Парсер «Докувики»

В этом документе излагаются детали функционирования парсера «Докувики», которые могут понадобиться разработчикам для модификации поведения парсера или получения контроля над выходным потоком документа.

Обзор

Парсер разбивает процесс трансформации исходного документа «Докувики» в финальный выходной документ (обычно XHTML) на дискретные стадии. Каждая стадия представлена одним или несколькими PHP-классами.

В общем рассмотрении этими элементами являются;

1. Лексический анализатор[1]: сканирует[2] исходный документ «Докувики» и выводит последовательность «вхождений»[3], соответствующих синтаксической структуре документа.
2. Обработчик[4]: получает вхождения от анализатора и преобразует их в последовательность «инструкций»[5]. Он описывает, как должет быть сформирован выходной документ, от начала до конца.
3. Собственно парсер[6]: «связывает» анализатор с обработчиком, предоставляя синтаксические правила «Докувики», а также точку доступа к системе (метод `Parser::parse()`)
4. Преобразователь[7]: принимает инструкции от обработчика и «отрисовывает» готовый к выводу документ (например, в виде XHTML).

Механизм, связывающий обработчик с преобразователем, **отсутствует** — для этого требуется программирование посредством специфического прецедента.

Схематическая диаграмма связей между компонентами;

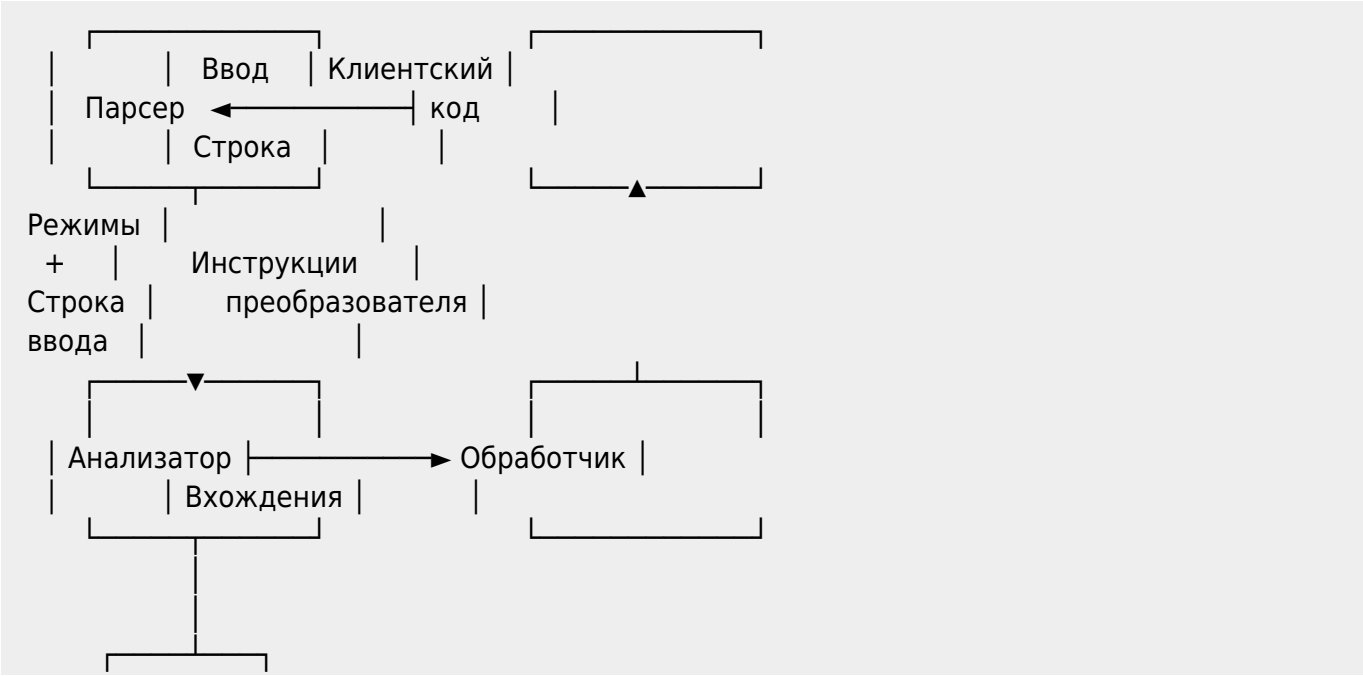

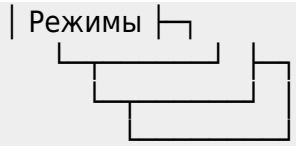

«Клиентский код» (код, использующий парсер) вызывает парсер, передавая ему входную строку. В ответ ему возвращается перечень «инструкций» преобразователя, построенных обработчиком. Они могут быть использованы неким объектом, реализующим преобразователь.

Замечание: критическим моментом здесь является намерение позволить преобразователю быть настолько «тупым», насколько это возможно. От него *не* требуется осуществлять дальнейшую интерпретацию или модификацию переданных инструкций, но полностью сконцентрироваться на формировании выходных данных (например, XHTML) — в особенности, преобразователю не следует отслеживать состояния. Соблюдение этого принципа и, кроме того, составление преобразователя достаточно простым для реализации (сосредоточенной исключительно на том, что следует выводить), также сделает возможным преобразователю быть взаимозаменяемым (например, вывод PDF в качестве альтернативы XHTML). В то же самое время, выходные инструкции обработчика *направляются* для преобразования в XHTML и не всегда могут быть пригодынми для всех выходных форматов.

Лексический анализатор

Определяется в `inc/parser/lexer.php`.

В самом общем смысле, он реализует инструмент для управления комплексными регулярными выражениями, где важным является состояние. Анализатор появился из простого теста, но содержит три модификации (читай: хака ;-)):

- поддержка шаблонов с просмотром вперёд и назад[8];
- поддержка изменения модификаторов шаблона в пределах шаблона;
- уведомление обработчика об индексе стартового байта в исходном тексте, когда найдено вхождение.

Анализатор как целое состоит из трёх основных классов;

- `Doku_LexerParallelRegex`: позволяет регулярному выражению состоять из множества отдельных шаблонов, каждый шаблон связан с идентифицирующей «меткой» , класс объединяет их в единое регулярное выражение, используя подшаблоны. *Используя анализатор, вам не нужно беспокоится об этом классе*.
- `Doku_LexerStateStack`: реализует простой конечный автомат (state mashine[9]), так что анализ может быть «осведомлённым о контексте». *Используя анализатор, вам не нужно беспокоится об этом классе*.
- `Doku_Lexer`: реализует точку доступа для клиентского кода, использующего анализатор. Управляет множеством объектов ParallelRegex, используя StateStack (стэк состояний) для применения корректных объектов ParallelRegex, в зависимости от «контекста». При нахождении «интересного текста» он вызывает функции реализуемого пользователем объекта (обработчика).

Необходимость в состояниях

Синтаксис вики, используемый в «Докувики», содержит разметку, «внутри» которой применяются только определённые синтаксические правила. Самый очевидный пример — тэг <code/> , внутри которого синтаксис вики не будет распознаваться анализатором. Для других синтаксических конструкций, таких как списки или таблицы, следует позволять использовать *некоторую* разметку, но не всю, например, в списка можно использовать ссылки, но не таблицы.

Анализатор обеспечивает «осведомлённость о состояниях», позволяющую применять корректные синтаксические правила в зависимости от текущий позиции (контекста) в сканируемом тексте. Если он видит открывающий тэг <code>, он переключается в другое состояние, в пределах которого другие синтаксические правила не применяются (т. е. что-либо, что выглядит как синтаксис вики должно восприниматься как «простой» текст), до тех пор, пока не найдёт закрывающий тэг </code>.

Режимы анализатора

Термин *режим* обозначает особенное состояние лексического анализа [10)]. Код, использующий анализатор, регистрирует один или более шаблон регулярного выражения с особенным наименованием режима. Затем анализатор, сравнивая эти паттерны со сканируемым текстом, вызывает функции обработчика с тем же самым наименованием режима (если метод `mapHandler` не был использован для создания псевдонимов — см. ниже).

API анализатора

Краткое введение в лексический анализатор можно найти в Simple Test Lexer Notes. Здесь предлагается более подробное описание.

Ключевыми методами анализатора являются:

Конструктор

Принимает ссылку на обработчик, наименование начального режима и (необязательно) логический флаг чувствительности сравнения шаблона к регистру.

Пример:

```
$Handler = & new MyHandler();
$Lexer = & new Doku_Lexer($Handler, 'base', TRUE);
```

Здесь указан начальный режим 'base'.

addEntryPattern / addExitPattern

Используется, чтобы зарегистрировать шаблон при входе и выходе из особенного режима обработки. Например:

```
// arg0: регулярное выражение для сравнения — заметьте, что нет необходимости добавлять ограничители шаблона
// arg1: наименование режима, где этот шаблон может быть использован
// arg2: наимерование режима, в который следует войти
$Lexer->addEntryPattern('<file>','base','file');

// arg0: регулярное выражение для сравнения
// arg1: наименование режима, из которого следует выйти
$Lexer->addExitPattern('</file>','file');
```

Код, приведённый выше, позволяет тэгу <file/> быть использованный при входе из базового в новый режим (`file`). Если в дальнейшем следует применить режимы, пока анализатор находится в режиме `file`, они должны быть зарегистрированы с режимом `file`.

Замечание: в паттернах не требуется использование ограничителей.

addPattern

Используется, чтобы реагировать на дополнительные «вхождения» внутри существующего режима (без переходов). Он принимает паттерн и наименование режима, внутри которого должен использоваться.

Это наиболее наглядно видно из разбора парсером синтаксиса списков. Синтаксис списков выглядит в «Докувики» следующим образом;

```
До списка
  * Ненумерованный элемент списка
  * Ненумерованный элемент списка
  * Ненумерованный элемент списка
После списка
```

Использование `addPattern` делает возможным сравнивать полный список, одновременно корректно захватывая каждый элемент списка;

```
// Сравнить начальный элемент списка и изменить режим
$Lexer->addEntryPattern('\n {2,}[\*]','base','list');

// Сравнить новый элемент списка, но остаться в режиме ''list''
$Lexer->addPattern('\n {2,}[\*]','list');

// Если строка не совпадает с указанным выше правилом addPattern, выйти из режима
$Lexer->addExitPattern('\n','list');
```

addSpecialPattern

Используется для входа в новый режим только для сравнения, затем возвращается в «родительский» режим. Принимает в качестве аргументов паттерн, наименование режима, внутри которого его (паттерн) можно применять, и наименование «временного режима«, в который нужно войти для сравнения. Обычно может быть использовано, если вы хотите заменить разметку вики на что-нибудь другое. Например, сравнить смайл вроде :-);

```
$Lexer->addSpecialPattern(':-)','base','smiley');
```

mapHandler

Позволяет особому режиму быть прикреплённым к методу с разными наименованиями в обработчике. Это может быть полезным, когда различные синтаксические конструкции следует обрабатывать таким образом, как конструкции «Докувики», отключающие другие синтаксические конструкции в особенном текстовом блоке:

```
$Lexer->addEntryPattern('<nowiki>','base','unformatted');
$Lexer->addEntryPattern('%%','base','unformattedalt');
$Lexer->addExitPattern('</nowiki>','unformatted');
$Lexer->addExitPattern('%%','unformattedalt');

// Оба вида синтаксических конструкций должны обрабатываться одинаковым образом...
$Lexer->mapHandler('unformattedalt','unformatted');
```

Подшаблоны не допускаются

Поскольку анализатор сам использует **подшаблоны** (внутри класса `ParallelRegex`), код, *использующий* анализатор, этого не может. Иногда это может пригодиться, но, по общему правилу, метод `addPattern` может быть применён для решения проблем, когда обычно применяются подшаблоны. Его преимуществом является упрощение регулярных выражений, таким образом, управления ими.

Замечание: если вы используете в шаблоне круглые скобки, они будут *автоматически* пропущены анализатором.

Синтаксические ошибки и состояния

Для предотвращение «плохо форматируемой» (особенно при пропуске закрывающих тэгов) разметки, приводящей к тому, что анализатор входит в состояние (режим), который он никогда не покинет, может быть полезным использование паттерна просмотра вперёд для проверки наличия закрывающей разметки[11]. Например:

```
// Использование просмотра вперёд во входном шаблоне...
$Lexer->addEntryPattern('<file>(?=.*</file>)','base','file');
$Lexer->addExitPattern('</file>','file');
```

Входной шаблон проверяет, может ли он найти закрывающий тэг `</file>`, до входа в состояние.

Обработчик

Определяется в `inc/parser/handler.php`.

Обработчик — это класс, реализующий методы, которые вызываются лексическим анализатором, когда тот обнаруживает вхождения. Затем он «тонко преобразует» вхождения в последовательность инструкций, готовых для передачи преобразователю.

Обработчик как целое состоит из следующих классов:

- `Doku_Handler`: все вызовы из анализатора адресованы этому классу. Для каждого режима, зарегистрированного анализатором, будет соответствующий ему метод в обработчике.
- `Doku_Handler_CallWriter`: реализует «прокладку» между массивом инструкций (массив `Doku_Handler::$calls`) и методами обработчика, *записывающими* эти инструкции. Пока идёт лексический анализ, он будет временно перемещён другими объектами, вроде `Doku_Handler_List`.
- `Doku_Handler_List`: отвечает за трансформацию перечня вхождений в инструкции, пока идёт лексический разбор.
- `Doku_Handler_Preformatted`: отвечает за трансформацию предварительно отформатированных вхождений (врезки в «Докувики») в инструкции, пока идёт лексический разбор.
- `Doku_Handler_Quote`: отвечает за трансформацию вхождений цитат (текста, начинающего с одной или более «>») в инструкции, пока идёт лексический разбор.
- `Doku_Handler_Table`: отвечает за трансформацию вхождений таблиц в инструкции, пока идёт лексический разбор.
- `Doku_Handler_Section`: отвечает за вставку инстукций секций, основываясь на позиции инструкций заголовков, только когда лексический анализ завершён — повторяется однократно.
- `Doku_Handler_Block`: отвечает за вставку инструкций 'p_open' и 'p_close', будучи осведомлённым об инструкциях 'block level' instructions, только когда лексический анализ завершён (т. е. он повторяется однократно посредством, выдавая полный перечень инструкций и вставляет дополнитльеный инструкции).
- `Doku_Handler_Toc`: отвечает за добавление инструкций таблицы содержания в начало последовательности, основываясь на инструкциях заголовка, только когда лексический анализ завершён (т. е. он повторяется однократно посредством, выдавая полный перечень инструкций и вставляет дополнитльеный инструкции).

Методы вхождений обработчика

Обработчик должен реализовывать методы, соответствующие режимам, зарегистрированным анализатором (подразумевается метод `mapHandler()` анализатора — см. выше).

Например, если вы зарегистировали в анализаторе режим `file` наподобие:

```
$Lexer->addEntryPattern('<file>(?=.*</file>)','base','file');
$Lexer->addExitPattern('</file>','file');
```

Обработчику требуется метод вроде:

```
class Doku_Handler {

    /**
  * @строковый параметр  match  содержит текст, который был обнаружен
  * @целочисленный параметр  state  -  тип совпадения (см. ниже)
  * @целочисленный параметр  pos  -  индекс байта, где было найдено совпадение
    */
    function file($match, $state, $pos) {
        return TRUE;
    }
}
```

Замечание: метод обработчика *обязан* вернуть «TRUE» или анализатор будет немедленно остановлен. Подобное поведение может быть полезным, когда встречаются другие проблемы обработки, но в парсере «Докувики» все методы обработчика *всегда* возвращают «TRUE».

Аргументы, реализумые методом обработчика;

- `$match`: текст, который был обнаружен;
- `$state`: содержит константу, которая описывает как именно было найдено совпадение:
  1. `DOKU_LEXER_ENTER`: найден входной паттерн (см. Lexer::addEntryPattern);
  2. `DOKU_LEXER_MATCHED`: найден паттерн (см. Lexer::addPattern);
  3. `DOKU_LEXER_UNMATCHED`: внутри режима не было совпадений;
  4. `DOKU_LEXER_EXIT`: найден выходной паттерн (см. Lexer::addExitPattern);
  5. `DOKU_LEXER_SPECIAL`: найден специальный паттерн (см. Lexer::addSpecialPattern);
- `$pos`: это индекс байта (длина строки от начала), где было найдено *начало* вхождения. `$pos + strlen($match)` даёт индекс байта конца совпадения.

В качестве более сложного примера, для поиска списков в парсере определено следующее;

```
    function connectTo($mode) {
        $this->Lexer->addEntryPattern('\n {2,}[\-\*]',$mode,'listblock');
        $this->Lexer->addEntryPattern('\n\t{1,}[\-\*]',$mode,'listblock');

        $this->Lexer->addPattern('\n {2,}[\-\*]','listblock');
        $this->Lexer->addPattern('\n\t{1,}[\-\*]','listblock');

    }

    function postConnect() {
        $this->Lexer->addExitPattern('\n','listblock');
    }
```

Метод `listblock` в обработчике (вызов просто `list` приводит к ошибке обработчика PHP, поскольку `list` зарезервировано в PHP) выглядит как:

```
    function listblock($match, $state, $pos) {

        switch ( $state ) {

            // Начало списка...
```

```
            case DOKU_LEXER_ENTER:
                // Создать List rewrite, пропуская текущий CallWriter
                $ReWriter = & new Doku_Handler_List($this->CallWriter);

                // Заменить текущий CallWriter на List rewriter
                // все поступающие вхождения (даже, если они не являются вхождениями
list)
                // теперь направляются в list
                $this->CallWriter = & $ReWriter;

                $this->__addCall('list_open', array($match), $pos);
            break;

            // Для конца списка
            case DOKU_LEXER_EXIT:
                $this->__addCall('list_close', array(), $pos);

                // Дать указание List rewriter об очистке
                $this->CallWriter->process();

                // Восстановить прежний CallWriter
                $ReWriter = & $this->CallWriter;
                $this->CallWriter = & $ReWriter->CallWriter;

            break;

            case DOKU_LEXER_MATCHED:
                $this->__addCall('list_item', array($match), $pos);
            break;

            case DOKU_LEXER_UNMATCHED:
                $this->__addCall('cdata', array($match), $pos);
            break;
        }
        return TRUE;
    }
```

Конвертирование вхождений

«Тонкая обработка» задействует вставку символа дроби «/», переименование или удаление вхождений, переданных анализатором.

Например, список вроде:

```
This is not a list
  * This is the opening list item
  * This is the second list item
  * This is the last list item
This is also not a list
```

в результате превратиться в последовательность вхождений вроде;

1. base: «This is not a list", DOKU_LEXER_UNMATCHED
2. listblock: «\n *", DOKU_LEXER_ENTER
3. listblock: « This is the opening list item", DOKU_LEXER_UNMATCHED
4. listblock: «\n *", DOKU_LEXER_MATCHED
5. listblock: « This is the second list item", DOKU_LEXER_UNMATCHED
6. listblock: «\n *", DOKU_LEXER_MATCHED
7. listblock: « This is the last list item", DOKU_LEXER_UNMATCHED
8. listblock: «\n", DOKU_LEXER_EXIT
9. base: «This is also not a list", DOKU_LEXER_UNMATCHED

Но чтобы быть использованными преобразователем, это может быть конвертировано в следующие инструкции:

1. p_open:
2. cdata: «This is not a list"
3. p_close:
4. listu_open:
5. listitem_open:
6. cdata: « This is the opening list item"
7. listitem_close:
8. listitem_open:
9. cdata: « This is the second list item"
10. listitem_close:
11. listitem_open:
12. cdata: « This is the last list item"
13. listitem_close:
14. list_close:
15. p_open:
16. cdata: «This is also not a list"
17. p_close:

В случае со списками, это требует помощи класса `Doku_Handler_List`, который принимает вхождения, заменяя их на корректные инструкции для Преобразователя.

Парсер

Парсер играет роль переднего рубежа для внешнего кода и устанавливает для лексического анализатора паттерны и режимы, описывающие синтаксис «Докувики».

Использование парсера в общем случае выглядит следущим образом:

```
// Создать парсер
$Parser = & new Doku_Parser();

// Создать обработчик и поместить в парсер
$Parser->Handler = & new Doku_Handler();

// Добавить требуемые синтаксические режимы в парсер
```

```
$Parser->addMode('footnote',new Doku_Parser_Mode_Footnote());
$Parser->addMode('hr',new Doku_Parser_Mode_HR());
$Parser->addMode('unformatted',new Doku_Parser_Mode_Unformatted());
# etc.

$doc = file_get_contents('wikipage.txt.');
$instructions = $Parser->parse($doc);
```

Более подробные примеры приведены ниже.

В целом, парсер также содержит классы, предсталяющие по отдельности каждый из доступных режимов, базовым классом для всех них является Doku_Parser_Mode. Поведение этих режимов лучше всего понять, посмотрев на примеры добавления синтаксиса ниже в этом документе.

Причиной для представления режимов как классов является желание избежать повторяющихся вызовов методов анализатора. Без них было бы необходимо упорно разрабатывать каждое правило паттерна для каждого режима, в котором паттерн мог бы сравниваться, например, для регистрации единого правила паттерна для синтаксиса ссылок ВерблюжьегоСтиля (CamelCase) требовалось бы что-то вроде:

```
$Lexer->addSpecialPattern('\b[A-Z]+[a-z]+[A-Z][A-Za-
z]*\b','base','camelcaselink');
$Lexer->addSpecialPattern('\b[A-Z]+[a-z]+[A-Z][A-Za-
z]*\b','footnote','camelcaselink');
$Lexer->addSpecialPattern('\b[A-Z]+[a-z]+[A-Z][A-Za-
z]*\b','table','camelcaselink');
$Lexer->addSpecialPattern('\b[A-Z]+[a-z]+[A-Z][A-Za-
z]*\b','listblock','camelcaselink');
$Lexer->addSpecialPattern('\b[A-Z]+[a-z]+[A-Z][A-Za-
z]*\b','strong','camelcaselink');
$Lexer->addSpecialPattern('\b[A-Z]+[a-z]+[A-Z][A-Za-
z]*\b','underline','camelcaselink');
// etc.
```

Каждый режим, который позволяет содержать ссылки ВерблюжьегоСтиля должен был быть явно указан.

Вместо этого используется единый класс вроде:

```
class Doku_Parser_Mode_CamelCaseLink extends Doku_Parser_Mode {

    function connectTo($mode) {
        $this->Lexer->addSpecialPattern(
                '\b[A-Z]+[a-z]+[A-Z][A-Za-z]*\b',$mode,'camelcaselink'
            );
    }

}
```

При установке параметров лексического анализатора, парсер вызывает метод connectTo

объекта Doku_Parser_Mode_CamelCaseLink для любого режима, который принимает синтаксис ВерблюжьегоСтиля.

Это позволяет коду быть более гибким при добавлении новых синтаксических конструкций.

Формат данных инструкций

Следующее показывает пример исходного текста вики и соответствующий вывод парсера:

Исходный текст (содержит таблицу):

```
abc
| Row 0 Col 1    | Row 0 Col 2     | Row 0 Col 3        |
| Row 1 Col 1    | Row 1 Col 2     | Row 1 Col 3        |
def
```

После обработки будет возвращён следующий массив PHP (описан ниже):

```
Array
(
    [0] => Array
        (
            [0] => document_start
            [1] => Array
                (
                )

            [2] => 0
        )

    [1] => Array
        (
            [0] => p_open
            [1] => Array
                (
                )

            [2] => 0
        )

    [2] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>

abc
                )
```

```
            [2] => 0
        )

    [3] => Array
        (
            [0] => p_close
            [1] => Array
                (
                )

            [2] => 5
        )

    [4] => Array
        (
            [0] => table_open
            [1] => Array
                (
                    [0] => 3
                    [1] => 2
                )

            [2] => 5
        )

    [5] => Array
        (
            [0] => tablerow_open
            [1] => Array
                (
                )

            [2] => 5
        )

    [6] => Array
        (
            [0] => tablecell_open
            [1] => Array
                (
                    [0] => 1
                    [1] => left
                )

            [2] => 5
        )

    [7] => Array
        (
            [0] => cdata
            [1] => Array
```

```
                (
                    [0] =>  Row 0 Col 1
                )

            [2] => 7
        )

    [8] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>
                )

            [2] => 19
        )

    [9] => Array
        (
            [0] => tablecell_close
            [1] => Array
                (
                )

            [2] => 23
        )

    [10] => Array
        (
            [0] => tablecell_open
            [1] => Array
                (
                    [0] => 1
                    [1] => left
                )

            [2] => 23
        )

    [11] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>  Row 0 Col 2
                )

            [2] => 24
        )
```

```
    [12] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>
                )

            [2] => 36
        )

    [13] => Array
        (
            [0] => tablecell_close
            [1] => Array
                (
                )

            [2] => 41
        )

    [14] => Array
        (
            [0] => tablecell_open
            [1] => Array
                (
                    [0] => 1
                    [1] => left
                )

            [2] => 41
        )

    [15] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>  Row 0 Col 3
                )

            [2] => 42
        )

    [16] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>
                )
```

```
            [2] => 54
        )

    [17] => Array
        (
            [0] => tablecell_close
            [1] => Array
                (
                )

            [2] => 62
        )

    [18] => Array
        (
            [0] => tablerow_close
            [1] => Array
                (
                )

            [2] => 63
        )

    [19] => Array
        (
            [0] => tablerow_open
            [1] => Array
                (
                )

            [2] => 63
        )

    [20] => Array
        (
            [0] => tablecell_open
            [1] => Array
                (
                    [0] => 1
                    [1] => left
                )

            [2] => 63
        )

    [21] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>  Row 1 Col 1
```

```
                )

            [2] => 65
        )

    [22] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>
                )

            [2] => 77
        )

    [23] => Array
        (
            [0] => tablecell_close
            [1] => Array
                (
                )

            [2] => 81
        )

    [24] => Array
        (
            [0] => tablecell_open
            [1] => Array
                (
                    [0] => 1
                    [1] => left
                )

            [2] => 81
        )

    [25] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>  Row 1 Col 2
                )

            [2] => 82
        )

    [26] => Array
        (
```

```
            [0] => cdata
            [1] => Array
                (
                    [0] =>
                )

            [2] => 94
        )

    [27] => Array
        (
            [0] => tablecell_close
            [1] => Array
                (
                )

            [2] => 99
        )

    [28] => Array
        (
            [0] => tablecell_open
            [1] => Array
                (
                    [0] => 1
                    [1] => left
                )

            [2] => 99
        )

    [29] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>  Row 1 Col 3
                )

            [2] => 100
        )

    [30] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] =>
                )

            [2] => 112
```

```
        )

    [31] => Array
        (
            [0] => tablecell_close
            [1] => Array
                (
                )

            [2] => 120
        )

    [32] => Array
        (
            [0] => tablerow_close
            [1] => Array
                (
                )

            [2] => 121
        )

    [33] => Array
        (
            [0] => table_close
            [1] => Array
                (
                )

            [2] => 121
        )

    [34] => Array
        (
            [0] => p_open
            [1] => Array
                (
                )

            [2] => 121
        )

    [35] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] => def

                )
```

```
            [2] => 122
        )

    [36] => Array
        (
            [0] => p_close
            [1] => Array
                (
                )

            [2] => 122
        )

    [37] => Array
        (
            [0] => document_end
            [1] => Array
                (
                )

            [2] => 122
        )

)
```

Верхний уровень массива — это просто список. Каждый из его дочерних элементов описывает возвратную функцию, которая будет запущена под преобразователем (см. описание преобразователя ниже), также как и индекс байта исходного текста, где был найден особенный «элемент» синтаксиса вики.

Единственная инструкция

Рассмотрим единственный элемент, который представляет единственную инструкцию, из списка инструкций, приведённого выше:

```
    [35] => Array
        (
            [0] => cdata
            [1] => Array
                (
                    [0] => def

                )

            [2] => 122
        )
```

Первый элемент (индекс 0) — это наименование метода или функции, исполняемой преобразователем.

Второй элемент (индекс 1) — сам является массивом, каждый из элементов *которого* будет аргументом вызываемого метода преобразователя.

В этом случае это будет единственный аргумент со значением `"def\n"`, так что вызов метода будет:

```
$Render->cdata("def\n");
```

Третий элемент (индекс 2) — является индексом байта первого символа, на котором «сработает» эта инструкция в исходном тексте. Он должен быть точно таким же, как и значение, возвращённое PHP-функцией «strpos». Это может использоваться для обнаружения секции исходного текста вики, основанной на позиции сгенерированной инструкции (позже будет пример).

Замечание: метод `parse` парсера разбивает исходный вики текст на предыдущий и последующий символы, чтобы гарантировать корректный выход анализатора из состояний, так что вам требуется вычесть единицу из индекса байта, чтобы получить корректную позицию оригинального исходного вики-текста. Также парсер нормализует строки под стиль Unix'а (т. е. все`\r\n` становятся `\n`), так что документ, который видит анализатор, может быть меньше, чем тот, который вы в действительности загрузили.

Пример массив инструкций страницы с описанием синтаксиса — sample_instructions.

Преобразователь

Преобразователь — это класс (или коллекция функций), определяемый вами. Его интерфейс описан в файле `inc/parser/renderer.php` и выглядит так:

```
<?php
class Doku_Renderer {

    // snip

    function header($text, $level) {}

    function section_open($level) {}

    function section_close() {}

    function cdata($text) {}

    function p_open() {}

    function p_close() {}

    function linebreak() {}

    function hr() {}

    // snip
```

```
}
```

Он используется для документирования преобразователя, хотя также может быть расширен, если вы захотите написать преобразователь, который лишь перехватывает определённые вызовы.

Основной принцип того, как инструкции, возвращаемые парсером, используются преобразователем, близок по смыслу к SAX XML API — инструкции являются перечнем имён функций / методов и их аргуменов. Каждая инструкция может быть вызвана через преобразователь (т. е. реализуемые им методы являются обратными). В отличие от «SAX API», где доступно совсем немного, достаточно общих, обратно вызываемых методов (например, tag_start, tag_end, cdata и т. д.), преобразователь определяет более точную API, где методы обычно соответствуют один-к-одному действию по генерации выходных данных.

Во фрагменте преобразователя, показанном выше методы `p_open` и `p_close` будут использованы для вывода тэгов и в XHTML, соответственно, в то время, как функция `header` принимает два аргумента — некоторый текст для отображения и «уровень» заголовка, так что вызов типа `header('Some Title',1)` выведет в XHTML <h1>Some Title</h1>.

Вызов преобразователя через инструкции

К **клиентскому коду** относится использование парсера для выполнения перечня инструкций через преобразователь. Обычно это делается использованием php-функции «call_user_func_array». Например:

```
// Получить перечень инструкций из парсера
$instructions = $Parser->parse($rawDoc);

// Создать преобразователь
$Renderer = & new Doku_Renderer_XHTML();

// Пройтись по всем инструкциям
foreach ( $instructions as $instruction ) {

    // Выполнить инструкции через преобразователь
    call_user_func_array(array(&$Renderer,
$instruction[0]),$instruction[1]);
}
```

Методы преобразователя для ссылок

Ключевыми методами преобразователя для обработки различного рода ссылок являются:

- `function camelcaselink($link) {} // $link вида «SomePage"`
  - Возможно, это будет проигнорировано проверкой на спам-адрес — маловероятно, что кто-нибудь подобным образом поставить ссылку вне сайта.
- `function internallink($link, $title = NULL) {} // $link вида «[[syntax]]"`
  - Хотя `$link` сама по себе является внутренней, `$title` может быть недоступным

изображением, так что требуется проверка.
- `function externallink($link, $title = NULL) {}`
  - И `$link`, и `$title` (изображение) требуют проверки.
- `function interwikilink($link, $title = NULL, $wikiName, $wikiUri) {}`
  - `$title` требует проверки для изображений.
- `function filelink($link, $title = NULL) {}`
  - Технически, только годные `file://` URL будут совпадать, но всё равно лучше проверить плюс проверка `$title`, которое может быть недоступным изображением.
- `function windowssharelink($link, $title = NULL) {}`
  - Требуется проверить только годные адреса доступа к общим ресурсам Windows, но всё равно лучше проверить плюс проверка `$title`, которое может быть недоступным изображением.
- `function email($address, $title = NULL) {}`
  - `$title` может быть изображением. Проверять ли адрес электропочты?
- `function internalmedialink ($src,$title=NULL,$align=NULL,$width=NULL,$height=NULL,$cache=NULL) {}`
  - Здесь проверка не требуется — следует только поставить ссылки на локальные изображения. `$title` сам по себе не может быть изображением.
- `function externalmedialink($src,$title=NULL,$align=NULL,$width=NULL,$height=NULL, $cache=NULL) {}`
  - `$src` требует проверки.

Особое внимание следует уделит методам, принимающим в качестве параметра `$title`, который представляет видимый текст ссылки, например:

```
<a href="http://www.example.com/">This is the title</a>
```

Аргумент `$title` может принимать три возможных типа значений:

1. NULL: у документа вики нет заголовка;
2. строка: в качестве заголовка использована простая тестовая строка;
3. массив (хэш): в качестве заголовка использовано изображение.

Если `$title` является массивом, он будет содержать ассоциированные значения, описывающие изображение:

```
$title = array(
    // Может быть 'internalmedia' (локальное изображение) или 'externalmedia' (внешнее изображение)
    'type'=>'internalmedia',

    // URL изображения (может быть вики-URL или http://static.example.com/img.png)
    'src'=>'wiki:php-powered.png',

    // Для альтернативного атрибута - a string or NULL
    'title'=>'Powered by PHP',

    // 'left', 'right', 'center' или NULL
```

```
    'align'=>'right',

    // Ширина в пикселях или  NULL
    'width'=> 50,

    // Высота в пикселях или  NULL
    'height'=>75,

    // Следует ли кэшировать изображение (для внешних изображений)?
    'cache'=>FALSE,
);
```

Примеры

Следующие примеры показывают общие задачи, которые будут решаться с помощью парсера.

Основной вызов

Чтобы вызвать парсер со *всеми* режимами, и обработать синтаксис документа «Докувики»:

```
require_once DOKU_INC . 'parser/parser.php';

// Создать парсер
$Parser = & new Doku_Parser();

// Добавить обработчик
$Parser->Handler = & new Doku_Handler();

// Загрузить все режимы
$Parser->addMode('listblock',new Doku_Parser_Mode_ListBlock());
$Parser->addMode('preformatted',new Doku_Parser_Mode_Preformatted());
$Parser->addMode('notoc',new Doku_Parser_Mode_NoToc());
$Parser->addMode('header',new Doku_Parser_Mode_Header());
$Parser->addMode('table',new Doku_Parser_Mode_Table());

$formats = array (
    'strong', 'emphasis', 'underline', 'monospace',
    'subscript', 'superscript', 'deleted',
);
foreach ( $formats as $format ) {
    $Parser->addMode($format,new Doku_Parser_Mode_Formatting($format));
}

$Parser->addMode('linebreak',new Doku_Parser_Mode_Linebreak());
$Parser->addMode('footnote',new Doku_Parser_Mode_Footnote());
$Parser->addMode('hr',new Doku_Parser_Mode_HR());

$Parser->addMode('unformatted',new Doku_Parser_Mode_Unformatted());
```

```
$Parser->addMode('php',new Doku_Parser_Mode_PHP());
$Parser->addMode('html',new Doku_Parser_Mode_HTML());
$Parser->addMode('code',new Doku_Parser_Mode_Code());
$Parser->addMode('file',new Doku_Parser_Mode_File());
$Parser->addMode('quote',new Doku_Parser_Mode_Quote());

// Здесь требуются данные. Функции  ''get*''остаются на ваше усмотрение
$Parser->addMode('acronym',new
Doku_Parser_Mode_Acronym(array_keys(getAcronyms())));
$Parser->addMode('wordblock',new
Doku_Parser_Mode_Wordblock(array_keys(getBadWords())));
$Parser->addMode('smiley',new
Doku_Parser_Mode_Smiley(array_keys(getSmileys())));
$Parser->addMode('entity',new
Doku_Parser_Mode_Entity(array_keys(getEntities())));

$Parser->addMode('multiplyentity',new Doku_Parser_Mode_MultiplyEntity());
$Parser->addMode('quotes',new Doku_Parser_Mode_Quotes());

$Parser->addMode('camelcaselink',new Doku_Parser_Mode_CamelCaseLink());
$Parser->addMode('internallink',new Doku_Parser_Mode_InternalLink());
$Parser->addMode('media',new Doku_Parser_Mode_Media());
$Parser->addMode('externallink',new Doku_Parser_Mode_ExternalLink());
$Parser->addMode('email',new Doku_Parser_Mode_Email());
$Parser->addMode('windowssharelink',new
Doku_Parser_Mode_WindowsShareLink());
$Parser->addMode('filelink',new Doku_Parser_Mode_FileLink());
$Parser->addMode('eol',new Doku_Parser_Mode_Eol());

// Загрузить исходный документ вики
$doc = file_get_contents(DOKU_DATA . 'wiki/syntax.txt');

// Получить список инструкций
$instructions = $Parser->parse($doc);

// Создать преобразователь
require_once DOKU_INC . 'parser/xhtml.php';
$Renderer = & new Doku_Renderer_XHTML();

# Здесь загрузите в преобразователь данные (например, типа смайлов)

// Проходимся по всем инструкциям
foreach ( $instructions as $instruction ) {

    // Выполняем обратный вызов через преобразователь
    call_user_func_array(array(&$Renderer,
$instruction[0]),$instruction[1]);
}

// Отображаем выходные данные
echo $Renderer->doc;
```

Выбор текста (для фрагментов)

Следующий код показывает, как выбрать фрагмент исходного текста, используя инструкции, полученные из парсера;

```
// Создаём парсер
$Parser = & new Doku_Parser();

// Добавляем обработчик
$Parser->Handler = & new Doku_Handler();

// Загружаем режим  header  для поиска заголовков
$Parser->addMode('header',new Doku_Parser_Mode_Header());

// Загружаем режимы, которые могут содержать разметку,
// которая может быть принята за заголовок
$Parser->addMode('listblock',new Doku_Parser_Mode_ListBlock());
$Parser->addMode('preformatted',new Doku_Parser_Mode_Preformatted());
$Parser->addMode('table',new Doku_Parser_Mode_Table());
$Parser->addMode('unformatted',new Doku_Parser_Mode_Unformatted());
$Parser->addMode('php',new Doku_Parser_Mode_PHP());
$Parser->addMode('html',new Doku_Parser_Mode_HTML());
$Parser->addMode('code',new Doku_Parser_Mode_Code());
$Parser->addMode('file',new Doku_Parser_Mode_File());
$Parser->addMode('quote',new Doku_Parser_Mode_Quote());
$Parser->addMode('footnote',new Doku_Parser_Mode_Footnote());
$Parser->addMode('internallink',new Doku_Parser_Mode_InternalLink());
$Parser->addMode('media',new Doku_Parser_Mode_Media());
$Parser->addMode('externallink',new Doku_Parser_Mode_ExternalLink());
$Parser->addMode('email',new Doku_Parser_Mode_Email());
$Parser->addMode('windowssharelink',new
Doku_Parser_Mode_WindowsShareLink());
$Parser->addMode('filelink',new Doku_Parser_Mode_FileLink());

// Загружаем исходный документ вики
$doc = file_get_contents(DOKU_DATA . 'wiki/syntax.txt');

// Получаем перечень инструкций
$instructions = $Parser->parse($doc);

// Используем эти переменные, чтобы узнать,
// находимся ли мы внутри необходимого фрагмента
$inSection = FALSE;
$startPos = 0;
$endPos = 0;

// Проходимся по всем инструкциям
foreach ( $instructions as $instruction ) {

    if ( !$inSection ) {
```

```
        // Ищем заголовки в списках
        if ( $instruction[0] == 'header' &&
                trim($instruction[1][0]) == 'Lists' ) {

            $startPos = $instruction[2];
            $inSection = TRUE;
        }
    } else {

        // Ищем конец фрагмента
        if ( $instruction[0] == 'section_close' ) {
            $endPos = $instruction[2];
            break;
        }
    }
}

// Нормализуем и разбиваем документ
$doc = "\n".str_replace("\r\n","\n",$doc)."\n";

// Получаем текст, идущий перед фрагментом, который нам необходим
$before = substr($doc, 0, $startPos);
$section = substr($doc, $startPos, ($endPos-$startPos));
$after = substr($doc, $endPos);
```

Управление входными файлами с данными в шаблонах

«Докувики» хранит части некоторых шаблонов во внешних файлах (например, смайлы). Поскольку парсинг и вывод документа являются отдельными стадиями, обрабатываемыми различными компонентами, при использовании данных также требуется дифференцированный подход.

Каждый подходящий режим принимает простой список элементов, который он собирает в список шаблонов для регистрации в анализаторе.

Например:

```
// Простой список вхождений смайлов...
$smileys = array(
    ':-)',
    ':-(',
    ';-)',
    // и т. д.
    );

// Создать режим
$SmileyMode = & new Doku_Parser_Mode_Smiley($smileys);

// Добавить режим в парсер
```

```
$Parser->addMode($SmileyMode);
```

Для парсера не имеет значения выходной формат смайлов.

Другие режимы, где применяется подобный подход, определяются классами;

- `Doku_Parser_Mode_Acronym` — для сокращений;
- `Doku_Parser_Mode_Wordblock` — для блоков специфических слов (например, ненормативной лексики);
- `Doku_Parser_Mode_Entity` — для типографических символов.

Конструктор каждого класса принимает в качестве параметра список указанных элементов.

На практике возникает необходимость в функциях для извлечения данных из конфигурационных файлов и размещение ассоциативных массивов в статической переменной, например:

```
function getSmileys() {

    static $smileys = NULL;

    if ( !$smileys ) {

        $smileys = array();

        $lines = file( DOKU_CONF . 'smileys.conf');

        foreach($lines as $line){

            // игнорировать комментарии
            $line = preg_replace('/#.*$/','',$line);

            $line = trim($line);

            if(empty($line)) continue;

            $smiley = preg_split('/\s+/',$line,2);

            // Собрать ассоциативный массив
            $smileys[$smiley[0]] = $smiley[1];
        }
    }

    return $smileys;
}
```

Эта функция может быть использована следующим образом:

```
// Загрузить шаблоны смайлов в режим
$SmileyMode = & new Doku_Parser_Mode_Smiley(array_keys(getSmileys()));
```

```
// Загрузить ассоциативный массив в Преобразователь
$Renderer->smileys = getSmileys();
```

Замечание: проверка ссылок, которые необходимо блокировать, обрабатывается другим способом, описанным ниже.

Проверка ссылок на спам

В идеале ссылки требуется проверять на спам *до* размещения документа (после редактирования).

> Этот пример следует использовать осторожно. Он создаёт полезные точки связывания, но по результатам тестирования является очень медленным — возможно проще использовать функцию, которая «закрывает глаза» на синтаксис, но ищет во всем документе ссылки, сверяя их с «чёрным списком». Между тем, этот пример может быть полезным как основа для построения «карты вики» или поиска «требуемых страниц» посредством проверки внутренних ссылок.

Это можно сделать, создав специальный преобразователь, который проверяет только относящиеся к ссылкам обратные вызовы и сверяет ULR с «чёрным списком».

Требуется функция для загрузки файла `spam.conf` и связывания его с единственным регулярным выражением:

> Недавно протестировал этот подход (единственное регулярное выражение) с использованием последней версии «чёрного списка» с blacklist.chongqed.org и получил ошибки о том, что окончательное регулярное выражение слишком велико. Возможно, следует разбить регулярное выражение на маленькие кусочки и возвращать их как массив.

```
function getSpamPattern() {
    static $spamPattern = NULL;

    if ( is_null($spamPattern) ) {

        $lines = @file(DOKU_CONF . 'spam.conf');

        if ( !$lines ) {

            $spamPattern = '';

        } else {

            $spamPattern = '#';
            $sep = '';

            foreach($lines as $line){

                $line = preg_replace('/#.*$/','',$line);
```

```
                // Игнорировать пустые строки
                $line = trim($line);
                if(empty($line)) continue;

                $spamPattern.= $sep.$line;

                $sep = '|';
            }

            $spamPattern .= '#si';
        }
    }

    return $spamPattern;
}
```

Теперь нам нужно расширить основной преобразователь ещё одним, который проверяет только ссылки:

```
require_once DOKU_INC . 'parser/renderer.php';

class Doku_Renderer_SpamCheck extends Doku_Renderer {

    // Здесь должен быть код, выполняющий инструкции
    var $currentCall;

    // Массив инструкций, которые содержат спам
    var $spamFound = array();

    //  PCRE-шаблон для нахождения спама
    var $spamPattern = '#^$#';

    function internallink($link, $title = NULL) {
        $this->__checkTitle($title);
    }

    function externallink($link, $title = NULL) {
        $this->__checkLinkForSpam($link);
        $this->__checkTitle($title);
    }

    function interwikilink($link, $title = NULL) {
        $this->__checkTitle($title);
    }

    function filelink($link, $title = NULL) {
        $this->__checkLinkForSpam($link);
        $this->__checkTitle($title);
    }

    function windowssharelink($link, $title = NULL) {
```

```
        $this->__checkLinkForSpam($link);
        $this->__checkTitle($title);
    }

    function email($address, $title = NULL) {
        $this->__checkLinkForSpam($address);
        $this->__checkTitle($title);
    }

    function internalmedialink ($src) {
        $this->__checkLinkForSpam($src);
    }

    function externalmedialink($src) {
        $this->__checkLinkForSpam($src);
    }

    function __checkTitle($title) {
        if ( is_array($title) && isset($title['src'])) {
            $this->__checkLinkForSpam($title['src']);
        }
    }

    // Поиск по шаблону осуществляется здесь
    function __checkLinkForSpam($link) {
        if( preg_match($this->spamPattern,$link) ) {
            $spam = $this->currentCall;
            $spam[3] = $link;
            $this->spamFound[] = $spam;
        }
    }
}
```

Обратите внимание на строку `$spam[3] = $link;` в методе `__checkLinkForSpam`. Она вставляет дополнительный элемент в список найденных спамовых инструкций, позволяя легко определить, какие URL были «плохими».

Наконец мы можем использовать преобразователь с проверкой на спам:

```
// Создать парсер
$Parser = & new Doku_Parser();

// Добавить обработчик
$Parser->Handler = & new Doku_Handler();

// Добавить режимы, которые могут содержать разметку,
// которая ошибочно будет принята за ссылку
$Parser->addMode('preformatted',new Doku_Parser_Mode_Preformatted());
$Parser->addMode('unformatted',new Doku_Parser_Mode_Unformatted());
$Parser->addMode('php',new Doku_Parser_Mode_PHP());
$Parser->addMode('html',new Doku_Parser_Mode_HTML());
```

```
$Parser->addMode('code',new Doku_Parser_Mode_Code());
$Parser->addMode('file',new Doku_Parser_Mode_File());
$Parser->addMode('quote',new Doku_Parser_Mode_Quote());

// Загружаем режим link...
$Parser->addMode('internallink',new Doku_Parser_Mode_InternalLink());
$Parser->addMode('media',new Doku_Parser_Mode_Media());
$Parser->addMode('externallink',new Doku_Parser_Mode_ExternalLink());
$Parser->addMode('email',new Doku_Parser_Mode_Email());
$Parser->addMode('windowssharelink',new
Doku_Parser_Mode_WindowsShareLink());
$Parser->addMode('filelink',new Doku_Parser_Mode_FileLink());

// Загружаем исходный документ вики
$doc = file_get_contents(DOKU_DATA . 'wiki/spam.txt');

// Получить список инструкций
$instructions = $Parser->parse($doc);

// Создать преобразователь
require_once DOKU_INC . 'parser/spamcheck.php';
$Renderer = & new Doku_Renderer_SpamCheck();

// Загрузить шаблон спама
$Renderer->spamPattern = getSpamPattern();

// Пройтись по всем инструкциям
foreach ( $instructions as $instruction ) {

    // Сохранить текущую инструкцию
    $Renderer->currentCall = $instruction;

    call_user_func_array(array(&$Renderer,
$instruction[0]),$instruction[1]);
}

// Что за спам был найден?
echo '<pre>';
print_r($Renderer->spamFound);
echo '</pre>';
```

Поскольку нам не нужны все режимы синтаксиса, проверка спама таким способом будет быстрее, чем обычный парсинг документа.

Добавление синтаксической конструкции

Предупреждение: приведённый ниже код ещё не испытан — это только пример.

Простая задача по модификации парсера: этот пример будет добавлять тэг-«закладку», который может быть использован для создания якоря в документе для создания ссылки на

него.

Синтаксис для тэга будет таким:

```
BM{Моя закладка}
```

Строка «Моя закладка» является наименование закладки, а BM {} идентифицируется как сама закладка. В HTML эта конструкция будет соответствовать:

```
<a name="Моя закладка"></a>
```

Добавление этой синтаксической конструкции требует следующих шагов:

1. создать синтаксический режим парсера, для регистрации в лексическом анализаторе;
2. обновить код функции `Doku_Parser_Substition`, находящейся в конце файла `parser.php` и которая используется для быстрого получения списка режимов (используется в классах вроде`Doku_Parser_Mode_Table`);
3. обновить код обработчика, дополнив его методом, «ловящим» вхождения закладок;
4. обновление абстрактного класса преобразователя и какого-нибудь конкретного преобразователя.

Создание режима парсера подразумевает расширение класса `Doku_Parser_Mode` и перегрузкой метода `connectTo`:

```
class Doku_Parser_Mode_Bookmark extends Doku_Parser_Mode {

    function connectTo($mode) {
        // Разрешаются слова и пробелы
        $this->Lexer->addSpecialPattern('BM\{[\w ]+\}',$mode,'bookmark');
    }

}
```

Будет осуществляться поиск целой закладки с использованием единственного шаблона (извлечение имени закладки из остального синтаксиса будет осущевляться обработчиком). Используется метод `addSpecialPattern` анализатора, так что закладка присутствует в своём собственном состоянии.

Замечание: анализатор не требует ограничителей шаблона — он заботиться об этом за вас.

Поскольку ничто *внутри* закладки не должно рассматриваться как годная разметка вики, связывание с другими режимами, которые может принимать этот, отсутствует.

Следующая функция `Doku_Parser_Substition` в файле `inc/parser/parser.php` требует обновления, чтобы она возвращала в списке новый режим с наименованием `bookmark`;

```
function Doku_Parser_Substition() {
    $modes = array(
        'acronym','smiley','wordblock','entity','camelcaselink',
        'internallink','media','externallink','linebreak','email',
        'windowssharelink','filelink','notoc','multiplyentity',
```

```
        'quotes','bookmark',

    );
    return $modes;
}
```

Эта функция лишь помогает в регистрации режима с другими режимами, которые получают его (например, списки могут содержать этот режим — ваша ссылка может быть внутри списка).

Замечание: существует похожая функция, вроде `Doku_Parser_Protected` и `Doku_Parser_Formatting`, которые возвращают разные группы режимов. Группировка различных типов синтаксиса не является полностью совершенной, но всё равно остаётся полезной для экономии кода.

Описав синтаксис, мы должны добавить в обработчик новый метод, который сравнивает наименование режима (т. е.`bookmark`).

```
class Doku_Handler {

    // ...

    // $match - строка, которая сравнивается анализатором
    //     с регулярным выражением для закладок
    // $state идентифицирует тип совпадения (см. выше)
    // $pos - индекс байта первого символа совпадения в исходном документе
    function bookmark($match, $state, $pos) {

        // Технически не следует беспокоится о состоянии:
        // оно всегда будет DOKU_LEXER_SPECIAL, если
        // нет серьёзных багов
        switch ( $state ) {

            case DOKU_LEXER_SPECIAL:

                // Попытка извлечения наименования закладки
                if ( preg_match('/^BM\{(\w{1,})\}$/', $match, $nameMatch) )
{

                    $name = $nameMatch[1];

                    // arg0: наименование вызываемого метода преобразователя
                    // arg1: массив аргументов для метода преобразователя
                    // arg2: индекс байта
                    $this->__addCall('bookmark', array($name), $pos);

                // Если у закладки нет годного имени,
                // пропускаем не меняя как cdata
                } else {

                    $this->__addCall('cdata', array($match), $pos);
```

```
                }
            break;

        }

        // Должно вернуть  TRUE  или анализатор будет остановлен
        return TRUE;
    }

    // ...

}
```

Последний этап — обновление кода преобразователя (`renderer.php`) новой функцией и её реализация в XHTML преобразовании (`xhtml.php`):

```
class Doku_Renderer {

    // ...

    function bookmark($name) {}

    // ...

}
```

```
class Doku_Renderer_XHTML {

    // ...

    function bookmark($name) {
        $name = $this->__xmlEntities($name);

        // id is required in XHTML while name still supported in 1.0
        echo '<a class="bookmark" name="'.$name.'" id="'.$name.'"></a>';

    }

    // ...

}
```

См. скрипт `tests/parser_replacements.test.php` в качестве примера того, как можно использовать этот код.

Добавление синтаксиса форматирования (с состоянием)

Предупреждение: нижеприведённый код ещё не протестирован — это только пример.

Для того, чтобы показать расширенное использование анализатора, этот пример добавляет разметку, которая позволяет пользователям менять цвет обрамляемый текст на красный, жёлтый или зелёный.

Разметка будет выглядеть так:

```
<red>Это красный цвет</red>.
Это чёрный цвет
<yellow>Это жёлтый цвет</yellow>.
Это тоже чёрный цвет
<green>Это зелёный цвет</green>.
```

Шаги, необходимые для внедрения данной возможности, в сущности, являются такими же, как в предыдущем примере, начинаются с нового синтаксического режима, но добавляет некоторые детали, поскольку задействуются другие режимы:

```
class Doku_Parser_Mode_TextColors extends Doku_Parser_Mode {

    var $color;

    var $colors = array('red','green','blue');

    function Doku_Parser_Mode_TextColor($color) {

        // Предотвращает ошибки использования этого режима
        if ( !array_key_exists($color, $this->colors) ) {
            trigger_error('Invalid color '.$color, E_USER_WARNING);
        }

        $this->color = $color;

        // Этот режим принимает другие режимы:
        $this->allowedModes = array_merge (
            Doku_Parser_Formatting($color),
            Doku_Parser_Substition(),
            Doku_Parser_Disabled()
        );

    }

    // connectTo вызывается однократно для каждого режима, зарегистрированного
анализатором
    function connectTo($mode) {

        // Шаблон с просмотром вперёд проверяет наличие закрывающего тэга...
        $pattern = '<'.$this->color.'>(?=.*</'.$this->color.'>)';

        // arg0: шаблон сравнения при входе в режим;
        // arg1: другие режимы, может сравниваться этот шаблон;
        // arg2: наименование режима.
        $this->Lexer->addEntryPattern($pattern,$mode,$this->color);
```

```
    }

    // post connect вызывается однократно
    function postConnect() {

        // arg0: шаблон сравнения при выходе из режима;
        // arg1: наименование режима.
        $this->Lexer->addExitPattern('</'.$this->color.'>',$this->color);

    }

}
```

Некоторые особенности вышеприведённых классов:

1. В действительности представляют множество режимов, один для каждого цвета. Цвета следует выделять в отдельные режимы так, что, например, </green> не будет закрывающим тэгом для <red>.
2. Эти режимы могут содержать, например, <red>**Предупреждение**</red> для полужирного текста красного цвета. Это регистрируется в конструкторе класса назначением полученных наименований режимов свойству `allowedModes`.
3. Когда регистрируется входной шаблон, имеет смысл проверить существование выходного шаблона (с помощью просмотра вперёд). Это поможет в защите пользователей от них самих, когда они забудут добавить закрывающий тэг.
4. Входной шаблон требует регистрации для каждого режима, внутри которого тэги <color /> могут использоваться. Нам требуется толь один выходной шаблон, помещённый в метод `postConnect`, который исполняется однократно, после всех вызовов `connectTo` по всем вызванным режимам.

Когда с классом режимами обработки покончено, новые режимы требуется добавить в в функцию `Doku_Parser_Formatting`:

```
function Doku_Parser_Formatting($remove = '') {
    $modes = array(
        'strong', 'emphasis', 'underline', 'monospace',
        'subscript', 'superscript', 'deleted',
        'red','yellow','green',
        );
    $key = array_search($remove, $modes);
    if ( is_int($key) ) {
        unset($modes[$key]);
    }

    return $modes;
}
```

Замечание: эта функция обрабатывается, чтобы снять режим для предотвращения включения режима форматирования в самого себя (так, например, нежелательно: <red>Срочное<red>и важное</red>сообщение</red>).

Далее обработчик должен быть обновлён методами для каждого цвета:

```
class Doku_Handler {

    // ...

    function red($match, $state, $pos) {
        // Метод  nestingTag  в обработчике предотвращает
        // многократное повторение одного и того же кода.
        // Он создаёт открывающий и закрывающий инструкции
        // для входных и выходных шаблонов,
        // пропуская остальные как  cdata.
        $this->__nestingTag($match, $state, $pos, 'red');
        return TRUE;
    }

    function yellow($match, $state, $pos) {
        $this->__nestingTag($match, $state, $pos, 'yellow');
        return TRUE;
    }

    function green($match, $state, $pos) {
        $this->__nestingTag($match, $state, $pos, 'green');
        return TRUE;
    }

    // ...

}
```

Наконец мы может обновить преобразователи:

```
class Doku_Renderer {

    // ...

    function red_open() {}
    function red_close() {}

    function yellow_open() {}
    function yellow_close() {}

    function green_open() {}
    function green_close() {}

    // ...

}
```

```
class Doku_Renderer_XHTML {

    // ...
```

```
    function red_open() {
        echo '<span class="red">';
    }
    function red_close() {
        echo '</span>';
    }

    function yellow_open() {
        echo '<span class="yellow">';
    }
    function yellow_close() {
        echo '</span>';
    }

    function green_open() {
        echo '<span class="green">';
    }
    function green_close() {
        echo '</span>';
    }

    // ...

}
```

См. скрипт `tests/parser_formatting.test.php` в качестве примера того, как можно использовать этот код.

Добавление блочных синтаксических конструкций

Предупреждение: приведённый ниже код ещё не тестировался — это только пример.

Развивая предыдущий пример, этот будет создавать новый тэг для разметки сообщений о том, что ещё предстоит сделать. Пример использования может выглядеть так:

```
===== Синтаксис цитирования в вики =====

Этот синтаксис позволяет

<todo>
Опишите синтаксис цитирования '>'
</todo>

Другой текст
```

Этот синтаксис позволяет искать страницы вики и находить вопросы, которые предстоит решить, выделяя их в документе бросающимся в глаза стилем.

Особенностью данного синтаксиса является то, что он должен отображаться в отдельном

блоке документа (например, внутри

, так что он с помощью CSS может «плавать»). Это требует модификации класса Doku_Handler_Block, который пробегает по всем инструкциям, после того, как обработчиком найдены все вхождения, и заботиться о добавлении тэгов <p/>.

Режим парсера для этого синтаксиса может быть таким:

```
class Doku_Parser_Mode_Todo extends Doku_Parser_Mode {

    function Doku_Parser_Mode_Todo() {

        $this->allowedModes = array_merge (
            Doku_Parser_Formatting(),
            Doku_Parser_Substition(),
            Doku_Parser_Disabled()
        );

    }

    function connectTo($mode) {

        $pattern = '<todo>(?=.*</todo>)';
        $this->Lexer->addEntryPattern($pattern,$mode,'todo');
    }

    function postConnect() {
        $this->Lexer->addExitPattern('</todo>','todo');
    }

}
```

Затем этот режим добавляется в функцию Doku_Parser_BlockContainers в файле parser.php:

```
function Doku_Parser_BlockContainers() {
    $modes = array(
        'footnote', 'listblock', 'table','quote',
        // горизонтальные разрывы нарушают принцип, но они не могут использоваться в
таблицах / списках,
        // так что вставляем их сюда
        'hr',
        'todo',
    );
    return $modes;
}
```

Обновление класса Doku_Handler:

```
class Doku_Handler {
```

```
    // ...

    function todo($match, $state, $pos) {
        $this->__nestingTag($match, $state, $pos, 'todo');
        return TRUE;
    }

    // ...

}
```

Класс Doku_Handler_Block (см. файл inc/parser/handler.php) также нуждается в обновлении, чтобы регистрировать открывающие и закрывающие инструкции todo:

```
class Doku_Handler_Block {

    // ...

    var $blockOpen = array(
            'header',
            'listu_open','listo_open','listitem_open',
'table_open','tablerow_open','tablecell_open','tableheader_open',
            'quote_open',
            'section_open', // Needed to prevent p_open between header and
section_open
            'code','file','php','html','hr','preformatted',
            'todo_open',
        );

    var $blockClose = array(
            'header',
            'listu_close','listo_close','listitem_close',
'table_close','tablerow_close','tablecell_close','tableheader_close',
            'quote_close',
            'section_close', // Needed to prevent p_close after
section_close
            'code','file','php','html','hr','preformatted',
            'todo_close',
        );
```

Регистрация todo_open и todo_close в массивах $blockOpen и $blockClose сообщает классу Doku_Handler_Block, что любые предыдущие абзацы должны быть закрыты *до* входа в секцию todo, а новый абзац должен начинаться *после* секции todo. Внутри todo дополнительные абзацы не вставляются.

После этого должен быть обновлён код преобразователя:

```
class Doku_Renderer {
```

```
    // ...

    function todo_open() {}
    function todo_close() {}

    // ...

}
```

```
class Doku_Renderer_XHTML {

    // ...

    function todo_open() {
        echo '<div class="todo">';
    }
    function todo_close() {
        echo '</div>';
    }

    // ...

}
```

Сериализация инструкций преобразователя

Список выводимых обработчиком инструкций можно сериализировать, чтобы устранить повторную обработку исходного документа при каждом запросе, если содержание документа не менялось.

Самая простая реализация может быть такой:

```
$ID = DOKU_DATA . 'wiki/syntax.txt';
$cacheID = DOKU_CACHE . $ID.'.cache';

// Если кэш-файл отсутствует или утратил актуальность
// (исходный документ модифицирован), получить «свежий» список инструкций
if ( !file_exists($cacheID) || (filemtime($ID) > filemtime($cacheID)) ) {

    require_once DOKU_INC . 'parser/parser.php';

    // Создать парсер
    $Parser = & new Doku_Parser();

    // Добавить обработчик
    $Parser->Handler = & new Doku_Handler();

    // Загрузить все режимы
    $Parser->addMode('listblock',new Doku_Parser_Mode_ListBlock());
    $Parser->addMode('preformatted',new Doku_Parser_Mode_Preformatted());
```

```
    $Parser->addMode('notoc',new Doku_Parser_Mode_NoToc());
    $Parser->addMode('header',new Doku_Parser_Mode_Header());
    $Parser->addMode('table',new Doku_Parser_Mode_Table());

    // и т. д., и т. п.

    $instructions = $Parser->parse(file_get_contents($filename));

    // Сериализировать и кэшировать
    $sInstructions = serialize($instructions);

    if ($fh = @fopen($cacheID, 'a')) {

        if (fwrite($fh, $sInstructions) === FALSE) {
            die("Cannot write to file ($cacheID)");
        }

        fclose($fh);
    }

} else {
    // Загрузить и десериализировать
    $sInstructions = file_get_contents($cacheID);
    $instructions = unserialize($sInstructions);
}

$Renderer = & new Doku_Renderer_XHTML();

foreach ( $instructions as $instruction ) {
    call_user_func_array(
        array(&$Renderer, $instruction[0]),$instruction[1]
        );
}

echo $Renderer->doc;
```

Замечание: эта реализация не является полной. Что должно просходить, если кто-либо, например, модифицирует файл `smiley.conf`, добавив новый смайл? Это изменение должно порождать изменение кэша с обработкой нового смайла. Также необходимо позаботиться о блокировке файлов (или их переименовании).

Сериализация парсера

По аналогии с приведённым выше примером, возможна сериализация самого парсера до начала обработки. Поскольку установка режимов поддерживает довольно высокую перегрузку, этот пример может немного увеличить производительность. По неточной оценке, обработка страницы syntax в медленной системе занимает около 1,5-а секунд для завершения *без* сериализации и около 1,25-х секунды в версии парсера *с поддержкой* сериализации.

Если коротко, то сериализация может быть реализована таким способом:

```
$cacheId = DOKU_CACHE . 'parser.cache';

if ( !file_exists($cacheId) ) {

    // Создаём парсер
    $Parser = & new Doku_Parser();
    $Parser->Handler = & new Doku_Handler();

    // Загружаем все режимы
    $Parser->addMode('listblock',new Doku_Parser_Mode_ListBlock());
    $Parser->addMode('preformatted',new Doku_Parser_Mode_Preformatted());

    # и т. д., и т. п.
    // ВАЖНО: вызов  connectModes()
    $Parser->connectModes();

    // Сериализация
    $sParser = serialize($Parser);

    // Запись в файл
    if ($fh = @fopen($cacheID, 'a')) {

        if (fwrite($fh, $sParser) === FALSE) {
            die("Cannot write to file ($cacheID)");
        }

        fclose($fh);
    }

} else {
    // Загружаем сериализированную версию
    $sParser = file_get_contents($cacheID);
    $Parser = unserialize($sParser);
}

$Parser->parse($doc);
```

Некоторые замечания по реализации, не упомянутые выше:

- Для некоторых файлов вместо записи требуется блокировка, в противном случае в ответ на запрос может быть получен частично кэшированный файл, если он будет считываться, пока продолжается запись.
- Что следует делать, если обновляется один из файлов `*.conf`? Необходимо очистить кэш.
- Могут быть различные версии парсера (например, с проверкой на спам), так что используйте кэш-идентификаторы (cache IDs).

Тестирование

Тесты программных единиц обеспечивают использование «Simple Test for PHP». «Simple Test» является отличным инструментом для тестирования единиц php-кода. Особенно выделяются блестящая документация (см. simpletest.sourceforge.net и www.lastcraft.com/simple_test.php) и хорошо продуманый код, обеспечивающий «прозрачное» решение многих вопросов (вроде перехвата ошибок PHP и сообщения о них в результатах тестирования).

Для парсера «Докувики» тесты проводились по всем внедряемым синтаксическим конструкциям, и я *очень сильно* рекомендую написание новых тестов, если добавляется новый синтаксис.

Чтобы запустить тесты, вам следует модифицировать файл `tests/testconfig.php`, указав корректные директории «Simple Test» и «Докувики».

Некоторые заметки и рекомендации:

1. Повторно запускайте тесты каждый раз, когда вы меняете что-нибудь в парсере — проблемы немедленно выплывают на поверхность, экономя кучу времени.
2. Это только тесты для специфических ситуаций. Они не гарантируют отсутствие ошибок, если в этих специфических ситуациях работают корректно.
3. Если найдена ошибка, в процессе её устранения напишите тесты (даже лучше, *до* её устранения), чтобы предотвратить её повторное возникновение.

Ошибки и проблемы

Некоторые вопросы остаются за рамками подробного рассмотрения.

Важность порядка добавления режимов

Требуется выполение не столько «правил», сколько порядка, в котором добавляются режимы (парсер этого не проверяет). В особенности, режим `eol` должен быть загружен последним, т. к. он «съедает» «обёрточные» символы, что может нарушить корректную работу других режимов, вроде `list` или `table`.

В общем случае рекомендуется загружать режимы в порядке, описанном выше в первом примере.

> По моим наработкам, порядок важен, только если два и более режима имеют шаблоны, с которыми могут сравниваться одинаковые совокупности символов - в этом случае «выиграет» режим, имеющий низший порядковый номер. Синтаксический плагин может извлечь из этого выгоду, заменяя оригинальный обработчик, в качестве примера см. плагин «Code» — *ChrisS 2005-07-30*

Замены «блокиратора слов»

В оригинале функционирование «блокиратора слов» `wordblock` заключалось в сравнении URL ссылок с «чёрным списком». Сейчас этот режим используется для нахождения грубых слов. Для блокирования спамовых URL лучше использовать приведённый выше пример.

Рекомендация — файл `conf/wordblock.conf` следует переименовать в `conf/spam.conf`, содержащий «чёрный список» URL. Новый файл`conf/badwords.conf` будет содержать список цензурируемых грубых слов.

Слабые моменты

С точки зрения архитектуры, наихудшие части кода находятся в файле `inc/parser/handler.php`, преимущественно в «re-writing»-классах;

- `Doku_Handler_List` (inline re-writer)
- `Doku_Handler_Preformatted` (inline re-writer)
- `Doku_Handler_Quote` (inline re-writer)
- `Doku_Handler_Table` (inline re-writer)
- `Doku_Handler_Section` (post processing re-writer)
- `Doku_Handler_Block` (post processing re-writer)
- `Doku_Handler_Toc` (post processing re-writer)

«Inline re-writers» используются, пока обработчик получает вхождения от анализатора, в то время как «post processing re-writers», вызываются из `Doku_Handler::__finalize()` и выполняются однократно в отношении полного списка инструкций, созданных обработчиком.

Возможно лучше устранить `Doku_Handler_List`, `Doku_Handler_Quote` и `Doku_Handler_Table`, использовав взамен многострочные лексические режимы.

Также *возможно лучше* изменить `Doku_Handler_Section` и `Doku_Handler_Toc` в «inline re-writers», срабатывающие на вхождения заголовков, принимаемых Обработчиком.

Самое «больное место» — это класс `Doku_Handler_Block`, отвечающий за вставку абзацев в инструкции. Имеет значение добавить в него больше абстракций для облегчения разработки, но в общем-то я не вижу каких-либо путей полного его устранения.

«Жадные» тэги

Рассмотрим следующий синтаксис вики:

```
Привет, <sup>Мир!

----

<sup>Пока,</sup> Мир...
```

Пользователь забыл закрыть первый тэг <sup>.

В результате получится:

Привет, <sup>Мир! —- ^{Пока,} Мир...

Первый тэг <sup> оказался слишком «жадным» в проверке своего входного шаблона.

Это применимо ко всем подобным режимам. Входные шаблоны проверяют наличие

закрывающего тэга, но также они должны проверять, чтобы раньше не встретился второй открывающий тэг.

Сноски через список

В сущности, если сноска закрывается через несколько элементов списка, это вызывает эффект открывающей инструкции сноски без соответствующей закрывающей. Вот пример синтаксиса, вызывающего проблему:

```
  *((A))
    *(( B
  * C ))
```

Это будет происходить до тех пор, пока пользователи не поправят страницу. Решение — разбить захват элементов списка в многострочные режимы (сейчас для списков есть только единственный режим `listblock`).

Захват «обёрточных» символов

Баг № 261.

Поскольку синтаксис заголовка, горизонтальной линии, списка, таблицы, цитаты и неформатируемого (выделяемого) текста полагается на «обёрточные» символы для разметки своих начала и окончания, им требуются регулярные выражения, которые поглощают «обёрточные» символы. Это означает, что пользователь должен добавлять «обёрточные» символы, если таблица находится сразу после списка, например:

```
До списка
  - Элемент списка
  - Элемент списка
| Ячейка A | Ячейка B |
| Ячейка C | Ячейка D |
После таблицы
```

Выдаёт:

До списка

1. Элемент списка
2. Элемент списка

| Ячейка A | Ячейка B |

Ячейка C	Ячейка D

После таблицы

Заметьте, что **первая строка** таблицы воспринимается как обычный текст.

Чтобы скорректировать это, синтаксис вики должен иметь дополнительную «обёртку» между списком и таблицей:

```
До списка
  - Элемент списка
  - Элемент списка

| Ячейка A | Ячейка B |
| Ячейка C | Ячейка D |
После таблицы
```

Что будет выглядеть следующим образом:

До списка

1. Элемент списка
2. Элемент списка

Ячейка A	Ячейка B
Ячейка C	Ячейка D

После таблицы

Без сканирования текста множества раз (некая разновидность «предварительных» операций, которые вставляют «обёртку»), едва ли можно найти простое решение.

Проблемы списков, таблиц и цитат

Для синтаксиса списков, таблиц и цитат есть вероятность, что использование внутри их другого синтаксиса «съест» несколько строк. Например, таблица вроде:

```
| Cell A | <sup>Cell B |
| Cell C | Cell D</sup> |
| Cell E | Cell F |
```

выдаёт:

Cell A	Cell B | | Cell C | Cell D
Cell E	Cell F

В идеале должно быть преобразовано так:

Cell A	<sup>Cell B
Cell C	Cell D</sup>
Cell E	Cell F

Т. е. открывающий тэг <sup> должен игнорироваться, если в текущей ячейке отсутствует закрывающий тэг.

Для устранения этого требуется поддержка многострочного режима внутри таблиц, списков и

цитат.

Сноски и блоки

Внутри сносок блоки игнорируются, вместо этого используется эквивалент инструкции
. Это связано с неудобным в разработке классом Doku_Handler_Block. Если внутри сноски используются таблица, список, цитата или горизонтальная линия, это *сработает* как абзац.

Устраняется модификацией класса Doku_Handler_Block, однако рекомендуется предварительно тщательно ознакомиться с его устройством.

Заголовки

Текущие заголовки могут находиться на той же строке, что и предшествующий текст. Это вытекает из эффекта, рассмотренного выше в вопросе «Захват строк», и требует некоторой предварительной обработки для устранения. Например:

```
До заголовка есть
Некоторый текст == Заголовок ==
После заголовка
```

Если бы поведение было бы таким же, как в оригинальном парсере «Докувики», преобразование было бы таким:

До заголовка есть Некоторый текст == Заголовок == После заголовка

Но в результате будет:

До заголовка есть Некоторый текст

Заголовок

После заголовка

Конфликт блоков и списков

Существует проблема: если до списка находится пустая строка с двумя пробелами, всё это вместе будет интерпретироваться как блок:

```
* list item
* list item 2
```

Что ещё необходимо сделать

Вот некоторые вопросы, которые ещё предстоит решить...

Больше состояний для закрывающих инструкций

Для преобразования в иные форматы, нежели XHTML, может оказаться полезным добавление отождествления уровня для закрывающих инструкций списка, и т. д.

> Почему бы просто не «преобразовать» в XML и затем применить к нему некоторые парсеры XSLT/XML?

Подрежимы для таблиц, списков, цитат

Анализатор с множественными режимами для предотвращения случаев вложенности состояний друг в друга.

Обсуждение

Спасибо за перевод!

1)
Lexer относится к классу `Doku_Lexer` и содержится в файле `inc/parser/lexer.php`.

2)
Сканирование — чтение строки PHP от начала до конца.

3)
Термин «вхождение» в этом документе относится к совпадению регулярного выражения, полученного анализатором, и соответствующему вызову метода обработчиком.

4)
Handler относится к классу `Doku_Handler` и содержится в файле `inc/parser/handler.php`.

5)
Последовательность инструкций содержится в массиве `$calls`, который является атрибутом обработчика. Предназначен для использования с call_user_func_array.

6)
Parser относится к классу `Doku_Parser` и содержится в файле `inc/parser/parser.php`.

7)
Renderer (от «to render» *в значении* превращать, преобразовывать) относится к абстрактному (implemented) классу `Doku_Renderer` - см. `inc/parser/renderer.php` и `inc/parser/xhtml.php`.

8)

Прим. переводчика: возможно, речь идёт т. н. **незахватывающем поиске**, подробнее см. литературу по регулярным выражениям, например, Джеффри Фридла «Регулярные выражения: библиотека программиста. Второе издание.» — СПб.: Питер, 2003, или документацию по PHP — ru.php.net/manual/en/ref.pcre.php.

9)

Уточнить перевод термина.

10)

Термины «состояние» и «режим» используются отчасти как взаимозаменяемые, когда здесь говориться об анализаторе

11)

Смысл «плохо форматируемый» не применим к парсеру «Докувики» — он разработан так, чтобы предотвращать случаи, когда пользователь забывает добавить закрывающий тэг некоторой разметки, полностью игнорируя эту разметку.