Технология программировния

Строки

Работа с текстом

В языке C# имеется много различных инструментов для работы с текстом

- Встроенные типы данных – char и string
- Классы из стандартной библиотеки – StringBuilder
- Классы для работы с регулярными выражениями
- Средства LINQ для строк

Отдельные символы

Фреймворк **.NET** содержит специальный класс для работы с отдельными символами – **System.Char**

- Использует **UTF-16** для хранения одной буквы, таким образом символ занимает **2 байта**
- В C# синонимом данного класса является встроенный тип **char**
- Также в языке определены **символьные константы**, задающиеся
  - Символом, заключенным в одинарные кавычки
  - Управляющей последовательностью
  - Unicode-последовательностью

Отдельные символы

```
char ch = 'A';
WriteLine(ch);
ch = '\x5A';
WriteLine(ch);
ch = '\u0058';
WriteLine(ch);
```

Отдельные символы

```
char ch = new Char();
ch = (char)65;
WriteLine(ch);
int code = ch;
WriteLine(code);
string s = ch.ToString() + " = " + code;
WriteLine(s);
```

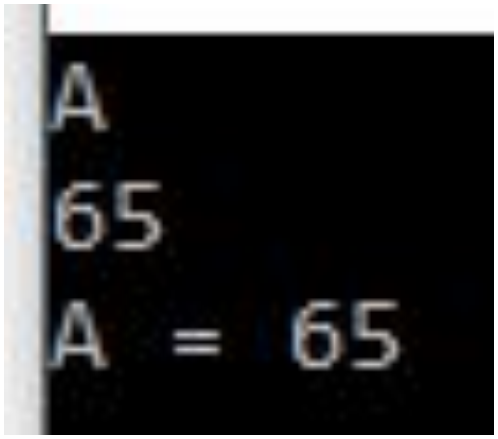

Отдельные символы

Цифры и буквы алфавитов обычно кодируются интервалами:

- **0 - 9** соответствует интервал **[65, 90]**
- **A - Z** соответствует интервал **[65, 90]**
- **a - z** соответствует интервал **[97, 122]**
- **А - Я** соответствует интервал **[1040, 1071]**
- **а - я** соответствует интервал **[1072, 1103]**
- Однако, буквам **Ё** и **ё** присвоены коды **1025** и **1105**

Отдельные символы

Класс char содержит достаточно много собственных методов. Большая часть из них используется для определения типа символа.

- **IsDigit** – проверка на десятичную цифру
- **IsLetter** – проверка на букву
- **IsPunctuation** – проверка на знак препинания
- **IsWhiteSpace** – проверка на пробелы, включая перевод строки и возврат каретки

Отдельные символы

В общем случае тип символа можно получить при помощи метода **GetUnicodeCategory**. Он возвращает одну из категорий, описанных в перечислении **UnicodeCategory** из пространства имен **System.Globalization**.

Отдельные символы

```
WriteLine("GetUnicodeCategory:");
var c1 = char.GetUnicodeCategory('A');
var c2 = char.GetUnicodeCategory(';');
WriteLine("'A' - category {0}", c1);
WriteLine("';' - category {0}", c2);
```

Отдельные символы

```
GetUnicodeCategory:
'A' - category UppercaseLetter
';' - category OtherPunctuation
Метод IsLetter:
'z' - IsLetter - True
'Я' - IsLetter - True
Метод IsControl:
';' - IsControl - False
'\r' - IsControl - True
Метод IsSeparator:
' ' - IsSeparator - True
';' - IsSeparator - False
Метод IsWhiteSpace:
' ' - IsWhiteSpace - True
'\r' - IsWhiteSpace - True
```

Отдельные символы

```
WriteLine("Метод IsLetter:");
WriteLine("'z' - IsLetter - {0}",
          char.IsLetter('z'));
WriteLine("'Я' - IsLetter - {0}",
          char.IsLetter('Я'));

WriteLine("Метод IsControl:");
WriteLine("';' - IsControl - {0}",
          char.IsControl(';'));
WriteLine(@"'\r' - IsControl - {0}",
          char.IsControl('\r'));
```

Отдельные символы

```
WriteLine("Метод IsSeparator:");
WriteLine("' ' - IsSeparator - {0}",
          char.IsSeparator(' '));
WriteLine("';' - IsSeparator - {0}",
          char.IsSeparator(';'));

WriteLine("Метод IsWhiteSpace:");
WriteLine("' ' - IsWhiteSpace - {0}",
          char.IsWhiteSpace(' '));
WriteLine(@"'\r' - IsWhiteSpace - {0}",
          char.IsWhiteSpace('\r'));
```

Отдельные символы

- **ToLower** – приводит символ к нижнему регистру
- **ToUpper** – приводит символ к верхнему регистру
- **CompareTo** – сравнивает два символа и возвращает разницу между их кодами

Массив символов

По аналогии с языками C и C++ мы можем представить строку в виде массива символов. Особого смысла это не имеет, т.к. у нас уже есть тип **string**, но может быть полезно для понимания внутреннего устройства различных классов по обработке текста. Над массивом символов сразу можно выполнять все операции с массивами: **Copy**, **IndexOf**, **LastIndexOf** и т.д.

Массив символов

```
char[] text = new [] {'H','e','l','l','o'};
for (int i = 0; i < text.Length; ++i) {
    if (char.IsLower(text[i])) {
        text[i] = char.ToUpper(text[i]);
    } else {
        text[i] = char.ToLower(text[i]);
    }
}
foreach (var ch in text) {
    Write(ch);
}
WriteLine();
```

Массив символов

Стандартный класс string внутри представлен в виде массива символов. Поэтому у него есть стандартный метод для его получения – **ToCharArray**

```
char[] text = "Hello".ToCharArray();
```

Массив символов

```
static int IndexOf(char[] text1,
                   char[] text2) {
  for (int i = 0; i < text1.Length; ++i) {
      bool isFound = true;
      for (int j = 0; j < text2.Length; ++j) {
          if (i + j >= text1.Length ||
                  text1[i + j] != text2[j]) {
              isFound = false;
              break;
          }
      }
      if (isFound) { return i; }
  } return -1; }
```

Массив символов

```
char[] text1 = "Progress".ToCharArray();
char[] text2 = "ogre".ToCharArray();
int index = IndexOf(text1, text2);
if (index >= 0) {
    for (int i = 0; i < text1.Length; ++i) {
        if (i == index ||
            i == index + text2.Length) {
            Write("|");
        }
        Write(text1[i]);
    }
} else { WriteLine("Не найдено"); }
```

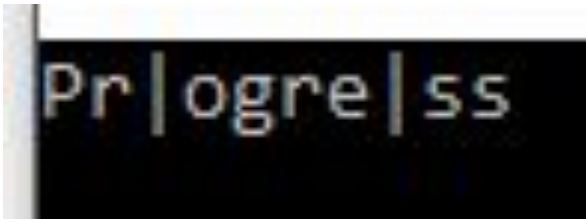

Строки string

Строки можно создавать при помощи строковых констант или конструктора string. Конструктор имеет много вариантов, но наиболее полезными являются:

- Создание строки из символа, повторенного заданное число раз
- Создание строки из массива символов char[]
- Создание строки из части массива символов

Строки string

```
string hello = "Hello";
string separator = new string('-', 5);
char[] array = hello.ToCharArray();
string fromArray = new string(array);
string strye = new string(array, 1, 3);

WriteLine(hello);
WriteLine(separator);
WriteLine(fromArray);
WriteLine(strye);
```

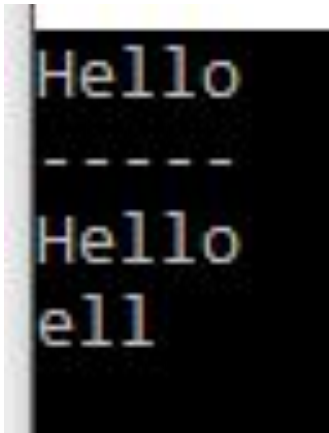

Строки string

В C# существуют два вида строковых констант:

- Обычные константы, которые представляют строку символов, заключенную в кавычки
- Константы с предшествующим знаком @.

Строки string

- Обычные строковые константы могут содержать управляющие последовательности - **\n, \t, \r** и т.д.
- В @-константах все символы трактуются в полном соответствии с их изображением. Символ кавычки внутри строки задается при помощи удвоения символа

Строки string

```
WriteLine("\x50");
WriteLine(@"\x50""");
WriteLine("c:\\folder\\folder\\file.txt");
WriteLine(@"c:\folder\folder\file.txt");
WriteLine("\"A\"");
WriteLine(@""""A""""");
```

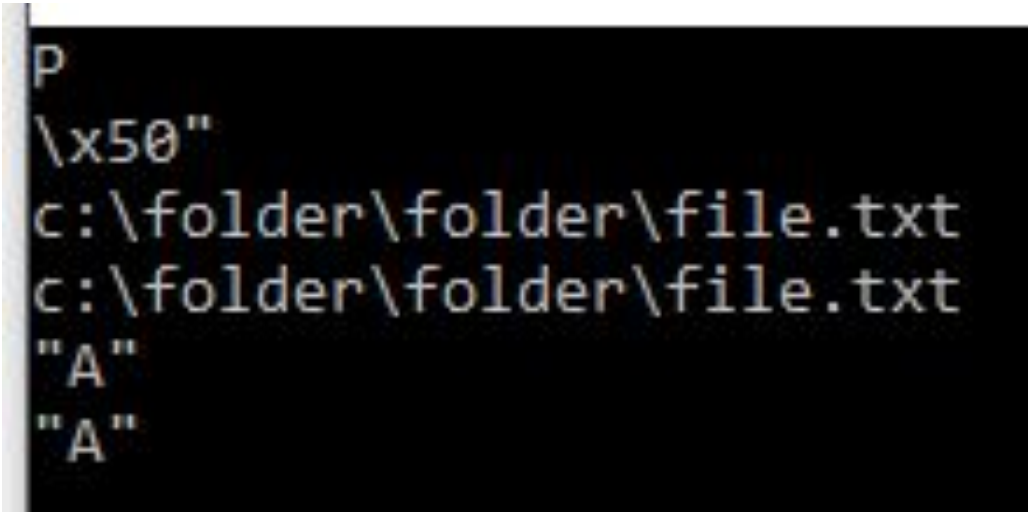

Строки string

Над строками определены следующие операции:

- Присваивание **=**
  Строки являются ссылочным типом. Если есть две строки s1 и s2, то в результате выполнения выражения s2 = s1 произойдет копирование **ссылок** на текст, а не самого текста
- Проверка эквивалентности == и **!=**
- Конкатенация или сцепление строк **+**
- Взятие индекса [ ]
  Индексы доступны **только для чтения**

Строки string

```
string s1 = "ABC", s2 = "DEF";
string s3 = s1 + s2;
string s4 = "ABCDEF";
WriteLine(s3);
WriteLine("s3 == s4 ? {0}", s3 == s4);
WriteLine("s1[2] = {0}", s1[2]);
```

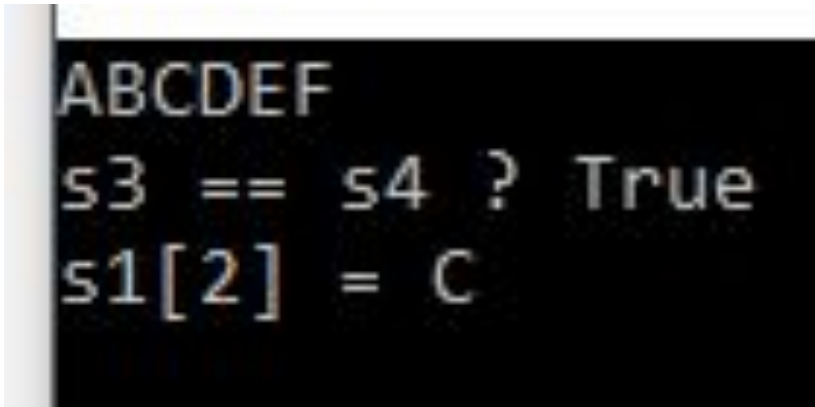

Методы класса string

- **Compare** – сравнение двух строк. Различные варианты метода позволяют сравнивать как строки, так и подстроки. При этом можно учитывать или не учитывать регистр, особенности национального форматирования дат, чисел и т.д.
- **CompareOrdinal** – сравнение двух строк. Сравниваются коды символов

Методы класса string

- **Concat** – конкатенация строк. Допускает сцепление произвольного числа строк
- **Copy** – создается копия строки
- **Format** – выполняет форматирование в соответствии с заданными спецификациями формата *(используется в методе WriteLine, см. первую лекцию)*

Методы класса string

- **Join** – конкатенация массива строк в единую строку. При этом между элементами массива вставляются разделители
- **Split** – осуществляет разделение строки на элементы

Методы класса string

```
var txt = "А это пшеница, которая в темном"

          "чулане хранится," +
          " в доме, который построил
```

```
WriteLine(txt);
```

```
А это пшеница, которая в темном чулане хранится,
в доме, который построил Джек!
```

Методы класса string

```
string[] sentences = txt.Split(',');
for (int i = 0; i < sentences.Length; i++) {
    WriteLine("sentences[{0}] = {1}",
              i, sentences[i]);
}
WriteLine();
```

```
sentences[0] = А это пшеница
sentences[1] =  которая в темном чулане хранится
sentences[2] =  в доме
sentences[3] =  который построил Джек!
```

Методы класса string

```
string join = string.Join(",", sentences);
WriteLine("join = {0}", join);
WriteLine();
```

```
join = А это пшеница, которая в темном чулане хранится,
, в доме, который построил Джек!
```

Методы класса string

```
WriteLine();
string[] words = txt.Split(' ');
for (int i = 0; i < words.Length; i++) {
    WriteLine("words[{0}] = {1}",
              i, words[i]);
}
WriteLine();
```

```
words[0] = А
words[1] = это
words[2] = пшеница,
words[3] = которая
words[4] = в
words[5] = темном
words[6] = чулане
words[7] = хранится,
words[8] = в
words[9] = доме,
words[10] = который
words[11] = построил
words[12] = Джек!
```

Методы класса string

```
join = string.Join(" ", words);
WriteLine("join = {0}", join);
WriteLine();
```

```
join = А это пшеница, которая в темном чулане хранится,
, в доме, который построил Джек!
```

Методы класса string

Методы **Split** и **Join** хорошо работают, когда при разборе используется только один разделитель. В этом случае сборка действительно является обратной операцией и позволяет восстановить исходную строку. Если же при разборе задается некоторое множество разделителей, то возникают две проблемы:

- Невозможно при сборке восстановить строку в прежнем виде, поскольку не сохраняется информация о том, какой из разделителей был использован при разборе строки
- Если при разборе предложения на слова использовать в качестве разделителей пробел и запятую, то запятая исчезнет как часть слова, но взамен появятся пустые слова

Методы класса string

- **Insert** – вставляет подстроку в заданную позицию
- **Remove** – удаляет подстроку в заданной позиции
- **Replace** – заменяет подстроку в заданной позиции на новую подстроку
- **Substring** – выделяет подстроку в заданной позиции

Методы класса string

- **IndexOf, IndexOfAny**, **LastIndexOf, LastIndexOfAny** – определяются индексы первого и последнего вхождения заданной подстроки или любого символа из заданного набора
- **StartsWith, EndsWith** – возвращается true или false, в зависимости от того, начинается или заканчивается строка заданной подстрокой
- **PadLeft, PadRight** – вставляют нужное число пробелов в начале или в конце строки
- **Trim, TrimStart, TrimEnd** – удаляются пробелы в начале или в конце строки

Класс StringBuilder

В языке C# существует понятие **неизменяемый (immutable) класс**. Для такого класса невозможно изменить значение объекта. Методы могут создавать новый объект на основе существующего, но не могут изменить значение существующего объекта.

Класс StringBuilder

К таким **неизменяемым** классам относится и класс **string**. Ни один из методов этого класса не меняет значения существующих объектов. Когда метод изменяет строку, результатом является **новая строка** - новый объект в куче.

При работе со строкой как с массивом разрешено только **чтение** отдельных символов, но не их замена.

Класс StringBuilder

Класс **StringBuilder** позволяет компенсировать этот недостаток. Этот класс принадлежит к изменяемым классам, и его можно найти в пространстве имен **System.Text**

Класс StringBuilder

Специальных констант этого типа не существует, поэтому объекты этого класса объявляются с явным вызовом конструктора класса.

- StringBuilder(string **str**, int **cap**)
  str - начальная строка
  cap - **емкость** объекта
- StringBuilder(int **cur**, int **max**)
  cur – начальная, **max** – максимальная емкость объекта

Класс StringBuilder

- StringBuilder(string **str**, int **start**, int **len**, int **cap**)
  Параметры **str, start, len** задают строку инициализации, **cap** - емкость объекта

Класс StringBuilder

```
var s1 = new StringBuilder("ABC");
var s2 = new StringBuilder("DEF");
var s3 = s2.Insert(0, s1.ToString());
WriteLine(s3);
s3.Remove(3, 3);
WriteLine(s3);
```

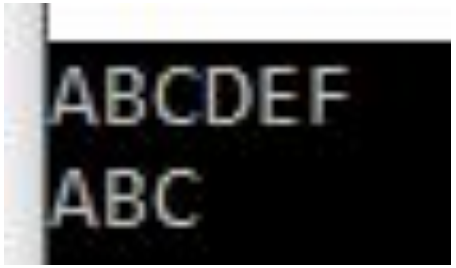

Класс StringBuilder

Операция конкатенации (+) не определена над строками класса StringBuilder, ее роль играет метод **Append**, дописывающий новую строку в хвост уже существующей

Класс StringBuilder

```
var s1 = new StringBuilder("ABC");
var s2 = new StringBuilder("DEF");

var s3 = s1;
s3.Append(s2);
WriteLine(s3);
```

Выполнение этого кода изменит

Класс StringBuilder

```
var s4 = new StringBuilder("Zenon");
WriteLine(s4);
s4[0] = 'L';
WriteLine(s4);
```

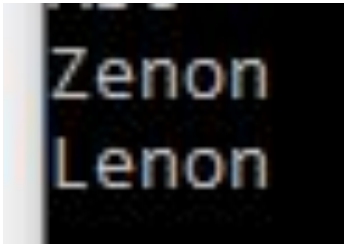

Класс StringBuilder

- **Capacity** - возвращает или устанавливает текущую емкость буфера
- **MaxCapacity** - возвращает максимальную емкость буфера. Результат один и тот же для всех экземпляров класса
- int **EnsureCapacity**(int capacity) - если текущая емкость меньше, то она увеличивается до значения capacity, иначе не изменяется. Максимум текущей емкости и capacity возвращается в качестве результата работы метода.

Класс StringBuilder

```
var s1 = new StringBuilder(10, 100);
WriteLine("s1: capacity = {0}, max = {1}",
          s1.Capacity, s1.MaxCapacity);

s1.Append("123");

WriteLine("s1: capacity = {0}, max = {1}",
          s1.Capacity, s1.MaxCapacity);
```

```
s1: capacity = 10, max = 100
s1: capacity = 10, max = 100
s2: capacity = 16, max = 2147483647
s2: capacity = 20, max = 2147483647
```

Класс StringBuilder

```
var s2 = new StringBuilder("Hello");
WriteLine("s2: capacity = {0}, max = {1}",
          s2.Capacity, s2.MaxCapacity);

s2.EnsureCapacity(20);

WriteLine("s2: capacity = {0}, max = {1}",
          s2.Capacity, s2.MaxCapacity);
```

```
s1: capacity = 10, max = 100
s1: capacity = 10, max = 100
s2: capacity = 16, max = 2147483647
s2: capacity = 20, max = 2147483647
```

Класс StringBuilder

```
for (int i = 0; i < 1000; ++i) {
    s1.Append("4");
}
```

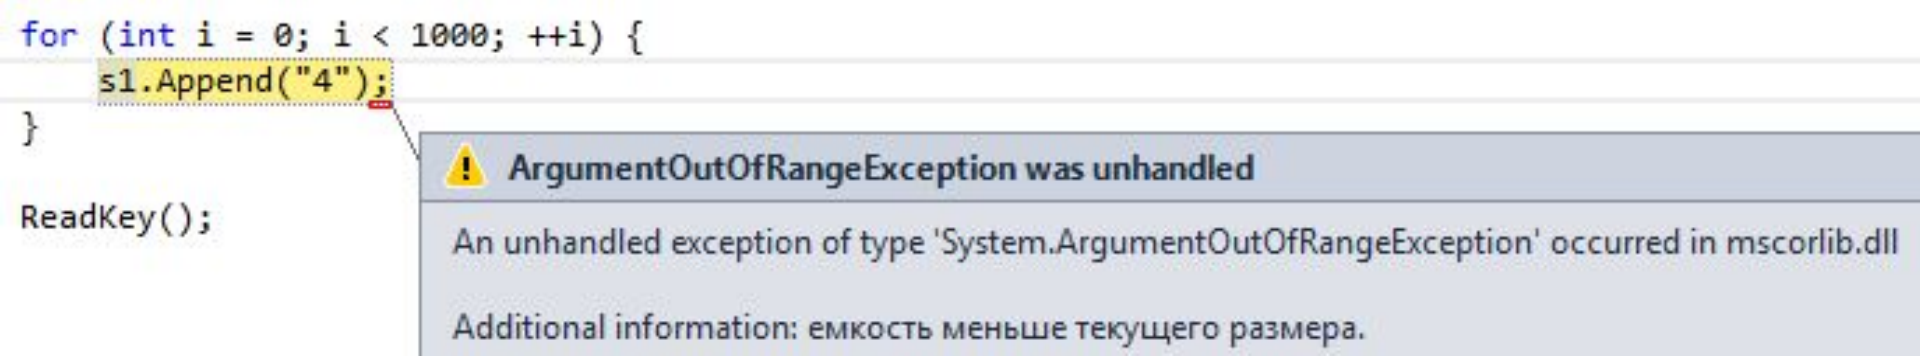

LINQ и строки

Библиотека LINQ также может быть использована для обработки текста.

Это достигается за счет того, что строка текста может быть представлена в виде массива, что и позволяет использовать любые запросы по их обработке.

LINQ и строки

```
string aString = "ABCDE99F-J74-12-89A";

IEnumerable<char> stringQuery =
    from ch in aString
    where Char.IsDigit(ch)
    select ch;

foreach (char c in stringQuery) {
    Write(c + " ");
}
```

LINQ и строки

```
int count = stringQuery.Count();
WriteLine("Count = {0}", count);
```

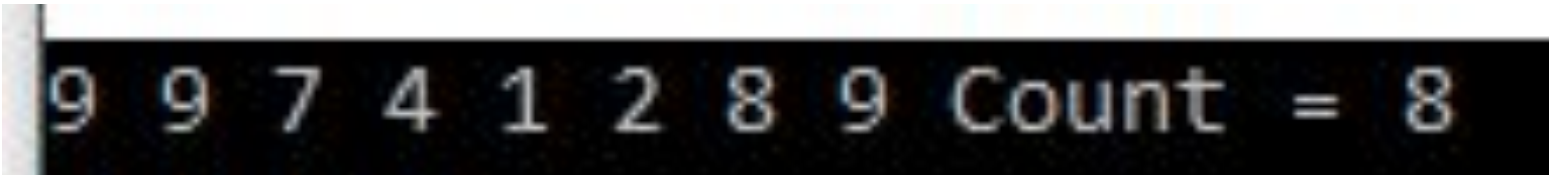

LINQ и строки

```
string text = @"Historically, the world of data and the world of objects"
 + @" have not been well integrated. Programmers work in C# or Visual Basic"
 + @" and also in SQL or XQuery. On the one side are concepts such as classes,"
 + @" objects, fields, inheritance, and .NET Framework APIs. On the other side"
 + @" are tables, columns, rows, nodes, and separate languages for dealing with"
 + @" them. Data types often require translation between the two worlds; there are"
 + @" different standard functions. Because the object world has no notion of query, a"
 + @" query can only be represented as a string without compile-time type checking or"
 + @" IntelliSense support in the IDE. Transferring data from SQL tables or XML trees to"
 + @" objects in memory is often tedious and error-prone.";
```

LINQ и строки

Пример: подсчитать количество слов “data” в тексте.

```
string searchTerm = "data";

string[] source = text.Split(
    new char[] {'.','?','!',' ',';',':',','},
    StringSplitOptions.RemoveEmptyEntries);
```

LINQ и строки

```
var matchQuery =
    from word in source
    where word.ToLowerInvariant() ==
          searchTerm.ToLowerInvariant()
    select word;
```

LINQ и строки

```
int wordCount = matchQuery.Count();
WriteLine("{0} occurrences(s) of the search" +
          " term \"{1}\" were found.",
          wordCount, searchTerm);
```

```
3 occurrences(s) of the search term "data" were found.
```

LINQ и строки

Пример: найти в тексте строку с заданными словами.

- **Distinct** – возвращает не повторяющиеся элементы последовательности
- **Intersect** – вычисляет пересечение двух массивов

LINQ и строки

```
string[] sentences = text.Split(
    new char[] { '.', '?', '!' }
);

string[] wordsToMatch = {
    "Historically", "data", "integrated"
};
```

LINQ и строки

```
var sentenceQuery =
    from sentence in sentences
    let w = sentence.Split(
        new char[] {
            '.','?','!',' ',';',':',','
        },
        StringSplitOptions.RemoveEmptyEntries)
    where w.Distinct()
            .Intersect(wordsToMatch)
            .Count() == wordsToMatch.Count()
    select sentence;
```

LINQ и строки

```
foreach (string str in sentenceQuery) {
    WriteLine(str);
}
```

```
Historically, the world of data and the world of
objects have not been well integrated
```