

# Война Данных

Кровавый Ынтерпрайз  
наносит ответный удар



# Виктор Полищук

infopulse  
bics

*Давным давно,  
в далекой  
далекой*

*галактике...*



@alkovictor



victor-cr



Смысл?

Что?

Зачем?

99% проектов имеют проблемы

Большая доля этого отводится данным

Разработка постоянно усложняется

Часто проблему можно было предотвратить

Деньги, числа, арифметика

Идентификаторы

Текст и строки

Дата и время

Участие  
Приветствуется



# Деньги



# Деньги

# Типы

Float и Double

Integer и Long

BigDecimal



Деньги

Float и  
Double

Хорошо

Встроенные типы

Большой диапазон значений

- Float:  $1.4 \cdot 10^{-45} \dots 3.4028235 \cdot 10^{+38}$
- Double:  $4.9 \cdot 10^{-324} \dots 1.7976931348623157 \cdot 10^{+308}$



Деньги

Float и  
Double

Беда

Обычно разработчики не знают как  
вот это представлено в памяти:

- $e = 2.718281828459045$
- $\pi = 3.141592653589793$
- $\tan\left(\frac{\pi}{2}\right) = 1.633123935319537\textbf{E}16$

Float:  $0.6 + 0.1$

• = ?

Double:  $0.6 + 0.1$

• = ?

Float:  $0.6 + 0.1$

• = 0.70000005

Double:  $0.6 + 0.1$

• = 0.7



The problem is not with Java but with the good standard float's ([http://en.wikipedia.org/wiki/IEEE\\_floating-point\\_standard](http://en.wikipedia.org/wiki/IEEE_floating-point_standard)).

6



You can either:

- use Double and have a bit more precision (but not perfect of course, it also has limited precision)
- use a arbitrary-precision-library
- use numerically stable algorithms and truncate/round digits of which you are not sure they are correct (you can calculate numeric precision of operations)

[share](#) [improve this answer](#)

answered Jul 15 '11 at 22:12



You could use doubles instead of floats

2



[share](#) [improve this answer](#)

answered Jul 15 '11 at 22:08



Float:  $0.2 + 0.1$

• = ?

Double:  $0.2 + 0.1$

• = ?

Float:  $0.2 + 0.1$

• = 0.3

Double:  $0.2 + 0.1$

• = 0.30000000000000000004

Деньги

Float и  
Double

Чё Внутри

Знак — плюс/минус

Экспонента — степень двойки

Мантисса — двоичное число



Деньги

Float и  
Double

Чё Внутри

Float (32 бита)

1

8

23

Double (64 бита)

1

11

52

# Деньги

## Float и Double

### и Чё?

$$0.1f = [0]-[01111011]-[10011001100110011001101]$$

$$0.1f = + 2^{123-127} * (1 + 2^{-1} + 2^{-4} + 2^{-5} + 2^{-8} + 2^{-9} + 2^{-12} + ...)$$

$$0.1f = 0.100000001490116119384765625$$

$$0.01f = [0]-[01111000]-[01000111101011100001010]$$

$$0.01f = 0.00999999977648258209228515625$$

# Деньги

## Float и Double

## Пример



### Баварезе

Ø 30 см    🍷 450 г

1 шт x 79 грн

79 грн



### Мексикано

Ø 30 см    🍷 450 г

1 шт x 79 грн

79 грн



### PEPSI

Ø    🍷

1 шт x 0.0099999997764826  
грн

0.0099999997764826  
грн

$+\infty$  = [0] - [11111111] - [0000000000000000000000000000]

$-\infty$  = [1] - [11111111] - [0000000000000000000000000000]

NAN = [?] - [11111111] - [????????????????????????????]

$+0.0$  = [0] - [00000000] - [0000000000000000000000000000]

$-0.0$  = [1] - [00000000] - [0000000000000000000000000000]

$+0.0f == -0.0f?$

```
/**
 * Get or create float value for the given float.
 *
 * @param d the float
 * @return the value
 */
public static ValueFloat get(float d) {
    if (d == 1.0F) {
        return ONE;
    } else if (d == 0.0F) {
        // -0.0 == 0.0, and we want to return 0.0 for both
        return ZERO;
    }
    return (ValueFloat) Value.cache(new ValueFloat(d));
}
```

# Деньги

## Float и Double

### Итог

Очень узкая область применения

Не очевидны

Не использовать

Забывать про существование

Деньги

Integer и  
Long

Хорошо

Встроенные типы

Целочисленная арифметика

- Нет деления на степень двойки

Деньги

Integer и  
Long

Как?

Храним деньги в «копейках»

Где-то храним «**scale**»

- например, как глобальную константу



# Деньги

Integer и  
Long

Как?

«**Scale**» — это  
N значащих  
цифр после  
запятой

Домножаем  
или делим  
на **10<sup>scale</sup>**

# Деньги

Integer и  
Long

Ч3X #1

$$10_{(2)} * 230_{(2)} + 4_{(2)}$$

● = ?

Деньги

Integer и  
Long

ЧЗХ #1

$$10_{(2)} * 230_{(2)} + 4_{(2)}$$

$$\bullet = 0.1 * 2.3 + 0.04 = 27_{(2)}$$

# Деньги

Integer и  
Long

Как Надо?

```
@Embeddable
public class Amount implements Serializable {
    private int rate;
    @Transient
    private final int scale;

    public Amount() {
        scale = 6;
    }
    public Amount(int rate, int scale) {
        this.scale = scale;
        setRate(rate);
    }
    ...
}
```

# Деньги

Integer и  
Long

Ч3X #2

1.000000\*0.150000

• = (int) ?

• = (long) ?

# Деньги

Integer и  
Long

43X #2

1.000000\*0.150000

• = (int) -323855360

• = (long) 0.150000.000000

# Деньги

Integer и  
Long

## Итог

Лучше когда «**scale**» является частью значения

Лучше когда арифметика и сравнения просто работают

Лучше когда корректность гарантирована

Корректность почти всегда важнее скорости

Деньги

BigDecimal

Хорошо

Встроенный тип

Нет предыдущих проблем

Очень большой диапазон



Деньги

BigDecimal

Ч3X #1

1.divide(2)

●=?

Деньги

BigDecimal

ЧЗХ #1

```
1.divide(2)
```

●=0.5

Деньги

BigDecimal

ЧЗХ #2

`2.divide(3)`

●=?

Деньги

BigDecimal

ЧЗХ #2

```
2.divide(3)
```

- `=ArithmeticException`

Деньги

BigDecimal

ЧЗХ #2

```
2.divide(3, 3, ...)
```

•=0.666 или 0.667

# Деньги

## BigDecimal

### ЧЗХ #3

```
1.divide(10).multiply(10).equals(1)
```

- =?

# Деньги

## BigDecimal

### ЧЗХ #3

```
1.divide(10).multiply(10).equals(1)
```

- = false

# Деньги

## BigDecimal

### ЧЗХ #4

```
BD.valueOf(0.1f).equals(new BD(0.1f))
```

• =?



# Деньги

## BigDecimal

### ЧЗХ #4

```
BD.valueOf(0.1f).equals(new BD(0.1f))
```

- = false

```
BigDecimal i = ONE;

while (i.compareTo(TEN) < 0) {
    i.add(TEN).multiply(i)
    .divide(valueOf(3L), 0, ROUND_HALF_EVEN);
}

System.out.println(i);
```

Деньги

BigDecimal

Ч3X #5

41

ArithmeticException

Ничего

19

```
BigDecimal i = ONE;

while (i.compareTo(TEN) < 0) {
    i.add(TEN).multiply(i)
    .divide(valueOf(3L), 0, ROUND_HALF_EVEN);
}

System.out.println(i);
```

Деньги

BigDecimal

ЧЗХ #5

41

ArithmeticException

Ничего

19

```
BigDecimal i = ONE;

while (i.compareTo(TEN) < 0) {
    i.add(TEN).multiply(i)
    .divide(valueOf(3L), 0, ROUND_HALF_EVEN);
}

System.out.println(i);
```

Деньги

BigDecimal

Итог

Точность и значность известна

Арифметика и сравнения включены

Поддерживается в JDK, JDBC и т.д.

Неплохая производительность



# Идентификаторы



ID

Содержание

# Integer и Long

# UUID



ID

Integer и  
Long

Integer и Long – конечные типы

Иногда они переполняются

Они в два раза меньше, чем мы думаем

ID

Integer и  
Long

Пример

## PSY - GANGNAM STYLE (강남스타일) M/V



officialpsy ✓



Subscribe

7,593,929

2,143,453,872



Add to



Share



More



8,733,800



1,134,338

ID

Integer и  
Long

Пример

## PSY - GANGNAM STYLE (강남스타일) M/TYLE (강남스타일) M/V



officialpsy ✓



Subscribe

7,593,929

-2142871897



Add to



Share

... More

e



8,757,056



1,139,323

ID

Integer и  
Long

Нежданчик

«Некоторые» языки не умеют работать с 64-битными целыми

Кроме того, «некоторые» языки работают со специальными 32-битными целыми

ID

Integer и  
Long

Итог

Разница между DB и API идентификаторами

Если не на 99.9% уверен

- Используй целочисленные ключи в DB
- Используй строковые идентификаторы для API
- Не используй 32- битные типы

ID

UUID

Хорошо

Генерирует ID локально

Довольно мал: 128 бит (16 байт)

Очень маленькая вероятность коллизии

- 1 на 2.71 квинтиллионов ( $10^{18}$ )
- Вероятность эквивалентна встрече 180 мужчин подряд

ID

UUID

Ну такое

Не гарантированно **глобально** уникальны

**Могут** быть источником проблем с производительностью

Существует несколько версий с разной степени полезности

Странно, но RDBMS редко поддерживают UUID/GUID типы



ID

UUID

Чё внутри

time\_low

time\_mid

version

time\_hi

variant

clock\_seq

node

32

16

4

12

4

12

48

High long

Low long

ID

UUID

Чё внутри

random

random

version

random

variant

clock\_seq

random

32

16

4

12

4

12

48

High long

Low long

ID

UUID

Пример

```
$ uuidgen
```

```
0c8aa0f6-9f6f-4fad-9662-1b683f2f4a0d
```

```
$ uuidgen
```

```
1ee09695-3a04-4e7a-8bab-e67dabc4b5a2
```

```
$ uuidgen -t
```

```
3770f4d0-88b3-11e6-bba6-005056bb68cb
```

```
$ uuidgen -t
```

```
3b14dd54-88b3-11e6-8c53-005056bb68cb
```

ID

UUID

v4

Зависит от генератора энтропии

Виртуальные машины

Контейнеры



# ID

# Итог

Используйте внешнее строковое представление (API)

Внутреннее представление должно быть:

- DB счетчик (Long/BigInteger)
- UUID + DB счетчик (Long/BigInteger)
- UUID
- Twitter Snowflake (Long) – не развивается
- \*Flake (128 bit)

# Строки



Строки

Содержание

Кодировка строк в Java

JDBC драйвера и DB типы

# Строки

## Кодировка

Java использует UTF-16 для строк

Кодовая таблица UTF-16: 0x0000..0x10FFFF

Строки используют char[] (byte[] in JDK9)

Возможные значения char: 0x0000..0xFFFF



Строки

Кодировка

ЧЗХ #1

Как представить символы  
**0x100000..0x10FFFF**  
используя char?

# Строки

## Кодировка

### ЧЗХ #1

Определим «суррогатный» диапазон: **0xD800..0xDFFF** [0x800] [2048]

Поделим его пополам:

- «High»: 0xD800..0xDBFF [0x400] [1024]
- «Low»: 0xDC00..0xDFFF [0x400] [1024]

Используем пары (High;Low) для получения недостающих символов

...

PROFIT!!!

```
String x = new String(new char[]{  
    'z', 0xD801, 0xDC05, 'a', 'b', 'c'  
});  
System.out.println(x.length());  
System.out.println(x);  
System.out.println(x.substring(0, 2));  
System.out.println(x.substring(2));
```

Строки

Кодировка

ЧЗХ #2

6

z0abc

z?

?abc

Строки

Кодировка

Решение

```
Character.isLowSurrogate(...);  
Character.isHighSurrogate(...);
```

Строки

Кодировка

Итог

Хорошего решения нет

Надо об этом помнить

# Строки

JDBC vs DB

Отображение JDBC типов на DB

Некоторые примеры

BLOB или CLOB

Несовместимые кодировки

```
public enum JDBCType implements SQLType {  
    CHAR(Types.CHAR),  
    VARCHAR(Types.VARCHAR),  
    LONGVARCHAR(Types.LONGVARCHAR),  
    ...  
    BLOB(Types.BLOB),  
    CLOB(Types.CLOB),  
    ...  
    NCHAR(Types.NCHAR),  
    NVARCHAR(Types.NVARCHAR),  
    LONGNVARCHAR(Types.LONGNVARCHAR),  
    NCLOB(Types.NCLOB),
```



Строки

JDBC vs DB

BLOB

BLOB — это не текст

И никогда не будет

# Строки

## JDBC vs DB

## BLOB/CLOB

### Binary Large Object

- Массив байт

### Character Large Object

- Массив символов в «некоторой» кодировке

```
public enum JDBCType implements SQLType {  
    CHAR(Types.CHAR),  
    VARCHAR(Types.VARCHAR),  
    LONGVARCHAR(Types.LONGVARCHAR),  
    ...  
    CLOB(Types.CLOB),  
    ...  
    NCHAR(Types.NCHAR),  
    NVARCHAR(Types.NVARCHAR),  
    LONGNVARCHAR(Types.LONGNVARCHAR),  
    NCLOB(Types.NCLOB),  
}
```

# Строки

JDBC vs DB

CHAR и  
VARCHAR

| Тип     | Oracle | MySQL               | MS SQL           |
|---------|--------|---------------------|------------------|
| CHAR    | 2000 b | 255 char            | 8000 b           |
| VARCHAR | 4000 b | 255 char<br>65535 b | 8000 b<br>~ 2 Gb |

# Строки

## JDBC vs DB

## Чё внутри?

```
setStringInternal(int var1,String var2) throws SQLException {  
    ...  
    int var6 = var2 != null?var2.length():0;  
    ...  
    if(var6 <= this.maxVcsCharsSql) {  
        this.basicBindString(var1, var2);  
    } else if(var6 <= this.maxStreamNCharsSql) {  
        this.setStringForClobCritical(var1, var2);  
    } else {  
        this.setStringForClobCritical(var1, var2);  
    }  
}
```

# Строки

## JDBC vs DB

## CHAR/NCHAR

### CHAR, VARCHAR, CLOB...

- Использует кодировку DB

### NCHAR, NVARCHAR, NCLOB...

- Использует указанную (национальную) кодировку

# Строки

## JDBC vs DB

### Совместимость

Иногда у вас нет проблем с кодировками

Иногда «умный» драйвер все портит

Иногда кодировки несовместимы

Используйте Unicode семейство в DB

# Строки

## JDBC vs DB

## Итог

Используй Unicode кодировку DB

Если уже поздно пользуйся N\* DB типами

Не храни текст как BLOB

Знай специфику драйвера и DB

Символ — это не байт, и часто даже не два



Дата и Время



# Дата

## Содержание

Базис: Instant и Date

DST и високосная магия

Временные зоны

# Дата

# Базис

# Инфо

## Instant

- Представляет некое временное событие отсчитанное от точки отсчета в равномерных интервалах

## DateTime

- Кортеж, неравномерных интервалов приятных для человеческого восприятия, чаще всего привязанных к циклам солнца и/или луны. Год-месяц-день и т.д.

# Дата

# Базис

# И Чё?

## Instant

- это «абсолютное» земное время

## DateTime

- это представление времени, конвертируемое в Instant, но не всегда однозначно.

# Дата

# Базис

# Итог

## Instant

- используй если важна причинность, и если даже [милли-]секунда важна

## DateTime

- используй во всех остальных случаях

Дата

DST и  
Магия

Пропущенные и лишние часы

«Високосные» секунды

# Дата

# DST и Магия

# Вычисления

24 часа в дне

60 минут в часе

60 секунд в минуте

Итого:  $24 * 60 * 60 * 1000$  мс/день

# Дата

# DST и Магия

# ЧЗХ #1

26.03.2017-27.03.2017 EET

- 23 часа (нет 26.03.2017 03:00-04:00)

29.10.2017-30.10.2017 EET

- 25 часа (два 29.10.2017 03:00-04:00)



# Дата

## DST и Магия

# ЧЗХ #2

31.12.2016-01.01.2017 MSK

- 24 часа

01.01.2017-02.01.2017 MSK

- 24 часа и 1 секунда

Дата

DST и  
Магия

Високосные  
секунды

Было: 31.12.2016 23:59:60 (UTC)

Пока нет точного графика

Виновата Земля, Луна, Солнце и т.д.

Разработчики тоже виноваты

# Дата

# Зоны

## Временные зоны

- позволяют работать с локальным временем

## Правила конвертации

- позволяют преобразовывать в Instant
- позволяют преобразовывать в другие зоны

Дата

Зоны

Запись

```
PreparedStatement.setTimestamp(  
    1,  
    new Timestamp(...),  
    Calendar.getInstance(  
        TimeZone.getTimeZone("UTC")  
    )  
);
```

# Дата

# Зоны

# Чтение

```
Timestamp ts = ResultSet.getTimestamp(  
    1,  
    Calendar.getInstance(  
        TimeZone.getTimeZone("...")  
    )  
);
```

# Дата

# Зоны

# ЧЗХ #3

Сохранили 2017-03-26 12:00+00:00

- UTC =?
- Москва =?
- Новосибирск =?
- \*BD\* =?

# Дата

# Зоны

# ЧЗХ #3

Сохранили 2017-03-26 12:00+00:00

- UTC = 2017-03-26 15:00+03:00 [ 0]
- Москва = 2017-03-26 12:00+03:00 [-3]
- Новосибирск = 2017-03-26 08:00+03:00 [-7]
- \*BD\* = 2017-03-26 12:00:00.0

# Дата

# Зоны

# ЧЗХ #3

Retrieves the value of the designated column in the current row of this **ResultSet** object as a **java.sql.Timestamp** object in the Java programming language. This method uses the given calendar to construct an appropriate millisecond value for the timestamp **if the underlying database does not store timezone information.**

- **columnIndex** - the first column is 1, the second is 2, ...
- **cal** - the **java.util.Calendar** object to use in constructing the timestamp



Дата

Зоны

А если  
надо?

TIMESTAMP

TIMESTAMP WITH TIME ZONE

DATETIMEOFFSET

# Дата

# Зоны

# ЧЗХ #4

Сохранили 2017-03-26 12:00+00:00

- MS SQL **v4** =?
- Oracle **v10** =?
- Oracle **v12** =?

# Дата

# Зоны

# ЧЗХ #4

Сохранили 2017-03-26 12:00+00:00

- MS SQL v4 = 2017-03-26 12:00+00:00
- Oracle v10 = 2017-03-26 12:00+00:00
- Oracle v12 = 2017-03-26 12:00+03:00

# Дата

# Зоны

oracle.sql.TIMESTAMP

```
public static byte[] toBytes(Timestamp var0, Calendar var1) {
    if (var0 == null) { return null; }
    int var2 = var0.getNanos();
    byte[] var3 = var2 == 0 ? new byte[7] : new byte[11];
    Calendar var4 = var1 == null ? Calendar.getInstance() : Calendar.getInstance(var1.getTimeZone());

    var4.setTime(var0);
    int var5 = getOracleYear(var4);
    var3[0] = (byte) (var5 / 100 + 100);
    var3[1] = (byte) (var5 % 100 + 100);
    var3[2] = (byte) (var4.get(2) + 1); // Calendar.MONTH
    var3[3] = (byte) var4.get(5); // Calendar.DATE (DAY_OF_MONTH)
    var3[4] = (byte) (var4.get(11) + 1); // Calendar.HOUR_OF_DAY
    var3[5] = (byte) (var4.get(12) + 1); // Calendar.MINUTE
    var3[6] = (byte) (var4.get(13) + 1); // Calendar.SECOND
    if (var2 != 0) {
        var3[7] = (byte) (var2 >> 24);
        var3[8] = (byte) (var2 >> 16 & 255);
        var3[9] = (byte) (var2 >> 8 & 255);
        var3[10] = (byte) (var2 & 255);
    }
    return var3;
}
```

# Дата

# Зоны

# ЧЗХ #4

Сохранили 2017-03-26 12:00+00:00

- MS SQL v4 = 2017-03-26 12:00+00:00
- Oracle v10 = 2017-03-26 12:00+00:00
- Oracle v12 = 2017-03-26 12:00+00:00

# Дата

# Зоны

# Что делать?

Использовать только UTC

Использовать “странный” API

- `void setObject(int, Object, int, int)`

Использовать `java.time` API или `Calendar`

- `ZonedDateTime` and etc

Не верить имплементаторам JDBC

Дата

Зоны

Вопросы

JavaScript клиент с непонятной зоной

Java сервер с +03:00 зоной

Как передавать даты?

Дата

Зоны

Ответы

Дата не определена в спецификации JSON

Long – это плохая идея для JavaScript

String как ISO 8601 меньшее зло



# Дата

# Зоны

# Итог

Используй единую временную зону

Тестируй драйвер на ожидаемое поведение

- Например: <https://github.com/victor-cr/jdbc-test>

\* Не используй `setTimestamp(...)` для `Instant`

Публикуй дату как строку в JSON API

# Дата

# Итог

Используй UTC как можно чаще

Помни про разницу даты и Instant

Работай с датами по закону Мерфи

$24 * 60 * 60 * 1000$  – это небезопасное упрощение

Используй специальные библиотеки для работы с датами

Спасибо

