

BIO-INFORMATICA

# OWE2A PYTHON II

PROGRAMMEREN IN PYTHON II



**HAN**\_UNIVERSITY  
OF APPLIED SCIENCES

# CURRICULUM OVERZICHT

|         | Periode 1                                                                        | Periode 2                                                       | Periode 3                                         | Periode 4                                                                           |
|---------|----------------------------------------------------------------------------------|-----------------------------------------------------------------|---------------------------------------------------|-------------------------------------------------------------------------------------|
| 1e jaar | Programmeren in Python (1)                                                       | Programmeren in Python (2)                                      | Informatiesystemen met Python                     | Geautomatiseerde identificatie van eiwitten via sequentievergelijking               |
|         | Metabolisme                                                                      | Opsporen van genetische mutaties bij erfelijke ziektes          | Vergelijkende genomanalyse: evolutie van virussen | Sequentie alignment (BLAST) en functionele eiwit analyse                            |
| 2e jaar | Programmeren in Java                                                             | Datastructuren en algoritmen in Java                            | Analyse en ontwerpstechnieken                     | Webtechnologie en textmining                                                        |
|         | Proteomics: eiwitstructuren, eiwitfuncties, scheidingstechnieken en data analyse | Transcriptomics: data analyse mbt regulatie van metabole routes | Genomics: annoteren van genomisch DNA             | Moleculaire fylogenie: evolutie, multiple sequence alignment mbt signaaltransductie |
| 3e jaar | Stage of minor                                                                   |                                                                 | Data Mining en grid computing                     | RNA seq, biostatistiek,                                                             |
|         |                                                                                  |                                                                 | Eiwitten: carcinogenese en eiwitstructuren        | Workflows                                                                           |
| 4e jaar | Stage, afstudeerstage of minor                                                   |                                                                 | Minor of afstudeerstage                           |                                                                                     |

# JAAR 1

Basis van programmeren in Python

Complexe structuren

Databases voor opslag van data

|         | Periode 1                  | Periode 2                                              | Periode 3                                         | Periode 4                                                             |
|---------|----------------------------|--------------------------------------------------------|---------------------------------------------------|-----------------------------------------------------------------------|
| 1e jaar | Programmeren in Python (1) | Programmeren in Python (2)                             | Informatiesystemen met Python                     | Geautomatiseerde identificatie van eiwitten via sequentievergelijking |
|         | Metabolisme                | Opsporen van genetische mutaties bij erfelijke ziektes | Vergelijkende genomanalyse: evolutie van virussen | Sequentie alignment (BLAST) en functionele eiwit analyse              |

Ontwikkelen van applicaties voor biologisch analyse en visualisatie op het web

# OVERZICHT OWE 1A INFORMATICA

| Week | Onderwerpen                                                  |                       |
|------|--------------------------------------------------------------|-----------------------|
| 1    | IDE: <u>PyCharm</u><br>Debuggen en testen<br>PEP richtlijnen | <u>PEP tutorial</u>   |
| 2    | Grafieken met<br>Matplotlib                                  | <u>Matplotlib.org</u> |
| 3    | Datastructuren                                               | H9 SowP               |
| 4    | Regular Expressions                                          | H7 DiP                |
| 5    | Object Oriëntatie                                            | H10 & H11 SowP        |
| 6    | Recursie                                                     | H12 SowP              |
| 7    | Graphical User<br>Interface                                  | H13 SowP              |

# AGENDA

1. Datastructuren
2. Dictionaries
3. Sets
4. Serializing objects

# WAAROM LEREN WE DATASTRUCTUREN?

- Datastructuren versnellen processen
- Ze zijn intuïtief en werken makkelijker

# WANNEER GEBRUIKEN WE DATASTRUCTUREN?

- Het netwerk van vrienden op Facebook zit in een datastructuur (Graph)
- Het telefoonboek in je telefoon zit in een datastructuur (Dictionary)
- De beschrijving van afstamming (Fylogenetische boom)

# LIJSTEN (1/2)

- In Python hebben we list
- Lists zijn makkelijk om lineaire data op te slaan
- In de informatica spreken we meestal over arrays

## LIJSTEN (2/2)

- Lijsten zijn geordend
- Lijsten hebben als nadeel dat het niet heel snel zoeken is naar een item als je de index niet kent

# AGENDA

1. Datastructuren
2. Dictionaries
3. Sets
4. Serializing objects

# DICTIONARIES

- In Python kennen we dictionaries
- Dictionaries heten officieel hashmaps
- Een hashmap maakt het mogelijk heel snel een waarde terug te vinden
- Hashmaps maken gebruik van een sleutel-waarde combinatie

# WAAROM DICTIONARIES?

```
lijst1 = ["Koe", "Geit", "Mier", "Slang", "Mus"]  
lijst2 = [4, 4, 6, 0, 2]
```

Wat is de betekenis van  
Lijst2?

```
dieren = ["Koe", "Geit", "Mier", "Slang", "Mus"]  
poten  = [4, 4, 6, 0, 2]
```

# CODE OM VRAAG TE BEANTWOORDEN

Hoe schrijven we de code om de vraag te beantwoorden hoeveel poten een koe heeft?

```
dieren = ["Koe", "Geit", "Mier", "Slang", "Mus"]
poten  = [4, 4, 6, 0, 2]

dier_vraag = input ("Aantal poten van een ")
teller = 0
for dier in dieren:
    if dier == dier_vraag:
        print ("Uw dier heeft ", poten[teller], " poten")
        teller += 1
```

# MET EEN DICTIONARY

- De vraag hoeveel poten een dier heeft is nu razendsnel te beantwoorden
- Er zijn *key-value pairs*

Key

Value

```
dieren = {"Koe":4, "Geit":4, "Mier":6, "Slang":0, "Mus":2}  
dier_vraag = input ("Aantal poten van een ")  
print ("Uw dier heeft ",dieren[dier_vraag], " poten")
```

# VRAAG

Maar kan ik ook de vraag beantwoorden welke dieren 6 poten hebben?

```
dieren = {"Koe":4, "Geit":4, "Mier":6, "Slang":0, "Mus":2}  
dier_vraag = input ("Aantal poten van een ")  
print ("Uw dier heeft ",dieren[dier_vraag], " poten")
```

# KEYS() EN VALUES()

De keys van een dictionary

```
>>> print (dieren.keys())  
dict_keys(['Mier', 'Geit', 'Koe', 'Mus', 'Slang'])
```

De values van een dictionary

```
>>> print (dieren.values())  
dict_values([6, 4, 4, 2, 0])
```

# WELKE DIEREN HEBBEN 6 POTEN?

- De dictionary is zeer geschikt om te bepalen hoeveel poten een dier heeft
- De dictionary is totaal ongeschikt om te bepalen welke dieren een bepaald aantal poten hebben

```
# Welke dieren hebben 6 poten?  
teller = 0  
lijst = list(dieren.values())  
for aantal in lijst:  
    if aantal == 6:  
        print (list(dieren.keys())[teller])  
        teller += 1
```

# DICTIONARIES

Een woordenboek **Nederlands-Engels** is erg geschikt om het Nederlandse woord **lintworm** op te zoeken

Een woordenboek **Engels-Nederlands** is totaal ongeschikt om het Engelse woord voor **lintworm** op te zoeken

# DICTIONARY IN DE BIO-INFORMATICA

Al onze cellen hebben ook een dictionary...

```
code = { 'ttt': 'F', 'tct': 'S', 'tat': 'Y', 'tgt': 'C',  
        'ttc': 'F', 'tcc': 'S', 'tac': 'Y', 'tgc': 'C',  
        'tta': 'L', 'tca': 'S', 'taa': '*', 'tga': '*',  
        'ttg': 'L', 'tcg': 'S', 'tag': '*', 'tgg': 'W',  
        'ctt': 'L', 'cct': 'P', 'cat': 'H', 'cgt': 'R',  
        'ctc': 'L', 'ccc': 'P', 'cac': 'H', 'cgc': 'R',  
        'cta': 'L', 'cca': 'P', 'caa': 'Q', 'cga': 'R',  
        'ctg': 'L', 'ccg': 'P', 'cag': 'Q', 'cgg': 'R',  
        'att': 'I', 'act': 'T', 'aat': 'N', 'agt': 'S',  
        'atc': 'I', 'acc': 'T', 'aac': 'N', 'agc': 'S',  
        'ata': 'I', 'aca': 'T', 'aaa': 'K', 'aga': 'R',  
        'atg': 'M', 'acg': 'T', 'aag': 'K', 'agg': 'R',  
        'gtt': 'V', 'gct': 'A', 'gat': 'D', 'ggc': 'G',  
        'gtc': 'V', 'gcc': 'A', 'gac': 'D', 'ggc': 'G',  
        'gta': 'V', 'gca': 'A', 'gaa': 'E', 'gga': 'G',  
        'gtg': 'V', 'gcg': 'A', 'gag': 'E', 'ggg': 'G'  
}
```

Eigen werk auteur

# WERKING DICTIONARY

```
code = { 'ttt': 'F', 'tct': 'S', 'tat': 'Y', 'tgt': 'C',  
        'ttc': 'F', 'tcc': 'S', 'tac': 'Y', 'tgc': 'C',  
        'tta': 'L', 'tca': 'S', 'taa': '*', 'tga': '*',  
        'ttg': 'L', 'tcg': 'S', 'tag': '*', 'tgg': 'W',  
        'ctt': 'L', 'cct': 'P', 'cat': 'H', 'cgt': 'R',  
        'ctc': 'L', 'ccc': 'P', 'cac': 'H', 'cgc': 'R',  
        'cta': 'L', 'cca': 'P', 'caa': 'Q', 'cga': 'R',  
        'ctg': 'L', 'ccg': 'P', 'cag': 'Q', 'cgg': 'R',  
        'att': 'I', 'act': 'T', 'aat': 'N', 'agt': 'S',  
        'atc': 'I', 'acc': 'T', 'aac': 'N', 'agc': 'S',  
        'ata': 'I', 'aca': 'T', 'aaa': 'K', 'aga': 'R',  
        'atg': 'M', 'acg': 'T', 'aag': 'K', 'agg': 'R',  
        'gtt': 'V', 'gct': 'A', 'gat': 'D', 'ggt': 'G',  
        'gtc': 'V', 'gcc': 'A', 'gac': 'D', 'ggc': 'G',  
        'gta': 'V', 'gca': 'A', 'gaa': 'E', 'gga': 'G',  
        'gtg': 'V', 'gcg': 'A', 'gag': 'E', 'ggg': 'G'  
}
```

**code['act']**      **T**

# DICTIONARY

- Maar om alle codons op te halen voor een aminozuur is het juist erg lastig
- Daarvoor zou je een andere dictionary nodig hebben

# DICTIONARY AMINOZUUR → CODON

```
aa3 = {"Ala": ["GCU", "GCC", "GCA", "GCG"],
      "Arg": ["CGU", "CGC", "CGA", "CGG", "AGA", "AGG"],
      "Asn": ["AAU", "AAC"],
      "Asp": ["GAU", "GAC"],
      "Cys": ["UGU", "UGC"],
      "Gln": ["CAA", "CAG"],
      "Glu": ["GAA", "GAG"],
      "Gly": ["GGU", "GGC", "GGA", "GGG"],
      "His": ["CAU", "CAC"],
      "Ile": ["AUU", "AUC", "AUA"],
      "Leu": ["UUA", "UUG", "CUU", "CUC", "CUA", "CUG"],
      "Lys": ["AAA", "AAG"],
      "Met": ["AUG"],
      "Phe": ["UUU", "UUC"],
      "Pro": ["CCU", "CCC", "CCA", "CCG"],
      "Ser": ["UCU", "UCC", "UCA", "UCG", "AGU", "AGC"],
      "Thr": ["ACU", "ACC", "ACA", "ACG"],
      "Trp": ["UGG"],
      "Tyr": ["UAU", "UAC"],
      "Val": ["GUU", "GUC", "GUA", "GUG"],
      "Start": ["AUG", "CUG", "UUG", "GUG", "AUU"],
      "Stop": ["UAG", "UGA", "UAA"]}
}
```

['UUA', 'UUG', 'CUU', 'CUC', 'CUA', 'CUG']

# KENMERKEN DICTIONARY

- Een dictionary is ongeordend
- Bevat altijd een sleutel-waarde combinatie
- De waarde mag zelf wel weer een complexe datastructuur zijn als een list, set of dictionary
- De snelheid van het retourneren van een waarde is onafhankelijk van de grootte van de dictionary

# SAMENGEVAT

- Dictionaries zijn erg geschikt om alles wat een sleutel-waarde combinatie op te slaan
- Het zorgt er voor dat je razendsnel hetgeen je zoekt terug krijgt

# AGENDA


1. Datastructuren
2. Dictionaries
3. Sets
4. Serializing objects

# SETS


- We kunnen in Python met verzamelingen werken en met set operatoren bewerkingen op uitvoeren

| Python       | Betekenis    |
|--------------|--------------|
| Union        | Samenvoeging |
| Intersection | Overlap      |
| Difference   | Verschil     |


$A \cup B$  Union



$A \cap B$  Intersection



$A - B$  Difference



# CREATIE VAN EEN SET

Een set maak je met het sleutelwoord set


```
mijnSet = set(["apen", "noten"])
```

Voor het toevoegen van waardes gebruik je add

```
mijnSet.add("miezen")
```

# SETS BESTAAN UIT UNIEKE WAARDES


```
boerderij = set(["Koe", "Geit", "Varken", "Konijn", "Konijn"])  
dierentuin = set(["Olifant", "Giraffe", "Zebra", "Konijn", "Geit"])  
print (boerderij)  
print (dierentuin)
```



```
{'Koe', 'Varken', 'Konijn', 'Geit'}  
{'Giraffe', 'Olifant', 'Zebra', 'Geit', 'Konijn'}
```


# SETS HEBBEN VEEL EIGEN METHODES

```
boerderij = set(["Koe", "Geit", "Varken", "Konijn", "Konijn"])
dierentuin = set(["Olifant", "Giraffe", "Zebra", "Konijn", "Geit"])
print (boerderij)
print (dierentuin)
```




# SET OPERATIONS


$A \cup B$  Union



$A \cap B$  Intersection



$A - B$  Difference



| Statement                        | Actie                                                          |
|----------------------------------|----------------------------------------------------------------|
| <code>s1.union(s2)</code>        | Retourneert een set alle items in s1 en s2                     |
| <code>s1.intersection(s2)</code> | Retourneert een set van items die zowel in s1 als s2 voorkomen |
| <code>s1.difference(s2)</code>   | Retourneert een set van items in s1 die niet in s2 voorkomen   |

# SETS EN OPERATOREN



Vul deze tabel in

|                            | Union           | Intersection | Difference   |
|----------------------------|-----------------|--------------|--------------|
| A: 12 5 17 6<br>B: 42 17 6 | 12 5 42 17<br>6 | 17 6         | 12 5         |
| A: 21 76 10 3<br>9<br>B:   | 21 76 10 3<br>9 |              | 21 76 10 3 9 |
| A: 87<br>B: 22 87 23       | 22 87 23        | 87           |              |

# VERSCHIL


Welke dieren komen wel voor op de boerderij maar niet in de dierentuin?

```
boerderij = set(["Koe", "Geit", "Varken", "Konijn", "Konijn"])
dierentuin = set(["Olifant", "Giraffe", "Zebra", "Konijn", "Geit"])

print (boerderij.difference(dierentuin))

{'Koe', 'Varken'}
```

# SYMMETRIC DIFFERENCE



**A Symmetric Difference B : C**

# SYMMETRIC DIFFERENCE

Bij een `symmetric_difference` verkrijg je van beide sets wat niet in de overlap zit

| Statement                                | Actie                                                                |
|------------------------------------------|----------------------------------------------------------------------|
| <code>s1.difference(s2)</code>           | Retourneert een set van items in s1 die niet in s2 voorkomen         |
| <code>s1.symmetric_difference(s2)</code> | Retourneert een set van items die niet in s1 en niet in s2 voorkomen |

Hoe toon je de overeenkomst tussen een dataScientist en dataEngineer?

```
dataScientist = set(['Python', 'R', 'SQL', 'Git',  
                    'Tableau', 'SAS'])  
dataEngineer = set(['Python', 'Java', 'Scala', 'Git',  
                    'SQL', 'Hadoop'])
```

```
>>>  
dataScientist.intersection(dataEngineer)  
{'SQL', 'Git', 'Python'}
```

```
>>>  
dataEngineer.intersection(dataScientist)  
{'SQL', 'Git', 'Python'}
```

# SUBSET EN SUPERSET

Met `issubset` kunnen we bepalen of het een deelverzameling betreft

Met `issuperset` kunnen we bepalen of het de ander set ook omvat

```
>>> set1 = set([1, 2, 3, 4])
>>> set2 = set([2, 3])
>>> set1.issubset (set2)
False
>>> set2.issubset (set1)
True
>>> set1.issuperset (set2)
True
>>> set2.issuperset (set1)
False
>>>
```

# SETS: SUBSET EN SUPERSSET



Vul de volgende tabel in

|                               | A issubset B | A issuperset B |
|-------------------------------|--------------|----------------|
| A: 12 5 17 6<br>B: 42 17 6    | False        | False          |
| A: 19 21 88<br>76<br>B: 21 76 | False        | True           |
| A: 87<br>B: 22 87 23          | True         | False          |

# KENMERKEN SETS

- Sets bevatten altijd unieke waarden
- Sets zijn ongeordend: de volgorde waarin waarden voorkomen is willekeurig
- Sets mogen zowel getallen als strings bevatten
- Sets zijn zeer geschikt voor het vergelijken van verzameling

# SAMENVATTEND

- Sets zijn ongeordende verzamelingen van unieke waarden
- Ze zijn erg geschikt om verschillen en overeenkomsten tussen groepen te bepalen

# AGENDA

1. Datastructuren
2. Dictionaries
3. Sets
4. Serializing objects

# WAT IS SERIALIZATION?

- Met serialization *bevries* je objecten (datastructuren) en kun je deze opslaan in een bestand
- Serialization heeft tot doel objecten tijdelijk op te slaan en later weer te kunnen gebruiken

# WAT IS EEN BINARY FILE?

- Een binary file is een computer readable file ofwel niet human readable

```
0000000 0000 0001 0001 1010 0010 0001 0004 0128
0000010 0000 0016 0000 0028 0000 0010 0000 0020
0000020 0000 0001 0004 0000 0000 0000 0000 0000
0000030 0000 0000 0000 0010 0000 0000 0000 0204
0000040 0004 8384 0084 c7c8 00c8 4748 0048 e8e9
0000050 00e9 6a69 0069 a8a9 00a9 2828 0028 fdfe
0000060 00fc 1819 0019 9898 0098 d9d8 00d8 5857
0000070 0057 7b7a 007a bab9 00b9 3a3c 003c 8888
0000080 8888 8888 8888 8888 288e be88 8888 8888
0000090 3b83 5788 8888 8888 7667 778e 8828 8888
00000a0 d61f 7abd 8818 8888 467c 585f 8814 8188
00000b0 8b06 e8f7 88aa 8388 8b3b 88f3 88bd e988
00000c0 8a18 880c e841 c988 b328 6871 688e 958b
00000d0 a948 5862 5884 7e81 3788 1ab4 5a84 3eec
00000e0 3d86 dcb8 5cbb 8888 8888 8888 8888 8888
00000f0 8888 8888 8888 8888 8888 8888 8888 0000
0000100 0000 0000 0000 0000 0000 0000 0000 0000
*
0000130 0000 0000 0000 0000 0000 0000 0000
000013e
```

# WAT IS HET NUT VAN SERIALIZATION?

# KENMERKEN SERIALIZATION

- Objecten en datastructuren worden tijdelijk opgeslagen voor gebruik later
- In Python wordt niet gesproken over serialization maar over pickling (op zuur zetten)

```
import pickle
```

```
def bepaalBi(bestandsnaam):  
    """Bepaal de bil klassen
```

```
    input:  
    bestandsnaam, str, naam bestand
```

```
    return  
    """
```

```
    meer = 'j'
```

```
    try:  
        input_file = open(bestandsnaam, 'rb')  
        bil = pickle.load(input_file)  
        input_file.close()
```

```
    except IOError:  
        bil = set()
```

```
    while meer.lower()=="j":  
        print("Studenten in Bil: ", bil)  
        student = input("Student: ")  
        bil.add(student)  
        meer = input("Doorgaan (j/n)")
```

```
    output_file = open(bestandsnaam, 'wb')  
    pickle.dump(bil, output_file)  
    output_file.close()  
    return
```

```
def main():  
    bestandsnaam = "studenten.dat"  
    bepaalBi(bestandsnaam)
```

```
main()
```

Read van een Binary bestand

Laden van een pickle bestand

Als bestand niet bestaat: maak lege set

Write van een Binary bestand

Dump van een pickle bestand

# MET OPEN WITH

```
import pickle

def bepaalBi(bestandsnaam):
    """Bepaal de bil klassen

    input:
    bestandsnaam, str, naam bestand

    return
    """
    meer = 'j'
    try:
        with open(bestandsnaam, 'rb') as input_file:
            bil = pickle.load(input_file)
    except IOError:
        bil = set()
    while meer.lower() == "j":
        print("Studenten in Bil: ", bil)
        student = input("Student: ")
        bil.add(student)
        meer = input("Doorgaan (j/n)")
    with open(bestandsnaam, 'wb') as output_file:
        pickle.dump(bil, output_file)
    return

def main():
    bestandsnaam = "studenten.dat"
    bepaalBi(bestandsnaam)

main()
```

# SAMENVATTING SERIALIZATION

- Serialization maakt het mogelijk complexe datastructuren op te slaan
- Gebruik in Python daarvoor de module pickle

# SAMENVATTING DATASTRUCTUREN

- Datastructure
  - HashTable (Dictionaries)
  - Sets
- Serializing objects

# APPENDIX

Tellen van codons en aminozuren

# BEPAAL AANTAL AMINOZUREN

Bepaal het aantal aminozuren in een sequentie:

- Met dictionaries
  - Zonder dictionaries
- ```
# Bepaal per aminozuur aantal in een sequentie
seq = "MTSSRLWFSLLLAAAFAGRATALWPWPQNFQTSQRYVLYPNNFQFQYDV"
A = seq.count("A")
B = seq.count("B")
C = seq.count("C")
D = seq.count("D")
G = seq.count("G")
H = seq.count("H")
K = seq.count("K")
M = seq.count("M")
N = seq.count("N")
R = seq.count("R")
S = seq.count("S")
T = seq.count("T")
V = seq.count("V")
W = seq.count("W")
Y = seq.count("Y")
print ("A =", A, "B =", B, "C =", C, "D =", D, "G =", G, "H =", H, "K =", K, "M =", M, "N =", N, "R =", R, "S =", S, "T =", T, "V =", V, "W =", W, "Y =", Y)
```

# BEPAAL AANTAL AMINOZUREN

Met een dictionary is het veel eenvoudiger tellen

```
seq = "MTSSRLWFSLLLAAAFAGRATALWPWPQNFQTSDQRYVLYPNNFQFQYDV"  
aantal = {}  
for letter in seq:  
    aantal[letter] = seq.count(letter)  
print (aantal)
```

# BEPAAL HET AANTAL CODONS

Maak een dictionary met het aantal als waarde en de codon als key. Gebruik hiervoor een willekeurige DNA sequentie

```
seq = "TCTCCAAGACGCATCCCAGTG"
codon_aantal = {}
for i in range(0, len(seq) - len(seq)%3, 3):
    codon = seq[i:i+3]
    codon_aantal[codon] = 0
    codon_aantal[codon] = codon_aantal[codon] + 1
print (codon_aantal)

{'ATC': 1, 'GTG': 1, 'TCT': 1, 'AGA': 1, 'CCA': 1, 'CGC': 1}
```

# VERANTWOORDING

- In deze uitgave is géén auteursrechtelijk beschermd werk opgenomen
- Alle teksten © Teuntje Peeters/HAN tenzij expliciet externe bronnen zijn aangegeven
- Screenshots op basis van eigen werk auteur en/of vernoemde sites
- Eventuele images zijn opgenomen met vermelding van bron