

Database Jungle に関する研究

115731 金川竜己 指導教員：指導教員名

1 研究目的

実際の業務システム等で、アカウント管理を行う際に既存の Database では、過去の version のデータを参照を行えなかったり、木構造のデータ型を入れる際に面倒だったり、問題がある。

そこで、当研究室ではデータの編集の際に一度木構造として保存したデータには触れず、新しく木構造を作成してデータの編集を行う非破壊的木構造を用いたデータベースである Jungle を開発している。

Jungle は非破壊で過去のデータを変更しないので、過去のデータを簡単に参照できたり、Jungle 自体が木構造データベースなので、木構造のデータをそのまま格納出来る。

本研究では Jungle に、検索 API、Index、過去データの参照の実装を行い、その後、当研究室と共同研究を行っている Symphonies 社が開発しているアカウント管理システム maTriX に Jungle を組み込む。

2 maTriX

maTriX とは Symphonies 社が開発しているアカウント管理、許諾判定システムのことである。

matrix は人、役職、役割、権限と言った木構造の組織、ポリシーファイルの2つのデータを持っている。maTriX が保持している人、役職、役割等のデータはお互いに参照している。ポリシーファイルは、組織の中で申請等を行った際に、どの権限によってその申請が許諾されるのかを指定している。

組織のデータ、ポリシーファイル共に木構造のデータであるため、木構造のデータベースである Jungle には、そのまま格納できる。

また、maTriX は、いつ、誰が、どんな申請をしたか、と言った過去の承認情報を保持するので、過去の組織のデータを参照する必要が出てくる。よって過去のデータの参照が出来る Jungle と相性が良い。

maTriX はデータを xml 形式で格納することが可能なので、xml 形式で書き出された maTriX のデータを Jungle に格納するために、SAX を用いて、Jungle 用の xmlReader を作成した。xmlReader を作成したことにより、実際に maTriX から出力されたデータを Jungle に取り込み、本格的なテストが行えるようになった。

3 検索 API の実装

Jungle は、データを格納する API は実装されていたが、データの検索を行う API の実装は行われていなかった。

本研究では Java8 の新機能である lambda 式を用いてデータの検索を行う find 関数の実装を行った。

以下に find 関数の使い方を示したソースコードを記述する。

Jungle の Query 部分のソースコード

```
Iterator<Pair<TreeNode, NodePath>> pairPersonIterator =
    traverser.find((TreeNode node) -> {
        String element = node.getAttributes().getString("element");
        if (element == null)
            return false;
        if (element.equals("Person"))
            return true;
        return false;
    }, "element", "Person");
```

find 関数は引数に Query、String key、String value の3つの引数を取り、条件に一致した Node と、その Node までの Path を1つにまとめた Pair の Iterator を返す。

第一引数には、探索の条件を記述する関数 boolean condition(TreeNode) を定義した Interface Query を。第二、第三引数の、String key、String value は後述する Index を使うために使用する。

Interface Query の定義

```
public interface Query {
    boolean condition(TreeNode node);
}
```

find 関数の処理の流れは、まず初めに、Index があるかどうかを調べる、index がある場合は Index を使用し探索を行う。Index がない場合は、Index を作成しながら Tree を全探索する。

上記の Jungle の Query 部分のソースコードは、"Person" というデータを持った Node と、その Node までの Path の Pair の iterator を返す。

検索 API は、他に特定の Node 以下に対して検索を行う findInSubTree(Query,node,key,value) も実装した。

4 Index の実装

Jungle の探索は Tree を全探索するので、探索の計算量は $O(n)$ となり、非常に効率が悪い。しかし、Index を使用することで効率よく探索を行えるようになる。Index の実装には、functionalJava の TreeMap を使用した。

TreeMap は、Key と Value のペアを用いて赤黒木を構築する。赤黒木の長所として、ソート済み二分木の探索なので計算量が $O(\log N)$ であること、データ編集時の最悪計算量が

データ構造のうちで最善のもの1つであるので、安定した速度でデータの編集が行える。また、TreeMapはimmutableなので一度作られたTreeに対して更新が行われない、つまり新しい要素を追加した際は、新しくTreeMapを作る。なのでTreeは、各versionごとに固定のIndexを持つことが出来る、また、新しくTreeを作る際に、過去のTreeの一部を再利用するのでメモリの使用量を抑えることが出来る、ということがあげられる。

Indexは各ユーザーがローカルにIndexを持つon the fly形式で実装する。

Indexのデータの型

```
TreeMap<String key,  
        TreeMap<String value, List<Pair<TreeNode, NodePath>>>>
```

最初のTreeMap<String key, TreeMap>はIndexを格納するTreeMapである。このTreeMapに対しkeyでgetを行うと、keyに対応するIndexが登録されている場合、Indexを取得できる。取得したIndexに対しvalueでgetを行うと、valueの値を持つNodeと、そのNodeまでのPathの2つをPairにまとめたListが返ってくる。

IndexのUpdate

Indexの更新はIndexEditorを用いて行う。

JungleでTreeの編集を行う際は、JungleTreeEditorを使用し、Nodeのadd、delete、値のput、deleteを行う。Treeに対して変更を加えると、それに伴い、Indexも更新する必要がある。そこでJungleTreeEditorの機能を拡張し、IndexJungleTreeEditorを作成した。

IndexJungleTreeEditorでは、Treeの更新と同時にIndexEditorを用いてIndexの更新も行い、Treeに対して両方の変更をCommitする。

IndexEditorの定義

```
public interface IndexEditor {  
    Either<Error, IndexJungleTreeEditor>  
        edit(TreeNode root, TransactionManager txManager,  
            TreeEditor editor, TreeOperationLog log,  
            TreeMap<String, TreeMap<String,  
                List<Pair<TreeNode, NodePath>>>> index);  
}
```

5 maTriXに必要なQueryの作成

maTriXは、許諾判定を行う際に、組織構造に対してQueryを行う。maTriXとJungleの接続を行うにあたり、組織構造に対するQueryは必要不可欠である。

当研究ではmaTriXにJungleを接続するのに必要なQuery15個を完成させた。maTriXのQueryを実装するにあたって、問題となったのが、特定のNodeの子供に対してのindexを使った検索である。Indexには、Tree全体のデータが入っているためIndexを使用した検索は必然的にTree全体に対する検索になる。

この問題は、NodePathに、関数compare()を実装し解決した。関数compareは引数に比較対象のNodePathを受け

取り、そのPathが自分の下にあるかどうかを調べる関数である。

compareを使用することにより、特定のNode下の探索を行う際、特定のNodeのPathとIndexで取ってきた結果に対し、compareを使い、フィルタリングを行うことで、Indexを用いた特定のNode下の探索を可能にした

今回追加実装したcompareの定義

```
public boolean compare(NodePath path);
```

6 これから行うべきこと

Indexを使用した場合の性能評価

IndexとmaTriXのQueryの実装が終わり、maTriXに接続する準備が整ったので、実際にmaTriXとJungleの接続を行い、既存のmaTriXとjunglemaTriXの性能を評価し、本当に早くなったのか確かめる。この時にIndexの性能も評価する。

過去のversionの参照APIの実装

Jungleは、過去のversionのTreeを保持しているので、簡単に参照できるはずである。過去のversionのuuidを指定して自由に過去のversionを参照できるようにする。

Jungleの設計手法の確立

Jungleは比較的自由にデータを格納することができるので、Jungleを実際に使用する際に、どこまでを一つの木として扱うか、等をまとめたJungleDBの設計手法を確立させる必要がある。

参考文献

- [1] 玉城将士 非破壊的木構造を用いた分散CMSの設計と実装
- [2] 大城信康 分散Database Jungleに関する研究
- [3] Eric Redmond and Jim R. Wilson 7つのデータベース7つの世界