

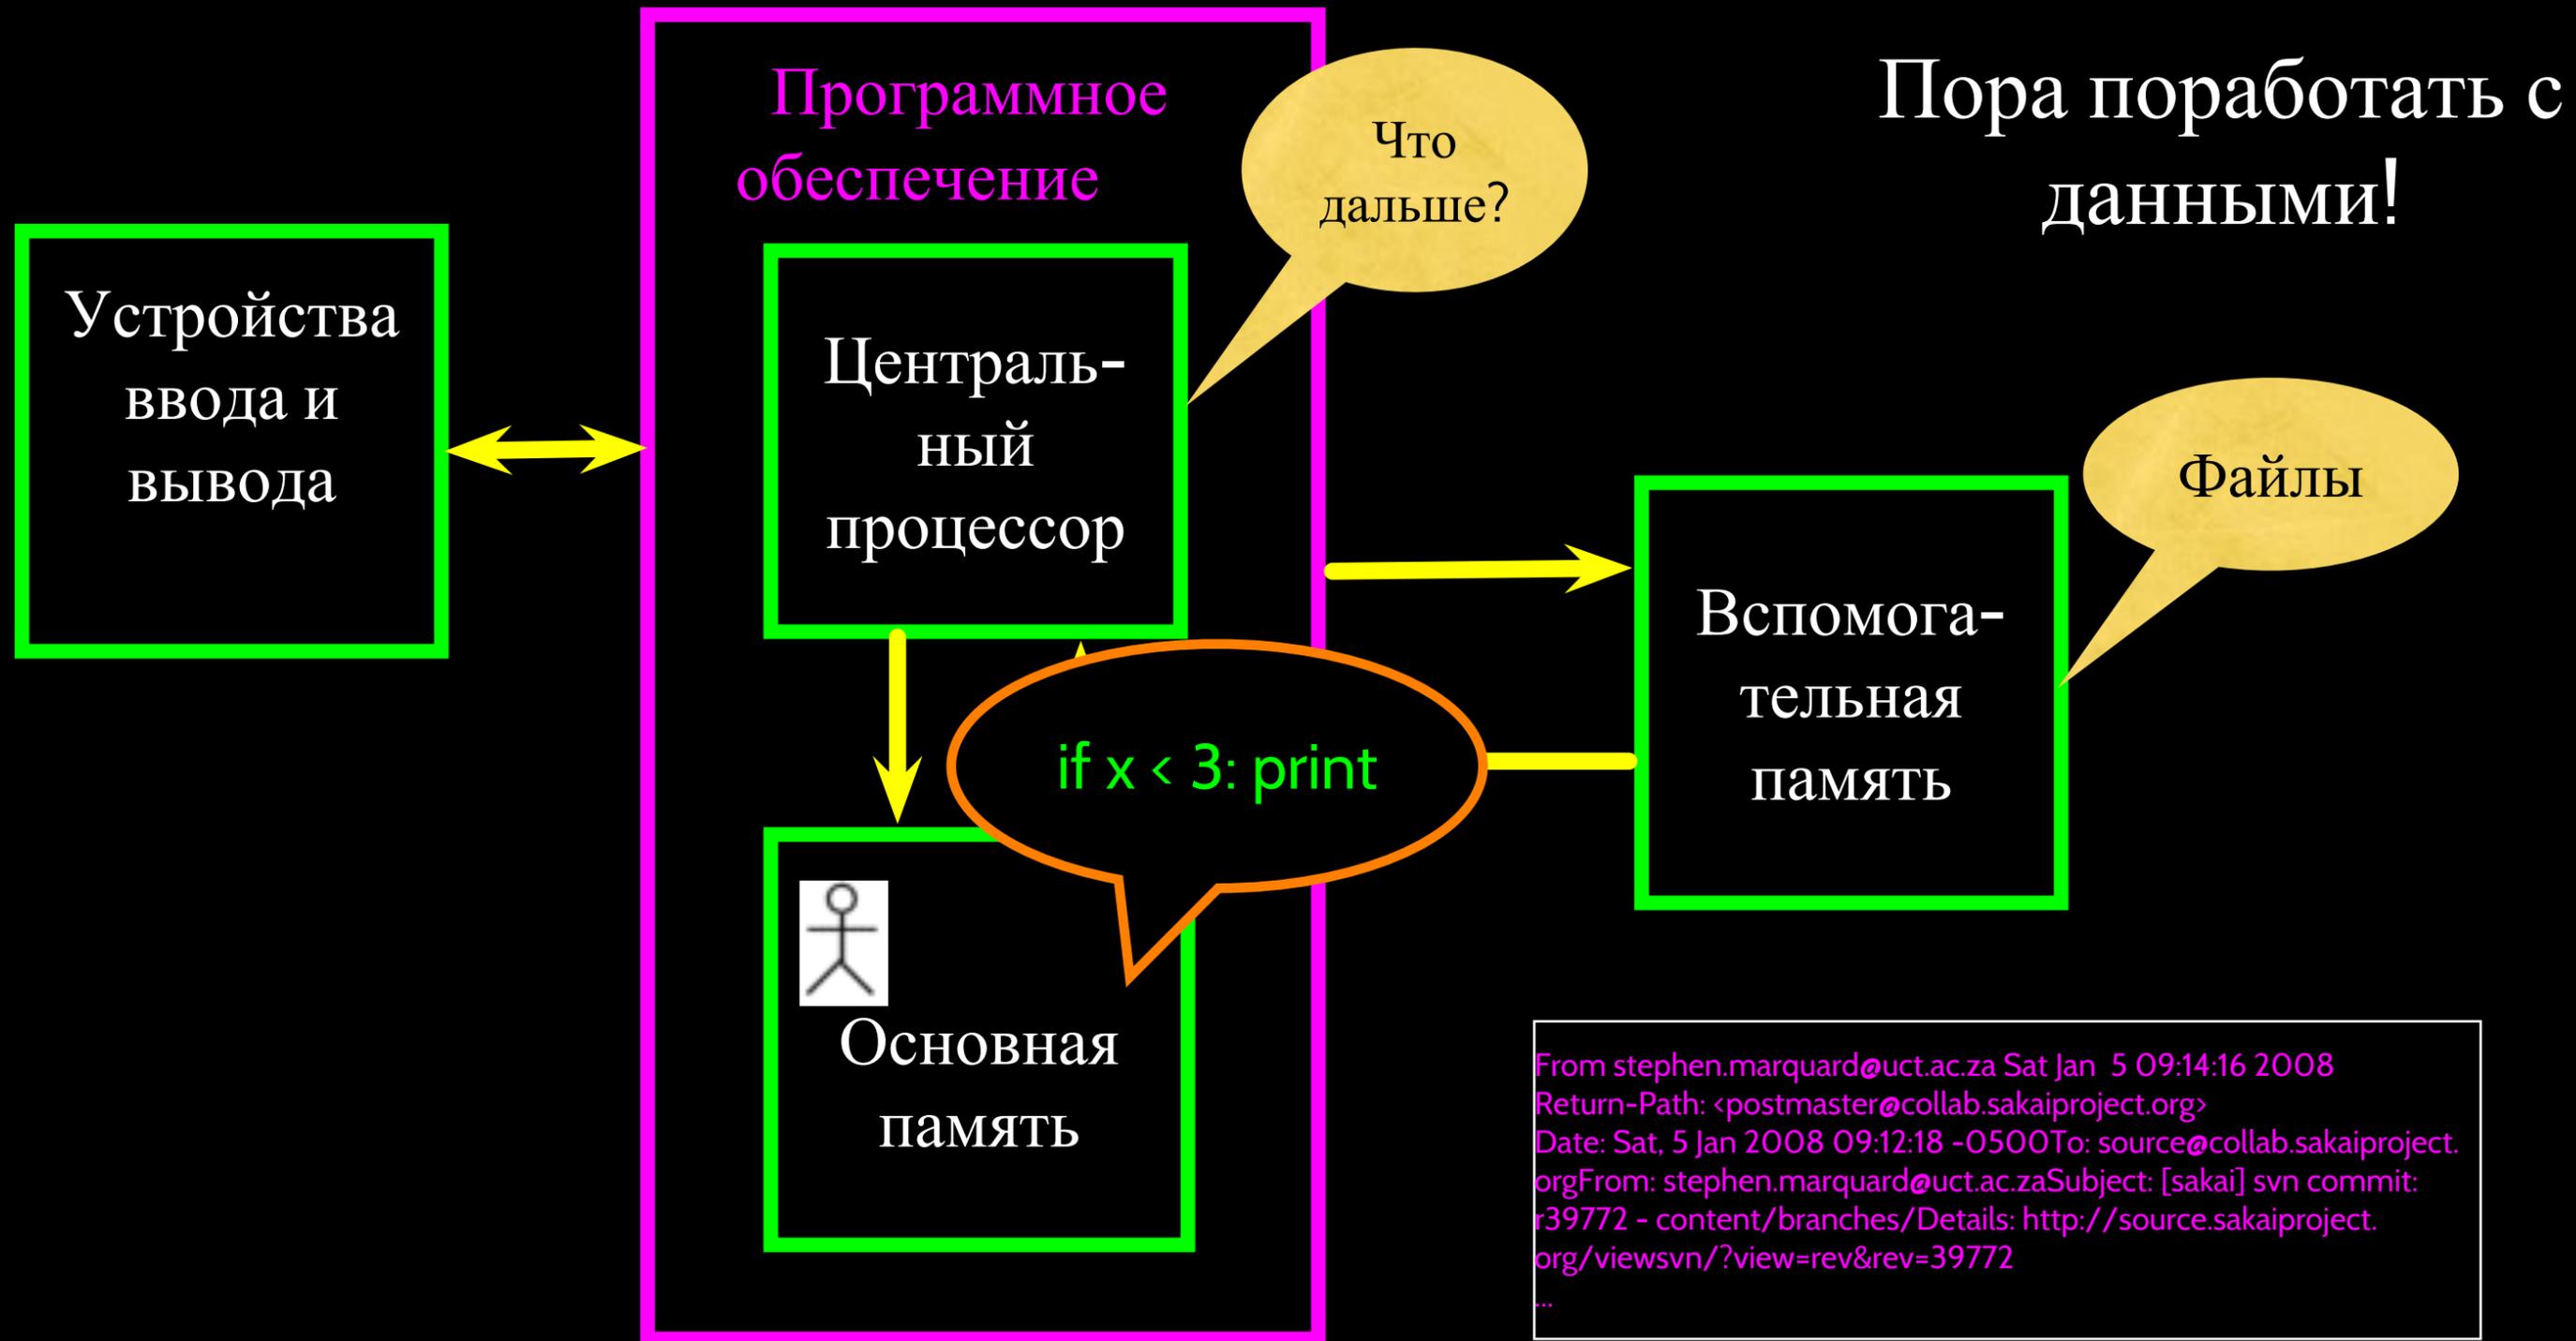
# Чтение из файлов

## Глава 7



Python for Informatics: Exploring Information  
[www.pythonlearn.com](http://www.pythonlearn.com)





# Разбор файлов

- Текстовый файл можно представить как последовательность строк

From stephen.marquard@uct.ac.za Sat Jan 5 09:14:16 2008

Return-Path: <postmaster@collab.sakaiproject.org>

Date: Sat, 5 Jan 2008 09:12:18 -0500

To: source@collab.sakaiproject.org

From: stephen.marquard@uct.ac.za

Subject: [sakai] svn commit: r39772 - content/branches/

Details: <http://source.sakaiproject.org/viewsvn/?view=rev&rev=39772>

<http://www.py4inf.com/code/mbox-short.txt>

# Открытие файла

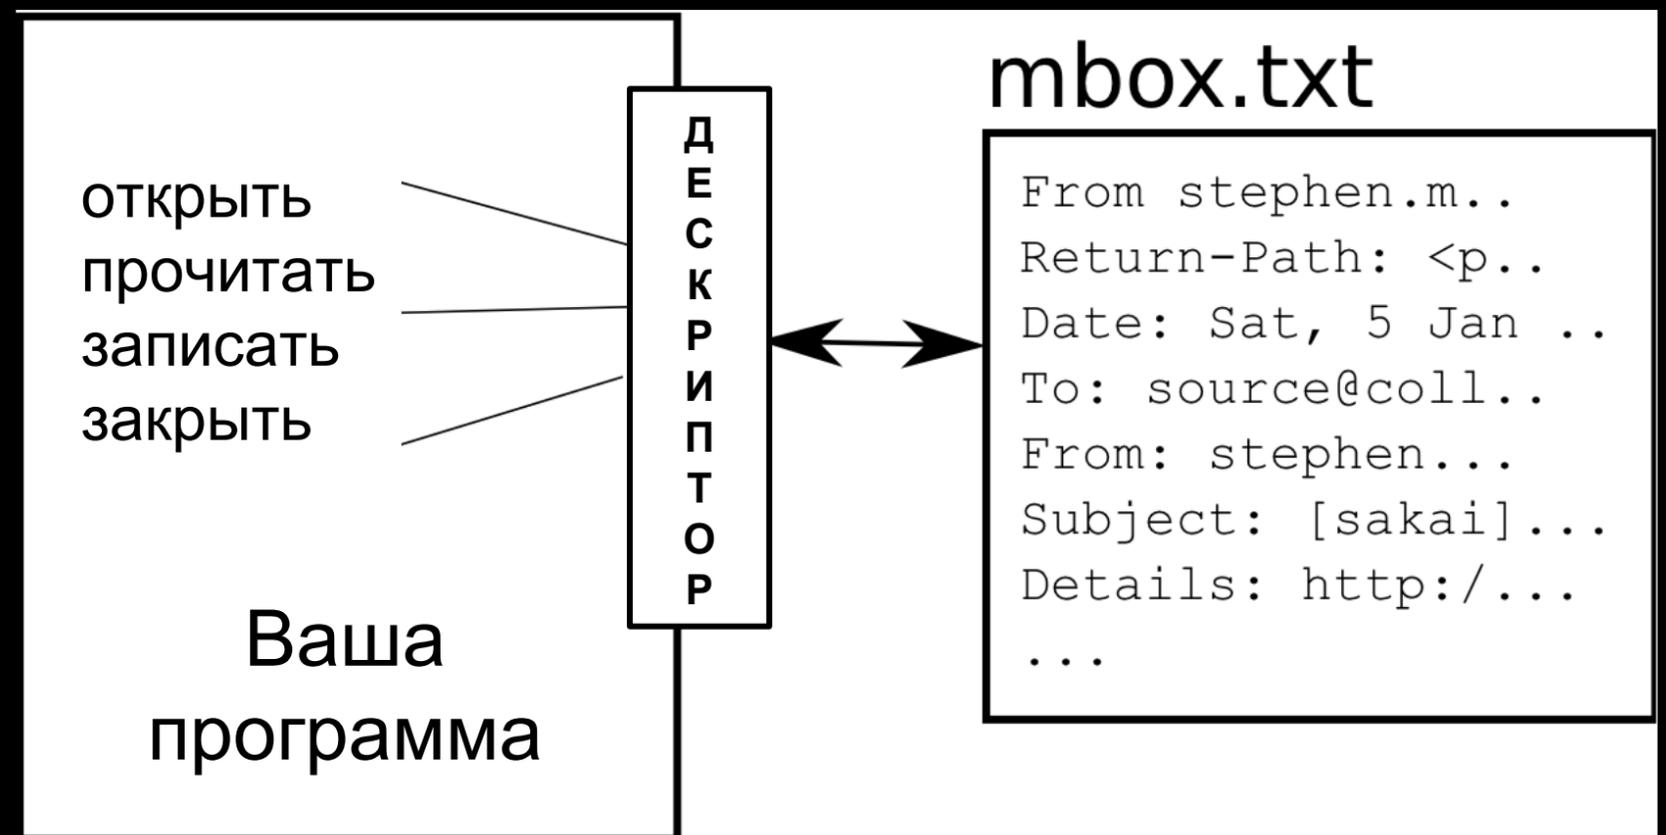
- Прежде чем мы сможем прочитать содержимое файла, мы должны задать файл, с которым мы будем, и что мы хотим с ним сделать
- Это делается с помощью функции `open()`
- Функция `open()` возвращает **дескриптор файла** - переменную, используемую для выполнения операций над файлом
- Эта функция схожа с опцией "Файл -> Открыть" в текстовом процессоре

# Использование функции `open()`

- `handle = open(filename, mode)` `fhand = open('mbox.txt', 'r')`
  - › Возвращает дескриптор файла, используемый для выполнения операций над файлом
  - › Название файла является строкой
  - › Указание режима необязательно. `'r'` используется для чтения из файла, а `'w'` - для записи в файл

# Дескриптор файла

```
>>> fhand = open('mbox.txt')
>>> print fhand
<open file 'mbox.txt', mode 'r' at 0x1005088b0>
```



# Если файл отсутствует

```
>>> fhand = open('stuff.txt')
Traceback (most recent call last):  File
"<stdin>", line 1, in <module>IOError: [Errno 2]
No such file or directory: 'stuff.txt'
```

# СИМВОЛ НОВОЙ СТРОКИ

- Для указания окончания строки используется символ **новой строки**
- В строках он отмечается как **\n**
- Символ новой строки считается как один знак, а не два

```
>>> stuff = 'Hello\nWorld!'
>>> stuff
'Hello\nWorld!'
>>> print stuff
Hello
World!
>>> stuff = 'X\nY'
>>> print stuff
X
Y
>>> len(stuff) 3
```

# Обработка файлов

- Текстовый файл можно представить как последовательность строк

```
From stephen.marquard@uct.ac.za Sat Jan 5 09:14:16 2008
Return-Path: <postmaster@collab.sakaiproject.org>
Date: Sat, 5 Jan 2008 09:12:18 -0500
To: source@collab.sakaiproject.org
From: stephen.marquard@uct.ac.za
Subject: [sakai] svn commit: r39772 - content/branches/
```

```
Details: http://source.sakaiproject.org/viewsvn/?view=rev&rev=39772
```

# Обработка файлов

- В конце каждой строки текстового файла содержится символ **НОВОЙ строки**

```
From stephen.marquard@uct.ac.za Sat Jan 5 09:14:16 2008\n
```

```
Return-Path: <postmaster@collab.sakaiproject.org>\n
```

```
Date: Sat, 5 Jan 2008 09:12:18 -0500\n
```

```
To: source@collab.sakaiproject.org\n
```

```
From: stephen.marquard@uct.ac.za\n
```

```
Subject: [sakai] svn commit: r39772 - content/branches/\n
```

```
\n
```

```
Details: http://source.sakaiproject.org/viewsvn/?view=rev&rev=39772\n
```

# Дескриптор файла как последовательность

- Открытый для чтения дескриптор файла можно рассматривать как последовательность строк, где каждая строка в файле является строкой в последовательности
- Инструкцию `for` можно использовать для итерации по последовательности
- Не забудьте, что последовательность – это упорядоченный набор данных

```
xfile = open('mbox.txt')  
for cheese in xfile:  
    print cheese
```

# Подсчет строк в файле

- Открыть **файл** только для чтения
- Цикл с **for** для чтения каждой строки
- **Посчитать** строки и распечатать число строк

```
fhand = open('mbox.txt')
count = 0
for line in fhand:
    count = count + 1
print 'Количество строк:', count
```

```
$ python open.py
Количество строк: 132045
```

# Чтение из **\*всего\*** файла

- Можно **прочитать** весь файл (включая разрывы строк) как **одну строку**

```
>>> fhand = open('mbox-short.txt')
>>> inp = fhand.read()
>>> print len(inp) 94626
>>> print inp[:20]
From stephen.marquar
```

# Поиск по файлу

- Если в наш цикл **for** добавить инструкцию **if**, можно распечатать строки, отвечающие некоторому заданному критерию

```
fhand = open('mbox-short.txt')
for line in fhand:
    if line.startswith('From:') :
        print line
```

# ОЙ!

Откуда взялись все эти  
пустые строки?

From: [stephen.marquard@uct.ac.za](mailto:stephen.marquard@uct.ac.za)

From: [louis@media.berkeley.edu](mailto:louis@media.berkeley.edu)

From: [zqian@umich.edu](mailto:zqian@umich.edu)

From: [rjlowe@iupui.edu](mailto:rjlowe@iupui.edu)

...

# ОЙ!

Откуда взялись все эти  
пустые строки?

- В конце каждой **строки** файла имеется символ **разрыва строки**
- Оператор **печати** добавляет к каждой строке **разрыв строки**

```
From: stephen.marquard@uct.ac.za\n\nFrom: louis@media.berkeley.edu\n\nFrom: zqian@umich.edu\n\nFrom: rjlowe@iupui.edu\n\n...
```

# Поиск по файлу (исправленный)

- С помощью оператора `rstrip()` библиотеки строк мы можем избавиться от лишних пробелов справа
- Разрыв строки считается “пробелом” и **удаляется**

```
fhand = open('mbox-short.txt')
for line in fhand:
    line = line.rstrip()
    if line.startswith('From:') :
        print line
```

```
From: stephen.marquard@uct.ac.za
From: louis@media.berkeley.edu
From: zqian@umich.edu
From: rjlowe@iupui.edu
....
```

# Пропуск строк с помощью `continue`

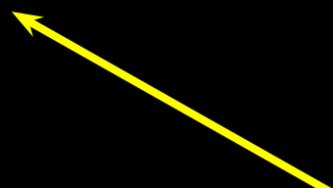
- С помощью оператора `continue` можно удобно пропустить строку

```
fhand = open('mbox-short.txt')
for line in fhand:
    line = line.rstrip()
    if not line.startswith('From:') :
        continue ←
    print line
```

# Выбор строк с помощью `in`

- С помощью ключевого слова `in` мы можем выполнять поиск по строкам

```
fhand = open('mbox-short.txt')
for line in fhand:
    line = line.rstrip()
    if not '@uct.ac.za' in line :
        continue
    print line
```



```
From stephen.marquard@uct.ac.za Sat Jan 5 09:14:16 2008
X-Authentication-Warning: set sender to stephen.marquard@uct.ac.za using -f
From: stephen.marquard@uct.ac.za
Author: stephen.marquard@uct.ac.za
From david.horwitz@uct.ac.za Fri Jan 4 07:02:32 2008
X-Authentication-Warning: set sender to david.horwitz@uct.ac.za using -f...
```

# Запрос названия файла

```
fname = raw_input('Введите название файла: ')
fhand = open(fname)
count = 0
for line in fhand:
    if line.startswith('Subject:') :
        count = count + 1
print 'Найдено', count, 'строк с темой в', fname
```

Enter the file name: mbox.txt  
There were 1797 subject lines in mbox.txt

Enter the file name: mbox-short.txt  
There were 27 subject lines in mbox-short.  
txt

# Неверные названия файлов

```
fname = raw_input('Введите название файла: ')
try:
    fhand = open(fname)
except:
    print 'Не удастся открыть файл:', fname
    exit()
count = 0
for line in fhand:
    if line.startswith('Subject:') :
        count = count + 1
print 'Найдено', count, 'строк с темой в', fname
```

Введите название файла: **mbox.txt**

Найдено **1797** строк с темой в **mbox.txt**

Введите название файла: **na na boo boo**

Не удастся открыть файл: **na na boo boo**

# Обзор

- Вторичная память
- Открытие файла - дескриптор файла
- Структура файла - символ разрыва строки
- Чтение файла по строкам с помощью цикла `for`
- Поиск строк
- Чтение названий файлов
- Работа с неверными названиями файлов



# Благодарность / Содействие



Данная презентация охраняется авторским правом “Copyright 2010- Charles R. Severance ([www.dr-chuck.com](http://www.dr-chuck.com)) University of Michigan School of Information” [open.umich.edu](http://open.umich.edu) и доступна на условиях лицензии 4.0 “С указанием авторства”. В соответствии с требованием лицензии “С указанием авторства” данный слайд должен присутствовать во всех копиях этого документа. При внесении каких-либо изменений в данный документ вы можете указать свое имя и организацию в список соавторов на этой странице для последующих публикаций.

Первоначальная разработка: Чарльз Северанс, Школа информации Мичиганского университета

Здесь впишите дополнительных авторов и переводчиков...