



ΠΑΝΕΠΙΣΤΗΜΙΟ  
ΘΕΣΣΑΛΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

Ευφυής Σύμβουλος Επαγγελματικού  
Προσανατολισμού

ΔΙΑΜΑΝΤΑΣ ΑΘΑΝΑΣΙΟΣ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΥΠΕΥΘΥΝΟΣ

Κωνσταντίνος Κολομβάτσος

Επίκουρος Καθηγητής

Τμήματος Πληροφορικής & Τηλεπικοινωνιών Πανεπιστημίου Θεσσαλίας

Λαμία 2021



«Με ατομική μου ευθύνη και γνωρίζοντας τις κυρώσεις <sup>(1)</sup>, που προβλέπονται από της διατάξεις της παρ. 6 του άρθρου 22 του Ν. 1599/1986, δηλώνω ότι:

1. Δεν παραθέτω κομμάτια βιβλίων ή άρθρων ή εργασιών άλλων αυτολεξεί **χωρίς να τα περικλείω σε εισαγωγικά** και χωρίς να αναφέρω το συγγραφέα, τη χρονολογία, τη σελίδα. Η αυτολεξεί παράθεση χωρίς εισαγωγικά χωρίς αναφορά στην πηγή, είναι λογοκλοπή. Πέραν της αυτολεξεί παράθεσης, λογοκλοπή θεωρείται και η παράφραση εδαφίων από έργα άλλων, συμπεριλαμβανομένων και έργων συμφοιτητών μου, καθώς και η παράθεση στοιχείων που άλλοι συνέλεξαν ή επεξεργάστηκαν, χωρίς αναφορά στην πηγή. Αναφέρω πάντοτε με πληρότητα την πηγή κάτω από τον πίνακα ή σχέδιο, όπως στα παραθέματα.

2 Δέχομαι ότι η αυτολεξεί **παράθεση χωρίς εισαγωγικά**, ακόμα κι αν συνοδεύεται από αναφορά στην πηγή σε κάποιο άλλο σημείο του κειμένου ή στο τέλος του, είναι αντιγραφή. Η αναφορά στην πηγή στο τέλος π.χ. μιας παραγράφου ή μιας σελίδας, δεν δικαιολογεί συρραφή εδαφίων έργου άλλου συγγραφέα, έστω και παραφρασμένων, και παρουσίασή τους ως δική μου εργασία.

3. Δέχομαι ότι υπάρχει επίσης περιορισμός στο μέγεθος και στη συχνότητα των παραθεμάτων που μπορώ να εντάξω στην εργασία μου εντός εισαγωγικών. Κάθε μεγάλο παράθεμα (π.χ. σε πίνακα ή πλαίσιο, κλπ), προϋποθέτει ειδικές ρυθμίσεις, και όταν δημοσιεύεται προϋποθέτει την άδεια του συγγραφέα ή του εκδότη. Το ίδιο και οι πίνακες και τα σχέδια

4. Δέχομαι όλες τις συνέπειες σε περίπτωση λογοκλοπής ή αντιγραφής.

Ημερομηνία: 23/11/2021

**Ο Δηλών**

**(1)** «Όποιος εν γνώσει του δηλώνει ψευδή γεγονότα ή αρνείται ή αποκρύπτει τα αληθινά με έγγραφη υπεύθυνη δήλωση του άρθρου 8 παρ. 4 Ν. 1599/1986 τιμωρείται με φυλάκιση τουλάχιστον τριών μηνών. Εάν ο υπαίτιος αυτών των πράξεων σκόπευε να προσπορίσει στον εαυτόν του ή σε άλλον περιουσιακό όφελος βλάπτοντας τρίτον ή σκόπευε να βλάψει άλλον, τιμωρείται με κάθειρξη μέχρι 10 ετών.»



## ΠΕΡΙΛΗΨΗ

Σε μία εποχή ταχύρρυθμης ζωής και ραγδαίας εξέλιξης, οι προσπάθειες για την αυτοματοποίηση όσων περισσότερων διαδικασιών είναι δυνατόν, μοιάζουν απολύτως λογικές. Πλέον, με το υψηλό επίπεδο ανάπτυξης της τεχνητής νοημοσύνης και της μηχανικής μάθησης που υφίσταται, τα chatbots μπορούν να φέρουν εις πέρας έναν τεράστιο αριθμό διαδικασιών διευκολύνοντας τη ζωή των ανθρώπων. Όλο και περισσότερες εταιρείες κολοσσοί όπως η Google, η Amazon, η Apple, η Microsoft και αρκετές άλλες έχουν δημιουργήσει ήδη τους δικούς τους βοηθούς οι οποίοι χρησιμοποιούνται κυρίως για την εξυπηρέτηση των πελατών. Εξυπηρετούν πελάτες συνήθως σε σχετικά απλά ζητήματα ή κάνουν ερωτήσεις ώστε να καταλάβουν τι ζητάει ο πελάτης. Με αυτό τον τρόπο, μειώνουν το γενικό κόστος καθώς “ελευθερώνουν” προσωπικό ώστε να μπορούν να κάνουν άλλες εργασίες, ενώ ταυτόχρονα ενισχύουν και την ποιότητα των υπηρεσιών προς τους πελάτες.

Ο στόχος αυτής της πτυχιακής εργασίας είναι η κατανόηση των chatbots και των recommendation systems, η παρουσίαση σύγχρονων παραδειγμάτων εφαρμογών καθώς και η ανάλυση των βασικών αλγορίθμων που χρησιμοποιούνται για την υλοποίηση και ανάπτυξη τους. Επίσης γίνεται μία αναφορά στο μέλλον των chatbots καθώς και στις μελλοντικές προκλήσεις που πρέπει να αντιμετωπιστούν. Τέλος, στα πλαίσια της πτυχιακής εργασίας υλοποιήθηκε ένας έξυπνος βοηθός ο οποίος έχει το ρόλο ενός συμβούλου επαγγελματικού προσανατολισμού. Ο επαγγελματικός προσανατολισμός είναι αρκετά σημαντικός στις μέρες μας, ιδιαίτερα στην Ελλάδα όπου οι έφηβοι καλούνται από πολύ νωρίς να πάρουν σημαντικές αποφάσεις που θα καθορίσουν την ενήλικη ζωή τους. Το προτεινόμενο chatbot, μέσα από ένα quiz ερωτήσεων έχει την ικανότητα να γνωρίσει τον χρήστη και να τον βοηθήσει να επιλέξει το επάγγελμα που του ταιριάζει περισσότερο.

©2021

Αθανάσιος Διαμαντάς

Τμήμα Πληροφορικής και Τηλεπικοινωνιών

Πανεπιστήμιο Θεσσαλίας

## **ABSTRACT**

In an age of fast-paced life and rapid evolution, efforts to automate as many processes as possible seem perfectly reasonable. Now, with the high level of development of artificial intelligence and machine learning, chatbots can carry out a huge number of processes making life easier for people. Giant companies like Google, Amazon, Apple, Microsoft and several others have already created their own assistants which are mainly used for customer service. They usually serve customers with relatively simple requests or ask questions to understand what the customer is looking for. In this way, they reduce the overall cost of the companies as they “free” staff so that they can do other work, while at the same time enhancing the customer experience.

The aim of this thesis is the understanding of chatbots and recommendation systems, the presentation of modern applications examples as well as the analysis of the basic algorithms adopted for their implementation and development. There is also a discussion on the future of chatbots as well as to the future challenges that need to be addressed. Finally, in the context of the thesis, an intelligent assistant was implemented having the role of a vocational guidance consultant. Vocational guidance is quite important nowadays, especially in Greece where teenagers are urged to take from a very early age important decisions that will determine their adult life. The proposed chatbot, through a quiz of questions has the ability to get to know the user and assist him/her to choose the job that best suits to his/her interests.

©2021

Athanasios Diamantas

Department of Computer Science and Telecommunications

University of Thessaly



# ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

<b>ΠΕΡΙΛΗΨΗ</b> .....	IV
<b>ABSTRACT</b> .....	V
<b>ΚΕΦΑΛΑΙΟ 1 - ΕΙΣΑΓΩΓΗ</b> .....	- 1 -
1.1 ΣΚΟΠΟΣ ΤΗΣ ΠΤΥΧΙΑΚΗΣ.....	- 1 -
1.2 ΓΙΑΤΙ ΣΥΜΒΟΥΛΟΣ ΕΠΑΓΓΕΛΜΑΤΙΚΟΥ ΠΡΟΣΑΝΑΤΟΛΙΣΜΟΥ;.....	- 1 -
1.3 ΔΟΜΗ ΤΗΣ ΠΤΥΧΙΑΚΗΣ .....	- 2 -
<b>ΚΕΦΑΛΑΙΟ 2 - CHATBOTS</b> .....	- 3 -
2.1 ΤΙ ΕΙΝΑΙ ΤΑ CHATBOTS .....	- 3 -
2.2 Η ΙΣΤΟΡΙΑ ΤΩΝ CHATBOTS .....	- 4 -
2.3 ΜΕΡΙΚΑ ΑΠΟ ΤΑ ΠΙΟ ΚΑΙΝΟΤΟΜΑ CHATBOTS .....	- 7 -
2.3.1 ENDURANCE’S CHATBOT.....	- 7 -
2.3.2 INSOMNOBOT 3000 .....	- 7 -
2.3.3 HIPMUNK AND HELLO CHATBOTS .....	- 8 -
2.3.4 WHO’S CHATBOT.....	- 9 -
2.4 ΠΩΣ ΛΕΙΤΟΥΡΓΟΥΝ ΤΑ CHATBOTS .....	- 9 -
2.4.1 RULE-BASED CHATBOTS.....	- 10 -
2.4.2 INTELLIGENT CHATBOTS.....	- 11 -
2.4.3 AI-BASED CHATBOTS .....	- 11 -
2.5 ΤΟ ΜΕΛΛΟΝ ΤΩΝ CHATBOTS .....	- 12 -
2.5.1 MULTIMODAL CHATBOTS.....	- 12 -
2.5.2 VISUAL DIALOGUE AND GROUNDED LANGUAGE LEARNING.....	- 14 -
2.5.3 ΛΟΓΙΚΗ ΚΑΙ ΣΥΝΕΡΓΑΤΙΚΗ ΕΠΙΛΥΣΗ ΠΡΟΒΛΗΜΑΤΩΝ ΣΕ ΜΙΑ ΣΥΝΟΜΙΛΙΑ ...	- 16 -
2.5.4 ΔΙΑΛΟΓΟΣ ΚΑΙ ΔΙΑΔΙΚΤΥΟ ΤΩΝ ΠΡΑΓΜΑΤΩΝ .....	- 16 -
<b>ΚΕΦΑΛΑΙΟ 3 - RECOMMENDATION SYSTEMS</b> .....	- 19 -
3.1 ΕΙΣΑΓΩΓΗ ΣΤΑ RECOMMENDATION SYSTEMS.....	- 19 -
3.2 ΕΠΕΞΗΓΗΣΗ ΟΝΤΟΤΗΤΩΝ ΤΩΝ ΣΥΣΤΗΜΑΤΩΝ ΣΥΣΤΑΣΕΩΝ.....	- 20 -
3.2.1 ΧΡΗΣΤΕΣ .....	- 20 -
3.2.2 ΑΝΤΙΚΕΙΜΕΝΑ.....	- 21 -
3.2.3 ΕΝΕΡΓΕΙΕΣ.....	- 21 -
3.3 ΤΕΧΝΙΚΕΣ ΤΩΝ RECOMMENDATION SYSTEMS .....	- 22 -
3.3.1 CONTENT-BASED RECOMMENDATION SYSTEM.....	- 23 -
3.3.2 COLLABORATIVE FILTERING.....	- 25 -
3.3.3 HYBRID RECOMMENDATION SYSTEM .....	- 27 -



3.4 ΠΡΟΚΛΗΣΕΙΣ ΤΩΝ ΣΥΣΤΗΜΑΤΩΝ ΣΥΣΤΑΣΕΩΝ .....	- 28 -
3.4.1 DATA SPARSITY .....	- 28 -
3.4.2 SCALABILITY .....	- 28 -
3.4.3 COLD-START PROBLEM .....	- 29 -
3.4.4 PRIVACY .....	- 29 -
3.4.5 SHILLING ATTACKS .....	- 29 -
3.5 NETFLIX'S RECOMMENDER SYSTEM .....	- 30 -
3.5.1 THE NETFLIX PRIZE .....	- 30 -
3.5.2 PERSONALIZED VIDEO RANKER (PVR) .....	- 31 -
3.5.3 TRENDING NOW SUGGESTIONS .....	- 32 -
3.5.4 CONTINUE WATCHING RANKER .....	- 32 -
3.5.5 SEARCH .....	- 32 -
3.5.6 THUMBNAILS .....	- 34 -
<b>ΚΕΦΑΛΑΙΟ 4 - ΠΡΟΤΕΙΝΟΜΕΝΟ ΣΥΣΤΗΜΑ .....</b>	<b>- 37 -</b>
4.1 ΕΙΣΑΓΩΓΗ .....	- 37 -
4.2 Η ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΤΟΥ ΣΥΣΤΗΜΑΤΟΣ .....	- 37 -
4.3 WEB SCRAPING .....	- 38 -
4.3.1 ΤΙΤΛΟΙ ΚΑΙ ΣΥΝΔΕΣΜΟΙ ΕΠΑΓΓΕΛΜΑΤΩΝ .....	- 39 -
4.3.2 ΠΕΡΙΓΡΑΦΕΣ ΕΠΑΓΓΕΛΜΑΤΩΝ .....	- 41 -
4.3.3 ΚΑΤΗΓΟΡΙΕΣ ΕΠΑΓΓΕΛΜΑΤΩΝ .....	- 43 -
4.4 QUESTION'S DATABASE .....	- 46 -
4.5 INFORMATION RETRIEVAL .....	- 49 -
4.5.1 NATURAL LANGUAGE PROCESSING .....	- 50 -
4.5.2 TERM FREQUENCY – INVERSE DOCUMENT FREQUENCY (TF-IDF) .....	- 52 -
4.6 JOBS – QUESTIONS SIMILARITY .....	- 57 -
4.7 WEIGHT ADJUSTMENT AND HEURISTIC METHOD .....	- 58 -
4.8 GRAPHICAL USER INTERFACE .....	- 62 -
4.8.1 ΑΡΧΙΚΗ ΟΘΟΝΗ .....	- 62 -
4.8.2 QUIZ SPACE .....	- 63 -
4.8.3 ΑΠΟΤΕΛΕΣΜΑΤΑ .....	- 64 -
<b>ΚΕΦΑΛΑΙΟ 5 - ΠΕΡΙΓΡΑΦΗ ΕΚΤΕΛΕΣΗΣ .....</b>	<b>- 65 -</b>
<b>ΚΕΦΑΛΑΙΟ 6 – ΣΥΜΠΕΡΑΣΜΑΤΑ, ΠΡΟΟΠΤΙΚΕΣ ΒΕΛΤΙΩΣΗΣ ΚΑΙ</b>	
<b>ΜΕΛΛΟΝΤΙΚΕΣ ΠΡΟΕΚΤΑΣΕΙΣ .....</b>	<b>- 71 -</b>
6.1 ΣΥΜΠΕΡΑΣΜΑΤΑ .....	- 71 -
6.2 ΒΕΛΤΙΩΣΕΙΣ .....	- 72 -

6.2.1 ΒΑΡΥΤΗΤΑ ΣΤΟΥΣ ΤΙΤΛΟΥΣ ΤΩΝ ΠΕΡΙΓΡΑΦΩΝ .....	- 72 -
6.2.2 ΠΑΡΑΛΛΗΛΗ ΕΠΙΚΟΙΝΩΝΙΑ ΤΟΥ VOGUI ΚΑΙ ΧΡΗΣΗΣ ΤΗΣ ΕΦΑΡΜΟΓΗΣ.....	- 73 -
6.2.3 ΕΡΩΤΗΣΕΙΣ ΒΑΣΙΣΜΕΝΕΣ ΣΤΑ ΣΥΓΚΕΚΡΙΜΕΝΑ ΕΠΑΓΓΕΛΜΑΤΑ .....	- 73 -
6.2.4 ΠΕΡΙΣΣΟΤΕΡΕΣ ΚΑΙ ΠΙΟ ΣΤΟΧΕΥΜΕΝΕΣ WRITING ΕΡΩΤΗΣΕΙΣ.....	- 73 -
6.2.5 ΑΝ ΟΙ ΕΡΩΤΗΣΕΙΣ ΣΩΣΤΟΥ/ΛΑΘΟΥΣ ΕΧΟΥΝ ΘΕΤΙΚΗ Ή ΑΡΝΗΤΙΚΗ ΣΗΜΑΣΙΑ .	- 74 -
<b>6.3 ΜΕΛΛΟΝΤΙΚΕΣ ΠΡΟΕΚΤΑΣΕΙΣ .....</b>	<b>- 74 -</b>
6.3.1 ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΣΩΠΙΚΟΤΗΤΑΣ .....	- 74 -
6.3.2 ΥΠΟΣΤΗΡΙΞΗ ΑΛΛΩΝ ΓΛΩΣΣΩΝ .....	- 75 -
6.3.3 ΠΡΟΣΘΗΚΗ ΝΕΟΥ ΕΠΙΠΕΔΟΥ ΓΙΑ ΕΞΕΙΔΙΚΕΥΣΗ ΕΠΑΓΓΕΛΜΑΤΩΝ.....	- 75 -
6.3.4 ΣΤΑΤΙΣΤΙΚΑ ΕΠΑΓΓΕΛΜΑΤΩΝ .....	- 75 -
6.3.5 ΔΙΑΔΙΚΤΥΑΚΗ ΕΦΑΡΜΟΓΗ .....	- 76 -
<b>ΒΙΒΛΙΟΓΡΑΦΙΑ .....</b>	<b>- 77 -</b>

# Κεφάλαιο 1

## Εισαγωγή

### 1.1 Σκοπός της πτυχιακής

Σκοπός αυτής της πτυχιακής εργασίας είναι η ανάπτυξη ενός έξυπνου προσωπικού βοηθού (chatbot), ο οποίος μέσα από ένα σύνολο ερωτήσεων, θα είναι ικανός να κατανοήσει τα ενδιαφέροντα του χρήστη και έπειτα να του προτείνει εργασίες που του ταιριάζουν περισσότερο. Πρόκειται για ένα ευφυή σύμβουλο επαγγελματικού προσανατολισμού που απευθύνεται σε εφήβους και ενήλικες, παρέχοντάς τους μία πολύτιμη βοήθεια για την επιλογή της επαγγελματικής τους καριέρας. Επιπλέον, θα εξηγηθούν αναλυτικά τα chatbots και οι τεχνολογίες τους, τι είναι τα συστήματα συστάσεων (recommender systems) καθώς και οι μέθοδοι/αλγόριθμοι που χρησιμοποιούνται για την υλοποίησή τους.

### 1.2 Γιατί σύμβουλος επαγγελματικού προσανατολισμού;

Η επαγγελματική εργασία είναι αναμφίβολα ένα από τα σημαντικότερα κομμάτια της ζωής μας. Πολλοί είναι εκείνοι, ιδιαίτερα στην Ελλάδα, οι οποίοι δεν ευχαριστιούνται τη δουλειά που κάνουν και την κάνουν καθαρά για βιοποριστικούς λόγους. Αυτό συμβαίνει γιατί από πολύ νωρίς, οι έφηβοι καλούνται να πάρουν σημαντικές αποφάσεις που θα επηρεάσουν την επαγγελματική και προσωπική τους ζωή. Είναι απόλυτα φυσιολογικό, σε αυτή την ηλικία, ο μαθητής να μην έχει κατασταλάξει στο τι επιθυμεί να ασχοληθεί επαγγελματικά μελλοντικά, με αποτέλεσμα πολλοί έφηβοι να παίρνουν τις λάθος αποφάσεις. Σύμφωνα με το Ελληνικό εκπαιδευτικό σύστημα, ο μαθητής καλείται στο λύκειο να επιλέξει, σύμφωνα με τα ενδιαφέροντα και τις ικανότητες που έχει, την κατεύθυνση που θα ακολουθήσει. Η απόφαση αυτή είναι ιδιαίτερα σημαντική καθώς με την επιλογή της κατεύθυνσης, ταυτόχρονα περιορίζει κατά πολύ τις επιλογές των επαγγελμάτων, αφού η κάθε κατεύθυνση έχει διαφορετικές διεξόδους.

Ο επαγγελματικός προσανατολισμός, κυρίως στους εφήβους, παίζει ιδιαίτερα σημαντικό ρόλο, αφού μέσα από τεστ επαγγελματικού προσανατολισμού, μπορούν να μάθουν τα ενδιαφέροντά τους αλλά και τον εαυτό τους, όπως επίσης και να μάθουν

πληροφορίες για τα επαγγέλματα που τους ενδιαφέρουν. Αυτό θα τους βοηθήσει να πάρουν μία όσο το δυνατόν περισσότερο σωστή απόφαση γίνεται για την επιλογή του μελλοντικού τους επαγγέλματος. Έτσι λοιπόν, αποφασίστηκε η υλοποίηση μίας εφαρμογής, ενός chatbot, το οποίο θα επεξεργάζεται τις απαντήσεις των χρηστών σε ένα σύνολο ερωτήσεων, θα μαθαίνει τα ενδιαφέροντα και τις προσδοκίες των χρηστών με απώτερο σκοπό να τους προτείνει τις επαγγελματικές δουλειές που τους ταιριάζουν, καθώς και ένα σύνολο πληροφοριών για την κάθε μία αντίστοιχα.

### **1.3 Δομή της πτυχιακής**

Η παρούσα πτυχιακή εργασία περιλαμβάνει έξι κεφάλαια, μαζί με το εισαγωγικό.

Στο Κεφάλαιο 2 γίνεται μία εισαγωγή στα chatbots, αναφέρονται σύγχρονα και καινοτόμα παραδείγματα εφαρμογών και εξηγείται ο τρόπος με τον οποίο λειτουργούν.

Στο Κεφάλαιο 3 παρουσιάζονται και περιγράφονται τα συστήματα συστάσεων, οι τεχνικές που χρησιμοποιούνται για την ανάπτυξή τους καθώς και οι προκλήσεις που αντιμετωπίζουν. Επιπρόσθετα, μελετάται και η αρχιτεκτονική του συστήματος σύστασης του Netflix.

Στο Κεφάλαιο 4 περιγράφεται βήμα προς βήμα η ανάπτυξη του ευφυή συμβούλου επαγγελματικού προσανατολισμού, τόσο το γραφικό περιβάλλον της εφαρμογής όσο και το backend.


Στο Κεφάλαιο 5 παρουσιάζεται με εικόνες η εκτέλεση του προγράμματος καθώς και μία δοκιμαστική λειτουργία της χρήσης του chatbot.

Τέλος, στο Κεφάλαιο 6 αναφέρονται τα συμπεράσματα που προέκυψαν έπειτα από την ανάπτυξη και χρήση του chatbot καθώς και μελλοντικές σκέψεις για επέκταση και βελτίωση της ήδη υπάρχουσας υλοποίησης.

## Κεφάλαιο 2

### Chatbots

#### 2.1 Τι είναι τα chatbots




Πηγή: [www.wordstream.com](http://www.wordstream.com)

Τα chatbots είναι συστήματα λογισμικού τεχνητής νοημοσύνης τα οποία συνηθίζεται να χρησιμοποιούνται για να απλοποιήσουν την αλληλεπίδραση μεταξύ ανθρώπων και υπολογιστών είτε μέσω μηνυμάτων, είτε μέσω φωνής (text-to-speech) με αποτέλεσμα την αντικατάσταση της άμεσης επαφής με τους αρμόδιους ανθρώπους. Η αλληλεπίδραση αυτή μπορεί να πραγματοποιηθεί μέσω εφαρμογών που χρησιμοποιούνται για συζήτηση (messaging apps), μέσω εφαρμογών κινητών τηλεφώνων (mobile apps), μέσω τηλεφωνικής κλήσης (phone calls) και ιστοσελίδων (websites). Αποκαλούνται επίσης και ως chatterbots, chat bots ή απλά bots. Σχεδιάζονται με τέτοιο τρόπο ώστε να προσομοιάσουν όσο καλύτερα γίνεται την ανθρώπινη συμπεριφορά σε μία συνομιλία μεταξύ άλλων ανθρώπων. Ένα chatbot μπορεί να επικοινωνήσει με τον χρήστη σε φυσική γλώσσα, όπως είναι για παράδειγμα η αγγλική ή σε οποιαδήποτε άλλη γλώσσα έχει κατασκευαστεί να υποστηρίζει.

Τα τελευταία χρόνια, λόγω της ραγδαίας εξέλιξης στη τεχνητή νοημοσύνη, πολλές φορές είναι δύσκολο να καταλάβουμε πότε συνομιλούμε με έναν άνθρωπο ή με ένα chatbot. Τα chatbots είναι projects που απαιτούν συνεχή ρύθμιση και πολλές δοκιμές καθώς η ανθρώπινη επικοινωνία είναι πολύ περισσότερο περίπλοκη απ' ό τι φανταζόμαστε αλλά η τεχνητή νοημοσύνη ανταπεξέρχεται ικανοποιητικά στις

δυσκολίες αυτές . Παρ' όλα αυτά, καμία εφαρμογή chatbot έως και σήμερα δεν έχει περάσει επιτυχώς το τεστ του Turing (Turing test).



Πηγή: [commons.wikimedia.org](https://commons.wikimedia.org)

Το τεστ του Turing είναι ένα κριτήριο μηχανικής νοημοσύνης. Είναι το αντίστοιχο τεστ IQ για τα chatbots. Είναι η παρατήρηση δύο συνομιλητών εκ των οποίων ο ένας γνωρίζουμε ότι είναι chatbot. Αν ο αξιολογητής που παρατηρεί τη συζήτηση δεν μπορεί να πει αξιόπιστα ποιος από τους δύο είναι μηχανή και ποιος άνθρωπος τότε το chatbot είναι «ιδιοφυία» και έχει περάσει επιτυχώς το τεστ του Turing.

## 2.2 Η ιστορία των chatbots

Τα chatbots δεν είναι μία καινούρια τεχνολογία. Έχουν μία μακρά ιστορία εξέλιξης εδώ και κάποιες δεκαετίες, όμως σήμερα αποτελούν ένα από τα πιο «ζεστά» θέματα της επιστήμης των υπολογιστών καθώς όλο και περισσότερες επιχειρήσεις αρχίζουν να τα χρησιμοποιούν. Ο όρος “Chatterbot” ειπώθηκε για πρώτη φορά το 1994 από τον επιχειρηματία Michael L. Mauldin όταν δημοσίευσε το άρθρο “Chatterbots, Tinymuds, and the Turing test entering the Loebner Prize Competition” για να περιγράψει τα προγράμματα που χρησιμοποιούνται για συνομιλία. Το πρώτο chatbot όμως, ακόμη κι αν δεν υπήρχε ο όρος chatbot τότε, δημιουργήθηκε περίπου 3 δεκαετίες νωρίτερα και ήταν ένα project που προκάλεσε μεγάλο ενδιαφέρον.

```
Welcome to
          EEEEE LL      IIII  ZZZZZZ  AAAAA
          EE     LL      II     ZZ     AA  AA
          EEEEE LL      II     ZZ     AAAAAA
          EE     LL      II     ZZ     AA  AA
          EEEEE LLLLLL IIII  ZZZZZZ  AA  AA

Eliza is a mock Rogerian psychotherapist.
The original program was described by Joseph Weizenbaum in 1966.
This implementation by Norbert Landsteiner 2005.

ELIZA: Is something troubling you ?
YOU:   Men are all alike.
ELIZA: What is the connection, do you suppose ?
YOU:   They're always bugging us about something or other.
ELIZA: Can you think of a specific example ?
YOU:   Well, my boyfriend made me come here.
ELIZA: Is it important to you that your boyfriend made you come here ?
YOU:   He says I'm depressed much of the time.
ELIZA: I am sorry to hear that you are depressed.
YOU:   It's true. I am unhappy.
ELIZA: Can you explain what made you unhappy ?
YOU:
```

Πηγή: Wikipedia

Το 1966 ο Joseph Weizenbaum, Γερμανός επιστήμονας και καθηγητής του MIT, δημιούργησε το project ELIZA που ήταν το πρώτο chatbot που «κοίταζε στα μάτια» το τεστ του Turing, αφού φαινόταν να μπορεί να ξεγελάσει τους χρήστες να πιστεύουν ότι συνομιλούσαν με έναν πραγματικό άνθρωπο. Είχε την ικανότητα να μιμείται έναν ψυχίατρο κάνοντας ανοιχτές ερωτήσεις στους χρήστες, ενώ ταυτόχρονα φαινόταν να ακολουθεί τη συζήτηση. Με λίγα λόγια, μέσω κάποιας διαδικασίας κρατούσε επιλεκτικά κάποιες λέξεις «κλειδιά» από τις απαντήσεις που έδινε ο χρήστης και αντιστοίχιζε τις λέξεις αυτές με κάποιες πιθανές ερωτήσεις που υπήρχαν εκ των προτέρων αποθηκευμένες σε έναν πίνακα. Για παράδειγμα αν η είσοδος του χρήστη ήταν 'Η μαμά μου μαγειρεύει καλό φαγητό.' το πρόγραμμα θα κρατούσε την λέξη 'μαμά' και ίσως απαντούσε με μία πιθανή ανοιχτή ερώτηση του τύπου 'Πες μου περισσότερα για την οικογένειά σου.'. Αυτή η διαδικασία λοιπόν έδινε την ψευδαίσθηση κατανόησης και αλληλεπίδρασης με έναν πραγματικό άνθρωπο και όχι με μηχανή παρόλο που η διαδικασία ήταν μηχανοποιημένη. Το περίεργο ήταν πως η μηχανή αυτή κατάφερε να μεταδώσει ένα αίσθημα εμπιστοσύνης σε πολλούς ανθρώπους με αποτέλεσμα να τους κάνει να εκφράσουν τις πιο βαθιές τους σκέψεις.

Μετά το chatbot ELIZA ακολούθησαν κι άλλες ενδιαφέρουσες chatbot εφαρμογές. Μερικές από τις πιο γνωστές είναι το project PARRY (δημιουργήθηκε το

1972 από τον ψυχίατρο Kenneth Colby) που προσομοιώνει έναν παρανοϊκό άνθρωπο που πάσχει από σχιζοφρένεια, η A.L.I.C.E (Artificial Linguistic Internet Computer Entity, δημιουργήθηκε από τον Richard Wallace το 1995) που συνομιλεί με ένα πραγματικό άνθρωπο διαδικτυακά χρησιμοποιώντας ευρετικές τεχνικές κατά τη ροή της συνομιλίας κερδίζοντας 3 φορές το βραβείο Loebner, η εικονικός βοηθός Siri (δημιουργήθηκε από την Apple το 2010) με κύριο στόχο την διευκόλυνση της ζωής του χρήστη εκτελώντας ορισμένες ενέργειες, απαντώντας ερωτήσεις, κάνοντας συστάσεις κ.τ.λ., η Cortana (αναπτύχθηκε από τη Microsoft το 2014) χρησιμοποιεί την μηχανή αναζήτησης Bing για την εκτέλεση εργασιών, όπως είναι η ρύθμιση ειδοποιήσεων και η εύρεση απαντήσεων σε ερωτήσεις χρηστών και η Amazon Alexa, γνωστή και ως απλά Alexa (αναπτύχθηκε το 2014 από την Amazon) είναι ένας έξυπνος προσωπικός βοηθός που ο χρήστης χρησιμοποιώντας μόνο τη φωνή του μπορεί εύκολα και γρήγορα να κάνει αναζήτηση στο internet, να ακούσει μουσική, να ορίσει ξυπνητήρια, να λάβει νέα ειδήσεων καθώς και να ελέγξει άλλες έξυπνες συσκευές του σπιτιού του και πολλά άλλα.

Το ταξίδι των chatbots, από την ELIZA μέχρι και σήμερα είναι αρκετά ενδιαφέρον. Η λειτουργικότητα και η διεπαφή με τον χρήστη είναι από τα κύρια χαρακτηριστικά των chatbots που παρατηρούμε τρομερή εξέλιξη. Με το σημερινό επίπεδο της τεχνητής νοημοσύνης και της μηχανικής μάθησης, τα chatbot γίνεται να κάνουν σχεδόν τα πάντα. Όλο και περισσότερες επιχειρήσεις δείχνουν να ενδιαφέρονται να χρησιμοποιήσουν μία τέτοια εφαρμογή που θα τους εξυπηρετεί στις δικές τους ανάγκες. Ήδη, αρκετές είναι αυτές που ανεξάρτητα από τη βιομηχανία χρησιμοποιούν chatbots για την πραγματοποίηση οικονομικών συναλλαγών, για την πραγματοποίηση παραγγελιών, για την εξυπηρέτηση των πελατών, για κράτηση εισιτηρίων και πολλά άλλα.



## 2.3 Μερικά από τα πιο καινοτόμα chatbots


### 2.3.1 Endurance's chatbot



Πηγή: [endurancerobots.com](http://endurancerobots.com)

Η Endurance είναι μία ρωσική εταιρεία τεχνολογίας η οποία δημιούργησε ένα chatbot που κρατάει συντροφιά σε ασθενείς που πάσχουν από την νόσο Αλτσχάιμερ. Πολλοί άνθρωποι, κυρίως ηλικιωμένοι, με νόσο Αλτσχάιμερ έρχονται καθημερινά αντιμέτωποι με την βραχυπρόθεσμη απώλεια μνήμη τους. Το chatbot μπορεί να συνομιλήσει μαζί τους σε διάφορα θέματα, να κάνει ερωτήσεις καθώς και να αντιδρά στις απαντήσεις τους. Το chatbot καταφέρνει να συλλέξει πληροφορίες, δηλαδή κάποιες ενδείξεις στη συνομιλία που μπορεί να υποδηλώνουν πρόβλημα σε άμεση ανάμνηση του ασθενούς. Έτσι, οικογένεια και γιατροί μπορούν να αξιολογήσουν τα αρχεία καταγραφής του chatbot και χρησιμοποιώντας αυτές τις πληροφορίες να κάνουν μία εκτίμηση για το αν η κατάσταση του ατόμου έχει επιδεινωθεί. Το project είναι ακόμα στα πρώτα του στάδια αλλά έχει μεγάλες δυνατότητες να βοηθήσει επιστήμονες, ερευνητές και ομάδες φροντίδας να κατανοήσουν καλύτερα πώς η νόσος Αλτσχάιμερ επηρεάζει τον ανθρώπινο εγκέφαλο.

### 2.3.2 Insomnobot 3000



Πηγή: [insomnobot3000.com](http://insomnobot3000.com)

Το Insomnobot 3000 δημιουργήθηκε για εκείνους που έχουν αϋπνίες τα βράδια. Η εταιρεία ηλεκτρονικού εμπορίου Casper που πωλάει προϊόντα ύπνου έφτιαξε ένα

chatbot “που κάνει τις 3 τα ξημερώματα λιγότερο μοναχικά” όπως είπε και η Lindsay Kaplan, επικεφαλής επικοινωνιών της Casper. Η επικοινωνία με το Insomnobot είναι διαθέσιμη μόνο από τις 11 το βράδυ έως τις 5 το πρωί καθώς και σε διάφορα χρονικά διαστήματα κατά τη διάρκεια της ημέρας. Αυτό που διαπιστώθηκε είναι πως οι χρήστες γύριζαν ‘πίσω στη μέρα’ και συνομιλούσαν για θέματα που τους δημιούργησαν στρες, για κάτι που είδαν στην τηλεόραση ή τα σχέδια τους για το Σαββατοκύριακο. Το chatbot δεν χρησιμοποιεί μηχανική μάθηση οπότε δεν μπορεί να μαθαίνει από μόνο του. Η ομάδα μηχανικών της Casper Θα ενημερώνει συνεχώς την υπηρεσία καθώς θα συλλέγει όλο και περισσότερα δεδομένα σχετικά με τα θέματα που αρέσουν στον κόσμο να συζητούν καθώς και ποιες απαντήσεις του Casper είναι πιο επιθυμητές.


### 2.3.3 Hipmunk and Hello Chatbots



Πηγή: [everplans.com](http://everplans.com)

Η Hipmunk είναι μία πλατφόρμα μέσω της οποίας μπορεί κανείς να μπει και να αναζητήσει ταξιδιωτικές προσφορές όπως επίσης και να κάνει κράτηση πτήσεων, ξενοδοχείων, αυτοκινήτων, ακόμη και πακέτων. Λόγω το ότι ένας μέσος άνθρωπος κάνει αναζήτηση σε αρκετούς ιστότοπους προκειμένου να βρει την καλύτερη προσφορά η Hipmunk δημιούργησε τα Hello chatbots τα οποία ενσωματώνονται εύκολα στις εφαρμογές Facebook, Slack ή Skype. Το bot μέσω της τοποθεσίας του χρήστη μπορεί να καθορίσει από που ταξιδεύει και έτσι να του στείλει ταξιδιωτικές προσφορές με σημείο αναχώρησης την τωρινή ή την κοντινότερη τοποθεσία του. Επιπλέον το bot χρησιμοποιεί φιλική και συνομιλητική γλώσσα και μιμείται τον τρόπο συνομιλίας με έναν ταξιδιωτικό πράκτορα ή ακόμα και με έναν φίλο. Συνεπώς, η διαδικασία εύρεσης προσφορών γίνεται γρηγορότερη και ευκολότερη ενώ ταυτόχρονα προσφέρει μία καλύτερη εμπειρία.

### 2.3.4 WHO's Chatbot



Πηγή: [messengerpeople.com](https://messengerpeople.com)

Λόγω της εποχής και της κατάστασης που ζούμε δεν θα μπορούσε να μην αναφερθεί το World Health Organization's WhatsApp Chatbot. Καθώς η πανδημία του COVID-19 εξαπλώνεται ο Παγκόσμιος Οργανισμός Υγείας είναι από τις λίγες αξιόπιστες πηγές πληροφοριών από την έναρξη του κορονοϊού. Για το λόγο αυτό δημιουργήθηκε το WHO Health alert. Ένα chatbot για την προστασία των ανθρώπων που προσφέρει έγκυρες πληροφορίες για την ιογενή λοίμωξη, ενημερώνει για τα τελευταία νέα και ενεργά κρούσματα και δίνει ταξιδιωτικές συμβουλές. Πρόσφατα προσφέρει και πληροφορίες σχετικά με τα εμβόλια κατά του COVID-19. Η νέα υπηρεσία διατίθεται δωρεάν και είναι προσβάσιμη όλο το 24ωρο.

Παρατηρούμε λοιπόν ότι τα chatbots πραγματικά μπορούν να χρησιμοποιηθούν παντού, από λιγότερο σημαντικά και αναγκαία πράγματα έως και σε ζητήματα ζωής και θανάτου όπως είναι μία πανδημία. Η χρησιμότητά τους πολλές φορές μπορεί να κριθεί αναγκαία και σε μία νέα εποχή τεχνολογίας όπου οι ανάγκες όλο και πληθαίνουν ο αυτοματισμός ορισμένων διαδικασιών είναι αρκετά σημαντικός.

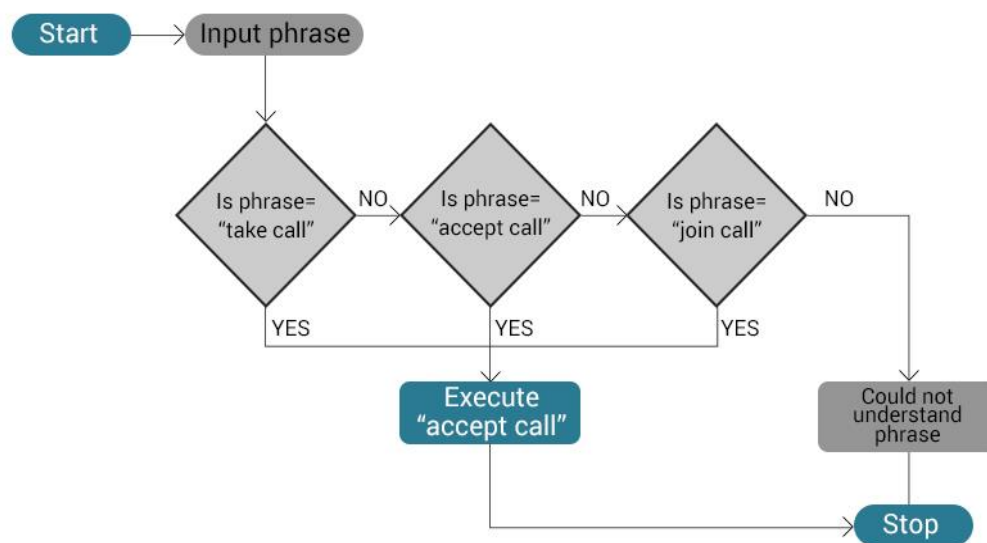
## 2.4 Πως λειτουργούν τα chatbots

Ένα chatbot δεν διαφέρει από μία κανονική εφαρμογή. Συνήθως, όπως και στις υπόλοιπες εφαρμογές υπάρχει το επίπεδο εφαρμογής (application layer), το τελευταίο

επίπεδο του OSI (Open Systems Interconnection), όπου καθορίζονται τα πρωτόκολλα επικοινωνίας, μία βάση δεδομένων, γραφικό περιβάλλον όπως και APIs για την επικοινωνία και σύνδεση με άλλες εξωτερικές εφαρμογές. Τα περισσότερα chatbots χωρίζονται σε 3 κατηγορίες. Στα chatbots που βασίζονται σε κανόνες (Rule-based chatbots), στα έξυπνα chatbots (Intelligent chatbots) και στα chatbots που χρησιμοποιούν τεχνητή νοημοσύνη (AI-based chatbots).

#### 2.4.1 Rule-based chatbots

##### SIMPLE RULE BASED RULE



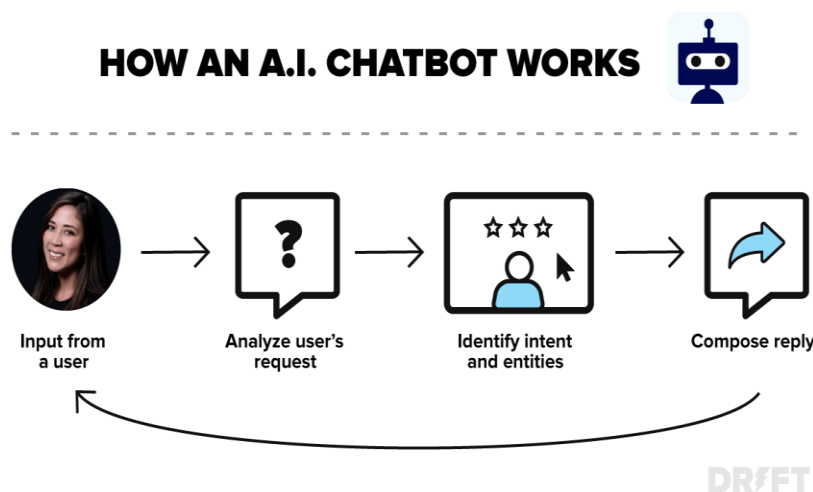
Πηγή: [www.cosoit.com](http://www.cosoit.com)

Τα chatbots που ανήκουν σε αυτή την κατηγορία είναι τα πιο απλά. Θέτουν ορισμένες ερωτήσεις στους χρήστες δίνοντάς του την δυνατότητα να επιλέξουν κάποια απάντηση. Η ροή της συνομιλίας δηλαδή βασίζεται σε προκαθορισμένες επιλογές και κανόνες που έχουν εκπαιδευτεί και χρησιμοποιούν έναν αλγόριθμο σωστού-λάθους για την κατανόηση των απαντήσεων. Αφού λοιπόν γίνει η ανάλυση των δεδομένων το chatbot δίνει μία απάντηση και έτσι συνεχίζεται η συζήτηση με τον χρήστη έως ότου εξυπηρετηθεί το ζήτημά του. Αυτά τα chatbots ταιριάζουν καλύτερα για απλούς διαλόγους διότι σε πιο περίπλοκα σενάρια με πολλές συνθήκες ή παράγοντες δεν είναι πάντα η καλύτερη λύση καθώς ενδέχεται να δώσουν λάθος απαντήσεις. Τέλος ένα rule-based chatbot δεν μπορεί να απαντήσει αποτελεσματικά σε ερωτήσεις οι οποίες ανήκουν σε ένα μοτίβο που δεν έχει εκπαιδευτεί.

## 2.4.2 Intelligent chatbots

Τα έξυπνα chatbots σε αντίθεση με τα rule-based χρησιμοποιούν μηχανική μάθηση για την κατανόηση των αιτημάτων του χρήστη. Μέσω αλγορίθμων μηχανικής μάθησης ο υπολογιστής αποκτά την ικανότητα να μαθαίνει από μόνος του και να αποφασίζει με ελάχιστη ανθρώπινη παρέμβαση. Έτσι οι συνομιλίες μπορούν να είναι ελεύθερες αφού τα έξυπνα chatbots μπορούν να κατανοήσουν και την πρόθεση και το συναίσθημα. Εκπαιδεύονται να κατανοούν συγκεκριμένες λέξεις-κλειδιά και φράσεις που προκαλούν την απάντησή τους και με τον καιρό εκπαιδεύονται για να καταλαβαίνουν όλο και περισσότερες ερωτήσεις. Τα έξυπνα chatbots είναι πολύ πιο δύσκολο να δημιουργηθούν και να εκτελεστούν και χρειάζονται πολλά δεδομένα καθώς και περισσότερο χρόνο για να εκπαιδευτούν.

## 2.4.3 AI-based chatbots



Πηγή: [drift.com](https://drift.com)

Τα chatbots αυτά αποτελούν έναν συνδυασμό των παραπάνω δύο. Χρησιμοποιούν μηχανική μάθηση, τεχνητή νοημοσύνη και επεξεργασία φυσικής γλώσσας (NLP) για να κατανοήσουν τους πελάτες. Μπορούν να «θυμηθούν» το περιεχόμενο των συνομιλιών και να καταλάβουν τις προτιμήσεις των χρηστών. Η τεχνητή νοημοσύνη επικεντρώνεται στη δημιουργία έξυπνων μηχανών που λειτουργούν και σκέφτονται ως άνθρωποι. Τα chatbots που χρησιμοποιούν τεχνητή νοημοσύνη μπορούν και κατανοούν την ελεύθερη γλώσσα αλλά έχουν επίσης και μία προκαθορισμένη ροή για να βεβαιωθούν πως θα λύσουν το πρόβλημα του χρήστη. Η επεξεργασία φυσικής γλώσσας δίνει την ικανότητα στο chatbot να κατανοήσει και να ανταποκριθεί σε δεδομένα κειμένου και να απαντήσει με δικό του κείμενο με τον ίδιο

τρόπο που κάνουν και οι άνθρωποι. Η NLP συνδυάζει υπολογιστική γλωσσολογία, μοντέλο βασισμένο σε κανόνες ανθρώπινης γλώσσας, στατιστικά μοντέλα, μηχανική μάθηση και βαθιά μάθηση (Deep Learning). Ο στόχος της NLP είναι να κάνει την αλληλεπίδραση μεταξύ υπολογιστών και ανθρώπων να μοιάζει σαν επικοινωνία μεταξύ δύο ατόμων.

Σε κάθε κατηγορία chatbot χρησιμοποιούνται διαφορετικές τεχνικές, τεχνολογίες και αλγόριθμοι ώστε να επιτευχθεί το καλύτερο αποτέλεσμα. Οι τρεις κύριες μέθοδοι που χρησιμοποιούνται είναι η αντιστοίχιση μοτίβων (pattern matching), αλγόριθμοι για την επεξεργασία των μοτίβων και τεχνητά νευρωνικά δίκτυα (artificial neural networks). Η επιλογή της κάθε μεθόδου καθώς και ο τύπος chatbot επιλέγεται ανάλογα με τη χρήση του.

## **2.5 Το μέλλον των chatbots**

Τα τελευταία χρόνια έχει αποδειχτεί ότι τα chatbots έχουν ένα τεράστιο δυναμικό ανάπτυξης και μπορούν να δώσουν αποτελέσματα που δεν ήταν αρχικά αναμενόμενα. Η συνομιλία με AI εφαρμογές είναι μία κατηγορία που προσελκύει το ενδιαφέρον πολλών ερευνητών για τη φυσική επεξεργασία γλώσσας καθώς και εταιρείες κολοσσούς όπως είναι η Amazon, η Google, το Facebook, η Microsoft και η IBM που έχουν αναπτύξει τέτοιες τεχνολογίες και διερευνούν τις δυνατότητες που έχουν συστήματα διαλόγου που είναι βασισμένα σε κείμενα αλλά και σε προφορικό λόγο. Σε προηγούμενη ενότητα μιλήσαμε για τον τρόπο που δουλεύουν τα chatbots και για ορισμένες τεχνολογίες που χρησιμοποιούν σήμερα. Σε αυτή την ενότητα θα αναφερθούν κάποια από τα θέματα που είναι πιθανό να αποτελέσουν το επίκεντρο στις μελλοντικές έρευνες των chatbots.

### **2.5.1 Multimodal chatbots**

Οι αλληλεπιδράσεις με τα chatbots μέχρι στιγμής είναι κυρίως με βάση το κείμενο και τον προφορικό λόγο. Ωστόσο υπάρχουν και αλληλεπιδράσεις ανθρώπου-μηχανής που χρησιμοποιούν περισσότερους τρόπους. Για παράδειγμα ένας χρήστης smartphone μπορεί να δώσει σαν είσοδο κείμενο, ομιλία είτε άγγιγμα ενώ η έξοδος του smartphone μπορεί να είναι έναν συνδυασμός κειμένου, ομιλίας, ήχου, εικόνων και βίντεο. Chatbots που προσφέρουν αυτή τη πολυτροπική (multimodal) αλληλεπίδραση είναι πιο ευέλικτα εφόσον επιτρέπουν στον χρήστη να επιλέξει τις λειτουργίες εισόδου

που επιθυμεί και του είναι περισσότερο οικείες. Τον πολυτροπικό διάλογο μπορούμε να τον διαχωρίσουμε σε δύο κομμάτια. Στη πολυτροπική ένωση η οποία αφορά την επεξεργασία της εισόδου και την πολυτροπική διάσπαση που αφορά την παραγωγή της εξόδου.

**SHOPPER:** Hello

**AGENT:** Hi, please tell me what i can help you with today?

**SHOPPER:** show me few of your top large sized rubber type upper material clogs that is mostly light pink in colored that i would like.

**AGENT:** Of course. Just wait a few seconds while i browse through my catalog

**AGENT:** Sorry i dont have any in pink but would you like to see some in



other color

**SHOPPER:** Please show me something similar to the 1st image but in a different upper material



**AGENT:** The similar looking ones are

**SHOPPER:** I like the 4th result . Show me something like it but in material as in the 1st image from what you had previously shown me in clogs

Πηγή: *Conversational AI: Dialogue Systems, Conversational Agents, and Chatbots*, Michael McTear

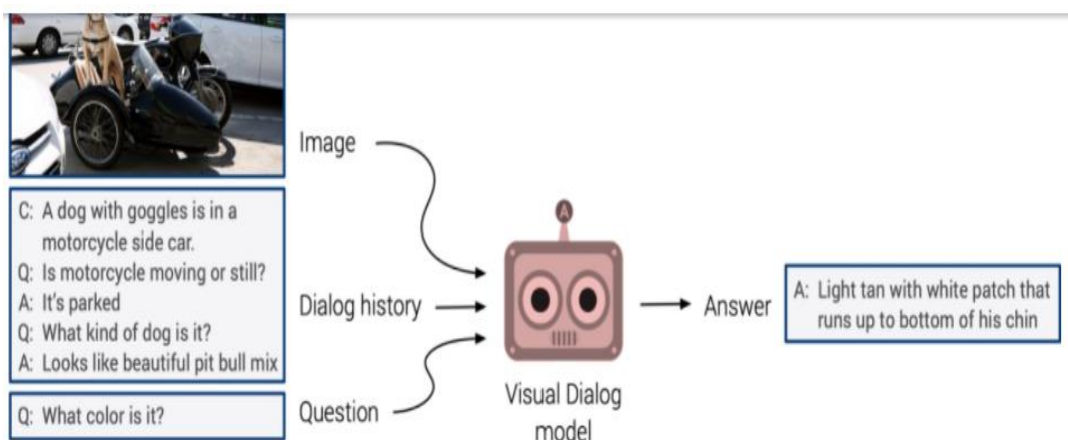
- Η πολυτροπική ένωση αφορά τη σχέση μεταξύ του χρήστη και του chatbot. Ένα πολυτροπικό chatbot μπορεί να διαθέτει αντίληψη συλλέγοντας δεδομένα από το βλέμμα, το κεφάλι, τις χειρονομίες και την ομιλία του χρήστη. Έτσι το chatbot θα μπορεί να ανιχνεύσει αν υπάρχει κάποιο πρόβλημα στη ποιότητα της συζήτησης και θα μπορεί να λάβει μέτρα για να το αντιμετωπίσει. Στα πολυτροπικά chatbots του 2000 η επεξεργασία της πολυτροπικής εισόδου του χρήστη γινόταν χειροκίνητα. Σήμερα έχουν προταθεί κάποιες τεχνικές και

ευρετικές μέθοδοι για την αυτοματοποίηση αυτής της διαδικασίας αλλά αντιμετωπίζουν ορισμένα προβλήματα όπως είναι το overfitting.

- Μία πολυτροπική έξοδος είναι χρήσιμη σε περιπτώσεις όπως είναι στην εικόνα παραπάνω, όπου ο χρήστης θα μπορεί να αναφέρεται σε κάτι δείχνοντας ή χρησιμοποιώντας όρους όπως “μου αρέσει η 4<sup>η</sup> εικόνα”. Όμως, η δημιουργία μιας πολυτροπικής εξόδου έχει αρκετές δυσκολίες, όπως η αναπαράσταση του πολυτροπικού περιεχομένου, ο προγραμματισμός της παραγωγής της εξόδου καθώς και πότε θα καταλαβαίνουμε ότι πρέπει να δημιουργηθεί μία πολυτροπική έξοδος. Από τις αρχές της δεκαετίας του 2000 έχουν ερευνηθεί αρκετά αυτά τα ζητήματα και έχουν βρεθεί αρκετοί ερευνητές με πολύ ενδιαφέρον προτάσεις με στόχο την επίλυση αυτών των ζητημάτων.

### 2.5.2 Visual dialogue and grounded language learning

Grounded language learning είναι η εκμάθηση της βαθύτερης έννοιας των εκφράσεων, φράσεων και λέξεων αξιοποιώντας οπτικά δεδομένα όπως για παράδειγμα μία εικόνα. Ο οπτικός διάλογος είναι ένας καινούριος τομέας ο οποίος συνδυάζει το Computer Vision και το Conversational AI (Artificial Intelligence). Χρησιμοποιώντας τεχνολογίες όπως είναι η ταξινόμηση εικόνας, αναγνώριση αντικειμένων, και απαντήσεις ερωτήσεων σχετικά με τις εικόνες ο οπτικός διάλογος χρησιμοποιεί έναν AI agent για να διεξάγει έναν ουσιαστικό διάλογο με τους ανθρώπους σε φυσική, συνομιλητική γλώσσα σχετικά με το οπτικό περιεχόμενο. Πιο συγκεκριμένα δίνοντας μία εικόνα με το ιστορικό του διαλόγου και μία ερώτηση σχετικά με αυτή την εικόνα, ο σκοπός είναι να απαντήσει την ερώτηση.



Πηγή : <https://visualdialog.org/>



Μεγάλο ενδιαφέρον έχει μία έρευνα που έγινε το 2016 από τους Harm de Vries, Florian Strub, Sarath Chandar, Olivier Pietquin, Hugo Larochelle και Aaron Courville στο παιχνίδι “Μάντεψε τι;”. Ο στόχος του “Μάντεψε τι;” είναι να βρεθεί ένα αντικείμενο σε μία εικόνα κάνοντας μία σειρά ερωτήσεων. Το παιχνίδι περιλαμβάνει 2 συμμετέχοντες εκ των οποίων ο ένας γνωρίζει το αντικείμενο και ο άλλος κάνει τις ερωτήσεις με σκοπό τον περιορισμό της λίστας των αντικειμένων. Αυτός που γνωρίζει το αντικείμενο μπορεί να απαντήσει μόνο με “Ναι/Όχι”. Και οι 2 ρόλοι εκπαιδεύτηκαν με τη χρήση νευρωνικών δικτύων. Η δουλειά του ενός ήταν να απαντήσει σε “Ναι/Όχι” ερωτήσεις ενώ του ερωτώντα ήταν αρκετά πιο δύσκολη καθώς έπρεπε να προβλέψει το σωστό αντικείμενο αλλά και να δημιουργήσει ερωτήσεις. Για το σκοπό αυτό χρησιμοποιήθηκε ένας hierarchical recurrent encoder-decoder (HRED).



**Questioner**

Is it a vase?  
Is it partially visible?  
Is it in the left corner?  
Is it the turquoise and purple one?

**Oracle**

Yes  
No  
No  
Yes

Πηγή: [www.arxiv-vanity.com/papers/1611.08481/](http://www.arxiv-vanity.com/papers/1611.08481/)

Με βάση αυτό το project το 2020 παρουσιάστηκε από τους Alessandro Suglia, Ioannis Konstas, Andrea Vanzo, Emanuele Bastianelli, Desmond Elliott, Stella Frank και Oliver Lemon ένα framework για την εκμάθηση γλωσσών με χαρακτηριστικά (Grounded Language Learning with Attributes - GroLLA). Για παράδειγμα σε μία αναπαράσταση ενός αντικείμενου όπως ένας φούρνος μικροκυμάτων, θα μπορούσε να έχει αφηρημένα χαρακτηριστικά όπως is\_appliance και κάποια πιο συγκεκριμένα όπως is\_white ώστε η εκμάθηση μιας αναπαράστασης να λαμβάνει υπόψιν και αυτά τα χαρακτηριστικά με στόχο την διάκριση ενός αντικειμένου από τα υπόλοιπα σε μία εικόνα. Τα αποτελέσματα δεν ήταν και πολύ καλά αλλά οι συγγραφείς προτείνουν ότι πιο προηγμένοι μηχανισμοί μάθησης θα μπορούσαν να χρησιμοποιηθούν για την

κωδικοποίηση των χαρακτηριστικών χρησιμοποιώντας έναν co-grounding operator ο οποίος θα συγχώνευε το κείμενο και την εικόνα για να μάθει τις αναπαραστάσεις.

### 2.5.3 Λογική και συνεργατική επίλυση προβλημάτων σε μία συνομιλία

Για να είναι σε θέση ένα chatbot να αλληλοεπιδράσει με συνεργατικό τρόπο σε μία συνομιλία θα πρέπει να μπορεί να αιτιολογεί για τις δικές του ενέργειες καθώς και για τις ενέργειες του συνομιλητή του. Εκτός από την κατανόηση του νοήματος από τις εκφράσεις του συνομιλητή θα πρέπει να μπορεί να συμπεράνει και τις προθέσεις των εκφράσεων και έπειτα να δώσει μία λογική απάντηση. Σε αυτά τα προβλήματα ήρθαν αντιμέτωποι οι Cohen και Perrault (1979), Allen και Perrault (1980) και Cohen και Levesque (1990) αλλά σε πρόσφατα έργα δεν δόθηκε ιδιαίτερο ενδιαφέρον σε αυτά τα ζητήματα πέρα από ένα πρόσφατο paper του Cohen το 2019 και μιας συζήτησης μιας επιτροπής που εξετάζει προκλήσεις για συστήματα πολυτροπικών διαλόγων που διατυπώνεται στο παρακάτω παράδειγμα.

A traveller in South Korea for the first time needs to catch a bus to her destination. She approaches an information provider at 10.45 pm.

USER: Do you know when is the next bus to Suwon?

A literal answer to the question would be uncooperative, e.g.,

SYSTEM: Yes, I do know.

as would an answer such as:

SYSTEM: The next bus leaves at 5.00 in the morning.

Instead, if the system has reasoned that the traveller's goal is to be in Suwon that evening and discovers an obstacle to the plan, i.e., that the last direct bus has departed, then the system should look for an alternative plan to help her achieve her goal, for example:

SYSTEM: Sorry, the last bus has left for the evening. You will have to take a bus to Seongnam and then transfer to the bus to Suwon. The bus leaves here from bay number 6 at 11:00 pm.

Πηγή: *Conversational AI: Dialogue Systems, Conversational Agents, and Chatbots*, Michael McTear

### 2.5.4 Διάλογος και Διαδίκτυο των Πραγμάτων

Τα τελευταία χρόνια μπορούμε να παρατηρήσουμε πως οι έξυπνες συσκευές όλο και αυξάνονται. Πλέον έξυπνα σπίτια, έξυπνα γραφεία και άλλα περιβάλλοντα είναι γεγονός. Υπάρχουν συσκευές για τον έλεγχο φώτων, συναγερμών, μουσικής για την παρακολούθηση φυσικών πτυχών του χρήστη όπως τοποθεσία, καρδιακός παλμός, για την καθαριότητα του σπιτιού και πολλές άλλες οι οποίες είναι συνδεδεμένες στον διαδίκτυο δημιουργώντας το Διαδίκτυο των Πραγμάτων (Internet of Things - IoT). Συνήθως η κάθε συσκευή διαχειρίζεται μέσω της εφαρμογής της ενώ μερικές φορές

υπάρχει ένας κεντρικός ελεγκτής που ενσωματώνει τις εφαρμογές. Όμως υπάρχουν (λίγες μέχρι στιγμής) εφαρμογές που προσφέρουν αλληλεπίδραση μέσω διαλόγου. Η Samsung Electronics παρουσίασε ένα παράδειγμα σχετικά με τις δυνατότητες που θα μπορούσε να έχει μία τέτοια εφαρμογή σε ένα έξυπνο σπίτι. Το σύστημα εφαρμόστηκε και δοκιμάστηκε σε ένα πραγματικό οικιακό περιβάλλον IoT και πιο συχνά αιτήματα ήταν “άναψε το φως”, “κλείσε την τηλεόραση σε 30 λεπτά” και “τι καιρό έχει σήμερα;”.

Αυτές οι διαδικασίες λοιπόν ενσωματώθηκαν στο Action Planner σε μορφή δέντρου εργασιών. Στο Action Planner δημιουργούνται κάποια σχέδια/καταστάσεις όπου ο χρήστης λέγοντας μία φράση το chatbot θα εκτελεί μία σειρά ενεργειών για την συγκεκριμένη κατάσταση. Υπάρχει ένας κεντρικός διαχειριστής των συσκευών ο οποίος επικοινωνεί με τις υπόλοιπες συσκευές και αναθέτει την κάθε δουλειά στην αντίστοιχη συσκευή με στόχο την ολοκλήρωση του σχεδίου. Μπορεί επίσης και να δέχεται πληροφορίες από άλλες συσκευές και να ενημερώνει τον χρήστη για την εξέλιξη των διαδικασιών όπως για παράδειγμα ότι το air condition άνοιξε στην κρεβατοκάμαρα ή να ενημερωθεί από την συσκευή που ελέγχει τι καιρό έχει σήμερα και με τη σειρά του να ενημερώσει τον χρήστη. Όμως πολλές φορές υπάρχουν και παρερμηνείες όπως στην παρακάτω συνομιλία.

Χρήστης : Παίξε μουσική σε 10 λεπτά.

Σύστημα : Σε ποιο δωμάτιο να παίζω μουσική;

Χρήστης : Στο υπνοδωμάτιο παρακαλώ.

Χρήστης : Επίσης άνοιξε και το κλιματιστικό εκεί.

Σύστημα : Εντάξει, το κλιματιστικό στο υπνοδωμάτιο είναι ανοιχτό!

Χρήστης : Περίμενε, θέλω το κλιματιστικό να ανοίξει σε 10 λεπτά, όχι τώρα.

*Πηγή: Conversational AI: Dialogue Systems, Conversational Agents, and Chatbots, Michael McTear*

Στο παραπάνω παράδειγμα ο χρήστης θέλει να ενεργοποιηθεί το κλιματιστικό στη κρεβατοκάμαρα σε 10 λεπτά αλλά ο τρόπος που το λέει δεν είναι ξεκάθαρος με αποτέλεσμα το σύστημα να παρερμηνεύσει το αίτημα.


Αυτές λοιπόν είναι ορισμένες τεχνολογίες καθώς και οι δυσκολίες που πρέπει να αντιμετωπιστούν μελλοντικά ώστε να γίνουν τα επόμενα μεγάλα βήματα στον χώρο των chatbots. Βέβαια, για το απόλυτο chatbot (όπως είναι ο JARVIS του Iron Man στο Marvel Cinematic Universe) υπάρχει πολύς δρόμος ακόμα και αρκετή δουλειά. Ένα

όμως είναι σίγουρο· πως τα chatbots πρόκειται να ενσωματωθούν σε όλους τους τομείς. Καθώς η τεχνολογία πίσω από τα chatbots προχωράει, οι εφαρμογές και οι δυνατότητές τους θα αλλάξουν με διάφορους τρόπους και θα γίνονται όλο και πιο έξυπνα αντικαθιστώντας τους ανθρώπους σε επαναλαμβανόμενες και δομημένες εργασίες.

## Κεφάλαιο 3

### Recommendation Systems

#### 3.1 Εισαγωγή στα Recommendation Systems



Πηγή: [www.projectpro.io](http://www.projectpro.io)

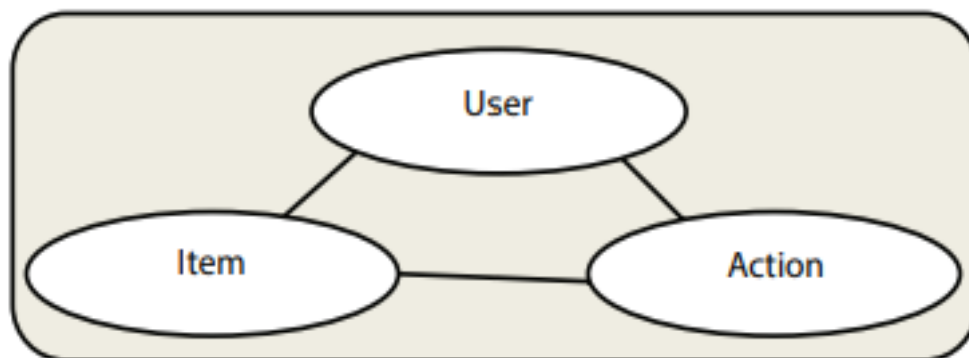
Λόγω της ταχείας ανάπτυξης του Παγκόσμιου Ιστού και του προβλήματος της συσσώρευσης των πληροφοριών, η χρήση των συστημάτων συστάσεων (recommendation systems) έχει αρχίσει να γίνεται όλο και πιο σημαντική για τις ηλεκτρονικές επιχειρήσεις αλλά και τους πελάτες. Τα συστήματα συστάσεων έχουν σχεδιαστεί για να προτείνουν στους χρήστες νέα προϊόντα και υπηρεσίες με βάση πολλούς διαφορετικούς παράγοντες. Είναι μια υποκατηγορία των συστημάτων που χρησιμοποιούνται για την επεξεργασία πληροφοριών και έχουν την ικανότητα να προβλέπουν το πιο πιθανό προϊόν που οι χρήστες είναι πιο πιθανό να αγοράσουν και ενδιαφέρονται για αυτό. Τα συστήματα συστάσεων αποτελούν έναν πολύ σημαντικό παράγοντα στην ψηφιακή μας εποχή αφού βοηθούν πολύ τον πελάτη που προσπαθεί να βρει αυτό που ψάχνει, τόσο που αρκετές φορές συγκλονίζεται με τις προτάσεις αυτών των συστημάτων, καθώς και τις επιχειρήσεις αφού φυσικά γίνονται περισσότερες πωλήσεις. Θα μπορούσαμε να τα παρομοιάσουμε με πωλητές που γνωρίζουν τον χρήστη, το ιστορικό του και τις προτιμήσεις του και μπορούν να του προτείνουν πράγματα που του αρέσουν.

Θα εξηγήσουμε αναλυτικά στη συνέχεια το πως λειτουργεί ένα σύστημα συστάσεων και τις τεχνολογίες που χρησιμοποιεί αλλά αυτό που συμβαίνει περιληπτικά είναι μέσω των δεδομένων που παρέχει ο χρήστης με τις επιλογές του, επεξεργάζεται τις πιο σημαντικές πληροφορίες, ανακαλύπτει την αντιστοιχία μεταξύ του χρήστη και του αντικειμένου και έτσι κατηγοριοποιεί τις ομοιότητες μεταξύ των χρηστών και των αντικειμένων που είναι για σύσταση.

Τέλος, η υλοποίηση και ανάπτυξη ενός τέτοιου συστήματος είναι αρκετά απαιτητική διαδικασία και απαιτεί συνδυασμό γνώσεων και δεξιοτήτων από διαφορετικούς τομείς της επιστήμης των υπολογιστών.

### 3.2 Επεξήγηση οντοτήτων των συστημάτων συστάσεων

Πριν προχωρήσουμε στον τρόπο με τον οποίο λειτουργούν καθώς και στις τεχνικές των συστημάτων συστάσεων καλό θα ήταν να εξηγήσουμε τις κύριες οντότητες. Τα συστήματα συστάσεων μπορούμε να πούμε πως ασχολούνται με τρία πράγματα: με τους χρήστες, τα αντικείμενα σύστασης και τις ενέργειες. Και οι τρεις οντότητες αυτές συνδέονται μεταξύ τους και αντιμετωπίζονται ως βασικό συστατικό για ένα σύστημα συστάσεων.



Πηγή: *Recommender System with Machine Learning and Artificial Intelligence*, Sachi Nandan Mohanty

#### 3.2.1 Χρήστες

Οι χρήστες αποτελούν το κύριο 'συστατικό' του συστήματος. Είναι οι πελάτες στους οποίους θα προταθούν τα αντικείμενα από το σύστημα. Ένας χρήστης θα μπορούσε να είναι ένας άνθρωπος που παρακολουθεί βίντεο στο YouTube, ή ένας αγοραστής ενός διαδικτυακού προϊόντος ή κάποιος χρήστης του Netflix κλπ. Δίχως χρήστες (δηλαδή πελάτες) δεν έχει νόημα να υπάρχουν συστήματα συστάσεων. Το

σύστημα λοιπόν λαμβάνει αρκετές πληροφορίες σχετικά με τον χρήστη, όπως η βαθμολογία που βάζει σε ένα προϊόν κ.α., δημιουργώντας με αυτό τον τρόπο ένα προφίλ χρήστη. Το προφίλ του χρήστη περιλαμβάνει το ιστορικό αναζήτησής του καθώς και τη συμπεριφορά του που είναι τα κύρια κριτήρια για το σύστημα ώστε να προτείνει κάτι το οποίο ταιριάζει σε αυτόν.

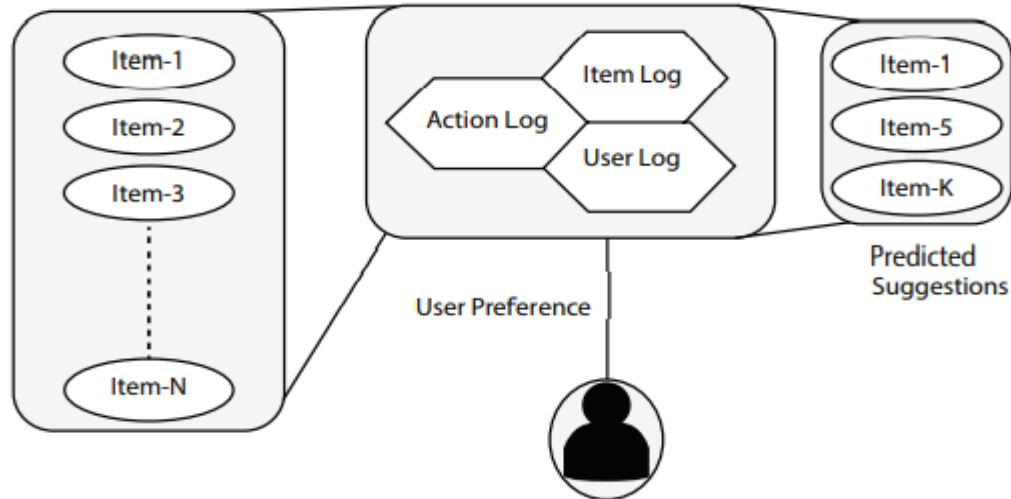
### **3.2.2 Αντικείμενα**

Τα αντικείμενα είναι οι υπηρεσίες ή τα προϊόντα που προτείνονται στον χρήστη μέσω του συστήματος σύστασης. Αν ο χρήστης ενδιαφέρεται για αυτή τη πρόταση τότε αντιμετωπίζεται ως θετική, αλλιώς ως αρνητική. Στη πρόταση ενός αντικειμένου λαμβάνεται πάντα υπόψιν και ο χρόνος που αφιέρωσε ο χρήστης για να το αναζητήσει καθώς και τα χρήματα που είναι διαθέσιμος να δαπανήσει για να αγοράσει αυτό το αντικείμενο. Για να προτείνει το σύστημα ένα αντικείμενο χρησιμοποιεί ορισμένα χαρακτηριστικά του αντικειμένου. Κάποια από αυτά είναι σταθερά για ένα προϊόν ενώ κάποια άλλα μπορούν να μεταβάλλονται με την πάροδο του χρόνου. Αυτό μπορεί να γίνει περισσότερο κατανοητό αν πάρουμε ως παράδειγμα το κινητό τηλέφωνο. Τα σταθερά χαρακτηριστικά ενός κινητού τηλεφώνου είναι η μάρκα, το χρώμα, η οθόνη, η κάμερα κ.λπ., ενώ οι κριτικές για ένα κινητό αλλάζουν κατά τη διάρκεια του χρόνου. Όταν ένα αντικείμενο έχει περισσότερα συγκεκριμένα χαρακτηριστικά τότε χαρακτηρίζεται ως σύνθετο (complex item) αλλιώς αν έχει περισσότερα γενικά χαρακτηριστικά χαρακτηρίζεται ως απλό (simple item).

### **3.2.3 Ενέργειες**

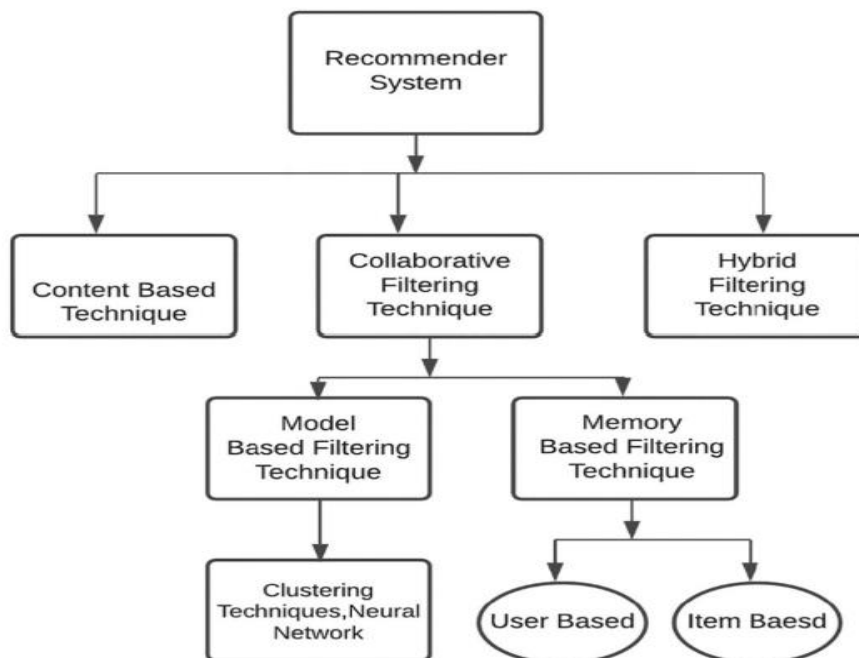
Τέλος, οι ενέργειες είναι η διαδικασία που εκτελεί ο χρήστης για ένα συγκεκριμένο αντικείμενο. Μία ενέργεια θα μπορούσε να είναι η αναζήτηση ενός προϊόντος ή η επιλογή μιας ταινίας. Αυτές οι ενέργειες καταγράφονται από το σύστημα στο προφίλ του χρήστη. Τα δεδομένα που λαμβάνει ένα σύστημα συστάσεων από έναν χρήστη μπορεί να είναι διαφορετικών μορφών, όπως μονοσήμαντο, δυαδικό, αριθμητικό και προτεινόμενο κείμενο. Το μονοσήμαντο σύστημα αποθηκεύει μόνο τη θετική τιμή, για παράδειγμα αν ο χρήστης αγοράσει ένα αντικείμενο τότε τα χαρακτηριστικά αυτού του αντικειμένου γίνονται πιο σημαντικά. Το δυαδικό σύστημα μπορεί να αποθηκεύσει είτε θετική ή αρνητική τιμή όπως αν του αρέσει ή αν δεν του αρέσει ένα προϊόν. Στο αριθμητικό σύστημα η αξία ενός στοιχείου αναλύεται από μία αριθμητική τιμή εντός κάποιου εύρους, όπως μία αξιολόγηση πέντε αστέρων. Το προτεινόμενο κείμενο είναι το σχόλιο που κάνει ο χρήστης για ένα αντικείμενο με

στόχο να βοηθήσει άλλους χρήστες για να αποφασίσουν σχετικά με το συγκεκριμένο προϊόν. Έτσι λοιπόν με βάση όλες αυτές τις πληροφορίες το σύστημα σύστασης βρίσκεται σε θέση να εντοπίσει το ενδιαφέρον του χρήστη.



Πηγή: *Recommender System with Machine Learning and Artificial Intelligence*, Sachi Nandan Mohanty

### 3.3 Τεχνικές των Recommendation Systems



Πηγή: *Recommender Systems Algorithms and Applications*, P. Pavan Kumar et al.

Σε γενικές γραμμές υπάρχουν δύο κύριοι τύποι συστημάτων συστάσεων, αυτά που βασίζονται στο περιεχόμενο (content-based) και αυτά με συνεργατικό φιλτράρισμα



(collaborative filtering). Ανάλογα με τους στόχους, τους πελάτες, την πλατφόρμα και τα αντικείμενα που προτείνονται, αυτές οι διαφορετικές προσεγγίσεις μπορούν να χρησιμοποιηθούν μεμονωμένα, αν και γενικά, τα καλύτερα αποτελέσματα προέρχονται από μοντέλα που είναι υβρίδια και των δύο (hybrid models).

### 3.3.1 Content-based Recommendation System

Ένα σύστημα συστάσεων με βάση το περιεχόμενο, χρησιμοποιεί την ομοιότητα μεταξύ των αντικειμένων με στόχο να προτείνει στον χρήστη ένα αντικείμενο που του αρέσει. Βασίζεται στα χαρακτηριστικά των αντικειμένων και στο γενικότερο σύνολο των αντικειμένων αυτών που έχουν βαθμολογηθεί προηγουμένως θετικά από τον χρήστη καθώς και στο προφίλ χρήστη (user profile). Αυτό που συμβαίνει αρχικά, είναι η δημιουργία ενός προφίλ για το αντικείμενο (item profile) βάση τις βαθμολογίες που έχει, ταινίες ή βίντεο που παρακολούθησε ο χρήστης, τραγούδια που άκουσε κ.λπ.. Το προφίλ χρήστη καταγράφει πληροφορίες όπως είναι τα προϊόντα που αγοράζει συχνά, του τύπου ταινιών που παρακολουθεί περισσότερο (με ένα συγκεκριμένο ηθοποιό/είδος/σκηνοθέτη κ.α.), το είδος μουσική που ακούει κ.λπ.. Το προφίλ του χρήστη δηλαδή δημιουργείται με το κάθε προφίλ του κάθε αντικειμένου που ο ίδιος έδειξε ενδιαφέρον. Ένας απλός τρόπος δημιουργίας προφίλ χρήστη είναι να πάρουμε την μέση τιμή των βαθμολογιών του.

Αφού δημιουργήθηκαν τα προφίλ, αυτό που έμεινε είναι να γίνει ένας έλεγχος μεταξύ των αντικειμένων που δεν έχουν βαθμολογηθεί και του προφίλ του χρήστη. Ο έλεγχος αυτός αφορά την ομοιότητα μεταξύ αυτών των δύο. Πρακτικά, η αναπαράσταση ενός προφίλ αντικειμένου ή ενός χρήστη γίνεται με διάνυσμα (πχ. [1,0,1,1,0], 1:αν ανήκει στην αντίστοιχη κατηγορία, 0: αν δεν ανήκει) ώστε να μπορέσει ο υπολογιστής να κάνει συγκρίσεις. Οι τρόποι λοιπόν για να υπολογιστεί αυτή η ομοιότητα μπορεί να είναι απλοί όπως μία συνάρτηση Ευκλείδειας απόστασης (Euclidean Distance) ή συνημιτονοειδής ομοιότητα (Cosine Similarity) ή πιο πολύπλοκες. Τέλος, αν η ομοιότητα είναι πάνω από ένα συγκεκριμένο όριο, το αντικείμενο συνιστάται στον χρήστη.

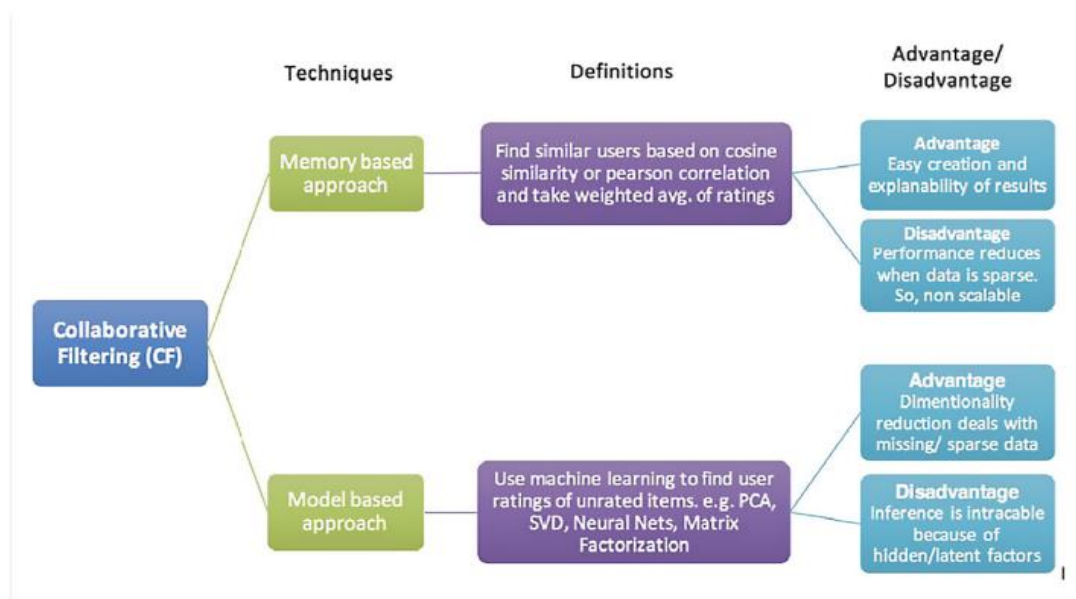
Ας εξηγήσουμε λοιπόν πιο αναλυτικά την αρχιτεκτονική ενός τυπικού content-based συστήματος συστάσεων. Η διαδικασία σύστασης πραγματοποιείται χρησιμοποιώντας τα εξής στάδια:

1. Ανάλυση περιεχομένου: Το πρώτο και σημαντικότερο βήμα σε αυτή τη διαδικασία είναι εξαγωγή και επιλογή των πληροφοριών/δεδομένων. Καθώς οι περισσότερες πληροφορίες που υπάρχουν σε ιστοσελίδες του διαδικτύου βρίσκονται σε μη δομημένη μορφή, χρειάζονται κάποια προεπεξεργασία ώστε να αλλάξουν στην κατάλληλη μορφή και να μπορέσει το σύστημα να τις επεξεργαστεί. Έπειτα, τα δεδομένα αυτά αναλύονται χρησιμοποιώντας τεχνικές εξαγωγής πληροφοριών (information retrieval techniques) όπως είναι για παράδειγμα η TF (Term Frequency) ή TF-IDF (Term Frequency–Inverse Document Frequency) κατά τις οποίες εξάγονται βεβαρημένες λέξεις όπου το βάρος της κάθε μίας αντιπροσωπεύει την αξία της στο κείμενο.
2. Εκμάθηση προφίλ χρήστη: Στο αυτό το στάδιο της διαδικασίας σύστασης δημιουργείται το προφίλ του χρήστη. Αφού συγκεντρωθούν οι πληροφορίες από το προηγούμενο στάδιο μέσω ενός μοντέλου μηχανικής μάθησης μαθαίνεται το μοτίβο των αντικειμένων στο οποίο ο χρήστης έδειξε ένα ενδιαφέρον στο παρελθόν. Τυχόν στοιχεία από τα οποία δεν μπορούμε να εξάγουμε κάποια πληροφορία, αφαιρούνται.
3. Δημιουργία σύστασης: Το τελευταίο μέρος αποτελείται από τη δημιουργία της σύστασης. Ο αλγόριθμος συγκρίνει τις αναπαραστάσεις των δεδομένων που προέκυψαν από τα δύο προηγούμενα στάδια, αντιστοιχίζοντας την εικόνα προφίλ του χρήστη με τα προτιμώμενα αντικείμενα. Τα αποτελέσματα αυτών των μετρήσεων ομοιοτήτων θα μπορούσε να είναι είτε δυαδικό ή δεκαδικό. Όταν ένα νέο προϊόν προστίθεται στην ιστοσελίδα, ο αλγόριθμος υπολογίζει το score προτίμησης για τον κάθε χρήστη, τους ταξινομεί (συνήθως) σε φθίνουσα κατάταξη, και το προτείνει στους πρώτους 'n' χρήστες. Ο αλγόριθμος θα παρατηρεί επίσης τη δράση του χρήστη σχετικά με τις συστάσεις που έκανε και στην περίπτωση που απαιτείται μπορεί να μετεκπαιδευτεί. Ορισμένες από τις μεθόδους που χρησιμοποιούνται για την εκπαίδευση αυτού του αλγορίθμου είναι η πιθανολογική μέθοδος (Probabilistic Method), Rocchio's and Relevance Feedback Method η οποία εφαρμόζεται πάνω στα αποτελέσματα εξαγωγής της TD-IDF, δέντρο απόφασης (Decision Tree), κοντινότερος γείτονας (Nearest Neighbor) κ.λπ..

### 3.3.2 Collaborative filtering

Η τεχνική του συνεργατικού φιλτραρίσματος (collaborative filtering technique), γνωστό και ως κοινωνικό φιλτράρισμα (social filtering) ή σύστημα φιλτραρίσματος πληροφοριών (information filtering system), επεξεργάζεται τις πληροφορίες αντλώντας συστάσεις διαφορετικών ανθρώπων. Η βασική ιδέα πίσω από αυτή την τεχνική είναι ότι παρόμοιοι χρήστες, δηλαδή άνθρωποι που μοιράζονται τα ίδια ενδιαφέροντα, είναι αρκετά πιθανό να τους αρέσουν και τα ίδια πράγματα δηλαδή τα ίδια αντικείμενα σύστασης. Το συνεργατικό φιλτράρισμα χρησιμοποιεί σχόλια, κριτικές και ενέργειες άλλων χρηστών για να συστήσει αντικείμενα σε άλλους παρόμοιους χρήστες με αυτούς. Έτσι μπορεί να προτείνει σε έναν χρήστη κάποιο αντικείμενο με εντελώς διαφορετικό περιεχόμενο από αυτά που παρακολουθεί μόνο και μόνο επειδή αρέσει σε κάποιον άλλο χρήστη που έχει τα ίδια ενδιαφέροντα με αυτόν. Υπάρχουν δύο κύριες προσεγγίσεις συνεργατικού φιλτραρίσματος, αυτή που βασίζεται στη μνήμη (memory-based approach) και η προσέγγιση βάσει μοντέλου (model-based approach).

- **Memory-based Approach:** Η πιο γνωστή από τις προσεγγίσεις που βασίζονται στη μνήμη είναι το φιλτράρισμα με βάση τη γειτονιά (Neighborhood-based filtering). Ο αλγόριθμος της γειτονιάς υπολογίζει τις ομοιότητες μεταξύ δύο χρηστών ή αντικειμένων και πραγματοποιεί μία πρόβλεψη για τον χρήστη λαμβάνοντας υπόψιν τον βεβαρημένο μέσο όρο όλων των αξιολογήσεων. Οι memory-based προσεγγίσεις ταξινομούνται σε δύο κύριες ενότητες:



Πηγή: Recommender Systems Algorithms and Applications, P. Pavan Kumar et al.

1. **User-based filtering:** Στην προσέγγιση του συνεργατικού φιλτραρίσματος βάσει τον χρήστη, εξετάζουμε παρόμοιους χρήστες. Η εξέταση αυτή περιλαμβάνει τη δημιουργία ομάδων χρηστών και την σύγκριση δραστηριοτήτων μελών εντός της ίδια ομάδας. Με αυτό τον τρόπο παρέχονται προτάσεις σε χρήστες που είναι δημοφιλείς μεταξύ άλλων μελών της ομάδας. Η τεχνική αυτή είναι αρκετά χρήσιμη, ιδιαίτερα σε ιστότοπους με μεγάλο και ευέλικτο κοινό ώστε να παρέχονται γρήγορα προτάσεις σε χρήστες για τους οποίους υπάρχουν λίγες πληροφορίες.

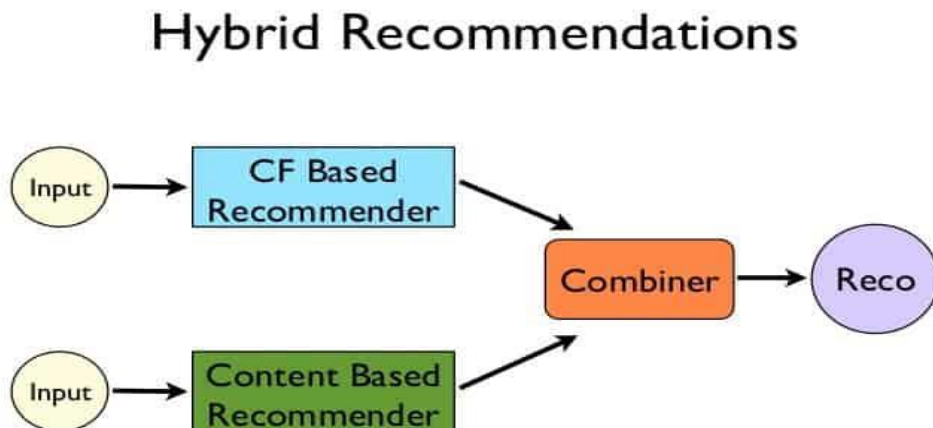
Tv Shows/Users	User 1	User 2	User 3
Squid Game	Like	Dislike	Like
Mr. Robot	Neutral	Like	Neutral
Loki	Dislike	Like	Dislike
Breaking Bad	Dislike	-	?
The Mentalist	Like	Dislike	?

Στο παραπάνω παράδειγμα παρατηρούμε ότι ο χρήστης 1 έχει τα ίδια ενδιαφέροντα με τον χρήστη 3. Έτσι λοιπόν, μέσω της τεχνικής φιλτραρίσματος βάσει χρήστη, στον χρήστη 3 η σειρά που θα πρέπει να προταθεί από το σύστημα σύστασης είναι το “The Mentalist”.

2. **Item-based filtering:** Η δεύτερη τεχνική είναι εκείνη που βασίζεται στα αντικείμενα. Το σύστημα ελέγχει τα αντικείμενα που είναι παρόμοια με τα αντικείμενα που αγόρασε ο χρήστης και η πρόβλεψη αξιολογείται χρησιμοποιώντας ομοιότητες μεταξύ των χαρακτηριστικών των αντικειμένων αυτών. Στο προηγούμενο παράδειγμα εφόσον στον χρήστη 3 αρέσει η σειρά “Squid Game” πρέπει να βρούμε ένα άλλο αντικείμενο (δηλαδή μία άλλη σειρά) που να έχει βαθμολογηθεί παρόμοια με τη σειρά “Squid Game”. Παρατηρούμε λοιπόν, πως οι αξιολογήσεις για τη σειρά “Squid Game” είναι αρκετά κοντά με τη σειρά “The Mentalist”, γι’ αυτό τον λόγο η σειρά που θα προταθεί στον χρήστη 3 θα είναι πάλι το “The Mentalist”.

- **Model-based Approach:** Τα memory-based συστήματα συστάσεων είναι αρκετά χρήσιμα όμως έχει παρατηρηθεί πως η απόδοσή τους τείνει να μειώνεται όταν τα δεδομένα που έχουμε στη διάθεσή μας είναι «αραιά», δηλαδή έχουμε λίγες πληροφορίες για την κάθε ομάδα χρηστών με αποτέλεσμα να μην έχουμε ένα αξιόπιστο συμπέρασμα για τα αντικείμενα σύστασης και αυτό δημιουργεί ένα μεγάλο πρόβλημα πολυπλοκότητας όταν έχουμε μεγάλο όγκο δεδομένων. Για την επίλυση αυτού του προβλήματος έχουν προταθεί αρκετές τεχνικές που βασίζονται σε μοντέλα μηχανικής μάθησης (model-based filtering techniques) όπως είναι Bayesian Networks, τεχνικές Clustering, Artificial Neural Networks κ.α.. Όλες αυτές οι τεχνικές συνδυάζουν τεχνικές της επιστήμης των δεδομένων (data mining) και χρησιμοποιούνται για να προβλέψουν το μοτίβο ενδιαφερόντων ενός χρήστη. Με αυτό τον τρόπο είμαστε στη θέση να μπορούμε να διαχειριστούμε αραιά δεδομένα καθώς και να μειώσουμε το κόστος υπολογισμού χρησιμοποιώντας διάφορες τεχνικές μείωσης διαστάσεων (dimensionality reduction techniques) όπως παραγοντοποίηση πινάκων (Matrix Factorization) και Singular Value Decomposition (SVD) ή Principal Component Analysis (PCA). Στα συστήματα συστάσεων συνηθίζεται να χρησιμοποιείται περισσότερο η τεχνική SVD.

### 3.3.3 Hybrid Recommendation System



Πηγή: [dataconomy.com](http://dataconomy.com)

Τα υβριδικά συστήματα σύστασης είναι τα συστήματα που αξιοποιούν τόσο την τεχνική με βάση το περιεχόμενο (content-based technique) όσο και το συνεργατικό φιλτράρισμα (collaborative filtering) για τη δημιουργία συστάσεων. Χρησιμοποιούνται

τα πλεονεκτήματα και των δύο τεχνικών ώστε να έχουμε ένα ακριβές αποτέλεσμα. Η μία τεχνική προσπαθεί να διορθώσει τα μειονεκτήματα της αλληλής. Για παράδειγμα η μέθοδος συνεργατικού φιλτραρίσματος έχει χειρότερα αποτελέσματα στην περίπτωση ενός καινούριου χρήστη σε σύγκριση με τη προσέγγιση βάσει περιεχομένου που βασίζεται σε ήδη υπάρχουσα περιγραφή του χρήστη. Έτσι, σε ένα υβριδικό σύστημα πραγματοποιείται πρώτα η σύσταση περιεχομένου, καθώς δεν υπάρχουν δεδομένα για έναν νέο χρήστη, και έπειτα καθορίζονται οι προτιμήσεις του χρήστη με τη βοήθεια του συνεργατικού φιλτραρίσματος. Τα υβριδικά συστήματα είναι και αυτά που χρησιμοποιούνται περισσότερο καθώς έχουν καλύτερα αποτελέσματα, όμως δεν παύουν να αντιμετωπίζουν και αυτά δυσκολίες, όπως είναι η ποικιλία μεταξύ των χρηστών αλλά και η αλλαγή στη προτίμησή τους.

### **3.4 Προκλήσεις των συστημάτων συστάσεων**

Εξαιτίας του τεράστιου όγκου και της ποικιλίας πληροφοριών και δεδομένων που διατίθενται σήμερα στο Διαδίκτυο, η αντιστοίχιση χρήστη-αντικειμένου είναι μία αρκετά δύσκολη διαδικασία για τα συστήματα συστάσεων. Ορισμένες από τις δυσκολίες που αντιμετωπίζουν είναι οι εξής:

#### **3.4.1 Data Sparsity**

Η αραιότητα των δεδομένων είναι μία από τις μεγαλύτερες προκλήσεις για ένα σύστημα σύστασης. Οι περισσότεροι χρήστες δεν θα αξιολογήσουν τα περισσότερα από τα αντικείμενα της αντίστοιχης υπηρεσίας και έτσι δεν θα υπάρχουν αρκετές πληροφορίες. Η έλλειψη αυτή στο ιστορικό των προτιμήσεων προκαλεί κακές συστάσεις για τους νέους χρήστες. Αυτό το πρόβλημα εμφανίζεται πολύ συχνά στο συνεργατικό φιλτράρισμα.

#### **3.4.2 Scalability**

Σήμερα, τα εμπορικά συστήματα συστάσεων έρχονται αντιμέτωπα με τεράστια σύνολα δεδομένων και γι' αυτό τον λόγο ο πίνακας χρήστης-αντικείμενο γίνεται μεγάλος και περίπλοκος με αποτέλεσμα να μειώνεται η απόδοση των συστάσεων. Το αυξανόμενο μέγεθος των δεδομένων επηρεάζει την απόδοση του αλγορίθμου και αυτό συμβαίνει λόγω του γεγονότος ότι η υπολογιστική ικανότητα ξεφεύγει από το πρακτικό όριο.

### 3.4.3 Cold-Start Problem

Ακόμα ένα δημοφιλές πρόβλημα των συστημάτων συστάσεων είναι το πρόβλημα “ψυχρής εκκίνησης”. Αυτό εντοπίζεται περισσότερο στους νέους χρήστες καθώς υπάρχει έλλειψη πληροφοριών ώστε να συμβεί αποδοτικά μία σύσταση. Το σύστημα σύστασης πρέπει με κάποιο τρόπο να συλλέξει δεδομένα για τον καινούριο χρήστη. Αυτό μπορεί να γίνει με αρκετούς τρόπους:

1. Ζητώντας από τον πελάτη να κατατάξει ορισμένα προϊόντα κατά την εγγραφή του σύμφωνα με τα ενδιαφέροντά του ώστε να έχουμε μία εικόνα του προφίλ του.
2. Λαμβάνοντας υπόψιν τις προτιμήσεις και τις απαιτήσεις των ήδη εγγεγραμμένων χρηστών.
3. Σύσταση προϊόντων ανάλογα με τις συγκεντρωμένες δημογραφικές του πληροφορίες.

Μέσω των δημογραφικών πληροφοριών ενός χρήστη (πχ. η τοποθεσία, ο ταχυδρομικός κώδικας), μπορούν να πραγματοποιηθούν προτάσεις αντικειμένων σύμφωνα με τα ενδιαφέροντα άλλων χρηστών με παρόμοιες δημογραφικές πληροφορίες.

### 3.4.4 Privacy

Η παροχή προσωπικών δεδομένων στα συστήματα συστάσεων μπορεί να αυξήσει την απόδοση του συστήματος, αλλά μπορεί να οδηγήσει σε προβλήματα απορρήτου και ασφάλειας δεδομένων. Οι περισσότεροι χρήστες δεν είναι πρόθυμοι να τροφοδοτούν τα συστήματα συστάσεων με προσωπικές πληροφορίες, ιδιαίτερα σε πλατφόρμες ή υπηρεσίες που είναι άγνωστες για αυτούς. Για παράδειγμα στο δημογραφικό φιλτράρισμα που αναφέραμε προηγουμένως, είναι δυνατόν ο χρήστης να μην επιτρέψει να δημοσιευθούν οι τοπογραφικές του πληροφορίες. Επομένως τα συστήματα συστάσεων θα πρέπει να οικοδομήσουν εμπιστοσύνη μεταξύ των χρηστών τους.

### 3.4.5 Shilling Attacks

Τα σημερινά μέσα κοινωνικής δικτύωσης πλημμυρίζουν από διάφορα ψεύτικα και κακόβουλα προφίλ. Εάν ένας κακόβουλος χρήστης ή ανταγωνιστής παρέχει αναληθείς αξιολογήσεις σε ορισμένα προϊόντα αυτό θα έχει σαν αποτέλεσμα την λανθασμένη επιρροή στα αντικείμενα όπως να γίνει κάποιο περισσότερο ή λιγότερο

δημοφιλές. Αυτές οι επιθέσεις μειώνουν την απόδοση και την ποιότητα των συστημάτων συστάσεων. Οι τεχνικές συνεργατικού φιλτραρίσματος είναι πιο επιρρεπείς σε αυτές τις επιθέσεις αφού βασίζονται και στις συνολικές αξιολογήσεις των αντικειμένων. Για τον εντοπισμό αυτών των επιθέσεων χρησιμοποιούνται διάφορες τεχνικές όπως είναι hit ratio, συγκεκριμένα χαρακτηριστικά αντικειμένου (model specific attributes), πρόβλεψη μετατόπισης (prediction shift) κ.α..

### **3.5 Netflix's Recommender System**

Σήμερα, με περισσότερους από 209 εκατομμύρια συνδρομητές και με περίπου 9,400 υπαλλήλους το Netflix είναι αναμφισβήτητα η μεγαλύτερη streaming κινηματογραφική υπηρεσία στον κόσμο. Ένας από τους κυριότερους λόγους που το Netflix κάνει τη διαφορά από άλλες πανομοιότυπες υπηρεσίες είναι το εκπληκτικό σύνθετο σύστημα προτάσεων που χρησιμοποιεί. Λόγω των γρήγορων ρυθμών μιας σύγχρονης πόλης, λόγω άγχους και στρες των σημερινών ανθρώπων, η παρακολούθηση ταινιών/σειρών ήταν ανέκαθεν μια ευκαιρία για διαφυγή λίγων ωρών από την πραγματικότητα και στιγμές ξεκούρασης και χαλάρωσης. Γι' αυτούς του λόγους όλοι θέλουν μία έξυπνη streaming πλατφόρμα που μπορεί να κατανοεί τις προτιμήσεις τους και να τους προτείνει ταινίες και σειρές που τους αρέσουν γλυτώνοντας έτσι την διαδικασία της αναζήτησης. Τους στόχους αυτούς τους έχει πετύχει εξαιρετικά καλά το Netflix που αποτελείται από μία ποικιλία αλγορίθμων από τους οποίους μερικοί θα αναλυθούν παρακάτω. Οι περισσότεροι από αυτούς αναφέρονται στην αρχική σελίδα καθώς είναι και το πρώτο πράγμα που βλέπει ένας χρήστης όταν συνδέεται από οποιαδήποτε συσκευή.

#### **3.5.1 The Netflix Prize**

Το 2006, το Netflix, μία εταιρεία που τότε ήταν μία διαδικτυακή υπηρεσία ενοικίασης DVD και παροχής video streaming, ανακοίνωσε το "The Netflix Prize", έναν διαγωνισμό με στόχο την βελτιστοποίηση ενός αλγορίθμου σύστασης του Netflix. Ο αλγόριθμος αυτός είχε μέσο τετραγωνικό σφάλμα (root mean square error - RMSE) 0.9525, και όποια ομάδα κατάφερε να μειώσει αυτό το σφάλμα κατά 10% τότε κέρδιζε το μεγάλο έπαθλο των 1,000,000 δολαρίων. Τρία χρόνια αργότερα, το 2009, το μεγάλο βραβείο δόθηκε στην ομάδα BellKor's Pragmatic Chaos, η οποία κατάφερε να βελτιστοποιήσει τον αλγόριθμο κατά 10.06%. Για την επίτευξη του στόχου




χρησιμοποιήθηκε ένας γραμμικός συνδυασμός παραγοντοποίησης πινάκων (γνωστός και ως SVD) και μηχανών Boltzmann (Restricted Boltzmann Machines - RBM).

### 3.5.2 Personalized Video Ranker (PVR)



Πηγή: [netflixtechblog.com](http://netflixtechblog.com)

Στην αρχική οθόνη, ανάλογα και με την κάθε συσκευή, υπάρχουν περίπου 40 κατηγορίες εκ των οποίων η κάθε μία περιέχει περίπου 75 ταινίες ή σειρές. Η ταξινόμηση αυτή των βίντεο ανά κατηγορία, πραγματοποιείται μόλις από έναν μόνο αλγόριθμο που ονομάζεται εξατομικευμένη ταξινόμηση βίντεο (PVR). Τα βίντεο αυτά ταξινομούνται με συγκεκριμένα κριτήρια (π.χ. Top 10 in Greece Today, Award-Winning TV Shows, Comedies κ.λπ.) σε συνδυασμό με παράπλευρες λειτουργίες, όπως τη δημοτικότητά τους και τα χαρακτηριστικά του κάθε χρήστη. Γι' αυτό τον λόγο κάθε μέλος/προφίλ σε έναν λογαριασμό μπορεί να έχει διαφορετικά προτεινόμενα βίντεο σε αρκετές κατηγορίες.



Παράδειγμα αλγορίθμου PVR

### 3.5.3 Trending Now Suggestions

Παρατηρήθηκε πως οι βραχυπρόθεσμες χρονικές τάσεις, που κυμαίνονται από λίγα λεπτά έως μερικές μέρες, μπορούν να προβλέψουν τα μελλοντικά βίντεο που θα παρακολουθήσουν οι χρήστες σε παρόμοιες χρονικές στιγμές ή συνθήκες. Έτσι, το Netflix αξιοποίησε αυτά τα δεδομένα για την υλοποίηση ενός αλγορίθμου που θα πραγματοποιεί αυτές τις προβλέψεις. Υπάρχουν 2 ειδών τάσεις που διαχειρίζεται αυτός ο αλγόριθμος:

1. Εκείνες που επαναλαμβάνονται κάθε αρκετούς μήνες (π.χ. ετησίως), δηλαδή εποχιακές τάσεις, όπως για παράδειγμα η παρακολούθηση ρομαντικών ταινιών την ημέρα του Αγίου Βαλεντίνου ή η παρακολούθηση χριστουγεννιάτικων ταινιών/σειρών κατά την περίοδο διακοπών των Χριστουγέννων.
2. Μεμονωμένα και στιγμιαία γεγονότα, όπως COVID-19, ένας μεγάλος τυφώνας και άλλες καταστροφές που οδηγούν σε αύξηση του ενδιαφέροντος των μελών για ντοκιμαντέρ και ταινίες φυσικών καταστροφών.

### 3.5.4 Continue Watching Ranker

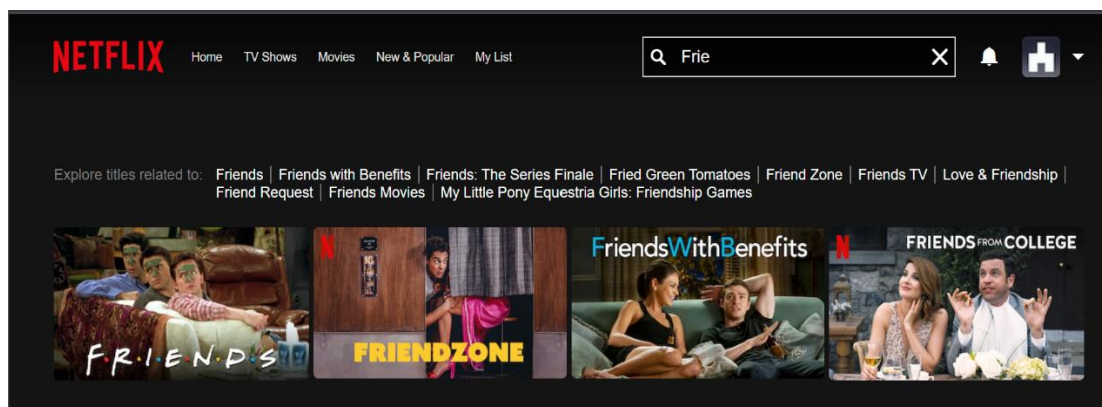
Αυτός ο αλγόριθμος εξετάζει τα βίντεο που ο χρήστης έχει ξεκινήσει να βλέπει αλλά δεν έχει ολοκληρώσει. Ο αλγόριθμος ταξινομεί τα βίντεο με βάση ορισμένες εκτιμήσεις/πιθανότητες για το εάν ο χρήστης σκοπεύει να συνεχίσει την παρακολούθηση ή να το παρακολουθήσει ξανά ή εάν το έχει εγκαταλείψει γιατί δεν ήταν τόσο ενδιαφέρον όσο αναμενόταν. Τα δεδομένα που λαμβάνονται υπόψιν για τις εκτιμήσεις αυτές, είναι ο χρόνος που έχει παρακολουθήσει το βίντεο, το σημείο εγκατάλειψης (αν ο θεατής το παράτησε στην αρχή, στη μέση ή στο τέλος), αν έχει παρακολουθήσει κάτι άλλο από τότε ή αν έχει ξανά συνδεθεί με την ίδια συσκευή.

### 3.5.5 Search

Εκτός από την παρακολούθηση ταινιών και σειρών, ένας χρήστης μπορεί να τροφοδοτήσει το σύστημα με πληροφορίες και από τα πράγματα που αναζητεί. Αυτό το εκμεταλλεύτηκε το Netflix, και έτσι ανέπτυξε για την αναζήτηση ένα σύνολο αλγορίθμων. Όταν λοιπόν ένας χρήστης αναζητεί κάποιο βίντεο μέσω του τίτλου, του ηθοποιού ή του είδους που ανήκει ο αλγόριθμος επεξεργάζεται αυτά τα δεδομένα και του εμφανίζει τα βίντεο που σχετίζονται με το αποτέλεσμα της αναζήτησης. Όμως υπάρχουν και περιπτώσεις όπου η αναζήτηση του χρήστη δεν θα ταυτίζεται με κάποιο

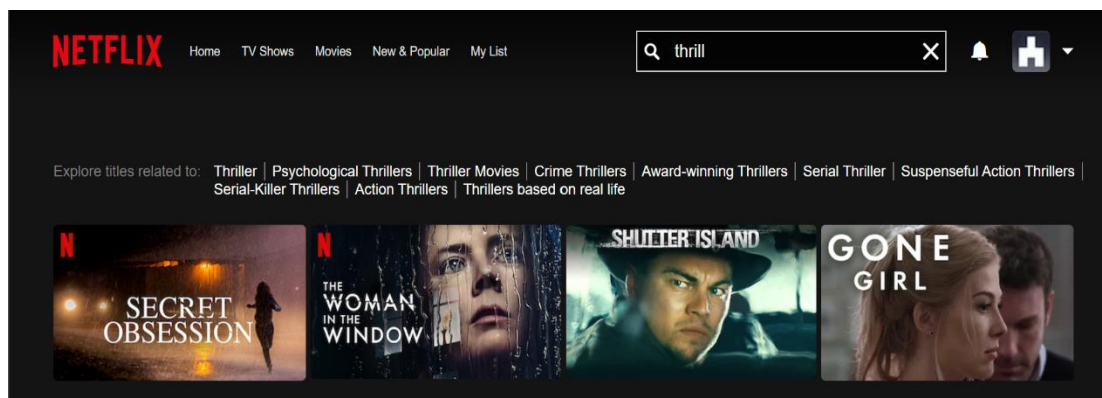
βίντεο που υπάρχει στη πλατφόρμα. Μία τέτοια περίπτωση μπορεί να αντιμετωπιστεί με τους παρακάτω αλγορίθμους:

1. Να βρεθεί και να προταθεί κάποιο βίντεο που θα ταιριάζει με το αίτημα του χρήστη. Για παράδειγμα, αν η είσοδος είναι “Frie” τότε θα προταθεί μία σειρά από βίντεο που περιέχουν την συμβολοσειρά “Frie” όπως παρατηρούμε στην παρακάτω εικόνα.



*Netflix's search algorithm example 1*

2. Να ταυτίσει την είσοδο της αναζήτησης με ένα είδος ταινιών και να επιστρέψει βίντεο που ανήκουν στο ίδιο είδος. Όπως σε μία αναζήτηση με την είσοδο “thrill”, ο αλγόριθμος θα προτείνει τίτλους που αντιπροσωπεύουν υποκατηγορίες ταινιών που ανήκουν στην κατηγορία “Thriller”.



*Netflix's search algorithm example 2*

3. Αφού βρεθεί μία ταύτιση με την αναζήτηση του χρήστη, όπως στο παραπάνω παράδειγμα με τη κατηγορία “Thriller”, υπάρχει ένας αλγόριθμος ο οποίος αναλαμβάνει να βρει προτάσεις βίντεο για τη συγκεκριμένη κατηγορία ώστε να προταθεί ένα σύνολο ταινιών που θα ταιριάζουν με την κατηγορία “Thriller”. Στην εικόνα, μπορούμε να παρατηρήσουμε πως κάτω από τους προτεινόμενους τίτλους, εμφανίζονται προτάσεις ταινιών, σχετικές με την πρόβλεψη που έκανε ο αλγόριθμος.

### 3.5.6 Thumbnails

Ένας χρήστης του Netflix μετά από 90 δευτερόλεπτα περιήγησης στη πλατφόρμα, αν δεν βρει κάτι που του κέντρισε το ενδιαφέρον να παρακολουθήσει, θα κλείσει την εφαρμογή. Τα thumbnails (τα εικονίδια δηλαδή των ταινιών και σειρών), παίζουν πολύ σημαντικό ρόλο, καθώς είναι η πρώτη εικόνα που βλέπει ένας χρήστης όταν ψάχνει κάτι να δει, και είναι αυτά που θα του κεντρίσουν το ενδιαφέρον ώστε να πατήσει να παρακολουθήσει το τρέιλερ. Τα εικονίδια αλλάζουν συνεχώς, διαφορετικά για τον κάθε χρήστη, κάνοντας την εμπειρία ακόμη πιο προσωποποιημένη. Το βλέμμα του κάθε χρήστη μένει σε κάθε εικονίδιο για 1,8 δευτερόλεπτα και αν το συγκρίνουμε με μέσο όρο τα 90 δευτερόλεπτα που χρειάζεται για να φύγει από την πλατφόρμα, τότε η εκμετάλλευση του κάθε δευτερολέπτου για να κερδίσει το ενδιαφέρον του θεατή, μοιάζει λογική.

Η μέθοδος επιλογής thumbnail του Netflix, βασίζεται σε ένα σύνολο αλγορίθμων που ονομάζεται «αισθητική οπτική ανάλυση» ή αλλιώς AVA. Οι αλγόριθμοι αυτοί επεξεργάζονται εκατομμύρια στιγμιότυπα των βίντεο με στόχο την εύρεση του καταλληλότερου ώστε να μπει σαν thumbnail. Μία μόνο σεζόν μιας μέσης τηλεοπτικής σειράς έχει περίπου 9 εκατομμύρια στιγμιότυπα ή αλλιώς καρτέ. Η επεξεργασία των καρτέ βασίζεται σε ορισμένες παραμέτρους μέσα στο κάθε καρτέ ώστε να επιλεγεί η πιο φανταχτερή, εντυπωσιακή και δημοφιλέστερη εικόνα. Η διαδικασία αυτή ονομάζεται “Frame Annotation” και λαμβάνονται χαρακτηριστικά της εικόνας όπως είναι η φωτεινότητά της, το χρώμα, πρόσωπα και χρώμα του δέρματος, εκφράσεις, διάταξη εικόνας (βασικές αρχές φωτογραφίας και κινηματογράφου όπως ο κανόνας των τρίτων, βάθος πεδίου και συμμετρία) κ.α..

Αφού γίνει η διαδικασία του Frame Annotation και επιλεγθούν οι high-quality εικόνες, το επόμενο βήμα είναι η εύρεση των καλύτερων υποψήφιων εικόνων για thumbnail. Τα πράγματα που λαμβάνονται υπόψιν είναι τα εξής:

- Ηθοποιοί: Οι ηθοποιοί παίζουν πολύ σημαντικό ρόλο στο thumbnail. Μέσω ενός deep learning αλγορίθμου για αναγνώριση προσώπων (face recognition) ξεχωρίζουν τις εικόνες που παίζουν οι πρωταγωνιστές και τις εικόνες που παίζουν δευτερεύοντες χαρακτήρες.



Example of actor clusters, frame ranking and optimal selection for Wynona Ryder as Joyce Byers.

Πηγή: [netflixtechblog.com](http://netflixtechblog.com)

- **Frame Diversity:** Αν και είναι υποκειμενικό το τι καταλαβαίνει κάποιος όταν παρατηρεί μία εικόνα, το thumbnail πρέπει να αντιπροσωπεύει όσο καλύτερα γίνεται τον τίτλο της ταινίας ή της σειράς. Αυτή είναι μία αρκετά δύσκολη διαδικασία αλλά οι εικόνες που επιλέγονται για έναν τίτλο συγκρίνονται στοιχεία όπως μακρινή ή μέτρια λήψη, οπτική ομοιότητα (κανόνας των τρίτων, φωτεινότητα και αντίθεση), χρώματα και saliency maps (εικόνες δηλαδή σε κλίμακα του γκρι που μπορούμε να παρατηρήσουμε μέσω της φωτεινότητας πόσο σημαντικό είναι το κάθε pixel).
- **Φιλτράρισμα περιεχομένου:** Για λόγους ευαίσθητου περιεχομένου και αποφυγής προβολής ακατάλληλου περιεχομένου στο κοινό πρέπει να αποκλειστούν εικόνες που περιέχουν σκηνές με σεξ ή γυμνό, λογότυπα με μη εξουσιοδοτημένη επωνυμία και σκηνές βίας.

Τέλος, μέσω ερευνών που έχουν πραγματοποιηθεί, έχει παρατηρηθεί ότι οι «κακοί» και οι γκριμάτσες είναι εικόνες οι οποίες τραβάνε το ενδιαφέρον του θεατή ενώ αντίθετα εικόνες με πολύ πληροφορία, όπως πολλούς ανθρώπους ή αντικείμενα μπερδεύει περισσότερο τον χρήστη και είναι λιγότερο πιθανό να πατήσει το “click”. Επίσης έχει διαφορά και σε ποια χώρα βρίσκεται ο κάθε χρήστης, διότι τα thumbnails επιλέγονται και βάσει την προτίμηση των άλλων χρηστών της ίδιας χώρας και αυτό φαίνεται στην παρακάτω εικόνα.



Top in Germany



Top in Brazil



Top in US



Top in UK



Πηγή: [unboxholics.com](http://unboxholics.com)

## Κεφάλαιο 4

### Προτεινόμενο Σύστημα

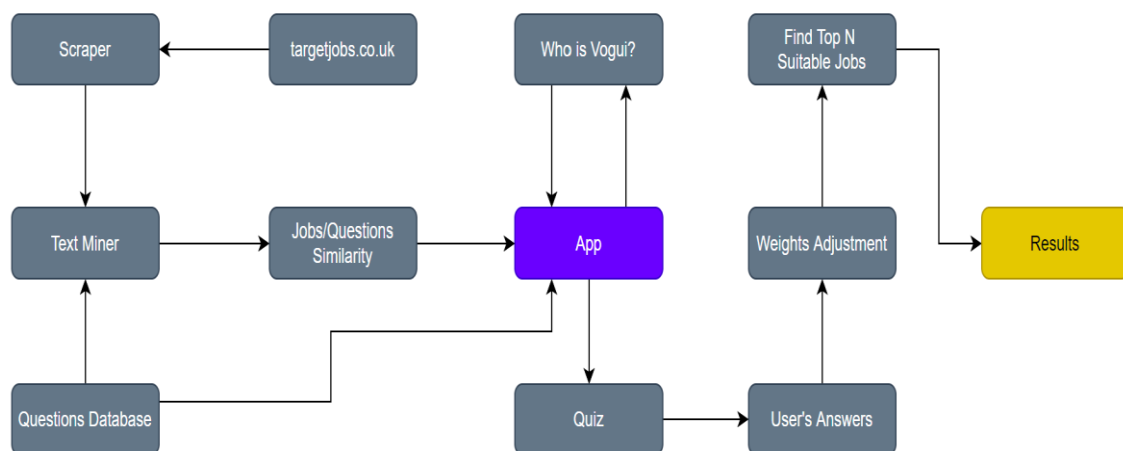
# VOGUI

#### 4.1 Εισαγωγή

Σε αυτό το κεφάλαιο θα γίνει μία αναλυτική περιγραφή για την υλοποίηση και ανάπτυξη του chatbot Vogui. Ο Vogui, “Vocational Guidance”, είναι ένα chatbot σύστημα συστάσεων που παίρνει το ρόλο ενός συμβούλου επαγγελματικού προσανατολισμού με στόχο να βοηθήσει τους χρήστες να επιλέξουν τη μελλοντική τους επαγγελματική ενασχόληση. Μέσα από ένα σύνολο ερωτήσεων, ο Vogui θα βρίσκεται σε θέση να κατανοήσει τα ενδιαφέροντα και τις προτιμήσεις του χρήστη, με αποτέλεσμα να του προτείνει αποτελεσματικά τις δουλειές που του ταιριάζουν.

Στα προηγούμενα κεφάλαια εξηγηθήκαν αναλυτικά τι είναι τα chatbots και τα συστήματα σύστασης, παρουσιάστηκαν παραδείγματα εφαρμογών καθώς και οι τεχνολογίες που χρησιμοποιούνται για την υλοποίηση του καθενός αντίστοιχα. Αποτέλεσμα αυτών, είναι να γίνει πιο εύκολα κατανοητή η ανάπτυξη του συστήματος και έτσι να βρισκόμαστε στη θέση να προσεγγίσουμε ορισμένες τεχνικές και αλγορίθμους σε βάθος. Η γλώσσα προγραμματισμού που χρησιμοποιήθηκε για την υλοποίηση της εφαρμογής είναι η Python 3.

#### 4.2 Η Αρχιτεκτονική του Συστήματος



Διάγραμμα του συστήματος

Στο παραπάνω διάγραμμα παρουσιάζεται συνοπτικά η διαδικασία του συστήματος και οι λειτουργίες που χρησιμοποιήθηκαν για την υλοποίησή του. Αρχικά λοιπόν το chatbot τροφοδοτείται από τις ερωτήσεις που θα χρησιμοποιηθούν για το Quiz καθώς και την ομοιότητα μεταξύ επαγγελμάτων και ερωτήσεων, δηλαδή σε ποια δουλειά αντιστοιχεί η κάθε ερώτηση. Μέσω λοιπόν τριών Scraper που δημιουργήθηκαν για την ανάκτηση των εργασιών από τον ιστότοπο "[targetjobs.co.uk](http://targetjobs.co.uk)" παίρνουμε τις απαραίτητες περιγραφές της κάθε εργασίας. Έπειτα οι περιγραφές των επαγγελμάτων και οι ερωτήσεις δίνονται στον Text Miner για να εξάγουμε τις σημαντικότερες πληροφορίες, δηλαδή τις **λέξεις κλειδιά (keywords)**. Μετά την διαδικασία του text mining (ή information retrieval) για τις περιγραφές χρησιμοποιήθηκε ένας αλγόριθμος ώστε να βρεθεί η αντιστοίχιση μεταξύ των ερωτήσεων και των επαγγελμάτων ο οποίος βασίζεται στην ομοιότητα των λέξεων καθώς και στη βαρύτητά τους και με το τέλος αυτής της διαδικασίας οι πληροφορίες περνούν στο σύστημα.

Αφού η εφαρμογή τροφοδοτηθεί με τα δεδομένα που χρειάζεται μπορεί να ξεκινήσει το Quiz. Στην αρχική οθόνη της εφαρμογής, εκτός από την εκκίνηση του τεστ, ο χρήστης μπορεί να επιλέξει αν επιθυμεί να γνωρίσει τον Vogui μέσω του κουμπιού "Who Am I". Με το πάτημα του κουμπιού ο Vogui θα του συστηθεί και θα του εξηγήσει τον λόγο ύπαρξής του. Εφόσον ο χρήστης ξεκινήσει το Quiz και απαντήσει σε όλες τις ερωτήσεις, το chatbot θα επεξεργαστεί τις απαντήσεις αυτές, θα ταξινομήσει τις βεβαρημένες ερωτήσεις σύμφωνα με την προτίμηση του χρήστη και τέλος θα του εμφανίσει έναν αριθμό ταιριαστών επαγγελμάτων για την προσωπικότητά του.

### 4.3 Web Scraping

Το Web Scraping είναι η αυτοματοποιημένη διαδικασία συλλογής πληροφοριών από κάποιον ιστότοπο. Για παράδειγμα η χειρωνακτική αντιγραφή και επεξεργασία ενός κειμένου που έχει ανακτηθεί από κάποια ιστοσελίδα αποτελεί την ίδια λειτουργία με τη λειτουργία ενός scraper μόνο που η διαδικασία είναι πολύ πιο απλή και μη αυτοματοποιημένη. Οι scrapers όμως δεν παρουσιάστηκαν μόνο για να αυτοματοποιήσουν αυτή την διαδικασία. Η αντιγραφή και επικόλληση ενός κειμένου από ένα website είναι αρκετά εύκολη, αλλά είναι προβληματική όταν χρειάζεται να επεργαστούμε όχι ένα αλλά 100 ή 1000 ή και παραπάνω κείμενα. Η διαδικασία θα είναι



πολύ χρονοβόρα και όσο μεγαλώνει ο αριθμός των δεδομένων που πρέπει να εξαχθούν από μία ιστοσελίδα ο χειροκίνητος τρόπος μοιάζει ακατόρθωτος. Έτσι λοιπόν, το web scraping χρησιμοποιεί μία έξυπνη αυτοματοποίηση για να ανακτήσει σε πολύ μικρό χρονικό διάστημα, εκατοντάδες εκατομμύρια ή και δισεκατομμύρια δεδομένα από μία ή περισσότερες ιστοσελίδες.

Για τις απαιτήσεις του συστήματος Vogui έπρεπε να δημιουργηθούν τρεις scrapers, τρία προγράμματα δηλαδή που θα εξάγουν τις απαραίτητες πληροφορίες από την ιστοσελίδα “[targetjobs.co.uk](http://targetjobs.co.uk)”. Συγκριμένα ο πρώτος scraper θα ανακτήσει τους τίτλους των εργασιών καθώς και το URL link για την κάθε μία από αυτές, ο δεύτερος θα χρησιμοποιήσει τα links των επαγγελμάτων που πήρε ο πρώτος για να εξάγει την περιγραφή για το κάθε επάγγελμα και ο τρίτος θα τραβήξει τις κατηγορίες των επαγγελμάτων καθώς και ποια επαγγέλματα ανήκουν στην κάθε μία από αυτές.

#### 4.3.1 Τίτλοι και Σύνδεσμοι Επαγγελμάτων

The screenshot displays a grid of 12 job cards, each with a title and a brief description. A red bracket on the left side of the grid is labeled "12 jobs per load". The top of the page features navigation filters: "Advice & Learning", "Sort by", "Sector", "Category", "+ All filters", and "Reset". The first card is highlighted with a red box around its title "Event manager: job description". The last card has a "Load more" button below it.

Ιστοσελίδα επαγγελμάτων

Αρχικά, η σύνδεση με τις ιστοσελίδες με τον κάθε scraper έγινε μέσω του WebDriver για το Chrome. Το ChromeDriver, το οποίο χρησιμοποιεί το πρότυπο W3C WebDriver, είναι ένα εργαλείο ανοιχτού κώδικα που παρέχει δυνατότητες πλοήγησης σε ιστοσελίδες μέσω του προγράμματος περιήγησης Chrome.

Στη παραπάνω εικόνα φαίνεται η ιστοσελίδα από την οποία θέλουμε να πάρουμε τους τίτλους των επαγγελμάτων καθώς και το link που αντιστοιχεί σε κάθε επάγγελμα. Ένας scraper μπορεί να πάρει μόνο τα δεδομένα τα οποία βλέπουμε μόλις ανοίξουμε την ιστοσελίδα. Για παράδειγμα, παρατηρούμε πως τα συνολικά επαγγέλματα είναι 496 αλλά ο scraper μπορεί να δει μόνο τα επαγγέλματα που έχουν φορτωθεί, δηλαδή 12. Το πρώτο πράγμα που πρέπει να γίνει λοιπόν είναι να πατηθεί το κουμπί 'Load more' ώστε να φορτωθούν όλα τα επαγγέλματα για να μπορεί να τα δει ο scraper.

```
# 'Load more' button
button = driver.find_elements_by_xpath("//button")
for i in range(len(button)):
    text = button[i].text
    if text != "":
        if "Load more" in button[i].text:
            load_more = i
            break

press_button_number = 496//12
for i in range(press_button_number):
    driver.execute_script("arguments[0].click();", button[load_more])
    time.sleep(4)
```

*Απόσπασμα κώδικα για το κουμπί "Load more"*

Ένας τρόπος για να βρούμε το κουμπί 'Load more' είναι να πάρουμε όλα τα κουμπιά μέσω του tag name <button>, να βρούμε ποιο γράφει "Load more" και να αποθηκεύσουμε την θέση στην οποία βρίσκεται.

Αφού βρούμε το κουμπί πρέπει έπειτα να το πατήσουμε. Όμως πόσες φορές; Κάθε φορά που το πατάμε εμφανίζονται 12 νέα επαγγέλματα. Έτσι έχουμε δύο περιπτώσεις:

1. Total Results / 12 = ακέραιος αριθμός => Σε αυτή την περίπτωση, που τα συνολικά αποτελέσματα διαιρούνται ακριβώς με το 12, το κουμπί πρέπει να

πατηθεί όσο είναι και το αποτέλεσμα της διαίρεσης μείον μια φορά. Αυτό συμβαίνει γιατί τα πρώτα 12 επαγγέλματα έχουν φορτωθεί ήδη με το που ανοίξαμε την ιστοσελίδα.

2. Total Results / 12 = δεκαδικός αριθμός => Στην περίπτωση που τα συνολικά αποτελέσματα δεν διαιρούνται ακριβώς με το 12, το κουμπί πρέπει να πατηθεί όσο είναι το αποτέλεσμα της ακέραιας διαίρεσης με το 12. Για παράδειγμα  $496/12 = 41.33$ , άρα το κουμπί θα πατηθεί 41 φορές (12 που εμφανίστηκαν στην αρχή,  $40*12=480$ , συν 1 φορά για τις 4 τελευταίες εργασίες που έμειναν).

Έτσι λοιπόν για να φορτωθούν όλα τα αποτελέσματα, το κουμπί θα πατηθεί 41 φορές. Η εντολή `time.sleep(4)` βρίσκεται για να περιμένει ο scraper 4” να φορτώσουν τα αποτελέσματα πριν πατήσει ξανά το κουμπί.

Αφού φορτώθηκαν όλα τα αποτελέσματα, ο scraper μπορεί να προχωρήσει στην εξαγωγή των αποτελεσμάτων. Από κάθε περιγραφή πρέπει να πάρουμε τον τίτλο της καθώς και το link της ιστοσελίδας που οδηγεί. Με παρόμοιο τρόπο όπως και με το κουμπί, βρέθηκαν πρώτα οι «χώρου» στη σελίδα που αποθηκεύονται το link και ο τίτλος και έπειτα από μία επεξεργασία αποθηκεύτηκαν σε δύο λίστες. Τα αποτελέσματα του πρώτου scraper φαίνονται στην παρακάτω εικόνα.

```
JOB LIST
Event manager
Literary agent
SEO analyst
Presales consultant
Accountant
...

LINKS LIST
https://targetjobs.co.uk/careers-advice/hospitality-and-event-management/event-manager-job-description
https://targetjobs.co.uk/careers-advice/job-descriptions/literary-agent-job-description
https://targetjobs.co.uk/careers-advice/job-descriptions/seo-analyst-job-description
https://targetjobs.co.uk/careers-advice/job-descriptions/presales-consultant-job-description
https://targetjobs.co.uk/accountant-job-description
...
```

*Αποτελέσματα 1ου scraper*

### 4.3.2 Περιγραφές Επαγγελμάτων

Η λειτουργία του δεύτερου scraper είναι η εξαγωγή των περιγραφών των επαγγελμάτων. Στον προηγούμενο scraper συλλέχθηκαν όλα τα επαγγέλματα καθώς και οι σύνδεσμοι που οδηγούν στις περιγραφές τους. Ο δεύτερος scraper λοιπόν, θα χρησιμοποιήσει τους συνδέσμους που δίνει σαν αποτέλεσμα ο πρώτος, θα επισκέπτεται κάθε έναν και θα συλλέγει την αντίστοιχη περιγραφή.

## Event manager: job description

When everything's in full swing, this role can be exciting – but the behind-the-scenes planning and organisation is equally essential to events management.

[Save](#)



Freelancing is common for event managers, so you could work for a number of employers and choose to specialise in a few different kinds of events.

What does an event manager do? | [Typical employers](#) | [Qualifications and training](#) | [Key skills](#)

Event managers, also known as events managers, are responsible for planning, promoting and ensuring the smooth running of an event schedule and individual events. These could span anything from a wedding to a virtual conference.

There is often plenty of overlap between the work of an events team and a marketing team. Promoting an event and an employer brand is vital to make sure that people turn up and future business comes out of it. If this doesn't happen, all the employer sees is the cost to the company in terms of money and time, no matter how much effort you've put into pulling off the event of the year.

However, there's a more practical 'roll-your-sleeves-up' aspect to events that isn't as common in marketing. As you're working your way up to the role of manager, and sometimes when you're a manager, you will often be one of the first people to arrive at an event and one of the last people to leave. You'll talk to attendees, make sure they have everything they expect (eg food or drink) and might spend time putting up stands or sorting out seating.

Typical responsibilities of an event manager are:

- recruiting and managing employees working on events – these might work on a short-term basis during busy periods or be full-time members of staff
- carrying out administrative duties such as booking hotels for those working on events and producing spreadsheets (eg on the numbers of attendees expected)
- setting clear objectives and targets for events, alongside plans for how to meet these
- helping to promote events and liaising with clients
- gathering feedback and data after an event (eg on attendance or sign-ups to your employer's website) and using it to inform decisions/future plans
- coming up with new and innovative ideas – both for events and event promotion
- working within a budget for events and managing spending accordingly
- problem solving and hosting during an event.

### Typical employers

Although you might be more likely to associate this role with more glamorous events such as large conferences, in reality the events sector is pretty varied. You could be planning fine dining and classy entertainment at a fancy hotel. Alternatively, if you work for a charity, you might be making sure leaflets handed out and staff working at fundraising events are both persuasive and knowledgeable.

You might work for:

- an events venue
- an event management consultancy
- a charity
- a hotel, pub or restaurant
- a conference or exhibition centre
- a festival
- an educational institution.

Freelancing is common for event managers, so you could work for a number of employers and choose to specialise in a few different kinds of events. You could also be involved with a mixture of events by working for a company specialising in event management for various clients.

### Qualifications and training

A degree in events management can be a useful way of demonstrating to employers your enthusiasm for the industry and building up your knowledge and network when you start out, but it isn't essential. You could enter this career with a degree in any subject; in fact, if you work your way up (eg from an administrative role for an events company), you won't necessarily need a degree.

What you will need is experience. If you do study for an events management degree, you could start gaining this experience by choosing one with a placement year and planning events for a university society, for instance.

It is likely that you will need to have spent between four and six years working in events before becoming an event manager, as this should give you a solid foundation of industry-related skills and knowledge. There are many options when it comes to the roles you could undertake as you gain experience. Spending some time working as an event assistant manager before making the move to manager would provide you with a good insight, but it is not crucial.

### Key skills

Some employers will be particularly impressed by candidates with certain specific skills, often related to the promotion of events – such as photography or social media proficiency. As more and more events are hosted online, it's also becoming increasingly likely that IT literacy will be an important focus.

Typical skills required for this industry are:

- The ability to manage multiple events and people simultaneously
- Collaboration
- Organisation
- Time management
- Problem solving
- Creativity and creative thinking
- Resilience when under pressure
- IT literacy
- The ability to reflect and consider ways to improve.

### Spotlight organisations

- RPC**  
Follow
- Kraft Heinz Company**  
Follow
- DCC**  
Follow
- BAE Systems**  
Follow
- British Airways**  
Follow

[View all](#)

### Essential advice

[Filling a coronavirus-shaped gap on your CV APPLICATIONS](#)

[Green careers: find a graduate job that helps the environment CAREERS ADVICE AND PLANNING](#)

[The graduate's guide to creating the perfect LinkedIn profile CAREERS ADVICE AND PLANNING](#)

[Dos and don'ts for Zoom and video calls INTERVIEWS AND ASSESSMENT CENTRES](#)

[Upskilling and why it is so important: advice from our ICAE... SKILLS AND COMPETENCIES](#)

[Fun, prospects or money: what are you looking for? CAREERS ADVICE AND PLANNING](#)

[View all](#)

### Get inspired

**What are the top 10 skills that'll get you a job when you...**  
ADVICE  
Have you got the key skills graduate employers look for? You'll need to give examples of these essential competencies in your job...

**What can you bring to the company? Tricky graduate...**  
ADVICE  
This traditional question can be asked in an interview across any profession or industry. Good self-knowledge combined with good...

**How to write a graduate CV: your FAQs answered**  
ADVICE  
You wouldn't use Comic Sans... or would you? Find answers to common questions about CV writing and pick up tips to make...

[View all](#)

### Top opportunities

**Software Development Graduate – Technology**  
Aviva  
21 DAYS TO APPLY  
South West \*5 + £25,000–£30,000

**Graduate Technical Engineer**  
TPP  
21 DAYS TO APPLY  
Yorkshire and the Humber + £25,000–£40,000

**Systems Engineer Graduate Programme**  
BAE Systems  
21 DAYS TO APPLY  
South East

**Electrical/Electronic Engineering Graduate Programme**  
BAE Systems  
21 DAYS TO APPLY  
South East

[View all](#)

Παράδειγμα περιγραφής επαγγέλματος

Στην παραπάνω εικόνα παρουσιάζεται η περιγραφή του επαγγέλματος «Event Manager». Όπως και προηγουμένως που έπρεπε να συλλέξουμε τους τίτλους και τους συνδέσμους, έτσι κι εδώ η διαδικασία θα είναι η ίδια. Πρώτα, πρέπει να κάνουμε inspect την ιστοσελίδα και να αναζητήσουμε στον HTML κώδικά της το μέρος, δηλαδή τα tags ή αλλιώς ετικέτες, μέσα στις οποίες περιλαμβάνονται τα δεδομένα που θέλουμε να συλλέξει ο scraper. Σχεδόν πάντοτε, ανεξάρτητα από το επάγγελμα ή την περιγραφή, για όμοια πράγματα ακολουθείται το ίδιο format, π.χ. όλες οι περιγραφές θα βρίσκονται μέσα στις ίδιες ετικέτες. Έτσι λοιπόν, αρκεί να βρεθούν μία φορά οι ετικέτες που περιέχουν τις περιγραφές και θα χρησιμοποιήσουμε τις ίδιες για να εξαχθούν και οι υπόλοιπες περιγραφές των επαγγελμάτων. Μέσα σε κόκκινα πλαίσια φαίνονται και τα κομμάτια της ιστοσελίδας που θέλουμε να συλλέξουμε. Το αποτέλεσμα της εξαγωγής της περιγραφής του επαγγέλματος «Event Manager» είναι το εξής:


```
Event manager: job description When everything's in full swing, this role can be exciting - but the behind-the-scenes planning and organisation is equally essential to events management.
Freelancing is common for event managers, so you could work for a number of employers and choose to specialise in a few different kinds of events.
What does an event manager do?
| Typical employers | Qualifications and training | Key skills Event managers, also known as events managers, are responsible for planning, promoting and ensuring the smooth running of an event schedule and individual events.
These could span anything from a wedding to a virtual conference.
There is often plenty of overlap between the work of an events team and a marketing team.
Promoting an event and an employer brand is vital to make sure that people turn up and future business comes out of it.
If this doesn't happen, all the employer sees is the cost to the company in terms of money and time, no matter how much effort you've put into pulling off the event of the year.
However, there's a more practical 'roll-your-sleeves-up' aspect to events that isn't as common in marketing.
As you're working your way up to the role of manager, and sometimes when you're a manager, you will often be one of the first people to arrive at an event and one of the last people to leave.
...
```

Αποτελέσματα 2ου scraper

### 4.3.3 Κατηγορίες Επαγγελμάτων

Ο τρίτος scraper θα συλλέξει δεδομένα που αφορούν την κατηγοριοποίηση των επαγγελμάτων. Ο λόγος που θα χρειαστούν οι κατηγορίες των επαγγελμάτων καθώς και ποια επαγγέλματα ανήκουν στην κάθε μία είναι για τη χρήση της μετρικής TF-IDF η οποία θα εξηγηθεί αναλυτικά στην ενότητα 4.5.

Είπαμε πως ο scraper μπορεί να δει μόνο αυτά που βλέπουμε και εμείς όταν φορτώσει η σελίδα που συνδέθηκε ο scraper, επομένως πρέπει πρώτα να βρούμε που είναι οι κατηγορίες. Για την εύρεση των κατηγοριών χρειάστηκε να πατηθούν δύο κουμπιά.



Κουμπί 1

Filters	X
Sort by	+
Sector <span style="border: 1px solid red; border-radius: 50%; padding: 2px;">2</span>	+
Category	+

### Κουμπί 2

Filters
X

---

Sector
-

Q

<input type="checkbox"/> Environmental (62)	<input type="checkbox"/> Armed Forces (60)
<input type="checkbox"/> Charities & Voluntary Sector (60)	<input type="checkbox"/> Charity, Public & Civil Service (60)
<input type="checkbox"/> Civil Services (60)	<input type="checkbox"/> Emergency Services (60)
<input type="checkbox"/> Engineering (60)	<input type="checkbox"/> Law Enforcement (60)
<input type="checkbox"/> Public Service (60)	<input type="checkbox"/> Security & Intelligence (60)
<input type="checkbox"/> Social Care (60)	<input type="checkbox"/> Social, Community & Youth (60)
<input type="checkbox"/> Agriculture (56)	<input type="checkbox"/> Agriculture, Animals & Plants (56)
<input type="checkbox"/> Compliance & Regulation (56)	<input type="checkbox"/> Food (56)
<input type="checkbox"/> Product R&D (56)	<input type="checkbox"/> Science, R&D, Food industry (56)
<input type="checkbox"/> Social & Market Research (56)	<input type="checkbox"/> Veterinary (56)
<input type="checkbox"/> Business & Systems Analysis (48)	<input type="checkbox"/> Data Science (48)
<input type="checkbox"/> Information Services (48)	<input type="checkbox"/> Network Engineering (48)
<input type="checkbox"/> Software Engineering (48)	<input type="checkbox"/> Software Testing (48)
<input type="checkbox"/> Technical Consultancy (48)	<input type="checkbox"/> Technical Sales (48)
<input type="checkbox"/> Technical Support (48)	<input type="checkbox"/> Technology (48)
<input type="checkbox"/> Web development (48)	<input type="checkbox"/> Advertising (47)
<input type="checkbox"/> Digital (47)	<input type="checkbox"/> Marketing (47)
<input type="checkbox"/> Marketing, Advertising & PR (47)	<input type="checkbox"/> Public Relations & Communications (47)
<input type="checkbox"/> Dental (37)	<input type="checkbox"/> Healthcare (37)
<input type="checkbox"/> Medical, Healthcare & Dental (37)	<input type="checkbox"/> Pharmaceutical (37)
<input type="checkbox"/> Event management (34)	<input type="checkbox"/> Hospitality, Sport, Leisure & Tourism (34)
<input type="checkbox"/> Hotel Management (34)	<input type="checkbox"/> Leisure & Tourism (34)

Reset - 1
Apply

### Κατηγορίες των Επαγγελματιών

Μετά το πάτημα και του 2<sup>ου</sup> κουμπιού, εμφανίστηκαν όλα τα ονόματα των κατηγοριών και μέσα σε παρένθεση πόσα επαγγέλματα έχει η κάθε κατηγορία. Αυτά τα δεδομένα θα συλλεχθούν σε δύο διαφορετικές λίστες. Στη λίστα “sectors” θα αποθηκευτούν τα ονόματα των κατηγοριών, ενώ στη λίστα “results” θα αποθηκευτεί ο αριθμός των επαγγελματιών που περιέχει η κάθε κατηγορία.

Όμως, εκτός από τα ονόματα και τα αποτελέσματα των κατηγοριών θα χρειαστούμε και τα url links αυτών ώστε να συνδεθεί ο scraper σε κάθε ένα και να

συλλέξει τα ονόματα των επαγγελματιών που ανήκουν σε κάθε κατηγορία. Εξαιτίας της “checkbox” μορφής που βρίσκονται οι κατηγορίες, τα url links δεν είναι εμφανή ώστε να συλλεχθούν, οπότε πρέπει να κατασκευαστούν. Έπειτα από παρατήρηση των url links των κατηγοριών, βγήκε το συμπέρασμα πως οι σύνδεσμοι είναι της μορφής ‘https://targetjobs.co.uk/search/advice?search=&categories=Job+descriptions+and+industry+overviews&sectors=<όνομα\_κατηγορίας>’, δηλαδή διαφέρει μόνο το όνομα της κατηγορίας. Τα ονόματα που περιέχουν χαρακτήρες (όπως το κενό, κόμμα κλπ.) πρέπει να κωδικοποιηθούν στην κατάλληλη μορφή, π.χ. το όνομα ‘Charity, Public & Civil Service’ θα κωδικοποιηθεί σε ‘Charity%2C+Public+%26+Civil+Service’. Για την κωδικοποίηση των λέξεων χρησιμοποιήθηκε το πακέτο urllib το οποίο είναι ήδη προεγκατεστημένο με την python.

Εφόσον λοιπόν κατασκευάστηκαν και τα links, ο scraper μπορεί να συνδεθεί σε καθένα από αυτά και να αποθηκεύσει τα ονόματα των επαγγελματιών σε κάθε κατηγορία.

62 results

Advice & Learning Sort by Sector Category + All filters Reset

**Geneticist: job description**  
Genetics is a branch of biology that studies the inheritance of physical and behavioural characteristics of living things, and how these traits...

**Seismic interpreter: job description**  
Seismic interpreters use a variety of technical, computational and scientific modelling techniques to produce geophysical and geological data that can b...

**Site engineer: job description**  
Site engineers provide technical advice about, plan, organise and supervise construction projects.

**Product development scientist: job description**  
Product or process development scientists are responsible for researching and developing new production processes and making modifications to...

**Soil scientist: job description**  
Soil scientists analyse soil samples to provide information about its quality and structure for construction, agricultural, government, industrial and...

**Statistician: job description**  
Statisticians collect, analyse and interpret quantitative data.

**Structural engineer: job description**  
Structural engineers design, plan and oversee the construction of new buildings and bridges, or alterations and extensions to existing properties or...

**Toxicologist: job description**  
Toxicologists use analytical and scientific techniques to identify toxins such as chemicals, biological substances and radiation, and to assess the potenti...

**Transportation planner: job description**  
Transportation planners (also known as transport planners) assess public, private and commercial transportation needs and analyse and devise new...

**Veterinary nurse: job description**  
Veterinary nurses assist veterinary surgeons in the diagnosis, treatment and care of sick or injured domestic, farm and zoo animals.

**Veterinary surgeon: job description**  
Veterinary surgeons maintain the health and welfare of a wide range of animals, from personal pets to livestock, zoo specimens, or even injured wild animals.

**Regulatory affairs officer: job description**  
Regulatory affairs officers act as a link between companies and regulatory authorities, ensuring that products are manufactured and distributed in...

Load more

Κατηγορία Επαγγελματιών Environmental

Η λίστα “results” χρησιμοποιήθηκε για τον υπολογισμό των φορών που θα πατηθεί το κουμπί “Load more” σε κάθε κατηγορία σύμφωνα με τις δύο περιπτώσεις που εξηγήθηκαν στον πρώτο scraper.

Τα αποτελέσματα του τελευταίου scraper είναι τα εξής :

```
Sectors :
Environmental
Armed Forces
Charities & Voluntary Sector
Charity, Public & Civil Service
Civil Services
...

Jobs per sector (first 5):
['Geneticist', 'Seismic interpreter', 'Site engineer', 'Product development scientist', 'Soil scientist']
['Academic librarian', 'Government research officer', 'Tax inspector', 'Waste management officer', 'Water conservation officer']
['Academic librarian', 'Government research officer', 'Tax inspector', 'Waste management officer', 'Water conservation officer']
...
```

*Αποτελέσματα 3ου scraper*

Για τους λόγους ότι η διαδικασία του Web Scraping δεν χρειάζεται να γίνεται κάθε φορά που θα τρέχει η εφαρμογή και επειδή οι συγκεκριμένοι scrapers δημιουργήθηκαν για την μορφή της ιστοσελίδας αυτή την στιγμή (ενδεχομένως με κάποιο update της ιστοσελίδας, η εμφάνισή της καθώς και ο κώδικάς της θα τροποποιηθούν και οι scrapers δεν θα δουλεύουν), τα αποτελέσματα του κάθε scraper αποθηκεύτηκαν σε ξεχωριστά αρχεία με τη βοήθεια του πακέτου pickle. Επομένως, η πρόσβαση σε αυτές τις μεταβλητές γίνεται μέσω αυτών των αρχείων.

#### 4.4 Question’s Database

Οι ερωτήσεις που θα χρησιμοποιηθούν για το quiz, τροφοδοτούνται στο σύστημα μέσω ενός ‘.txt’ αρχείου. Ο διαχειριστής μπορεί να τροποποιήσει, να προσθέσει και να αφαιρέσει ανά πάσα στιγμή οποιαδήποτε ερώτηση επιθυμεί μέσα από το αρχείο κειμένου. Όμως, για την ανάγκη της σωστής σάρωσης των δεδομένων/ερωτήσεων ακολουθείται ένα συγκεκριμένο format, το οποίο είναι αυτό που φαίνεται παρακάτω. Το quiz χωρίζεται σε τρεις κατηγορίες: στις ερωτήσεις writing, όπου ο χρήστης δίνει απαντήσεις κειμένου, στις multiple choice ερωτήσεις όπου ο χρήστης επιλέγει σε μία κλίμακα 1-5 ανάλογα με το πόσο του αρέσει το αντικείμενο που περιγράφει η ερώτηση, και στις ερωτήσεις true/false όπου επιλέγει αν



η ερώτηση είναι ψευδής ή αληθής σύμφωνα με το αν τον χαρακτηρίζει η ερώτηση ή όχι.

WRITING

(example answers : My name is Thanos,I am 22 years old, and I am studying Computer Science.)

What is your gender?

How old are you?

Where are you from?

Do you have any hobby?

Can you tell me a few things about yourself?

END\_WRITING

### *Writing questions*

MULTIPLE\_CHOICE

(example answers : 1.Hate it, 2.Dislike it, 3.Neutral, 4.Like it, 5.Love it)

Would you like to advise organizations on how to meet their business goals?

Would you like to analyze data using statistics?

Would you like to counsel people with drug or alcohol addiction?

Would you like to create art for sale and exhibition?

Would you like to direct the making of a movie?

Would you like to examine artifacts left behind by previous civilizations?

Would you like to help elderly people complete their daily activities?

Would you like to help someone with a disability get dressed?

Would you like to install drywall in houses?

Would you like to interpret results of medical tests?

Would you like to investigate causes of climate change?

Would you like to keep records of payments received?

Would you like to oversee the hiring of new employees?

Would you like to perform scientific analyses on evidence from a crime scene?

Would you like to process transactions at a bank?

Would you like to repair damaged farm equipment?

Would you like to research how genes function?

Would you like to sell a house?

Would you like to study sea creatures?

Would you like to take part in a musical performance?

Would you like to teach kids how to play well with other children?

Would you like to write a play for a theater?

Would you like to write lyrics for songs?

Would you like to write medical reports?

Would you like to do activities that contribute to a more sustainable world?

Would you enjoy athletics?

Would you enjoy beauty and style?

Would you enjoy activities involving the visual arts or music?

Would you enjoy culinary arts?

Would you enjoy developing and using technology to produce and maintain things?

Would you enjoy flying airplanes and working around them?

Would you enjoy programming and providing support for software or hardware of computing devices?

Would you enjoy debating legal matters?

Would you enjoy working with quantitative concepts and mathematical formulas?

Would you enjoy working in national armed forces?

Would you enjoy teaching, composing, or performing music?

Would you enjoy protective services?

Would you enjoy selling and marketing products?

Would you enjoy research and consulting activities relevant to human behavior and social organizations?

Would you enjoy teaching?

Would you enjoy working with animals?

END\_MULTIPLE\_CHOICE

### *Multiple choice questions*

```
TRUE/FALSE
(example answers : 1.Yes, this is true, 2.No, this is not true)
I am always prepared.
I am exacting in my work.
I am a fast learner.
I am very shy in social situations.
I am the life of the party.
I don't talk a lot.
I feel comfortable around people.
I keep in the background.
I start conversations.
I have little to say.
I talk to a lot of different people at parties.
I don't like to draw attention to myself.
I don't mind being the center of attention.
I am quiet around strangers.
I get stressed out easily.
I am relaxed most of the time.
I worry about things.
I seldom feel blue.
I am easily disturbed.
I get upset easily.
I change my mood a lot.
I like driving a car or truck many hours a day.
I get irritated easily.
I often feel blue.
I feel little concern for others.
I am interested in people.
I insult people.
I sympathize with others feelings.
I am not interested in other people's problems.
I have a soft heart.
I am not really interested in others.
I take time out for others.
I feel others emotions.
I make people feel at ease.
I am always prepared.
I leave my belongings around.
I pay attention to details.
I make a mess of things.
I get chores done right away.
I often forget to put things back in their proper place.
I like order.
I shirk my duties.
I follow a schedule.
I am exacting in my work.
I like organizing or leading others.
I have difficulty understanding abstract ideas.
I like to study the history of ancient civilizations.
I am not interested in abstract ideas.
I have excellent ideas.
I do not have a good imagination.
I am quick to understand things.
I use difficult words.
I spend time reflecting on things.
I am full of ideas.
END_TRUE/FALSE
```

#### *True/False questions*

Όπως μπορούμε να παρατηρήσουμε και στις τρεις κατηγορίες ερωτήσεων ακολουθείται το εξής format:

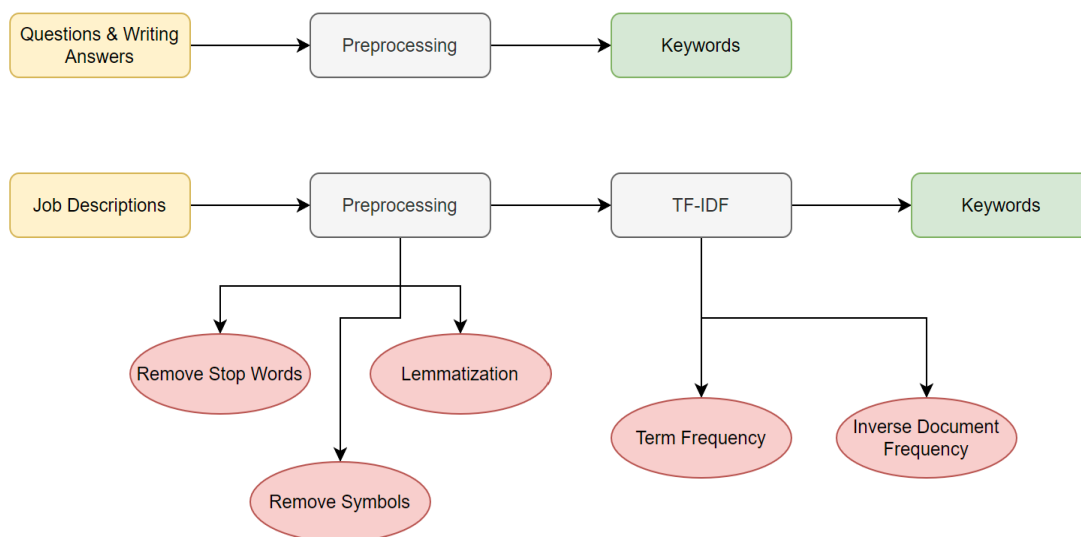
- Κατηγορία
- Παραδείγματα απαντήσεων

- Ερωτήσεις
- Τέλος κατηγορίας

Τα “tags” ‘WRITING-END\_WRITING’, ‘MULTIPLE\_CHOICE-END\_MULTIPLE\_CHOICE’, ‘TRUE/FALSE-END\_TRUE/FALSE’ δεν πρέπει να τροποποιηθούν από τον διαχειριστή καθώς είναι λέξεις κλειδιά που εντοπίζει το πρόγραμμα ώστε να συλλέξει τις ερωτήσεις σύμφωνα με την κατηγορία στην οποία ανήκουν. Η γραμμή ‘example answers’ δεν λαμβάνεται υπόψιν στη σάρωση του αρχείου. Ο συνολικός αρχικός αριθμός των ερωτήσεων και στις τρεις κατηγορίες είναι 100, και είναι αυτές που φαίνονται στις παραπάνω εικόνες.

## 4.5 Information Retrieval

Το σημαντικότερο κομμάτι της υλοποίησης του συστήματος, είναι αυτό της ανάκτησης πληροφοριών. Η ανάκτηση πληροφοριών ασχολείται με την οργάνωση, την αποθήκευση, την ανάκτηση και αξιολόγηση των δεδομένων. Συγκεκριμένα, στο chatbot Vogui, η ανάκτηση πληροφοριών θα χρησιμοποιηθεί για την εξαγωγή των σημαντικότερων πληροφοριών από τις περιγραφές των επαγγελμάτων, από τις ερωτήσεις, καθώς και από τις απαντήσεις που έδωσε ο χρήστης (στην πρώτη κατηγορία ερωτήσεων).



*IR Procedure*

### 4.5.1 Natural Language Processing

Όπως μπορούμε να διακρίνουμε στη παραπάνω φωτογραφία, στα δεδομένα απαιτείται να ακολουθηθεί μία προεπεξεργασία. Η προεπεξεργασία αυτή ονομάζεται ‘Επεξεργασία Φυσικής Γλώσσας’ ή αλλιώς NLP (Natural Language Processing). Η επεξεργασία φυσικής γλώσσας, αναφέρεται στον κλάδο της επιστήμης των υπολογιστών και πιο συγκεκριμένα στον κλάδο της τεχνητής νοημοσύνης και στοχεύει στο να δώσει την ικανότητα στους υπολογιστές να κατανοούν κείμενα (ή προφορικές λέξεις) με τον ίδιο τρόπο που μπορούν και οι άνθρωποι. Για την υλοποίηση, χρησιμοποιήθηκε το Natural Language Toolkit (NLTK), ένα πακέτο το οποίο περιέχει μία πληθώρα βιβλιοθηκών και προγραμμάτων για NLP. Τα βήματα επεξεργασίας που ακολουθήθηκαν για τις ανάγκες του συστήματος είναι τα εξής:

1. Αφαίρεση τερματικών όρων (stopwords)
2. Αφαίρεση συμβόλων (symbols)
3. Λημματοποίηση (lemmatization)

Λόγω ‘case sensitivity’, δηλαδή τα κεφαλαία γράμματα διαφέρουν από τα μικρά, πριν η περιγραφή περάσει από τα τρία βήματα επεξεργασίας μετατρέπουμε την περιγραφή σε lowercase.

#### 4.5.1.1 Stopwords

Οι τερματικές λέξεις (stopwords) είναι λέξεις οι οποίες δεν είναι ιδιαίτερα σημαντικές σε μία πρόταση. Είναι λέξεις που μπορούν να αφαιρεθούν από μία πρόταση δίχως να χάσουμε πληροφορίες για το νόημά της, όπως για παράδειγμα οι λέξεις “is, am, or, who, was, here, it, how” κλπ., δεν δίνουν κάποια σημαντική πληροφορία για την πρόταση ή για το κείμενο. Για την αφαίρεση αυτών των λέξεων χρησιμοποιήθηκε μία έτοιμη λίστα stopwords που προσφέρει το πακέτο NLTK. Στη λίστα προστέθηκαν και οι λέξεις “would, what, like, can”, οι οποίες εμφανίζονται αρκετές φορές στις ερωτήσεις του quiz. Έτσι λοιπόν, η παρακάτω συνάρτηση δημιουργεί μία νέα λίστα μόνο με τις λέξεις της περιγραφής που δεν ανήκουν στη λίστα stopwords.

```

def remove_stop_words(desc):
    stop_words = stopwords.words('english')
    my_stop_words = ["would", "what", "like", "can"]
    stop_words.extend(my_stop_words)
    word_tokens = word_tokenize(desc)

    no_stop_words_desc = []
    for w in word_tokens:
        if w not in stop_words:
            no_stop_words_desc.append(w)

    return no_stop_words_desc

```

*Κώδικας για την αφαίρεση των stopwords*

#### 4.5.1.2 Symbols

Για τον ίδιο ακριβώς λόγο με τις τερματικές λέξεις πρέπει να αφαιρέσουμε και τα σύμβολα που υπάρχουν σε μία περιγραφή. Επομένως, δημιουργήθηκε μία λίστα με τα σύμβολα που πρέπει να αφαιρεθούν και με παρόμοιο τρόπο κρατάμε την περιγραφή του επαγγέλματος χωρίς τα σύμβολα.

```

def remove_symbols(desc):
    symbols = "!\"#$%&()*+,--./:;<=>?@[\\]^_`{|}~\n'"
    no_symbols_desc = []
    for w in desc:
        if w not in symbols:
            no_symbols_desc.append(w)

    return no_symbols_desc

```

*Κώδικας για την αφαίρεση των symbols*

#### 4.5.1.3 Lemmatization

Το lemmatization, είναι μία τεχνική κανονικοποίησης κειμένου που ανήκει στον τομέα της επεξεργασίας φυσικής γλώσσας. Είναι η αλγοριθμική διαδικασία εύρεσης της ρίζας μιας λέξης. Ο λόγος που χρειάζεται να μετατρέψουμε τις λέξεις στις αρχικές τους ρίζες είναι ότι το chatbot δεν μπορεί να κατανοήσει την σημασία των λέξεων. Για παράδειγμα τις λέξεις 'playing, plays, played' παρόλο που έχουν την ίδια σημασία, το chatbot τις θεωρεί διαφορετικές μεταξύ τους. Επομένως μετά το lemmatization και οι τρεις λέξεις θα μετατραπούν στην αρχική τους ρίζα που είναι η λέξη 'play' και έτσι το chatbot θα μπορέσει να καταλάβει ότι και οι τρεις λέξεις έχουν κοινό νόημα.

```

def lemmatization(desc):
    lemmatizer = WordNetLemmatizer()

    lemma_desc = []
    for word in desc:
        lemma_desc.append(lemmatizer.lemmatize(word, pos="v"))

    return lemma_desc

```

*Κώδικας για την εφαρμογή του Lemmatization*

Για τις ερωτήσεις καθώς και για τις απαντήσεις του χρήστη (στην πρώτη κατηγορία ερωτήσεων), το μόνο που χρειάζεται να γίνει για την εξαγωγή των λέξεων κλειδιών ήταν η διαδικασία του NLP. Οι απαντήσεις που θα δώσει ο χρήστης στις writing ερωτήσεις θα γίνουν ένα ενιαίο κείμενο το οποίο θα περάσει από τα τρία βήματα που εξηγήθηκαν. Έπειτα από την ολοκλήρωση του lemmatization, ό,τι λέξεις έχουν απομείνει από ερωτήσεις αλλά και από το κείμενο που δημιουργήθηκε από τις απαντήσεις του χρήστη, θα είναι και οι λέξεις κλειδιά που θα δοθούν στο σύστημα για επεξεργασία.

#### **4.5.2 Term Frequency – Inverse Document Frequency (TF-IDF)**

Το TF-IDF είναι μία τεχνική με την οποία μπορούμε να ξεχωρίσουμε τις σημαντικότερες λέξεις σε ένα κείμενο. Ο αλγόριθμος υπολογίζει ένα σκορ για κάθε λέξη το οποίο αντιπροσωπεύει το πόσο σημαντική είναι με βάση το νόημα του κειμένου. Με αυτό τον τρόπο, το σύστημα θα είναι σε θέση να καταλάβει καλύτερα το νόημα των περιγραφών με αποτέλεσμα να έχουμε καλύτερα αποτελέσματα. Για τον υπολογισμό της μετρικής ισχύει ο ακόλουθος μαθηματικός τύπος.

$$\text{TF-IDF} = \text{Term Frequency (TF)} * \text{Inverse Document Frequency (IDF)}$$

##### **4.5.2.1 Term Frequency**

Η συχνότητα του όρου μετράει πόσες φορές βρίσκεται η κάθε λέξη στην περιγραφή. Όμως η συχνότητα της λέξης εξαρτάται και από το σύνολο όλων των λέξεων. Μια λέξη που υπάρχει 10 φορές σε ένα κείμενο 100 λέξεων δεν είναι το ίδιο από το να υπάρχει τις ίδιες φορές σε ένα κείμενο 1000 λέξεων. Γι' αυτό τον λόγο, τη συχνότητα μιας λέξης την διαιρούμε με το λεξιλόγιο (vocabulary) της περιγραφής. Το

λεξιλόγιο είναι το σύνολο των λέξεων (μία φορά την κάθε μία) που υπάρχουν στην περιγραφή. Ακόμα ένας λόγος που αφαιρέσαμε προηγουμένως τις τερματικές λέξεις, είναι ότι λέξεις όπως “is, are, and” θα υπάρχουν πολλές φορές μέσα σε ένα κείμενο οπότε θα έχουν υψηλή συχνότητα και δεν θα μας δώσουν καμία απολύτως πληροφορία για το νόημα του κειμένου. Έτσι λοιπόν για τον υπολογισμό του TF θα χρειαστεί να μετρήσουμε τη συχνότητα κάθε λέξης του λεξιλογίου καθώς και το μήκος του λεξιλογίου σύμφωνα με τον επόμενο μαθηματικό τύπο.

$$TF = \text{συχνότητα λέξης} / \text{μήκος λεξιλογίου}$$

```
def words_frequency(desc):
    words_freq = {}
    for word in desc:
        if word in words_freq:
            words_freq[word] += 1
        else:
            words_freq[word] = 1

    vocab_length = len(words_freq)

    return words_freq, vocab_length
```

*Υπολογισμός της συχνότητας των λέξεων και του μήκους του λεξιλογίου*

Για τον υπολογισμό της συχνότητας των λέξεων φτιάχνουμε ένα dictionary· αν η λέξη υπάρχει ήδη στο dictionary τότε αυξάνουμε την τιμή της κατά 1 αλλιώς την αρχικοποιούμε με τιμή 1. Αφού μετρήσουμε πόσες φορές υπάρχει η κάθε λέξη στο κείμενο, τότε μπορούμε εύκολα να υπολογίσουμε το μήκος του λεξιλογίου αφού θα είναι ίσο με το μήκος του dictionary δηλαδή όσα είναι τα κλειδιά του.

```
def term_frequency(words_freq, vocab_length):
    term_freq = {}
    for word, freq in words_freq.items():
        t_f = freq / vocab_length
        term_freq[word] = t_f

    return term_freq
```

*Term Frequency*

Έπειτα μπορούμε να υπολογίσουμε το TF διαπερνώντας το dictionary και διαιρώντας την κάθε τιμή των λέξεων με το μήκος του λεξιλογίου.

#### 4.5.2.2 Inverse Document Frequency

Την τεχνική IDF θα την χρησιμοποιήσουμε για να μπορέσουμε να βρούμε με μεγαλύτερη ακρίβεια τη σημαντικότητα των λέξεων. Το Document Frequency, δηλαδή η συχνότητα εγγράφου, μετράει την συχνότητα κάθε λέξης σε ένα σύνολο κειμένων/περιγραφών που ανήκουν στην ίδια κατηγορία. Στη συχνότητα εγγράφου δεν μας απασχολεί πόσες είναι οι συνολικές λέξεις αλλά ούτε πόσες φορές υπάρχει η λέξη στην περιγραφή. Μας ενδιαφέρει μόνο ο αριθμός των περιγραφών που ανήκουν στην ίδια κατηγορία στις οποίες υπάρχει η λέξη. Το Inverse Document Frequency, δηλαδή η αντίστροφη συχνότητα εγγράφου, είναι το αντίστροφο από το DF, δηλαδή ο λόγος  $N/DF$  (όπου  $N$  ο αριθμός των περιγραφών της κατηγορίας) και μετράει την πληροφορία που μας δίνει η λέξη. Επειδή αν έχουμε πάρα πολλές περιγραφές η τιμή του IDF θα είναι αρκετά μεγάλη, θα χρησιμοποιήσουμε τον παρακάτω μαθηματικό τύπο. Αν η λέξη δεν υπάρχει σε κάποια περιγραφή τότε η τιμή του DF θα γίνει 0 και δεν θα μπορέσουμε να διαιρέσουμε γι' αυτό προσθέτουμε 1.

$$IDF = \log(N / (DF+1))$$

Ο τρίτος scraper έχει συλλέξει τις κατηγορίες, και τα επαγγέλματα που ανήκουν σε κάθε κατηγορία. Όμως, πολλά από τα επαγγέλματα ανήκουν σε παραπάνω από μία κατηγορία, επομένως τίθεται το εξής ερώτημα: για κάθε επάγγελμα, ποια κατηγορία πρέπει να πάρουμε; Η τεχνική που ακολουθήθηκε είναι από κάθε κατηγορία στην οποία ανήκει το επάγγελμα, να πάρουμε τις κοινές εργασίες δηλαδή την τομή των κατηγοριών. Το σκεπτικό αυτής της τεχνικής είναι ότι εφόσον οι εργασίες αυτές βρίσκονται σε όλες τις κατηγορίες, τότε θα μοιάζουν περισσότερο μεταξύ τους και θα μπορέσουμε να κατανοήσουμε καλύτερα τη σημαντικότητα των λέξεων στο κείμενο. Στην εικόνα που ακολουθεί φαίνεται ένα παράδειγμα επιλογής επαγγελμάτων. Το επάγγελμα στο οποίο υπάρχει η λέξη που εξετάζουμε ανήκει στις κατηγορίες A, Δ, E και Z αλλά τα επαγγέλματα που θα επιλεγθούν θα είναι αυτά με τίτλους 1, 4 και 7 καθώς είναι τα μοναδικά που ανήκουν και στις τέσσερις κατηγορίες. Επομένως οι λέξεις της περιγραφής του επαγγέλματος με τίτλο 1, θα εξεταστούν αν υπάρχουν στις περιγραφές των επαγγελμάτων 1, 4 και 7.



Επάγγελμα : Τίτλος 1 ← Επάγγελμα στο οποίο ανήκει η λέξη που εξετάζουμε

Κατηγορίες :

A :	Τίτλος 1, Τίτλος 3, Τίτλος 4, Τίτλος 6, Τίτλος 7	Επαγγέλματα κάθε κατηγορίας
Δ :	Τίτλος 1, Τίτλος 2, Τίτλος 4, Τίτλος 7, Τίτλος 8, Τίτλος 9, Τίτλος 10	
Ε :	Τίτλος 1, Τίτλος 4, Τίτλος 6, Τίτλος 7, Τίτλος 11	
Ζ :	Τίτλος 1, Τίτλος 4, Τίτλος 5, Τίτλος 6, Τίτλος 7	

↑  
Κατηγορίες στις οποίες ανήκει το επάγγελμα με τίτλο 1

#### Παράδειγμα επιλογής επαγγελμάτων για αναζήτηση

Τον υπολογισμό του IDF μπορούμε να τον κάνουμε μόνο στην περίπτωση όπου το επάγγελμα ανήκει σε κάποια κατηγορία αλλιώς η τελική βαρύτητα των λέξεων θα είναι μόνο ο υπολογισμός του TF. Γενικά υπάρχουν οι παρακάτω περιπτώσεις :

- Αν το επάγγελμα δεν εντάσσεται σε κάποια κατηγορία => TF
- Αν το επάγγελμα εντάσσεται μόνο σε μία κατηγορία => TF\_IDF (με όλα τα επαγγέλματα της κατηγορίας)
- Αν το επάγγελμα εντάσσεται σε 2 ή περισσότερες κατηγορίες => TF\_IDF (με υπολογισμό τομής, αν η τομή είναι ίση με 1 δηλαδή το μόνο κοινό επάγγελμα είναι το ίδιο το επάγγελμα τότε ο υπολογισμός του IDF θα γίνει με τα επαγγέλματα της πρώτης κατηγορίας που βρέθηκε)

Οι περιπτώσεις αυτές ελέγχονται στην συνάρτηση `find_sector(i)`, όπου η παράμετρος `i` είναι ο δείκτης του επαγγέλματος στο οποίο γίνεται η διαδικασία. Έπειτα αν γίνεται να υπολογιστεί το IDF εκτελείται ο κώδικας της συνάρτησης `inverse_doc_frequency(desc, i, descriptions)`, όπου `desc` η περιγραφή του επαγγέλματος, `i` ο δείκτης του και `descriptions` όλες οι περιγραφές.

```

def find_sector(i):
    # Find out in which sector the job belongs
    similar_jobs = []
    for s in range(len(jobs_per_sector)):
        if jobs_list[i] in jobs_per_sector[s]:
            similar_jobs.append(s)

    # Find common jobs
    if len(similar_jobs) == 0:
        return 0
    elif len(similar_jobs) == 1:
        return jobs_per_sector[similar_jobs[0]]
    elif len(similar_jobs) >= 2:
        for s in range(len(similar_jobs)-1):
            intersection_set = set.intersection(set(jobs_per_sector[similar_jobs[s]]), set(jobs_per_sector[similar_jobs[s+1]]))
            intersection_list = list(intersection_set)
            if len(intersection_list) == 1:
                return jobs_per_sector[similar_jobs[0]]
            else:
                return intersection_list

```

### Εύρεση κατηγορίας αναζήτησης

```

def inverse_doc_frequency(desc, i, descriptions):
    sector = find_sector(i)
    if sector:
        N = len(sector)
        df = {}

        for word in desc:
            for job in sector:
                if word in descriptions[jobs_list.index(job)]:
                    if word in df:
                        df[word] += 1
                    else:
                        df[word] = 1
                if word not in df:
                    df[word] = 0

        idf = {}
        for key, val in df.items():
            idf[key] = log((val+1)/N)

        return idf
    else:
        return None

```

### Υπολογισμός IDF

Μετά τον υπολογισμό των τιμών για κάθε λέξη της περιγραφής, κρατάμε το 30% των λέξεων με το μεγαλύτερο σκορ σαν λέξεις κλειδιά, καθώς οι κατώτερες λέξεις θα έχουν ελάχιστο σκορ και δεν θα επηρεάσουν σχεδόν καθόλου την διαδικασία που ακολουθεί.

## 4.6 Jobs – Questions Similarity

Το επόμενο βήμα είναι να υπολογίσουμε την ομοιότητα των λέξεων κλειδιών των ερωτήσεων με αυτών των περιγραφών. Ο λόγος που το κάνουμε αυτό, είναι για να αντιστοιχίσουμε κάθε ερώτηση με ένα επάγγελμα, δηλαδή να βρούμε που απευθύνεται η κάθε ερώτηση. Έτσι, όταν ο χρήστης θα απαντάει σε μία ερώτηση θα μπορούμε να ξέρουμε ποιο επάγγελμα του αρέσει πολύ, λίγο ή καθόλου.

Στη παρακάτω συνάρτηση λοιπόν διαπερνάμε τις ερωτήσεις και τις περιγραφές και ελέγχουμε πόσες λέξεις από κάθε ερώτηση υπάρχουν σε κάθε περιγραφή. Ο πίνακας score αρχικοποιείται με μηδενικά όσες είναι και οι λέξεις της ερώτησης στην οποία βρισκόμαστε· αν βρεθεί μία λέξη τότε στη θέση του πίνακα που αντιστοιχεί η λέξη αλλάζουμε την τιμή της με τη βαρύτητα που έχει η λέξη στην περιγραφή. Έτσι, όχι μόνο ξέρουμε ότι βρέθηκε κάποια κοινή λέξη αλλά ξέρουμε και το πόσο σημαντική ήταν αυτή η λέξη που βρέθηκε. Αφού ελέγξουμε όλες τις λέξεις της ερώτησης με μια περιγραφή, προσθέτουμε όλες τις τιμές του πίνακα score ώστε να βγάλουμε ένα τελικό συνολικό σκορ ομοιότητας. Το τελικό σκορ θα αποθηκευτεί στον πίνακα scores και θα συνεχίσουμε με την επόμενη περιγραφή. Μετά τον έλεγχο μιας ερώτησης με όλες τις περιγραφές και εφόσον έχουμε υπολογίσει όλα τα σκορ ομοιότητας, επιλέγουμε το μεγαλύτερο σκορ, που θα είναι και η περιγραφή στην οποία απευθύνεται και αντιστοιχεί η ερώτηση. Επαναλαμβάνουμε την παραπάνω διαδικασία για όλες τις ερωτήσεις. Για το πρώτο επίπεδο του quiz λαμβάνουμε υπόψιν μας το ενιαίο κείμενο με τις απαντήσεις του χρήστη και όχι τις ερωτήσεις.

```
# FIND THE DESCRIPTION-QUESTION SIMILARITY
def find_similarity(desc_keywords, quest_keywords):
    questions_and_jobs = []
    for q in range(len(quest_keywords)):
        scores = []
        for desc in desc_keywords:
            score = [0 for _ in range(len(quest_keywords[q]))]
            for i in range(len(quest_keywords[q])):
                for word, w in desc.items():
                    if word == quest_keywords[q][i]:
                        score[i] += w

            scores.append(sum(score))

        maximum_score = max(scores)
        job_index = scores.index(maximum_score)
        questions_and_jobs.append([q, job_index, maximum_score])

    return questions_and_jobs
```

*Εύρεση ομοιότητας ερώτησης-επαγγέλματος*

## 4.7 Weight Adjustment and Heuristic Method

Αφού ολοκληρωθούν οι διαδικασίες που αναφέρθηκαν προηγουμένως και ο χρήστης απαντήσει σε όλες τις ερωτήσεις, τότε μπορούμε να περάσουμε στην τελική διαδικασία που είναι η αναπροσαρμογή των βαρών σύμφωνα με τις απαντήσεις που δόθηκαν. Στο πρώτο επίπεδο του quiz (writing), ο χρήστης έδωσε κάποιες γενικές πληροφορίες για την προσωπικότητα και τα ενδιαφέροντά του, στο δεύτερο επίπεδο (multiple choice) επέλεξε από μία κλίμακα 1-5 πόσο του αρέσει το αντικείμενο που περιγράφει η ερώτηση, ενώ στο τρίτο επίπεδο (true/false) απάντησε με το αν ισχύουν ορισμένα πράγματα που στόχευαν περισσότερο στον χαρακτήρα του και στις ικανότητές του. Επομένως έχουμε ότι πληροφορίες χρειαζόμαστε για να υπολογίσουμε τα τελικά αποτελέσματα.

Η συνάρτηση που καλείται για να ξεκινήσει η διαδικασία υπολογισμού των αποτελεσμάτων είναι η `calculate_results`. Οι παράμετροι της συνάρτησης είναι οι εξής:

1. `answers` = μία λίστα με τις απαντήσεις που έδωσε ο χρήστης
2. `questions_and_jobs` = η λίστα που δημιουργήθηκε στην ενότητα 4.6 και περιέχει τις αντιστοιχίσεις ερωτήσεων-επαγγελμάτων
3. `ans_factor` = τα βάρη/τιμές που θα αλλάξουν τα σκορ ομοιότητας σύμφωνα με την απάντηση που έδωσε ο χρήστης. Προτεινόμενα βάρη:

### Level 2

- 1) Hate it = 0.5
- 2) Dislike it = 0.6
- 3) Neutral = 1
- 4) Like it = 1.1
- 5) Love it = 1.25

### Level 3

- 1) True = 1.25
- 2) False = 0.5

4. `same_job_factor` = πόσο θα αλλάξει το σκορ ομοιότητας σύμφωνα με την ευρετική τεχνική που χρησιμοποιήθηκε (προτεινόμενη τιμή = 0.1)
5. `jobs_number` = ο αριθμός των πιο ταιριαστών επαγγελμάτων που θα προταθούν στον χρήστη

Η συνάρτηση `calculate_results` θα καλέσει τη συνάρτηση `final_weights`, η οποία θα υπολογίσει τα τελικά βάρη και τη συνάρτηση `return_jobs` η οποία θα επιστρέψει τα top n επαγγέλματα.

```

def calculate_results(answers, questions_and_jobs, ans_factor, same_job_factor, jobs_number):
    # CALCULATE WEIGHTS
    questions_and_jobs = final_weights(answers, questions_and_jobs, ans_factor, same_job_factor)

    # RETURN MOST MATCHING JOBS
    final_jobs = return_jobs(jobs_number, questions_and_jobs)

    return final_jobs

```

*Η συνάρτηση calculate\_results*

Η συνάρτηση final\_weights είναι και η συνάρτηση στην οποία γίνεται η αναπροσαρμογή των scores. Όμως πρώτα θα εξηγήσουμε την ευρετική τεχνική που ακολουθήθηκε στη παρούσα υλοποίηση.

Όταν υπολογίσαμε την ομοιότητα ερωτήσεων-επαγγελμάτων (βλ. ενότητα 4.6) και βρήκαμε σε ποιο επάγγελμα αντιστοιχεί η κάθε ερώτηση, είναι αρκετά πιθανό να βρεθούν δύο ή περισσότερες ερωτήσεις οι οποίες να αντιστοιχούν στην ίδια περιγραφή επαγγέλματος. Οι ερωτήσεις του 2<sup>ου</sup> επιπέδου είναι και αυτές που είναι οι πιο αξιόπιστες στην αντιστοίχιση που κάναμε καθώς αναφέρονται περισσότερο σε επαγγέλματα παρά στην προσωπικότητα. Αν ο χρήστης λοιπόν, απαντήσει θετικά σε κάποια ερώτηση του 2<sup>ου</sup> επιπέδου, ή με άλλα λόγια αν η απάντησή του είναι 3, 4 ή 5 τότε θα έχουμε μία «εικόνα» για το επάγγελμα που του αρέσει. Αν όμως απαντήσει θετικά και σε κάποια άλλη ερώτηση η οποία αντιστοιχεί και αυτή στο ίδιο επάγγελμα, τότε η αξιοπιστία και η βαρύτητα αυτού του επαγγέλματος είναι ισχυρότερη από κάποιο άλλο επάγγελμα που βρέθηκε στις θετικές του επιλογές λιγότερες φορές. Γι' αυτό λοιπόν δημιουργήθηκε η συνάρτηση count\_same\_jobs η οποία μετράει πόσες φορές επιλέχθηκε θετικά το κάθε επάγγελμα από τον χρήστη. Έτσι οδηγούμαστε στους παρακάτω μαθηματικούς τύπους:

Επίπεδο 2:

Απάντηση 1 ή 2:

$$\text{score} = \text{answer\_factor} * \text{max\_score}$$

Απάντηση 3,4 ή 5:

$$\text{score} = \text{answer\_factor} * \text{max\_score} + \text{same\_jobs} * \text{same\_job\_factor}$$

Επίπεδο 3:

Απάντηση 1:

$$\text{score} = \text{answer\_factor} * \text{max\_score} + \text{same\_jobs} * \text{same\_job\_factor}$$

Απάντηση 2:

$$\text{score} = \text{answer\_factor} * \text{max\_score}$$

Για το πρώτο επίπεδο δεν χρειάζεται να γίνει κάποια επιπλέον αλλαγή στο σκορ. Εφόσον όλες οι απαντήσεις του πρώτου επιπέδου γίνουν ένα ενιαίο κείμενο, αυτό θα έχει ως αποτέλεσμα το επάγγελμα το οποίο θα αντιστοιχηθεί στις απαντήσεις αυτές να έχει μεγαλύτερο σκορ από οποιοδήποτε άλλο. Αυτό θα συμβεί λόγω των αρκετά περισσότερων λέξεων που περιέχει το ενιαίο κείμενο από τις ερωτήσεις. Επίσης το αποτέλεσμα αυτό μας συμφέρει καθώς στο επίπεδο του writing, ο χρήστης δεν δεσμεύεται, μπορεί να απαντήσει ελεύθερα και να δώσει αρκετές πληροφορίες για τα ενδιαφέροντά του αλλά και για τον χαρακτήρα του. Επομένως είναι λογικό το επάγγελμα που θα εξαχθεί από το πρώτο επίπεδο να έχει κάποια επιπλέον βαρύτητα.

```
def final_weights(answers, questions_and_jobs, ans_factor, same_job_factor):
    same_jobs = count_same_jobs(questions_and_jobs, answers)

    questions = read_file()
    level2 = questions[1]

    # LEVEL 2
    for i in range(1, len(level2)+1):
        job = questions_and_jobs[i][1]
        max_score = questions_and_jobs[i][2]

        if answers[i] == 1:
            questions_and_jobs[i][2] = ans_factor[0] * max_score
        elif answers[i] == 2:
            questions_and_jobs[i][2] = ans_factor[1] * max_score
        elif answers[i] == 3:
            questions_and_jobs[i][2] = (ans_factor[2]*max_score) + (same_jobs[job]*same_job_factor)
        elif answers[i] == 4:
            questions_and_jobs[i][2] = (ans_factor[3]*max_score) + (same_jobs[job]*same_job_factor)
        elif answers[i] == 5:
            questions_and_jobs[i][2] = (ans_factor[4]*max_score) + (same_jobs[job]*same_job_factor)

    # LEVEL 3
    for i in range(len(level2)+1, len(answers)):
        job = questions_and_jobs[i][1]
        max_score = questions_and_jobs[i][2]

        if answers[i] == 1:
            questions_and_jobs[i][2] = (ans_factor[4]*max_score) + (same_jobs[job]*same_job_factor)
        elif answers[i] == 2:
            questions_and_jobs[i][2] = ans_factor[0] * max_score

    return questions_and_jobs
```

*Υπολογισμός τελικών βαρών*

```

def count_same_jobs(questions_and_jobs, answers):
    same_jobs = {i: 0 for i in range(len(jobs))}

    for pair in questions_and_jobs:
        if pair[0] == 0:
            same_jobs[pair[1]] += 1
        else:
            if answers[pair[0]] in [3, 4, 5]:
                same_jobs[pair[1]] += 1

    return same_jobs

```

*Μέτρηση φορών που επιλέχθηκε θετικά το κάθε επάγγελμα*

Τέλος, μετά την αναπροσαρμογή των βαρών, η συνάρτηση `return_jobs` θα ταξινομήσει τα επαγγέλματα σε φθίνουσα σειρά με βάση τα τελικά σκορ και θα επιστρέψει τα  $n$  πιο ταιριαστά επαγγέλματα για τον χρήστη. Επίσης γίνεται ένας έλεγχος ώστε να επιλεγθεί μία φορά το κάθε επάγγελμα στα πιο ταιριαστά, καθώς όπως αναφέραμε προηγουμένως είναι αρκετά πιθανό να υπάρχουν ίδια επαγγέλματα δύο και περισσότερες φορές.

```

def return_jobs(n, questions_and_jobs):
    questions_and_jobs.sort(key=lambda x: x[2], reverse=True)
    top_matched_jobs = []

    for pair in questions_and_jobs:
        if pair[1] not in top_matched_jobs:
            top_matched_jobs.append(pair[1])
            if len(top_matched_jobs) == n:
                break

    top_matched_jobs = [(jobs[i], links[i]) for i in top_matched_jobs]

    return top_matched_jobs

```

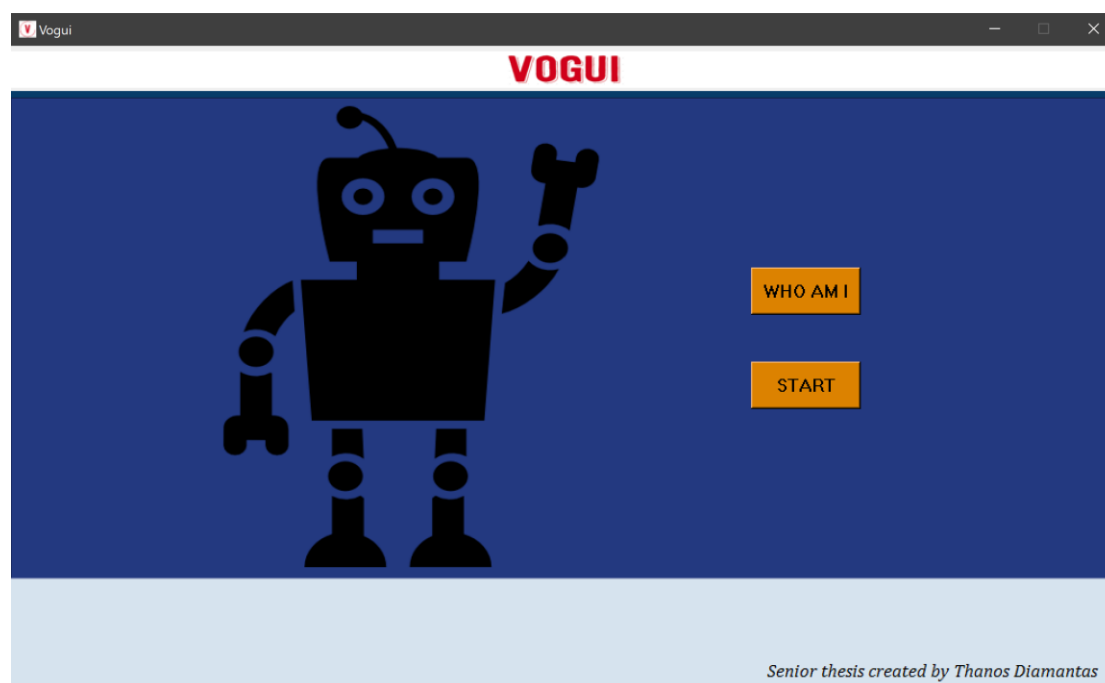
*Επιστροφή  $n$  πιο ταιριαστών επαγγελμάτων*

## 4.8 Graphical User Interface

Η υλοποίηση του γραφικού περιβάλλοντος της εφαρμογής έγινε με τη βοήθεια του tkinter, το οποίο είναι το standard πακέτο της Python που χρησιμοποιεί την γλώσσα προγραμματισμού Tcl (Tool Command Language), η οποία είναι κατάλληλη για δημιουργία γραφικών περιβαλλόντων (GUIs).

Η ανάπτυξη του συγκεκριμένου GUI χωρίζεται σε τρία μέρη: στην Αρχική Οθόνη (δηλαδή οι επιλογές που υπάρχουν με το που ξεκινάει η εφαρμογή), στο Quiz Space (το «μέρος» όπου πραγματοποιείται το τεστ) και τέλος στα Αποτελέσματα (η εμφάνιση των επαγγελμάτων που ταιριάζουν στον χρήστη).

### 4.8.1 Αρχική Οθόνη

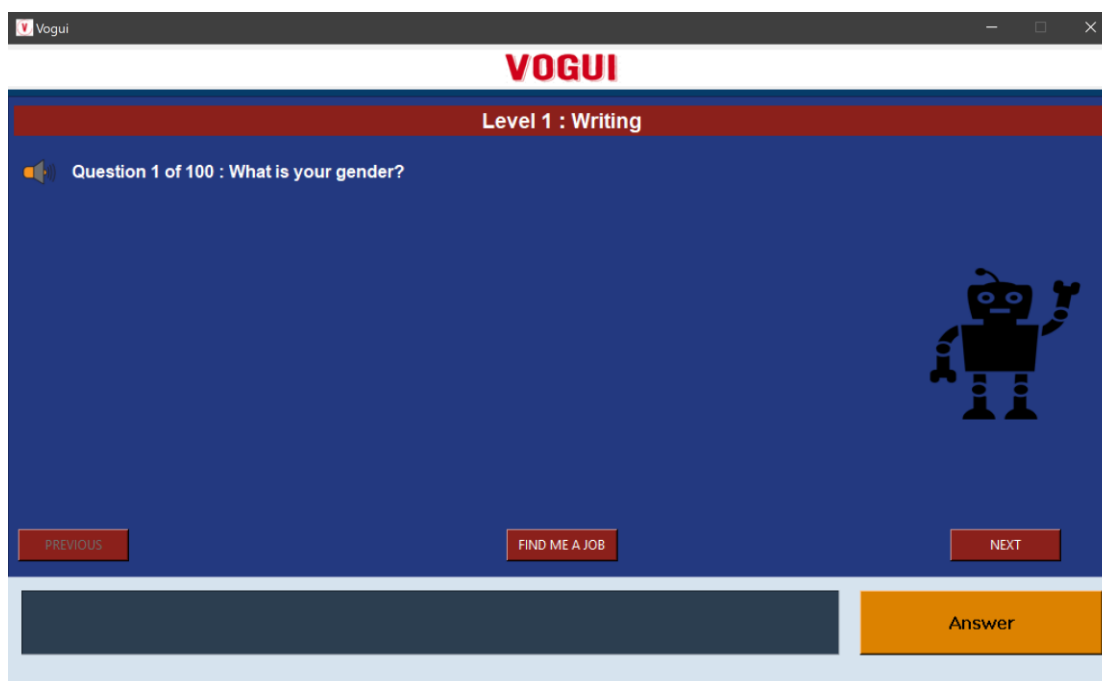


*Αρχική Οθόνη*

Στην Αρχική Οθόνη, έχουν δημιουργηθεί δύο κουμπιά. Πατώντας το κουμπί “WHO AM I”, ο Vogui θα εκφωνήσει ένα κείμενο καλωσορίζοντας τον χρήστη και λέγοντάς του ποιος είναι και για ποιον λόγο έχει δημιουργηθεί. Αυτό βοηθάει τον χρήστη να μπορέσει να ενταχθεί στο ‘mood επικοινωνίας με ένα chatbot’ προσφέροντάς του μία καλύτερη και πιο ενδιαφέρουσα εμπειρία. Με το πάτημα του κουμπιού “START” μεταφέρεται στο Quiz Space ώστε να ξεκινήσει την διαδικασία του quiz.



## 4.8.2 Quiz Space

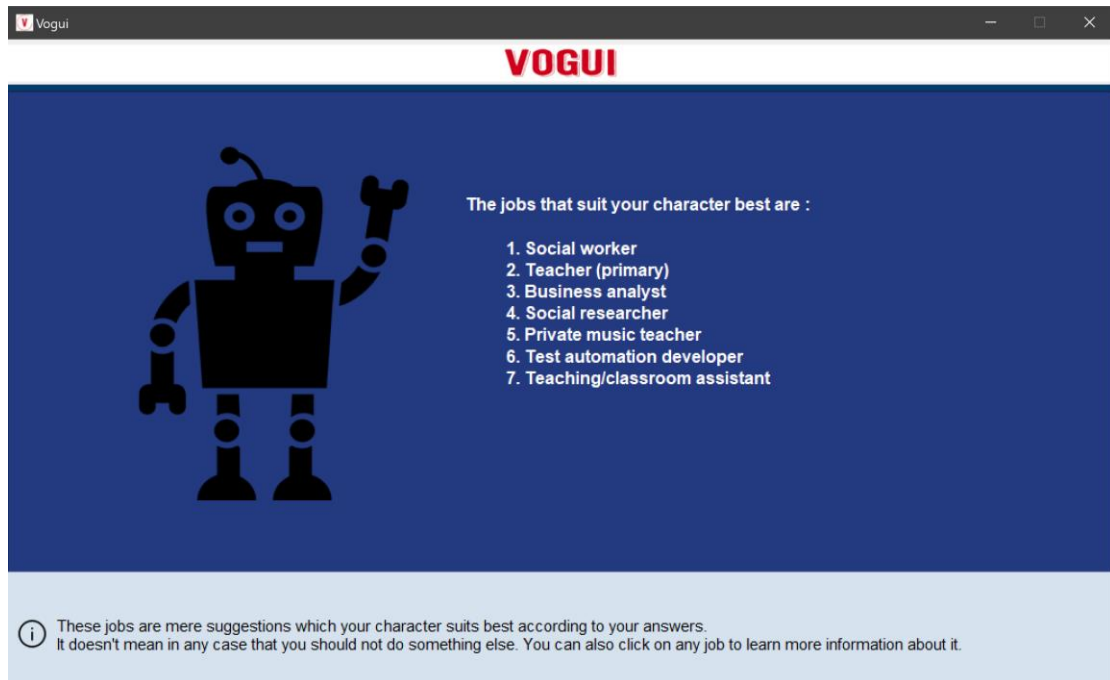


Quiz Space

Στην πραγματικότητα δεν πρόκειται για κάποια μεταφορά από το ένα μέρος στο άλλο. Αυτό που γίνεται στην πράξη είναι απλά αλλαγή αντικειμένων πάνω στον ίδιο καμβά. Το background είναι ο ίδιος καμβάς σε όλα τα μέρη, απλά με κάθε ενέργεια του χρήστη τα αντικείμενα πάνω σε αυτόν αλλάζουν. Για παράδειγμα, με το πάτημα του κουμπιού “NEXT”, τα κουμπιά “NEXT” και “PREVIOUS”, η ερώτηση καθώς και το εικονίδιο αριστερά από την ερώτηση με το οποίο μπορεί να εκφωνηθεί, θα είναι διαφορετικά αντικείμενα από τα προηγούμενα καθώς η συνάρτηση πίσω από τα αντικείμενα θα εκτελεί διαφορετικές λειτουργίες. Πιο συγκεκριμένα τα κουμπιά “NEXT” και “PREVIOUS”, δηλαδή τα κουμπιά που κατευθύνουν τις ερωτήσεις, είναι στην πραγματικότητα δύο αναδρομικές συναρτήσεις όπου με το κάθε πάτημα «δείχνουν» στην επόμενη ή στην προηγούμενη ερώτηση αντίστοιχα. Το κουμπί “FIND ME A JOB”, είναι μία συνάρτηση η οποία ελέγχει αν ο χρήστης έχει απαντήσει σε όλες τις ερωτήσεις και αν η απάντηση είναι θετική τότε υπολογίζει τα τελικά αποτελέσματα σύμφωνα με τους αλγόριθμους που αναλύθηκαν στις προηγούμενες ενότητες του κεφαλαίου. Τέλος το κουμπί “Answer” στέλνει την απάντηση του χρήστη στο σύστημα για έλεγχο εγκυρότητας και αποθήκευση.

Η ομιλία του Vogui στην Αρχική Οθόνη, όπως και κατά την διάρκεια του Quiz έγινε με τη χρήση του πακέτου pytt3x3.

### 4.8.3 Αποτελέσματα



The screenshot shows a web browser window with the VOGUI logo at the top. The main content area has a dark blue background with a white robot icon on the left. To the right of the robot, the text reads: "The jobs that suit your character best are :". Below this, a numbered list of seven job titles is displayed: 1. Social worker, 2. Teacher (primary), 3. Business analyst, 4. Social researcher, 5. Private music teacher, 6. Test automation developer, and 7. Teaching/classroom assistant. At the bottom of the page, there is a light blue footer with an information icon and the text: "These jobs are mere suggestions which your character suits best according to your answers. It doesn't mean in any case that you should not do something else. You can also click on any job to learn more information about it."

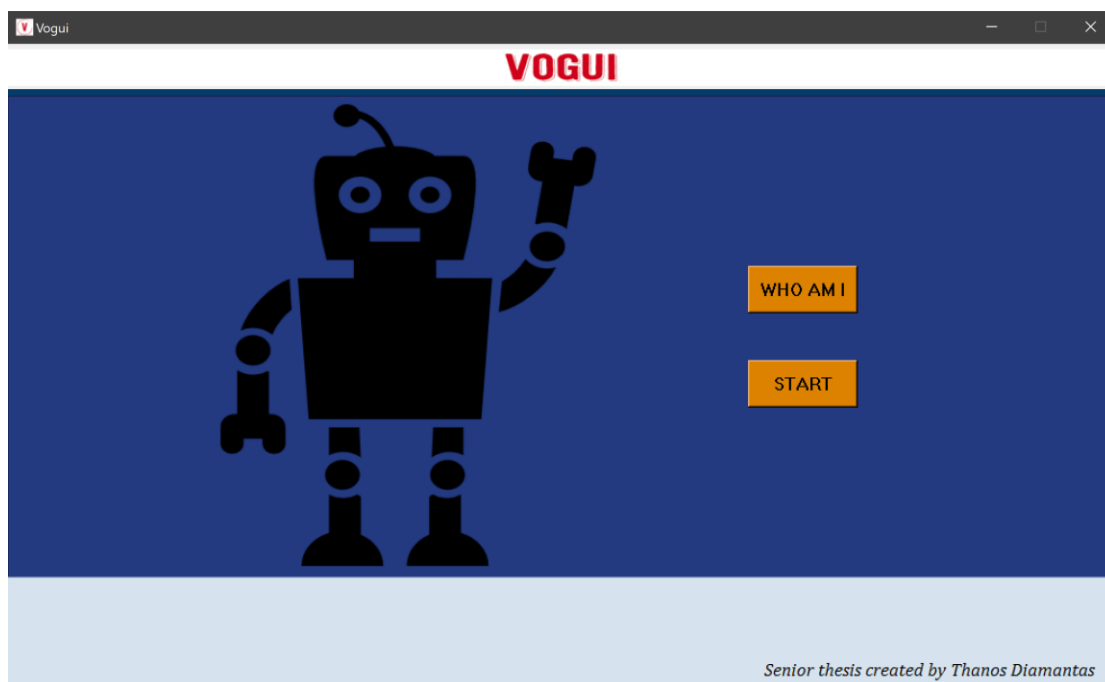
#### *Αποτελέσματα*

Στο τρίτο και τελευταίο μέρος έχουμε την εμφάνιση των αποτελεσμάτων. Η εμφάνιση, δεν είναι κάτι άλλο από μία λίστα με αντικείμενα που είναι τα πιο ταιριαστά επαγγέλματα για τον χρήστη. Κάθε αντικείμενο της λίστας είναι συνδεδεμένο με ένα url link που είναι η σελίδα της περιγραφής του. Έτσι στον χρήστη δίνεται η δυνατότητα να κάνει 'κλικ' σε κάποιο επάγγελμα και να μάθει περισσότερες πληροφορίες σχετικά με αυτό.

## Κεφάλαιο 5

### Περιγραφή Εκτέλεσης

Στο κεφάλαιο 5 θα εξηγήσουμε βήμα προς βήμα ένα παράδειγμα εκτέλεσης της εφαρμογής. Για να ξεκινήσει η εφαρμογή πρέπει να εκτελεστεί το αρχείο `chatroom.py`, το οποίο είναι και το αρχείο που περιλαμβάνει την ανάπτυξη του γραφικού περιβάλλοντος (GUI) του Vogui. Με την εκτέλεση του αρχείου παρουσιάζεται η Αρχική Οθόνη.

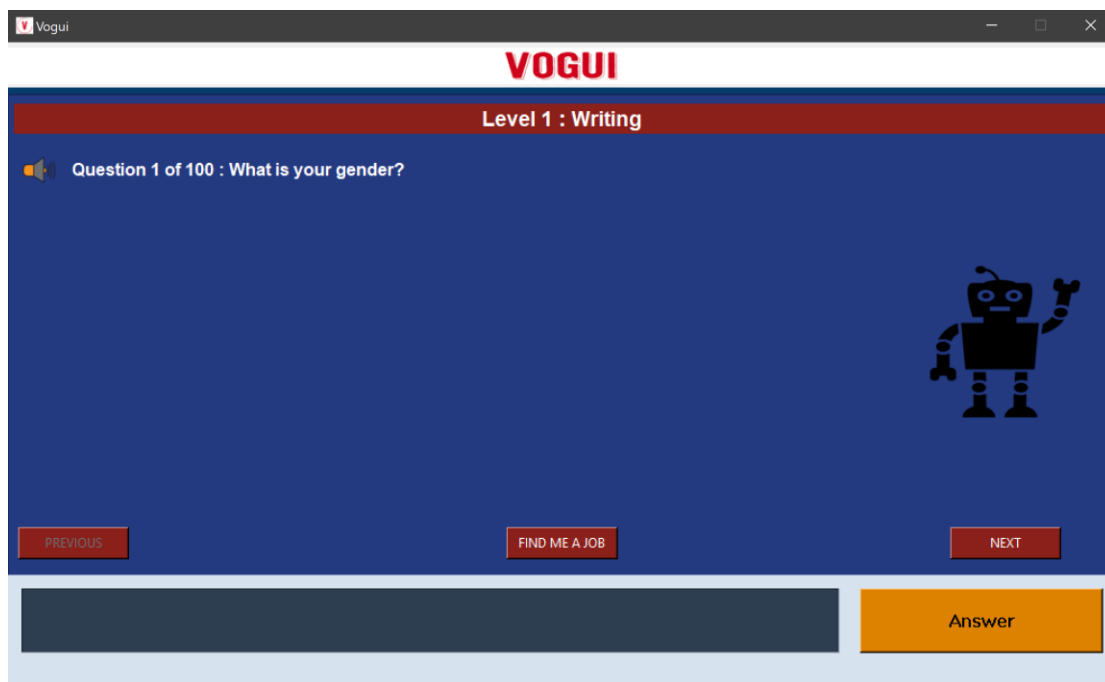


*Αρχική Οθόνη*

Στην αρχική οθόνη, δίνονται στον χρήστη δύο επιλογές. Με το πάτημα του κουμπιού “WHO AM I”, ο Vogui θα συστηθεί στον χρήστη. Πατώντας το κουμπί “START”, ο χρήστης είναι έτοιμος να ξεκινήσει το quiz ξεκινώντας από το Level 1.

Στο πάνω μέρος του Quiz Space, ο χρήστης μπορεί να δει σε ποιο level βρίσκεται. Συνολικά υπάρχουν τρία level όπου το κάθε ένα αποτελείται από διαφορετικού τύπου ερωτήσεις. Κάθε ερώτηση μπορεί να εκφωνηθεί από τον Vogui πατώντας το εικονίδιο του ήχου που βρίσκεται αριστερά από την ερώτηση. Η διαπέραση των ερωτήσεων μπορεί να πραγματοποιηθεί με το πάτημα των κουμπιών “PREVIOUS” και “NEXT” πηγαίνοντας στην προηγούμενη ή στην επόμενη ερώτηση αντίστοιχα. Για την μετάβαση στην επόμενη ερώτηση δεν είναι απαραίτητο να έχει

απαντηθεί η τωρινή. Όμως για τον υπολογισμό των αποτελεσμάτων η απάντηση όλων των ερωτήσεων είναι υποχρεωτική. Ο υπολογισμός των αποτελεσμάτων ξεκινάει με το κουμπί “FIND ME A JOB”.



*Quiz Space*

Στο κάτω μέρος ο χρήστης μπορεί να πληκτρολογήσει την απάντησή του και μόλις είναι έτοιμος να πατήσει το κουμπί “Answer” για να απαντήσει την ερώτηση.



*Απάντηση Ερώτησης*

Αφού απάντησε στην ερώτηση, μπορεί να δει την απάντηση που έδωσε ακριβώς πάνω από το κουμπί “FIND ME A JOB” καθώς και το μήνυμα «Answered!» για την επιβεβαίωση της απάντησης. Μπορεί ανά πάσα στιγμή να αλλάξει την απάντηση που έδωσε πληκτρολογώντας μία καινούρια και πατώντας ξανά το κουμπί “Answer”.



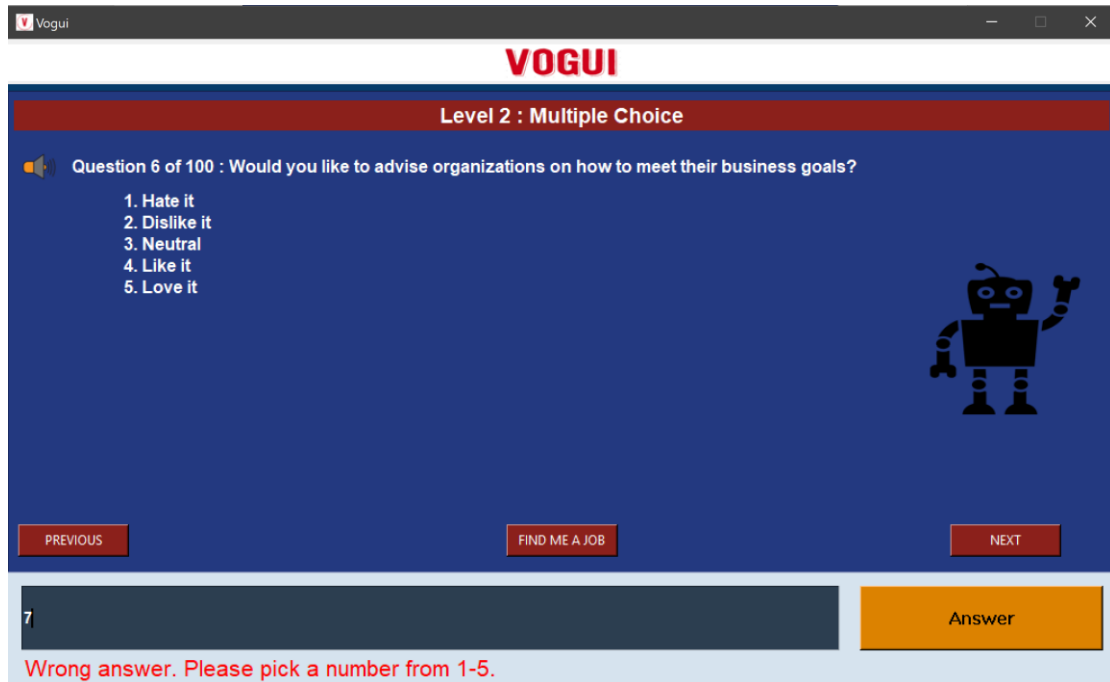
#### Επιτυχής Απάντηση

Αν ο χρήστης προσπαθήσει να πατήσει το κουμπί “FIND ME A JOB” χωρίς να έχει απαντήσει όλες τις ερωτήσεις, θα του εμφανιστεί ένα μήνυμα λάθους όπου θα τον ενημερώσει πόσες ερωτήσεις δεν έχει απαντήσει ακόμα.



#### Αναπάντητες Ερωτήσεις

Στο δεύτερο level, που είναι το Multiple Choice, η απάντηση που θα δώσει ο χρήστης δεσμεύεται καθώς θα πρέπει να απαντήσει με έναν αριθμό από το 1 έως και το 5 όπου αναπαριστά πόσο πολύ του αρέσει το αντικείμενο που περιγράφει η ερώτηση. Αν ο χρήστης δώσει οποιαδήποτε άλλη απάντηση θα του εμφανιστεί μήνυμα λάθους και θα πρέπει να δώσει μία έγκυρη απάντηση ώστε να απαντηθεί η ερώτηση.



**VOGUI**

Level 2 : Multiple Choice

Question 6 of 100 : Would you like to advise organizations on how to meet their business goals?

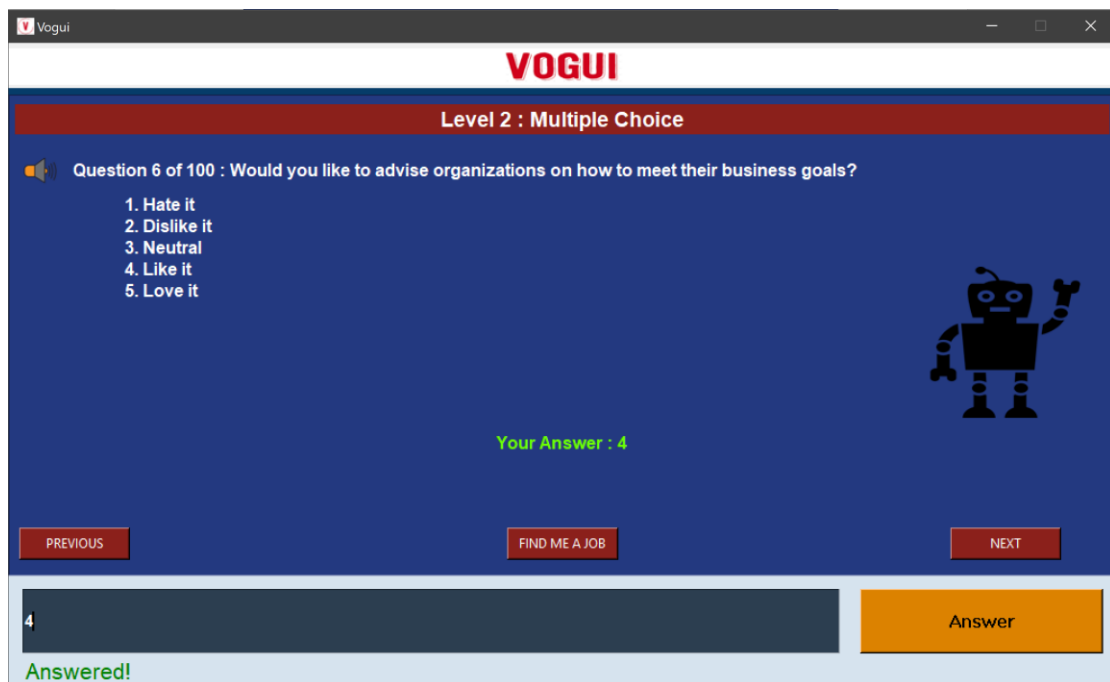
1. Hate it
2. Dislike it
3. Neutral
4. Like it
5. Love it

PREVIOUS FIND ME A JOB NEXT

7 Answer

Wrong answer. Please pick a number from 1-5.

*Μη έγκυρη απάντηση στο 2ο level*



**VOGUI**

Level 2 : Multiple Choice

Question 6 of 100 : Would you like to advise organizations on how to meet their business goals?

1. Hate it
2. Dislike it
3. Neutral
4. Like it
5. Love it

PREVIOUS FIND ME A JOB NEXT

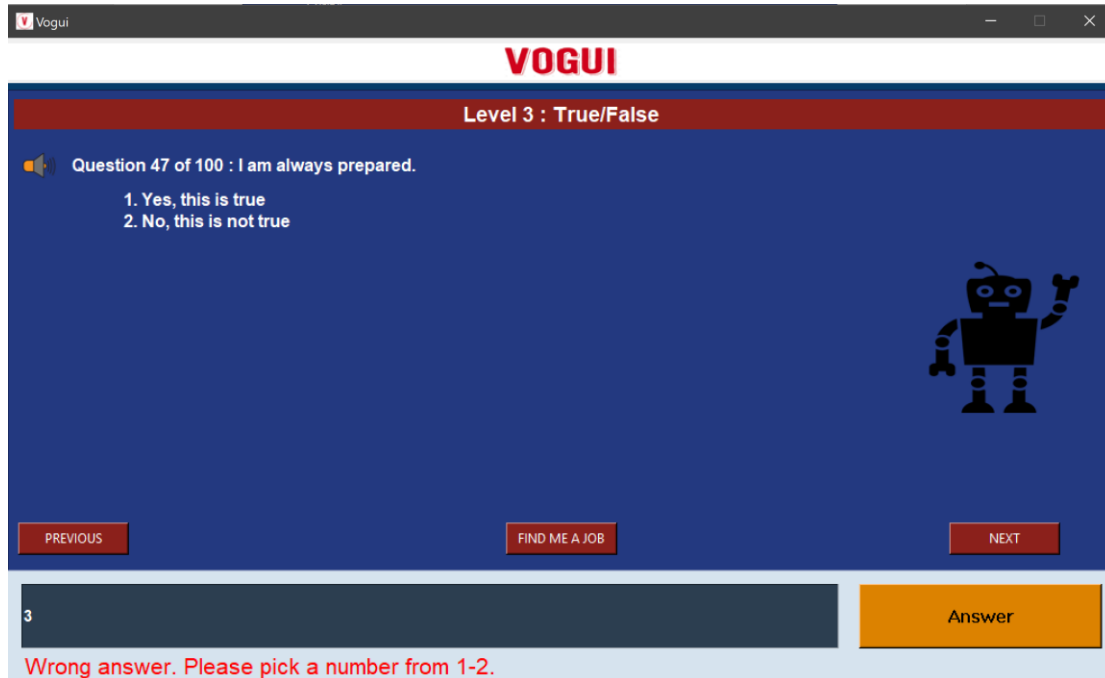
Your Answer : 4

4 Answer

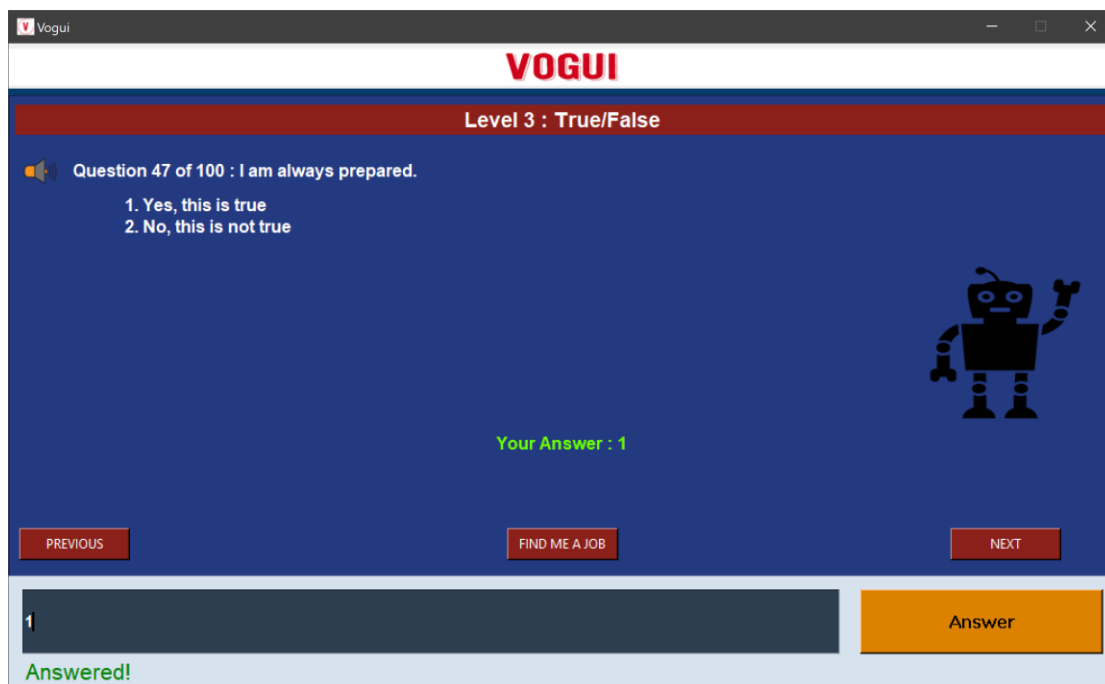
Answered!

*Έγκυρη απάντηση στο 2ο level*

Παρόμοια και για το τρίτο level που είναι True/False, ο χρήστης πρέπει να δώσει μία απάντηση πληκτρολογώντας τους αριθμούς 1 ή 2 ανάλογα με το αν συμφωνεί ή δεν συμφωνεί με την ερώτηση αντίστοιχα.

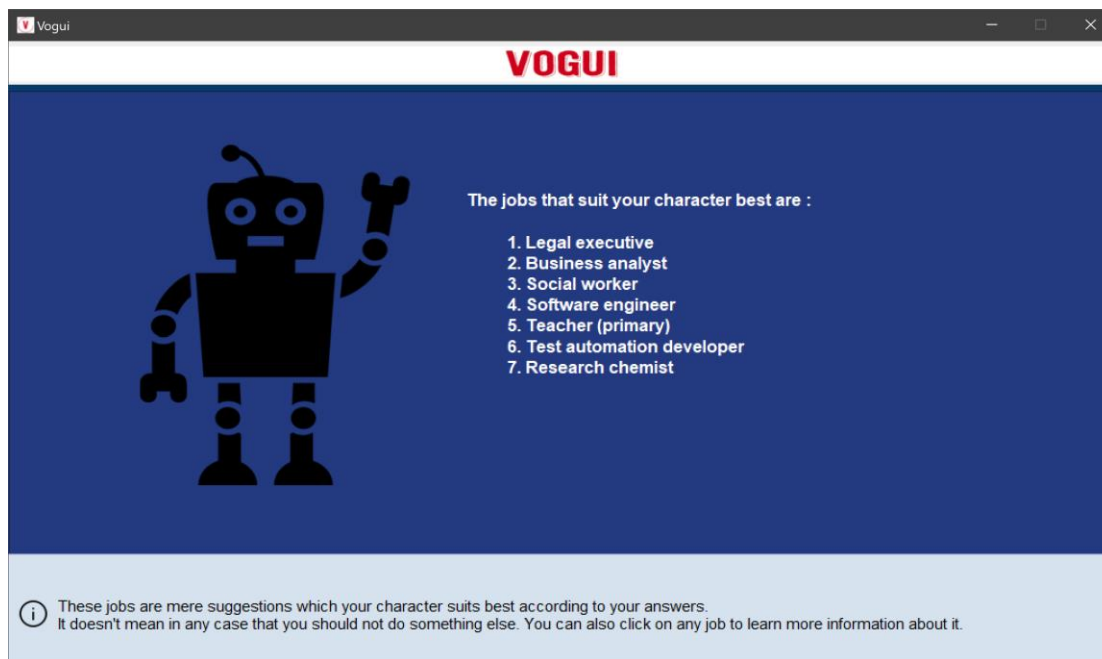


*Μη έγκυρη απάντηση στο 3ο level*



*Έγκυρη απάντηση στο 3ο level*

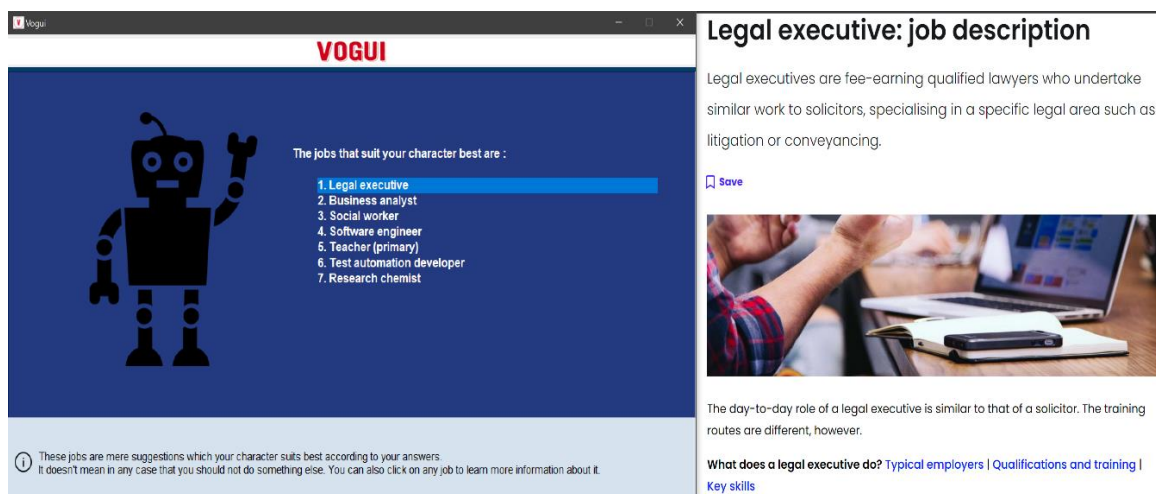
Τέλος, αφού απαντηθούν όλες οι ερωτήσεις ο χρήστης μπορεί να πατήσει το κουμπί “FIND ME A JOB” με σκοπό να βρει ο Vogui τα επαγγέλματα που ταιριάζουν περισσότερο στον χαρακτήρα του και στη προσωπικότητά του. Ο υπολογισμός των αποτελεσμάτων κρατάει περίπου 40 δευτερόλεπτα (ανάλογα πάντα και με τα χαρακτηριστικά του υπολογιστή που χρησιμοποιεί ο χρήστης).



The screenshot shows the Vogui website interface. At the top, the logo "VOGUI" is displayed in red. Below the logo, a blue background features a black robot icon on the left. To the right of the robot, the text reads "The jobs that suit your character best are :" followed by a numbered list of seven job titles: 1. Legal executive, 2. Business analyst, 3. Social worker, 4. Software engineer, 5. Teacher (primary), 6. Test automation developer, and 7. Research chemist. At the bottom of the page, there is a light blue box containing an information icon and the text: "These jobs are mere suggestions which your character suits best according to your answers. It doesn't mean in any case that you should not do something else. You can also click on any job to learn more information about it."

#### Εμφάνιση αποτελεσμάτων

Για επιπλέον πληροφορίες για το κάθε επάγγελμα, ο χρήστης μπορεί να κάνει ‘κλικ’ πάνω σε οποιοδήποτε αποτέλεσμα επιθυμεί και να μεταφερθεί στην αντίστοιχη ιστοσελίδα πληροφοριών για το επάγγελμα που επέλεξε.



The screenshot shows the Vogui website interface with a job description for a "Legal executive". The left side of the page displays the same robot icon and job list as in the previous screenshot, with "1. Legal executive" highlighted in blue. The right side of the page has a white background with the heading "Legal executive: job description". Below the heading, the text reads: "Legal executives are fee-earning qualified lawyers who undertake similar work to solicitors, specialising in a specific legal area such as litigation or conveyancing." There is a "Save" button below the text. A photograph of a person's hands working on a laptop is shown. Below the photo, the text states: "The day-to-day role of a legal executive is similar to that of a solicitor. The training routes are different, however." At the bottom, there are links for "What does a legal executive do?", "Typical employers", "Qualifications and training", and "Key skills".

#### Πληροφορίες για το επάγγελμα 'Legal executive'



## **Κεφάλαιο 6**

### **Συμπεράσματα, Προοπτικές Βελτίωσης και Μελλοντικές Προεκτάσεις**

Στο τελευταίο κεφάλαιο της πτυχιακής εργασίας αναφέρονται τα συμπεράσματα που εξάχθηκαν από την εκπόνηση και ανάπτυξη της εργασίας, όπως και προοπτικές βελτίωσης και μελλοντικές προτάσεις, με σκοπό την βελτίωση της ήδη υπάρχουσας υλοποίησης ή της προσθήκης νέων δυνατοτήτων στην εφαρμογή.

#### **6.1 Συμπεράσματα**

Αρχικά, θα πρέπει να τονιστεί πως η εφαρμογή που υλοποιήθηκε στην παρούσα πτυχιακή εργασία δεν αποτελεί εμπορικό προϊόν που σημαίνει πως, προς το παρόν, δεν υπάρχει κάποιος τρόπος πρόσβασης στην εφαρμογή από τρίτο άτομο.

Η υλοποίηση και ανάπτυξη του Vogui θα μπορούσε να πραγματοποιηθεί αρκετά πιο εύκολα με τη βοήθεια της χρήσης εξαιρετικών εργαλείων που υπάρχουν αυτή τη στιγμή στο διαδίκτυο. Για λόγους όμως πειραματισμού καθώς και προσωπικής αγάπης για τον προγραμματισμό επέλεξα, για την απόκτηση του πτυχίου μου, να δημιουργήσω ένα chatbot το οποίο θα έχει υλοποιηθεί εξ' ολοκλήρου με «καθαρό» κώδικα, με τη χρήση πακέτων και βιβλιοθηκών της Python. Η επιλογή της γλώσσας προγραμματισμού Python, ειδικά για εφαρμογές με χρήση τεχνητής νοημοσύνης και μηχανικής μάθησης μοιάζει μονόδρομος καθώς εκτός από μία πανίσχυρη γλώσσα με πολλές δυνατότητες, περιέχει μία πληθώρα βιβλιοθηκών και πακέτων για τεχνητή νοημοσύνη και μηχανική μάθηση, με αποτέλεσμα να κάνει την διαδικασία αρκετά πιο εύκολη και ευχάριστη.

Για την δημιουργία ενός chatbot, δεν αρκεί μόνο ο κώδικας ή τα εργαλεία που χρησιμοποιούνται για να βγει ένα σωστό αποτέλεσμα. Στις περισσότερες περιπτώσεις εφαρμογής chatbot, απαιτείται ένας ειδικός πάνω στο αντίστοιχο θέμα ώστε να τροφοδοτήσει το chatbot με τις κατάλληλες πληροφορίες. Για παράδειγμα ένα chatbot που χρησιμοποιείται για την πρόβλεψη μιας συγκεκριμένης πάθησης σε ασθενείς δεν αρκεί απλά ένας προγραμματιστής που θα το υλοποιήσει, αλλά απαιτούνται γιατροί, δηλαδή εξειδικευμένοι άνθρωποι πάνω στην πάθηση οι οποίοι θα δώσουν τα δεδομένα

που χρειάζεται το chatbot ώστε να καταφέρει να πραγματοποιήσει την πρόβλεψη. Σε ένα chatbot ίδιου τύπου με της παρούσας πτυχιακής εργασίας, το πιο σωστό θα ήταν να ληφθούν συμβουλές από έναν επαγγελματία σύμβουλο επαγγελματικού προσανατολισμού ο οποίος θα μπορούσε να αξιολογήσει τις ερωτήσεις καθώς και να τροφοδοτήσει το σύστημα με τις απαραίτητες πληροφορίες. Όμως στην περίπτωση του Vogui, ο ειδικός θα μπορούσαμε να πούμε πως αντικαταστάθηκε με την δημιουργία των scrapers οδηγώντας σε ένα μοντέλο το οποίο μπορεί να προσαρμοστεί σε οποιοδήποτε δικτυακό τόπο που παρουσιάζει αγγελίες για εργασίες. Η ιστοσελίδα από την οποία συλλέγονται τα δεδομένα περιέχει αρκετά και σύγχρονα επαγγέλματα τα οποία συνεχώς ανανεώνονται. Εκτός αυτού, η κάθε περιγραφή επαγγέλματος που συλλέχθηκε περιέχει όλες τις απαραίτητες πληροφορίες που θα χρειαζόταν το chatbot για να αξιολογήσει τις απαντήσεις, συμπεριλαμβανομένου και χαρακτηριστικά της προσωπικότητας που απαιτούνται για την συγκεκριμένη δουλειά.

Έτσι, με τον ίδιο τρόπο που ένας επαγγελματίας θα έδινε αυτά τα δεδομένα στον Vogui, οι scrapers «μαθαίνουν» από την ιστοσελίδα και έπειτα τροφοδοτούν το σύστημα με αυτές τις πληροφορίες. Επίσης, αυτό έχει ως αποτέλεσμα, η εκμάθηση του Vogui να είναι δυναμική καθώς ανά πάσα στιγμή οι scrapers μπορούν να συλλέξουν νέες πληροφορίες από το site και να τροφοδοτήσουν εκ νέου το σύστημα.

## **6.2 Βελτιώσεις**

Στην ενότητα αυτή θα αναφερθούν ορισμένες ιδέες και σκέψεις, οι οποίες θα βοηθούσαν στην βελτίωση των ήδη υπάρχοντων δυνατοτήτων του Vogui.

### **6.2.1 Βαρύτητα στους τίτλους των περιγραφών**

Στην ήδη υπάρχουσα υλοποίηση, στον υπολογισμό της βαρύτητας της κάθε λέξης σε μία περιγραφή, χρησιμοποιήθηκε η ίδια τεχνική υπολογισμού βαρών για όλες τις λέξεις. Στην εξαγωγή των λέξεων-κλειδιών μία βελτίωση που θα μπορούσε να πραγματοποιηθεί για καλύτερα αποτελέσματα θα ήταν κάποιες λέξεις να ήταν εξαρχής πιο σημαντικές από τις υπόλοιπες. Για παράδειγμα σε κάθε περιγραφή, ο τίτλος της καθώς και η πρώτη παράγραφος η οποία περιγράφει συνοπτικά το επάγγελμα, περιέχουν λέξεις που είναι στενά συνδεδεμένες με το αντικείμενο του επαγγέλματος. Επομένως, θα μπορούσαμε να προσθέσουμε εξαρχής μια παραπάνω σημασία στις

συγκεκριμένες λέξεις ώστε να έχουν υψηλό σκορ, ανεξάρτητα από τη συχνότητά τους στην περιγραφή ή στις άλλες περιγραφές της ίδιας κατηγορίας.

### **6.2.2 Παράλληλη επικοινωνία του Vogui και χρήσης της εφαρμογής**

Για την ομιλία του Vogui χρησιμοποιήθηκε το πακέτο pytt3x3. Ο τρόπος με τον οποίο γίνεται η ομιλία είναι μέσω της συνάρτησης runAndWait() του πακέτου η οποία εκτελεί την εντολή ομιλίας και το πρόγραμμα περιμένει να τελειώσει ώστε να συνεχίσει στις επόμενες εντολές. Αυτό σημαίνει πως κάθε φορά που ο Vogui «μιλάει», είτε με το πάτημα του κουμπιού “WHO AM I”, είτε στην εκφώνηση της ερώτησης είτε κατά την διάρκεια του quiz, το πρόγραμμα «παγώνει» και ο χρήστης δεν μπορεί να κάνει τίποτα έως ότου σταματήσει ο Vogui. Ο τρόπος για να λυθεί αυτό είναι με την χρήση πολυνημάτωσης (multithreading), δηλαδή ο κώδικας για την ομιλία να πραγματοποιείται σε διαφορετικό νήμα (thread) από αυτό στο οποίο τρέχει η εφαρμογή, ώστε να μπορούν να εκτελεστούν παράλληλα διαφορετικές διεργασίες. Δυστυχώς με τη χρήση του πακέτου pytt3x3 δεν μπορεί να γίνει πολυνημάτωση. Επομένως, μία λύση θα μπορούσε να είναι η χρήση άλλου πακέτου για ομιλία ή η αποθήκευση των κειμένων που θα εκφωνήσει το chatbot σε mp3 αρχεία τα οποία θα εκτελούνται την κατάλληλη στιγμή.

### **6.2.3 Ερωτήσεις βασισμένες στα συγκεκριμένα επαγγέλματα**

Οι ερωτήσεις από τις οποίες αποτελείται το quiz, ανακτήθηκαν από διαφορετικές ιστοσελίδες από αυτή που οι scrapers εξήγαγαν τα επαγγέλματα και τις περιγραφές τους. Αυτό έχει ως αποτέλεσμα, ορισμένες ερωτήσεις να αναφέρονται σε επαγγέλματα τα οποία δεν υπάρχουν σε αυτά που έχουν εξαχθεί, με αποτέλεσμα ο χρήστης να έχει επιλέξει μία ερώτηση που του αρέσει, όμως το επάγγελμα στο οποίο αναφέρεται η ερώτηση να μην του προταθεί ποτέ. Αυτό δεν δημιουργεί κάποιο πρόβλημα στην υλοποίηση και εμφανίζεται σε ελάχιστες ερωτήσεις αλλά είναι ένα λογικό λάθος που θα μπορούσε να βελτιωθεί.

### **6.2.4 Περισσότερες και πιο στοχευμένες writing ερωτήσεις**

Οι ερωτήσεις στο πρώτο επίπεδο είναι ελάχιστες και γενικές. Το πρώτο επίπεδο είναι ιδιαίτερα σημαντικό στην επιλογή του επαγγέλματος και στην αναγνώριση προσωπικότητας διότι ο χρήστης δεν περιορίζεται στον τρόπο που πρέπει να απαντήσει και μπορεί να δώσει αρκετές σημαντικές πληροφορίες. Όμως είναι αρκετά πιθανό με μία γενική ερώτηση να μην πάρουμε καμία σημαντική πληροφορία για τον χρήστη. Σε

μία ερώτηση όπως “Πες κάποια πράγματα για τον εαυτό σου”, ο χρήστης θα μπορούσε να απαντήσει άσχετα πράγματα τα οποία να μην έδιναν καμία σημαντική πληροφορία ή και να μπερδεύαν τον Vogui στο να βγάλει ένα επάγγελμα κοντά στα γούστα του χρήστη. Συμπερασματικά, χρειάζονται περισσότερες αλλά και πιο στοχευμένες ερωτήσεις ώστε να μειωθεί η πιθανότητα να δοθεί μία πολύ γενική και άσχετη απάντηση.

### **6.2.5 Αν οι ερωτήσεις σωστού/λάθους έχουν θετική ή αρνητική σημασία**

Στο τρίτο και τελευταίο επίπεδο, οι ερωτήσεις αναφέρονται περισσότερο στις ικανότητες και στον χαρακτήρα του χρήστη. Στον χρήστη δίνεται μία πρόταση π.χ. “I am always prepared”, και ο χρήστης καλείται να απαντήσει με “True” αν αυτό τον χαρακτηρίζει ή με “False” για το αντίθετο. Η παραπάνω ερώτηση έχει θετική σημασία καθώς αν ο χρήστης απαντήσει “True”, τότε σημαίνει πως είναι πάντα προετοιμασμένος. Όμως η ερώτηση “I am not always prepared”, έχει αρνητική σημασία και στην απάντηση “True” σημαίνει ότι ο χρήστης δεν είναι πάντα προετοιμασμένος. Αυτή τη στιγμή ο Vogui δεν υποστηρίζει την αναγνώριση θετικής ή αρνητικής σημασίας κειμένων και απλά ελέγχει αν οι λέξεις των ερωτήσεων υπάρχουν μέσα σε μία περιγραφή. Επομένως αν η λέξη “prepared” βρεθεί και ο χρήστης έχει απαντήσει “True” στην ερώτηση “I am not always prepared”, ο Vogui θα υποθέσει πως είναι πάντα προετοιμασμένος ενώ ισχύει το αντίθετο.

## **6.3 Μελλοντικές Προεκτάσεις**

Στην τελευταία ενότητα θα προταθούν ιδέες οι οποίες έχουν να κάνουν με την προσθήκη δυνατοτήτων στην εφαρμογή που δεν υποστηρίζονται στην υπάρχουσα υλοποίηση. Πρόκειται για προεκτάσεις του συστήματος που είναι δυνατόν να προστεθούν μελλοντικά.

### **6.3.1 Αναγνώριση προσωπικότητας**

Στο τρίτο επίπεδο ερωτήσεων, οι ερωτήσεις στοχεύουν στην προσωπικότητα του χρήστη, όμως ο Vogui διαχειρίζεται αυτό το επίπεδο όπως και τα προηγούμενα δύο. Κάθε περιγραφή επαγγέλματος διαθέτει πληροφορίες σχετικά με τις ικανότητες και τα χαρακτηριστικά που θα έπρεπε να έχει ένας ενδιαφερόμενος για το συγκεκριμένο επάγγελμα. Προς το παρόν, η διαδικασία που γίνεται είναι η εύρεση ομοιότητας μεταξύ των λέξεων της ερώτησης και των περιγραφών και όχι η

αναγνώριση της προσωπικότητας του χρήστη. Μια μελλοντική ανάπτυξη της εφαρμογής θα μπορούσε να είναι η κατάταξη του χρήστη σε κάποια κατηγορία προσωπικότητας (π.χ. five-factor model FFM), σύμφωνα με τις απαντήσεις που έδωσε στις ερωτήσεις τρίτου επιπέδου. Έτσι, θα έχουμε ένα συνολικό προφίλ προσωπικότητας του χρήστη το οποίο θα είναι πιο αξιόπιστο από το να λαμβάνουμε υπόψη τη κάθε ερώτηση ξεχωριστά, καθώς θα συγκρίνουμε ομάδες προσωπικοτήτων και δεν θα βασιζόμαστε απλά στην ταύτιση μοναδικών λέξεων.

### **6.3.2 Υποστήριξη άλλων γλωσσών**

Μία επιπλέον δυνατότητα που θα ήταν ωραίο να έχει ο χρήστης, είναι να μπορεί να επιλέξει τη μητρική του γλώσσα για να πραγματοποιήσει το quiz ή ακόμα και για την ομιλία του chatbot. Λόγω ότι η διαδικασία του backend είναι αρκετά δύσκολο να υλοποιηθεί σε γλώσσα διαφορετική της αγγλικής, πέρα της ομιλίας του chatbot που δεν επηρεάζει τον κώδικα, οι ερωτήσεις καθώς και οι απαντήσεις που δίνει ο χρήστης θα μπορούσαν να φαίνονται στο γραφικό περιβάλλον (δηλαδή στο frontend) στη γλώσσα που επέλεξε ο χρήστης αλλά στο backend να εξακολουθούν να είναι στα αγγλικά. Για παράδειγμα οι αγγλικές ερωτήσεις θα μπορούσαν να γίνουν μία αντιστοίχιση με τις μεταφράσεις τους στην επιλεγμένη γλώσσα του χρήστη και οι απαντήσεις των ερωτήσεων να μεταφράζονται στα αγγλικά προτού αποθηκευτούν στην εφαρμογή.

### **6.3.3 Προσθήκη νέου επιπέδου για εξειδίκευση επαγγελματιών**

Τη δεδομένη στιγμή, το quiz αποτελείται από τρία επίπεδα εκ των οποίων οι ερωτήσεις είναι προεπιλεγμένες ανεξάρτητα με την πρόοδο του χρήστη κατά τη διάρκεια του τεστ. Μία σημαντική προσθήκη θα μπορούσε να είναι ένα νέο επίπεδο μεταξύ του 2<sup>ου</sup> και του 3<sup>ου</sup> όπου οι ερωτήσεις θα επιλέγονται ανάλογα με τις απαντήσεις του χρήστη στο 2<sup>ο</sup> επίπεδο. Ο στόχος του νέου επιπέδου θα είναι η εξειδίκευση σε μία κατηγορία επαγγελματιών στην οποία έδειξε ενδιαφέρον ο χρήστης. Συγκεκριμένα, στο δεύτερο επίπεδο θα εξάγεται ο τομέας (sector) επαγγελματιών στον οποίο ανήκει και έπειτα στο νέο επίπεδο θα του γίνονται ερωτήσεις σχετικά με τον τομέα που επιλέχθηκε, με στόχο να καταλήξουμε στα επαγγέλματα που του ταιριάζουν.

### **6.3.4 Στατιστικά επαγγελματιών**

Ένας επαγγελματίας σύμβουλος επαγγελματικού προσανατολισμού είναι αρκετά έμπειρος και μπορεί να δώσει επιπλέον πληροφορίες στον ενδιαφερόμενο οι οποίες βασίζονται στις γνώσεις του. Ορισμένες από αυτές, είναι κατά πόσο δημοφιλές

είναι κάποιο επάγγελμα την χρονιά που διανύουμε, ποια είναι η εξέλιξή του, τι ζήτηση έχει σύμφωνα με τη χώρα που θα ήθελε να δουλέψει ο ενδιαφερόμενος κ.λπ.. Ορισμένες από αυτές τις πληροφορίες βασίζονται σε έρευνες που γίνονται σε κάθε χώρα ανά τακτά χρονικά διαστήματα και υπάρχουν αρκετά sites που διαθέτουν αυτά τα στατιστικά. Επομένως θα μπορούσαμε μέσω της τοποθεσίας του χρήστη, ανάλογα με την ήπειρο, χώρα ή πόλη στην οποία βρίσκεται να του προσφέρουμε αυτά τα στατιστικά των επαγγελμάτων που του ταιριάζουν ώστε να τον βοηθήσουμε περισσότερο στην επιλογή του.

### **6.3.5 Διαδικτυακή εφαρμογή**

Φυσικά, μία από τις σημαντικότερες εξελίξεις θα ήταν ο Vogui να «ζωντανέψει» και να γίνει μία online εφαρμογή στην οποία θα μπορεί να απευθυνθεί για βοήθεια οποιοσδήποτε χρήστης. Προς το παρόν ο Vogui βρίσκεται σε πειραματικό στάδιο και όπως αναφέρθηκε και σε προηγούμενο κεφάλαιο, για να είναι έτοιμο ένα chatbot να χρησιμοποιηθεί από χρήστες χρειάζεται αρκετός χρόνος και πάρα πολλές δοκιμές.

## Βιβλιογραφία

Sumit Raj (2019), Building Chatbots with Python

Michael McTear (2020), Conversational AI-Dialogue Systems, Conversational Agents, and Chatbots

Srini Janarthanam (2017), Hands-On Chatbots and Conversational UI Development

Sachi Nandan Mohanty, Jyotir Moy Chatterjee, Sarika Jain, Ahmed A. Elngar & Priya Gupta (2020), Recommender System with Machine Learning and Artificial Intelligence

P. Pavan Kumar, S. Vairachilai, Sirisha Potluri & Sachi Nandan Mohanty (2021), Recommender Systems – Algorithms and Applications

Carlos A. Gomez-Uribe & Neil Hunt, Netflix, Inc. (2015), The Netflix Recommender System: Algorithms, Business Value, and Innovation

Kazimierz Rajnerowicz (2021), What Is a Chatbot and What Are Chatbots Used for?, TIDIO

Expert.ai Team (2020), Chatbot: What is a Chatbot? Why are Chatbots Important?, expert.ai

Ina (2017), The History Of Chatbots – From ELIZA to ALEXA, ONLIM

Archna Oberoi (2019), The History and Evolution of Chatbots, daffodil

Nick Ismail (2019), The history of the chatbot: Where it was and where it's going, Information Age

Wikipedia, ELIZA, <https://en.wikipedia.org/wiki/ELIZA>

Manisha Salecha (2016), Story of ELIZA, the first chatbot developed in 1966, Analytics India Magazine

Wikipedia, PARRY, <https://en.wikipedia.org/wiki/PARRY>

Wikipedia, Cortana, <https://en.wikipedia.org/wiki/Cortana>

Wikipedia, Artificial Linguistic Internet Computer Entity (A.L.I.C.E.),  
[https://en.wikipedia.org/wiki/Artificial\\_Linguistic\\_Internet\\_Computer\\_Entity](https://en.wikipedia.org/wiki/Artificial_Linguistic_Internet_Computer_Entity)

Wikipedia, Amazon Alexa, [https://en.wikipedia.org/wiki/Amazon\\_Alexa](https://en.wikipedia.org/wiki/Amazon_Alexa)

Khari Johnson (2016), Why mattress startup Casper built a chatbot for night owls,  
VentureBeat

Kevin J. Ryan, Staff Writer, Inc. (2016), Casper Moves Beyond Mattresses to...a  
Chatbot for Insomniacs, Inc.

WhatsApp (2021), The World Health Organization launches WHO Health Alert on  
WhatsApp, WhatsApp

Harm de Vries et al. (2017), GuessWhat?! Visual object discovery through multi-modal  
dialogue, Cornell University

Sergios Karagiannakos (2021), An introduction to Recommendation Systems: an  
overview of machine and deep learning architectures, AI SUMMER

Badreesh Shetty (2019), An In-Depth Guide to How Recommender Systems Work,  
builtin

Rohit Dwivedi (2020), What Are Recommendation Systems in Machine Learning?,  
analytics steps

Wikipedia, Recommender systems,  
[https://en.wikipedia.org/wiki/Recommender\\_system](https://en.wikipedia.org/wiki/Recommender_system)

James Le (2019), Recommendation System Series Part 1: An Executive Guide to  
Building Recommendation System, towards data science

Libby Plummer (2017), This is how Netflix's top-secret recommendation system  
works, WIRED

Springboard India (2019), How Netflix's Recommendation Engine Works?,  
Springboard India

Κυριάκος Στεργιάδης (2021), Ποια είναι η κρυφή τεχνολογία του Netflix που το κάνει  
διαφορετικό για τον καθένα;, Unboxholics



David Chong (2020), Deep Dive into Netflix's Recommender System, towards data science

Wikipedia, Netflix Prize, [https://en.wikipedia.org/wiki/Netflix\\_Prize](https://en.wikipedia.org/wiki/Netflix_Prize)

Dan Jackson (2017), The Netflix Prize: How a \$1 Million Contest Changed Binge-Watching Forever, Thrillist

Chris Alvino & Justin Basilico (2015), Learning a Personalized Homepage, The Netflix Tech Blog

Madeline et al. (2018), AVA: The Art and Science of Image Discovery at Netflix, The Netflix Tech Blog

Laduram Vishnoi (2020), Conversational Agent: A More Assertive Form of Chatbots, towards data science

MonkeyLearn, Keyword Extraction, <https://monkeylearn.com/keyword-extraction/>

Bruno Stecanella (2019), Understanding TF-IDF: A Simple Introduction, MonkeyLearn

Sunny Srinidhi (2020), Lemmatization in Natural Language Processing (NLP) and Machine Learning, towards data science