

# Návrh a prototypová implementace databáze pro snadnější práci se strukturami nukleových kyselin

Bc. Ondřej Čečák

Fakulta elektrotechnická  
České vysoké učení technické v Praze

10. června 2011



# Obsah

- 1 Obsah
- 2 Zadání a účel práce
- 3 Návrh řešení
- 4 Realizace a testování
- 5 Zhodnocení a závěr

# Stručné zadání práce

Zadané části práce:

- 1 návrh a implementace datových struktur potřebných pro databázi struktur nukleových kyselin
- 2 importy dat z veřejné databáze PDB obohacených analýzou programem 3DNA
- 3 návrh a prototypová implementace webové aplikace pro příjemné dotazování nad daty
- 4 zobrazení výsledků s použitím grafické aplikace JMol

# Motivace – cíl a účel

- aktuální téma, studium struktury pro pochopení funkce a interakce biomakromolekul v organizmech
- přímo nezpracovaná oblast, v současné době neexistuje podobný nástroj pro rychlé zpracování dotazů nad požadovanými daty
- cíl je zpracovat analyzovaná data struktur pro snadné použití – vyhledávání
- aplikace má sloužit zejména výzkumníkům a studentům VŠCHT v Praze


# Návrh

Návrh a následně pracovní postup:

- 1 nastudování problematiky, rešerše existujících řešení
- 2 import dat z veřejné databáze PDB
- 3 analýza struktur programem 3DNA
- 4 databáze struktur a souvisejících parametrů v PostgreSQL
- 5 funkční prototyp aplikace pro dotazování
- 6 vizualizace v grafickém appletu Jmol
- 7 testování importu

# Import dat

- jazyk Python
- exaktní analýza mmCIF dat externí knihovnou mmLib
- výpočet strukturních dat externím programem 3DNA 2.0
- uložení získaných dat do databáze




# PostgreSQL databáze

- „mělká“ struktura – vazba přes identifikátor biomolekuly, data organizovaná v tabulkách podle typu dat
- B-tree indexy, vyhledávání se složitostí  $O(\log n)$
- uživatelské datové typy po úvodní rešerši zamítnuty
- PostgreSQL sekvence a transakce – podpora pro paralelní zpracování dat
- nenašel jsem podobnou práci, nejbližší je návrh zpracování PDB dat „PDB-SQL“ pro ukládání a vyhledávání alpha uhlíkových pozic do MySQL

# Funkční prototyp webové aplikace

- jazyk PHP
- Java Applet Jmol
- jazyk JavaScript
- uložení získaných dat do databáze



# Realizace

- komponenty implementovány dle návrhu

The screenshot shows a web browser window titled "Nucleic Acids Database - Opera". The address bar shows "localhost:8081-1BNA". The page content includes:

**Nucleic Acids Database**  
 query | browse database | import structures | about

**Detail of 1BNA**

Structure PDB code: 1BNA  
 Name: Structure of a B-DNA dodecamer: conformation and dynamics.  
 Authors: Drew, H.R.; Wing, R.M.; Takano, T.; Broka, C.; Tanaka, S.; Itakura, K.; Dickerson, R.E.  
 Method: X-RAY DIFFRACTION  
 Date of deposition: 1981-01-26  
 Date of release: 1981-05-21  
 Sequence: CGCGAATTCGCG

PDB lookup: [1BNA](#)

X-Ray Diffraction details  
 Resolution low: 8  
 Resolution high: 1.9  
 Method: VAPOR DIFFUSION  
 Temperature: 290  
 pH:  
 Reflections all:  
 Reflections obs: 2725

Structure details  
 Chain: A, lenght 49, sequence Res(DC,1,A) ... Frag(HOH,102,A)  
 Chain: B, lenght 55, sequence Res(DC,13,B) ... Frag(HOH,104,B)

On the right side of the page, there is a 3D ball-and-stick model of a DNA dodecamer structure, showing two intertwined strands with atoms represented by colored spheres (red, blue, orange).

# Testování

- import všech struktur obsahující RNA nebo DNA
- 5316 souborů mmCIF, cca 7 GB organizovaného textu, nejstarší z roku 1978
- 3 pracovní procesy na CPU Intel Quad 9400 2,66 GHz cca 13 hodin čistého procesorového času
- kontrolní skript v BASHi sledující výstup importního skriptu
- 95,96 % dat importováno, zbytek označen jako chyba analýzy mmView nebo 3DNA

# Testování komponent aplikace

- 5.101 struktur, 4.303.860 základních jednotek, 36.071.202 atomů
- 12.600.746 strukturních parametrů
- cca 1,9 GB čistých textových dat v SQL dumpu
- dotazy na strukturu průměrně do 6 sekund
- výsledek zobrazen se zvýrazněnými detaily včetně prezentace výsledné části struktury v JMol
- testování použitelnosti na poučených uživatelích PC v pořádku

# Zhodnocení

- zadání splněno, určené části databáze pro snadnější práci se strukturami nukleových kysel jsem plně vypracoval pod licenci GNU/GPL a otestoval importem všech známých struktur s DNA a RNA
- vlastní diplomová dokumentuje v angličtině úvodní rešerši, návrh a detaily implementace
- závěr – komplexní data jako strukturální parametry makrobiomolekul mohou být pomocí relační databáze vyhledávány velmi rychle
- cíl splněn, aplikace pomůže pracovníkům a studentům VŠCHT v Praze při výzkumu a studiu
- další možné pokračování – vylepšení webové aplikace, knihovny mmLib nebo programu pro analýzu 3DNA

# Diskuze: Oponentský posudek I.

## Otázka 1

Čím je způsobeno, že u struktur např. 3kuy, 2vju, 1kx3 a dalších se zobrazují neúplné seznamy nukleotidů a případně žádné jejich další parametry, přestože program 3DNA generuje čisté a bezchybné výstupní soubory?

Všechny tyto struktury (a několik dalších) mají záporné indexy jednotlivých residuí, se kterým se nástroj pro import nevyrovná správně kvůli příliš širokému regulárnímu výrazu (znaménko u celého čísla tak bylo oříznuto).

## Diskuze: Oponentský posudek I. – demonstrace

Původní výraz:

```
conversionArray... =  
  int(re.sub(r'?\D', "", numberBuilder...
```

Opravená verze:

```
conversionArray... =  
  int(re.sub(r'[^0-9]*', "", numberBuilder...
```

## Diskuze: Oponentský posudek II.

### Otázka 2

Zajímaly by mě bližší důvody, čím je způsobena značná prodleva při dotazu „browse database“ z webového rozhraní.

Stránka „browse database“ provádí výpočet statistik databáze, 14× zavolá dotaz `SELECT COUNT(*)` pro všechny relevantní tabulky a vypočítá výsledek.

V našem případě databázový stroj zavolá logický ekvivalent scan převedený na fyzické operace exekutoru, Seq Scan. Operace Seq Scan nemá žádnou podřízenou operaci – data získává voláním storage manageru, který má na starosti plnění a správu obsahu datové cache. Když není konkrétní databáze nějakou dobu využívána, cache na výsledek Seq Scan se vyprázdní a data se tedy musí znovu získat fyzickým procházením dat na disku, které je časově náročné.

## Diskuze: Oponentský posudek II. – demonstrace

Prováděcí plán dotazu typu `SELECT COUNT(*)` s daty v cache:

```
EXPLAIN ANALYZE SELECT COUNT(*) FROM structureParameter;  
QUERY PLAN
```

---

```
Aggregate (cost=6646.39..6646.40 rows=1 width=0)  
  (actual time=46.124..46.124 rows=1 loops=1)  
    -> Seq Scan on structureparameter  
      (cost=0.00..5919.51 rows=290751 width=0)  
      (actual time=0.007..26.099 rows=235766 loops=1)  
Total runtime: 46.157 ms
```

Pokud by se v reálném použití ukázalo, že tento typ dotazu zpomaluje práci, bude nejlepší řešení data vhodně předpočítat pro snadné získání, například pomocí databázového TRIGGERu.

## Diskuze: Oponentský posudek III.

### Otázka 3

Jak je databáze zabezpečena z hlediska využití kombinace HTML formulářových polí, skriptovacího jazyka PHP a přístupu do databáze? Nehrozí neoprávněný přístup a spuštění SQL příkazů typu `DROP DATABASE name;` skrze formulářová pole webového rozhraní?

- nasazení není předpokládáno v „nepřátelském“ prostředí (běžný uživatel může importem dat by-design smazat celou databázi), bezpečnost je zajištěna na úrovni práv uživatele databáze
- HTML vstupy jsou přesto ošetřeny před útoky typu SQL injection na úrovni PHP kódu

## Diskuze: Oponentský posudek III. – demonstrace

PHP kód:

```
$where = "";
$where .= $_POST["detailSelect"] . " ";
$where .= "=\'" . $_POST["detail"] . "\'";
$query = "SELECT biomoleculeId FROM biomoleculeData
        WHERE $where;";
$result = pg_exec($link, $query);
```

Výsledný SQL dotaz s ošetřeným **útokem** typu SQL injection:

```
SELECT biomoleculeId
FROM biomoleculeData
WHERE name ='\'; DROP TABLE biomolecule; --';
```

## Diskuze: Oponentský posudek IV.

### Připomínka

Za nevhodný považuji název projektu „Nucleic Acids Database“, protože téměř koliduje s názvem celosvětově uznávaného zdroje strukturních dat nukleových kyselin „Nucleic Acid Database“ (<http://ndbserver.rutgers.edu/>).

Název aplikace byl myšlen zkratkou NADB. S panem oponentem souhlasím, po obhajobě práce bude projekt přejmenován na NASQYT – „Nucleic Acids Structure QuerY Tool“. Děkuji za připomínku.