

Уязвимость регулярных выражений

Теория и практика ReDoS-атак



Алексей Авдеев
avdeev@viva64.com

Speaker

Алексей Авдеев

- Разработчик в C# команде PVS-Studio
- Изучаю информационную безопасность
- Окружен багами, но не сломлен



Введение

Что за зверь такой, ReDoS?

ReDoS - regular expression denial of service

Разновидность DOS атаки, инициируемой при помощи уязвимого регулярного выражения

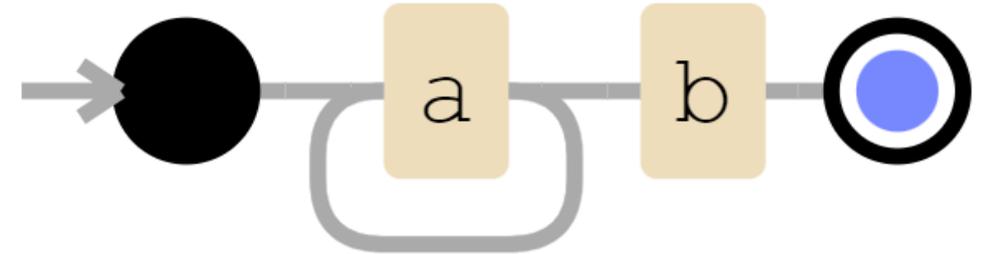
Чем опасен ReDoS?

- Замедление приложения
- Отказ в обслуживании

Рассмотрим пример

Регулярное выражение: a^+b

Последовательность для разбора: aaa

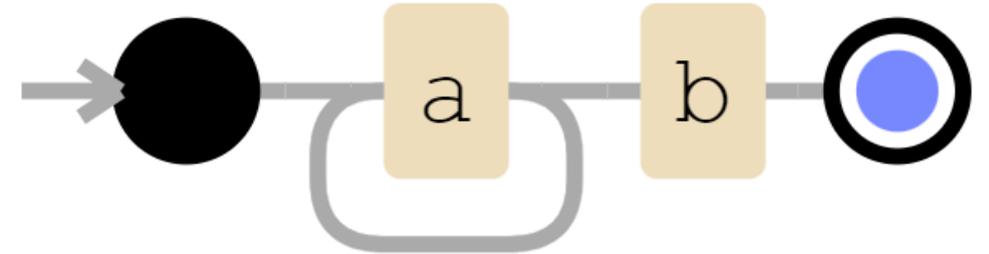


Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	aaa	aaa	Not Found

Рассмотрим пример

Регулярное выражение: a^+b

Последовательность для разбора: aaa

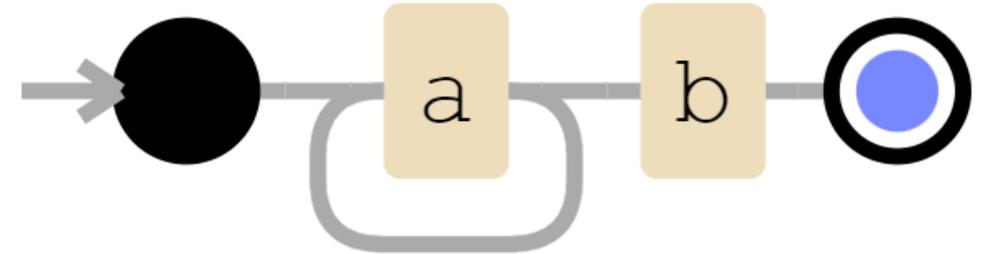


Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	aaa	aaa	Not Found
2	aaa	aa	Not Found

Рассмотрим пример

Регулярное выражение: a^+b

Последовательность для разбора: aaa

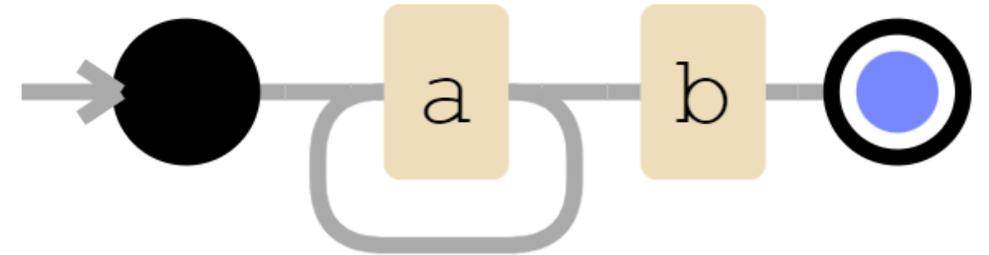


Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	aaa	aaa	Not Found
2	aaa	aa	Not Found
3	aaa	a	Not Found

Рассмотрим пример

Регулярное выражение: a^+b

Последовательность для разбора: `aaa`

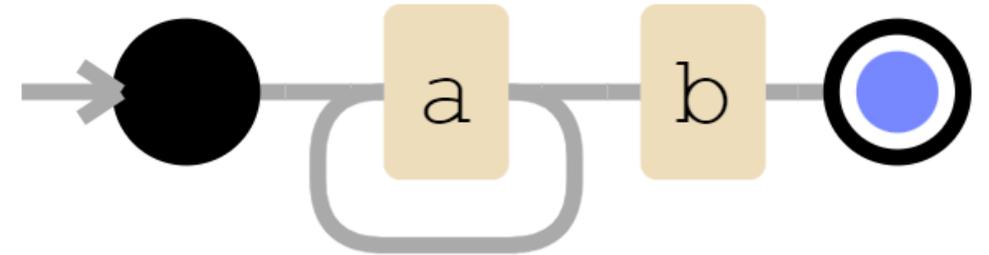


Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	<code>aaa</code>	<code>aaa</code>	Not Found
2	<code>aaa</code>	<code>aa</code>	Not Found
3	<code>aaa</code>	<code>a</code>	Not Found
4	<code>aaa</code>	<code>aa</code>	Not Found

Рассмотрим пример

Регулярное выражение: a^+b

Последовательность для разбора: aaa

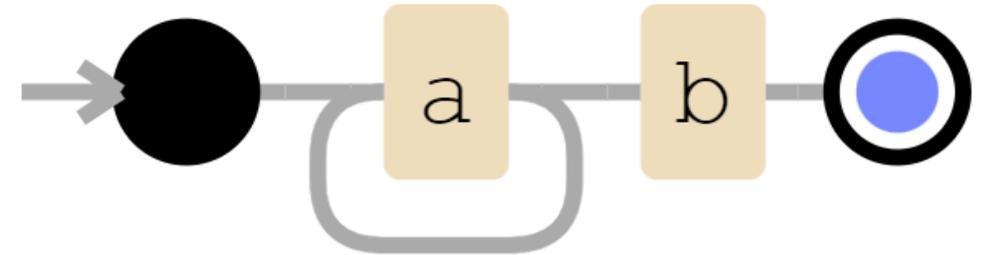


Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	aaa	aaa	Not Found
2	aaa	aa	Not Found
3	aaa	a	Not Found
4	a aa	aa	Not Found
5	a aa	a	Not Found

Рассмотрим пример

Регулярное выражение: a^+b

Последовательность для разбора: aaa

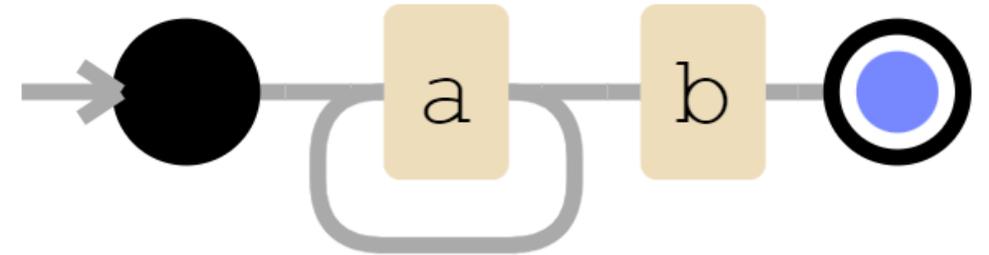


Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	aaa	aaa	Not Found
2	aaa	aa	Not Found
3	aaa	a	Not Found
4	a aa	aa	Not Found
5	a aa	a	Not Found
6	a aa	a	Not Found

Рассмотрим пример

Регулярное выражение: a^+b

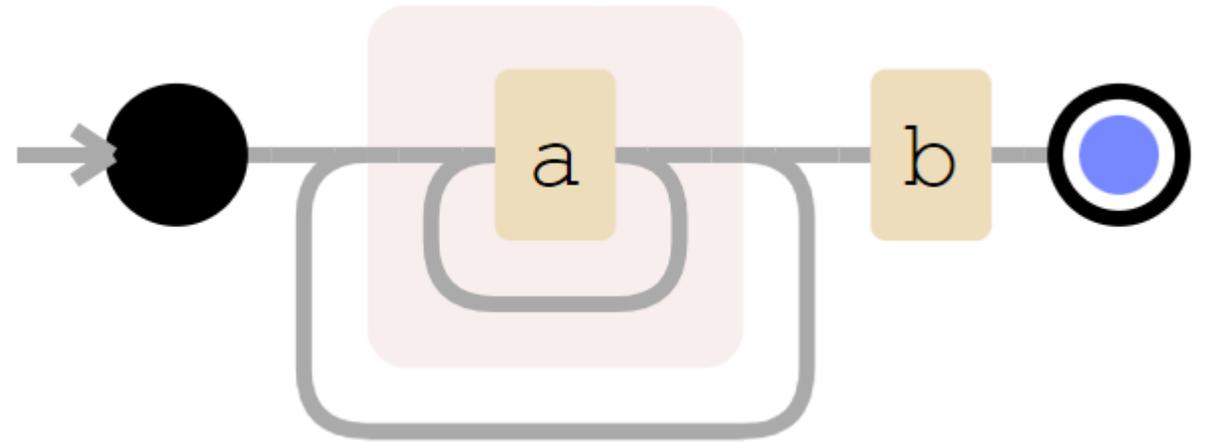
Последовательность для разбора: aaa



Номер шага	Последовательность для разбора	Сопоставление с паттерном a^+	Сопоставление с паттерном b
1	aaa	aaa	Not Found
2	aaa	aa	Not Found
3	aaa	a	Not Found
4	a aa	aa	Not Found
5	a aa	a	Not Found
6	aa a	a	Not Found
7	aaa	Not Found	Not Found

Рассмотрим пример

Регулярное выражение: $(a^+)+b$



Что изменилось?

- На графе появилась дополнительная петля
- Количество возможных вариантов сопоставления увеличилось
- Увеличилось время, требуемое для разбора последовательности

Или нет?

Сравним два регулярных выражения

a+b

Input strings:

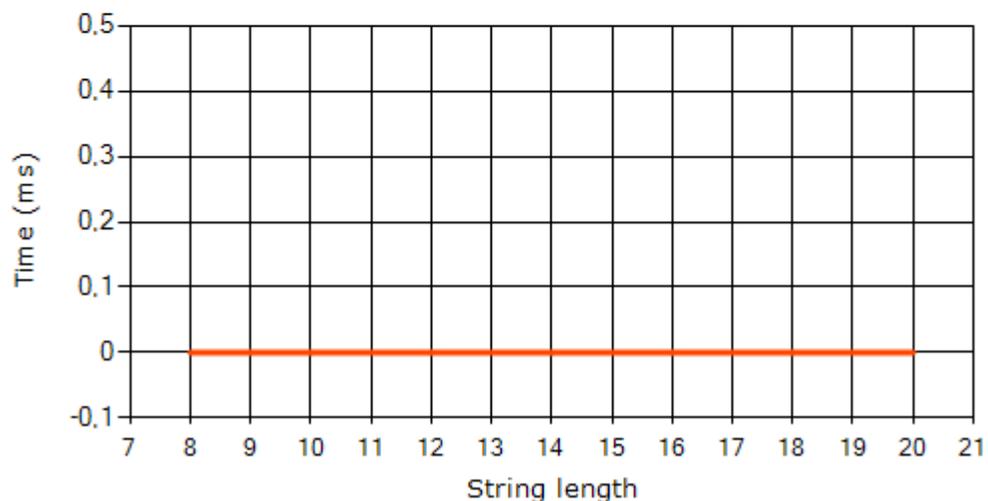
```
aaaaaab  
aaaaaaaaab  
aaaaaaaaaabb  
aaaaaaaaaaaaab  
aaaaaaaaaaaaaaab  
aaaaaaaaaaaaaaaaab  
aaaaaaaaaaaaaaaaaabb  
aaaaaaaaaaaaaaaaaaaaab
```

(a+)+b

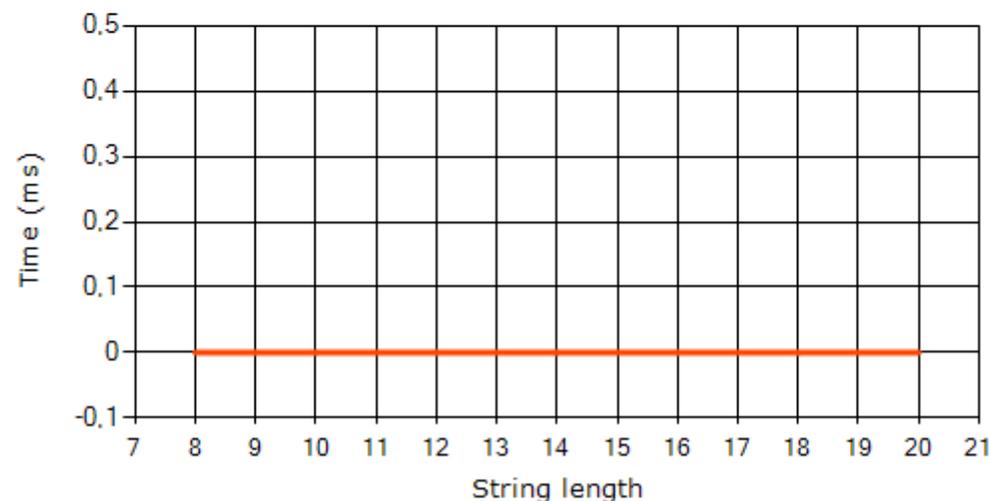
Input strings:

```
aaaaaab  
aaaaaaaaab  
aaaaaaaaaabb  
aaaaaaaaaaaaab  
aaaaaaaaaaaaaaab  
aaaaaaaaaaaaaaaaab  
aaaaaaaaaaaaaaaaaabb  
aaaaaaaaaaaaaaaaaaaaab
```

Effect of input string length on regular expression execution time.



Effect of input string length on regular expression execution time.



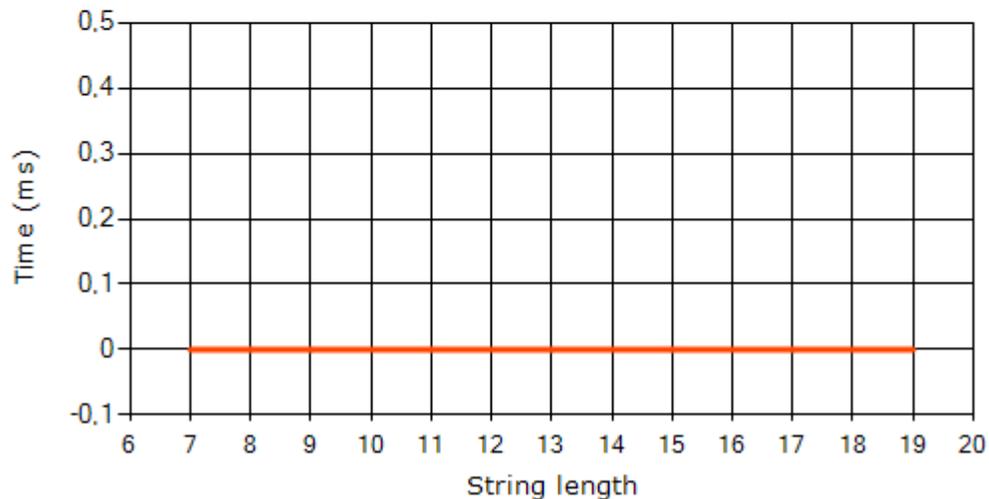
Еще один тест

a+b

Input strings:

```
aaaaaaaa
aaaaaaaaa
aaaaaaaaaa
aaaaaaaaaaa
aaaaaaaaaaaa
aaaaaaaaaaaaa
aaaaaaaaaaaaaa
aaaaaaaaaaaaaaa
aaaaaaaaaaaaaaa
```

Effect of input string length on regular expression execution time.

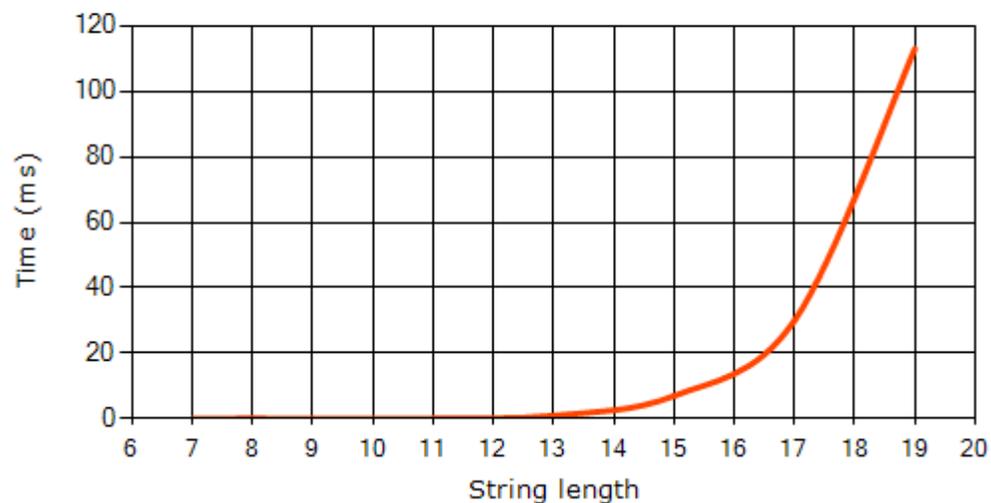


(a+)+b

Input strings:

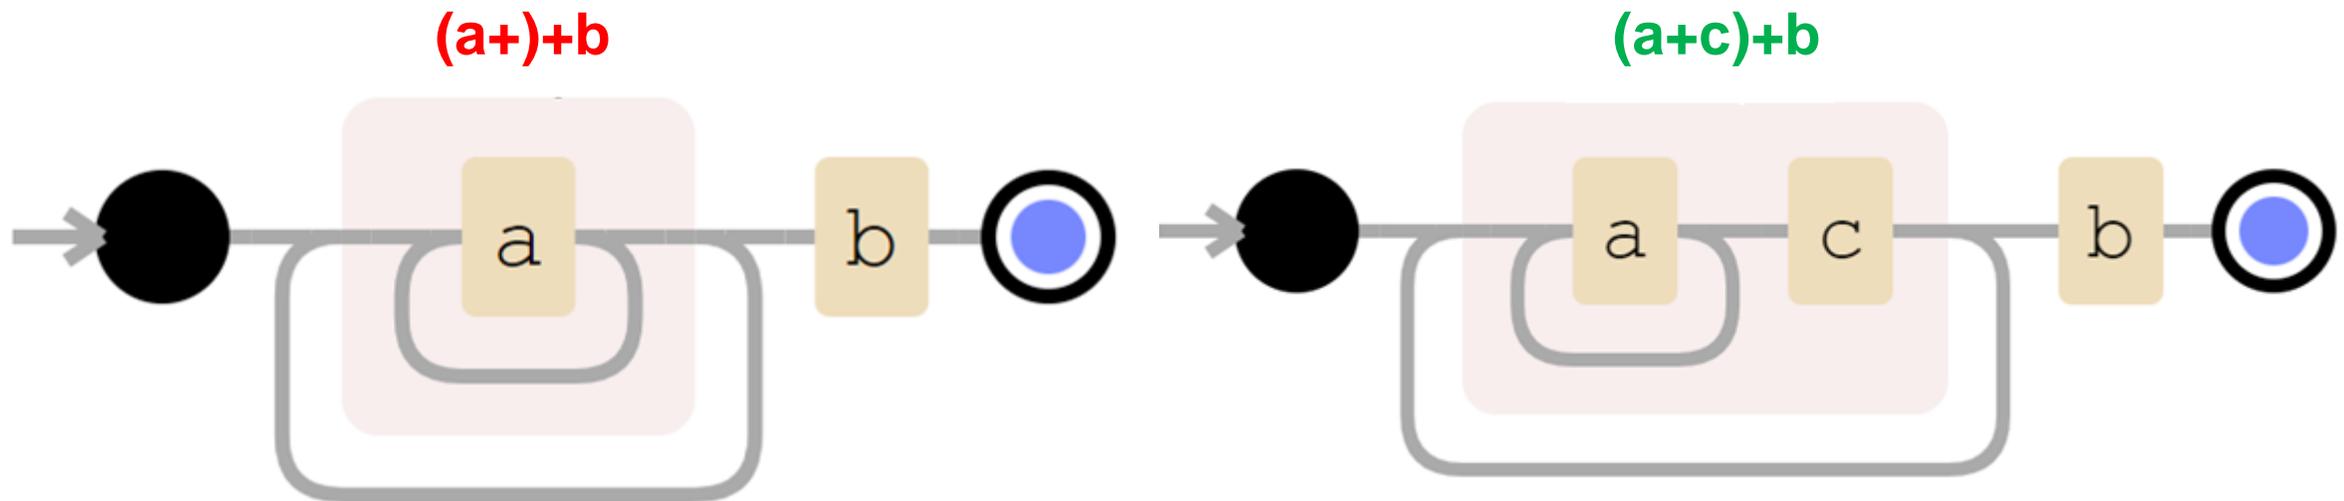
```
aaaaaaaa
aaaaaaaaa
aaaaaaaaaa
aaaaaaaaaaa
aaaaaaaaaaaa
aaaaaaaaaaaaa
aaaaaaaaaaaaaa
aaaaaaaaaaaaaaa
aaaaaaaaaaaaaaa
```

Effect of input string length on regular expression execution time.



Катастрофический возврат

- Существует два подвыражения, при этом одно из них включено в другое и к каждому из них применяется один из следующих кванторов: '*', '+', '*?', '+?', '{...}'
- Существует такая строка, которую можно было бы сопоставить с обоими этими подвыражениями



Уязвимости на реальных проектах

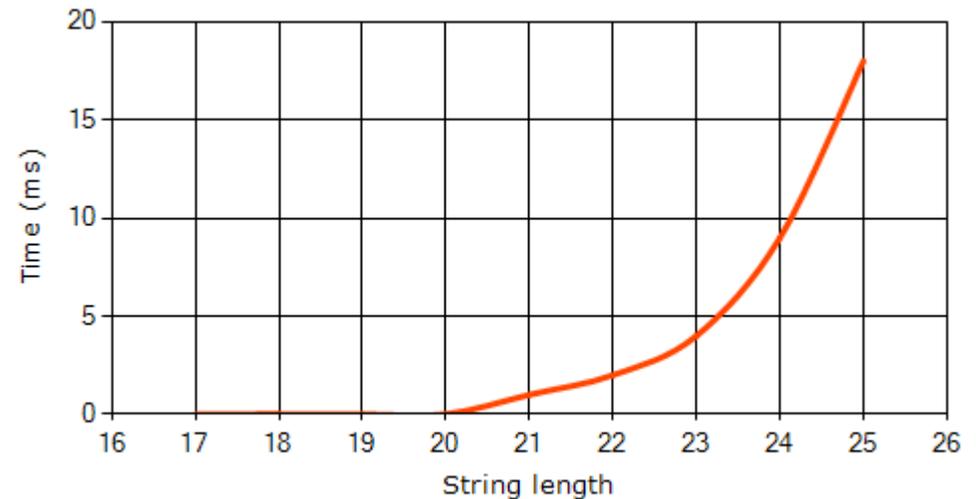
RestSharp

- CVE-2021-27293
- Regex: `newDate\((-?\d+)*\)`
- *Ищем строку формата:*
`newDate(10-01-2007)`

Input strings:

```
newDate(1111111111  
newDate(1111111112  
newDate(11111111133  
newDate(111111111444  
newDate(1111111115555  
newDate(11111111166666  
newDate(111111111777777  
newDate(1111111118888888  
newDate(11111111199999999
```

Effect of input string length on regular expression execution time.



System.ComponentModel.DataAnnotations

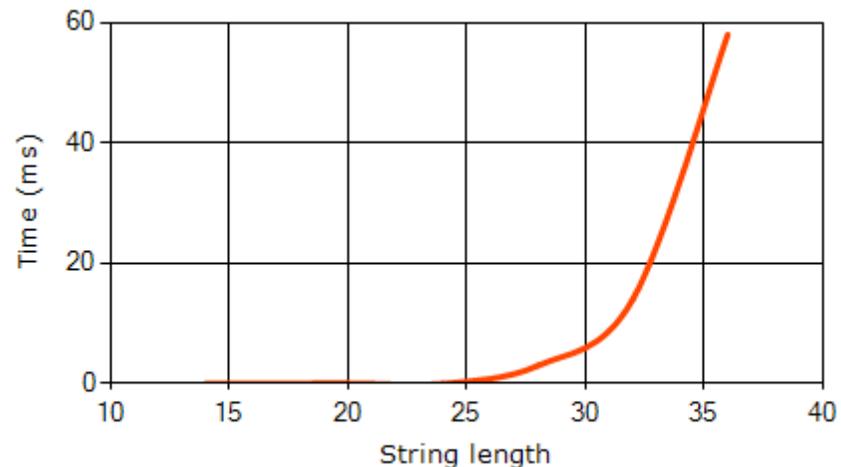
- CVE-2015-2526
- Классы EmailAddressAttribute и PhoneAttribute
- Попытка валидации email и номера телефона

email validation

Input strings:

```
t@t.t.t.t.c%20  
t@t.t.t.t.t.t.c%20  
t@t.t.t.t.t.t.t.c%20  
t@t.t.t.t.t.t.t.t.c%20  
t@t.t.t.t.t.t.t.t.t.c%20  
t@t.t.t.t.t.t.t.t.t.t.c%20
```

Effect of input string length on regular expression execution time.

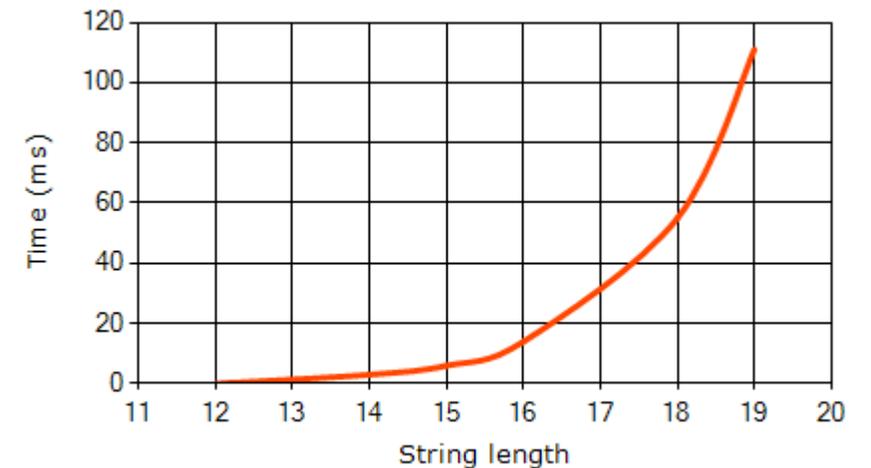


phone validation

Input strings:

```
66666666666d  
6666666666666d  
66666666666666d  
666666666666666d  
6666666666666666d  
6666666666666666d
```

Effect of input string length on regular expression execution time.



ReDoS вне C# кода

- **Cloudflare (2019)**

WAF правило содержало опасное регулярное выражение

- **Stack Overflow (2016)**

DOS в результате обработки опасным регулярным выражением вопроса, содержащего 20 000 символов пробела

🔍 Search Results [\(Refine Search\)](#)

Search Parameters:

- Results Type: Overview
- Keyword (text search): regular expression denial of service
- Search Type: Search All
- CPE Name Search: false

There are **316** matching records.
Displaying matches **301** through **316**.

Из них за:

- 2021: 66 уязвимостей
- 2022: 57 уязвимостей

Что делать, если у нас ReDoS?

Что делать, если у нас ReDoS?

- Используйте другое регулярное выражение
- Замените регулярное выражение рукописным обработчиком
- Разбивайте регулярные выражения
- Проверяйте источник данных. Не всем данным стоит доверять
- Будьте внимательнее к сгенерированным в runtime и основанным на пользовательском вводе регулярным выражениям

Пример ReDoS via injection

```
String login = loginTB.Text;
String password = passwordTB.Text;
Regex testPassword = new Regex(login);
Match match = testPassword.Match(password);
if (match.Success)
{
    MessageBox.Show("Don't include login in password.");
}
else
{
    MessageBox.Show("Good password.");
}
```

Пользовательский ввод:

login: (a*)*b

password: аааааааааааааааа!

Результат – ReDoS!

Что делать, если у нас ReDoS?

- Используйте другое регулярное выражение
- Замените регулярное выражение рукописным обработчиком
- Разбивайте регулярные выражения
- Проверяйте источник данных. Не всем данным стоит доверять
- Будьте внимательнее к сгенерированным в runtime и основанным на пользовательском вводе регулярным выражениям
- Используйте timeout

Используйте timeout

Третий аргумент конструктора регулярных выражений – `matchTimeout`

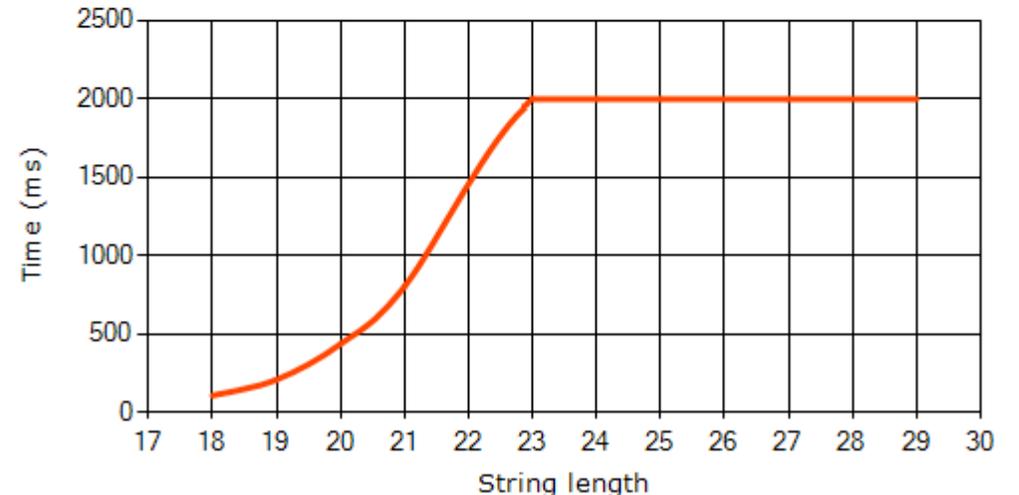
В случае превышения времени разбора выбросит `RegexMatchTimeoutException`

```
Regex regex = new Regex("(a*)*b",  
                        RegexOptions.None,  
                        TimeSpan.FromSeconds(2));
```

Input strings:

```
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa  
aaaaaaaaaaaaaaaaaaaa
```

Effect of input string length on regular expression execution time.



Что делать, если у нас ReDoS?

- Используйте другое регулярное выражение
- Замените регулярное выражение рукописным обработчиком
- Разбивайте регулярные выражения
- Проверяйте источник данных. Не всем данным стоит доверять
- Обратите внимание на сгенерированные в runtime и основанные на пользовательском вводе регулярным выражениям
- Используйте timeout
- Используйте атомарные группы

Используйте атомарные группы

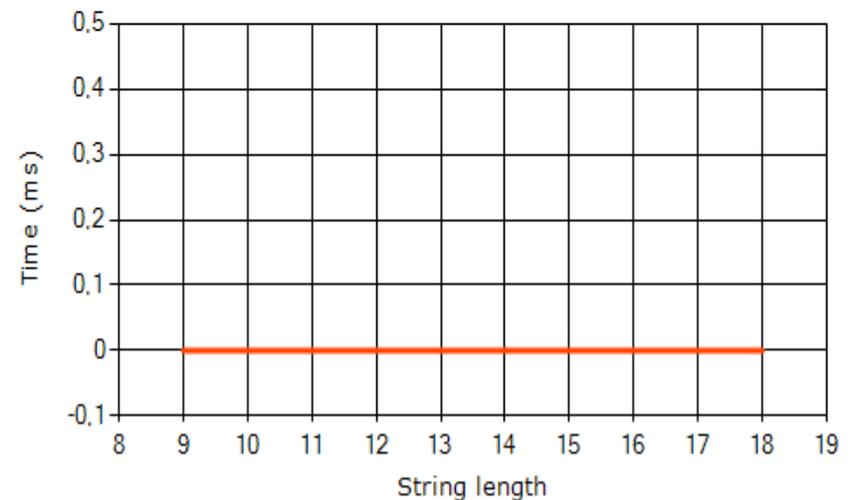
- Синтаксис определения атомарных групп:
(?>...)
- Для выражения внутри отключается функция обратного отслеживания
- Внимание! Использование атомарных групп меняет логику обработки соответствий

(?>a*)*b

Input strings:

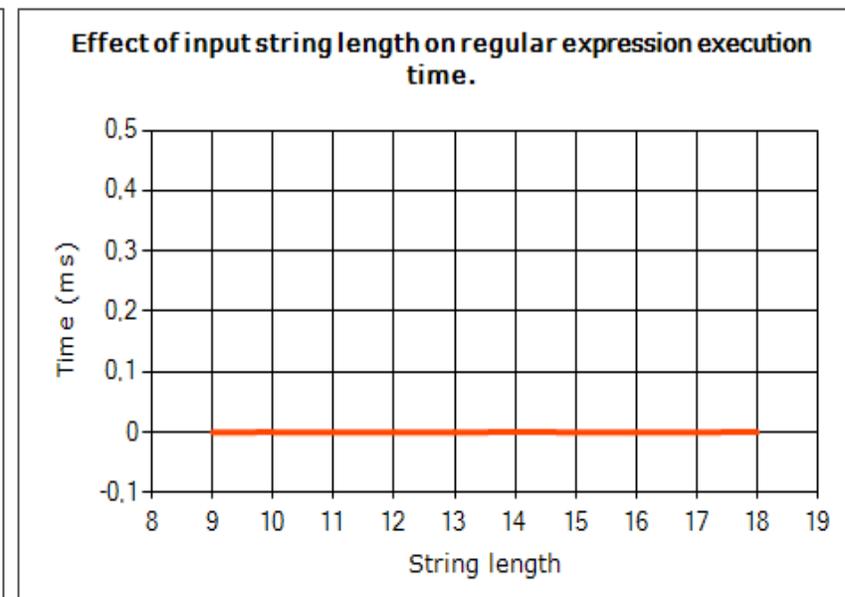
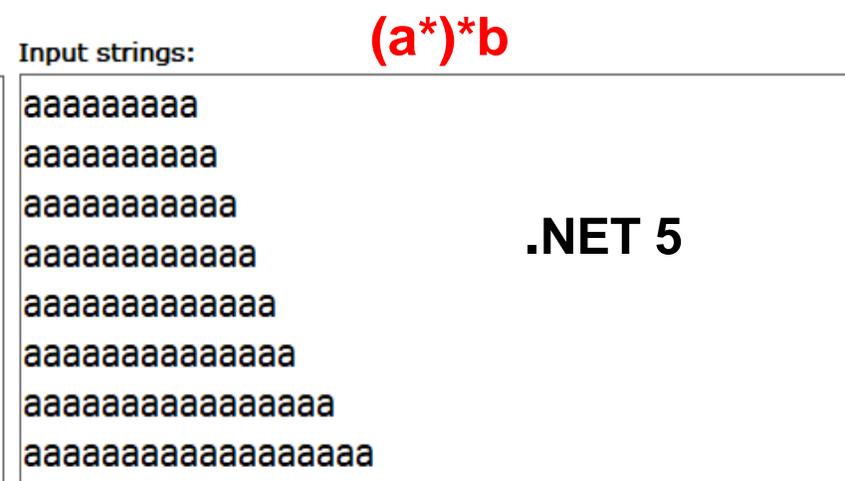
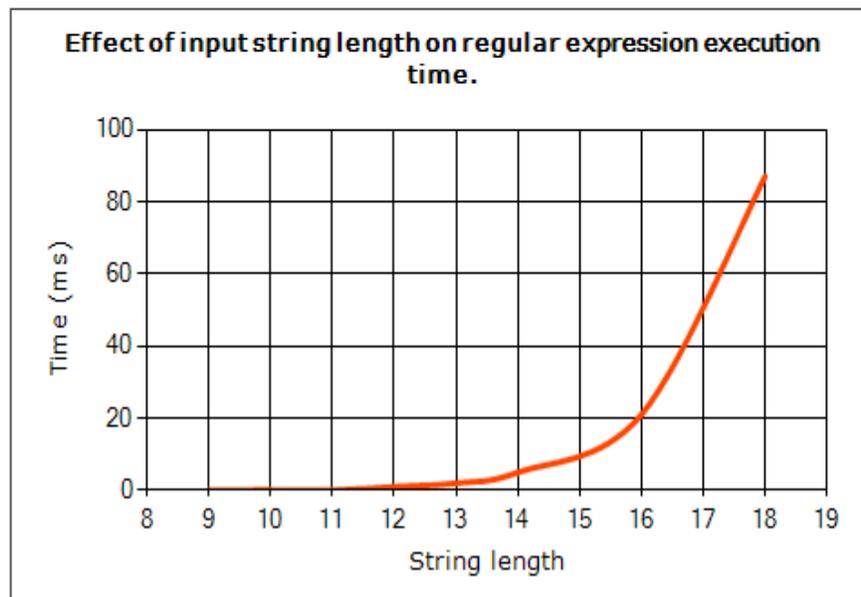
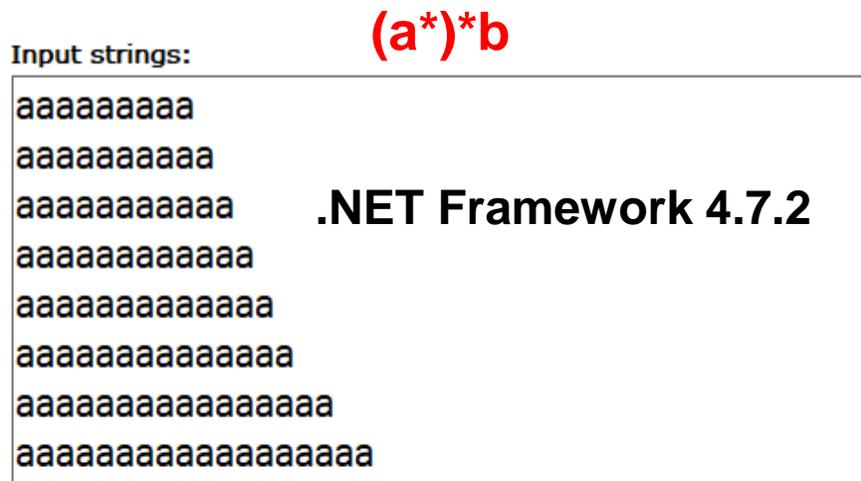
```
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
aaaaaaaaa
```

Effect of input string length on regular expression execution time.



В чем разница?

- Два одинаковых регулярных выражения
- Одинаковые входные данные
- Абсолютно одинаковый код
- Не фотошоп!



Что делать, если у нас ReDoS?

- Используйте другое регулярное выражение
- Замените регулярное выражение рукописным обработчиком
- Разбивайте регулярные выражения
- Проверяйте источник данных. Не всем данным стоит доверять
- Обратите внимание на сгенерированные в runtime и основанные на пользовательском вводе регулярным выражениям
- Используйте timeout
- Используйте атомарные группы
- Используйте новые версии .NET
- Используйте движок Regex на основе DFA

DFA Regex engine

В .NET 7 вы можете указать флаг `RegexOptions.NonBacktracking`

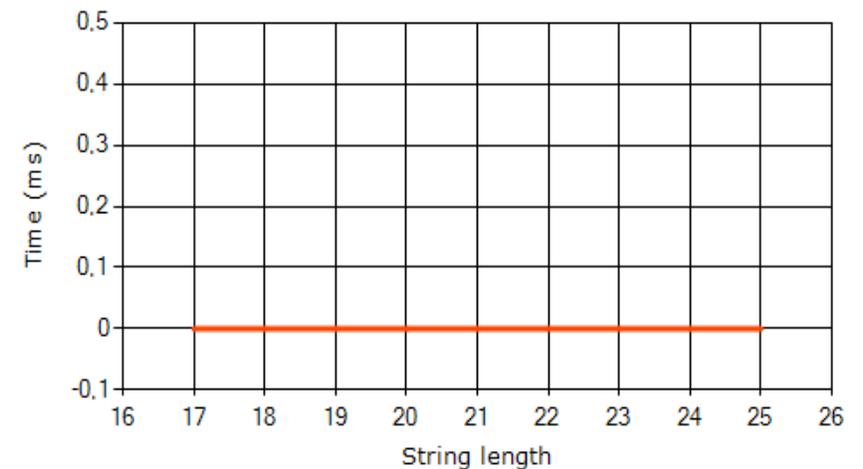
```
Regex regex = new Regex(@"newDate\((-?\d+)*\)",  
                        RegexOptions.NonBacktracking);
```

В таком случае для разбора будет использован основанный на DFA движок регулярных выражений

Input strings:

```
newDate(111111111  
newDate(1111111112  
newDate(11111111133  
newDate(111111111444  
newDate(1111111115555  
newDate(11111111166666  
newDate(111111111777777  
newDate(1111111118888888  
newDate(11111111199999999
```

Effect of input string length on regular expression execution time.



Резюмируем

- Используйте другое регулярное выражение
- Замените регулярное выражение рукописным обработчиком
- Разбивайте регулярные выражения
- Проверяйте источник данных. Не всем данным стоит доверять
- Обратите внимание на сгенерированные в runtime и основанные на пользовательском вводе регулярным выражениям
- Используйте timeout
- Используйте атомарные группы
- Используйте новые версии .NET
- Используйте движок Regex на основе DFA

Профилактика ReDoS уязвимости

Профилактика ReDoS уязвимости

- Уделяйте время проверке чужих регулярных выражений

Доверяй, но проверяй

Regular Expression Details

Title **RegEx for email validation**

Expression `/^([a-zA-Z0-9])(([\-]|[_]+)?([a-zA-Z0-9]+))*(@){1}[a-z0-9]+[.]{1}([a-z]{2,3})|([a-z]{2,3}[.]{1}[a-z]{2,3})$/`

Description This expression will validate all possible formats except if web site URL contains hyphen characters like aa@a-b-c.com. I will include this feature also in next version.

Matches a@abc.com,a@abc.co.in,aa.bb@abc.com.sg,aa_bb@abc.biz,aa.C.bb@abc.com,aa_1900@abc.co.in

Non-Matches @abc.com,a@abc.co.in.in,a@abc.com.in.in,a@a-b-c.com

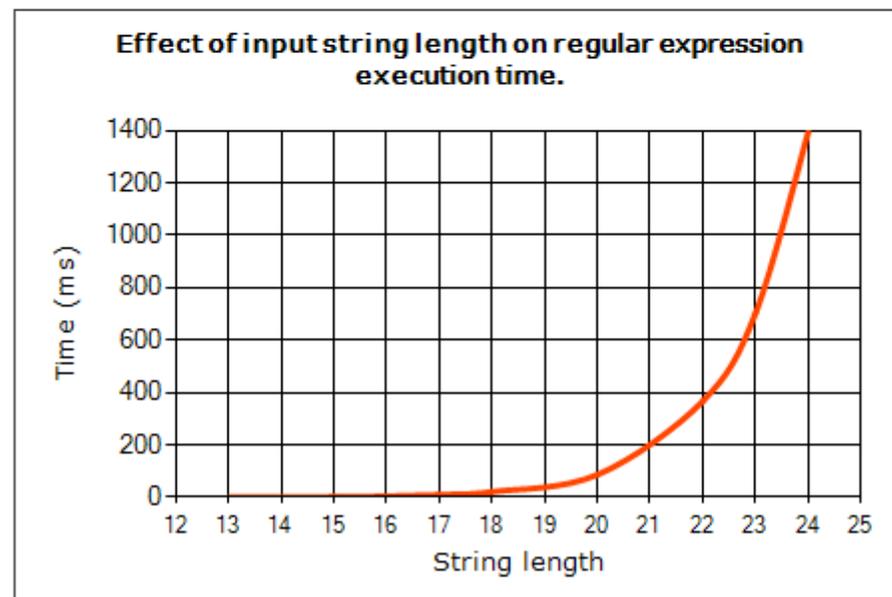
Author **Rafiq** **Rating:**

Source Email

Your Rating **Bad** 1 2 3 4 5 **Good**

Input strings:

```
aaaaaaaaaaaaa!  
aaaaaaaaaaaaaaa!  
aaaaaaaaaaaaaaaaa!  
aaaaaaaaaaaaaaaaaaa!  
aaaaaaaaaaaaaaaaaaaaa!  
aaaaaaaaaaaaaaaaaaaaaa!  
aaaaaaaaaaaaaaaaaaaaaaa!  
aaaaaaaaaaaaaaaaaaaaaaa!
```



Профилактика ReDoS уязвимости

- Уделяйте время проверке чужих регулярных выражений
- Используйте утилиты для проверки безопасности регулярных выражений
- Обновляйте уязвимые зависимости
- Используйте SAST решения для анализа кода



Q&A



pvs-studio.com
avdeev@viva64.com