Dawkins weasel

In his 1986 book *The Blind Watchmaker*, Richard Dawkins says:

> *I don't know who it was first pointed out that, given enough time, a monkey bashing away at random on a typewriter could produce all the works of Shakespeare. The operative phrase is, of course, given enough time. Let us limit the task facing our monkey somewhat. Suppose that he has to produce, not the complete works of Shakespeare but just the short sentence 'METHINKS IT IS LIKE A WEASEL', and we shall make it relatively easy by giving him a typewriter with a restricted keyboard, one with just the 26 (capital) letters, and a space bar. How long will he take to write this one little sentence?*

Then Dawkins suggests that this is a bad analogy for evolution, and proposes the following alternative:

> *We again use our computer monkey, but with a crucial difference in its program. It again begins by choosing a random sequence of 28 letters, just as before … it duplicates it repeatedly, but with a certain chance of random error — 'mutation' — in the copying. The computer examines the mutant nonsense phrases, the 'progeny' of the original phrase, and chooses the one which, however slightly, most resembles the target phrase, 'METHINKS IT IS LIKE A WEASEL'.*

He then describes a computer program that simulates his monkey, which he says took about half an hour to yield the target phrase because it was written in the programming language BASIC. When he rewrote his program in the programming language Pascal, runtime dropped to eleven seconds.

However, Dawkins overlooked to include the source code of the computer program in his book, nor did he include a formal description of the algorithm used. All the book contains is an output sequence of some of the simulations steps generated by the computer program. To illustrate evolution, Dawkins starts with the phrase

```
Y YVMQKZPFJXWVHGLAWFVCHQYOPY
```

New phrases *breed from* this random phrase. The program duplicates the phrase repeatedly, but with a certain chance of random error — a *mutation* — in the copying. Every 10th generation is recorded and its (best) result is displayed:

```
Y YVMQKSPFTXWSHLIKEFV HQYSPY
YETHINKSPITXISHLIKEFA WQYSEY
METHINKS IT ISSLIKE A WEFSEY
METHINKS IT ISBLIKE A WEASES
METHINKS IT ISJLIKE A WEASEO
METHINKS IT IS LIKE A WEASEP
```

This way, the target phrase

```
METHINKS IT IS LIKE A WEASEL
```

was reached in 64 generations. Without a detailed explanation of the algorithm, the procedure for

generating these phrases is open for interpretation. Speculations were fueled even more by a fragment in the BBC series Richard Dawkins made about his book, in which a simulation of the computer program is displayed on a computer screen (see video fragment, starting from 4:40).

Assignment

What Richard Dawkins describes in his book, is a forerunner of what today would be called a genetic algorithm. This is a class of meta-heuristics that is routinely used to generate useful solutions to optimization and search problems by using techniques inspired by natural evolution such as inheritance, mutation, selection and crossover. Your task is to implement some of the basic building blocks of a genetic algorithm.

- Write a function `fitness` that takes two strings. In case the strings have a different length, the function must raise an `AssertionError` with the message `strings must have equal length`. Otherwise, the function must return an integer that indicates the number of positions in which both strings have the same character.
- Write a function `mutation` that takes a single string. The function also has a second optional parameter `mutations` (default value: 1) that takes an integer $m \in \mathbb{N}$. If the given string has length $n \in \mathbb{N}$, the function must return a string containing n uppercase letters and spaces that differs in exactly m positions from the given string. In other words, the given string must have undergone exactly m mutations. Make sure all positions have equal probability for a mutation, and that all uppercase letters or the space have equal probability to replace a letter at a given position. Of course, it must hold that $0 \leq m \leq n$. If this is not the case, the function must raise an `AssertionError` with the message `invalid number of mutations`.
- Write a function `crossover` that takes two strings. In case the strings have a different length, the function must raise an `AssertionError` with the message `strings must have equal length`. The function also has a third optional parameter `point`, that takes an integer $c \in \mathbb{N}_0$. If the given strings have length $n \in \mathbb{N}$, the function must return a tuple containing the two strings that result from crossover of the given strings with crossover point at position c. This crossover procedure is illustrated in the figure below. We put the two strings underneath each other, and after c characters we draw a vertical line across both strings. The first string of the tuple is the concatenation of the part of the first given string to

the left of the line and the part of the second given string to the right of the line. The second string of the tuple is the concatenation of the part of the second given string to the left of the line and the part of the first given string to the right of the line. It must hold that $0 < c < n$. If this is not the case, the function must raise an AssertionError with the message invalid crossover point. In case no value was explicitly passed to the parameter point, a random integer $c \in \mathbb{N}_0$ must be drawn from the interval $0 < c < n$.

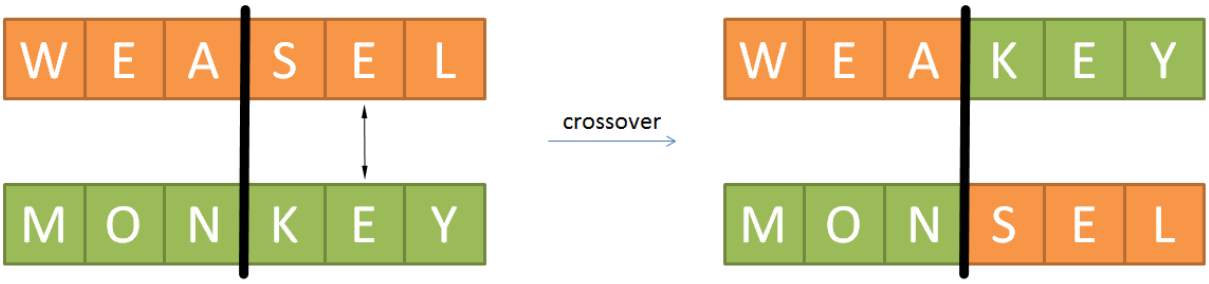

Crossover between the strings WEASEL and MONKEY with a crossover point at position 3.

You may assume that all strings passed as an argument to the above functions only contain uppercase letters and spaces, and have length at least 2. There's no need to explicitly check these conditions.

Example

```
>>> fitness('WEASEL', 'WETSEL')
5
>>> fitness('WEASEL', 'OECYEL')
3
>>> fitness('WEASEL', 'METHINKS')
Traceback (most recent call last):
AssertionError: strings must have equal length

>>> mutation('WEASEL')
'WETSEL'
>>> mutation('WEASEL', mutations=3)
'OECYEL'
>>> mutation('WEASEL', mutations=13)
Traceback (most recent call last):
AssertionError: invalid number of mutations

>>> crossover('WEASEL', 'MONKEY', point=3)
('WEAKEY', 'MONSEL')
>>> crossover('METHINKS', 'AARDVARK')
('MARDVARK', 'AETHINKS')
>>> crossover('WEASEL', 'METHINKS')
Traceback (most recent call last):
AssertionError: strings must have equal length
>>> crossover('WEASEL', 'MONKEY', point=0)
Traceback (most recent call last):
AssertionError: invalid crossover point
>>> crossover('WEASEL', 'MONKEY', point=6)
Traceback (most recent call last):
AssertionError: invalid crossover point
```

In zijn boek *De blinde horlogemaker* (originele titel: *The Blind Watchmaker*) uit 1986 zegt Richard Dawkins:

> *I don't know who it was first pointed out that, given enough time, a monkey bashing away at random on a typewriter could produce all the works of Shakespeare. The operative phrase is, of course, given enough time. Let us limit the task facing our monkey somewhat. Suppose that he has to produce, not the complete works of Shakespeare but just the short sentence 'METHINKS IT IS LIKE A WEASEL', and we shall make it relatively easy by giving him a typewriter with a restricted keyboard, one with just the 26 (capital) letters, and a space bar. How long will he take to write this one little sentence?*

Verderop argumenteert Dawkins dat dit een slechte analogie is voor evolutie, en stelt hij het volgende alternatief voor:

> *We again use our computer monkey, but with a crucial difference in its program. It again begins by choosing a random sequence of 28 letters, just as before … it duplicates it repeatedly, but with a certain chance of random error — 'mutation' — in the copying. The computer examines the mutant nonsense phrases, the 'progeny' of the original phrase, and chooses the one which, however slightly, most resembles the target phrase, 'METHINKS IT IS LIKE A WEASEL'.*

Hij omschrijft daarna een computerprogramma waarmee hij zijn aap gesimuleerd heeft, en waarvan hij beweert dat het een half uur nodig had om tot de gewenste zin te komen omdat het geschreven was in de programmeertaal BASIC. Nadat hij zijn programma had herschreven in de programmeertaal Pascal, duurde het nog slechts elf seconden om de gewenste zin te bekomen.

Dawkins liet echter na om de broncode van het computerprogramma in zijn boek op te nemen, noch om een formele omschrijving van het gebruikte algoritme te geven. Het boek bevat enkel de uitvoer van enkele simulatiestappen van het computerprogramma. Om het principe van evolutie te illustreren, vertrekt Dawkins vanaf de willekeurige zin

```
Y YVMQKZPFJXWVHGLAWFVCHQYOPY
```

Uit deze zin worden telkens nieuwe zinnen *voortgebracht*. Hierbij wordt de zin herhaaldelijk gedupliceerd, waarbij er een zekere kans is op een willekeurige fout — een *mutatie* — tijdens het kopieerproces. Na elke 10 generaties wordt het (beste) resultaat uitgeschreven:

```
Y YVMQKSPFTXWSHLIKEFV HQYSPY
YETHINKSPITXISHLIKEFA WQYSEY
METHINKS IT ISSLIKE A WEFSEY
METHINKS IT ISBLIKE A WEASES
METHINKS IT ISJLIKE A WEASEO
METHINKS IT IS LIKE A WEASEP
```

Op die manier werd de gewenste zin

```
METHINKS IT IS LIKE A WEASEL
```

bekomen na 64 generaties. Zonder een gedetailleerde omschrijving van het algoritme stond de procedure die gebruikt werd om de zinnen te genereren open voor heel wat verschillende interpretaties. De speculaties werden nog verder gevoed door een fragment in de BBC reeks die Richard Dawkins over zijn boek maakte, en waarin een simulatie van het programma op het scherm te zien is (zie onderstaande fragment vanaf 4:40).

Opgave

Wat Richard Dawkins in zijn boek omschrijft, is een voorloper van wat we vandaag een genetisch algoritme zouden noemen. Dit is een klasse van algoritmen die gebruikt worden om oplossingen te vinden voor optimalisatie- en zoekproblemen, waarbij uitgegaan wordt van ideeën uit de evolutietheorie zoals overerving, mutatie, natuurlijke selectie en crossover. Je opdracht bestaat erin enkele bouwstenen voor een genetisch algoritme te implementeren.

- Schrijf een functie `fitness` waaraan twee strings moeten doorgegeven worden. Indien de strings een verschillende lengte hebben, dan moet de functie een `AssertionError` opwerpen met de boodschap `strings moeten even lang zijn`. Anders moet de functie een natuurlijk getal teruggeven dat aangeeft op hoeveel posities eenzelfde karakter staat in de twee strings.
- Schrijf een functie `mutatie` waaraan een string moet doorgegeven worden. De functie heeft ook nog een tweede optionele parameter `mutaties` (standaardwaarde: 1) waaraan een getal $m \in \mathbb{N}$ kan doorgegeven worden. Als de gegeven string $n \in \mathbb{N}$ karakters lang is, dan moet de functie een string van n hoofdletters en spaties teruggeven die in exact m posities verschilt van de gegeven string. De gegeven string moet met andere woorden exact m mutaties ondergaan hebben. Zorg ervoor dat elke positie van de gegeven string evenveel kans maakt om te muteren, en dat alle hoofdletters of de spatie evenveel kans maken om de letter op een bepaalde positie te vervangen. Er moet uiteraard gelden dat $0 \leq m \leq n$. Indien dit niet het geval is, dan moet de functie een `AssertionError` opwerpen met de boodschap `ongeldig aantal mutaties`.
- Schrijf een functie `crossover` waaraan twee strings moeten doorgegeven worden. Indien de strings een verschillende lengte hebben, dan moet de functie een `AssertionError` opwerpen met de boodschap `strings moeten even lang zijn`. De functie heeft ook nog een derde optionele parameter `punt`, waaraan een getal $c \in \mathbb{N}_0$ kan doorgegeven worden. Als de gegeven strings beide $n \in \mathbb{N}$ karakters lang zijn, dan moet de functie een tuple van twee strings teruggeven die ontstaan na crossover van de gegeven strings met crossoverpunt op positie c. Deze crossoverprocedure wordt geïllustreerd in onderstaande figuur. We zetten de twee strings onder elkaar en trekken na c karakters een verticale streep door de twee strings. De eerste string van het tuple wordt gevormd door het deel van de eerste gegeven string links van de streep, gevolgd door het deel van de tweede gegeven string rechts van de streep. De tweede string van het tuple wordt

gevormd door het deel van de tweede gegeven string links van de streep, gevolgd door het deel van de eerste gegeven string rechts van de streep. Er moet gelden dat $0 < c < n$. Indien dit niet het geval is, dan moet de functie een AssertionError opwerpen met de boodschap ongeldig crossoverpunt. Indien er geen expliciete waarde wordt doorgegeven aan de parameter punt, dan moet een willekeurige waarde $c \in \mathbb{N}_0$ gekozen worden waarvoor geldt dat $0 < c < n$.

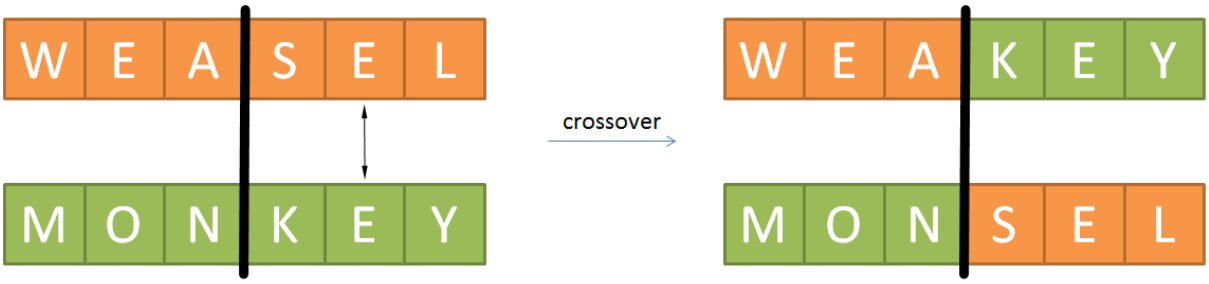

Crossover tussen de strings WEASEL en MONKEY met crossoverpunt op positie 3.

Je mag ervan uitgaan dat alle strings die als argument aan bovenstaande functies worden doorgegeven, enkel bestaan uit hoofdletters en spaties, en dat ze minstens twee karakters lang zijn. Deze voorwaarden hoef je dus niet expliciet te controleren.

Voorbeeld

```
>>> fitness('WEASEL', 'WETSEL')
5
>>> fitness('WEASEL', 'OECYEL')
3
>>> fitness('WEASEL', 'METHINKS')
Traceback (most recent call last):
AssertionError: strings moeten even lang zijn

>>> mutatie('WEASEL')
'WETSEL'
>>> mutatie('WEASEL', mutaties=3)
'OECYEL'
>>> mutatie('WEASEL', mutaties=13)
Traceback (most recent call last):
AssertionError: ongeldig aantal mutaties

>>> crossover('WEASEL', 'MONKEY', punt=3)
('WEAKEY', 'MONSEL')
>>> crossover('METHINKS', 'AARDVARK')
('MARDVARK', 'AETHINKS')
>>> crossover('WEASEL', 'METHINKS')
Traceback (most recent call last):
AssertionError: strings moeten even lang zijn
>>> crossover('WEASEL', 'MONKEY', punt=0)
Traceback (most recent call last):
AssertionError: ongeldig crossoverpunt
>>> crossover('WEASEL', 'MONKEY', punt=6)
Traceback (most recent call last):
AssertionError: ongeldig crossoverpunt
```