Презентация была сделана в небольшой спешке, специально для нескольких занятий с магистрами ВМК МГУ, поэтому содержит некоторые вольности...
О всех ошибках просьба сообщить автору.

В целом, получилось неплохо, особенно, если учесть, что сейчас в интернете презентаций по «Панде» почти нет...

Pandas
Обзор основных функций

Александр Дьяконов

Московский государственный университет имени М.В. Ломоносова (Москва, Россия)

Основные объекты в Pandas

1. Серия (1D)

```
s = pd.Series(np.random.randn(5), index=['a', 'b', 'c', 'd', 'e'])
```

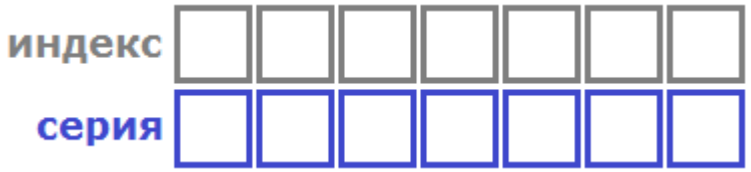


```
s
a    1.321250
b    0.365307
c    0.709577
d    0.542710
e   -0.212721
dtype: float64
```

Похоже на словарь:

```
print s['b']
0.365307109524

print s.get('z', 'error')
error
```

Автоматическое выравнивание по индексу

```
print s + s[1:]
a         NaN
b    0.730614
c    1.419154
d    1.085419
e   -0.425441
```

n

Основные объекты в Pandas

2. ДатаФрейм (2D)

```
df = pd.DataFrame(np.random.randn(8, 3),
index=pd.date_range('1/1/2000', periods=8),
columns=['A', 'B', 'C'])
```

```
df
```

	A	B	C
2000-01-01	0.684918	0.240427	-0.030283
2000-01-02	0.533952	-0.573713	-1.602537
2000-01-03	-1.291314	-0.650594	1.771561
2000-01-04	2.813297	-1.093390	-0.209462
2000-01-05	0.894795	-0.574468	0.765031
2000-01-06	1.513772	0.618505	-1.402341
2000-01-07	-0.435267	-1.199286	0.990490
2000-01-08	-0.541890	0.590653	-0.530153

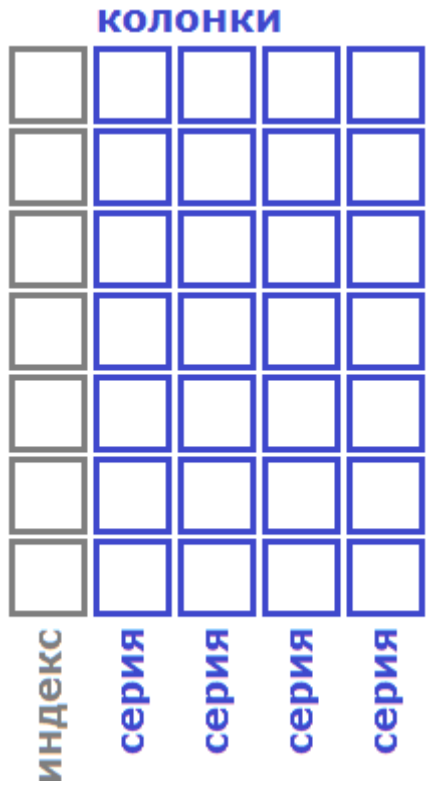

Основные объекты в Pandas

3. Панель (3D)

```
wp = pd.Panel(np.random.randn(2, 5, 4), items=['Item1', 'Item2'],
major_axis=pd.date_range('1/1/2000', periods=5),
minor_axis=['A', 'B', 'C', 'D'])
wp
```

```
<class 'pandas.core.panel.Panel'>
Dimensions: 2 (items) x 5 (major_axis) x 4 (minor_axis)
Items axis: Item1 to Item2
Major_axis axis: 2000-01-01 00:00:00 to 2000-01-05 00:00:00
Minor_axis axis: A to D
```

Есть ещё и многомерные объекты…

Подключение пакетов

```
import pandas as pd
import numpy as np
```

Загрузка данных

```
# Excel
data2 = pd.read_excel('D:\\filename.xlsx', sheetname='1')
# csv-файл
data = pd.read_csv('D:\\filename.csv', sep=';', decimal=',')
data.to_csv('foo.csv') # сохранение
# HDF5
pd.read_hdf('foo.h5', 'df')df.to_hdf('foo.h5', 'df') #
сохранение
```

Важно: не забывать сепараторы

После загрузки –
1. Смотрим на данные

```
datatrain = pd.read_csv('D:\\Competitions\\Rossman\\train.csv')
datatrain[:3]
```

	Store	DayOfWeek	Date	Sales	Customers	Open	Promo	StateHoliday	SchoolHoliday
0	1	5	2015-07-31	5263	555	1	1	0	1
1	2	5	2015-07-31	6064	625	1	1	0	1
2	3	5	2015-07-31	8314	821	1	1	0	1

В ноутбуке `print datatrain[:3]` **смотрится хуже**

2. Приводим данные к нужным типам

```
datatrain.Date = pd.to_datetime(datatrain.Date)
```

Создание ДатаФрейма

```
# первый способ
data = pd.DataFrame({ 'A' : [1., 4., 2., 1.],
'B' : pd.Timestamp('20130102'),
'C' : pd.Series(1,index=list(range(4)),dtype='float32'),
'D' : np.array([3] * 4,dtype='int32'),
'E' : pd.Categorical(["test","train","test","train"]),
'F' : 'foo' }, index=pd.period_range('Jan-2000', periods=4,
freq='M'))
print data
```

```
            A           B   C  D      E    F
2000-01   1 2013-01-02 NaN  3   test  foo
2000-02   4 2013-01-02 NaN  3  train  foo
2000-03   2 2013-01-02 NaN  3   test  foo
2000-04   1 2013-01-02 NaN  3  train  foo
```

Создание ДатаФрейма

```
# второй способ
tmp = dict([('A',[1., np.nan, 2., 1.]), ('B',[2.2, np.nan, np.nan,
0.0])]) # ещё один способ
data2 = pd.DataFrame(tmp)
print data2
```

```
    A    B
0   1  2.2
1 NaN  NaN
2   2  NaN
3   1  0.0
```

Простейшие операции

```
# простейшие операции
# столбцы
print data.columns
Index([u'A', u'B', u'C', u'D', u'E', u'F'], dtype='object')

# строки - но тут временная индексация
print data.index
<class 'pandas.tseries.period.PeriodIndex'>
[2000-01, ..., 2000-04]

# сортировка
print data.sort(columns='A')
            A          B   C  D      E    F
2000-01     1 2013-01-02 NaN  3   test  foo
2000-04     1 2013-01-02 NaN  3  train  foo
2000-03     2 2013-01-02 NaN  3   test  foo
2000-02     4 2013-01-02 NaN  3  train  foo
```

Простейшие операции

```
# превращение в np-матрицу
print data.values # без скобок
```

```
array([[1.0, Timestamp('2013-01-02 00:00:00'), nan, 3, 'test', 'foo'],
       [4.0, Timestamp('2013-01-02 00:00:00'), nan, 3, 'train', 'foo'],
       [2.0, Timestamp('2013-01-02 00:00:00'), nan, 3, 'test', 'foo'],
       [1.0, Timestamp('2013-01-02 00:00:00'), nan, 3, 'train', 'foo']],
dtype=object)
```

n

Статистика по признакам

```
# типы
print data.dtypes
A           float64
B    datetime64[ns]
C           float32
D             int32
E            object
F            object
dtype: object
```

Изменение типа: `.astype()`

```
# статистика + транспонирование
print data.describe().T # транспонирование часто удобно!
   count  mean       std  min  25%  50%  75%  max
A      4     2  1.414214    1    1  1.5  2.5    4
C      0   NaN       NaN  NaN  NaN  NaN  NaN  NaN
D      4     3  0.000000    3    3  3.0  3.0    3

print data.describe(include=['object']) # категориальные признаки
                                                                n
```

Совет: смотрите на число уникальных элементов .nunique()

```
# число уникальных элементов (можно через describe)
for i in data.columns: # можно просто data
    print str(i) + ':' + str(data[i].nunique())
```

```
A:3
B:1
C:0
D:1
E:2
F:1
```

`.columns` – **это список, по нему можно бегать в цикле**

Кстати,

нельзя `data.i.nunique()`

нельзя пропустить `str`

«+» – **конкатенация строк**

Переименование колонок

```
df2 = df.rename(columns={'int_col' : 'some_other_name'})

# изменение текущего датафрейма
df2.rename(columns={'some_other_name' : 'int_col'}, inplace = True)
```

Во втором случае не нужно присваивание!

Удаления

```
df = pd.DataFrame({'x':[1,3,2], 'y':[2,4,1]})
# удаление строки
df.drop(1, axis=0, inplace=True)
# удаление столбца
del df['x'] # df.drop('x', axis=1)
df
```

	y
0	2
2	1

Индексация

```
data.at['2000-01','A'] = 10. # по названию
data.iat[0,1] = pd.Timestamp('19990101') # по номеру
# просто = '1999/01/01' не работает

data.loc['2000-01':'2000-02',['D','B','A']] # по названию
data.iloc[0:2,1:3] # по номеру


data.ix[0:2,1:3] # по номеру и по названию


# выбор с проверкой на вхождение
data[data['E'].isin(['test','valid'])] # полезно: isin
```

первая строка (точнее срез датафрейма) – `data[:1]`

последняя строка – `data[-1:]`

нельзя – `data[1], data[1,2]`

можно – `data[data.columns[0]][2]`

Индексация

Выбор нескольких случайных строк

```
print df.take(np.random.permutation(len(df))[:2])
```

Изменить порядок записи в датафрейме

```
data.reindex(index=data.index[::-1])
    # или data = data.iloc[::-1]
```

Умная переиндексация

```
s = pd.DataFrame({'x':[1,2,3,4], 'y':[10,20,30,40]}, index=['a','b','c','d'])
s.reindex(index=['d','b','x'], columns=['y','z'])
```

	y	z
d	40	NaN
b	20	NaN
x	NaN	NaN

Индексация

Переиндексация

```
s = pd.Series([10,20,60], index=[1,2,6])
s.reindex(index=[2,3,4,5,6,7], method='ffill')
```

```
2    20
3    20
4    20
5    20
6    60
7    60
```

Для вставки колонок в любое место

```
.insert()# если df['new'] = ..., то вставляется в конец
```

n

Итерации

```
df = pd.DataFrame({'x':[1,2,1,2], 'y':[1,2,3,3], 'z':[0,0,0,0]},
index=['a','b','c','d'])
```

	x	y	z
a	1	1	0
b	2	2	0
c	1	3	0
d	2	3	0

```
for col in df: # не обязательно писать df.colunms
    print col
```

```
x
y
z
```

n

Итерации

```
for index, row in df.iterrows():
    print index, row
```

a		b		c		d	
x	1	x	2	x	1	x	2
y	1	y	2	y	3	y	3
z	0	z	0	z	0	z	0

```
for t in df.itertuples(): # так быстрее;)
    print t
('a', 1, 1, 0)
('b', 2, 2, 0)
('c', 1, 3, 0)
('d', 2, 3, 0)
```

Не модифицировать внутри итераций то, по чему итерируетесь

Сравнения

```
df1 = pd.DataFrame({'x':[1,3,2], 'y':[2,4,1]})
df2 = pd.DataFrame({'x':[3,1,2], 'y':[0,2,2]})

print df1>=df2
       x      y
0  False   True
1   True   True
2   True  False

print (df1>=df2).any(axis=1)

0    True
1    True
2    True

print (df1>=df2).all()

x    False
y    False
```

n

NaN

	A	B
0	1	2.2
1	NaN	NaN
2	2	NaN
3	1	0.0

```
print data2.isnull()# маска Нанов
       A      B
0  False  False
1   True   True
2  False   True
3  False  False

print data2.mean()# nan автоматически не учитываются
A    1.333333
B    1.100000

print data2.apply(np.cumsum) # тоже обходятся nan
    A    B
0   1  2.2
1 NaN  NaN
2   3  NaN
3   4  2.2
```

не забывать `data3 = data2.apply(np.cumsum)`

NaN

	A	B
0	1	2.2
1	NaN	NaN
2	2	NaN
3	1	0.0

```
print data2.dropna()# удаление Нанов
   A    B
0  1  2.2
3  1  0.0

print data2.fillna(value=5.5) # заполнение Нанов

     A    B
0  1.0  2.2
1  5.5  5.5
2  2.0  5.5
3  1.0  0.0

print data2.ffill()# заполнение соседними значениями
dtype: float64
   A    B
0  1  2.2
1  1  2.2
2  2  2.2
3  1  0.0
```

NaN

Отличие от numpy

```
df = pd.DataFrame({'x':[1, np.nan], 'y':[1, 2]})

print df.mean()
x    1.0
y    1.5


print np.mean(df)
x    1.0
y    1.5

print np.mean(df.values)
nan
```

n

Комбинирование

```
df1 = pd.DataFrame({'x':[1,np.nan,2], 'y':[2,4,np.nan], 'z':[1,2,3]})
df2 = pd.DataFrame({'x':[20,40,np.nan], 'y':[2,4,20]})
```

```
print df1
print df2
```

```
    x   y  z
0   1   2  1
1 NaN   4  2
2   2 NaN  3

    x   y
0  20   2
1  40   4
2 NaN  20
```

```
print df1.combine_first(df2)
```

```
    x   y  z
0   1   2  1
1  40   4  2
2   2  20  3
```

```
print df1.combineAdd(df2)
```

```
    x   y  z
0  21   4  1
1  40   8  2
2   2  20  3
```

Пытаемся грамотно объединить: учитывая, что одинаковые строки могут быть частично описаны в разных ДатаФреймах

n

Комбинирование

```
# используем свой комбайнер

combiner = lambda x, y: np.where(pd.isnull(x), y, 100*x) # свой комбайнер
```

```
print df1
print df2
```

```
     x   y  z
0    1   2  1
1  NaN   4  2
2    2 NaN  3

     x   y
0   20   2
1   40   4
2  NaN  20
```

```
print df1.combine(df2, combiner)
```

```
      x    y    z
0   100  200  100
1    40  400  200
2   200   20  300
```

Объединение ДатаФреймов

```
# объединение дата-фреймов
left = pd.DataFrame({'key': [1,2,1], 'l': [1, 2, 3]})
right = pd.DataFrame({'key': [1,2,3], 'r': [4, 5, 6]})
print left
print right
pd.merge(left, right, on='key')
```

Вертикальная конкатенация ДатаФреймов

```
a = pd.DataFrame(dict([('A',[1., 3., 2., 1.]), ('B',[2.2, 1.1, 3.3, 0.0]), ('C', 1)]))
b = pd.DataFrame(dict([('A',[0., 2.]), ('B',4)]))
```

Первый способ

```
a.append(b)
```

Второй способ

```
pd.concat([a, b])
```

	A	B	C
0	1	2.2	1
1	3	1.1	1
2	2	3.3	1
3	1	0.0	1
0	0	4.0	NaN
1	2	4.0	NaN

```
# можно и вертикально
    # и с ключами
    pd.concat([a, b],
keys=['a', 'b'], axis=1)
```

	a			b	
	A	B	C	A	B
0	1	2.2	1	0	4
1	3	1.1	1	2	4
2	2	3.3	1	NaN	NaN
3	1	0.0	1	NaN	NaN

Передача аргументов через список типична

n

Выравнивание

```
s1 = pd.Series([10,20,30,40], index = [1,2,3,4])
s2 = pd.Series([20,30,50], index = [2,3,5])

s1.align(s2)
```

1	10	1	NaN
2	20	2	20
3	30	3	30
4	40	4	NaN
5	NaN	5	50

Это такой вывод: tuple из двух серий.

```
s1.align(s2, join='inner')
```

2	20	2	20
3	30	3	30

n

Группировка

Функция `.groupby()` :

1. **Разделение данных на группы (по некоторому критерию)**
2. **Применение к каждой группе функции**
3. **Получение результата**

Функция

2.1. Агрегация (статистика по группе)

2.2. Трансформация (изменение/формирование значений по группе)

2.3. Фильтрация (удаление некоторых групп)

Группировка

Для каждого уникального значения A найти минимальный B

```
d = pd.DataFrame({'A': [1,2,2,1,3,3], 'B': [1,2,3,3,2,1]})
print d

# первый способ
print d.loc[d.groupby('A')['B'].idxmin()]

# второй способ
print d.sort('B').groupby('A', as_index=False).first()
```

	A	B
0	1	1
1	2	2
2	2	3
3	1	3
4	3	2
5	3	1

	A	B
0	1	1
1	2	2
5	3	1

	A	B
0	1	1
1	2	2
5	3	1

Группировка

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
print a.groupby(['A','B']).groups # индексы элементов групп
{(1L, 3L): [0L, 4L], (2L, 3L): [2L, 5L], (2L, 4L): [1L, 6L], (1L,
4L): [3L]}
# вывод групп
for x, y in a.groupby(['A','B']): # можно for (x1, x2), y in ...
    print x
    print y
(1, 3)
   A  B  C
0  1  3  5
4  1  3  6
(1, 4)
   A  B  C
3  1  4  6
(2, 3)
   A  B  C
2  2  3  5
5  2  3  6
(2, 4)
   A  B  C
1  2  4  5
6  2  4  6
```

.groupby(, sort=True) – **сортировка результата** n

Группировка

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
print a.groupby(['A','B']).first() # первые элементы
      C
A B
1 3   5
  4   6
2 3   5
  4   5
print a.groupby(['A','B'])['C'].mean() # средние по группам
A  B
1  3    5.5
   4    6.0
2  3    5.5
   4    5.5
print a.groupby(['A','B']).get_group((1,3)) # выбор конкретной группы
   A  B  C
0  1  3  5
4  1  3  6
```

`.cumcount()` – **номер в группе,**

Можно группировать по столбцам…

Агрегация

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
print a.groupby(['A','B']).aggregate(np.sum) # пример агрегации
print a.groupby(['A','B']).sum() # эквивалентная запись
      C
A B
1 3  11
  4   6
2 3  11
  4  11
print a.groupby(['A','B']).sum().reset_index() # без индекс-и
   A  B   C
0  1  3  11
1  1  4   6
2  2  3  11
3  2  4  11
print a.groupby(['A','B']).agg([np.sum, np.mean, np.std]) # ещё
       C
     sum  mean       std
A B
1 3   11   5.5  0.707107
  4    6   6.0       NaN
2 3   11   5.5  0.707107
  4   11   5.5  0.707107
```

Агрегация

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
# агрегация по одному столбцу
print a.groupby(['A','B'])['C'].agg({'sum':np.sum,
'mean':np.mean})
      sum  mean
A B
1 3    11   5.5
  4     6   6.0
2 3    11   5.5
  4    11   5.5

# агрегация по разным столбцам
print a.groupby('A').agg({'B':np.sum, 'C':np.mean})
           C   B
A
1   5.666667  10
2   5.500000  14
```

Замечание: `aggregate = agg`

Трансформация

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
mmean = lambda x: (x-np.mean(x))
print a.groupby('A').transform(mmean)
```

```
          B         C
0 -0.333333 -0.666667
1  0.500000 -0.500000
2 -0.500000 -0.500000
3  0.666667  0.333333
4 -0.333333  0.333333
5 -0.500000  0.500000
6  0.500000  0.500000
```

Фильтрация

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
a.groupby('A').filter(lambda x: x['B'].sum()>10, dropna=False)
```

	A	B	C
0	NaN	NaN	NaN
1	2	4	5
2	2	3	5
3	NaN	NaN	NaN
4	NaN	NaN	NaN
5	2	3	6
6	2	4	6

Применение функций

`pipe()` – к ДатаФреймам

`apply()` – к строкам/столбцам

`applymap()` – поэлементно

Pipe

```
f(g(h(df), arg1=1), arg2=2, arg3=3)
```

эквивалентно

```
(df.pipe(h)
        .pipe(g, arg1=1)
        .pipe(f, arg2=2, arg3=3)
    )
```

n

Apply

	A	B	C
0	1	3	5
1	2	4	5
2	2	3	5
3	1	4	6
4	1	3	6
5	2	3	6
6	2	4	6

```
def f(x):
    return pd.DataFrame({'x': x, 'x-mean': x - x.mean()})
a.groupby('A')['B'].apply(f)
```

	x	x-mean
0	3	-0.333333
1	4	0.500000
2	3	-0.500000
3	4	0.666667
4	3	-0.333333
5	3	-0.500000
6	4	0.500000

Apply

Пример нормировки

```
a.apply(lambda x: x/sum(x))
# по столбцам
```

	A	B	C
0	0.090909	0.125000	0.128205
1	0.181818	0.166667	0.128205
2	0.181818	0.125000	0.128205
3	0.090909	0.166667	0.153846
4	0.090909	0.125000	0.153846
5	0.181818	0.125000	0.153846
6	0.181818	0.166667	0.153846

```
a.apply(lambda x: x/sum(x), axis=1)
# по строкам
```

	A	B	C
0	0.111111	0.333333	0.555556
1	0.181818	0.363636	0.454545
2	0.200000	0.300000	0.500000
3	0.090909	0.363636	0.545455
4	0.100000	0.300000	0.600000
5	0.181818	0.272727	0.545455
6	0.166667	0.333333	0.500000

n

Applymap

```
# applymap - поэлементно

a = pd.DataFrame({'A': [1,2,2], 'B': ['a','b','a']})

def some_fn(x):
    if type(x) is str:
        return 'applymap_' + x
    else:
        return (10*x)

a.applymap(some_fn)
```

	A	B
0	10	applymap_a
1	20	applymap_b
2	20	applymap_a

Map

```
# все строки, в которых столбец начинается с определённой буквы
d = pd.DataFrame({'A': [1,2,2,1,2,3,2,1,3],
'B': ['as','bs','e','qq','aaa','a','e','qwr','www']})

d[d['B'].map(lambda x: x.startswith('a'))]
```

	A	B
0	1	as
4	2	aaa
5	3	a

```
df = pd.DataFrame({'name': [u'Маша', u'Саша', u'Рудольф'],
'marks':[[2,3,3,5], [4,5,5], [2,3]]})
print df[df['marks'].map(lambda x: 3 in x)]
```

```
          marks      name
0  [2, 3, 3, 5]      Маша
2        [2, 3]   Рудольф
```

n

Map – основное применение

```
df = pd.DataFrame({'CITY': [u'London', u'Moscow', u'Paris'], 'Stats': [0,2,1]})

d = {u'London':u'GB', u'Moscow':u'RUS', u'Paris':u'FR'}
df['country'] = df['CITY'].map(d)
df.columns = map(str.lower, df.columns)
df
```

	city	stats	country
0	London	0	GB
1	Moscow	2	RUS
2	Paris	1	FR

Иногда есть другие средства – замена значений

```
df.replace(u'Moscow', u'Ufa') # замена значения
```

n

Группировка серий

```
s = pd.Series(['a', 'aa', 'bA', 'BB', 'AB', 'AAB'])
s.groupby([1,2,1,2,1,1]).sum()
```

```
1    abAABAAB
2        aaBB
```

Сумма для строк – конкатенация

ДатаФрейм состоит из серий…

Рисование

```
a.boxplot(by='A') # a.groupby('A').boxplot()
```

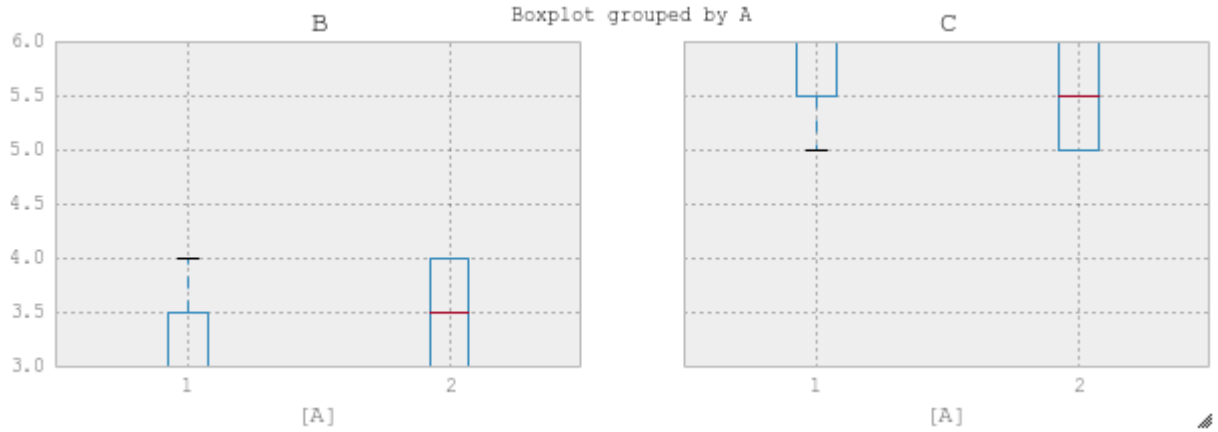

Вот тут можно вставить ещё много красивых картинок…

Иерархическая (многоуровневая) индексация

```
tuples = list(zip(*[['bar', 'bar', 'baz', 'baz', 'foo', 'foo', 'qux', 'qux'],
 ['one', 'two', 'one', 'two','one', 'two', 'one', 'two']]))
print tuples
[('bar', 'one'), ('bar', 'two'), ('baz', 'one'), ('baz', 'two'),
('foo', 'one'), ('foo', 'two'), ('qux', 'one'), ('qux', 'two')]

index = pd.MultiIndex.from_tuples(tuples, names=['first', 'second'])
df = pd.DataFrame(np.random.randn(8, 2), index=index, columns=['A', 'B'])
print df
                     A         B
first second
bar   one    -0.240469 -0.533312
      two    -0.847305  0.845316
baz   one     0.274592  0.473476
      two     1.433575 -0.977992
foo   one     0.957252 -1.246396
      two    -2.821039 -0.625924
qux   one     0.086683 -0.450850
      two    -1.236494  0.706156
```

Иерархическая (многоуровневая) индексация

```
print df.stack() # обратная операция unstack()
```

```
first  second
bar    one      A    -0.240469
                B    -0.533312
       two      A    -0.847305
                B     0.845316
baz    one      A     0.274592
                B     0.473476
       two      A     1.433575
                B    -0.977992
foo    one      A     0.957252
                B    -1.246396
       two      A    -2.821039
                B    -0.625924
qux    one      A     0.086683
                B    -0.450850
       two      A    -1.236494
                B     0.706156
dtype: float64
```

Pivot tables

```
df = pd.DataFrame({'ind1':[1,1,1,2,2,2,2], 'ind2':[1,1,2,2,3,3,2],
'x':[1,2,3,4,5,6,7], 'y':[1,1,1,1,1,1,2]})

print df
print df.pivot(index='x', columns='ind2', values='y')
```

```
   ind1  ind2  x  y
0     1     1  1  1
1     1     1  2  1
2     1     2  3  1
3     2     2  4  1
4     2     3  5  1
5     2     3  6  1
6     2     2  7  2
```

```
ind2    1   2   3
x
1       1 NaN NaN
2       1 NaN NaN
3     NaN   1 NaN
4     NaN   1 NaN
5     NaN NaN   1
6     NaN NaN   1
7     NaN   2 NaN
```

n

Pivot tables

```
dfp = df.pivot_table(index=['ind1','ind2'], aggfunc='sum')
dfp
```

		x	y
ind1	ind2		
1	1	3	2
	2	3	1
2	2	11	3
	3	11	2

```
# отличается от
df.set_index(['ind1', 'ind2'], drop=False)
```

```
ind1  ind2
1     1          1     1   1   1
      1          1     1   2   1
      2          1     2   3   1
2     2          2     2   4   1
      3          2     3   5   1
      3          2     3   6   1
      2          2     2   7   2
```

Pivot tables

```
print dfp

print dfp.sum(level='ind2')

dfp.swaplevel('ind1','ind2')
```

		x	y
ind1	ind2		
1	1	3	2
	2	3	1
2	2	11	3
	3	11	2

```
      x  y
ind2
1     3  2
2    14  4
3    11  2
```

		x	y
ind2	ind1		
1	1	3	2
2	1	3	1
	2	11	3
3	2	11	2

Melt

Операция, в некотором смысле обратная Pivot

```
cheese = pd.DataFrame({'first' : ['John', 'Mary'], 'last' :
['Doe', 'Bo'], 'height' : [5.5, 6.0], 'weight' : [130, 150]})

pd.melt(cheese, id_vars=['first', 'last'])
```

	first	height	last	weight
0	John	5.5	Doe	130
1	Mary	6.0	Bo	150

	first	last	variable	value
0	John	Doe	height	5.5
1	Mary	Bo	height	6.0
2	John	Doe	weight	130.0
3	Mary	Bo	weight	150.0

Делаем из «широкой» таблицы «высокую».

n

Категориальные признаки

```
# создание категориального признака = интервалы попаданий
x = np.random.randn(10000)
y  = pd.cut(x,10)
z = pd.value_counts(y)
z.plot(figsize=(20,3))
pd.DataFrame(x).plot(kind='kde')
pd.DataFrame(z).T
```

	(-0.211, 0.629]	(-1.0502, -0.211]	(0.629, 1.468]	(-1.89, -1.0502]	(1.468, 2.308]	(-2.729, -1.89]	(2.308, 3.147]	(-3.569, -2.729]	(3.147, 3.987]	(-4.417, -3.569]
0	3247	2638	1921	1192	634	226	102	32	6	2

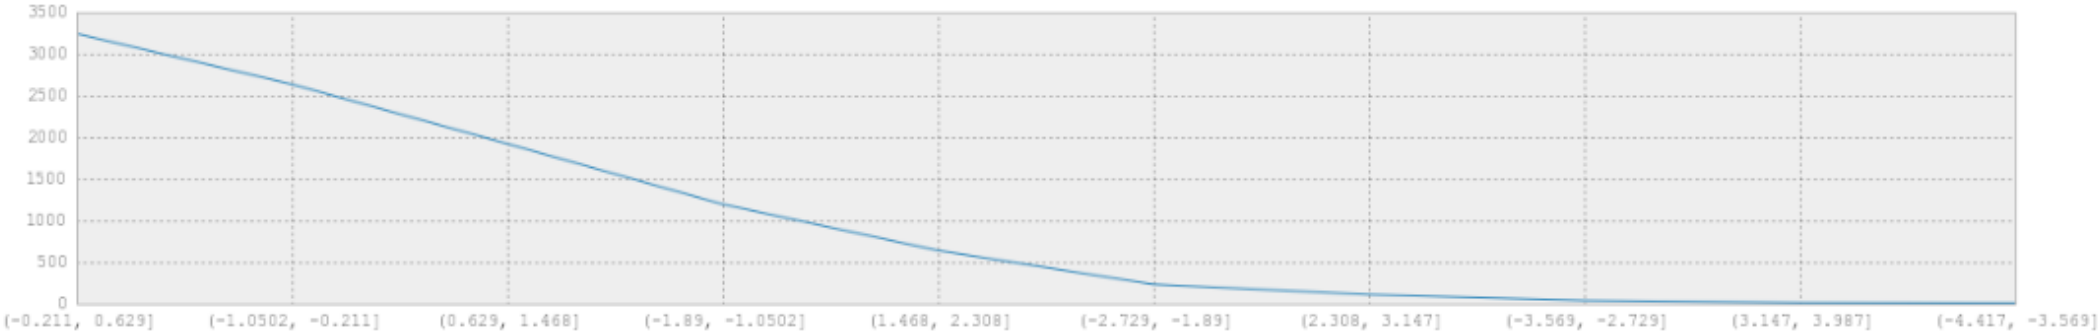

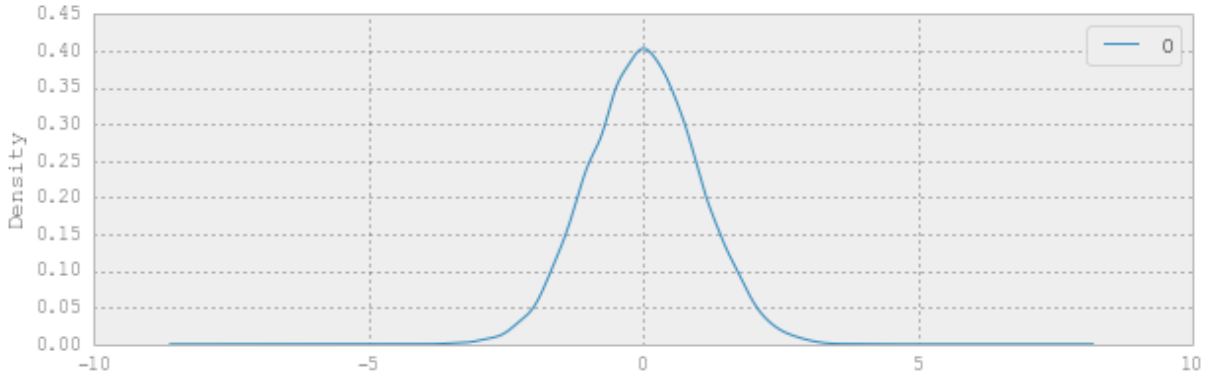

Несколько колонок как функция одной

```
a = pd.DataFrame({'a': [1,2,1,2], 'b':[3,3,3,4]})

def two_three_strings(x):
    return x*2, x*3

a['twice'], a['thrice'] = zip(*a['a'].map(two_three_strings))
a
```

	a	b	twice	thrice
0	1	3	2	3
1	2	3	4	6
2	1	3	2	3
3	2	4	4	6

```
0    (2, 3)
1    (4, 6)
2    (2, 3)
3    (4, 6)
```

Одна колонка как функция нескольких

```
# Из имени и фамилии делаем полное имя
df = pd.DataFrame({'name': [u'Маша', u'Саша', u'Рудольф'],
'surname':[u'Петрова', u'Сидоров', u'Кац']})

# первый способ
lst = []
for n, s in zip(df.name,  df.surname):
    lst.append(n + ' ' + s)
df['fullname'] = lst

# второй способ
df['fullname2'] = df[['name', 'surname']].apply(lambda x: x[0] + ' ' +
x[1], axis=1)

# самый простой способ
df['fullname3'] = df['name'] + ' ' + df['surname']
```

	name	surname	fullname	fullname2	fullname3
0	Маша	Петрова	Маша Петрова	Маша Петрова	Маша Петрова
1	Саша	Сидоров	Саша Сидоров	Саша Сидоров	Саша Сидоров
2	Рудольф	Кац	Рудольф Кац	Рудольф Кац	Рудольф Кац

n

Временные ряды

```
#временные ряды
data = {'date': ['2014-05-01 18:47:05.069722', '2014-05-01 18:47:05.119994', '2014-05-02
18:47:05.178768', '2014-05-02 18:47:05.230071', '2014-05-02 18:47:05.230071', '2014-05-02
18:47:05.280592', '2014-05-03 18:47:05.332662', '2014-05-03 18:47:05.385109', '2014-05-04
18:47:05.436523', '2014-05-04 18:47:05.486877'],
'battle_deaths': [34, 25, 26, 15, 15, 14, 26, 25, 62, 41]}
```

```
df = pd.DataFrame(data)
df.index = pd.to_datetime(df['date'])
del df['date']
df['05-2014']
```

	battle_deaths
date	
2014-05-01 18:47:05.069722	34
2014-05-01 18:47:05.119994	25
2014-05-02 18:47:05.178768	26
2014-05-02 18:47:05.230071	15
2014-05-02 18:47:05.230071	15
2014-05-02 18:47:05.280592	14
2014-05-03 18:47:05.332662	26
2014-05-03 18:47:05.385109	25
2014-05-04 18:47:05.436523	62
2014-05-04 18:47:05.486877	41

n

Временные ряды

Индексация

```
print df['5/1/2014']  # df['2014-05-01']
                            battle_deaths
date
2014-05-01 18:47:05.069722             34
2014-05-01 18:47:05.119994             25

print df['2014-05-03':'2014-05-04']
                            battle_deaths
date
2014-05-03 18:47:05.332662             26
2014-05-03 18:47:05.385109             25
2014-05-04 18:47:05.436523             62
2014-05-04 18:47:05.486877             41
```

n

Временные ряды

```
# переход к дням и визуализация
print df.resample('D', how='mean').plot(kind='bar')

# пересортировка df
df.sort_index(by = 'battle_deaths', inplace=True)
df
```

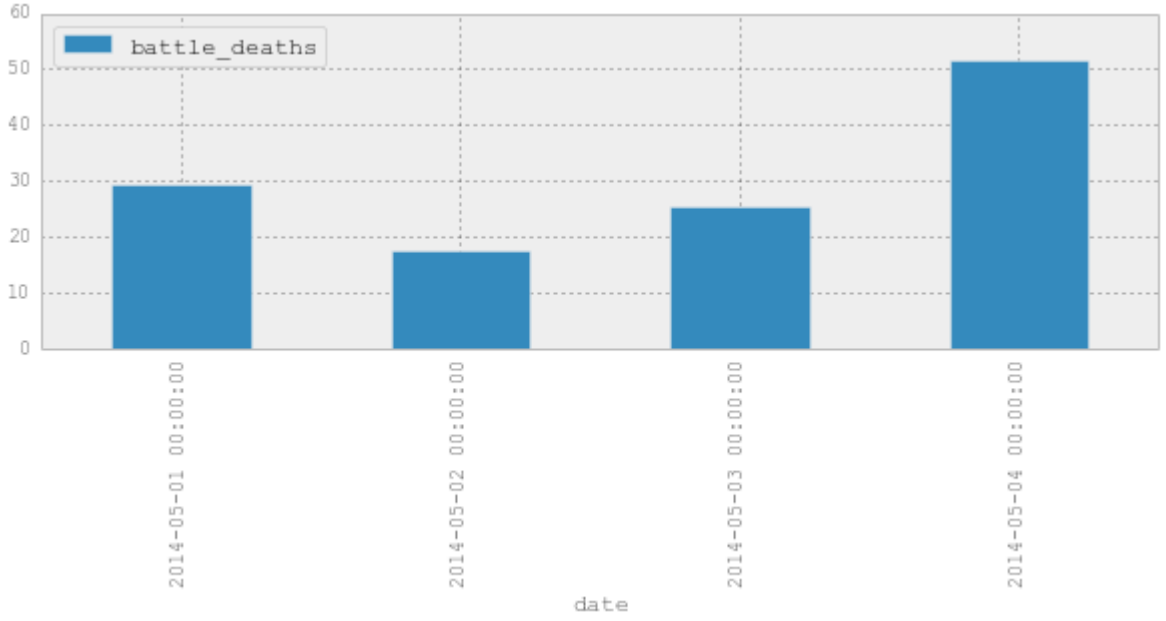

	battle_deaths
date	
2014-05-02 18:47:05.280592	14
2014-05-02 18:47:05.230071	15
2014-05-02 18:47:05.230071	15
2014-05-01 18:47:05.119994	25
2014-05-03 18:47:05.385109	25
2014-05-02 18:47:05.178768	26
2014-05-03 18:47:05.332662	26
2014-05-01 18:47:05.069722	34
2014-05-04 18:47:05.486877	41
2014-05-04 18:47:05.436523	62

n

Строки

```
s = pd.Series(['AbA', 'Sasha', 'DataMining'])
s.str.lower()
```

```
0           aba
1         sasha
2    datamining
```

```
df = pd.DataFrame({'name': [u'Маша', u'Саша', u'Рудольф'],
'mail':['1@mail.ru', 'Amail@vk.ru', '12_Wq@ru.ru']})
print df.mail.str.contains('mail')
```

```
0     True
1     True
2    False
```

```
pattern = '([A-Z0-9._%+-]+)@([A-Z0-9.-]+)\\.([A-Z]{2,4})'
import re as re
df['mail'].str.match(pattern, flags=re.IGNORECASE)
0      (1, mail, ru)
1    (Amail, vk, ru)
2    (12_Wq, ru, ru)
```

n

Строки

Пример возможного извлечения признаков

```
lst = ['mark 10 12-10-2015', 'also 7 10-10-2014', 'take 2 01-05-2015']
df = pd.DataFrame({'x':lst})
df['num'] = df.x.str.extract('(\d+)')
df['date'] = df.x.str.extract('(..-..-....)')
df['word'] = df.x.str.extract('([a-z]\w{0,})')
df
```

	x	num	date	word
0	mark 10 12-10-2015	10	12-10-2015	mark
1	also 7 10-10-2014	7	10-10-2014	also
2	take 2 01-05-2015	2	01-05-2015	take

n

Строки

Забавная индексация

```
s = pd.Series(['one','two','three'])

s.str[1]
```

```
0     n                                  one
1     w                                  two
2     h                                  tree
```

Экстракция

```
pd.Series(['a1', 'b2', 'c3']).str.extract('[ab](\d)')
```

```
0      1
1      2
2    NaN
```

Есть куча функций для строк…

n

Как часто встречаются пары значений

очень полезная штука!

```
d = pd.DataFrame({'A': [1,2,2,1,2,3,2,1,3],
'B': [1,2,3,4,1,2,3,3,4]})

pd.crosstab(d['A'], d['B'])
```

B	1	2	3	4
A				
1	1	0	1	1
2	1	1	2	0
3	0	1	0	1

Другие возможности

Скользящее среднее

```
a = pd.DataFrame({'x':[1,2,3,1,2,3,1,2,3], 'y':[2,2,10,2,2,2,2,2,2]})

pd.rolling_mean(a, 2) # можно сумму, медиану и любую функцию!
```

	x	y
0	NaN	NaN
1	1.5	2
2	2.5	6
3	2.0	6
4	1.5	2
5	2.5	2
6	2.0	2
7	1.5	2
8	2.5	2

n

Другие возможности

Корреляция

```
s1 = pd.Series(np.cos(np.arange(100)))
s2 = pd.Series(np.sin(np.arange(100)))
f = pd.DataFrame({'s1':s1, 's2':s2}).plot()
pd.rolling_corr(s1, s2, window=5).plot(style='.')
f.legend(['signal 1', 'signal 2', 'corr'])
```

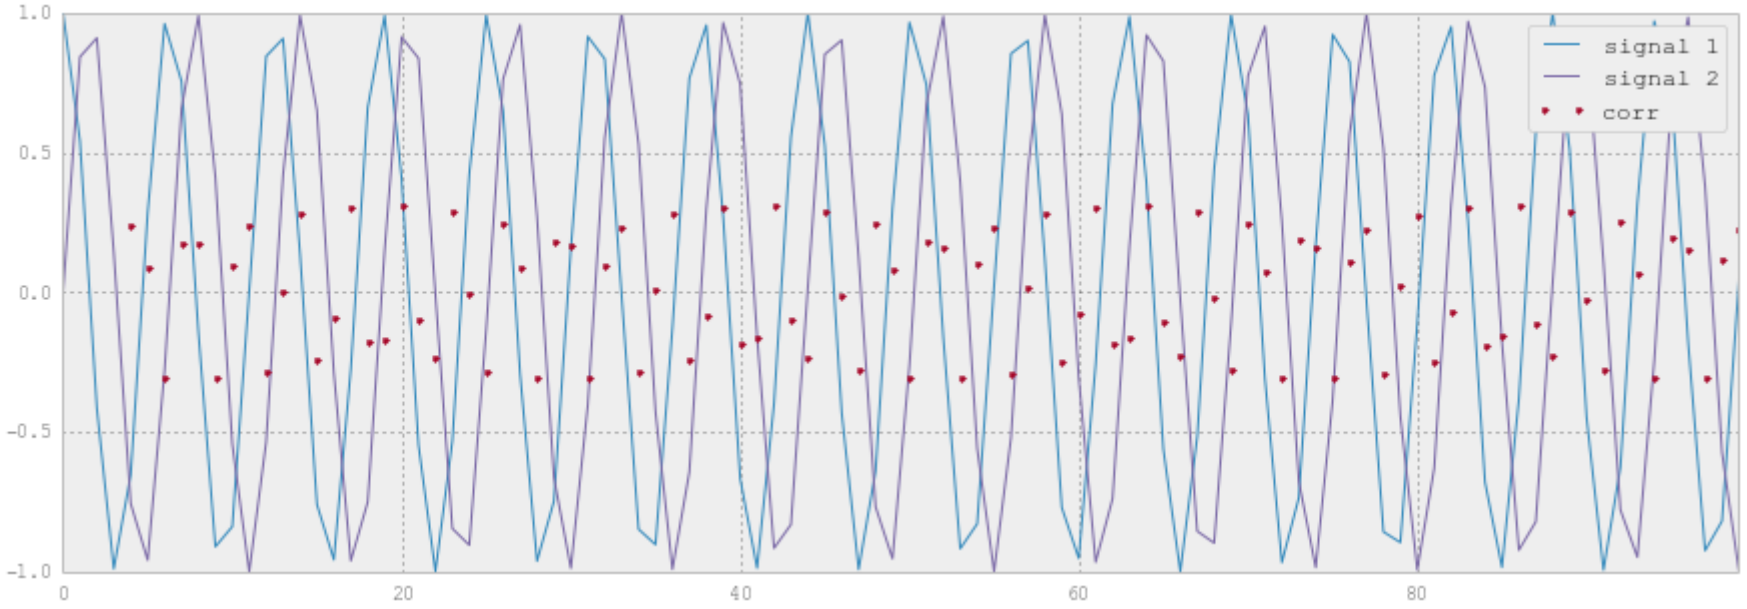

`.corr()` – **корреляция (колонок)**

Другие возможности

Кумулятивные функции

```
# кумулятивное усреднение
s1 = pd.Series(np.cos(np.arange(100)))
s2 = pd.expanding_mean(s1)
f = pd.DataFrame({'s1':s1, 's2':s2}).plot()
f.legend(['signal', 'cum_mean'])
```

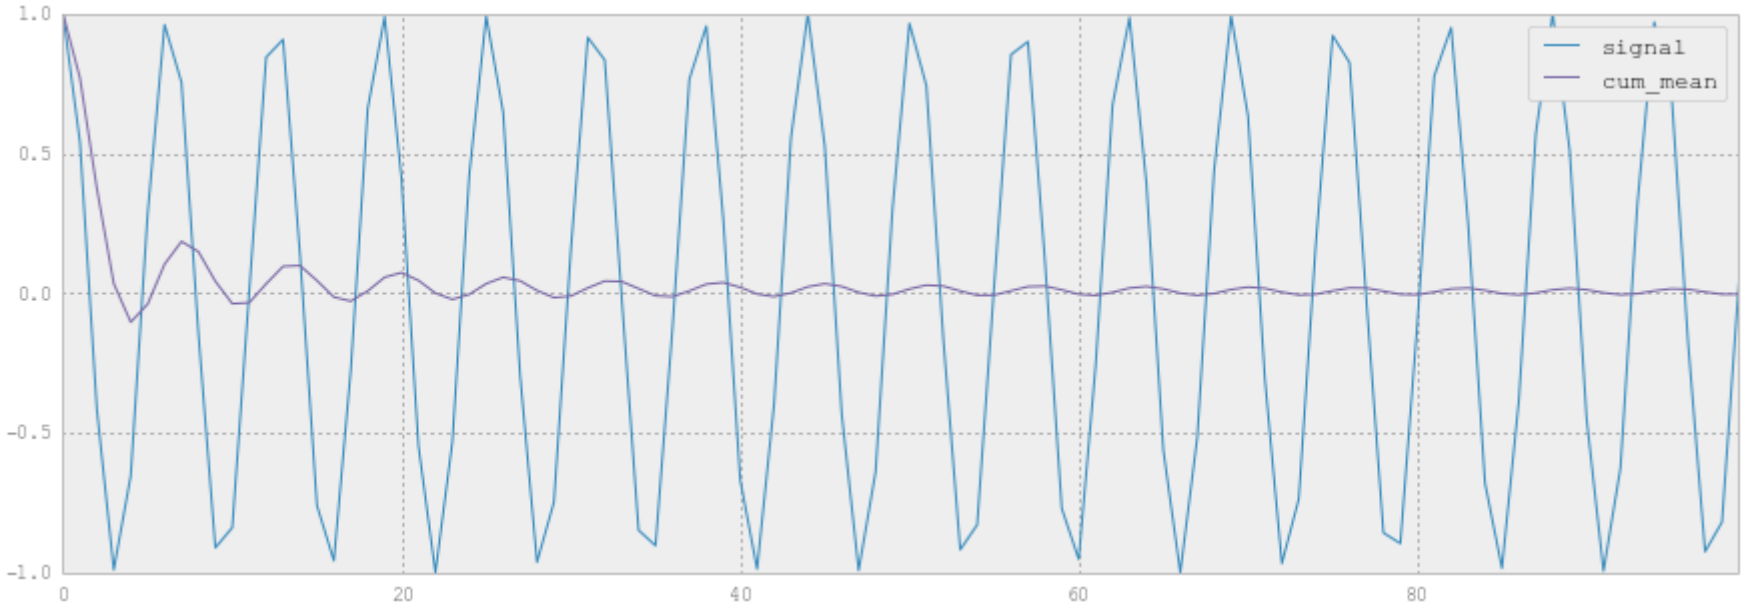

Другие возможности

Удаление дубликатов

```
df = pd.DataFrame({'name': ['Al', 'Max',  'Al'],
'surname':[u'Run', u'Crone', u'Run']})
print df.duplicated()

df.drop_duplicates(['name'], take_last=True)
# df.drop_duplicates()
```

```
0    False
1    False
2     True
```

	name	surname
1	Max	Crone
2	Al	Run

Другие возможности

Максимальные элементы

```
df = pd.DataFrame({'x':[12, 10, 54, 10], 'y':[2, 4, 1, 4]})
print df.rank(method='average') # номера по возрастанию
print df.idxmax() # индексы максимальных элементов
```

```
     x    y
0  3.0  2.0
1  1.5  3.5
2  4.0  1.0
3  1.5  3.5
x    2
y    1
```

n наименьших

```
s = pd.Series([3,2,6,5,1,4])
s.nsmallest(3)
```

```
4    1
1    2
0    3
```

Другие возможности

```
# сколько каждого значения
print pd.value_counts([3,2,2,2,5,3], sort=False)
2    3
3    2
5    1

# мода
print pd.DataFrame({'x': [3,2,2,2,5,3,3]}).mode()
   x
0  2
1  3
```

Зачем нужны встроенные операции

```
# способ вычитания колонки
df = pd.DataFrame({'x':[1,3,2], 'y':[2,4,1]})
df.sub(df['x'], axis=0) # add
```

	x	y
0	0	1
1	0	1
2	0	-1

```
df.T.dot(df) # матричное умножение
```

	x	y
x	14	16
y	16	21

dummy-кодирование для категориальных признаков

```
pd.get_dummies([1,2,1,2,3])
```

	1	2	3
0	1	0	0
1	0	1	0
2	1	0	0
3	0	1	0
4	0	0	1

И так можно!

```
pd.Series(['one,two', 'two,three', 'one!']).str.get_dummies(sep=',')
```

	one	one!	three	two
0	1	0	0	1
1	0	0	1	1
2	0	1	0	0

Кодирование категориальных признаков по порядку

```
pd.factorize([20,10,np.nan,10,np.nan,30,20])
```

```
(array([ 0,  1, -1,  1, -1,  2,  0]), array([ 20.,  10.,  30.]))
```

n

Ссылка на презентацию опубликована в блоге автора
alexanderdyakonov.wordpress.com