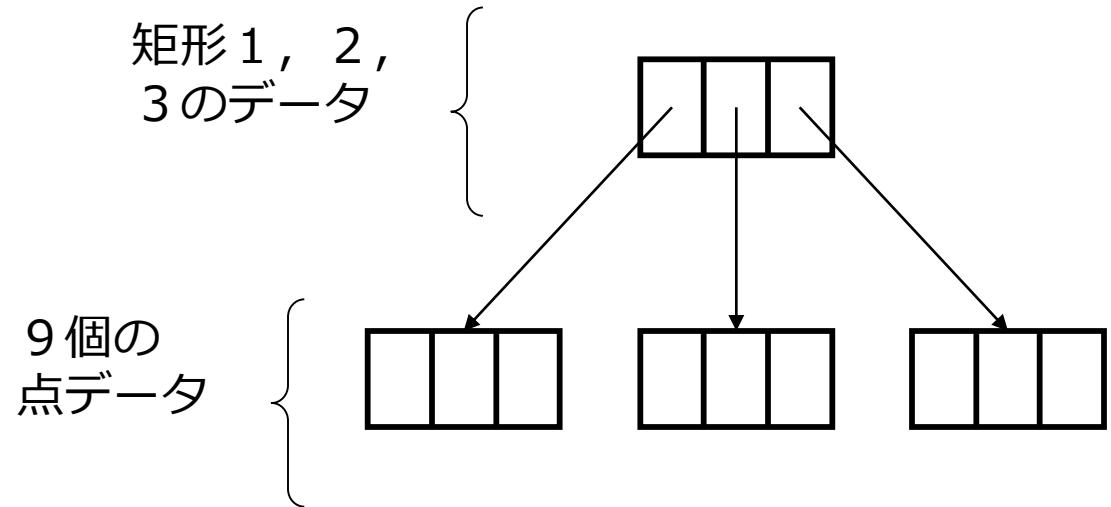
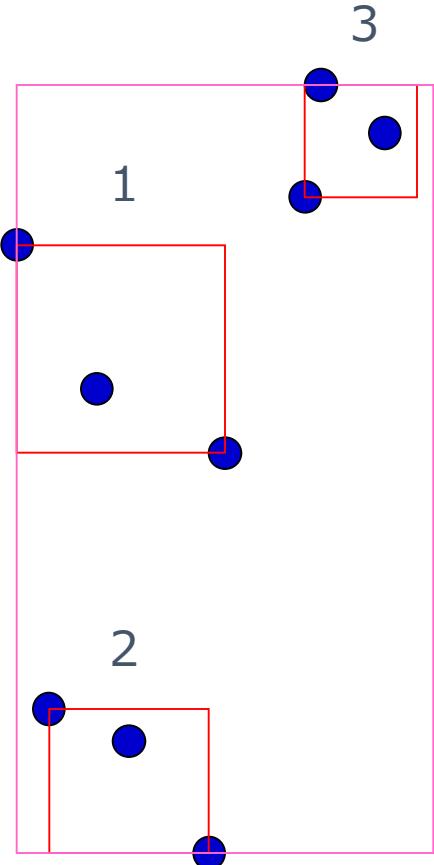
R-Tree / R*-tree

「領域」情報を扱うための手法

R-tree, R*-tree の構造



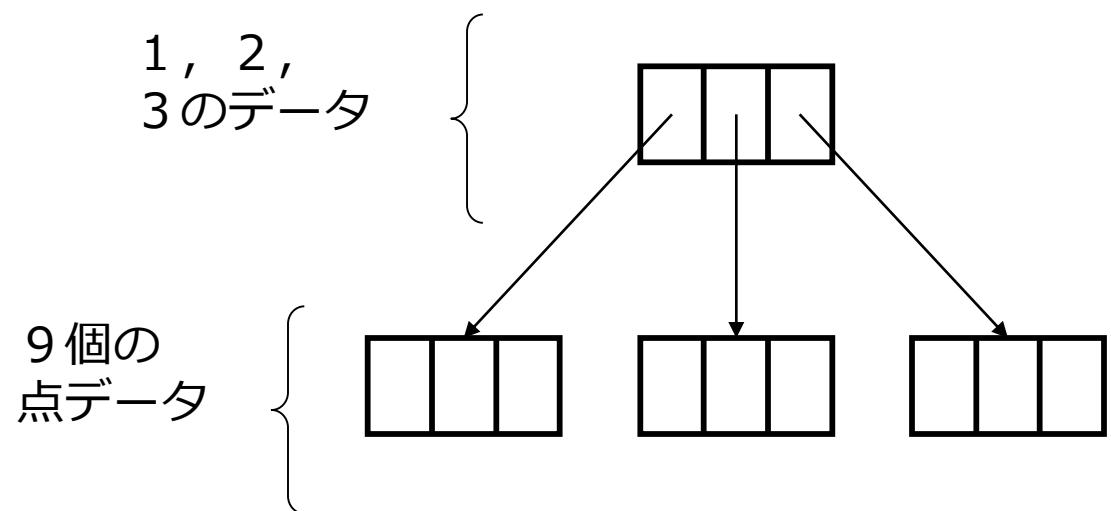
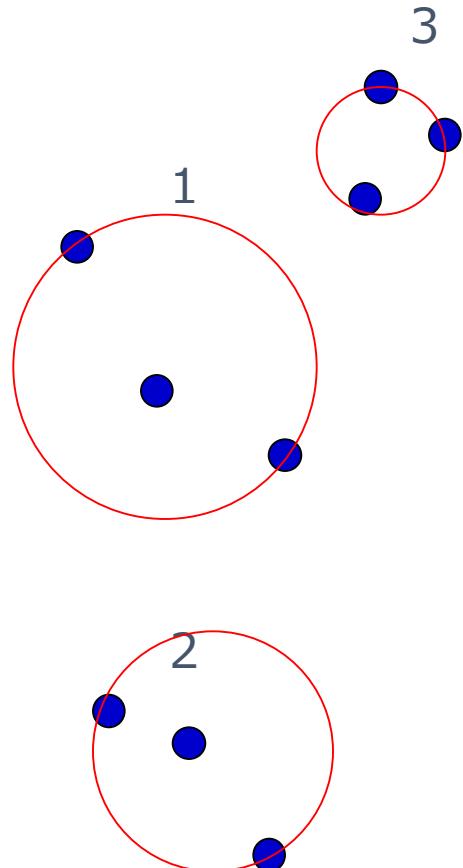
9 個のベクトルデータ



SS-tree の構造



9 個のベクトルデータ





MX QuadTree

MX QuadTree



- MX QuadTree は、点の座標値にかかわらず、ノードを均等に分割
 - 木の形は、データの挿入順に依存しない
 - データの挿入、削除の操作が簡単になる

MX QuadTree



- 根ノード
 - 領域 [(0, 0), (2, 2)]

$k \quad k$

[(XLB, YLB) , (XUB ,YUB)] の子ノード

NW : [(XLB, YLB+w/2) , (XLB+w/2, YLB+w)]

SW: [(XLB, YLB) , (XLB, YLB+w/2)]

NE: [(XLB+w/2, YLB+w/2) , (XLB+w/2, YLB+w)]

SE: [(XLB+w/2, YLB) , (XLB, YLB+w/2)]

MX QuadTree の性質



- データは、すべて、根ノードにある
- 根でないノードのサブツリーは、必ず、データの入った根ノードを含む
- 挿入、削除は、根ノードについて行う

MX QuadTree を使った削除



- 削除したい点を (x,y) とする
- MX QuadTree から点 (x,y) を探す (Nとする)
 - Nは必ず葉ノードである.
- Nを削除する
- Nの親ノードをMとする.
- MのエントリのうちNを指している方をNILとする
- M のNW,SW,NE,WEが全てNILならば、 Mを削除する (削除は再帰的に繰り返す)

空間インデックス研究課題



- 検索効率
 - 領域検索
 - 最近接点探索
- データの追加, 削除, 更新の効率
- 空間使用量
- 大規模なデータセット
- 高次元のデータ