



**ВЯЧЕСЛАВ
ТРЕТЬЯК**

КАК ЛОКАЛИЗОВАТЬ ПРОЕКТ И НЕ СОЙТИ С УМА

- **2006** — начало
- **2009** — локализованное приложение под Android
- **2014** — локализовал веб-приложение ≈ 500 файлов ($\approx 100\,000$ строк)
- Думал, что всё знаю и умею про локализацию
- **2017** — ...



The Проект

- ≈ 3500 файлов
- ≈ 500 000 строк
- PHP, JavaScript, CoffeeScript, Twig, Pug, Html
- ZF2, Angular (1.x)
- Очень много нелокализованного текста



Всё как у всех

"Привет "


```
+ (user.isGuest() ? "Гость" : user.getName())  
+ "! , онлайн "  
+ onlineCount  
+ " "  
+ pluralize(onlineCount,  
    "пользователь",  
    "пользователя",  
    "пользователей")
```



1–2–3

1. Моё видение хорошей интернационализации
(*best practices*)
2. Что всё-таки делать, если уже есть нелокализабельный проект (*наш опыт*)
3. Резюме

МОЁ ВИДЕНИЕ ХОРОШЕЙ ИНТЕРНАЦИОНАЛИЗАЦИИ

A man in a blue plaid shirt is running away from a giant hamster in a forest. The hamster is orange and white, and it's looking directly at the man. The man has a concerned expression. The background is a lush green forest with trees and sunlight filtering through the leaves.

Беги, Лес, беги! Лес, которым управляют!

Локализация vs Интернационализация

- Локализация — **перевод** проекта на другой язык
- Интернационализация — **написание кода**, который позволяет легко делать локализацию

Наивный подход

```
hi: "Привет"  
guest: "Гость"  
online: "онлайн"  
users: one="пользователь", two="пользователя",  
        many="пользователей"
```

```
t("hi")  
  + " " + (user.isGuest()  
           ? t("guest") : user.getName())  
  + "!," + t("online")  
  + " " + onlineCount + p("users", online)
```

Не работает

- Одно и то же слово в разном контексте переводится по-разному:
 - Класс — как класс в школе (grade)
 - Класс — как поощрение пользователя (cool)
 - Класс — как css-класс (class)
- Может потребоваться поменять части предложения местами:
 - “Привет, Саша!”
 - “Alex, welcome to the system!”

Подстановка строк

```
hello_user: "Привет {username}!, онлайн {onlineCount}  
{onlineStr}"
```

```
guest: "Гость"
```

```
user_plural: one="пользователь", two="пользователя",  
             many="пользователей"
```

```
t("hello_user", {  
    username: user.isGuest()  
        ? t("guest") : user.getName(),  
    onlineCount: onlineCount,  
    onlineStr: p("user_plural", onlineCount)  
})
```

Не совсем работает

- Не надо использовать повторно строки для разных экранов
- В разном контексте одинаковое по смыслу слово может переводиться по-разному

(Yes: Да / Согласен, Удалить: Delete / Remove)

- На разных экранах одна и та же фраза на одном из языков может не влезть

Именуем ключи правильно

dashboard_welcome: "Привет {username}!, онлайн {onlineCount} {onlineStr}"

dashboard_guest: "Гость"

dashboard_user_plural: one="пользователь",
two="пользователя",
many="пользователей"

Почти хорошо, но...

- “На сайте было 2 пользователя в течение последних 15 дней” — неудобно разделять **plurals** с самими строками
- “Возьмите карточку **{color}** цвета со стола”, где color это “красного”, “синего” или “желтого” — одно сообщение разделяется на несколько, переводчику не удобно
- **Plurals** + подстановки + **select**–подстановки в одном предложении — всё очень грустно 🙄

ICU MessageFormat

```
dashboard_welcome: "Привет {hasUsername, select, yes  
{{username}} other {Гость}}! онлайн {onlineCount,  
plural, one {# пользователь} two {# пользователей}  
many {# пользователей} other {# пользователей}}"
```

```
t("dashboard_welcome", {  
  hasUsername: !user.isGuest(),  
  username: user.getName(),  
  onlineCount: onlineCount  
})
```

CSS-классы — прокидываем

Нет:

```
'Hello <span class="cabinet-payments-multi-discount-  
popup__red-text">{username}</span>! '
```

Да:

```
'Hello <span class="{cls}">{username}</span>! '
```

Ссылки — по возможности прокидываем

"Нажмите `{link}` здесь `{_link}` для входа в систему."

Профит — может быть реальная ссылка,
а может и **span** с **onclick**

Работает, но...

- Сообщение удалили из кода, но не из ресурсов
- Удалили сообщение из ресурсов, но не из кода
- Добавили ключ сообщения в код, но в ресурсы — забыли
- В коде и в ресурсах сообщение есть, но в ключе описки
- Html–сообщение вставлено как текст — не “**привет**” болдом, а “привет”
- Фигак–фигак и в продакшен — в код захардкодили строку (vs добавили через ресурсы)

Статический анализ

- В коде нет захардкоженных строк
- Нет дубликатов ключей
- **Ключ используется в коде**
- В коде нет ключей, которые отсутствуют в ресурсах
- Строки правильно подставляются (html как html, текст как текст)
- Каждый конкретный ключ есть во всех языках

И ещё

- В большинстве систем локализации для каждого языка есть файл **key** → **value**
- Добавляешь строку в один язык — надо не забыть добавить во все остальные
- Идеальный проект — после программистов должны работать переводчики
- У кого есть этот идеальный проект? 😊

И ещё

```
'Application_Promo_EmailPlaceholder' => [  
    'ru' => 'Введите email',  
    'en' => 'Please, enter email',  
],
```

- Программистам — удобней
- Для всего остального есть скрипты

ЧТО ВСЁ–ТАКИ ДЕЛАТЬ, ЕСЛИ УЖЕ ЕСТЬ НЕЛОКАЛИЗАБЕЛЬНЫЙ ПРОЕКТ



Наивный подход

Открывать по очереди каждый файл, и выносить строки в ресурсы

- + Достаточно раздеваться и работать
- Over 100500 часов

Если есть много денег

Нанять аутсорсеров

+ Пусть аутсорсеры вкалывают, а мы будем отдыхать на Бали 😊

– Нет гарантии нормального качества, надо тратить деньги

Реалистичный подход

Попытаться по максимуму автоматизировать процесс

- + Значительно уменьшается доля ручного труда
- Надо писать тулы, и всё равно, некая доля ручного труда остаётся

Почему не xgettext?

- Не умеет Pug и Html (а также CoffeeScript)
- Не понимает какие сообщеньки — это сообщеньки, а какие — служебные строки

Процесс эволюции

- Проект на русском — любая строка, в которой есть русские символы подлежит локализации
- Скрипт регэкспами проходит по файлам, и пишет в консоль где и что не переведено
- Руками это всё заносится в ресурсы
- **Проблемы** — не всегда правильно выдирает сообщеньки (ну... regexp)

- Скрипт различает типы файлов, и для PHP парсит через встроенный `token_get_all()`
- **Профит** — для PHP сообщеньки выдираются идеально (кроме конкатенации нескольких строк)
- **Проблемы** — лень руками вносить сообщения, тем более что часть ключа (префикс **Модуль_Компонент_**) поддаётся автогенерации

- Автогенерация части ключа и режим автодополнения ресурсов выдираемыми сообщениями
- **Профит** — запустил, получил почти готовые локализационные файлы, остаётся только добавить последнюю часть ключа
- **Проблемы** — менять в исходниках текст на ключи надо руками, кажется, что это можно автоматизировать

- Автозамена на регэкспах (для PHP)
- **Профит** — запустил генератор, подправил ключи, запустил автозамену, готово
- **Проблемы** — надоело дополнять ключи


```
...->add((new Element\Text('title'))  
->setLabel('Название')) // ключ будет Title
```

```
$field = new Element\Text('address');  
$field->setLabel('Адрес'); // ключ будет Address
```

- Анализатор контекста (на основе конечных автоматов), в 70% угадывает название ключа
- **Профит** — для PHP-файлов интернационализация вообще сказка
- **Проблемы** — в rig-файлах надо пропускать комментарии, а на регэкспах это не очень хорошо делать; так же, когда есть много текста разбавленного html-ом, то регэкспы отрабатывают плохо

- Подключили rid–парсер
- **Профит** — генерация — сказка
- **Проблемы** — RNP–файлы закончились, а для других типов нет автогеренатора ключа и автопатчера

- На самом деле нет
- Можно подключить парсеры для остальных типов файлов, а для автогенерации ключей можно подключить Google Translate API
- Но это занимает время и стоит денег
- Лучше включить на пару недель режим биоробота, и всё допилить руками



Дальнейшая эволюция

- Переводчикам платят за знаки, а в проекте есть места, где строки можно объединить (например, кнопки “Сохранить” в админке)
- Скрипт для поиска и замены дубликатов
- **Профит** — избавляемся от дубликатов (**только от тех, от которых стоит избавиться**), экономим деньги на перевод (до дедупликации было ≈ 7000 сообщений, после — ≈ 5000)

Что 100% можно было бы сделать лучше

- Автозамена для PHP не на основе регэкспов, а через parse / re-print — меньше косяков
- Парсеры для Twig, JS и HTML — точное выдирание, автозамена, возможность автогенерации ключей
- Translation memory для автогенератора ключей
- Ещё более умная выдиралка, которая бы понимала конкатенацию
- Поправить CSS, чтоб в сообщениях не использовать классы, а только простые тэги

Что, вероятно, можно было бы сделать лучше

- Пусть ключом будет часть сообщения латиницей —
“Введите имя” → **“VvediteImja”**
- Некрасиво, но можно генерировать ключи полностью автоматически
- Или всё-таки раскошелиться на Google Translate API

РЕЗЮМЕ

- Проект с нуля — сразу интернационализацию!
 - Даже если кажется, что она никогда в жизни не понадобится
- Проект достался в наследство? Сначала определите объем работ
 - Это просто: `find / cat / wc -l`, подсчитайте количество файлов и количество строк

Проект достался в наследство?

- Небольшой — можно обойтись тулой, которая просто показывает в каких файлах есть нелокализованные строки
- Среднего размера — тула для поиска нелокализованных строк + пара джунов
- Большой — придётся автоматизировать процесс

Самое важное — определение локализуемости строки

- Если проект с нелатинским языком, то всё просто
- Если латиница, то считать локализуемыми строки, в которых есть пробелы и знаки пунктуации
- Может быть, определять из контекста

Автоматизация

- Узнайте какие типы файлов есть в проекте, сколько их, нужна ли им автоматическая обработка
- Продумайте механизм генерации ключей:
 - Латинизация сообщения
 - Перевод через Google Translate API
 - Полуручной режим

Автоматизация

- Парсилка под конкретный тип файла **vs** простой код на regex-ах
- **Парсилка** — точное выдирание строк, автозамена строк на ключи, можно анализировать контекст (для “угадывания” ключа, типа сообщения или ещё чего-нибудь)
- **Регэкспы** — скрипт в десяток строчек и подходит для любых типов файлов

Автоматизация

- Запаситесь терпением — как бы вы не автоматизировали, всё равно будет доля нудного и монотонного ручного труда
- И не забудьте написать скрипты для статического анализа!

А теперь надо локализовать контент... 😊

Полезные ссылки

- Пара слов об интернационализации приложений
<https://habrahabr.ru/post/165705/>
- **Android string.xml** — несколько вещей, которые **СТОИТ ПОМНИТЬ**
<https://habrahabr.ru/post/307798/>
- **Formatting messages**
<http://userguide.icu-project.org/formatparse/messages>



<http://eightsines.com/me.html#talks>