

ВИКОРИСТАННЯ МОДЕЛІ NESTED SET ДЛЯ ЗБЕРІГАННЯ ДЕРЕВОВИДНИХ СТРУКТУР В БАЗІ ДАНИХ SQL

Перед автором була поставлена задача – зберігання та використання деревовидних структур (категорій оголошень) з застосуванням технології MySQL при розробці веб-сайту оголошень besplatka.ua.

Стандартна реляційна алгебра та побудовані на ній SQL операції не можуть бути застосовані для всіх потрібних маніпуляцій з деревами (ієрархіями). Якщо дерево має довільну глибину, це не дозволяє використовувати SQL вирази для таких операцій, як порівняння місця в ієрархії для двох елементів або визначення належності елемента до певного під-дерева.

Існує декілька підходів для вирішення проблеми і деякі є доступними в системах керування базами даних:

- підтримка ієрархічних типів даних;
- розширення SQL для маніпуляцій з деревами;
- SQL запити можуть бути виражені мовою програмування, яка підтримує ітерації та дозволяє виконувати реляційні операції, як от PL/SQL, T-SQL, або майже будь-якою сучасною мовою програмування;

Деревовидні структури в реляційних базах даних можна зберігати трьома основними способами: Adjacency List (суміжні списки), Materialized Path (матеріалізовані шляхи) та Nested Set (вкладені множини). Перший спосіб передбачає зберігання батьківського елемента в полі `parent_id`. Другий – повний шлях до елемента зберігається в полі типу `path`. Модель Nested Set передбачає зберігання дерева в трьох колонках – `left`, `right` та `depth`, де перші дві зберігають в собі діапазон усіх вкладених елементів.

Перший спосіб – зберігання для кожного елемента ідентифікатору його батька – спосіб, мабуть, найпопулярніший, проте, має значний недолік – SQL запитом можна «пройти» по дереву тільки рівнем вище (маючи на руках `parent_id`), та рівнем нижче (побудувавши зв'язок на основі того ж `parent_id`). Кожен наступний рівень передбачає додавання ще одного зв'язку в SQL запиті, що значно нагромаджує сам запит, не кажучи вже про те, що час виконання такого запиту зростає в геометричній прогресії. В такому разі дерево можливо побудувати за допомогою рекурсії. У випадку MySQL ми маємо рекурсію, але тільки на рівні збережених процедур і до 255 рівнів. Також можна застосувати рекурсію, зв'язавши мову програмування та БД, але кількість запитів може бути величезною, тому краще це робити на рівні бази даних.

Другий спосіб – зберігання для кожного елемента його повного шляху в дереві – незручний тим, що переміщення елементів по дереву веде за собою непередбачувану кількість SQL запитів на зміну власне поля `path`, так як заздалегідь невідомо кількість можливих нащадків елемента, який рухають усередині дерева. Те саме стосується і операції видалення елемента з дерева.

Та, власне, вкладені множини (Nested Set), техніка моделі яких полягає в нумерації вузлів відповідно до обходу дерева. Кожен вузол оброблюється двічі, кожному вузлу надається номер, відповідний до порядкового номеру згідно з обходом. Кожен вузол набуває двох номерів, які зберігаються як два атрибути. Вибірка стає швидкою: належність до дерева (або певної гілки дерева) може бути визначена через порівняння цих номерів. Оновлення дерева вимагає повторної нумерації атрибутів, тому може бути повільною. Проте, в рамках поставленої задачі дерево часто використовується (багато запитів) та рідко змінюється, така модель є найбільш оптимальною.

Дерево складає собою масив вузлів, де кожен вузол має 4 складові – унікальний ідентифікатор, рівень вузла, лівий та правий ключ. Саме у цих двох цифрах закладена вся інформація про дерево. Та, якщо цю інформацію занести до бази даних, то робота з деревом значно спроститься. Щоб проставити ліві та праві ключі, краще всього накласти на дерево асоціацію з лабіринтом без циклів, який потрібно пройти від входу до виходу. Ідея полягає в тому, що потрібно йти лабіринтом, постійно та невідривно торкаючись стіни правою рукою. Таким чином здійснюється обхід від початку до кінця по всім вузлам лабіринту/дерева, причому захід в кожний елемент (комірка для правого та лівого ключів) здійснюється лише один раз. Головною особливістю такого підходу є те, що значення лівого (та правого, але для вибірки достатньо лівого) ключа будь-якого вузла (окрім кореня) знаходиться в діапазоні лівого та правого ключів усіх своїх предків, звідки власне пішла назва цієї моделі – «Вкладені множини».

Визначимо які дані можна вибрати з таблиці шляхом запиту:

1. Власне, саме дерево
`SELECT id, name, level FROM my_tree ORDER BY left_key`

В результаті отримано список, де кожен нащадок знаходиться після свого батька. Слід зауважити, що лівий ключ визначає не лише положення елемента в дереві, а й порядок

- відносно сусідів, тому, видозмінивши отриманий список, додаючи до назви відступи у кількості рівня елемента, отримаємо дерево в класичному представленні/вигляді.
2. Вибір підпорядкованої гілки (усіх нащадків)
`SELECT id, name, level FROM my_tree WHERE left_key >= $left_key AND right_key <= $right_key ORDER BY left_key`
 3. Вибір батьківської гілки (тобто усіх предків)
`SELECT id, name, level FROM my_tree WHERE left_key <= $left_key AND right_key >= $right_key ORDER BY left_key`
 4. Вибір гілки, у якій приймає участь поточний вузол
`SELECT id, name, level FROM my_tree WHERE right_key > $left_key AND left_key < $right_key ORDER BY left_key`

В цілому, застосовуючи в умові запиту ключів вузла, можна вибрати будь-які дані, пов'язані з цим вузлом.

Отже, можна виділити основні правила та прикмети даної моделі:

1. Лівий ключ завжди менше правого;
2. Найменший лівий ключ дорівнює одиниці;
3. Найбільший правий ключ дорівнює подвоєній кількості вузлів;
4. Різниця між правим та лівим ключем завжди число непарне;
5. Якщо рівень вузла – число непарне, то лівий ключ завжди непарне число, аналогічно з парними числами.
6. Ключі завжди унікальні, незалежно від того правий він чи лівий.
7. Кількість підпорядкованих вузлів (нащадків) для кожного елемента можна визначити за формулою

$$count = (right - left - 1) / 2$$

Отже, щоб визначити, є у елемента нащадки чи ні, не потрібно робити додаткові запити в базу даних – якщо різниця між правим та лівим ключами складає одиницю, елемент є кінцевим у гілці.

Розглянемо операції зміни дерева – створення вузла, переміщення по дереву та видалення з дерева.

Для створення вузла потрібно знати рівень та правий ключ батьківського вузла, або максимальний правий ключ, якщо у нового вузла не буде батьківського. Створення нового вузла пройде в 3 кроки – оновлення ключів існуючого дерева, вузлів, що стоять за батьківським вузлом. (`UPDATE my_tree SET left_key = left_key + 2, right_key = right_key + 2 WHERE left_key > $right_key`); наступний – оновити батьківську гілку (`UPDATE my_tree SET right_key = right_key + 2 WHERE right_key >= $right_key AND left_key < $right_key`); та власне створення нового вузла (`INSERT INTO my_tree SET left_key = $right_key, right_key = $right_key + 1, level = $level + 1`).

Операція видалення вузла не набагато складніша, проте потрібно врахувати, що у вузла, що видаляється, можуть бути нащадки. Тому, видалення з дерева також проходить поетапно – спочатку власне видаляються ті вузли, у яких лівий ключ не менший за лівий ключ потрібного елемента і правий ключ не більший за правий ключ цього елемента. Наступним кроком буде оновлення батьківського елемента – зменшення його правого ключа на величину, що дорівнює різниці правого та лівого ключів елемента на видалення, до якої додається одиниця. Останнє – оновлення наступних вузлів (тобто тих, що стоять правіше) – від їх лівих та правих ключів також віднімається значення того ж виразу.

Переміщення вузла – найскладніша дія в управлінні деревом. Вузол може переміщуватися в дві різні області: вищестоящий і нижчестоящих вузлів.

1. Вверх по дереву включає в себе:
 - a. Перенесення гілки (вузла) в підпорядкування нижчестоящому по дереву вузлу;
 - b. Перенесення гілки вгору без зміни батьківського вузла (зміна порядку вузлів);
2. Вниз по дереву:
 - a. Перенесення вузла в корінь дерева;
 - b. Перенесення вузла вниз без зміни батьківського вузла (зміна порядку вузлів);
 - c. Підняття вузла на рівень вище;
 - d. Переміщення вузла вниз по дереву.

Висновок. У даній роботі була розглянута і описана задача зберігання деревовидних структур в реляційних базах даних. Було запропоновано використання моделі «Вкладені множини» та описано переваги методу над іншими.

ВІДОМОСТІ ПРО АВТОРІВ:

СУЙКОВСЬКА Катерина Андріївна, магістрант групи ПІ-41м кафедри програмного забезпечення систем Житомирського державного технологічного університету.