

Использование заметающих кривых для построения геопространственного индекса

Автор: Башков Алексей Александрович,
Инженер, НИИ ТП

Общий алгоритм поиска пересечения в геопространственном индексе.

- 1) все имеющиеся данные (полигоны и точки) кодируются совокупностью идентификаторов ячеек, которыми покрываются геометрии для поиска;
- 2) во время запроса на поиск запрашиваемая геометрия также покрывается ячейками и формируется множество идентификаторов по которым выполняется поиск;
- 3) идентификатор ячейки, обычно, является целым числом (индексом ячейки при обходе по кривой, заметающей пространство), то поиск соответствия выполняется намного быстрее. В таком случае используется либо выборка по значению, либо выборка по диапазону.

Задача нумерации ячеек может решаться с помощью кривых, заметающих пространство.

Вариант нумерации 1

1	4	7	10
2	5	8	11
3	6	9	12

Вариант нумерации 2

1	2	3	4
8	7	6	5
9	10	11	12

Стандартные заметающие кривые

Основным свойством заметающих кривых является преобразование двумерного / трехмерного пространства в одномерное. Это позволяет использовать более эффективные алгоритмы поиска.

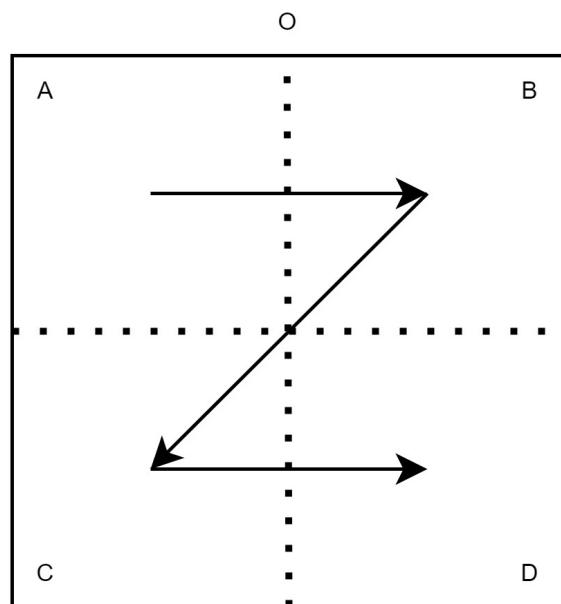
Пространственная локальность данных – близкие индексы на заметающей кривой означают пространственную близость двумерных областей.

При построении геопространственных индексов наиболее часто используется следующие заметающие кривые:

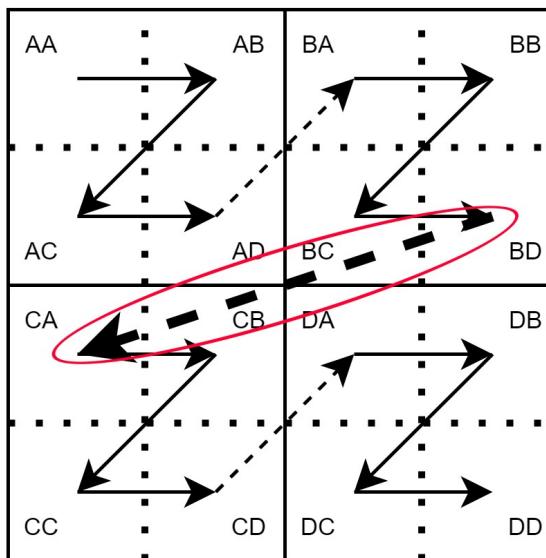
- кривая Лебега (Z-кривая, кривая Мортона)
- кривая Гильберта
- Н-кривая

и некоторые другие.

Кривая Лебега (Z-кривая)



а) деление пространства на
на первом шаге

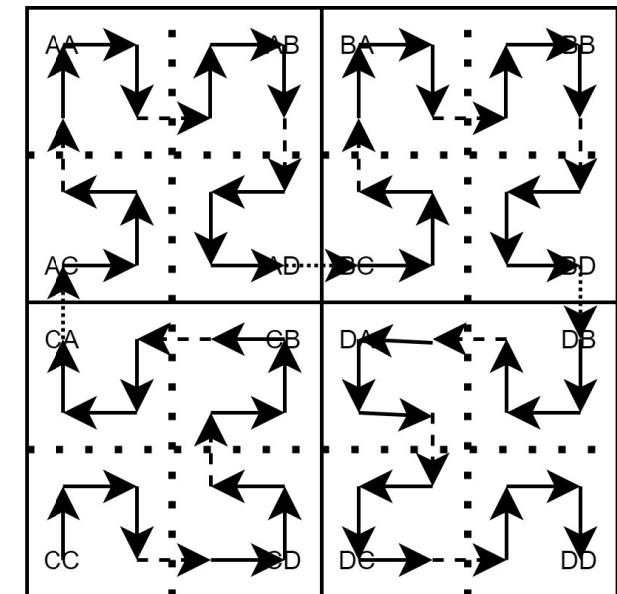
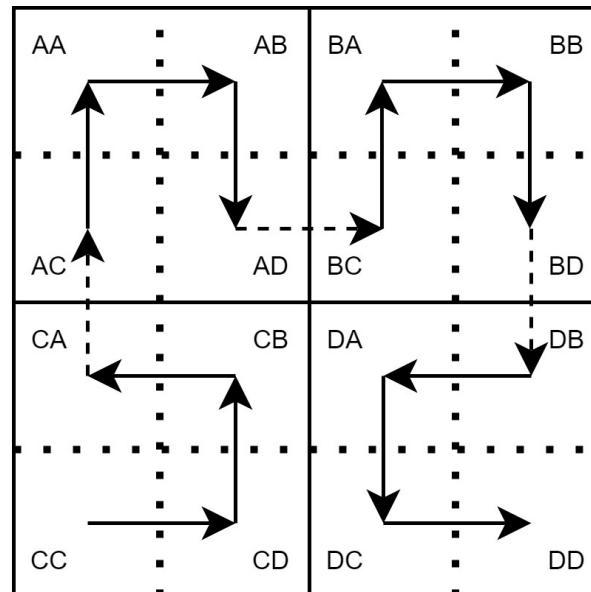
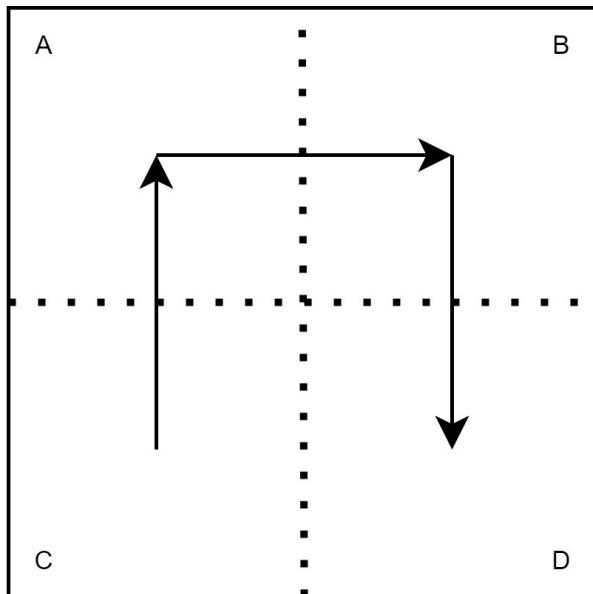


б) демонстрация деления
на следующем шаге

В некоторых геопространственных индексах (Bing Maps) используется кривая Лебега, в которой базовой структурой является Z-образный обход четырех ячеек. Одним из недостатков которой является длинный переход между ячейками BD и CA. Расстояние между которыми в пределе доходит до ширины области определения.

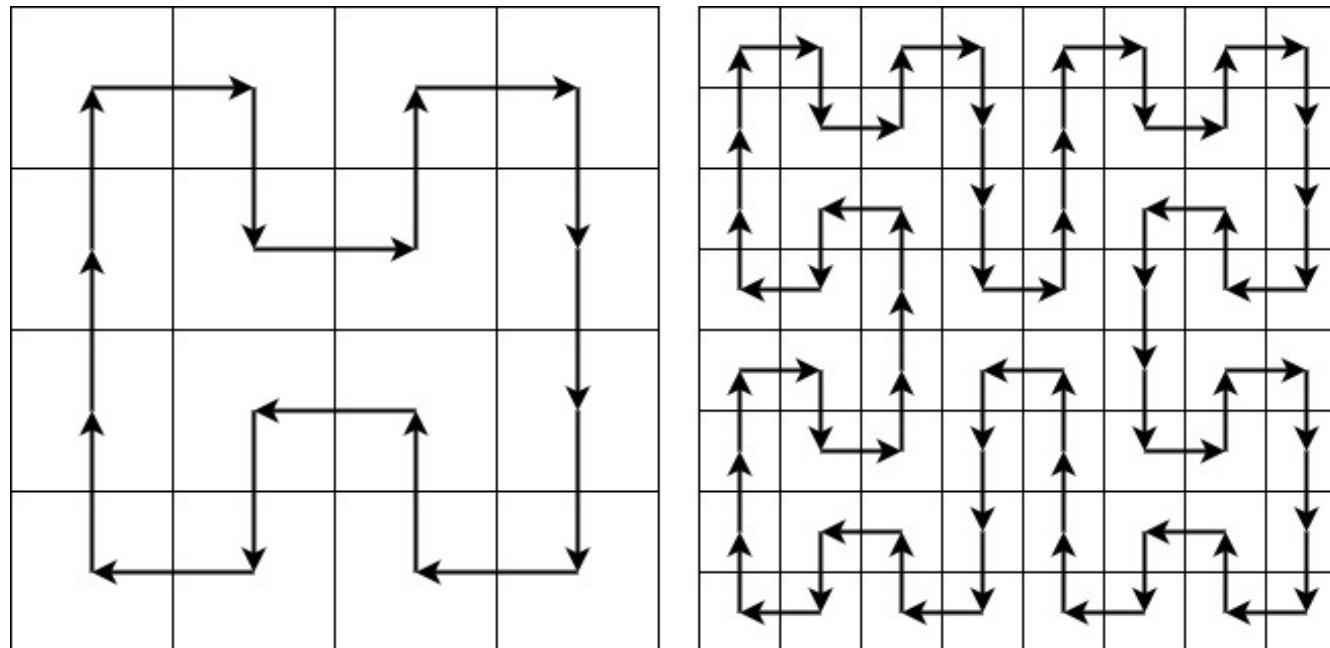
Кривая Гильберта

Используется во многих современных индексах (например в S2Geometry), является функцией заматающей квадрат. Важная особенность - смежные ячейки на кривой, являются смежными и на заметаемой области.



Н-кривая

Разработана в 2020 году Игорем Нетаем. Смежные ячейки на кривой, являются смежными и на заметаемой области, кроме этого является циклической (начало и конец кривой являются смежными в пространстве.)



Особенности стандартных заметающих кривых

- 1) заметаемая область является квадратом;
- 2) в случае с кривой Лебега (Z-кривая), имеет место нарушение локальности данных: когда области с соседними номерами на кривой не являются смежными на заметаемой области;

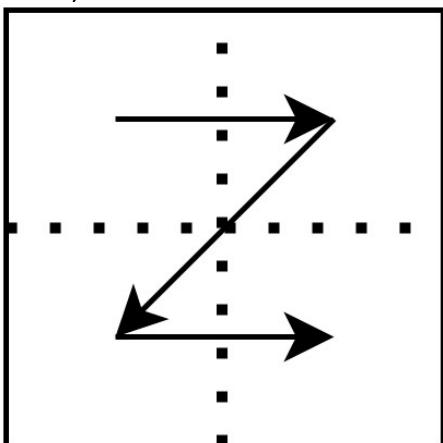
Особенности данных ДЗЗ, которые не учитываются стандартными заметающими кривыми

- 1) стандартные заметающие кривые не учитывают географические особенности заметаемой области (в области построения геопространственных индексов)
- 2) в зависимости от проекции заметаемая область является квадратом, прямоугольником или кругом
- 3) поверхность планеты неоднородна (есть океаны, материки, густо– и малозаселенные области)
- 4) имеются широкораспространенные проекции (например UTM) которые не обладают регулярным способом деления на зоны. Как правило, число зон по осям не равно степени двойки.

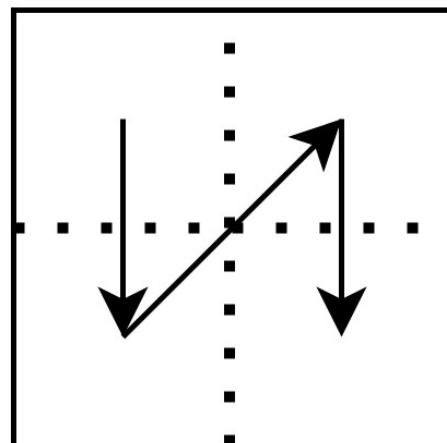
Предлагаемый способ построения заматающих кривых

Прямой и обратный алгоритм преобразования 2-мерного пространства в 1-мерное, а также эффективный алгоритм построения заматающих кривых, опубликованы в журнале «Естественные и технические науки» в 2024 году.

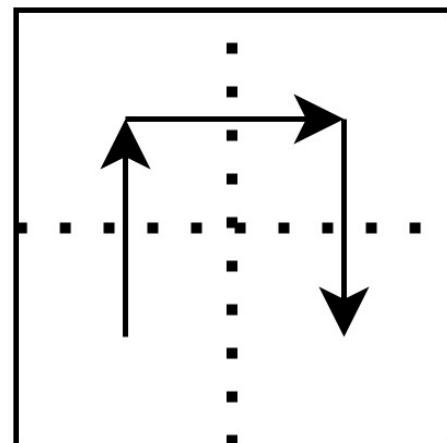
Базовыми элементами построения произвольной кривой являются 4 типа блоков Z, И, П, У:



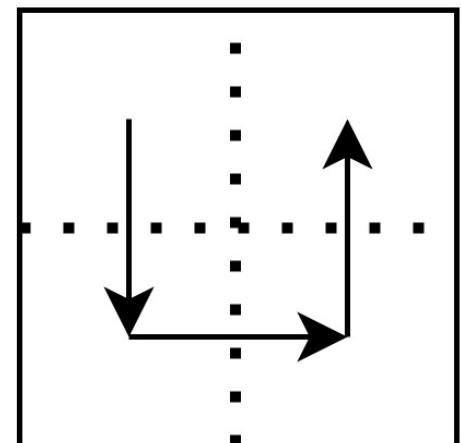
Блок Z



Блок И



Блок П



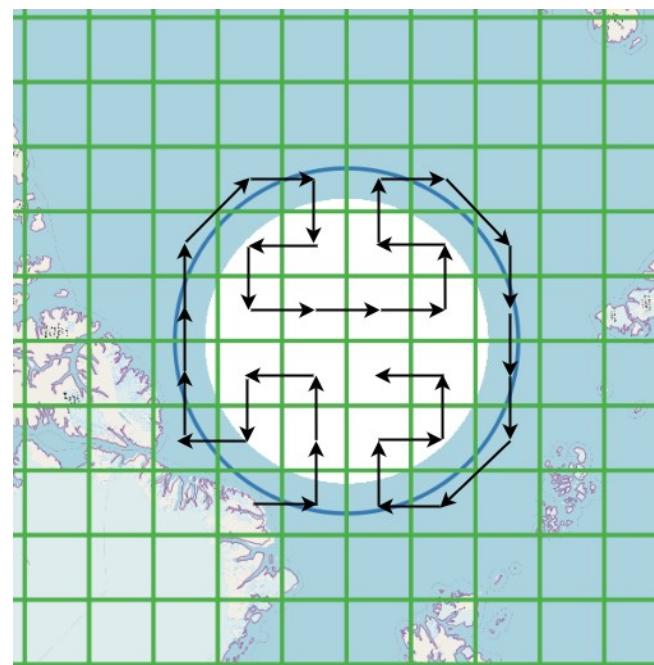
Блок У

Эти блоки могут быть повернуты на углы 0, 90, 180, 270 градусов

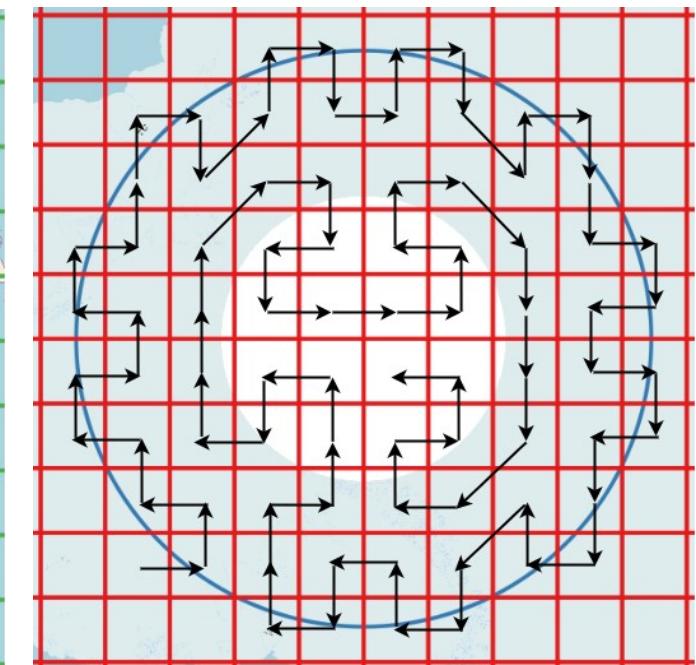
Базовые кривые для обхода полярных областей

Ниже представлены варианты обхода полярных областей, которые обладают следующими свойствами:

- 1) конец (или начало) обхода находится на полюсах;
- 2) кривая для южной полярной области включает в себя кривую для северной;
- 3) шаг сетки един и составляет 250 000 м в проекциях EPSG:5041 и EPSG:5042

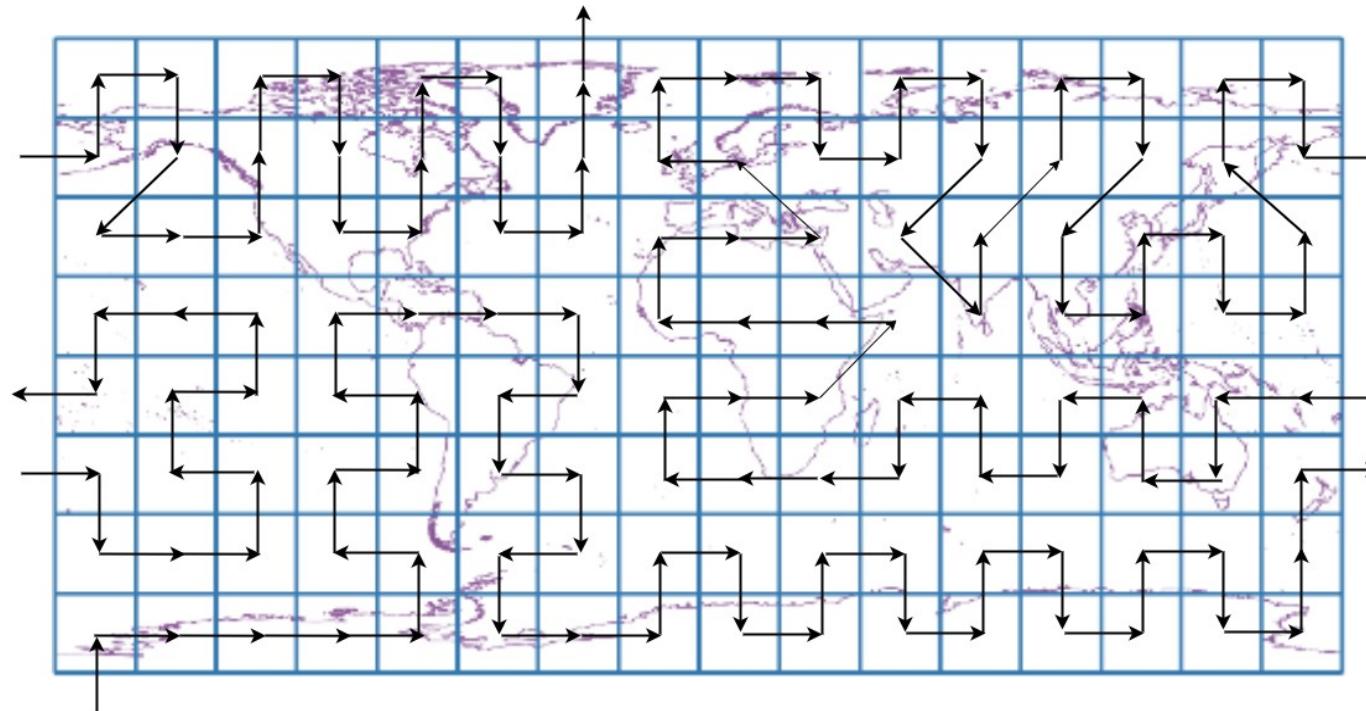


Северная полярная область



Южная полярная область

Вариант построения базовой кривой для геодезической СК



Особенностью данного обхода является то, что участки заселенных континентов, являются близко расположеными на кривой. Вариант ручного заполнения.

Особенности зон УТМ. Способ построения регулярной сетки, совместимой с УТМ.

Зоны над северной Европой имеют размеры (градусы по долготе на градусы по широте):

X31: 9 на 12,

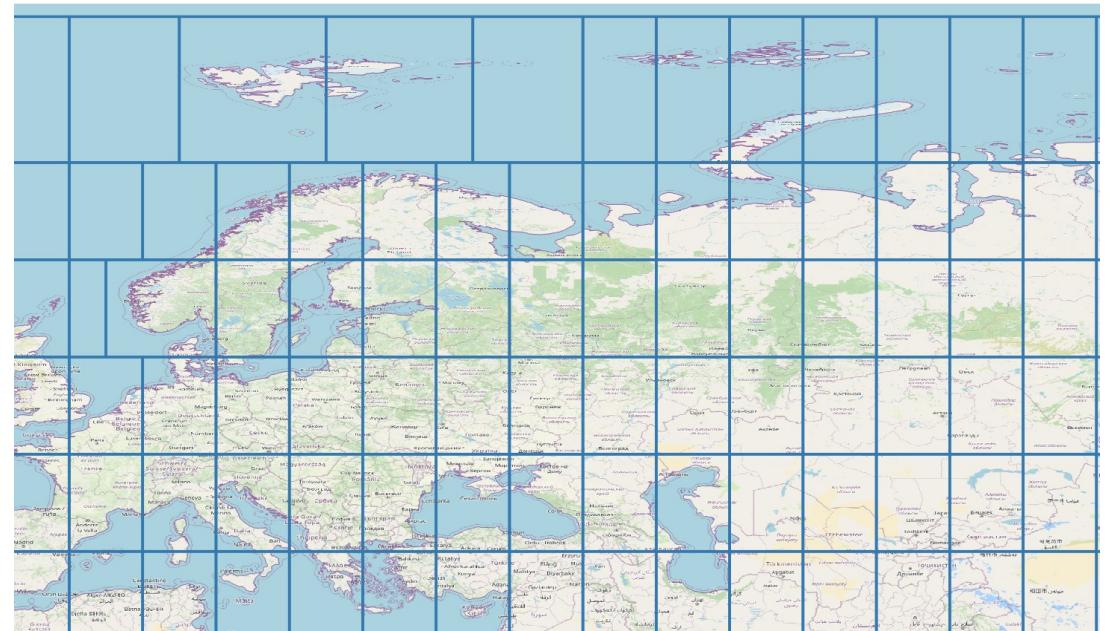
X33: 12 на 12,

X35: 12 на 12,

X37: 9 на 12,

V31: 3 на 8,

V32: 9 на 8.

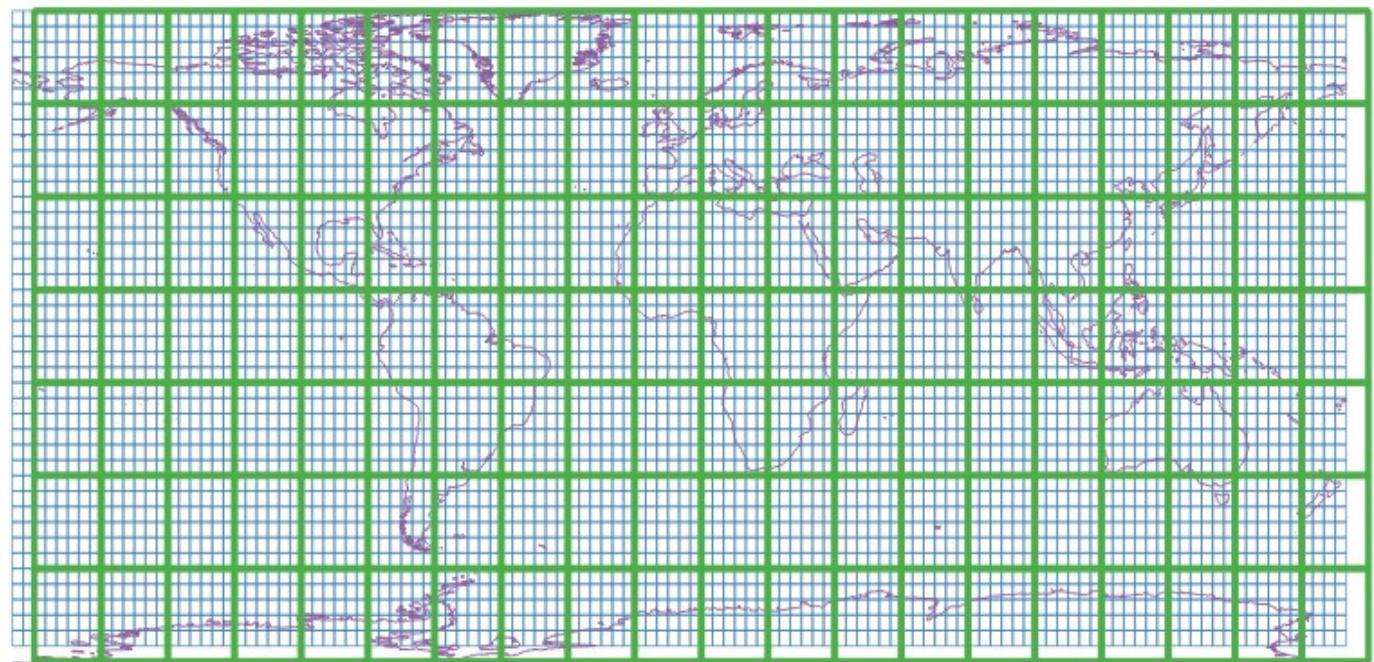


Для того, чтобы устранить эти исключения, можно перейти к сетке 3 на 4 градуса.

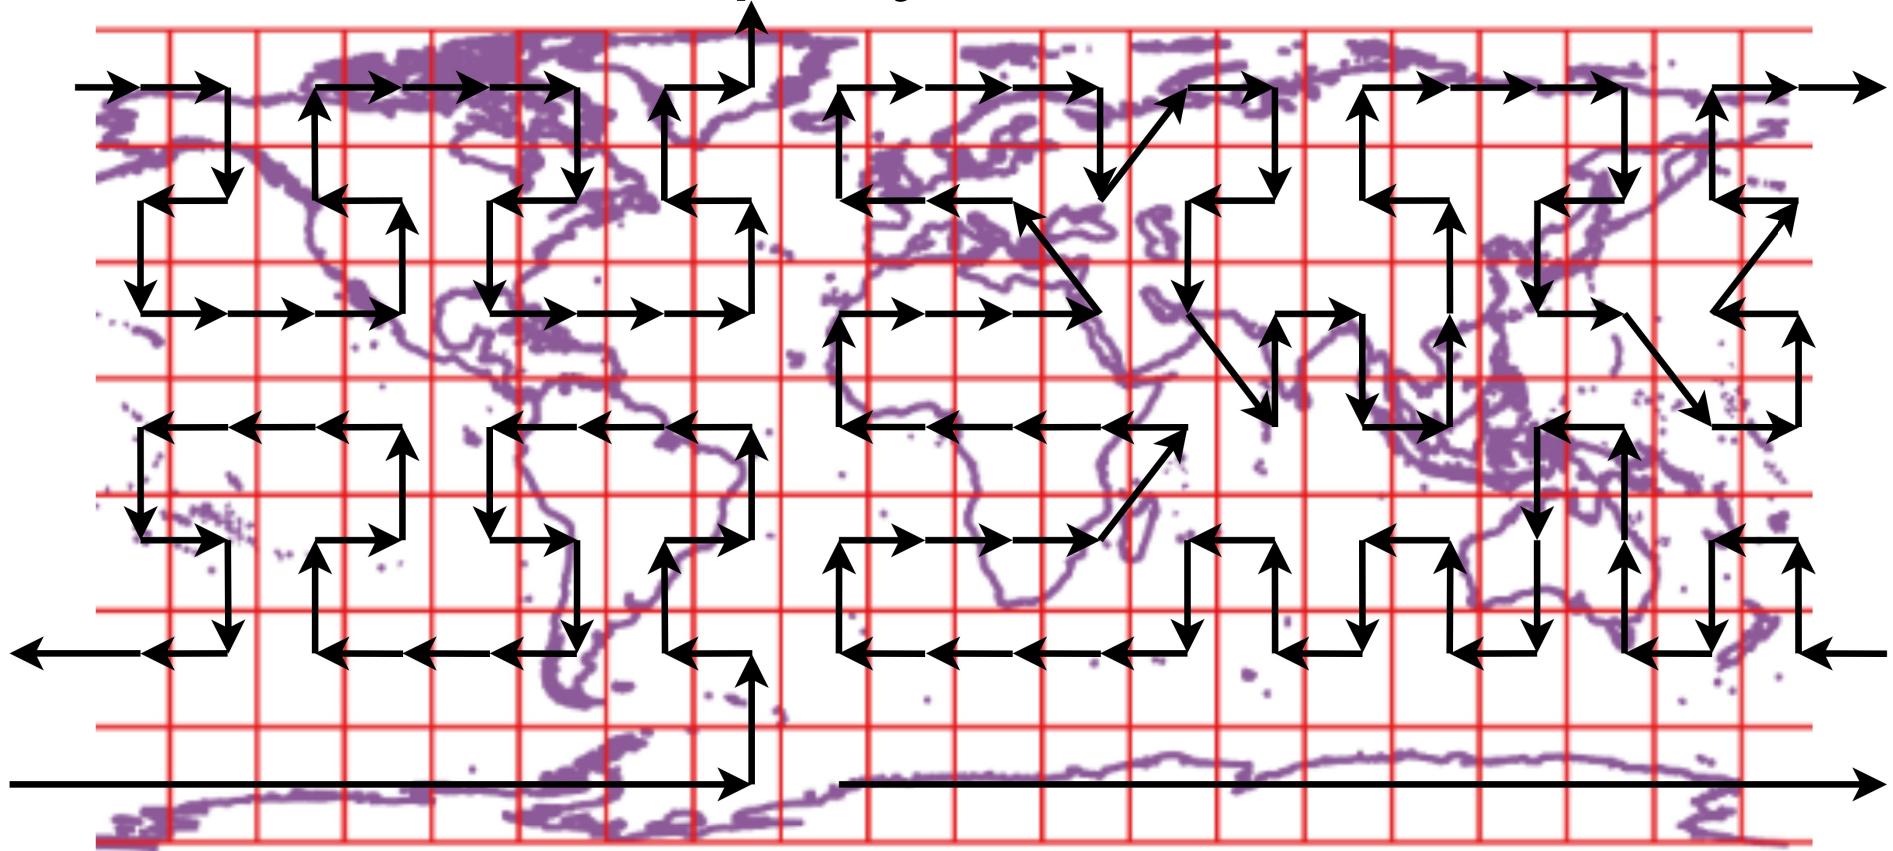
3x4-градусная глобальная сетка с блоками по 6x6 ячеек

После разбиения всей поверхности Земли на ячейки меньшего размера требуется выполнить группировку ячеек на блоки.

В данный момент выполняется исследование возможности группировки по 36 ячеек, что позволит с одной стороны упростить подбор варианта обхода блоков, а с другой – оставить некоторую свободу выбора обхода ячеек внутри блока.



Вариант обхода блоков ячеек 3x4-градусной сетки



Вариант обхода блока из ячеек 3x4-градусной сетки

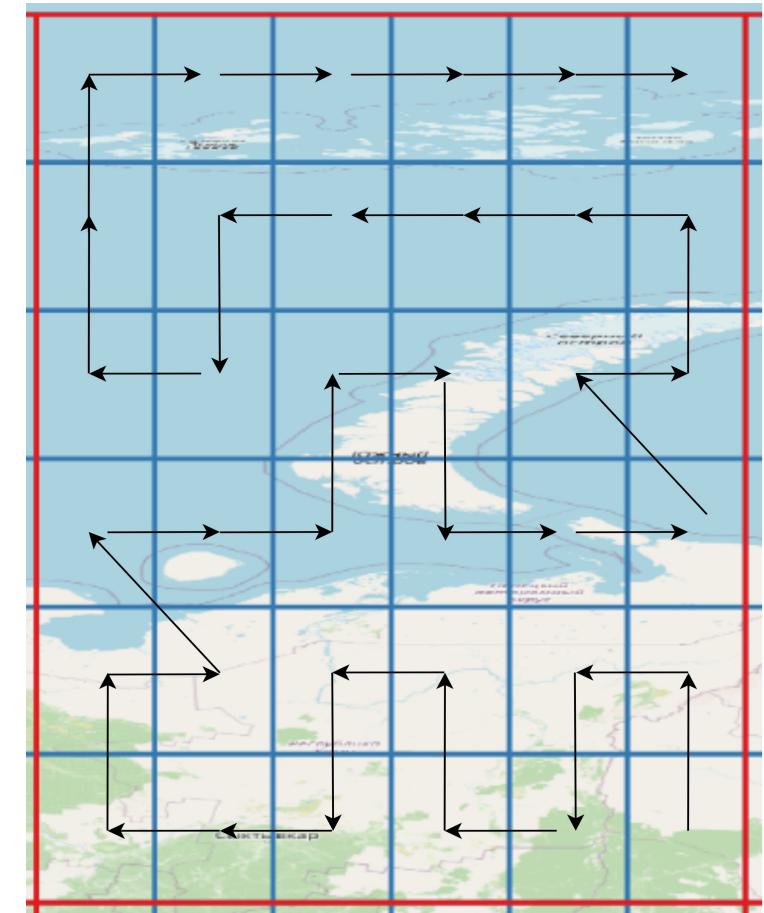
На рисунке продемонстрирован ручной вариант обхода ячеек 3 на 4 градуса объединенный в блок 6 на 6 ячеек.

Шаблон типа ПI.

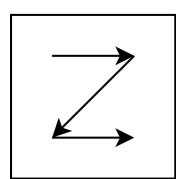
Имеется как минимум 3 способа отбора вариантов:

- 1) критерии симметрии кривой и ее участков;
- 2) критерий пересечения по суше для смежных ячеек на ломаной;
- 3) критерий минимума числа пересечений границ государств.

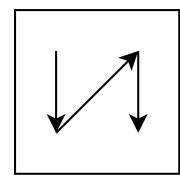
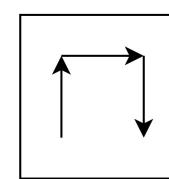
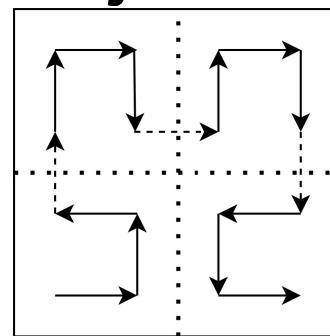
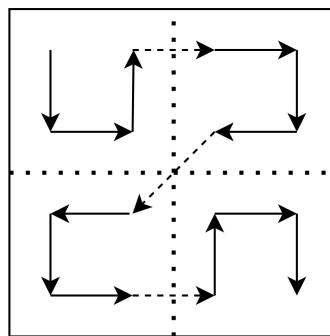
Данные критерии позволяют автоматизировать выбор шаблонов для заметания разных блоков.



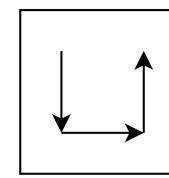
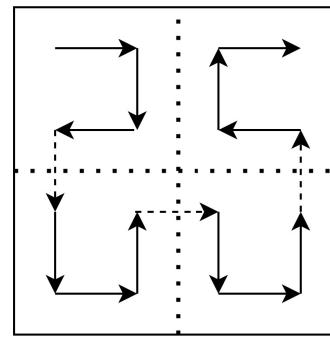
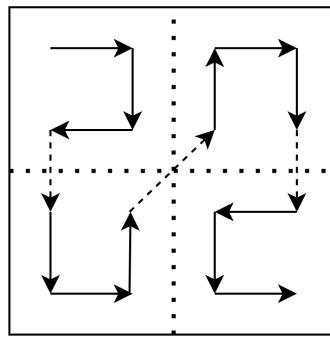
Декомпозиция четырех базовых шаблонов на 4 дочерние области размером 2 на 2, используя шаблоны П и У



Декомпозиция шаблона Z с использованием шаблонов П и У



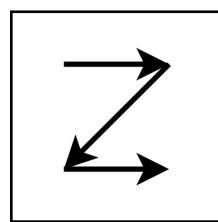
Декомпозиция шаблона И с использованием шаблонов П и У



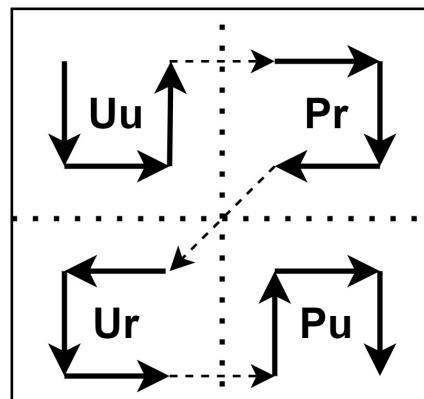
Представленный способ декомпозиции может использоваться на уровнях деления ячеек на 4 дочерние области с конфигурацией 2 на 2 и минимизацией числа используемых шаблонов.

После иерархического перехода остаются только шаблоны П и У

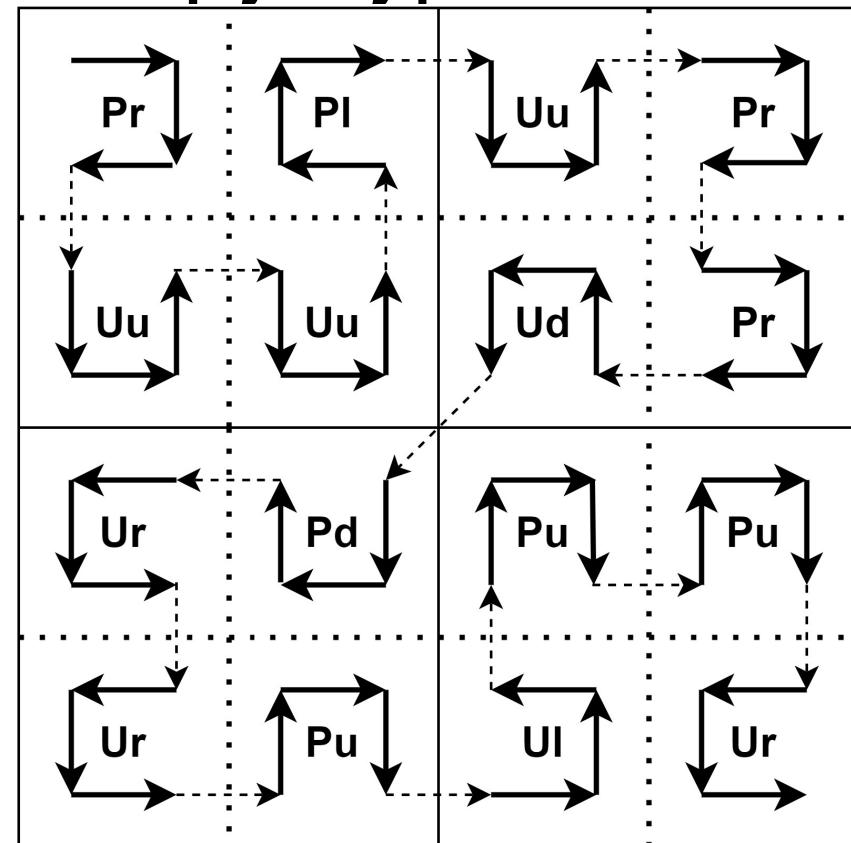
Демонстрация двух последовательных иерархических переходов при делении на дочерние области со структурой 2 на 2



Базовый шаблон Z



Уровень декомпозиции 1



Уровень декомпозиции 2

Заключение

Предложен способ индексации данных в различных проекциях, и областью индексации отличной от квадрата. Способ обладает большой вариативностью в зависимости от интересующих параметров заметаемой области.

Геопространственные индексы, построенные с использованием ZIPU-кривых, позволяют на ранних этапах фильтрации получать информацию о континенте, позволяют упростить запрос на выборку информации.

Предложен способ оценки площади региона по покрытию, построены таблицы зависимости площади от уровня ячейки и её индекса по широте.

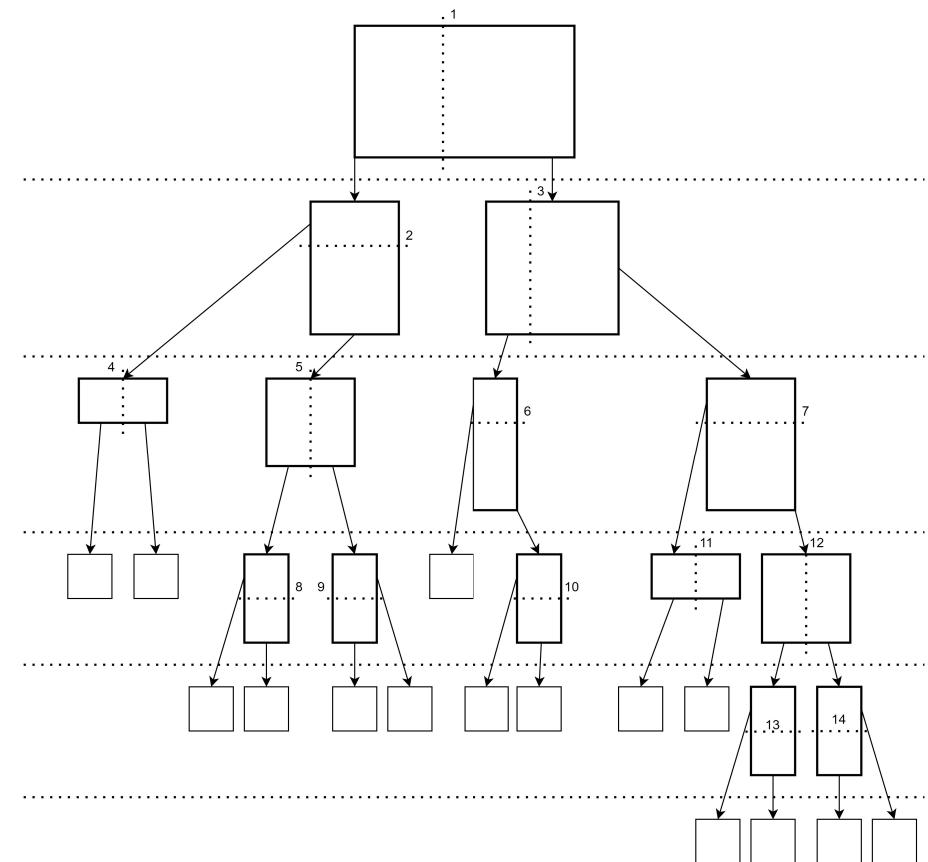
Спасибо за внимание!

Иерархическое деление ячеек

Наиболее вычислительно эффективным является деление ячейки на 4 части, поэтому, начиная с определенного уровня детализации, при дальнейшем делении для достижения определенной точности покрытия лучше использовать степени двойки.

Однако, необходимо продемонстрировать иерархическое деление нестандартной области, например 3 на 5.

Для вычисления покрытия произвольной области сеткой с размерами 3 на 5 ячеек требуется выполнить до 28 пересечений с прямоугольником.



Идея вычисления оценки площади по покрытию

Способ вычисления оценки площади по покрытию (без вычисления процента пересечения). Для регулярных сеток.

При получении покрытия региона ячейками мы знаем индекс/номер ячейки по оси широт. Если ячейка полностью входит в регион, то мы знаем точную площадь данной ячейки. Можем ограничить площадь региона снизу. Если учитывать ячейки не полностью входящие в регион, то мы можем ограничить площадь региона сверху.

$$S_{min} = S_2 \cdot 4 + S_3 \cdot 4 + S_4 \cdot 4 + S_5 \cdot 4$$

$$S_{max} = S_1 \cdot 6 + S_2 \cdot 6 + S_4 \cdot 6 + S_5 \cdot 6 + S_6 \cdot 6$$

