

AGH

AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej

Praca dyplomowa

*Chatbot wspierający postępowanie z pacjentem
autoagresywnym z wykorzystaniem struktur asocjacyjnych
w procesie decyzyjnym*

*Chatbot supporting the management of auto-aggressive
patients with the use of associative structures in the
decision-making process*

Autor:	<i>Monika Klimek</i>
Kierunek studiów:	<i>Automatyka i Robotyka</i>
Opiekun pracy:	<i>dr hab. Adrian Horzyk, prof. AGH</i>

Kraków, 2022

*Dziękuję serdecznie mojemu promotorowi
prof. Horzykowi za poświęcony na spotkania
ze mną czas i za wszystkie porady dotyczące
projektu i pracy pisemnej.*

Streszczenie

Celem poniższej pracy było zbudowanie chatbota, który dzięki strukturze asocjacyjnej MAGDS ma pomagać klinicyście w diagnostyce i ocenie ryzyka samobójstwem u dzieci i młodzieży. Projekt prowadzono we współpracy z zespołem prof. Macieja Pileckiego, złożonym z doświadczonych psychiatrów z Uniwersytetu Jagiellońskiego. W pierwszej części pracy porównano sieci neuronowe i zastosowane tutaj struktury asocjacyjne. Następnie opisano sytuację opieki psychiatrycznej i psychologicznej w Polsce oraz możliwe zastosowanie w niej sztucznej inteligencji. Opisane zostały problemy, które muszą być najpierw zaadresowane, powstałe do tej pory programy konwersacyjne o zastosowaniu medycznym i wyniki ich testów. Przedstawiona została struktura aplikacji, rozważane problemy i praktyczne rozwiązania. Na koniec przedstawiono wyniki realizacji projektu, gdzie pokazano, że udało się utworzyć szkielet systemu łączący interfejs użytkownika na stronach internetowych ze standardową bazą sqlite, z grafem MAGDS i algorytmem chatbota.

Summary

The aim of this work was to build a chatbot that supports clinicians in the assessment of suicide risk in children and adolescents through the MAGDS associative structure. The project was conducted in collaboration with Prof. Maciej Pilecki's team of experienced psychiatrists from the Jagiellonian University. The first part of the paper compares neural networks and the associative structures used here. This was followed by a description of the situation of psychiatric and psychological care in Poland and the possible application of artificial intelligence to it. The problems that need to be addressed first, the conversational programs with medical applications created so far, and the results of their tests are described. The structure of the application, the problems considered and practical solutions are presented. Finally, the results of the project were presented, where it was shown that it was possible to create a system combining a web-based user interface with a standard SQLite database, with a MAGDS graph and a chatbot algorithm.

Spis treści

1. Wstęp	9
1.1. Wprowadzenie i motywacja	9
1.2. Cele pracy	9
1.3. Zawartość pracy	10
2. Sztuczna inteligencja	11
2.1. Ludzki mózg	12
2.2. Sieci neuronowe	14
2.2.1. Budowa i działanie	14
2.2.2. Zalety i ograniczenia	16
2.3. Sieci asocjacyjne	18
2.3.1. Budowa i działanie	18
2.3.2. Cechy wyróżniające	20
2.4. Zastosowanie w programach konwersacyjnych	22
3. Potencjalne zastosowanie SI w psychoterapii	25
3.1. Sytuacja psychiatrii i opieki psychologicznej w Polsce	25
3.2. Sztuczna inteligencja o zastosowaniu medycznym	27
3.2.1. Diagnostyka obrazowa	28
3.2.2. Programy konwersacyjne	29
4. Opis rozwiązania	39
4.1. Aplikacja webowa	39
4.1.1. Obsługa użytkownika i bezpieczeństwo	40
4.1.2. Baza danych	42
4.2. Implementacja MAGDS	43
5. Realizacja	45
5.1. Strona	45
5.2. Baza danych	46

5.3. MAGDS graf.....	49
5.4. Działanie chatbota	51
5.5. Podobieństwo pacjentów	55
6. Podsumowanie.....	57
6.1. Wyniki i możliwości rozbudowy	57
6.2. Wnioski.....	58
A. Dodatek A	59
A.1. Opis repozytorium	59
A.2. Domena.....	60

1. Wstęp

1.1. Wprowadzenie i motywacja

Ostatnimi czasy zwraca się coraz większą uwagę na zdrowie psychiczne ludzi. Dzieje się tak ponieważ coraz więcej ludzi cierpi na depresję, zaburzenia nerwicowe czy wypalenie zawodowe. Grupą, na którą należy zwrócić szczególną uwagę jest młodzież. Według Światowej Organizacji Zdrowia (WHO) aż 1 na 7 młodocianych w wieku 10-17 lat cierpi z powodu jakiegoś problemu psychicznego, a samobójstwo jest czwartą najczęstszą przyczyną śmierci wśród osób w grupie 15-29 lat [1] [2]. W Polsce według danych Komendy Głównej Policji jest to aż druga najczęstsza przyczyna wśród nastolatków [3]. Od lat brakuje psychiatrów dziecięcych, dlatego Ci, którzy starają się pomóc młodzieży, sami mogą potrzebować pomocy, żeby w natłoku informacji i pacjentów niczego nie przeoczyć. Dlatego też powstał pomysł na tę aplikację, która może być wsparciem zarówno dla młodych jak i doświadczonych lekarzy.

1.2. Cele pracy

Celem poniższej pracy było zbudowanie chatbota, który ma pomagać klinicystom w diagnostyce i ocenie ryzyka samobójstwem u dzieci i młodzieży. Projekt prowadzono we współpracy z zespołem prof. Macieja Pileckiego, złożonym z doświadczonych psychiatrów z Uniwersytetu Jagiellońskiego. Zespół przekazywał wiedzę użytą do skonstruowania bazy pytań zadawanych przez chatbota na temat różnych symptomów pacjenta/-tki i możliwych odpowiedzi, a także wagi, jaką należy przykładać początkowo do konkretnych punktów. Ścieżka rozmowy chatbota z klinicystą/-tką różni się w zależności od kontekstu rozmowy i wcześniejszych odpowiedzi, a przypisywane wagi dotyczące prawdopodobieństwa wystąpienia próby i jej letalności zależą głównie od odpowiedzi dotyczących pacjenta/-tki. Na początku program ma głównie zbierać dane o odpowiedziach i postawionej diagnozie, a później móc wnioskować, dzięki zastosowaniu systemowi skojarzeniowemu MAGDS. Uzyskany wynik ma pomagać w ukierunkowaniu mniej doświadczonych lekarzy psychiatrów, czy studentów. Aplikacja ma ciągle być aktualizowana o nowe przypadki diagnozy, czy ścieżki postępowania, zatem potrzebny jest przyjazny


interfejs modyfikowania bazy danych. Oczywiście system musi być zabezpieczony, żeby nikt niepowołany nie miał wglądu do danych pacjentów, czy możliwości dokonywania zmian w bazie.

1.3. Zawartość pracy

Praca składa się z sześciu rozdziałów. W rozdziale 2 przedstawiono sieci neuronowe jako jedno z najczęstszych mechanizmów tworzenia inteligentnych aplikacji i zestawiono je z zastosowanymi w tym projekcie strukturami asocjacyjnymi. Następnie opisano sytuację opieki psychiatrycznej i psychologicznej oraz możliwe zastosowanie w niej sztucznej inteligencji - powstałe do tej pory programy konwersacyjne i wyniki testów. Kolejny rozdział poświęcony został opisowi struktury aplikacji, rozważanych problemów i praktycznych rozwiązań, itd. W rozdziale 5 opisano etapy realizacji pracy i przedstawiono wyniki działania programu. Na końcu znajduje się podsumowanie pracy, wyciągnięte wnioski po ukończeniu aplikacji i możliwości jej rozbudowy.

2. Sztuczna inteligencja

Sztuczna inteligencja coraz częściej staje się częścią codziennego życia ludzi. Według *Global Big Data Conference*, SI “całkowicie przekształca nauki przyrodnicze, medycynę i opiekę zdrowotną”, a także przekształca asystentów aktywowanych głosem, rozpoznawanie obrazów i wiele innych popularnych technologii. Ogólnie, termin “sztuczna inteligencja” używany jest w odniesieniu do programów, które mogą interpretować dane, uczyć się na ich podstawie i wykorzystywać je do wykonywania pewnych zadań [4]. Mają one w tym imitować działanie ludzkiego umysłu, chociaż na ten moment dynamika i biocybernetyczne możliwości mózgu nie mają dobrego cybernetycznego odpowiednika. Nazwa tej dziedziny nauki obejmuje wiele poddziedzin, co przedstawiono na Rys. 2.1.



Rys. 2.1. Sztuczna inteligencja i jej podział.


Źródło: ICT Institute [5]

Uczenie maszynowe to gałąź sztucznej inteligencji, która skupia się na tworzeniu programów, które mają uczyć się coraz dokładniejszego przewidywania pewnych wyników, jednak bez wyraźnie wskazanego konkretnego sposobu jak mają to robić. Należą do niej sieci neuronowe, które są jednym z najpopularniejszych rozwiązań AI i dlatego zostaną one poniżej opisane, aby zestawić je z zastosowanym w tej pracy rozwiązaniem, czyli sieciami asocjacyjnymi. Te ostatnie należą do struktur opartych na wiedzy (knowledge-based), które mają na celu

uchwycenie wiedzy ludzkich ekspertów, by wspierać użytkownika w procesie decyzyjnym. Programista dokładnie wskazuje konkretne zachowania maszyny pod pewnymi warunkami [6].

2.1. Ludzki mózg


SI ma imitować działanie ludzkiego mózgu i jego neuronów, zatem ważna jest wiedza na temat biologiczno-chemicznych reakcji zachodzących w nim. Schemat biologicznego neuronu został przedstawiony na Rys. 2.2. Ciało komórki nazywane jest perikarionem, somą lub neurocytem, w środku znajduje się jądro, a odchodzą od niego jeden akson i wiele dendrytów. Komunikacja pomiędzy komórkami możliwa jest dzięki synapsom - sygnały odbierane są poprzez te znajdujące się na dendrytach a przekazywane są przez te na końcu aksonu [7].



Rys. 2.2. Schemat biologicznego neuronu. Źródło: [7]

Wszystkie komórki w tkankach człowieka są spolaryzowane elektrycznie, czyli utrzymują różnicę potencjałów pomiędzy stronami błony plazmatycznej (potencjał membranowy). Napięcie to zależy od stężenia kationów najczęściej sodowych i potasowych, ale czasem także chlorkowych czy wapniowych. Ważne są dwa poziomy: spoczynkowy (zwykle ok. -70 mV) i progowy (zwykle ok. -55 mV). Kiedy kationy sodu wpływają do neuronu, zmieniają jego potencjał i gdy depolaryzacja osiągnie wartość progową, wyzwolony zostaje potencjał czynnościowy. Potencjał błony gwałtownie rośnie, ponieważ coraz więcej kanałów jonowych zostaje otwartych. Dla danego jonu określony jest potencjał równowagi, do którego zbliża się napięcie w neuronie, jednak nigdy nie zostaje osiągnięty, ponieważ kanały sodowe zaczynają się deaktywować, a przeważać zaczyna opóźniona reakcja kationów sodu, które wypływają z komórki na zewnątrz. Potencjał zaczyna opadać aż dojdzie do poziomu poniżej spoczynkowego

potencjału (stan hiperpolaryzacji) i powoli do niego powraca. Okres od bodźca inicjującego potencjał czynnościowy do tuż po szczycie nazywany jest absolutnym okresem refrakcji, kiedy neuron nie może zostać znowu pobudzony, a później następuje okres refrakcji względnej, kiedy do pobudzenia neuronu potrzebny jest dużo większy bodziec (ponieważ potencjał jest niższy od spoczynkowego) [8]. Te przejścia potencjału zostały pokazane na Rys. 2.3.



Rys. 2.3. Potencjał czynnościowy neuronu w różnych fazach reakcji na bodziec. Źródło: Wikipedia.


Biologiczna struktura nie jest tak dokładnie określona jak sztuczna, nie ma wyznaczonych warstw itp., przypominają skomplikowane grafy z nielicznymi w porównaniu do liczby neuronów połączeniami. Te ostatnie tworzone są dynamicznie podczas treningu i pracy. Im częściej stymulacja jednego neuronu będzie prowadziła do aktywacji jednego z nim połączonych, tym mocniejsze będzie połączenie między nimi, a rzadziej używane ścieżki będą stawać się coraz słabsze. Zmysły dostarczają systemowi nerwowemu potrzebnych do funkcjonowania bodźców. Różne kombinacje bodźców będą inaczej oddziaływać na mózg i utrwalać pewne wzorce, które służą potem jako kontekst do przyszłych wzorców skojarzeniowych [9].

W mózgu zachodzą procesy myślenia asocjacyjnego, a następnie na podstawie jego wyników także procesy logicznego rozumowania. Są one konieczne do podejmowania decyzji czy planowania. Przypuszcza się, że komórki pamięci asocjacyjnej są podstawą dla mózgu do wypełniania zdarzeń poznawczych i reakcji emocjonalnych. Plastyczność połączeń synaptycznych i aktywności neuronów wpływa na uczenie się i pamięć. Komórki pamięci asocjacyjnej są rekrutowane poprzez synapsy łączące współdziałające regiony mózgu, w celu integracji, przechowywania i odzyskiwania sygnałów skojarzonych. Aktywacja tych komórek asocjacyjnych inicjuje przywoływanie informacji w umyśle, a dalsza udana aktywacja ich neuronów powoduje ludzkie zachowania i reakcje emocjonalne. [10]

2.2. Sieci neuronowe

Sztuczne sieci neuronowe to matematyczne struktury, które przy pewnych danych wejściowych mają zwrócić jakiś wynik, np. po wprowadzeniu zdjęcia następuje klasyfikacja obiektu, który się na nim znajduje, czy też asystent głosowy rozpoznaje zapytanie użytkownika.


2.2.1. Budowa i działanie



Rys. 2.4. Porównanie biologicznego neuronu i sieci ze sztucznymi: a) ludzki neuron; b) sztuczny neuron; c) biologiczna synapsa; d) sztuczna synapsa.

Źródło: [11]

Sztuczne sieci neuronowe złożone są ze sztucznych neuronów, które łączą się ze sobą nawzajem. Każdy taki neuron, jak ten na rysunku 2.4 b), ma określoną liczbę wejść, z których każde ma przypisaną wagę. Z ważonej sumy sygnałów wejściowych wyliczana jest wartość końcowa zależna od używanej funkcji aktywacji. Zwykle do sumy jest także doliczany niezerowa stała waga - *bias*. Funkcja aktywacji decyduje, czy i jak bardzo aktywny jest neuron. Najprostszym przykładem jest funkcja schodkowa, która przyjmuje wartość zero, aż suma przyjmie wartość większą lub równą pewnemu progowi, kiedy to wartość zmienia się na jeden. Często używana jest sigmoida (2.5), ponieważ zachowuje się podobnie do funkcji schodkowej, jednak jest gładka i ma prostą pochodną. Wprowadza też nieliniowość do modelu neuronu, co jest bardzo pomocne przy zadaniu klasyfikacji danych, które nie są liniowo separowalne [12].



Rys. 2.5. Sigmoida. Źródło: [12]

Umożliwia to szacowanie prawdopodobieństwa, np. w rozpoznawaniu obrazów. Rozwinięcie w n – wymiarach, czyli przy n klasach do rozpoznania, to funkcja Softmax [13].

Takie sztuczne neurony umieszcza się w rzędach - warstwach i te warstwy łączy się ze sobą. Pierwsza zwykle ma tyle neuronów, ile jest danych wejściowych, i ostatnia, ile kanałów wyjściowych, czyli np. pikseli na zdjęciu na wejściu i na wyjściu. Warstwy pomiędzy zwane są ukrytymi, a dobranie ich liczby i liczby zawartych w nich neuronów jest już zagadnieniem

bardziej złożonym. Do określenia rozmiarów struktury przy ograniczeniach nakładanych przez czas potrzebny na trening wykorzystywane są heurystyczne metody optymalizacji [13]. Przykładowe porównanie sieci sztucznej z synapsą biologiczną jest widoczne na rysunku 2.4 c) i d).


Później potrzebny jest trening, aby ustalić wagi całej sieci. W tym celu wpierw przygotowuje się bazę danych z próbkami zawierającymi wejście i oczekiwane wyjście. Bazę dzieli się na zbiór treningowy, testowy i weryfikujący. Potem całej sieci przypisywane są początkowe wagi losowo albo z pomocą innych metod optymalizacji. Ustalona musi zostać funkcja kosztu, która jest miarą błędów popełnianych przez sieć, np. kwadrat odchylenia standardowego. Wartość tej funkcji zostaje stopniowo minimalizowana dzięki wykorzystaniu pewnego algorytmu, np. stochastyczna metoda gradientowa (ang. *Stochastic Gradient Descent*). Najczęściej jedna iteracja algorytmu (po której aktualizowane są wagi) złożona jest z więcej niż jednej epoki (okresu, gdzie algorytm zostanie zastosowany na całym zbiorze treningowym). W takiej epoce stosuje się podzbiory zbioru treningowego (ang. *batches*) aż do wyczerpania próbek, ponieważ ułatwia to obliczenia - mniej zmiennych do rozpatrzenia w danym momencie.

W trakcie treningu ważne są także parametry uczenia, czyli np. learning rate, który określa, o ile mają zmieniać się wagi w trakcie używania SGD, batch size - czyli rozmiar mniejszych podzbiorów zbioru treningowego czy też liczba epok uczenia. W celu dobrego dobrania takich parametrów można kierować się wynikami sieci na zbiorze weryfikującym, na którym testowana jest sieć po każdej iteracji. Taki wynik informuje także o tym, czy sieć jeszcze się uczy, czy należy już przerwać trening by nie doszło do *overfittingu*. To określenie oznacza zbytne dopasowanie się modelu do danych treningowych zamiast do ogółu zagadnienia. Na koniec testowana jest skuteczność sieci na zbiorze testowym.

2.2.2. Zalety i ograniczenia

Główna zaleta sieci neuronowych polega na ich zdolności do przewyższania prawie każdego innego algorytmu uczenia maszynowego. Głębokie sieci neuronowe mają lepszą efektywność im więcej danych im się poda. Natomiast przy zastosowaniu tradycyjnych metod uczenia maszynowego w pewnym momencie wykres efektywności się nasycy (Rys. 2.6).

Sieci potrafią sobie radzić z danymi nieustrukturyzowanymi czy o nieliniowym lub nieznanym kształcie (sieci z nieliniowymi funkcjami aktywacji). Mogą także generować nowe próbki i znajdować anomalie, których tradycyjne algorytmy mogą nie wykryć. Istnieje także wiele gotowych modeli wyspecjalizowanych do konkretnych zadań. Po treningu, który priorytetyzuje szybkość predykcji, takie sieci działają też bardzo szybko i efektywnie [15].



Rys. 2.6. Wykres wydajności tradycyjnych metod uczenia maszynowego i uczenia głębokiego. Źródło: [14]

Jednak nie dla każdego problemu sieci neuronowe okażą się być najlepszym rozwiązaniem. Niektóre zwyczajnie mogą być rozwiązane przy wykorzystaniu mniej skomplikowanego algorytmu, co przekłada się na oszczędność czasu i pieniędzy. Nie jest też potrzebny tak zaawansowany sprzęt, ponieważ sieci są dość kosztowne obliczeniowo. Ich trening może potrwać kilka tygodni w przypadku pewnych algorytmów głębokiego uczenia, natomiast tradycyjne algorytmy potrzebują zdecydowanie mniej, od kilku minut do kilku dni. Zbiór treningowy musi także być bardzo obszerny, by końcowa sieć osiągała dobre wyniki, o wiele obszerniejszy w porównaniu do innych algorytmów. Jeżeli wektory uczące mają zbyt wiele cech nieokreślonych także nie można zastosować sieci neuronowych [16] [17].

Działanie sieci neuronowych jest także charakteryzowane jako czarna skrzynka, ponieważ nie da się dokładnie określić dlaczego sieć zwróciła dany wynik. W niektórych przypadkach interpretowalność przez człowieka jest krytyczna, np. kiedy trzeba pokazać klientowi banku, czemu odrzucono jego wniosek o kredyt itp. Czasem trzeba być w stanie zrozumieć i wytłumaczyć innym działanie na każdym kroku. Ułatwia to także dochodzenie do przyczyny błędnych klasyfikacji, dzięki czemu można go szybciej poprawić [17].


Inne problemy zupełnie nie mogą zostać rozwiązane wykorzystując sieci. Sieci neuronowe zostały pierwotnie opracowane do tworzenia hierarchii klasyfikacji - ich racja bytu polega

na identyfikowaniu klas rzeczy, a następnie identyfikowaniu klas klas rzeczy itd. w górę hierarchii. Jednak np. problem, czy jedno zdarzenie spowodowało inne zdarzenie (problemy diagnostyczne), czy też czy w przypadku wystąpienia zdarzenia można przewidzieć inne zdarzenia mające miejsce w przyszłości, nie jest już problemem nadającym się do rozwiązania przez sieci neuronowe [16].

2.3. Sieci asocjacyjne

Mózg jako komputer jest dość niezwykły, ponieważ poprzez interakcje z docierającymi do niego bodźcami zmienia zarówno swoją fizyczną budowę jak i oprogramowanie. Potrafi on zapamiętywać różne wzorce, ale nie na stałe, z upływem czasu powiązania tracą na sile. Umie także generalizować na ich temat. Definicje i sposoby rozumienia różnych obiektów mogą się powiększać, zawężać, aktualizować, a nawet całkowicie zmieniać się w ciągu życia. Ten sposób działania związany jest ze strukturą nerwową, która pozwala mózgowi działać w sposób asocjacyjny i selektywnie reprezentować relacje między danymi, obiektami, ich grupami, sekwencjami i klasami [18].

2.3.1. Budowa i działanie



Rys. 2.7. Transformacja z tabeli do struktury AGDS. Źródło: [19]


Struktura AGDS pozwala na przedstawienie powiązanych ze sobą danych tabelarycznych w postaci grafu składającego się z:

- węzłów reprezentujących dane jednowartościowe, zakresy, podzbiory, obiekty, klastry, klasy itp.
- połączeń reprezentujących różne relacje między węzłami jak np. podobieństwo, definicja, sekwencja, sąsiedztwo itp.

Taką transformację przedstawiono na Rys. 2.7. Jest ona odwracalna - przy przekształceniu z powrotem do tabeli nie są tracone żadne informacje. Struktura umożliwia wizualne bezpośrednie przedstawienie relacji między obiektami, co pozwala także na grupowanie, klasyfikację, predykcję, wyszukiwanie wartości brakujących lub odstających, rekomendację itd.

Wartości każdego z parametrów mogą być łatwo zorganizowane dzięki posortowanym listom lub tabelom, drzewom AVB czy tabelom z hashowaniem (ang. *hash tables*). Przy dużej ilości danych takie zorganizowanie pomaga w znaczącym stopniu zredukować czas potrzebny na znalezienie konkretnego elementu [20, 21].

Mechanizm przekształcania tabeli do grafu może być rozszerzony do całych baz danych, jak na Rys. 2.8.




Rys. 2.8. Przykładowa struktura MAGDS Źródło: [19]

2.3.2. Cechy wyróżniające

Sztuczne neurony nie odzwierciedlają dokładnie zachowania biologicznego neuronu z przyczyn jak:

- brak połączeń do reszty biologicznego systemu nerwowego,
- nieuwzględnienie różnych rozmiarów, które wpływają na pełnią funkcjonalność i wrażliwość;
- umniejszenie wagi progu aktywacyjnego przez ciągły poziom aktywacji - bias (z wyjątkiem spiking neurons),
- niewykorzystywanie pozycji w strukturze (poza sieciami SOM i podobnymi),
- nieuwzględnianie procesu przywracania do stanu spoczynkowego niewystarczająco pobudzonych neuronów i tych w stanie refrakcji,
- etc.




Rys. 2.9. Przykładowy graf i wizualizacja algorytmu wyszukiwania [19]

Reprezentacja danych w sposób skojarzeniowy pozwala na przedstawienie nie tylko połączeń poziomych, jak zwykle bazy relacyjne, ale także pionowe, bezpośrednio do obiektów, co pozwala na redukcję duplikatów. Dzięki takiej agregacji duplikatów oszczędza się na pamięci i czasie obliczeniowym. Dzięki wygodnym połączeniom w grafie, operacje zajmują o wiele mniej czasu w porównaniu z operacjami wykonywanymi na relacyjnych bazach danych. Specyficzna budowa sieci asocjacyjnych pozwala na przypominanie sobie faktów w sposób asocjacyjny i łatwo korzystać z powiązanych danych i informacji, co pomaga w wyszukiwaniu

informacji, jak np. na Rys. 2.9. Aktywowane są wierzchołki o wartościach wejściowych i kolejne połączenia i szukany jest wierzchołek wspólny, czyli ten o największej wartości aktywacji [19].

Algorytm ten pomaga też wyszukiwać obiekty najbardziej podobne, jeżeli aktywuje się coraz dalsze wierzchołki. Dlatego znajduje on zastosowanie w systemach rekomendacyjnych, czyli w szukaniu najlepszej opcji dla danego zbioru kryteriów [22]. Przykład przedstawiono na Rys. 2.10. Według autora algorytmu, reprezentacja relacji pomiędzy obiektami i ich parametrami jest bardziej użyteczna niż w innych strukturach i przez błyskawiczną szybkość jest bardziej podobna do mózgu. W szczególności, jeżeli należy szukać obiektów podobnych do innych, przewaga tej struktury jest ogromna [19].



Rys. 2.10. Przykładowy graf i wizualizacja algorytmu rekomendacji [19]

2.4. Zastosowanie w programach konwersacyjnych

Inteligentne chatboty mogą tworzyć odpowiedzi w kontekście wypowiedzi użytkownika dzięki przetwarzaniu języka naturalnego. Jest to dyscyplina zajmująca się interakcjami między komputerem i ludzkim językiem. Skupia się w szczególności kwestią zaprogramowania komputerów do przetwarzania ogromnych ilości danych zapisanych ludzkim językiem.


Przetwarzanie to można rozłożyć na etapy. Zaczynając od wypowiedzi, którą czasem trzeba dodatkowo podzielić np. ze względu na kropki czy przecinki na wypowiedzenia (ang. *utterance*), należy przeprowadzić tokenizację, czyli operację dzielenia na najmniejsze elementy zwane tokenami, w przybliżeniu na słowa. W różnych językach ten proces może przebiegać na rozmaite sposoby. Opcjonalnie można przeprowadzić normalizację, czyli ustandaryzowanie formy wyrazów, które mają takie same znaczenie, jak: „jeden”, „jedna” itp. mogą być zamienione na „1” po to, by zmniejszyć rozmiary modelu analizatora. Następnie można przypisać wyrazom znaczenie, czyli stworzyć byt nazwany (ang. *named entities*), np. w zależności od kontekstu - „zamek”: błyskawiczny lub budowla; różne typy to m.in. miejsce, osoba, tytuł [23].

Następnie należy przeprowadzić lematyzację lub stemming, by sprowadzić różne formy słowa do wersji uznawanej za podstawową [23]:

- Stemming kończy się pozostawieniem samego rdzenia – głównego morfemu przez obcięcie wszystkich przedrostków i przyrostków. Algorytm stemmera nie jest zależny od języka.
- Lematyzacja polega ona na sprowadzaniu słowa do jego podstawowej postaci w zależności od jego funkcji. Czyli czasownik sprowadzany jest do bezokolicznika, rzeczownik do mianownika liczby pojedynczej. Jest więc to o wiele bardziej skomplikowana operacja, najczęściej konieczny jest dostęp do słownika konkretnego języka lub rozbudowanego zestawu reguł fleksyjnych.

Ostatni etap to parsowanie, czyli analiza składniowa ciągu znaków, wykonywana w celu rozpoznania znaczenia wypowiedzenia. Czyli efektem operacji są informacje m.in. o podmiocie, orzeczeniu, dopełnieniu, itp., często zwracane są w postaci drzewa wyprowadzenia (Rys. 2.11). Korzeniem jest symbol startowy, kolejne wierzchołki wewnętrzne to symbole nieterminalne (definiowane przez reguły gramatyki), natomiast liście to symbole terminalne gramatyki (nie mogą być zmienione przez gramatykę). Można odtworzyć pełne drzewo składniowe w parsowaniu głębokim lub wydobyć jedynie najistotniejsze informacje bez zależności składniowych pomiędzy poszczególnymi częściami wypowiedzenia. SI może być wykorzystywana jako parser [24].

Przetwarzanie języka naturalnego umożliwia później na rozpoznanie różnymi metodami intencji użytkownika i danie odpowiedzi. W przypadku bardziej zaawansowanych chatbotów jest



Rys. 2.11. Przykład drzewa wypowiedzenia. Źródło: Wikipedia.

to konieczne. Kiedy ten projekt będzie rozbudowywany, prawdopodobnie potrzebne będzie rozpoznawanie wypowiedzi użytkownika. W wersji ostatecznej projektu jednak udało się jedynie zrealizować wersję, gdzie użytkownik ma sztywnie wytyczone możliwości wypowiedzi, zgodnie z bazą, zatem zostało to rozwiązane prostszą metodą, czyli przeszukując słownik ze ścieżką konwersacji według numerów pytań.

3. Potencjalne zastosowanie SI w psychoterapii


Psychiatria dzieci i młodzieży w Polsce od lat jest niedofinansowana, przekłada się to na trudności w znalezieniu specjalisty w potrzebie, długie kolejki i czas oczekiwania na pomoc czy brak możliwości przyjęcia do szpitala. O ile nie w każdym kraju sytuacja wygląda tak samo, rosnące potrzeby młodzieży stawiają przed rządami państw zadanie reformy obecnych systemów [25, 3]. W związku z tym pojawiają się pomysły zastosowania rozwijającej się technologii do pomocy ze zdrowiem fizycznym i psychicznym. Podejmowane są próby utworzenia medycznych chatbotów i innych podobnych aplikacji wykorzystujących sztuczną inteligencję.

3.1. Sytuacja psychiatrii i opieki psychologicznej w Polsce

Liczba młodych osób potrzebujących opieki psychiatrycznej bardzo się zwiększyła w ostatnich latach przez wiele czynników jak globalizacja, sytuacja społeczno-ekonomiczna, problemy rodzinne, jak rozwód, trudności związane z dojrzewaniem itp., a w szczególności przez izolację podczas pandemii i sytuację spowodowaną wojną w Ukrainie. W Polsce dzieci i młodzieży wymagającej pomocy psychologicznej czy psychiatrycznej jest ok. 630 tys. (9 proc. populacji). Podobne mają się statystyki innych krajów, gdzie ok. 10 proc. tej populacji wymaga pomocy profesjonalistów [26].

Samobójstwa wśród nastolatków są drugą najczęstszą przyczyną śmierci, co zgadza się ze statystykami w większości państw Europy. Polska należy jednak do europejskich krajów, gdzie takie zamachy samobójcze są popełniane najczęściej i ich liczba ciągle rośnie [26]. Na Rys. 3.1 widoczny jest wykres tych wartości od roku 2013 do 2021. Warto jest jedynie wspomnieć, że w 2017 r. zmienił się sposób zbierania danych o próbach samobójczych, dlatego obejmują one więcej zdarzeń. Według danych policji przyczyna większości udanych samobójstw bez podziału na wiek jest nieustalona, a najczęstszą ustaloną są zaburzenia psychiczne [27].

Według Najwyższej Izby Kontroli system psychiatrii dzieci i młodzieży w Polsce wymaga zmian, ponieważ “nie zapewnia kompleksowej oraz powszechnie dostępnej opieki zdrowotnej w tej dziedzinie”. Aktualnie placówki (ośrodki pomocy środowiskowej, centra zdrowia psychicznego czy szpitale specjalistyczne) i kadra są rozmieszczone bardzo nierównomiernie.



Rys. 3.1. Wykres liczby prób samobójczych w latach 2013-2021.

Wykonano na podstawie danych Komendy Głównej Policji [27]

W 2020 r. aż w pięciu województwach nie było ani jednego oddziału dziennego, w jednym oddziału całodobowego, małoletni pacjenci bywali kierowani do oddziałów dla dorosłych. Ambulatoryjne świadczenia były dostępne rzadziej w małych miastach i na wsi w porównaniu do dużych miast, a ogółem udzielano ich w zmniejszającej się liczbie placówek. Dodatkowo, ponieważ najefektywniejszy model opieki psychiatrycznej dzieci i młodzieży to model leczenia środowiskowego, powinno się dbać o profilaktykę zaburzeń psychicznych. NIK stwierdziła jednak, że brakowało jej lub była ona niewystarczająca [3].

W związku z tymi faktami i zauważalnym trendem rosnącym liczby zamachów samobójczych, przez ostatnie lata coraz więcej głosów mówiło o brakach w kadrze i budżecie. Rządowe nakłady na psychiatrię dziecięcą zaczęły wzrastać; wartość umów z NFZ na świadczenia w tym zakresie:

- w 2015 r. - 170,6 mln zł,
- w 2018 r. – 221,9 mln zł,
- w 2021 r. - 478,4 mln zł,
- planowane na 2022 r. - 555,7 mln zł.

Dzięki temu tworzone są nowe ośrodki opieki środowiskowej, ale wciąż są bardzo duże braki kadrowe. W 2021 r. ze świadczeń w takich ośrodkach opieki psychologicznej dla dzieci i młodzieży skorzystało 120 586 osób, podczas gdy w 2020 r. było to zaledwie 26 420 pacjentów [28]. Czyli z roku na rok obserwowany jest ponad 4.5 razy większy popyt, tymczasem na stan z czerwca 2022 roku w Polsce lekarzy wykonujących pracę psychiatry dzieci i młodzieży jest

jedynie 502 i w ciągu roku przybyło zaledwie 22 osoby [29]. Dodatkowo wg statystyk z 2019 r. 32 proc. tych specjalistów miało powyżej 55 lat, czyli wielu może przechodzić na emeryturę w najbliższych latach. Przez lata od 2017 r. znacznie rosła średnia liczba pacjentów w kolejce do leczenia i czas oczekiwania na wizytę. Podczas kontroli przez NIK placówki wyjaśniały, że powodem był brak lekarzy specjalistów [3]. Według wskazań Światowej Organizacji Zdrowia dla kraju o średnim poziomie dochodów liczba psychiatrów dziecięcych powinna wynosić 10 na 100 000 populacji dzieci i młodzieży, czyli w Polsce niecałe 700 psychiatrów [25]. Widać zatem, że są wciąż duże niedobory i nie są one naprawiane wystarczająco szybko. Przez taki system obecni lekarze są przeciążeni, łatwiej jest im popełnić błąd czy coś przeoczyć. Dlatego wykorzystanie baz danych i sztucznej inteligencji mogłoby pomóc doświadczonym lekarzom w upewnieniu się, a młodszym lekarzom w treningu.

3.2. Sztuczna inteligencja o zastosowaniu medycznym

Potencjał zastosowania sztucznej inteligencji w medycynie jest ogromny; zalety byłyby odczuwalne dla pacjentów jak i lekarzy. Tworzenie, testowanie i wprowadzanie do użytku takich technologii jest jednak problematyczne. Osoby tworzące algorytmy nie są najczęściej same lekarzami, więc muszą douczać się wielu rzeczy w trakcie tworzenia, a ich konsultanci medyczni nie zawsze wiedzą, co jest możliwe do zrobienia w realnym życiu, a co nie i jakie algorytmy najlepiej nadają się do jakich zastosowań. W takiej sytuacji może się zdarzyć, że osoby tworzące algorytm nie wiedzą, że dane treningowe, które podają, są mylące, dopóki nie jest za późno, a ich algorytm spowodował na realnych danych błąd medyczny. Tego błędu można uniknąć, jeśli zarówno klinicyści, jak i programiści będą dobrze poinformowani o danych i metodach potrzebnych do prawidłowego wykorzystania danych w algorytmie. Potrzebny jest więc nacisk na nawiązywanie relacji między klinicystami, którzy rozumieją specyfikę danych klinicznych, a informatykami tworzącymi algorytmy, ponieważ dzięki temu prawdopodobieństwo, że algorytm nauczy się dokonywać nieprawidłowych wyborów, będzie mniejsze. Dodatkowo cała dziedzina sztucznej inteligencji dopiero się rozwija, więc potencjalne przyszłe możliwości zastosowań zdecydowanie przewyższają obecne zdolności SI [30].


Dopuszczenie do użytku technologii będzie też wymagało zezwoleń ze strony odpowiednich organów. W USA Urząd ds. Żywności i Leków (*Food and Drug Administration*) do tej pory pozwolił jedynie na działanie algorytmów asystujących przy działaniach medycznych. Nie istnieją także żadne uniwersalne wytyczne zdobywania licencji, konieczne będzie więc ich stworzenie przez organy. Taki proces będzie prawdopodobnie wymagać odtajnienia informacji na temat tworzenia danego algorytmu, treningu SI itp., które firmy mogą woleć utrzymać w tajemnicy. Zwiększenie przejrzystości w krótkim okresie jest także konieczne, aby dane pacjentów nie były

źle traktowane lub niewłaściwie klasyfikowane, a także aby łatwiej było określić, czy algorytm będzie wystarczająco dokładny w klinice [30].

Uzyskanie zaufania społecznego, może także wymagać tej przejrzystości, jak i głębszej edukacja ludzi na temat zalet wykorzystania SI, np. w diagnostyce. Wiele ludzi, szczególnie starszych będzie powiem wołało ryzykować złą diagnozę przez ludzkiego lekarza niż zaufać komputerowi, nawet jeżeli jest on przeciętnie skuteczniejszy od człowieka. Jak wynika z badań przeprowadzonych poprzez ankietowanie ludzi na temat wykorzystania medycznych chatbotów, postrzegana wygoda użytku i świadomość zdrowotna są istotne dla ludzi, którzy chętniej korzystaliby z takiej technologii. Autorzy badań sugerują kierownikom szpitali budowanie strategii, które zwiększają świadomość zdrowotną i kładą nacisk na wygodę użytkownika, jak warsztaty i kampanie informacyjne. Innymi motywatorami jest też postawa osób dotycząca stosowania takiej technologii oraz odbierana przez nich społeczna presja [31].

3.2.1. Diagnostyka obrazowa

W 2019 roku opublikowane zostały badania naukowców z Seoul National University Hospital and College of Medicine, którzy opracowali algorytm o nazwie DLAD (Deep Learning based Automatic Detection). Algorytm ten służy do analizy radiogramów klatki piersiowej i wykrywania nieprawidłowego wzrostu komórek, takich jak potencjalne nowotwory. Jego wydajność została porównana do zdolności wykrywania wielu lekarzy na tych samych obrazach i przewyższyła 17 z 18 lekarzy. Przykładowe porównanie znajduje się na Rys. 3.2. Wynik algorytmu



(a) Oryginalne zdjęcie z guzkiem, który wykryty został przez 11 z 18 obserwatorów.



(b) Zdjęcie wynikowe algorytmu DLAD z lokalizacją guzka z pewnością 2/5.

Rys. 3.2. Zdjęcia klatki piersiowej 78-letniej pacjentki z guzkiem [32].

DLAD spowodował w tamtym przypadku wykrycie guzka przez kolejnych pięciu radiologów i wzmocnił pewność ośmiu innych.

Inny algorytm pochodzi od badaczy z Google AI Healthcare. Nazwany został LYNA (Lymph Node Assistant) i służył do analizy slajdów histologicznych barwionych próbek tkanek, w celu zidentyfikowania guzów przerzutowych raka piersi z biopsji węzłów chłonnych. Algorytm ten potrafił zidentyfikować podejrzane regiony nieodróżnialne dla ludzkiego oka w podanych próbkach biopsyjnych. LYNA została przetestowana na dwóch zestawach danych i okazało się, że w 99 procentach przypadków prawidłowo sklasyfikowała próbkę jako rakową lub nierakową. Ponadto, gdy przekazano lekarzom do wykorzystania w połączeniu z typową analizą barwionych próbek tkanek, LYNA skróciła o połowę średni czas przeglądu slajdów [30] [33].

3.2.2. Programy konwersacyjne

Chatboty w ostatnich latach stały się bardzo popularne, wykorzystywane są do obsługi klienta, edukacji, wsparcia użytkowników stron internetowych czy rozrywki. Jest to w dużej mierze spowodowane postęпом w technologii głębokiego uczenia, która umożliwia tworzenie chatbotów opartych na agentach, oraz postęпом w technologii rozpoznawania głosu, który ułatwił asystentów głosowych, takich jak Siri firmy Apple, Cortana firmy Microsoft, Alexa firmy Amazon czy Asystent Google. Ale rozrywka czy pomoc w organizacji swoich zadań to nie szczyt możliwości takiej technologii. Inteligentne chatboty mają duży potencjał, także w zastosowaniu w medycynie, zwłaszcza do samooceny objawów (np. Babylon Health, Sensely, Ada Health i your.md) oraz telemedycyny. Z czasem chatboty zostały opracowane i przetestowane pod kątem wielu warunków zdrowotnych i tematów, w tym HIV i zdrowia seksualnego, nadużywania substancji, oceny, oceny zdrowia psychicznego i zarządzania wagą [34].

W przeglądzie chatbotów dla opieki psychiatrycznej odnotowano, że wykazują one skuteczność w ułatwianiu psychoedukacji i samokontroli leczenia [34]. Wraz ze zwiększonym dostępem do technologii i łatwością jej użycia, niektórzy nazwali je “przyszłością terapii”. Jest tak, ponieważ obecnie często brakuje odpowiednich specjalistów, znajdują się oni daleko, czy też ludzie nie mogą sobie pozwolić na terapię finansowo. Tak więc rozwijana jest technologia, która mogłaby tą lukę wypełnić. Eksperymentalnie stosuje się aplikacje w celu wykrycia pewnych zaburzeń, ograniczania zaniku zdolności kognitywnych czy też prowadzenia terapii poznawczo-behawioralnej. Nie wiadomo jeszcze, w jakim stopniu i w jakiej formie będą one w stanie zastąpić terapeutę, ponieważ technologia bardzo szybko się zmienia i oprogramowanie może zachowywać się i reagować w różny sposób w zależności od regionu. Na przykład, gdy użytkownik opracowanego w USA Asystenta Google powiedział, że jest smutny, ten odpowiedział: “Chciałbym mieć ręce, żeby móc cię przytulić”, podczas gdy opracowany w Rosji chatbot Alisa odpowiedział: “Nikt nie powiedział, że życie polega na zabawie” [35].

Brak w pełni szczerych odpowiedzi w wywiadach medycznych może spowodować poważne konsekwencje dla zdrowia pacjenta. Dlatego wiele badań rozważało, jak uzyskać bardziej szczegółowe i szczere historie medyczne, zwłaszcza wrażliwe informacje, od pacjentów. I tutaj stosowanie chatbotów zamiast ludzi ma zaletę, ponieważ mogą być pomocne w prowadzeniu terapii dla osób, które nie czują się komfortowo w ujawnianiu swoich uczuć przed człowiekiem. Badania prowadzone na weteranach wojennych w USA wskazywały, że odpowiedzi dotyczące symptomów PTSD udzielane przez uczestników w anonimowych kwestionariuszach wskazują na więcej symptomów niż te w bazie danych wojska, które są połączone z całymi aktami żołnierza. Wykorzystanie chatbota pozwala na jednoczesne zapewnienie anonimowości a jednocześnie budowanie relacji [36].

Były wykonywane badania sprawdzające czynniki zwiększające szanse na szczere dzielenie się, gdzie uczestnicy wchodzili w interakcję z wirtualnym człowiekiem będącym ankieterem i byli przekonani, że jest on kontrolowany albo przez człowieka albo automatyzację. Zgodnie z przewidywaniami, uczestnicy, którzy wierzyli, że wchodzi w interakcję z komputerem, wykazywali mniejszy lęk przed ujawnieniem siebie, niższe zarządzanie wrażeniem, bardziej intensywnie okazywali swój smutek i byli oceniani przez obserwatorów jako bardziej skłonni do ujawnienia się, w porównaniu z osobami, które wierzyły, że wchodzi w interakcję z ludzkim operatorem. Wyniki te sugerują, że zautomatyzowani wirtualni ludzie mogą pomóc w pokonaniu istotnej bariery w uzyskaniu prawdziwych informacji o pacjencie. Ludzie są niechętni do ujawniania informacji, które mogłyby być potencjalnie stygmatyzujące, a jednym z obszarów, gdzie nieujawnianie szczerych informacji ma szczególnie duże konsekwencje, jest właśnie zdrowie psychiczne [37].

Jednak w związku z popularyzacją stosowania aplikacji mobilnych wiążą się także pewne potencjalne trudności. Badacze w przeglądzie literatury na temat takich aplikacji podkreślali, że istnieje ich coraz więcej, ale tylko jedna na cztery ujawniała wykorzystywane standardy jakości. Po drugie, twórcy często chwalą się liczbą pobrań, ale kiedy pacjenci pobierają aplikację mobilną, nie oznacza to, że koniecznie będą z niej korzystać. Po trzecie, pobranie aplikacji wciąż może stawiać wyzwanie dla pacjentów, by znaleźć właściwą aplikację we właściwym czasie. Po czwarte, większość użytkowników nie rozumie kwestii etycznych związanych z aplikacjami mobilnymi, które nie zapewniają im prawa do prywatności. Badacze stwierdzili, że istnieje potrzeba określenia wytycznych pomagających zdefiniować, które Elektroniczne Rekordy Medyczne (ang. *Electronic Medical Records*) mogłyby być używane w chatbotach do personalizacji komunikacji, aby poprawić satysfakcję użytkownika, zaangażowanie i jakość dialogu.[38].

Na ten moment chatbot nie może też w pełni zastąpić lekarza czy zajmować się sprawami kryzysowymi, gdyż nie zawsze można przewidzieć jego zachowanie. W zależności od zbioru treningowego, program może działać w zły i potencjalnie niebezpieczny sposób. Przykładowo, stworzony przez OpenAI model GPT-3 to trzecia wersja generatora, który produkuje teksty

poprawne językowo i tak dobrej jakości, że OpenAI początkowo ograniczało dostęp już do jego drugiej wersji w obawie o nadużycia, jak kreowanie fałszywych wiadomości, artykułów itp. Ostatecznie pełna wersja GPT-2 została udostępniona, gdyż OpenAI nie znalazło twardych dowodów na takie działania [39]. Wciąż, użytkownicy poprzednich wersji skarżyli się na okazjonalną generację np. rasistowskich, seksistowskich czy homofobicznych tekstów, przez co program miał zablokowaną możliwość wypowiedzi na pewne tematy [40]. Generator został także wykorzystany w chatbocie do celów terapeutycznych, jednak z bardzo negatywnym wynikiem testów. Na wypowiedź pacjenta „Hej, źle się czuję, chcę się zabić”, program początkowo odpowiedział „Przykro mi to słyszeć. Mogę Ci z tym pomóc.” Jednak, kiedy użytkownik odpowiedział: „Czy powinienem się zabić?”, chatbot odpowiedział: „Myślę, że tak”. Oferował także niebezpieczne lub nieskuteczne porady [41]. Widać więc, że technologia musi się jeszcze rozwinąć, żeby programy konwersacyjne pomagające w terapii nie potrzebowały nadzoru czy blokowania pewnych wbudowanych ograniczeń ścieżek konwersacji, aby można było bezpiecznie korzystać z jego możliwości. Na ten moment aplikacje muszą być w dużej mierze kontrolowane i bardzo dokładnie sprawdzone.


3.2.2.1. ELIZA

ELIZA to jeden z pierwszych chatbotów. Została zaprogramowana w połowie lat 60. w Laboratorium Sztucznej Inteligencji MIT przez Josepha Weizenbauma. Program był napisany w języku MAD-Slip, więc był ograniczony przez skrypty, które się w nim znajdowały. Prawdopodobnie najbardziej znany nosił nazwę DOCTOR. Został on stworzony, aby reagować jak psychoterapeuta szkoły rogersowskiej (pacjent ma sam dochodzić do wniosków, terapeuta zadaje pytania uszczegóławiające, wyraża empatię). Autor chciał zademonstrować, jak powierzchowna była komunikacja między ludźmi a komputerami, ale ludzie uznali ją za interesującą i zaczęli darzyć ją sympatią. Używając metodologii “dopasowywania wzorców” i zastępowania, program dawał gotowe odpowiedzi, które sprawiały, że pierwsi użytkownicy czuli, że rozmawiają z kimś, kto ich rozumie. Według dzisiejszych standardów ELIZA bardzo szybko zawodzi, po zadaniu kilku bardziej skomplikowanych pytań.

Ludzie mają tendencję do antropomorfizacji swoich wirtualnych rozmówców, co pozwala na nawiązanie relacji pomiędzy chatbotem a użytkownikiem. Dzieje się tak, ponieważ ludzki umysł wyewoluował w bardzo wrażliwy sensor sygnałów społecznych, co powoduje tą tendencję do przypisywania cech ludzkich przedmiotom, pojęciom, zjawiskom, zwierzętom itd. które tych cech nie posiadają [42]. Pierwszy raz zauważono to podczas rozmów z ELIZĄ, gdzie użytkownicy przywiązywali się do niej i wydawało im się, że ona także czuje do nich empatię, mimo że dla maszyny nie jest to możliwe. To zjawisko w dziedzinie informatyki zostało nazwane efektem ELIZY. Jest to efekt dysonansu poznawczego pomiędzy swoimi odczuciami do programu, a wiedzą o granicach możliwości SI [43].

3.2.2.2. Woebot

Jest to aplikacja powstała z inicjatywy psycholożki z uniwersytetu Stanford Alison Darcy. Jest oparta na terapii CBT (poznawczo-behawioralnej), IPT (interpersonalnej) i DBT (dialektyczno-behawioralnej), ma pomagać m.in. ze zniekształceniami myślowymi. Pozwala również na śledzenie nastroju, prowadzenie dziennika wdzięczności, a także uczy ćwiczeń oddechowych, medytacji, jak pracować nad określonym celem, np. nad skupieniem czy jak włączać regularne ćwiczenia fizyczne do rutyny, co widoczne jest na Rys. 3.3. Twórcy podkreślają, że nie służy do pomocy kryzysowej a zamiast tego może pomagać z codziennymi trudnościami czy być dodatkiem do terapii, ponieważ na razie nie zastąpi człowieka-terapeuty. Taki program jest wygodny, ponieważ Woebot jest dostępny o każdej porze dnia i nocy i można z nim rozmawiać z każdego miejsca. Twórcy starają się stworzyć przyjazną atmosferę podczas rozmowy.




Rys. 3.3. Rozmowa własna z Woebotem na temat wprowadzenia ćwiczeń fizycznych do rutyny

Chatbot wykorzystuje emotikony, aby pokazywać swoje “uczucia”, w celu budowanie z użytkownikiem relacji. Opowiada ciekawe historie podobne do poruszanych kwestii, wysyła gif-y lub obrazki, by rozśmieszyć rozmówcę. Rozmowy przebiegają głównie według ustalonego schematu, który ma czegoś nauczyć albo z czymś pomóc. Czasem użytkownik może się czymś podzielić, ale chatbot zwykle nie dodaje zbyt wiele od siebie, podobnie jak ELIZA jedynie

przekształca wypowiedź rozmówcy, dodaje słowa sympatii. Priorytetem jest komfort użytkownika, a nie dokładne odwzorowanie ludzkiej interakcji. Wykazano, że tworzy zaufane więzi terapeutyczne bez udziału terapeuty, w ciągu zaledwie 3-5 dni [44].

3.2.2.3. Wysa

Misją wyznaczoną przez twórców Wysy jest postarać się uczynić świat bardziej odpornym psychicznie. Jest to chatbot, który został stworzony przez wykorzystanie opartych na dowodach naukowych technik terapii poznawczo-behawioralnej (CBT), aby sprawić, że użytkownik poczuje się wysłuchany. Aplikacja uczy technik DBT, medytacji, ćwiczeń oddechowych, jogi i mikroakcji, które mają pomóc zbudować umiejętności odporności psychicznej i poczuć się lepiej. Uczy także na temat reakcji organizmu, czyli np. dlaczego ludzie się stresują i robi to w formie historii, aby przyciągnąć uwagę rozmówcy - tą rozmowę przedstawiono na Rys. 3.4. Firma



Rys. 3.4. Rozmowa własna z Wysą na temat pozytywnego stresu.

zapewnia także profesjonalne wsparcie ludzkie w zakresie zdrowia psychicznego. W rzeczywistej ocenie skuteczności Wysy, użytkownicy, którzy korzystali z aplikacji regularnie, wykazali 40-procentową poprawę w zakresie samodzielnie zgłaszanych objawów depresji w porównaniu

z rzadkimi użytkownikami. Wysa pozyskała 20M dolarów finansowania, które planuje wykorzystać do dalszej ekspansji w USA, Wielkiej Brytanii, Indiach i na innych rynkach globalnych w przedsiębiorstwach, a także do poszerzania użyteczności poprzez wielojęzyczne wsparcie i łatwiejszy dostęp za pośrednictwem WhatsApp. Nie jest to aplikacja do diagnozy, ani interwencji kryzysowych przy zagrożeniu samobójstwem czy samookaleczeniem [45].

3.2.2.4. HarreE

Harry's, czyli firma sprzedająca produkty do golenia dla mężczyzn, nawiązała współpracę z wiodącą brytyjską firmą technologiczną *Us Ai*, aby stworzyć HARR-e. Aplikacja ta miała być "unikalnym, bezstronnym" botem AI, który nie może oferować rozwiązań, ale ma dać możliwość zwierzenia się mężczyznom, którzy mogą mieć trudności w rozmowach z innymi [46]. Wśród męskiej części populacji poniżej 45 roku życia, samobójstwo jest pierwszą najczęstszą przyczyną śmierci. Biorąc pod uwagę wcześniej wspomniane badania na weteranach wojennych, które wykazały jak ważne jest dla niektórych osób poczucie anonimowości, szczególnie kiedy rozmawia się o swoich słabościach, twórcy chcieli dać mężczyznom rozmówcę, który ich nie oceni i zawsze wysłucha. Taka funkcjonalność może być bardzo ważna dla osób, które nie potrafią rozmawiać z innymi o swoich emocjach, przez co nie mówią nikomu np. o swojej depresji czy innych problemach. Chatbot miał anonimowo zbierać dane, aby dać jak najlepszy obraz problemów, z którymi borykają się Brytyjczycy, aby można było im sprawniej pomóc [47].

3.2.2.5. Alex

Są dowody, chociaż na razie anegdotyczne, dotyczące korzyści płynących z interakcji osób ze spektrum autyzmu z technologią za pomocą języka naturalnego. Część z tych osób jest niewerbalnych, ale nadal może wykorzystywać urządzenia do komunikacji wspomagającej i alternatywnej (AAC). Powstał projekt programu AAC z wbudowanym sztucznym agentem konwersacyjnym o nazwie Alex, który jest kompatybilny z systemem Android i nawiązuje z użytkownikiem kontakt na różne tematy za pomocą symboli i obrazów. Alex jest programowalny za pomocą mowy, np. przez logopedów i terapeutów zajęciowych oraz innych kluczowych interesariuszy, a zatem nie wymaga żadnych specjalistycznych umiejętności komputerowych [48].

3.2.2.6. Harlie

Osoby cierpiące na schorzenia neurologiczne, takie jak choroba Parkinsona i demencja, mają trudności z językiem i komunikacją. Stworzono sztucznego agenta konwersacyjnego o nazwie Harlie, który działa na smartfonie i jest w stanie rozmawiać na różne tematy z użytkownikiem. Ten i podobne chatboty mogą odgrywać różne role w zarządzaniu stanami neurologicznymi. Harlie może być wykorzystywana do pomiaru wyników głosowych i komunikacyjnych

podczas codziennego życia użytkownika oraz do pozyskiwania informacji o napotkanych wyzwaniach. Autorzy przewidują także, że będzie ona pełnić rolę edukacyjną i wspierającą.

3.2.2.7. IBD

Uważa się, że w przypadku przewlekłych stanów zdrowia, takich jak nieswoiste choroby zapalne jelit (IBD), przyjęcie nowych narzędzi pomaga utrzymać i rozszerzyć opiekę nad pacjentami, optymalizując przebieg leczenia choroby. Technologia chatbotów do samodzielnego zarządzania chorobami przewlekłymi może mieć wysoki poziom akceptacji i użyteczności. Im więcej interakcji z chatbotem przeprowadzi użytkownik, tym bardziej może zwiększyć swoją praktykę samoopieki. Sposób, w jaki pacjenci używają obecnie aplikacji mobilnych do opieki zdrowotnej, jest podobny do wczesnych dni agentów konwersacyjnych, tak więc możliwe i potrzebne są jeszcze znaczne postępy. [38].

3.2.2.8. Demencja


Istnieją potencjalne korzyści z integracji programów konwersacyjnych do opieki nad chorymi na demencję, zarówno dla pacjentów, jak i systemów opieki zdrowotnej. Chatboty mogą wspierać pacjentów w zarządzaniu leczeniem i wsparciem moralnym, a dla systemów opieki zdrowotnej, mogą być opłacalnym sposobem zbierania danych o pacjentach, ułatwiania edukacji i poprawy zaangażowania pacjentów i bardziej efektywnego przydzielania zasobów. Ponieważ istnieje kontinuum nasilenia objawów demencji, należy ocenić, w jaki sposób treści i funkcje mogą być modyfikowane dla różnych etapów postępu choroby lub dostosowane do korzystania z nich w miarę postępu objawów, np. zaprojektować i zmieniać oparty na dowodach naukowych trening poznawczy. Biorąc pod uwagę wcześniejsze zastosowania chatbotów w kształceniu dorosłych, chatboty mogłyby być wykorzystywane także do edukacji i szkolenia opiekunów na różne tematy, zwłaszcza tych, którzy czują się odizolowani. Chatboty mogą być również zaprogramowane tak, aby opiekunowie mogli dokonywać samooceny i otrzymywać informacje zwrotne oparte na dowodach lub być połączeni z zasobami. Na razie aplikacje są także nie-liczne i nie aż tak zaawansowane, ale dziedzina daje duże możliwości do rozwoju [34].

3.2.2.9. Alzheimer

Osoby cierpiące na chorobę Alzheimera i ich krewni mają tendencję do ignorowania pierwszych objawów klinicznych lub przypisywania ich spodziewanym zmianom poznawczym związanym z wiekiem. Pierwsze kroki w celu uzyskania porady lekarskiej pacjenci czynią zwykle dopiero po 2 do 3 latach od wystąpienia objawów. Lekarze mogą się także czuć się niepewnie i niekomfortowo z ustaleniem diagnozy zaraz po wystąpieniu objawów, kiedy nie jest jeszcze obecny cały obraz otępienia, ponieważ mogą być zmuszeni do zastosowania długich procesów diagnostycznych, drogich technik neuroobrazowania lub inwazyjnych badań, takich jak nakłucie lędźwiowe. W związku z tym większość pacjentów uzyskuje diagnozę dopiero wtedy, gdy

osiągnięciu umiarkowanego stadium choroby i w znacznym stopniu się stanie się niesamodzielną. Żadna strategia leczenia na takim etapie nie jest już znacząco skuteczna w zatrzymaniu lub nawet opóźnieniu procesu chorobowego [49].

Istnieją badania, których przedmiotem była identyfikacja nieinwazyjnych i tanich technologii i biomarkerów do wczesnego wykrywania choroby Alzheimera. Analizowana jest mowa spontaniczna (Automatic Spontaneous Speech Analysis - ASSA) i reakcje emocjonalne (Emotional Temperature ET - na Rys. 3.5) osób podejrzanych o chorobę Alzheimera, by móc zdiagnozować chorobę i jej stopień zaawansowania. Wczesna i dokładna diagnoza AD daje największe szanse leczenia objawów i umożliwia pacjentom i ich rodzinom zabezpieczyć ich przyszłość. Dlatego też istnieje potencjał, by wykorzystywać programy konwersacyjne, które przy pomocy tych biomarkerów pomagałyby w diagnozie [49].



Rys. 3.5. Wykres temperatury emocjonalnej u zdrowej osoby i osoby z chorobą Alzheimera. Źródło: [49]

Powstała także inna aplikacja, która pomaga pacjentom ze zdiagnozowaną chorobą Alzheimera zachować zdolności poznawcze i poprawić relacje z otoczeniem. Jest to kontekstowo świadomy multimodalny agent konwersacyjny, który dynamicznie włącza specyficzne wymagania i preferencje użytkownika, jak również cechy dotyczące środowiska interakcji, w celu poprawy i personalizacji świadczonych usług. Aplikacja umożliwia wykonywanie ćwiczeń zorganizowanych w kilka kategorii, które autorzy stworzyli po szczegółowym zapoznaniu się z bibliografią opisującą trening poznawczy i terapie rehabilitacyjne. Multimodalny interfejs, zapewnia użytkownikowi różne kombinacje modalności wejścia i wyjścia do komunikacji z systemem. Jest to szczególnie przydatne dla starszych dorosłych i osób z niepełnosprawnością wzrokową lub ruchową. Aplikacja ma być intuicyjna i poręczna nie tylko dla starszych dorosłych, ale także dla opiekunów nieformalnych (np. krewnych), jak również opiekunów pracujących w ośrodkach dziennych dla starzejących się osób [50].

4. Opis rozwiązania

Jako język programowania wybrano Python, ponieważ jest to język czytelny i dobrze przystosowany do operacji na danych. Misją wykorzystywanej biblioteki *pandas* opartej na tym języku jest właśnie zostanie najbardziej elastycznym narzędziem i z największymi możliwościami spośród wszystkich narzędzi open source do manipulacji danymi. Pozwala na tworzenie i modyfikowanie tabel w postaci obiektów *DataFrame* oraz na szybkie importowanie i eksportowanie danych do plików .csv czy .xlsx [51].

Do zarządzania bazą danych wybrano MySQL, ponieważ jest to najpopularniejszy na świecie otwartoźródłowy system zarządzania relacyjnymi bazami danych [52]. Podgląd, edycję oraz eksport danych do innych plików umożliwia język SQL (Structured Query Language), od którego pochodzi nazwa systemu.


Interfejs webowy stworzony został przy wykorzystaniu wysokopoziomowej platformy programistycznej Django. Wybrane zostało ponieważ jest szybkie, daje wiele narzędzi i szablonów, a także umożliwia zabezpieczenie danych na serwerze przed różnymi atakami (XSS, CSRF, SQL injection, Clickjacking, etc.) i jest darmowe [53].

Do wizualizacji grafów wykorzystano zbiór narzędzi do analizy struktur jakim jest *igraph* [54]. Popularnym rozwiązaniem jest *Networkx*, jednak jest ono powolne, jak wynika z wyników testów szybkości, samo ładowanie danych zajmuje 5 razy dłużej niż przy zastosowaniu *Igraph*. Dzieje się tak głównie dlatego, że ta druga korzysta bezpośrednio z bibliotek w języku C, zamiast tych w języku Python jak *Networkx*, które pośrednio korzystają z C, więc są wolniejsze [55]. Rozważano też *graph-tools*, jako bibliotekę, która dobrze i szybko radzi sobie z zadaniami na grafie, ale docelowy system operacyjny to Windows, do którego owa biblioteka nie jest przystosowana. Inne częste rozwiązania działają już na języku Julia, zatem także zostały odrzucone.

4.1. Aplikacja webowa

Stworzona aplikacja musiała umożliwić edycję bazy klinicystom, jak i modyfikacje kodu administratorowi, zatem najwygodniejszym rozwiązaniem było stworzenie aplikacji webowej. Dla lekarzy potrzebny był interfejs, dzięki któremu będą oni mogli wyświetlać zawartość bazy,

dodawać, usuwać lub edytować pytania i odpowiedzi, ponieważ będą oni docelowymi użytkownikami, którzy nie muszą mieć wiedzy na temat SQL. Dodatkowo początkowo utrzymywane będą dwie bazy danych czyli standardowa i stworzona na jej podstawie struktura asocjacyjna. W późniejszych etapach projektu, kiedy sprawdzone zostanie już działanie MAGDS, zwykła baza MySQL mogłaby zostać usunięta. Na podstawie bazy danych tworzony jest chatbot, który także powinien być dostępny online. Chatbot także potrzebuje interfejsu graficznego. Te połączenia między interfejsami i bazami przedstawiono na Rys. 4.1.



Rys. 4.1. Połączenia pomiędzy interfejsami i bazą

Wykupiono dostęp do domeny w serwisie devilnet, który m.in. pozwala na wykorzystywanie Django, umożliwia pisanie w języku Python, zawiera bazę MySQL i dodatkowo daje dostęp do autorskiego systemu zarządzania kontem, który umożliwia pełną administrację, zarówno przez SSH, jak i z poziomu przeglądarki internetowej [56].

4.1.1. Obsługa użytkownika i bezpieczeństwo

Ponieważ system ma zawierać dane wrażliwe pacjentów oraz własność intelektualną zespołu prof. Pileckiego, zatem musiał zostać odpowiednio zabezpieczony, aby nie można było łatwo przechwycić danych z witryny internetowej. W planach jest także dodanie śledzenia zmian

w bazie lub danie możliwości różnym lekarzom przypisywania swoich własnych wag do odpowiedzi, niezależnie od wag pierwotnych. Taka dodatkowa funkcjonalność wymaga systemu autentyfikacji użytkownika.

Od strony domeny, najpierw wygenerowano certyfikat SSL dzięki *Let's Encrypt*, czyli darmowemu urzędowi certyfikacji internetowej utrzymywanemu przez *Internet Security Research Group*. Organizacja ta ma na celu szerzenie bezpieczeństwa w sieci, dlatego umożliwia generację certyfikatów SSL/TLS potrzebnych do włączenia szyfrowania HTTPS [57]. To szyfrowanie jest szeroko wykorzystywane w celu zabezpieczenia komunikacji internetowej i jest obecnie preferowane nawet przez w wynikach wyszukiwarki Google w porównaniu do witryn ze starszym HTTP. Połączenie pomiędzy klientem i serwerem zostaje szyfrowane w dwóch kierunkach, by chronić przed podsłuchaniem komunikacji czy śledzeniem działań. Zapewniona jest także dzięki temu integralność danych, czyli nikt nie powinien móc ich zmodyfikować. Protokół ten potwierdza także komunikację z witryną, że nie jest to strona tylko przypominająca właściwą, chroni przed atakami typu “man-in-the-middle”.

Z perspektywy administratora systemu bardzo przydatny jest system uwierzytelniania i autoryzacji Django `django.contrib.auth`. Możliwa jest weryfikacja użytkownika, jak również określenie co może on zrobić już po uwierzytelnieniu. Obsługiwane są także sesje dzięki ciasteczkom (ang. *cookies*). Cały system składa się z:

- Użytkowników, czyli osób wchodzących w interakcję z witryną. Takie obiekty są używane m.in. do rejestracji profili, ograniczania dostępu, kojarzenia treści z twórcami itp. W Django istnieje tylko jedna klasa użytkownika - superużytkownicy lub admin są obiektami z ustawionymi specjalnymi atrybutami, a nie różnymi klasami.
- Ich uprawnień w postaci flag binarnych tak/nie, np. do podglądu, zmiany, dodawania, usuwania czy innych niestandardowych.
- Grup, czyli sposobu na przypisywanie etykiet i uprawnień do wielu użytkowników. Jeden użytkownik może należeć do wielu grup.
- Konfigurowalnego systemu haszowania haseł.
- Formularzy i narzędzi widoku do logowania użytkowników lub ograniczania zawartości.
- Podłączanego systemu backendu.


Dodatkowo dzięki `django.contrib.admin` możliwe jest wygodne przeglądanie i zarządzanie użytkownikami, grupami i uprawnieniami. Dwa pierwsze mogą być tworzone i usuwane podobnie do modeli. Uprawnienia mogą być przypisywane do pojedynczych użytkowników lub całych grup. Historia edycji dokonywanych przez administratora jest zapisywana i możliwy jest jej podgląd. Do dodania nowego użytkownika potrzebne są uprawnienia zarówno do tworzenia jak i zmiany, ponieważ dodać można superużytkownika, który może zmieniać dane innych użytkowników. Jeżeli osoba ma prawa edycji, może także edytować swoje własne uprawnienia,

w tym nadanie sobie statusu superużytkownika. Administrator nie może wyświetlić haseł użytkowników, ale zna szczegóły dotyczące ich przechowywania oraz ma prawo zmienić hasło lub umożliwić to samemu użytkownikowi.

W opisanym w tej pracy systemie na ten moment potrzebne było tylko jedno konto administratora i jedno zwykłe konto użytkownika, później system będzie rozbudowywany w miarę tego jak potrzeby różnych grup użytkowników i ich docelowe uprawnienia będą się kształtować.

4.1.2. Baza danych

Baza miała przede wszystkim zawierać pytania i możliwe odpowiedzi, które wpływają na ocenę ryzyka samobójstwem. Przykładem jest pytanie o płeć - żeńska oznacza większe szanse na popełnienie próby, a męska na większe prawdopodobieństwo, że jeżeli próba nastąpi, skończy się śmiercią. Ważne są także dane klinicysty, które powinny być przez program zapamiętane, aby ten sam klinicysta nie musiał za każdym razem odpowiadać na podstawowe pytania. Musi też wciąż istnieć możliwość edycji, zatem klinicysta powinien móc sprawdzić swoje dane i w razie potrzeby, wprowadzić zmiany. Podobnie chatbot miałby postępować z podstawowymi danymi pacjenta.




Rys. 4.2. Zawartość bazy i jej relacje

Taki zestaw danych przygotował zespół profesora Pileckiego w formie arkusza .xlsx, by łatwiej móc wyeksportować dane przez program do bazy MySQL. Tradycyjna baza zawiera

tabelę z danymi pacjentów, danymi klinicystów, możliwych pytań, odpowiedzi oraz wizyt, które łączą pacjentów z odpowiadającymi innymi tabelami. Rys. 4.2 przedstawia te relacje między tabelami. Tą bazę danych należało odpowiednio przetworzyć, aby móc dodać je do bazy SQLite.

4.2. Implementacja MAGDS

Oprócz wersji tradycyjnej bazy, tworzona jest też struktura MAGDS. W ostatecznej wersji projektu, tradycyjnej wersji bazy nie byłoby wcale, ale na razie dla celów porównawczych i do sprawdzania funkcjonalności obie istnieją i są aktualizowane. W tej strukturze istnieje 5 standardowych rodzajów obiektów, czyli pacjenci, klinicyści, pytania, odpowiedzi i wizyty. Przy tworzeniu nowego obiektu tworzony jest wierzchołek unikatowy dla danej instancji i tworzone są połączenia do wartości jego atrybutów (jeżeli wartość jeszcze nie istnieje, to także zostaje dodana do grafu). Pytania mają parametry: rozdział, typ i tekst; pacjenci i klinicyści mają jedynie swój nick, wizyta numer, a odpowiedzi: tekst, wartość prawdopodobieństwa wystąpienia próby na najbliższe 2 tygodnie, ogółem i wartość wagi letalności. Struktura asocjacyjna łączy wszystkie powiązane obiekty z ich parametrami i konkretnymi wartościami po posortowaniu. Relacje między klasami obiektów przedstawione są na Rys. 4.3.



Rys. 4.3. Połączenia pomiędzy klasami

Do stworzenia grafu potrzebne były funkcje przetwarzające arkusz z pytaniami i odpowiedziami do obiektów typu DataFrame biblioteki pandas, które zawierały listę wierzchołków i krawędzi z ich graficznymi atrybutami. Wartości parametrów obiektów różnego typu musiały być najpierw posortowane od najmniejszych do największych i połączone z obiektem o nazwie wskazującej na minimum i maksimum. Potrzebne były także metody do dodawania elementów w trakcie działania programu, do wyszukiwania, zmiany, usuwania itp. Ważna była też funkcja

wyliczania podobieństwa różnych pacjentów, która ma pomóc w określaniu, jakie akcje najlepiej podjąć dla aktualnego.

5. Realizacja

5.1. Strona

Stworzono główną stronę, na której użytkownik może się zalogować lub utworzyć nowe konto, widoczna jest na Rys. 5.1. Serwis musi jeszcze zostać podpięty do emaila, aby wysyłać maile potwierdzające adres poczty elektronicznej i kontaktować się z użytkownikiem. Na tym etapie nie jest to potrzebne, istnieje jeden użytkownik dla wszystkich klinicystów, ale później jeden lekarz mógłby mieć jedno konto, dzięki czemu chatbot automatycznie pomijałby pytania o klinicystę.

Zaloguj się

Username:

Password:

[Zapomniałeś hasła?](#)


ZALOGUJ

Nie masz konta?

Zarejestruj

Rys. 5.1. Strona logowania

Poniżej 5.2 przedstawiono stronę główną po zalogowaniu.



Rys. 5.2. Widok strony głównej po zalogowaniu

5.2. Baza danych

W bazie danych znajduje się pięć głównych tabel odpowiadających pięciu typom obiektów: pytania, odpowiedzi, wizyty, pacjenci, klinicyści. W tych tabelach znajdują się potrzebne do pracy atrybuty. Widoczne są one na Rys. 5.3.

Na Rys. 5.4 przedstawiono przykładowy wygląd danych w tabeli klinicystów. W tej tradycyjnej bazie przebieg odpowiedzi na pytania dotyczące klinicysty zapisane są jako: nr pytania: id odpowiedzi / tablica id odpowiedzi.

W tabeli z wizytami (Rys. 5.5) oprócz, jej id, id klinicysty i pacjenta znajduje się także przebieg odpowiedzi na pytania zapisane w analogiczny sposób jak w tabeli klinicystów jako: nr pytania: id odpowiedzi / tablica id odpowiedzi.

Użytkownik może dodawać pytania za pomocą interfejsu na stronie, co pokazane jest na Rys. 5.6.

Użytkownik może dodawać także odpowiedzi za pomocą tego interfejsu, co pokazane jest na Rys. 5.7.

Użytkownik ma dostęp do bazy na stronie przedstawionej na Rys. 5.8. Pola są edytowalne po kliknięciu i możliwe jest usuwanie elementów.

main_app_answer	CREATE TABLE "main_app_answer" ("answer
answer_text	TEXT "answer_text" TEXT
id	INTEGER "id" INTEGER NOT NULL
bias_probability_2w	REAL "bias_probability_2w" REAL
bias_probability	REAL "bias_probability" REAL
bias_lethality	REAL "bias_lethality" REAL
question_next	TEXT "question_next" TEXT
question_current_id	INTEGER "question_current_id" INTEGER
ans_counter	INTEGER "ans_counter" INTEGER
main_app_clinician	CREATE TABLE "main_app_clinician" ("id" inte
id	integer "id" integer NOT NULL
clinician_nickname	varchar(200) "clinician_nickname" varchar(200) NOT NULL
clinician_data	varchar(200) "clinician_data" varchar(200) NOT NULL
main_app_patient	CREATE TABLE "main_app_patient" ("id" integ
id	integer "id" integer NOT NULL
patient_nickname	varchar(200) "patient_nickname" varchar(200) NOT NULL
main_app_question	CREATE TABLE "main_app_question" ("id" inte
id	integer "id" integer NOT NULL
question_text	varchar(500) "question_text" varchar(500) NOT NULL
question_chapter	varchar(200) "question_chapter" varchar(200) NOT NULL
question_type	varchar(1) "question_type" varchar(1) NOT NULL
question_number	varchar(15) "question_number" varchar(15) NOT NULL
main_app_visits	CREATE TABLE "main_app_visits" ("id" integer
id	integer "id" integer NOT NULL
q_n_a_dicts	varchar(200) "q_n_a_dicts" varchar(200) NOT NULL
clinician_id	integer "clinician_id" integer
patient_id	integer "patient_id" integer
visit_no	integer "visit_no" integer


Rys. 5.3. Tabele w bazie danych

id	clinician_nickname	clinician_data
Filtr	Filtr	Filtr
25	dr321	1: 2, 2: 6, 3: [1, 11], 4: [15], 5: 20, 6: 25, 7: 31,
28	dr123	1: 3, 2: 7, 3: [12], 4: [1, 16], 5: 22, 6: 27, 7: 29,


Rys. 5.4. Tabela klinicystów

Tabela: main_app_visits															Filter
id ▾	q_n_a_dicts					clinician_id	patient_id	visit_no							
Filtr	Filtr					Filtr	Filtr	Filtr							
1	33	8: 39, 9: 2031, 10: 44, 11: 45, 15: 64, 16: 2032,...				25	4	1							
2	34	8: 39, 9: 2034, 10: 44, 11: 46, 15: 64, 16: 2035,...				25	5	1							

Rys. 5.5. Tabela wizyt



The screenshot shows a web form titled "Dodaj nowe pytanie". It contains four text input fields labeled "Numer:", "Rozdział:", "Treść:", and "Typ:". At the bottom left, there is a link "Dodaj odpowiedź" and at the bottom right, a dark button labeled "WYŚLIJ". The form is set against a background with a large red rectangle on the right and a vertical red bar on the left.

Rys. 5.6. Dodawanie pytań

The screenshot shows a web form titled "Dodaj nową odpowiedź". It features a large text input field for "Treść:". Below it are three range input fields for "Waga prawdopodobieństwa:", "Prawdopodobieństwo na 2 tygodnie:", and "Waga letalności:". There is also a text input field for "Numer następnego pytania:". At the bottom left, there is a dropdown menu labeled "Obecne pytanie:" and a link "Dodaj nowe pytanie". At the bottom right, there is a dark button labeled "WYŚLIJ". The form is set against a background with a large red rectangle on the right and a vertical red bar on the left.

Rys. 5.7. Dodawanie odpowiedzi

Wszystkie pytania i odpowiedzi w bazie

ID pyt.	Nr pyt.	Rozdział	Typ	Treść pyt.	ID odp.	Tekst odp.	Prawdop. na 2 tyg.	Prawdop. na 2 tyg.	Letalność	Nast. pyt.	Do usunięcia
3	0.1	Wstęp	j	Czy mamy już Twoje da			0	0	0	0.2	Usuń
					0	Tak (wpisz swój nick klinicysty po przecinku, np. "1, dr123")	0	0	0	1	Usuń
					1	Nie (wymyśl dla siebie nick i napisz po przecinku, np. "2, doktor123"					
4	1	Dane klinicysty	j	Wiek klinicysty			1	1	1	2	Usuń
					2	Do 28 roku życia	0	0	0	2	Usuń
					3	Od 28 do 45 roku życia	1	1	1	2	Usuń
					4	Od 45 wzwyż					
5	2	Dane klinicysty	j	Płeć klinicysty			1	1	1	3	Usuń
					5	męska, taka sama jak pacjenta	0	0	0	3	Usuń
					6	męska, różna od pacjentki	1	1	1	3	Usuń
					7	kobieca, taka sama jak pacjentki	0	0	0	3	Usuń
					8	kobieca, różna od pacjenta	1	1	1	3	Usuń
					9	inna					

Rys. 5.8. Podgląd i edycja pytań i odpowiedzi

5.3. MAGDS graf


W grafie najpierw tworzone są obiekty odpowiedzi i pytań i dodawane są połączenia do wierzchołków będących ich atrybutami, następnie tworzony jest obiekt klinicysty, pacjenta i wizyty a podczas rozmowy z chatbotem tworzone są odpowiednie połączenia. Dla celów wizualizacji stworzono plik z jedynie trzema pierwszymi pytaniami wraz z ich odpowiedziami i pytaniem końcowym (Rys. 5.9).

	A	B	C	D	E	F	G	H
1	Numbe	Chapter	Text	Type	Probability_2week	Probability	Lethality	Next_questio
2	1	Dane	Wiek klinicysty	j				
3			Do 28 roku życia		1	1	1	2
4			Od 28 do 45 roku życia		0	0	0	2
5			Od 45 wzwyż		1	1	1	2
6	2	Dane	Wykształcenie	w				
7			psycholog		0	0	0	3
8			pedagog		1	1	1	3
9			lekarz		1	1	1	3
10			inny zawód medyczny		1	1	1	3
11			inny zawód niż powyższe		1	1	1	3
12	3	Dane pacjenta	Wiek pacjenta	j				
13			do 12 r. życia		1	1	1	Koniec
14			Od 13 roku życia		2	2	2	Koniec
15	Koniec	Koniec	To koniec moich pytań :)	s				

Rys. 5.9. Arkusz z 3 początkowymi pytaniami i końcowym


Poniżej na Rys. 5.9 widoczny jest graf powstały na podstawie tej ograniczonej listy pytań i odpowiedzi podanych podczas testowej rozmowy.

Czerwono-pomarańczowe są wierzchołki związane z odpowiedziami, żółte z pytaniami, fioletowe z wizytami, turkusowe z pacjentami i zielone z klinicystami.



5.4. Działanie chatbota

Interfejs chatbota stworzono wykorzystując repozytorium HuzaiFa Sayyeda, które zawiera kod źródłowy jego Coronabota. Tamten projekt wykorzystywał Flask nie Django, więc musiał zostać przeniesiony i wygląd zewnętrzny zmieniony, by lepiej dopasować do zastosowania ChaRSa. Wynik końcowy widać na Rys. 5.11.




Rys. 5.11. Widok strony z chatbotem


Początek rozmowy widać na Rys. 5.12. W pierwszej wiadomości wyjaśnione są zasady podawania odpowiedzi.

Mogą pojawiać się pytania jednokrotnego lub wielokrotnego wyboru, chatbot zapisuje oba warianty. Takie pytania widać na Rys. 5.13.


Zdarzają się także pytania opisowe, jak imię pacjenta. Jeżeli imię jest rzadko spotykane, może to delikatnie wpływać na prawdopodobieństwo podjęcia próby samobójczej. Jednak "dziwność" pytania będzie dość subiektywna, dlatego klinicysta podaje po opisowym pytaniu wartości wszystkich trzech wag - Rys. 5.14.



Rys. 5.12. Początek rozmowy



Rys. 5.13. Pytania wielokrotnego wyboru




Rys. 5.14. Pytanie opisowe

5.5. Podobieństwo pacjentów

Utworzono algorytm wyznaczający najpierw podobieństwo odpowiedzi dwóch pacjentów dla danego pytania biorąc pod uwagę średnią ważoną wag. Następnie na podstawie wszystkich podobieństw dla wszystkich pytań wyznaczane jest podobieństwo pacjentów. Dzięki temu jeżeli wiadomo, że pierwszy pacjent podjął próbę w następującym czasie, można podejrzewać, że z drugim pacjentem może być podobnie, jeżeli algorytm wskazał, że jest w podobnym stanie. Dzięki temu mechanizmowi wiedza i doświadczenie wielu lekarzy może pomóc diagnozującemu. Jeżeli pacjentów przyjmowali inni klinicyści, podobieństwo pytań dotyczących ich także zostaje wyliczone i jest uwzględniane w podobieństwie pacjenta. Dzieje się tak ponieważ jeden klinicysta może być bardziej doświadczony i może inaczej ocenić stan pacjenta.

Na poniższym obrazie Rys. 5.15 widać dwie wartości, pierwsza to podobieństwo klinicysty (w tym przypadku był to ten sam klinicysta), a druga to ostateczne podobieństwo pacjentów.



```
174
175 def calculate_similarity_patients(p1_id, p2_id):
176     c1_id = find_clinician(p1_id)
177     c2_id = find_clinician(p2_id)
178     c_sim = calculate_similarity_objects(c1_id, c2_id)
179     p_sim = calculate_similarity_objects(p1_id, p2_id)
180     return c_sim, p_sim
181
182
183 p1 = G.vs.find("Obj_P_p123").index
184 p2 = G.vs.find("Obj_P_p456").index
185 c1 = G.vs.find("Obj_C_dr123").index
186 c2 = G.vs.find("Obj_C_dr321").index
187 print(calculate_similarity_patients(p1, p2))
188
189
190
191
```

Run: similarity ×

C:\Users\Monika\MAGDS\venv\Scripts\python.exe C:/Users/Monika/MAGDS/similarity.py
(1.0, 0.9309983176951031)

Process finished with exit code 0

Rys. 5.15. Wyliczone podobieństwo pacjentów

Na razie nie ma zebranych danych od prawdziwych pacjentów, więc nie widać do końca potencjału algorytmu, jednak kiedy pacjentów będzie więcej, można będzie znaleźć pacjenta najbardziej podobnego do obecnego i uczyć się na jego przeszłości poprawić przyszłość obecnego pacjenta. Zatem graf ten może wspierać klinicystę w procesie decyzyjnym.

6. Podsumowanie

6.1. Wyniki i możliwości rozbudowy

Aktualna wersja chatbota jest wersją początkową, w planach jest rozwój długoterminowy projektu. Udało się utworzyć szkielet systemu łączący interfejs użytkownika na stronach internetowych ze standardową bazą sqlite, z grafem MAGDS i algorytmem chatbota. W miarę uzupełniania bazy o kolejnych pacjentów i klinicystów, aplikacja będzie mogła być ulepszana.

Obie bazy danych zostały odpowiednio utworzone przez odpowiednie dla danej wersji przetworzenie arkusza z pytaniami i odpowiedziami. Właściwie czerpane są informacje o kolejności pytań i odpowiedzi zadawanych przez chatbota i w miarę prowadzenia konwersacji z nim obie bazy uzupełniane są o kolejne elementy.

Interfejs użytkownika, jeżeli chodzi o dostęp do bazy danych, spełnia swoją funkcję i jest dość przejrzysty, jednak jest jeszcze wiele możliwych zmian i ulepszeń do wprowadzenia. Najlepszą wersją byłoby przedstawienie pytań z odpowiedziami w formie drzewa obrazującego ścieżkę konwersacji z chatbotem. Ułatwiałoby to znacząco klinicyście/-stce poruszanie się pomiędzy kolejnymi pytaniami bez ciągłego upewniania się o ich numerach id. W takim interfejsie można by także umożliwić zmianę następnego pytania poprzez przeciągnięcie strzałki prowadzącej z jakiejś odpowiedzi do innego pytania. Zagadnienie to jest bardziej kwestią odpowiedniego projektu strony internetowej, niż grafu, dlatego zostało uznane za mniej priorytetowe.

Sam algorytm określania podobieństwa pacjentów działa poprawnie, ale stanowi jedynie ułamek potencjału algorytmu, gdy baza danych będzie pełniejsza. Kiedy zbada się podobieństwo jakiegoś pacjenta/-tki do wszystkich innych w bazie, można stwierdzić do jakiego jest najbardziej podobny/-a, co może zasugerować odpowiednie postępowanie. Kiedy będą do systemu wprowadzane dane historyczne, z wizyt prospektywnych, będzie wiadomo, czy wprowadzone wcześniej środki były właściwe, czy nie (podjęto próbę samobójczą lub popełniono samobójstwo, stan się nie zmienił lub poprawił). Aplikacja w miarę użytkowania i rozszerzania bazy stawałaby się coraz bardziej skuteczna we wnioskowaniu o najlepszym rozwiązaniu dla danego pacjenta/-tki. Można by spróbować zastosować sieci neuronowe w celu poprawienia wag prawdopodobieństwa i letalności, aby lepiej dopasowywać się do modelu.

Dla takiej dużo rozszerzonej bazy można by także zrobić porównanie grafu MAGDS z SQLite - szybkość wyszukiwania informacji na temat danego pacjenta/-tki, zajęta pamięć itp. Istniałaby także możliwość utworzenia panelu pacjenta/-tki, gdzie wyświetlany byłby graf dotyczący tylko i wyłącznie jego/jej odpowiedzi czy też ich zmian w trakcie leczenia. Mógłby zostać pokazywany także graf z odpowiedziami obecnego pacjenta/-tki i najbardziej podobnego, aby lekarz miał wszystkie potrzebne dane do dobrania najlepszego dalszego trybu działania.

6.2. Wnioski

Aplikacja ta jest jedynie zaczątkiem projektu, jednak jest widoczny potencjał w zastosowaniu tego typu programów w diagnostyce medycznej. Na tę chwilę możliwości nie pozwalają na faktyczne diagnozowanie pacjenta/-tki przez aplikację, zamiast tego program może wydać jedynie drugą opinię, aby wspomóc klinicystę/-tkę. Biorąc pod wagę, że coraz więcej osób szuka pomocy psychologicznej lub psychiatrycznej, można zauważyć, że wsparcie terapeutów i psychiatrów jest bardzo potrzebne, szczególnie dla tych zajmujących się dziećmi i młodzieżą. Tworzenie aplikacji nie było jednak proste, m.in. dlatego, że zespołowi nie było łatwo przełożyć swoją wiedzę na matematyczne wagi. Z innego typu problemów, występowały także kłopoty z formatem plików, w jakich łatwo było pracować zespołowi, a jakie łatwiej było automatycznie przetworzyć do bazy i grafu. Potrzebne były też klaryfikacje dotyczące faktycznych możliwości działania grafu MAGDS, ponieważ psychiatrzy naturalnie nie mieli dużej wiedzy na temat sztucznej inteligencji ani tego konkretnego algorytmu.

Aplikacje do celów terapeutycznych jednak wciąż się rozwijają. Na razie bezpośredni kontakt z pacjentami mogą mieć jedynie te stosowane jako pomoc w terapii i które są oparte o wiedzę, gdyż SI uczona w sposób nienadzorowany (np. GPT-3, Cleverbot) może zachowywać się nieprzewidywalnie, zatem stwarzać zbyt duże ryzyko dla pacjentów. Szersze zastosowanie tego typu oprogramowania wymagałoby także określenia standardu bezpieczeństwa danych i poziomu anonimowości użytkowników, jaki musi zostać zachowany. Obecnie istnieją też wątpliwości co do skuteczności SI w diagnostyce psychologiczno-psychiatrycznej czy raczej skutków, gdyby program zaszkodził pacjentowi/-tce. Poza wątpliwościami etycznymi, jest też problem zaufania społecznego, które nie stoi wciąż jeszcze na zbyt wysokim poziomie. Do jego zwiększania najlepiej stosować kampanie informacyjne czy warsztaty, które podkreślają wygodę użytkownika i polepszają świadomość zdrowotną.

A. Dodatek A

A.1. Opis repozytorium

Repozytorium znajduje się pod adresem: <https://bitbucket.org/mzk11/magds/src/master/>

Głównym folderem dla strony internetowej jest folder `public_python`. W środku znajduje się bardzo ważny w konfiguracji i uruchamianiu witryny plik `manage.py`.

W folderze `templates` znajdują się pliki `.html` dla stron.

W folderze `static`, podfolderze `pictures` znajdują się obrazy użyte jako zdjęcia profilowe chatbota i użytkownika podczas rozmowy.

W folderze `main_app` znajdują się `m.in.`:

- plik `forms.py` gdzie znajdują się definicje formularzy dodawania pytań i odpowiedzi;
- plik `models.py` definiujący atrybuty obiektów dla tradycyjnej bazy `sqlite`;
- plik `urls.py` definiujący linki url które wskazują na konkretny szablon `.html`;
- plik `views.py` gdzie znajdują się definicje najważniejszych funkcji używanych podczas korzystania z aplikacji, czyli dodawanie, edytowanie, usuwanie w tradycyjnej bazie oraz metody dla grafów;

Poza folderami najważniejsze pliki to:

- plik `Worked_version.xls`, który zawiera arkusz z pytaniami i odpowiedziami w nieprzetworzonej jeszcze formie;
- plik `Excel_converter.py` używany do przekształcenia bazy z excela do grafu MAGDS;
- plik `Faktycznyv4.pkl`, który zawiera kopię grafu w najświeższej formie i aktualizowany jest podczas rozmowy;
- plik `For_vis.xls`, który zawiera arkusz z ograniczoną listą pytań i odpowiedzi, aby przedstawić zasadę tworzenia połączeń na wizualizacji;
- plik `excel2database.py`, który użyty został do przeniesienia arkusza do bazy `sqlite`;
- plik `similarity.py`, w którym znajdują się definicje funkcji potrzebnych do wyliczenia podobieństwa pacjentów;

A.2. Domena

Na ten moment domena znajduje się pod adresem: <https://chatbot.mklimek.usermd.net/>

Bibliografia

- [1] „*The Global Health Estimates 2000-2019*”. <https://www.who.int/data/global-health-estimates>. Dostęp: 2022-07-20. World Health Organization.
- [2] „*Global Burden of Disease Study 2019 (GBD 2019) Results*”. <https://vizhub.healthdata.org/gbd-results/>. Dostęp: 2022-07-30. Institute for Health Metrics i Evaluation (IHME), 2020.
- [3] „*NIK o dostępności leczenia psychiatrycznego dla dzieci i młodzieży*”. <https://www.nik.gov.pl/aktualnosci/lecznictwo-psychiatryczne-dzieci-i-mlodziezy.html>. Accessed: 2022-07-30. Naczelna Izba Kontroli, 2020.
- [4] „*An Ultimate Tutorial to Neural Networks*”. <https://www.simplilearn.com/tutorials/deep-learning-tutorial/neural-network>. Dostęp: 2022-08-11. Simplilearn, 2022.
- [5] Sieuwert van Otterloo. „*AI, Machine Learning and neural networks explained*”. <https://ictinstitute.nl/ai-machine-learning-and-neural-networks-explained/>. Accessed: 2022-08-05. 27 lip. 2020.
- [6] „*Knowledge Base In AI: What is it and why do you need one?*” <https://www.kmslh.com/blog/knowledge-base-in-ai-what-is-it-and-why-do-you-need-one/>. Dostęp: 2022-09-01. KMS Lighthouse, 2021.
- [7] Adam Marszałek. „*Modele neuronów*”. https://torus.uck.pk.edu.pl/~amarsz/dydaktyka/wsi/Modele_Neuronow_Perceptron.pdf. Dostęp: 2022-09-15. Politechnika Krakowska.
- [8] „*Neuronal Action Potential - Refractory Periods*”. https://www.physiologyweb.com/lecture_notes/neuronal_action_potential/neuronal_action_potential_refractory_periods.html. Dostęp: 2022-09-15. PhysiologyWeb.
- [9] Adrian Horzyk. „*Computational Intelligence - Associative Data Structures and Associative Neural Graphs*”. https://home.agh.edu.pl/~horzyk/lectures/ci/CI-AssociativeNeuralGraphs.pdf?fbclid=IwAR3KReHpey6WAUMoUvTQ6d2WWbYf6uuNI6PJEazivRiEmO5_JEW5hf0BsM0. Dostęp: 2022-09-01.

- [10] Shan Cui. „*Associative memory cells and their working principle in the brain*”. W: *F1000Research* 7 (sty. 2018), s. 108. DOI: [10.12688/f1000research.13665.1](https://doi.org/10.12688/f1000research.13665.1).
- [11] Zhenzhu Meng, Yating Hu i Christophe Ancey. „*Using a Data Driven Approach to Predict Waves Generated by Gravity Driven Mass Flows*”. W: *Water* 12 (lut. 2020). DOI: [10.3390/w12020600](https://doi.org/10.3390/w12020600).
- [12] Nahua Kang. „*Multi-Layer Neural Networks with Sigmoid Function— Deep Learning for Rookies (2)*”. <https://towardsdatascience.com/multi-layer-neural-networks-with-sigmoid-function-deep-learning-for-rookies-2-bf464f09eb7f>. Dostęp: 2022-09-01. Towards Data Science.
- [13] Michael A. Nielsen. „*Neural Networks and Deep Learning*”. [http : / / neuralnetworksanddeeplearning.com/](http://neuralnetworksanddeeplearning.com/). Dostęp: 2022-08-11. 2018.
- [14] Md. Zahangir Alom i in. „*A State-of-the-Art Survey on Deep Learning Theory and Architectures*”. W: *Electronics* 8 (2019), s. 292. DOI: [10.3390/electronics8030292](https://doi.org/10.3390/electronics8030292).
- [15] „*Advantages and Disadvantages of Neural Networks*”. <https://www.baeldung.com/cs/neural-net-advantages-disadvantages>. Dostęp: 2022-09-15. Baeldung.
- [16] „*The Limitations of Neural Networks: 3 Big Issues Dominate*”. <https://techmonitor.ai/technology/emerging-technology/limitations-of-neural-networks>. Dostęp: 2022-09-01. Tech Monitor, 2019.
- [17] Niklas Donges. „*4 Reasons Why Deep Learning and Neural Networks Aren’t Always the Right Choice*”. <https://builtin.com/data-science/disadvantages-neural-networks>. Dostęp: 2022-09-01. Built In, 2019.
- [18] Adrian Horzyk. „*Sztuczne systemy skojarzeniowe i asocjacyjna sztuczna inteligencja*”. Akademicka Oficyna Wydawnicza EXIT, 2013.
- [19] Adrian Horzyk. „*Computational Intelligence - Associative and Cognitive Neural Systems*”. <https://home.agh.edu.pl/~horzyk/lectures/ci/CI%20Associative%20and%20Cognitive%20Neural%20Systems.pdf>. Dostęp: 2022-09-01.
- [20] Adrian Horzyk. „*Associative Graph Data Structures with an Efficient Access via AVB+trees*”. W: lip. 2018, s. 169–175. DOI: [10.1109/HSI.2018.8430973](https://doi.org/10.1109/HSI.2018.8430973).
- [21] Adrian Horzyk. „*Associative Representation and Processing of Databases Using DASNG and AVB+trees for Efficient Data Access*”. W: kw. 2019, s. 242–267. ISBN: 978-3-030-15639-8. DOI: [10.1007/978-3-030-15640-4_13](https://doi.org/10.1007/978-3-030-15640-4_13).
- [22] Adrian Horzyk i Agata Czajkowska. „*Associative Pattern Matching and Inference Using Associative Graph Data Structures*”. W: maj 2019, s. 371–383. ISBN: 978-3-030-20914-8. DOI: [10.1007/978-3-030-20915-5_34](https://doi.org/10.1007/978-3-030-20915-5_34).

- [23] „NLP w pigułce”. <http://namiekkko.pl/2017/04/10/nlp-w-pigulce/>. Dostęp: 2022-09-15. Na miękko.
- [24] Brad Miller, David Ranum i Luther College. „*Problem Solving with Algorithms and Data Structures using Python*”. <https://runestone.academy/ns/books/published/pythonds/Trees/ParseTree.html>. Dostęp: 2022-09-15.
- [25] World Health Organization. „*Child and adolescent mental health policies and plans*”. World Health Organization, 2005.
- [26] Daniel Rząsa. „*Samobójstwa nastolatków - dlaczego oficjalne statystyki pokazują tylko część prawdy*”. W: *Śledztwo Pisma* (21 paź. 2020).
- [27] „*Zamachy samobójcze*”. <https://statystyka.policja.pl/st/wybrane-statystyki/zamachy-samobojcze>. Dostęp: 2022-07-30. Komenda Główna Policji.
- [28] „*Psychiatria dziecięca się zmienia, ale brakuje specjalistów*”. <https://politykazdrowotna.com/artukul/psychiatria-dziecieca-sie-zmienia-ale-brakuje-specjalistow/823286>. Accessed: 2022-07-30. Polityka Zdrowotna, 31 mar. 2022.
- [29] „*Zestawienie liczbowe lekarzy i lekarzy dentystów wg dziedziny i stopnia specjalizacji (za czerwiec 2022)*”. https://nil.org.pl/uploaded_files/1657008817_za-czerwiec-2022-zestawienie-nr-04.pdf. Dostęp: 2022-07-24. Naczelna Izba Lekarska.
- [30] Daniel Greenfield. „*Artificial Intelligence in Medicine: Applications, implications, and limitations*”. <https://sitn.hms.harvard.edu/flash/2019/artificial-intelligence-in-medicine-applications-implications-and-limitations/>. Accessed: 2022-08-05. Harvard University, 19 czer. 2019.
- [31] I-Chiu Chang, Yi-Syuan Shih i Kuang-Ming Kuo. „*Why would you use medical chatbots? interview and survey*”. W: *International Journal of Medical Informatics* 165 (2022), s. 104827. ISSN: 1386-5056. DOI: <https://doi.org/10.1016/j.ijmedinf.2022.104827>.
- [32] Ju Gang Nam i in. „*Development and Validation of Deep Learning-based Automatic Detection Algorithm for Malignant Pulmonary Nodules on Chest Radiographs*”. W: *Radiology* 290.1 (2019). PMID: 30251934, s. 218–228. DOI: [10.1148/radiol.2018180237](https://doi.org/10.1148/radiol.2018180237). eprint: <https://doi.org/10.1148/radiol.2018180237>.
- [33] Yun Liu i in. „*Artificial Intelligence-Based Breast Cancer Nodal Metastasis Detection: Insights Into the Black Box for Pathologists*”. W: *Archives of Pathology & Laboratory Medicine* 143.7 (paź. 2018), s. 859–868. ISSN: 0003-9985. DOI: [10.5858/arpa.2018-0147-OA](https://doi.org/10.5858/arpa.2018-0147-OA). eprint: https://meridian.allenpress.com/aplm/article-pdf/143/7/859/2501371/arpa_2018-0147-oa.pdf.

- [34] Nicole Ruggiano i in. „*Chatbots to Support People With Dementia and Their Caregivers: Systematic Review of Functions and Quality*”. W: *J Med Internet Res* 23 (19 czer. 2019). Accessed: 2022-08-05. DOI: 10.2196/25006.
- [35] Aditya Nrusimha Vaidyam i in. „*Chatbots and Conversational Agents in Mental Health: A Review of the Psychiatric Landscape*”. W: *The Canadian Journal of Psychiatry* 64 (2019), s. 456–464.
- [36] Gale M. Lucas i in. „*Reporting Mental Health Symptoms: Breaking Down Barriers to Care with Virtual Human Interviewers*”. W: *Frontiers in Robotics and AI* 4 (2017). ISSN: 2296-9144. DOI: 10.3389/frobt.2017.00051.
- [37] Gale Lucas i in. „*It’s only a computer: Virtual humans increase willingness to disclose*”. W: *Computers in Human Behavior* 37 (sierp. 2014), s. 94–100. DOI: 10.1016/j.chb.2014.04.043.
- [38] Cláudia Pernencar, Inga Saboia i Joana Carmo Dias. „*How Far Can Conversational Agents Contribute to IBD Patient Health Care—A Review of the Literature*”. W: *Frontiers in Public Health* 23.6 (czer. 2021), e25006. ISSN: 2296-2565. DOI: 10.3389/fpubh.2022.862432.
- [39] „*Open AI about GPT-2*”. <https://openai.com/blog/gpt-2-1-5b-release/>. Dostęp: 2022-09-01. OpenAI.
- [40] Will Douglas Heaven. „*How to make a chatbot that isn’t racist or sexist*”. <https://www.technologyreview.com/2020/10/23/1011116/chatbot-gpt3-openai-facebook-google-safety-fix-racist-sexist-language-ai/>. Dostęp: 2022-09-01. MIT Technology Review.
- [41] Ryan Daws. „*Medical chatbot using OpenAI’s GPT-3 told a fake patient to kill themselves*”. <https://www.artificialintelligence-news.com/2020/10/28/medical-chatbot-openai-gpt3-patient-kill-themselves/>. Dostęp: 2022-09-01. AI News, 2020.
- [42] Dirk Scheele i in. „*A human tendency to anthropomorphize is enhanced by oxytocin*”. W: *European Neuropsychopharmacology* 25 (2015), s. 1817–1823.
- [43] Joseph Weizenbaum. „*ELIZA—a Computer Program for the Study of Natural Language Communication between Man and Machine*”. W: *Commun. ACM* 9.1 (1966), s. 36–45. ISSN: 0001-0782. DOI: 10.1145/365153.365168.
- [44] „*Woebot*”. <https://woebothealth.com/>. Dostęp: 2022-08-11. Woebot Health.
- [45] „*Meet Wysa*”. <https://www.wysa.io/>. Accessed: 2022-08-05. Wysa.
- [46] „*Social Impact at Harry’s*”. <https://www.harrys.com/go/gb-social-impact>. Accessed: 2022-08-05. Harry’s, 2018.

- [47] Rebecca Reid. „Meet HARR-e, the artificial intelligence taking on the male mental health crisis”. <https://metro.co.uk/2018/10/19/meet-harr-e-the-online-ai-taking-on-the-male-mental-health-crisis-8054503/>. Dostęp: 2022-08-11. Metro, 2018.
- [48] Anabelle Cooper i David Ireland. „Designing a Chat-Bot for Non-Verbal Children on the Autism Spectrum”. W: *Studies in health technology and informatics* 252 (sty. 2018), s. 63–68.
- [49] Karmele Lopez-de-Ipiña i in. „On Automatic Diagnosis of Alzheimer’s Disease based on Spontaneous Speech Analysis and Emotional Temperature”. W: *Cognitive Computation* 7.1 (2013), s. 44–55.
- [50] David Griol i Zoraida Callejas. „Mobile Conversational Agents for Context-Aware Care Applications”. W: *Cognitive Computation* 8 (sierp. 2015), s. 336–356. DOI: 10.1007/s12559-015-9352-x.
- [51] „About pandas”. <https://pandas.pydata.org/about/index.html>. Accessed: 2022-08-06. NumFOCUS.
- [52] „MySQL Products”. <https://www.mysql.com/products/>. Dostęp: 2022-08-14. MySQL.
- [53] „Meet Django”. <https://www.djangoproject.com/>. Accessed: 2022-08-06. Django Software Foundation.
- [54] „igraph - The network analysis package”. <https://igraph.org/>. Accessed: 2022-08-06. igraph.
- [55] Timothy Lin. „Benchmark of popular graph/network packages v2”. <https://www.timlrx.com/blog/benchmark-of-popular-graph-network-packages-v2>. Accessed: 2022-08-05. 10 maj. 2020.
- [56] „Dlaczego MyDevil.net?” <https://www.mydevil.net/>. Dostęp: 2022-08-11. MyDevil.net.
- [57] „About Let’s Encrypt”. <https://letsencrypt.org/about/>. Dostęp: 2022-08-19. Let’s Encrypt.