

A4B99RPH: Řešení problémů a hry

Unit testing. Vývoj řízený testy.

Petr Pošík

Katedra kybernetiky
ČVUT FEL

Úvod	2
Cíle	3
Zpětná vazba z prvního testíku	4
Ukázka na třídě MyVector.....	5
Python Shell.....	6
Manuální testy	7
Automatické testování.....	8
Příklad	9
Z úlohy "Spam filter"	10
Binární matice záměn.....	11
Ukázka vývoje BCF s testy	12
Testy s modulem unittest.....	13
Testování	14
Testování	15
Automatizované testy: F.I.R.S.T.....	16
Modul doctest	17
xUnit Framework	18
Vývoj řízený testy	19
TDD: Vývoj řízený testy	20
TDD Ukázka	21
TDD Úvod	22
TDD Číslo 2	23
TDD Číslo 3	24
TDD Číslo 4	25
TDD Číslo 5	26
TDD Číslo 6	27
TDD Číslo 8	28
TDD Číslo 9	29
TDD Čistý kód	30
TDD: Závěr	31

Cíle

- Ukázat, co jsou automatické testy a jaké výhody mají.
- Poskytnout metodu, jak lépe splnit zadání testíků na cvičeních.
- Zajistit, abyste se nelekli unit testů, které od nás dostanete k úloze spam filtr.
- Zkusit vás přesvědčit, že používání testů může být dobré i pro vás.

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 3 / 31

Zpětná vazba z prvního testíkuZadání: V modulu `vectors.py` rozšiřte třídu `MyVector`

- o metodu `__add__(self, other)` realizující sčítání 2 vektorů a
- o metodu `norm(self)` realizující výpočet velikosti vektoru.

Čtěte dobře specifikace!

- Jak se měl jmenovat soubor, který se měl odevzdat?
- Jak se měla jmenovat třída definovaná v tomto souboru?
- Jaké metody tato třída měla mít?
- Objekt jakého typu měla vracet metoda `__add__`?

Proč jste tyto chyby neodhalili?**Jak otestovat vlastní kód?**

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 4 / 31

Ukázka na třídě MyVector

Demo

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 5 / 31

Python Shell

Spusťte Python shell a zkuste svůj kód použít:

```
>>> from vectors import MyVector
>>> a = MyVector([1,1,1])
>>> b = MyVector([1,2,3])
>>> c = a+b
>>> type(c)
<class 'vectors.MyVector'>
>>> c.get_vector()
[2, 3, 4]
```

Snadno odhalíte všechny výše zmíněné chyby, jenže:

- Při každé změně v kódu dá hodně práce test znova spustit.
- Správnost výsledků musíte ohodnotit vy sami.
- Navíc:
 - Někdy je nutné přepnout se do pracovního adresáře (`import os; os.chdir()`).
 - Bývají problémy s re-importem již jednou importovaného modulu.
 - V Pythonu 2x: `reload(module)`
 - V Pythonu 3x: `import imp; imp.reload(module)`
 - Ani v jednom případě nefunguje re-import zcela spolehlivě.

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 6 / 31

Manuální testy

Využít sekci `if __name__ == '__main__':` ke spuštění testu:

```
class MyVector:  
    ...  
  
if __name__ == "__main__":  
    from vectors import MyVector  
    a = MyVector([1,1,1])  
    b = MyVector([1,2,3])  
    c = a+b  
    print(type(c))  
    print(c.get_vector())
```

Rychlé opakované spuštění testu je velmi snadné! Ale:

- Správnost výsledků musíte stále hodnotit sami.
- Je-li třeba otestovat několik rysů funkce/třídy:
 - Nelze je testovat po jednom (leda zakomentováním ostatních).
 - Je obtížné udržet v testech pořádek.

Automatické testování

Využít metod automatického testování:

- doctest, unittest, či jiný framework
- lze spouštět i velké množství testů s automatickou kontrolou výsledků

Z úlohy "Spam filter"

Předpokládejme:

- máme sadu emailů uložených v souborech
- pro každý email z této sady víme, zda je to spam nebo ham
- máme jakýkoli funkční spam filter
- pro každý email z naší sady víme, zda jej filtr klasifikuje jako spam nebo ham

Jakých chyb se může spam filtr dopustit? *Matici záměn!*

		V datové sadě	
		pozitivních	negativních
Pozitivní předpověď'	<i>TP</i>	<i>FP</i>	
	<i>FN</i>	<i>TN</i>	

True positives (TP): počet případů klasifikátorem *správně* označených jako *pozitivní*.

False positives (FP): počet případů klasifikátorem *chybně* označených jako *pozitivní*.

False negatives (FN): počet případů klasifikátorem *chybně* označených jako *negativní*.

True negatives (TN): počet případů klasifikátorem *správně* označených jako *negativní*.

Míra kvality je pak nějakou funkcí *TP*, *TN*, *FP* a *FN*.

Binární matice záměn

Binary confusion matrix, BCM:

- Takový "lepší" čítač (čtveřice čítačů).
- Cíl: Ze slovníků `truth` a `prediction` napočítat matici záměn.

```
>>> truth = {
    'email1': 'OK',
    'email2': 'OK',
    'email3': 'SPAM',
    ...
}

>>> prediction = {
    'email1': 'SPAM',
    'email2': 'OK',
    'email3': 'SPAM',
    ...
}
```

Požadavky na BCF:

- Lze nastavit libovolný kód pro spam a ham (zde např OK a SPAM).
- Metoda `as_dict()` vrátí čítače ve formě slovníku.
- Po vytvoření objektu jsou všechny čítače vynulované.
- Zavolám-li metodu `update('SPAM', 'SPAM')`, inkrementuje se čítač TP a hodnota ostatních se nezmění.
- ...
- Zavolám-li metodu `update()` s nesprávným argumentem, vyhodí se výjimka `ValueError`.
- Zavolám-li metodu `compute_from_dicts(truth, prediction)`, čítače TP, FP, TN, FN se správně aktualizují.

Ukázka vývoje BCF s testy

Demo

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 12 / 31

Testy s modulem unittest

```
import unittest
from confmat import BinaryConfusionMatrix
SPAM_TAG = 'SPAM'
HAM_TAG = 'HAM'

class BinaryConfusionMatrixTest(unittest.TestCase):

    def setUp(self):
        self.cm = BinaryConfusionMatrix(
            pos_tag=SPAM_TAG, neg_tag=HAM_TAG)

    def test_countersAreZero_afterCreation(self):
        # Exercise the SUT
        cmDict = self.cm.as_dict()
        # Assert
        self.assertDictEqual(cmDict,
            {'tp': 0, 'tn': 0, 'fp': 0, 'fn': 0})

    def test_updatesTPcorrectly(self):
        # Exercise the SUT
        self.cm.update(SPAM_TAG, SPAM_TAG)
        # Assert
        self.assertDictEqual(self.cm.as_dict(),
            {'tp': 1, 'tn': 0, 'fp': 0, 'fn': 0})

    def test_updatesTNincorrectly(self):
        # Exercise the SUT
        self.cm.update(HAM_TAG, HAM_TAG)
        # Assert
        self.assertDictEqual(self.cm.as_dict(),
            {'tp': 0, 'tn': 1, 'fp': 0, 'fn': 0})

    def test_updatesFPcorrectly(self):
        # Exercise the SUT
        self.cm.update(HAM_TAG, SPAM_TAG)
        # Assert
        self.assertDictEqual(self.cm.as_dict(),
            {'tp': 0, 'tn': 0, 'fp': 1, 'fn': 0})

    def test_updatesFNincorrectly(self):
        # Exercise the SUT
        self.cm.update(SPAM_TAG, HAM_TAG)
        # Assert
        self.assertDictEqual(self.cm.as_dict(),
            {'tp': 0, 'tn': 0, 'fp': 0, 'fn': 1})

    def test_update_raisesValueError_forWrongTruthValue(self):
        # Assert and exercise the SUT
        with self.assertRaises(ValueError):
            self.cm.update('a bad value', SPAM_TAG)

    def test_update_raisesValueError_forWrongPredictionValue(self):
        # Assert and exercise the SUT
        with self.assertRaises(ValueError):
            self.cm.update(SPAM_TAG, 'a bad value')

    def test_computeFromDicts_allCasesOnce(self):
        # Prepare fixture
        truth = {1: SPAM_TAG, 2: SPAM_TAG, 3: HAM_TAG, 4: HAM_TAG}
        prediction = {1: SPAM_TAG, 2: HAM_TAG, 3: SPAM_TAG, 4: HAM_TAG}
        # Exercise the SUT
        self.cm.compute_from_dicts(truth, prediction)
        # Assert
        self.assertDictEqual(self.cm.as_dict(),
            {'tp': 1, 'tn': 1, 'fp': 1, 'fn': 1})

if __name__ == '__main__':
    unittest.main()
```

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 13 / 31

Automatizované testování

Zpracováno podle

Gerard Meszarosz: *xUnit Test Patterns: Refactoring Test Code*,
Addison-Wesley, 2007.

14 / 31

Testování

Kvalita softwaru z pohledu testování:

- Jak dobře kód splňuje specifikace?

Testování z pohledu QA týmu (acceptance tests, functional tests):

- Testujeme, protože jsme si jistí, že kód obsahuje chyby! (Nesplňuje specifikace zákazníka.)
- Testujeme poté, co je kód hotový.
- Obvykle black-box testování.
- Testování je spíš *měření* kvality softwaru, nikoli způsob, jak napsat kvalitní software.
- Zpětná vazba přichází příliš pozdě.
- V minulosti prováděny převážně ručně.

Testování z pohledu programátora (unit tests, integration tests):

- Testuji, protože si chci být jistý, že jednotka, na které právě pracuji, dělá to, co po ní chci. (Splňuje požadavky, které vznikly v důsledku designu architektury softwaru.)
- Obvykle white-box testování.
- V minulosti většinou dočasný kód, který se po otestování zahodil.

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 15 / 31

Automatizované testy: F.I.R.S.T.

Automatizované testy by měly být F.I.R.S.T.

Fast

- Pomalé testy → nebude je spouštět často → chyby odhalíte pozdě

Independent

- Jeden test by neměl nastavovat podmínky pro další test.
- Musí jít spustit každý test samostatně a celou sadu testů v jakémkoli pořadí.
- Závislé testy → jedna chyba spustí celý řetězec chyb v navazujících testezech → složité hledání chyb.

Repeatable

- Možnost *zopakovat* testy kdykoli a kdekoli se stejným výsledkem.
- Testy lze spustit jen někde → budou se pouštět zřídka → chyby odhalíte pozdě

Self-validating

- Dvoustavový výstup → snadné ověřit, zda test prošel nebo selhal.
- Složitý (dlouhý) výstup, který je nutno "ručně" zkontolovat → málo časté testování → pozdní odhalení chyb.

Timely

- Testy by měly být psány včas, ideálně před produkčním kódem.
- Testy psané po produkčním kódu → kód se špatně testuje → nebude se chtít s jeho testováním zdržovat.

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 16 / 31

Modul doctest

- specialita Pythonu (opravte mě, pokud se pletu)
- velmi vhodný pro jednoduché testy nevyžadující žádnou přípravu a úklid
- složitější testy lze dělat také, ale někomu to přijde ... nepřirozené

```
class PrimesGenerator:  
    """Prime numbers generator.  
  
    >>> pg = PrimesGenerator()  
    >>> pg.get_primes_up_to(1)  
    []  
    >>> pg.get_primes_up_to(2)  
    [2]  
    >>> pg.get_primes_up_to(3)  
    [2, 3]  
    >>> pg.get_primes_up_to(4)  
    [2, 3]  
    >>> pg.get_primes_up_to(5)  
    [2, 3, 5]  
    >>> pg.get_primes_up_to(20)  
    [2, 3, 5, 7, 11, 13, 17, 19]  
    """  
    ...  
  
if __name__ == "__main__":  
    import doctest  
    doctest.testmod()
```

xUnit Framework

- Standardní testovací framework
- Implementován v mnoha jazycích (naučte se ho, bude se vám hodit)
- V Pythonu implementován jako modul unittest.

```
import unittest  
from primes3 import PrimesGenerator  
  
class PrimesGeneratorTest(unittest.TestCase):  
  
    known_values = ( ( 0, [] ),  
                     ( 1, [ ] ),  
                     ( 2, [2] ),  
                     ( 3, [2,3] ),  
                     ( 4, [2,3] ),  
                     ( 5, [2,3,5] ),  
                     ( 7, [2,3,5,7] ),  
                     ( 20, [2,3,5,7,11,13,17,19] ))  
  
    def setUp(self):  
        self.pg = PrimesGenerator()  
  
    def test_get_primes_up_to(self):  
        for limit, expected in self.known_values:  
            observed = self.pg.get_primes_up_to(limit)  
            self.assertEqual(observed, expected)  
    ...  
  
if __name__=='__main__':  
    unittest.main()
```

TDD: Vývoj řízený testy

Tři zákony TDD (Test-driven development):

1. Nenapíšeš ani kousek produkčního kódu, aniž bys předtím napsal selhávající unit test.
2. Nenapíšeš větší část unit testu, než je potřebná k selhání (chybě).
3. Nenapíšeš větší část produkčního kódu, než je potřebná ke splnění aktuálně selhávajícího unit testu.

Výsledek těchto pravidel:

- velmi krátký cyklus, v němž střídavě hrajete
 - roli zákazníka, který říká, co se má dělat (píšete test), a
 - roli programátora, který říká, jak se to má dělat (upravujete kód).
- Testy a produkční kód se piší *společně* (testy o pár sekund napřed).
- Testy pak pokrývají všechn produkční kód!

TDD Ukázka

Vytvořte funkci/metodu třídy na faktorizaci čísla na prvočíselné činitele.

- Vstup: číslo, které chceme rozložit
- Výstup: seznam prvočísel, jejichž součin je roven vstupnímu číslu

Jak byste postupovali?

TDD Ukázka: Úvodní fáze

Zakládáme test_factorize.py

```
import unittest
from factorization import factorize
```

Zakládáme prázdný factorization.py

Upravujeme factorization.py:

```
def factorize():
    pass
```

Upravujeme test_factorize.py

```
import unittest
from factorization import factorize

class FactorizeTest(unittest.TestCase):
    pass

if __name__=="__main__":
    unittest.main()
```

Po spuštění test_factorize.py:

```
Traceback (most recent call last):
  File "<string>", line 2, in <fragment>
builtins.ImportError: No module named factorization
```

Po spuštění test_factorize.py:

```
Traceback (most recent call last):
  File "<string>", line 2, in <fragment>
builtins.ImportError: cannot import name factorize
```

Po spuštění test_factorize.py:

```
--- Zadny vystup, kod bez chyby. ---
```

Po spuštění test_factorize.py:

```
-----
Ran 0 tests in 0.000s
OK
builtins.SystemExit: False
```

TDD Ukázka: Test faktorizace čísla 2

Upravujeme test_factorize.py

```
class FactorizeTest(unittest.TestCase):

    def test_two(self):
        observed = factorize(2)
        self.assertEqual(observed, [2])
```

Upravujeme factorization.py:

```
def factorize(product):
    pass
```

Upravujeme factorization.py:

```
def factorize(product):
    return [2]
```

Po spuštění test_factorize.py:

```
E
=====
ERROR: test_one (__main__.FactorizeTest)
-----
Traceback (most recent call last):
  File "<wingdb_compile>", line 7, in test_one
TypeError: factorize() takes no arguments (1 given)
-----
Ran 1 test in 0.000s
```

```
F
=====
FAIL: test_one (__main__.FactorizeTest)
-----
Traceback (most recent call last):
  File "<wingdb_compile>", line 8, in test_one
AssertionError: None != [2]
-----
Ran 1 test in 0.000s
```

```
.
-----
Ran 1 test in 0.000s
```

TDD Ukázka: Test faktORIZACE čísla 3

Upravujeme test_factorize.py:

```
def test_three(self):
    observed = factorize(3)
    self.assertEqual(observed, [3])
```

Po spuštění test_factorize.py:

```
F.
=====
FAIL: test_three (FactorizeTest)
-----
Traceback (most recent call last):
  File "<wingdb_compile>", line 12, in test_three
AssertionError: Lists differ: [2] != [3]

First differing element 0:
2
3

- [2]
+ [3]

-----
Ran 2 tests in 0.016s
```

Upravujeme factorization.py:

```
def factorize(product):
    return [product]
```

```
...
-----
Ran 2 tests in 0.000s
```

TDD Ukázka: Test faktORIZACE čísla 4

Upravujeme test_factorize.py:

```
def test_four(self):
    observed = factorize(4)
    self.assertEqual(observed, [2,2])
```

Po spuštění test_factorize.py:

```
F..
=====
FAIL: test_four (FactorizeTest)
-----
Traceback (most recent call last):
  File "<wingdb_compile>", line 16, in test_four
AssertionError: Lists differ: [4] != [2, 2]
[...snip...]
-----
Ran 3 tests in 0.000s
```

Upravujeme factorization.py:

```
def factorize(product):
    factors = []
    while product % 2 == 0:
        factors.append(2)
        product /= 2
    return factors
```

```
.F.
=====
FAIL: test_three (FactorizeTest)
-----
Traceback (most recent call last):
  File "<wingdb_compile>", line 12, in test_three
AssertionError: Lists differ: [] != [3]
[...snip...]
-----
Ran 3 tests in 0.016s
```

Upravujeme factorization.py:

```
def factorize(product):
    factors = []
    while product % 2 == 0:
        factors.append(2)
        product /= 2
    if product != 1:
        factors.append(product)
    return factors
```

```
...
-----
Ran 3 tests in 0.000s
```

TDD Ukázka: Test faktORIZACE čísla 5

Upravujeme test_factorize.py

```
def test_five(self):
    observed = factorize(5)
    self.assertEqual(observed, [5])
```

Po spuštění test_factorize.py:

```
.....
-----
Ran 4 tests in 0.000s
```

TDD Ukázka: Test faktORIZACE čísla 6

Upravujeme test_factorize.py

```
def test_six(self):
    observed = factorize(6)
    self.assertEqual(observed, [2,3])
```

Po spuštění test_factorize.py:

```
.....
-----
Ran 5 tests in 0.000s
```

Test faktORIZACE čísla 7 vynecháváme, je to stejný případ, jako pro 3 a 5.

TDD Ukázka: Test faktORIZACE čísla 8

Upravujeme test_factorize.py

```
def test_eight(self):
    observed = factorize(8)
    self.assertEqual(observed, [2,2,2])
```

Po spuštění test_factorize.py:

```
.....
-----
Ran 6 tests in 0.000s
```

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 28 / 31

TDD Ukázka: Test faktORIZACE čísla 9

Upravujeme test_factorize.py

```
def test_nine(self):
    observed = factorize(9)
    self.assertEqual(observed, [3,3])
```

Po spuštění test_factorize.py:

```
...F...
=====
FAIL: test_nine (__main__.FactorizeTest)
-----
Traceback (most recent call last):
  File "<wingdb_compile>", line 32, in test_nine
AssertionError: Lists differ: [9] != [3, 3]
[...snip...]
-----
Ran 7 tests in 0.000s
```

Upravujeme factorization.py:

```
def factorize(product):
    factors = []
    for factor in range(2,product+1):
        while product % factor == 0:
            factors.append(factor)
            product /= factor
    return factors
```

```
.....
-----
Ran 7 tests in 0.015s
```

- Jsme schopni přijít na nějaký další test, kde by náš kód selhal?
- Nevadí náhodou, že jako faktory bereme všechna čísla a nikoli jen prvočísla? Jak by se kód lišil?

P. Pošík © 2012

A4B99RPH: Řešení problémů a hry – 29 / 31

TDD Ukázka: Je naše funkce napsaná čistě?

Stávající factorization.py:

```
def factorize(product):
    factors = []
    for factor in range(2,product+1):
        while product % factor == 0:
            factors.append(factor)
            product /= factor
    return factors
```

.....
Ran 7 tests in 0.015s

Přepsaný factorization.py:

```
def factorize(product):
    factors = []
    for factor in range(2,product+1):
        product, factors_subset = factor_out(product, factor)
        factors.extend(factors_subset)
    return factors

def factor_out(product, factor):
    factors = []
    while product % factor == 0:
        factors.append(factor)
        product /= factor
    return product, factors
```

.....
Ran 7 tests in 0.000s

Která z verzí se vám jeví přehlednější/čitelnější?

TDD: Závěr

Testy

- slouží jako specifikace.
- slouží jako dokumentace.
- pomáhají pochopit algoritmus.
- pomáhají předejít zbytečným složitostem v kódu.
- určují, kdy “je hotovo”.
- pomáhají zajistit, abychom úpravami do kódu nevnesli nové chyby.