

DOI:10.12923/2353-8627/2023-0001

Czasopismo indeksowane
na liście MNiSW - 70 pkt.

Application of artificial intelligence tools in diagnosis and treatment of mental disorders

Zastosowanie narzędzi sztucznej inteligencji w diagnostyce oraz leczeniu zaburzeń psychicznych

Klaudia Kister¹ ABCDEF, <https://orcid.org/0000-0003-2058-5395>,Jakub Laskowski² ABCDEF, <https://orcid.org/0000-0002-9547-0608>,Agata Makarewicz³ ABCDEF, <https://orcid.org/0000-0002-4478-8608>,Jakub Tarkowski⁴ ABCDEF,¹Students Research Group at the I Department of Psychiatry, Psychotherapy and Early Intervention of Medical University in Lublin, Poland²Students Research Group at the Department of Paediatric Oncology, Transplantology and Haematology of Medical University in Lublin, Medical University in Lublin, Poland³I Department of Psychiatry, Psychotherapy and Early Intervention of Medical University in Lublin, Poland⁴Medical University of Warsaw, Polska

Abstract

Introduction: Artificial intelligence research is increasing its application in mental health services. Machine learning, deep learning, semantic analysis in the form of transcriptions of patients' statements enable early diagnosis of psychotic disorders, ADHD, anorexia nervosa. Of great importance are the so-called digital therapists. This paper aims to show the use of AI tools in diagnosing, treating, the benefits and limitations associated with mental disorders.

Material and methods: This literature review was conducted by searching scientific articles from 2015 to 2022. The basis were PubMed, OpenKnowledge, Web of Science, using the following keywords: artificial intelligence, digital therapy, psychiatry, machine learning.

Results: A review indicates the widespread use of AI tools in screening for mental disorders. These tools advance the clinical diagnosis medical specialists make up for several years. They impact solving medical staff shortages, lack of access to medical facilities and leveling patient resistance to treatment. The benefits are ultra-fast analysis of large sets of information, effective screening of people in need of specialized psychiatric care, reduction of doctors' duties and maximization of their work efficiency. During the current COVID 19 pandemic, robots in the form of digital psychotherapists are playing a special role.

Conclusions: The need for further research, testing and clarification of regulations related to the use of AI tools is indicated. Ethical and social problems need to be resolved. The tools should not form the basis of autonomous therapy without the supervision of highly trained professionals. Human beings should be at the center of analysis just as their health and well-being.

Keywords: artificial intelligence, digital therapy, psychiatry, machine learning

Streszczenie

Wstęp: Badania nad sztuczną inteligencją (AI) znajdują coraz szersze zastosowanie w usługach zdrowia psychicznego. Uczenie maszynowe, głębokie uczenie, analiza semantyczna w postaci transkrypcji wypowiedzi pacjentów, neuroobrazowanie podatnych rejonów mózgu umożliwiają wczesne rozpoznanie m.in. zaburzeń psychotycznych, ADHD, jadłowstrętu psychicznego oraz autyzmu. Duże znaczenie mają tzw. cyfrowi terapeuci. Celem pracy jest ukazanie zastosowania narzędzi AI w diagnostyce oraz leczeniu zaburzeń psychicznych, a także korzyści oraz ograniczeń z nimi się wiążących.

Materiał i metoda: Dokonano przeglądu recenzowanych artykułów naukowych z lat 2015-2022. Podstawę stanowiły bazy danych PubMed, OpenKnowledge, Web of Science.

Dyskusja: Przegląd przeanalizowanej literatury wskazuje na szerokie zastosowanie narzędzi AI w przesiewowym

wykrywaniu zaburzeń psychicznych. Narzędzia te wyprzedzają diagnozę kliniczną stawianą przez lekarzy specjalistów nawet o kilka lat. Wpływają na rozwiązanie kwestii niedoborów kadry medycznej, braku dostępu do placówek medycznych oraz niwelowanie oporu pacjentów przed podjęciem leczenia. Korzyściami są: ultraszybka analiza dużych zbiorów informacji, efektywne przesiewowe badanie osób wymagających specjalistycznej opieki psychiatrycznej, redukcja obowiązków lekarzy i zmaksymalizowaniem efektywności ich pracy. Interwencje terapeutyczne za pośrednictwem narzędzi AI mogą poprawić dostęp do opieki zdrowotnej. W czasie obecnej pandemii COVID 19, szczególną rolę pełnią roboty w postaci cyfrowych psychoterapeutów

Wnioski: Wskazuje się na potrzebę dalszych badań, testów oraz sprecyzowanie regulacji prawnych związanych z korzystaniem z narzędzi AI. Rozwiązania wymagają też problemy etyczne i społeczne związane z ich użyciem. Narzędzia nie powinny stanowić podstawy samodzielnej terapii bez nadzoru wysoko wykwalifikowanych specjalistów. W centrum analiz powinien znaleźć się człowiek, a jego dobrostan zdrowotny powinien być priorytetem.

Słowa kluczowe: artificial intelligence, digital therapy, psychiatry, machine learning.

Introduction

Artificial intelligence (AI), has applications in many health science disciplines, including psychiatry. In broad terms, it is used to assess a patient's mental state through the use of advanced computer techniques such as automatic language processing and machine learning algorithms. The term artificial intelligence also refers to the science and engineering of creating intelligent machines [1]. AI is mainly based on deep learning algorithms and is gaining great interest due to its promising results in tests of image recognition and comparison and the creation of databases based on the analyzed information. It also allows us to measure with self-reports and clinical observations the mental state and treat disorders in this area of medicine [2]. The concept of using computers to simulate intelligent behavior and critical thinking was first described by Alan Turing in 1950 in his book *Computers and Intelligence*. He devised a simple test called the "Turing test" to determine whether computers could read human intelligence. After that, interest in AI and its tools have grown.

As it has evolved, AI has included more complex algorithms that work similarly to the human brain. There are many subfields of AI, such as machine learning (ML), deep learning (DL) and computer vision (CV). Machine learning involves identifying and analyzing patterns, refining through experience from provided data sets. The idea is to transform the raw data into a suitable internal representation or feature vector based on which the learning subsystem could detect or classify patterns in the input data [3]. Deep learning creates neural networks that enable machines to learn and make decisions autonomously [4]. DL algorithms are constantly being developed because of their commercial applications. They can autonomously detect high-level abstractions in input data [5]. Computer vision (CV) refers to the process by which a computer obtains information and understanding from a series of images or videos. These subfields are

integral to the correct diagnosis and treatment process in medicine.

The development of AI tools has not always been uniform. In the early days, "discoveries" of their applications were met with little interest and consequently reduced funding, as well as little scientific and technological progress in this area. Two periods of stagnation can be identified: the first in the late 1970s, caused by the perceived limitations of artificial intelligence, and the second between 1980 and 1990, caused by the high cost of creating and maintaining databases containing digital information. The later period saw a breakthrough in using computers in biomedicine and increased networking among clinical and biomedical researchers and their application in other scientific fields. AI research has shown that the ratio of results to inputs in medicine is more promising than in other fields [6]. The combination of AI and medicine is changing the traditional medical model and is an essential part of the development of modern medicine due to its potential benefits and future facilitation.

In this article, the authors attempt to show the diversity and usefulness of using artificial intelligence tools in the diagnosis and treatment of mental disorders. In addition, the benefits and challenges of using AI tools in medical practice for clinicians are presented. The article summarizes scientific research published between 2015 and 2022.

Materials and methods

This literature review was conducted by searching scientific articles from 2015 to 2022. The basis were PubMed, OpenKnowledge, Web of Science databases, using the following keywords: artificial intelligence, digital therapy, psychiatry, machine learning. Among the 2146 articles in the available database, 84 publications were included in this study after detailed analysis.

AI and its tools in psychiatry

Table 1.

Mental disorder	Application of AI tools
Schizophrenia	Analysis of speech transcripts, listing of linguistic markers, analysis of linguistic features of social media speech, analysis of brain tractography
ADHD	EEG recording analysis, test ANOVA,
Alzheimer Disease	Intelligent classification of MRI, PET and CSF fluid analysis results
Autism spectrum disorder	Screening based on machine learning of the ADOS schedule
Anorexia nervosa	Classification of brain MRI images, LASSO program

Source: own study.

In an era of rapid digital development, researchers seek new solutions for applying artificial intelligence to psychiatry. However, a major barrier to improving diagnosis is the lack of objective clinical tests using markers based on disease pathophysiology, routinely used in other medical specialties. The AI tools described in the article are presented in Table 1. Hence, only the first attempts are being made to diagnose mental disorders. An example of such efforts is the use of latent semantic analysis of LSA to analyze speech transcripts. Fakhoury et al. [1] define LSA as a high-dimensional tool for analyzing verbal speech transcripts. The tool can analyze text based on key concepts, using a computational technique in spoken language processing. Bedi et al. also used latent semantic analysis to assess the likelihood of psychosis in adolescents at a later age [7]. With the artificial intelligence tool described above, interview transcriptions were evaluated for semantic and syntactic features predicting the later onset of schizophrenia. The use of LSA could predict the later development of schizophrenia in the patients studied with an accuracy of 100%, compared to the clinical interviews conducted, using a lower score.

Many cases of schizophrenia remain untreated due to lack of diagnosis, self-denial and social stigma [9]. With the advent of social media, patients share their problems and seek support and treatment options. Statements shared on social media by schizophrenia patients form the basis of a content database for artificial intelligence tools [10]. Bae et al. [11] designed a study to analyze the feasibility of using machine learning for screening the diagnosis of schizophrenia patients based on statements shared on social media. The study gathered content from posts shared online on the schizophrenia platform Reddit

and those unrelated to mental health concerning everyday life topics for a control group. The authors analyzed the language functions and topics of the postings from the information obtained. Then, using artificial intelligence tools, they classified and interpreted the content of the statements of the patients. Consequently, it was possible to emerge linguistic markers of schizophrenia. The described contents differed from the utterances of healthy people in language construction, increased use of pronouns and third person plural forms, and were more often concerned with negative descriptions of emotions and feelings than positive ones. In addition, they more often referred to topics related to the symptoms of the disease. Based on the above data, the authors classified sick people with 96% accuracy [12]. Birbaum et al. described that by using machine learning algorithms, it is possible to differentiate statements contained in social networks of people with schizophrenia from healthy people more than a year before hospitalization. The authors point to the vital role of social media in diagnosing psychotic disorders. Based on the analysis of the language of the subjects' statements, they defined some characteristics typical of schizophrenia: patients express negative emotions more often than healthy people and more often bring up disease topics [13].

Another social media platform that can be used to screen for schizophrenia is Twitter. Mitchell et al. analyzed various linguistic features of schizophrenia using a machine learning method using a lexicon-based and open vocabulary approach. In addition, they classified schizophrenia-affected users from healthy individuals using linguistic features with 82% accuracy [14]. Similarly, Coppersmith et al. identified the linguistic features of various mental disorders, including schizophrenia, and examined their language use differences [15]. Salvador et al. [16] achieved 75.76% accuracy in diagnosing schizophrenia using machine learning techniques, and de Filippis et al. [17] reported that a support vector machine associated with other machine learning techniques can achieve accuracy close to 100%.

The described studies indicate that exploring mental health with artificial intelligence tools through the lens of language is fertile ground for advances in mental health. The wealth of information content recorded in social media provides an invaluable database to develop artificial intelligence tools for diagnosis on a broader scale.

In addition to linguistic markers, other forms of schizophrenia diagnosis are also being sought. Shi et al. [18] conducted a study of 72 patients using machine learning based on tractography analysis of the brain. Based on this method, the authors singled out patients with schizophrenia from a control sample. The authors

indicated that it is possible to classify schizophrenic patients based on the analysis of signals read from susceptible brain regions. In contrast, Zhu et al. [19] focused on aspects of the heritability of schizophrenia. They analyzed gene expression in patients with the condition using machine learning methods. The aim of the study was to differentiate schizophrenic patients from healthy individuals using the expression levels of informative RNAs in peripheral blood using machine learning algorithms or artificial neural networks. The expression of six mRNAs was detected using quantitative real-time polymerase chain reaction (qRT-PCR). The results of the described study helped suggest that using machine learning methods to analyze genes that determine schizophrenia is better than analyzing individual genes on their own. The study's authors indicate that artificial intelligence tools can be used to search for genetic biomarkers of schizophrenia.

Another example in which artificial intelligence tools have found application is a study comparing EEG recordings of adult patients for the diagnosis of attention deficit hyperactivity disorder (ADHD). The prevalence of the disorder in childhood is estimated at 5-9% [20]. ADHD symptoms can fade over time, but more than half of children with ADHD continue to manifest clinically significant symptoms after reaching maturity. Thereupon nearly 5% of adults worldwide are still struggling with the disorder [21]. The disorder is characteristic of early childhood, so most research has focused on diagnosing patients at the typical age for detecting ADHD [22]. As part of the diagnostic process, machine learning techniques often use an ANOVA test [23] based on EEG recordings. These methods have led to related results among researchers in diagnosing children and adolescents with ADHD. However, in the diagnosis of adult patients, they do not condition good results, so still, the diagnosis of the disorder in the adult population remains dependent on the skills and knowledge of the specialist.

Attempts have been made to distinguish individuals with ADHD from the healthy population using artificial intelligence methods [24]. Tenev et al. [25], based on the application of machine learning techniques, made a classification of ADHD subtypes in adult patients based on the power spectra of EEG measurements. A support vector machine classifier using differences in EEG potentials made it possible to distinguish adult ADHD patients from control groups.

Artificial intelligence tools also have applications in diagnosing Alzheimer's disease [26]. Wiltfang et al. reviewed machine learning and deep learning techniques in population detection and automatic classification of Alzheimer's disease. Based on a combination of data from ancillary MRI brain scans, PET scans and CSF fluid used

as neurobiological markers, they obtained diagnoses of patients with an accuracy of up to 98.8%.

The Autism Diagnostic General Observation Schedule (ADOS) is one of the most widely used tools for the behavioral assessment of autism spectrum disorders. The ADOS consists of four modules, and each targets a different group of patients due to the child's speech and mental development. In their study, Wall et al. [27] used machine learning algorithms to screen patients with an autism spectrum disorder. Based on only one selected module of the ADOS schedule, the authors of the study showed that using artificial intelligence tools, they could classify the disorder with 100% accuracy. The use of machine learning tools helped minimize the ADOS schedule items used - the authors used only 8 of the 29 items. This is particularly important because it can take up to an hour to perform a single module on a selected patient. In addition, the need for a child and adolescent psychiatry specialist to conduct the ADOS exam at a clinical facility contributes to delays in diagnosis and longer queues to see the specialist. Highly specialized facilities with this schedule are usually concentrated in large urban areas, associated with the following inequalities in access to health in rural areas. Hence, researchers are working on state-of-the-art solutions to diagnose ASD regardless of access to highly specialized facilities. Wall et al. applied 16 machine learning algorithms with data in multiple autism spectrum disorder (ASD) data repositories, including the Autism Genetics Resource Exchange (AGRE) and the Autism Consortium (AC). They suggested that the machine learning technique can differentiate between classic autism and other mental disorders with 100% accuracy. Bertonecchi et al. created a model for predicting the development of autism spectrum disorders among adolescents with cerebral palsy using artificial intelligence tools. The authors obtained an average accuracy prediction score of 75% [28]. The usefulness of applying artificial intelligence techniques to diagnose autism spectrum disorders was also highlighted by Choi et al., who analyzed patients to predict the development of ASD with an average accuracy of 96.3% [29]. Wall et al. [30] applied machine learning algorithms with data collected from multiple databases of information on ASD, including the Autism Genetic Resource Exchange (AGRE) and the Autism Consortium (AC). The authors indicated that artificial intelligence tools make it possible to differentiate between autism spectrum disorders and similar diseases with 100% accuracy [31].

Currently, no neuroanatomical biomarkers of mental anorexia nervosa [32] (AN) have been classified, allowing clinical conclusions to be drawn at the individual patient level. Lavagnino et al. worked using a machine learning multidimensional approach to screening for mental

anorexia nervosa. The authors analyzed brain MRI images from 15 hospitalized female patients and an equal number of healthy girls of similar age. Neuroanatomical volumes were extracted using FreeSurfer software and fed into a multidimensional machine learning algorithm (Least Absolute Shrinkage and Selection Operator - LASSO). The described artificial intelligence tool was adapted to identify new subjects as anorexia patients or healthy control subjects. In addition, the model estimated the probability that a person belonged to the AN group based on an individual scan. The machine learning algorithm correctly classified 83% of the patients as having anorexia. The study showed that several areas of the brain subjected to the scans - the white matter of the cerebellum, choroid plexus, shell, midbrain, intercerebrum and third ventricle - were significant in differentiating patients with AN from the healthy population.

Artificial intelligence in treatment

Challenges such as the shortage of mental health personnel, long waiting times and the perceived stigma of mental disorders are major obstacles to mental health treatment. Psychotherapy, an essential component of treatment, only provides support for a limited period. A modern solution that can change the reality of mental disorder treatment are artificial intelligence solutions, using the example of intelligent robots conducting therapy with the patient. Modern technology can provide additional support, especially with the existing inequalities in access to mental health services around the world. Examples of AI applications in the treatment of mental disorders are shown in Table 2.

Table 2.

The AI tools	Application
Intelligent robot therapist	Reduction of symptoms of depression and anxiety
Intelligent robot-animal	Assist dementia patients with daily activities
Avatar therapy	Creating a virtual image of the stalking voice
Intelligent robot	Rehabilitation of autism spectrum disorders
SAR therapy	Supporting the establishment of interpersonal relations
ReSET-O application	Supervision of the opioid addiction treatment process
CAT therapy	Cognitive-behavioral therapy
MOST platform	Group therapy
Youper	A stand-alone form of depression therapy

Source: own study.

Chatbots providing cognitive-behavioral therapy succeeded in being effective in reducing symptoms of depression and anxiety. Brunn et al. showed a reduction in the severity of depressive symptoms in patients working with the intelligent robot Woebot compared to other study groups using only e-book resources [33]. Woebot participated in the treatment process with the patient as an intelligent therapist [34]. Similar conclusions were reached by Sachan et al., who described the use of an analogous robot, Tess, which was created to respond to the emotional distress of patients with anxiety disorders. The authors showed that the use of the Tess robot helps patients treat depression and various types of phobias [35]. Other chatbots used to treat depressive symptoms include Sara and Wysa [36]. Similar solutions were described by Fulmer et al. [37] in their evaluation of the effectiveness of a psychological intervention using the Tess robot to reduce the severity of depressive symptoms in adolescents.

Among the latest artificial intelligence tools developed to support people with dementia, there are intelligent animal-like robots, such as Paro, Harp seal, or eBear. They are programmed as companion robots, helping the elderly with basic home activities. In addition to providing support in daily life, they act as companions and provide interaction based on intelligent, communicative dialogue [38]. Petersen et al. [39] described a study evaluating the effectiveness of a PARO robot in treating symptoms associated with dementia. They showed that using an intelligent robotic companion reduced stress and anxiety in the study group. In addition, the authors observed less frequent use of psychoactive substances and painkillers by patients with dementia.

Auditory-verbal hallucinations are characteristic symptoms of schizophrenia and are among the most disturbing symptoms of the disease. Artificial intelligence solutions being introduced in schizophrenia therapy focus mainly on the interaction between the patient and the voices the patient experiences. The developers of the Avatar therapy sought to create as close to a real-life representation of the persecutory voice as possible. Leff et al. [40] described Avatar Therapy (AT), which, using machine learning methods, allows patients to create a virtual image of their stalker. Patients were invited to converse with an avatar animated by the therapist. The goal of the therapy above is to learn to control auditory symptoms. The created avatar was designed to reflect both the stalker's face and voice. With the help of therapists, patients learned how to respond to his speech and cope with him [41]. Dellazizzo et al. conducted similar tests using Avatar therapy [42]. The research team obtained positive results from the use of the above intelligent robot: an improvement in the mastery of positive symptoms,

a reduction in hostile attitudes toward other people, and a reduction in the severity of depressive symptoms. Quality of life improved at the 3-month follow-up. Similar conclusions were reached in their study by Craig et al. [43].

Most of the studies analyzed the therapy of children with ASD focus on improving the social communication skills of children with autism and measuring the extent to which robots mitigate the stereotypical behaviors typical of the disorder. Scassellati et al. described the use of intelligent robots in rehabilitating children treated for autism spectrum disorders. The authors showed that the use of artificial intelligence tools improves patients' cognitive abilities and social interaction. However, much more research is needed to bring such robots into widespread use [44]. SAR therapy, which focuses on supporting patients' social functioning and establishing interpersonal contacts, has also been applied in the treatment of autism spectrum disorders [45]. Autism therapy is one of the first studied areas of SAR applications [46]. The effectiveness of intelligent robots in ASD therapy is evidenced by the cases described by Kozim et al. [47] of cases of children developing emotional behavior toward robotic therapists.

In addition to applied intelligent robots, intelligent applications are also showing promising results in the treatment of mental health disorders. An example is reSET-O, a program downloaded to a phone and available by prescription. The app allows monitoring the treatment process of opioid use disorders. The program has a built-in pharmacotherapy reminder function and controls the next steps of outpatient treatment. Wozniacka et al. [48] conducted an analysis in which patients were instructed to use the reSET-O app for 12 weeks. Users of the program achieved better treatment outcomes than the control group that did not use the app.

Another example of the use of artificial intelligence is computer-assisted therapy (CAT) [1]. This program is rich in videos and questionnaires that the patient can access through a digital platform. CAT is designed to support patients in cognitive-behavioral therapy and interpersonal interactions. MOST social therapy, which provides a type of group therapy to patients with mental disorders through an online platform, has similar characteristics. The MOST method is essential [49] especially among adolescents, due to the ability to maintain contact with peers [50] and access to social networks. To date, MOST therapy has been used among patients with psychosis and depression [51-52]. MOST therapy is also described in their study by D'Alfonso et al. [53] as smart support for mental health therapy for young people. Long-term results of the platform's activities have not been described, so patients should be observed for long-term effects.

Other intelligent apps used to treat mental disorders

include Youper, used to treat anxiety and depression [54]. Users well regard the program as an inexpensive, stand-alone form of treatment for those without access to specialized psychiatric care. Users of Youper have emphasized the app's effectiveness in combating symptoms of anxiety and depression.

The above solutions provide evidence that artificial intelligence tools have many applications in the treatment of mental disorders and should serve as a widely available therapeutic agent. With proper supervision by a qualified professional, artificial intelligence therapies represent promising solutions to global mental health challenges.

Artificial intelligence in suicide risk assessment

Technological advances, and with them, the advancement of analytical tools, including artificial intelligence, could radically transform one of the biggest problems in psychiatry of the day - suicide. Nevertheless, predicting the risk of suicide based on a few patients' feedback, previous diagnosis and treatment history is a big problem even for experienced specialists. This has to do with the complexity of the processes and factors responsible for the basis of suicide and the problems associated with identifying the right people in a vast population of people with very similar symptoms or risk factors. The central premise of AI in psychiatry is to develop methods that would identify suicide risk factors while taking into account complex interactions between specific variables. Based on the limitations presented, the development of statistically advanced machine learning (UM) methods is being pursued to improve the reliability of diagnoses and the quality of care for people at risk of suicide. One of the most significant advantages that UM methods offer is the ability to analyze vast amounts of data from medical records and the associations between suicide risk and risk factors such as current mental illness, emotional disturbance, treatment history, or addiction [55]. Analysis of online search history patterns has been used to identify individual risk factors [56]. Moreover, studies have shown that in some cases, analysis of Google data by AI tools significantly better estimated the probability of suicide than traditional descriptive scales [57]. The development of predictive models relies primarily on accurately identifying risk factors through specialized exploratory analysis. Predictive analytics helps identify individuals at risk for suicide and estimating the likelihood that these individuals will attempt suicide in the future. This is made possible by matrices, which are created by combining multiple data including, but not limited to, risk factors to non-linear model relationships between them.

Large clinical databases are being used to develop, refine and validate suicide prediction algorithms [58].

There are two dominant domains of suicide risk identified from exploratory analyses. The first is a clinical risk, which includes prognostic and diagnostic factors related to treatment, such as sudden mood change, history of self-harm, psychiatric comorbidities, and prior hospitalizations [59]. The second is a cognitive risk, which refers to thoughts related to life satisfaction, overall purpose, feelings of hopelessness, self-esteem, and self-perception [60].

Studies have shown that using machine learning algorithms to assess the writing patterns of psychiatric patients can predict a possible suicide attempt up to 10 weeks in advance, with as much as an 80% accuracy rate [61]. When the above AI tool is applied to data sources received in real-time, e.g., from social media, instant messaging conversations or smartphone apps, it has a great opportunity to enable early identification of the risk of a suicide attempt. Furthermore, it gives the specialist more time to develop an appropriate and effective prevention method. Moreover, machine learning has been extended to natural language processing (NLP). It enables devices to manipulate, interpret and respond to natural human language in written and spoken form. NLP is able to distinguish between authentic and simulated notes of possible suicide with greater efficiency than psychiatrists [62]. Algorithms have also been designed to automate the detection of emotions in suicide notes using affective computing [63] and to help classify the content of statements into specific thematic subgroups [64].

Benefits associated with the use of artificial intelligence

The primary goal of artificial intelligence (AI) is to develop technologies that best serve humanity. The expected acceleration of technological development over the coming decades will lead to a proliferation of applied artificial intelligence. We can already see many benefits from its use.

The main advantage of artificial intelligence in healthcare applications is the ultra-fast analysis of large sets of information [65]. The processing of high-quality data by machines can be used to quickly and efficiently screen people who require specialized psychiatric care. Using artificial intelligence in primary health services, specialists could focus mainly on patients who need real help. This would have the effect of reducing doctors' additional duties and maximizing the efficiency of their work. This is particularly important in areas where there is a shortage of psychiatrists.

In their discussion, Erden et al. point out that removing face-to-face interactions with the therapist and programming an understanding of the ASD patient's behavior into artificial intelligence diagnostic tools can help reduce the waiting time faced by many adults

awaiting diagnosis. In addition, the solutions described could help reduce the number of false diagnostic negatives that occur due to masking other learned behaviors. According to the latest statistics from NHS Digital dated August 2020, people over 18 waiting for referral and diagnosis between April 2019 and January 2020 waited for an average of 361 days from first contact with a doctor for diagnosis. The older the patient, the longer the diagnostic process took, with those aged 45-54 and 55-64 waiting for an average of 480 days [74].

Similarly, Fiske et al., showed that people with autism spectrum disorder fared better with their robot partners than with human therapists, responded with social behavior toward the robots, and improved spontaneous language during therapy sessions [75]. Therefore, virtual applications or robots may be preferable for mental health services for some patients, as they will improve trust and interpersonal responses by minimizing patient contact with the alien therapist [76]. In addition, artificial intelligence tools may reduce embarrassment or shame, which is often the cause of concealment of the patient's symptoms or problems and prevents maximum insight into the disease [77]. The important thing about having such a robotic psychotherapist is that he is always available to the patient and can conduct numerous therapies. In addition, it is always patient and doesn't judge anyone [75,78].

Risks of using AI tools in psychiatry

Despite the continuous development of artificial intelligence tools, some issues of their use are being considered by skeptics. Most current artificial intelligence applications involve making logical decisions or drawing conclusions based on programmed rules. However, when it comes to clinical decision-making, robots still need improvement. Therapeutic oversight of a patient requires more than intelligent, concrete thinking - consideration of ethical issues, moral issues, empathy and feelings that robots cannot understand. This barrier continues to block the introduction of robotic interventions into psychiatric care on a large scale [79]. The robots' inability to show affection or care leads to a cold relationship with the robot and does not foster patient engagement in therapy. As a result, individuals who rely solely on AI-based interventions are often discouraged from continuing treatment [80].

Concerns about patient privacy have also been raised about artificial intelligence tools. The amount of collected data processed by AI continues to grow. So far, no legal standards have been set for applications that integrate video data regarding privacy safeguards [81]. Nor have rules been developed for robots to store sensitive patient data. Privacy risks mainly affect the elderly or

intellectually disabled, who may not understand the functioning of a robot installed at home [82]. Currently, existing robots have not yet been tested on a large scale. Artificial intelligence research to date is mostly conducted by the developers of individual tools, who aim to demonstrate the effectiveness of their products, which is directly related to financial gain. This poses the risk of a lack of objectivity in testing due to the strenuous pursuit of positive results [83].

Long-term use of intelligent robots as the only form of therapy can result in reduced interpersonal relationships due to fear and stress from people [84]. Such limitations on interpersonal relationships may lead to the development of new mental disorders in the future, which, again treated with artificial intelligence tools, will lead to a vicious cycle.

Summary

There is still a need for thorough, large-scale, reliable, particularly randomized controlled clinical trials that will present objective results of AI applications in healthcare. In light of the demonstrated benefits of AI tools and the opportunities these tools bring, there is

an expansion of the reach of mental health services to underserved populations and an improvement in service delivery by mental health specialists. It is necessary to revise and create guidelines for the proper use of AI in mental health services, as well as recommendations on how doctors should be trained and prepared to use AI-based techniques, preferably by specially established organizations dedicated to managing such services. The authors emphasize the need to establish regulations for the management of artificial intelligence tools. Despite the implementation of modern digital solutions into healthcare, AI tools should not form the basis of stand-alone therapy without the supervision of highly trained professionals. Any applications offered outside of mental health facilities, such as programs and bots, should be required to present reliable pathways for risk assessment and referral to appropriate services in the event of loss of life. This is to maximize the services' reliability and offset possible errors generated by AI.

In conclusion, there is a need to monitor both the benefits and effects of the use of artificial intelligence tools in psychiatry, noting that human beings should be at the center of analysis, and their health and well-being should be a priority.

Wprowadzenie

Sztuczna inteligencja, z ang. artificial intelligence (AI), ma zastosowanie w wielu dyscyplinach naukowych nauk o zdrowiu m.in. w psychiatrii. W szerokim ujęciu jest wykorzystywana do oceny stanu psychicznego pacjenta poprzez wykorzystanie zaawansowanych technik komputerowych, takich jak automatyczne przetwarzanie języka i algorytmy uczenia maszynowego. Termin sztuczna inteligencja oznacza także naukę i inżynierię tworzenia inteligentnych maszyn [1]. AI oparta jest głównie na algorytmach uczenia głębokiego, zyskuje ogromne zainteresowanie ze względu na obiecujące wyniki w testach rozpoznawania i porównywania obrazów oraz tworzenia baz danych w oparciu o przeanalizowane informacje. Pozwala także na zmierzenie za pomocą samoopisów i obserwacji klinicznych stanu psychicznego oraz jest wykorzystywana do leczenia zaburzeń w tym obszarze medycyny [2]. Koncepcję używania komputerów do symulowania inteligentnego zachowania i krytycznego myślenia po raz pierwszy opisał Alan Turing w 1950 roku w książce *Computers and Intelligence*. Wymyślił on prosty test zwany jako „test Turninga”, który pozwalał na określenie, czy komputery były zdolne do odczytywania ludzkiej inteligencji. Po tym wydarzeniu zainteresowanie AI i jej narzędziami wzrosło.

W miarę rozwoju, AI obejmowała bardziej złożone

algorytmy, które działają podobnie do ludzkiego mózgu. Istnieje wiele poddziedzin AI takich jak: uczenie maszynowe (ML), głębokie uczenie (DL) i widzenie komputerowe (CV). Uczenie maszynowe obejmuje identyfikację i analizę wzorców, doskonalenie dzięki doświadczeniu z dostarczonych zbiorów danych. Chodzi o przekształcenie surowych danych w odpowiednią wewnętrzną reprezentację lub wektor cech, na podstawie którego podsystem uczący, mógł wykryć lub klasyfikować wzorce na danych wejściowych [3]. Głębokie uczenie tworzą sieci neuronów, które umożliwiają maszynom samodzielne uczenie się i podejmowanie decyzji [4]. Algorytmy DL są stale rozwijane z uwagi na ich komercyjne zastosowanie. Są zdolne do samodzielnego wykrywania wysokopoziomowych abstrakcji w danych wejściowych [5]. Wizja komputerowa (CV) oznacza proces, dzięki któremu komputer uzyskuje informacje i zrozumienie z serii obrazów lub filmów. Te wszystkie poddziedziny są nierozzerwalną częścią prawidłowej diagnozy i procesu leczenia w medycynie.

Rozwój narzędzi AI nie zawsze był równomierny. W początkowym okresie „odkrycia” ich zastosowań spotkały się z małym zainteresowaniem i w konsekwencji zmniejszonym finansowaniem, a także małym postępem naukowo-technicznym w tym obszarze. Można tu wskazać na dwa okresy stagnacji: pierwszy w późnych

latach 70. ub. wieku, spowodowany postrzeganymi ograniczeniami sztucznej inteligencji, a drugi w latach 1980-1990, spowodowany wysokimi kosztami tworzenia i utrzymywania baz danych zawierających informacje cyfrowe. W późniejszym okresie nastąpił przełom w zastosowaniu komputerów w biomedycynie i zwiększeniu współpracy sieciowej wśród badaczy klinicznych i biomedycznych, a ich zastosowaniu w innych dziedzinach nauki. Badania nad sztuczną inteligencją wykazały, że stosunek wyników do nakładów w medycynie jest bardziej obiecujący niż w innych dziedzinach [6]. Połączenie AI i medycyny zmienia tradycyjny model medyczny i ważny element rozwoju nowoczesnej medycyny ze względu na swoje potencjalne korzyści oraz ułatwienia w przyszłości.

Materiały i metody

Dokonano przeglądu recenzowanych artykułów naukowych z lat 2015-2022. Podstawę stanowiły bazy danych PubMed, OpenKnowledge, Web of Science, przy użyciu następujących słów kluczowych: sztuczna inteligencja, cyfrowa terapia, psychiatria, uczenie maszynowe. Spośród 2146 artykułów w dostępnej bazie, po szczegółowej analizie w niniejszej pracy uwzględniono 84 publikacje.

AI i jej narzędzia w psychiatrii

Tabela 1.

Zaburzenie psychiczne	Zastosowanie narzędzi AI
Schizofrenia	Analiza transkryptów mowy, wyszczególnienie markerów językowych, analiza cech językowych wypowiedzi w mediach społecznościowych, analiza traktografii mózgu
ADHD	Analiza zapisu EEG, test ANOVA,
Choroba Alzheimera	Inteligentna klasyfikacja wyników badań MRI, PET oraz analizy płynu CSF
Zaburzenie ze spektrum autyzmu	Przesiewowa diagnostyka w oparciu o uczenie maszynowe harmonogramu ADOS
Anoreksja	Klasyfikacja obrazów MRI mózgu, program LASSO

Źródło: opracowanie własne.

W dobie szybkiego rozwoju technologii cyfrowej naukowcy poszukują nowych rozwiązań zastosowania sztucznej inteligencji w psychiatrii. Jednak poważną barierę w udoskonalaniu diagnostyki stanowi brak obiektywnych testów klinicznych z wykorzystaniem markerów opartych na patofizjologii choroby, rutynowo stosowanych w innych specjalizacjach medycznych.

Stąd też podejmowane są dopiero pierwsze próby diagnozowania zaburzeń psychicznych. Opisane w artykule narzędzia AI przedstawia tabela 1. Przykładem takich działań jest zastosowanie utajonej analizy semantycznej LSA do analizy transkryptów mowy. Fakhoury i in. [1] definiują LSA jako wysoko wymiarowe narzędzie do analizy zapisów wypowiedzi słownych. Stosując technikę obliczeniową w przetwarzaniu języka mówionego narzędzie jest w stanie dokonać analizy tekstu w oparciu o kluczowe pojęcia. Bedi i in. również posługując się utajoną analizą semantyczną, dokonali oceny prawdopodobieństwa wystąpienia psychozy u nastolatków w wieku późniejszym [7]. Za pomocą opisywanego narzędzia sztucznej inteligencji transkrypcje wywiadów zostały ocenione pod kątem cech semantycznych i syntaktycznych przewidujących późniejszy początek schizofrenii. Użycie LSA pozwoliło przewidzieć późniejszy rozwój schizofrenii u badanych pacjentów z dokładnością 100%, w porównaniu do przeprowadzonych wywiadów klinicznych, przy użyciu których osiągnięto niższy wynik.

Podobne badania przeprowadzili Elvevag i in., którzy dokonali analizy zapisów wypowiedzi pacjentów chorujących na schizofrenię w porównaniu do zdrowych ochotników z grupy kontrolnej, niespokrewnionych z badanymi. W oparciu o użycie narzędzi sztucznej inteligencji możliwe było dokładne rozróżnienie między krewnymi pierwszego stopnia pacjentów ze schizofrenią, a niespokrewnionymi osobami zdrowymi. Autorzy zwrócili uwagę, że za pomocą komputerowej analizy mowy można odróżnić subtelne różnice, wskazujące na podatność genetyczną pacjenta na schizofrenię [8].

Wiele przypadków schizofrenii pozostaje nieleczonych z powodu braku diagnozy, samozaparcia i napiętnowania społecznego [9]. Wraz z pojawieniem się mediów społecznościowych chorzy dzielą się swoimi problemami i szukają wsparcia oraz możliwości leczenia. Udostępnione w mediach społecznościowych wypowiedzi chorych na schizofrenię stanowią podstawę do tworzenia bazy danych treści dla narzędzi sztucznej inteligencji [10]. Bae i in. [11] opracowali badanie, którego celem była analiza możliwości wykorzystania uczenia maszynowego do diagnostyki przesiewowej chorych na schizofrenię na podstawie wypowiedzi udostępnianych w mediach społecznościowych. Badanie polegało na zgromadzeniu treści z postów udostępnionych w internecie na platformie Reddit poświęconej schizofrenii, a także tych niezwiązanych ze zdrowiem psychicznym – dotyczących tematów życia codziennego dla grupy kontrolnej. Z uzyskanych informacji autorzy przeanalizowali funkcje językowe i tematy wypowiedzi. Następnie korzystając z narzędzi sztucznej inteligencji dokonali klasyfikacji oraz interpretacji treści wypowiedzi osób chorych.

W konsekwencji było możliwe wyłonienie markerów językowych schizofrenii. Opisane treści różniły się od wypowiedzi osób zdrowych konstrukcją języka, zwiększonym użyciem zaimków i form w liczbie mnogiej osoby trzeciej oraz częściej dotyczyły negatywnych opisów emocji i uczuć niż pozytywnych. Ponadto częściej nawiązywały do tematów związanych z objawami choroby. Bazując na powyższych danych, autorzy dokonali klasyfikacji osób chorych z dokładnością do 96% [12]. Birbaum i in. opisali, że przy zastosowaniu algorytmów uczenia maszynowego istnieje możliwość różnicowania wypowiedzi zawartych w sieciach społecznościowych osób chorych na schizofrenię od zdrowych na ponad rok przed hospitalizacją. Autorzy wskazują na istotną rolę mediów społecznościowych w diagnozowaniu zaburzeń psychiatrycznych. W oparciu o analizę języka wypowiedzi badanych zdefiniowali pewne cechy typowe dla schizofrenii: chorzy częściej od osób zdrowych wyrażają negatywne emocje, częściej poruszają tematy chorobowe [13].

Inną platformą społeczną, przy użyciu której można przesiewowo diagnozować schizofrenię jest Twitter. Mitchell i in. przeanalizowali różne cechy językowe schizofrenii przy użyciu podejścia opartego na leksykonie i otwartego słownictwa metodą uczenia maszynowego. Ponadto sklasyfikowali użytkowników dotkniętych schizofrenią od osób zdrowych za pomocą cech językowych z dokładnością do 82% [14]. Podobnie Coppersmith i in. określili cechy językowe różnych schorzeń psychicznych, w tym schizofrenii, i zbadali różnice w używaniu języka między nimi [15]. Salvador i in. [16] osiągnęli 75,76% dokładności w diagnozie schizofrenii z użyciem techniki uczenia maszynowego, a de Filippis i in. [17] poinformowali, że maszyna wektorów nośnych powiązana z innymi technikami uczenia maszynowego może osiągnąć dokładność bliską 100%.

Opisane badania wskazują, że badanie zdrowia psychicznego narzędziami sztucznej inteligencji przez pryzmat języka jest podatnym gruntem dla postępów w zakresie zdrowia psychicznego. Bogactwo informacji treści zapisanych w mediach społecznościowych stanowi nieoszacowaną bazę danych, na której można rozwijać narzędzia sztucznej inteligencji do diagnostyki na szerszą skalę.

Oprócz markerów językowych poszukiwane są również inne formy diagnostyki schizofrenii. Shi i wsp. [18] przeprowadzili badanie 72 pacjentów za pomocą uczenia maszynowego na podstawie analizy traktografii mózgu. W oparciu o tę metodę dokonano wyszczególnienia pacjentów ze schizofrenią od próby kontrolnej. Autorzy wskazali, że możliwe jest klasyfikowanie pacjentów chorych na schizofrenię w oparciu o analizę sygnałów odczytanych z podatnych regionów mózgu. Natomiast

Zhu i wsp. [19] skupili się na aspektach dziedziczności schizofrenii. Używając metod uczenia maszynowego dokonali analizy ekspresji genów u pacjentów chorych. Celem badania było różnicowanie pacjentów ze schizofrenią od osób zdrowych przy użyciu poziomu ekspresji RNA informacyjnego we krwi obwodowej za pomocą algorytmów uczenia maszynowego, czyli sztucznych sieci neuronowych. Ekspresję sześciu mRNA wykryto za pomocą ilościowej reakcji łańcuchowej polimerazy w czasie rzeczywistym (qRT-PCR). Wyniki opisywanego badania pozwoliły zasugerować, że stosowanie metod uczenia maszynowego do analizy genów warunkujących schizofrenię jest lepsze niż samodzielna analiza poszczególnych genów. Autorzy badania wskazują, że narzędzia sztucznej inteligencji mogą być użyte do poszukiwania genetycznych biomarkerów schizofrenii.

Innym przykładem, w którym narzędzia sztucznej inteligencji znalazły zastosowanie, są badania porównujące zapis EEG dorosłych pacjentów w celu diagnostyki zespołu nadpobudliwości ruchowej z deficytem uwagi (ADHD). Częstość występowania zaburzenia w dzieciństwie szacuje się na 5–9% [20]. Objawy ADHD mogą z czasem zanikać, jednak ponad połowa dzieci z ADHD nadal przejawia klinicznie istotne objawy po osiągnięciu dorosłości. Oznacza to, że prawie 5% dorosłych na całym świecie nadal zmaga się z chorobą [21]. Zaburzenie jest charakterystyczne dla wieku wczesnodziecięcego, dlatego większość badań skupia się na diagnostyce pacjentów w wieku typowym dla wykrywania ADHD [22]. W ramach procesu diagnostycznego techniki uczenia maszynowego są stosowane najczęściej w oparciu o test ANOVA [23] na podstawie zapisu EEG. Metody te doprowadziły do powiązanych wyników między badaczami w diagnozie dzieci i młodzieży z ADHD. Jednak w diagnozie pacjentów dorosłych nie warunkują one dobrych efektów, dlatego nadal diagnoza zaburzenia w populacji osób dorosłych pozostaje uzależniona od umiejętności i wiedzy specjalisty.

Podjęto próby wyróżnienia osób z ADHD populacji zdrowej przy użyciu metod sztucznej inteligencji [24]. Tenev i wsp. [25] w oparciu o zastosowanie technik uczenia maszynowego dokonali klasyfikacji podtypów ADHD u dorosłych pacjentów na podstawie widm mocy pomiarów EEG. Poprzez klasyfikator maszynowy wektora nośnego wykorzystujący różnice potencjałów EEG możliwe było odróżnienie dorosłych pacjentów z ADHD od grup kontrolnych.

Narzędzia sztucznej inteligencji znalazły zastosowanie również w diagnostyce choroby Alzheimera [26]. Wiltfang i in. dokonali przeglądu technik uczenia maszynowego oraz głębokiego uczenia w zastosowaniu wykrywania w populacji oraz automatycznej klasyfikacji

choroby Alzheimera. W oparciu o kombinację danych z badań pomocniczych MRI mózgu, PET oraz płynu CSF zastosowanych jako markerów neurobiologicznych, otrzymano wyniki diagnozowanych pacjentów z dokładnością do 98,8%.

Ogólny Harmonogram Obserwacji Diagnostyki Autyzmu (ADOS) jest jednym z najczęściej używanych narzędzi do oceny behawioralnej zaburzeń ze spektrum autyzmu. ADOS składa się z czterech modułów, a każdy skierowany jest do innej grupy pacjentów ze względu na rozwój mowy oraz rozwój psychiczny dziecka. Wall i wsp. [27] w swoich badaniach wykorzystali algorytmy stosowane w uczeniu maszynowym do przesiewowej diagnostyki pacjentów z zaburzeniem ze spektrum autyzmu. Bazując tylko na jednym wybranym module harmonogramu ADOS autorzy badania wykazali, że korzystając z narzędzi sztucznej inteligencji byli w stanie sklasyfikować zaburzenie z 100% dokładnością. Zastosowanie narzędzi uczenia maszynowego pozwoliło do minimum ograniczyć wykorzystane pozycje z harmonogramu ADOS – autorzy zastosowali jedynie 8 z 29 pozycji. Jest to szczególnie istotne, ponieważ przeprowadzenie jednego modułu na wybranym pacjencie może trwać nawet do godziny. Dodatkowo konieczność przeprowadzania egzaminu ADOS w placówce klinicznej przez specjalistę psychiatrii dzieci i młodzieży przyczynia się do opóźnień w diagnozie oraz wydłużenia kolejek do specjalisty. Wysokospecjalistyczne placówki dysponujące tym harmonogramem skupione są zazwyczaj w dużych aglomeracjach miejskich, co wiąże się z następującymi nierównościami w dostępie do zdrowia na terenach wiejskich. Stąd też badacze pracują nad nowoczesnymi rozwiązaniami, które umożliwią diagnozę zaburzeń ze spektrum autyzmu (ASD) niezależnie od dostępu do wysokospecjalistycznych placówek. Wall i in. zastosowali 16 algorytmów uczenia maszynowego z danymi w wielu repozytoriach danych zaburzeń ze spektrum autyzmu, w tym w Autism Genetic Resource Exchange (AGRE) i Autism Consortium (AC), i zasugerowali, że technika uczenia maszynowego umożliwia różnicowanie klasycznego autyzmu i innych zaburzeń psychicznych ze 100% dokładnością. Bertoni i in. stworzyli przy pomocy narzędzi sztucznej inteligencji model prognozowania rozwoju zaburzeń ze spektrum autyzmu wśród młodzieży z porażeniem mózgowym. Autorzy uzyskali średni wynik prognozowania o dokładności 75% [28]. Przydatność stosowania technik sztucznej inteligencji do diagnostyki zaburzeń ze spektrum autyzmu podkreślili również Choi i in., którzy dokonali analizy pacjentów w celu przewidzenia rozwoju ASD ze średnią dokładnością 96,3% [29]. Wall i in. [30] zastosowali algorytmy uczenia maszynowego z danymi zgromadzonymi w wielu bazach informacji na temat

ASD, w tym Autism Genetic Resource Exchange (AGRE) i Autism Consortium (AC). Autorzy wskazali, że narzędzia sztucznej inteligencji umożliwiają różnicowanie zaburzeń spektrum autyzmu oraz podobnych chorób ze 100% dokładnością [31].

Obecnie nie sklasyfikowano żadnych biomarkerów neuroanatomicznych jądrostrętu psychicznego [32] (AN), pozwalających na wyciągnięcie wniosków klinicznych na poziomie indywidualnego pacjenta. Lavagnino i in. pracowali przy użyciu uczenia maszynowego wielowymiarowe podejście do przesiewowej diagnostyki jądrostrętu psychicznego. Autorzy przeanalizowali obrazy rezonansu mózgu u 15 hospitalizowanych pacjentek oraz takiej samej liczby zdrowych dziewcząt w zbliżonym wieku. Objętości neuroanatomiczne wyodrębniono za pomocą oprogramowania FreeSurfer i wprowadzono do wielowymiarowego algorytmu uczenia maszynowego (Least Absolute Shrinkage and Selection Operator - LASSO). Opisywane narzędzie sztucznej inteligencji dostosowano do identyfikacji nowych osób jako chorych na anoreksję lub zdrowych osób z grupy kontrolnej. Ponadto model oszacował prawdopodobieństwo, że dana osoba należała do grupy AN na podstawie indywidualnego skanu. Algorytm uczenia maszynowego poprawnie sklasyfikował 83% pacjentów jako chorych na anoreksję. Badanie wykazało, że kilka obszarów mózgu poddanych skanom - istota biała mózdzku, splot naczyńkowy, skorupa, półkole, międzymózgowie i trzecia komora są istotne w różnicowaniu pacjentów z AN od zdrowej populacji.

Sztuczna inteligencja w leczeniu

Wyzwania takie jak niedobór personelu zajmującego się zdrowiem psychicznym, długi czas oczekiwania oraz postrzegane piętno zaburzeń psychicznych są poważną przeszkodą w terapii zdrowia psychicznego. Psychoterapia będąca istotnym elementem leczenia zapewnia wsparcie jedynie w określonym czasie. Nowoczesnym rozwiązaniem mogącym zmienić rzeczywistość leczenia zaburzeń psychicznych są rozwiązania sztucznej inteligencji na przykładzie inteligentnych robotów prowadzących terapię z pacjentem. Nowoczesne technologie mogą zapewnić dodatkowy rodzaj wsparcia, zwłaszcza przy istniejących nierównościami w dostępie do usług zdrowia psychicznego na świecie. Przykłady zastosowań AI w leczeniu zaburzeń psychicznych przedstawia Tabela 2.

Wykazano, że chatboty zapewniające terapię poznawczo-behawioralną, są skuteczne w zmniejszaniu objawów depresji i lęku. Bruni i in. wykazali zmniejszenie nasilenia objawów depresji u pacjentów pracujących z inteligentnym robotem Woebotem w porównaniu do

Tabela 2.

Narzędzie sztucznej inteligencji	Zastosowanie
Inteligentny robot-terapeuta	Redukcja objawów depresji i lęków
Inteligentne roboty-zwierzęta	Pomoc w codziennych czynnościach pacjentom chorym na demencję
Terapia Avatar	Stworzenie wirtualnego obrazu głosu prześladowczego
Inteligentny robot	Rehabilitacja zaburzeń ze spektrum autyzmu
Terapia SAR	Wspomaganie nawiązywania kontaktów interpersonalnych
Aplikacja reSET-O	Nadzór procesu leczenia uzależnienia od substancji opioidowych
Terapia CAT	Terapia poznawczo-behawioralna
Platforma MOST	Terapia grupowa
Youper	Samodzielna forma terapii depresji

Źródło: opracowanie własne.

innych grup badanych, korzystających tylko z zasobów książek elektronicznych [33]. Woebot brał udział w procesie leczniczym z pacjentem w roli inteligentnego terapeuty [34]. Do podobnych wniosków doszli Sachan i in., którzy opisali, że zastosowanie analogicznego robota Tess, którego stworzono do reagowania na niepokój emocjonalny pacjentów z zaburzeniami lękowymi. Autorzy wykazali, że korzystanie z usług robota Tess pomaga pacjentom w leczeniu depresji oraz różnego rodzaju fobii [35]. Inne chatboty wykorzystywane w terapii objawów depresji to Sara i Wysa [36]. Podobne rozwiązania opisali Fulmer i in. [37] w swojej ocenie skuteczności wykorzystania interwencji psychologicznej z użyciem robota Tess w celu zmniejszenia nasilenia objawów depresyjnych u młodzieży.

Do najnowszych narzędzi sztucznej inteligencji opracowanych w celu wsparcia osób cierpiących na demencję należą inteligentne roboty przypominające zwierzęta, np. Paro, foka Harfa lub eBear. Są one zaprogramowane jako roboty towarzyszące, pomagające osobom starszym w podstawowych czynnościach w domu. Oprócz wsparcia w życiu codziennym, spełniają rolę towarzysza oraz zapewniają interakcję na zasadzie komunikatywnego inteligentnego dialogu [38]. Petersen i in. [39] opisali badanie oceniające skuteczność robota PARO w leczeniu objawów związanych z demencją. Wykazali, że korzystanie z inteligentnego zrobotyzowanego towarzysza spowodowało zmniejszenie

stresu oraz lęku w grupie badanej. Ponadto autorzy zaobserwowali rzadsze korzystanie z substancji psychoaktywnych oraz przeciwbólowych przez chorych z otępieniem.

Halucynacje słuchowo-werbalne są charakterystycznymi objawami schizofrenii i należą do najbardziej niepokojących objawów tej choroby. Rozwiązania sztucznej inteligencji wprowadzane w terapii schizofrenii koncentrują się głównie na interakcji między pacjentem a głosami, których ten doświadcza. Twórcy terapii Avatar starali się stworzyć jak najbardziej zbliżoną do rzeczywistej reprezentację głosu prześladowczego. Leff i in. [40] opisali terapię Avatar (AT), która przy użyciu metod uczenia maszynowego umożliwia pacjentom stworzenie wirtualnego obrazu swojego prześladowcy. Pacjenci zostali zaproszeni do konwersacji z awatarem animowanym przez terapeutę. Celem terapii powyższej jest nauka kontroli objawów słuchowych. Stworzony awatar został zaprojektowany tak, aby odzwierciedlał zarówno twarz, jak i głos prześladowcy. Przy pomocy terapeutów pacjenci uczyli się jak reagować na jego mowę oraz jak sobie z nim radzić [41]. Dellazizzo i in. przeprowadzili podobne testy z wykorzystaniem terapii Avatar [42]. Zespół badawczy uzyskał pozytywne wyniki stosowania powyższego inteligentnego robota: poprawę w opanowywaniu objawów pozytywnych, zmniejszenie wrogiej postawy w stosunku do innych ludzi, redukcję nasilenia symptomów depresyjnych. Jakość życia uległa poprawie w czasie 3 miesięcznej obserwacji. Do podobnych wniosków doszli w swoich rozważaniach Craig i in. [43].

Większość analizowanych badań na temat terapii dzieci z ASD skupia się na poprawie umiejętności komunikacji społecznej dzieci z autyzmem i mierzeniu zakresu łagodzenia przez roboty stereotypowych zachowań typowych dla tego zaburzenia. Scassellati i in. opisali zastosowanie inteligentnych robotów w rehabilitacji dzieci leczonych z powodu zaburzeń ze spektrum autyzmu. Autorzy wykazali, że zastosowanie narzędzi sztucznej inteligencji poprawia zdolności poznawcze oraz kontakty społeczne pacjentów. Jednak potrzeba jeszcze wielu badań, aby móc wprowadzić takie roboty do powszechnego użytku [44]. W terapii zaburzeń ze spektrum autyzmu zastosowanie znalazła również terapia SAR, która skupia się na wsparciu funkcjonowania pacjentów w społeczeństwie oraz nawiązania kontaktów interpersonalnych [45]. Terapia autyzmu jest jedną z pierwszych zbadanych dziedzin zastosowań SAR [46]. O skuteczności inteligentnych robotów w terapii ASD świadczą opisane przez Kozima i in. [47] przypadki dzieci rozwijających zachowania emocjonalne w stosunku do robotów-terapeutów.

Obiecujące wyniki w terapii zaburzeń zdrowia

psychicznego oprócz zastosowanych inteligentnych robotów dają również inteligentne aplikacje. Przykładem jest reSET-O, program pobierany na telefon, dostępny na receptę. Aplikacja umożliwia nadzorowanie procesu leczniczego zaburzeń związanych z używaniem opioidów. Program ma wbudowaną funkcję przypominania o farmakoterapii oraz kontrolowania kolejnych etapów leczenia ambulatoryjnego. Woźniacka i wp. [48] przeprowadzili analizę, w której polecono pacjentom korzystanie z aplikacji reSET-O przez 12 tygodni. Użytkownicy programu uzyskali lepsze efekty leczenia, niż grupa kontrolna, która nie posługiwała się aplikacją.

Innym przykładem zastosowania sztucznej inteligencji jest terapia wspomagana komputerowo (CAT) [1]. Jest to program bogaty w filmy oraz kwestionariusze, do których pacjent ma dostęp przez cyfrową platformę. CAT ma na celu wsparcie chorych w terapii poznawczo-behawioralnej oraz w kontaktach interpersonalnych. Podobnymi właściwościami cechuje się terapia społeczna MOST, która poprzez platformę internetową zapewnia pacjentom z zaburzeniami psychicznymi rodzaj terapii grupowej. Metoda działania MOST jest istotna [49] zwłaszcza wśród młodzieży, ze względu na możliwość zachowania kontaktu z rówieśnikami [50] oraz dostęp do sieci społecznościowych. Dotychczas zastosowano terapię MOST wśród pacjentów z psychozą oraz depresją [51-52]. Terapię MOST opisuje również w swoich badaniach D'Alfonso i wsp. [53] jako rodzaj inteligentnego wsparcia dla terapii zdrowia psychicznego ludzi młodych. Długoterminowych wyników działań platformy jak dotąd nie opisano, dlatego należy obserwować pacjentów pod kątem działań długofalowych.

Do innych inteligentnych aplikacji stosowanych w leczeniu zaburzeń psychicznych należy Youper stosowany w terapii lęku i depresji [54]. Program jest dobrze oceniany przez użytkowników jako niedroga, samodzielna forma leczenia dla osób niemających dostępu do specjalistycznej opieki psychiatrycznej. Korzystający z Youpera podkreślili skuteczność aplikacji w zwalczaniu objawów lęku i depresji.

Powyższe rozwiązania stanowią dowód na to, że narzędzia sztucznej inteligencji znajdują wiele zastosowań w terapii zaburzeń psychicznych i powinny służyć jako ogólnodostępny środek terapeutyczny. Przy odpowiednim nadzorze wykwalifikowanego specjalisty, terapie przy użyciu sztucznej inteligencji stanowią obiecujące rozwiązania wobec globalnych wyzwań zdrowia psychicznego.

Sztuczna inteligencja w ocenie ryzyka samobójstw

Rozwój technologiczny, a wraz z nim idący rozwój narzędzi analitycznych w tym sztucznej inteligencji może radykalnie odmienić jeden z największych problemów

ówczesnej psychiatrii – samobójstwa. Niemniej jednak, przewidywanie ryzyka samobójstwa na podstawie kilku informacji zwrotnych otrzymanych od pacjenta, wcześniejszej diagnozy oraz historii leczenia stanowi duży problem nawet dla doświadczonych specjalistów. Ma to związek ze złożonością procesów oraz czynników odpowiedzialnych za podstawę samobójstw oraz problemów związanych z identyfikacją właściwych osób w ogromnej populacji ludzi o bardzo zbliżonych objawach, czy czynnikach ryzyka. Głównym założeniem AI w psychiatrii jest opracowanie metod, które umożliwiłyby identyfikację czynników ryzyka samobójstw przy uwzględnieniu złożonych interakcji pomiędzy specyficznymi zmiennymi. Na podstawie przedstawionych ograniczeń dąży się do opracowania zaawansowanych statystycznie metod uczenia maszynowego (UM), w celu poprawy rzetelności stawianych diagnoz oraz jakości opieki na osobami zagrożonymi popełnieniem samobójstwa. Jedną z największych zalet, które oferują metody UM jest możliwość analizowania ogromnej ilości danych z dokumentacji medycznej oraz związków między ryzykiem samobójstwa a czynnikami ryzyka, takimi jak aktualna choroba psychiczna, zaburzenia emocjonalne, historia leczenia czy uzależnienia [55]. Analiza wzorców historii wyszukiwania w internecie została wykorzystana do identyfikacji poszczególnych czynników ryzyka [56], co więcej badania wykazały, że w niektórych przypadkach analiza danych Google przez narzędzia AI, zdecydowanie lepiej oszacowała prawdopodobieństwo popełnienia samobójstwa niż tradycyjne skale opisowe [57]. Opracowywanie modeli predykcyjnych opiera się w głównej mierze na dokładnej identyfikacji czynników ryzyka za pomocą specjalistycznych analiz eksploracyjnych. Analityka predykcyjna jest użyteczna w identyfikowaniu osób zagrożonych samobójstwem oraz oszacowaniu prawdopodobieństwa podjęcia przez te osoby próby samobójczej w przyszłości. Jest to możliwe dzięki macierzom, które powstają poprzez połączenie wielu danych obejmujących m.in. czynniki ryzyka, by móc modelować nieliniowe zależności pomiędzy nimi.

Duże kliniczne bazy danych są wykorzystywane do opracowywania, udoskonalania oraz walidacji algorytmów przewidywania samobójstw [58]. Wyróżniono dwie dominujące domeny ryzyka samobójstwa zidentyfikowane na podstawie analiz eksploracyjnych. Pierwsza z nich to ryzyko kliniczne, które obejmuje czynniki prognostyczne jak i diagnostyczne, związane z leczeniem, takie jak nagła zmiana nastroju, samookaleczenia w wywiadzie, współwystępowanie chorób psychicznych i wcześniejsze hospitalizacje [59]. Druga z nich to ryzyko poznawcze, które dotyczy myśli związanych z satysfakcją z życia, ogólnym celem, poczuciem beznadziei, samooceną i postrzeganiem własnej osoby [60].

Badania wykazały, że zastosowanie algorytmów uczenia maszynowego do oceny wzorców pisma pacjentów psychiatrycznych pozwala przewidzieć możliwą próbę samobójczą z wyprzedzeniem do 10 tygodni, przy aż 80% wskaźniku dokładności [61]. W przypadku zastosowania powyższego narzędzia AI do źródeł danych otrzymywanych w czasie rzeczywistym np. z mediów społecznościowych, rozmów na komunikatorach czy aplikacjach na smartfony ma ona ogromną szansę umożliwić wczesną identyfikację ryzyka podjęcia próby samobójczej i daje specjalistom więcej czasu na opracowanie odpowiedniego oraz skutecznego sposobu prewencji. Co więcej, uczenie maszynowe zostało rozszerzone o przetwarzanie języka naturalnego (PjN). Umożliwia ono urządzeniom manipulowanie, interpretowanie i reagowanie na naturalny język ludzki w formie pisemnej i mówionej. PjN jest w stanie odróżnić autentyczne i symulowane notatki o możliwym samobójstwie z większą skutecznością niż lekarze psychiatry [62]. Algorytmy zostały również zaprojektowane w celu zautomatyzowania wykrywania emocji w notatkach samobójczych za pomocą obliczeń afektywnych [63] oraz wspomagania klasyfikowania treści wypowiedzi do określonych podgrup tematycznych [64].

Korzyści związane z wykorzystaniem sztucznej inteligencji

Podstawowym celem sztucznej inteligencji (SI) jest rozwój technologii, które najlepiej służą ludzkości. Spodziewane przyspieszenie rozwoju technologicznego w ciągu najbliższych dekad doprowadzi do rozpowszechnienia stosowanej sztucznej inteligencji. Już obecnie możemy dostrzec wiele korzyści ze jej użytkowania.

Główną zaletą sztucznej inteligencji w zastosowaniach opieki zdrowotnej jest ultraszybka analiza dużych zbiorów informacji [65]. Proces przetwarzania danych wysokiej jakości przez maszyny może posłużyć do szybkiego i efektywnego przesiewowego badania osób wymagających specjalistycznej opieki psychiatrycznej. Korzystając ze sztucznej inteligencji w podstawowych usługach zdrowotnych, specjaliści mogliby skoncentrować się głównie na pacjentach wymagających realnej pomocy. Skutkowałoby to redukcją dodatkowych obowiązków lekarzy i zmaksymalizowaniem efektywności ich pracy. Ma to szczególne znaczenie na obszarach, gdzie występuje niedobór psychiatrów.

Świadczenie niektórych usług w zakresie zdrowia psychicznego, na przykład poprzez interwencje terapeutyczne za pośrednictwem chatbotów lub awatarów, może być szczególnie korzystne dla populacji żyjących w środowiskach ubogich. W przypadku osób mieszkających

w odległych wiejskich lokalizacjach lub w miejscach, w których usługi w zakresie zdrowia psychicznego są trudno dostępne [66], inteligentne aplikacje mogą poprawić dostęp do opieki zdrowotnej. W czasie obecnej pandemii COVID 19, podczas której ograniczano osobisty kontakt lekarza z pacjentem, z pomocą mogą przyjść roboty działające na zasadach sztucznej inteligencji w postaci cyfrowych psychoterapeutów. Jednym z nieustających wyzwań w pracy z chatbotem jest dążenie do oferowania emocjonalnego wsparcia z natury nieożywionego kodu komputerowego [67]. Istnieją dowody na to, że ludzie mogą rozwijać relacje terapeutyczne za pomocą technologii cyfrowych (określanych jako „cyfrowy sojusz terapeutyczny”) [68]. Mimo nowoczesnych zastosowań, nadal uważa się, że współpraca z osobistym ludzkim terapeutą wiąże się z bardziej pozytywnymi wynikami leczenia zdrowia psychicznego [69], niż z jego zautomatyzowanym odpowiednikiem. Jednak celem nauki jest, aby interakcje w ludzkim stylu z chatbotem mogły promować zmiany w zdrowiu psychicznym bez potrzeby ciągłego ludzkiego wsparcia [70]. Badania wykazały, że u niektórych grup pacjentów rozmowa z anonimowym chatbotem wiązała się ze zmniejszeniem poziomu stresu [71], niż w przypadku kontaktu z obcym, ludzkim terapeutą [72]. Podobne wyniki uzyskali w swoich badaniach Lucas i in. [73]. Takie rozwiązania mogą być niezwykle istotne w przypadku pacjentów z zaburzeniem ze spektrum autyzmu.

Erden i in. w swoich rozważaniach wskazują, że usunięcie interakcji twarzą w twarz z terapeutą oraz zaprogramowanie zrozumienia zachowania pacjenta z ASD w narzędziach diagnostycznych sztucznej inteligencji może pomóc w skróceniu czasu oczekiwania, z jakim spotyka się znaczna liczba dorosłych oczekujących na diagnozę. Ponadto opisane rozwiązania mogą przyczynić się do zmniejszenia liczby diagnostycznych fałszywie negatywnych wyników, które występują z powodu maskowania innych, wyuczonych zachowań. Według najnowszych statystyk NHS Digital datowanych na sierpień 2020 roku, osoby powyżej 18 roku życia oczekujące na skierowanie i diagnozę w okresie od kwietnia 2019 r. do stycznia 2020 r. czekały średnio 361 dni od pierwszego kontaktu z lekarzem do postawienia diagnozy. Im starszy pacjent, tym dłużej trwał proces diagnostyczny, przy czym osoby w wieku 45-54 i 55-64 lata czekały średnio 480 dni [74].

Podobnie Fiske i in., wykazali, że osoby z zaburzeniem ze spektrum autyzmu lepiej radziły sobie ze swoimi partnerami-robotami niż z ludzkimi terapeutami, reagowali zachowaniami społecznymi w stosunku do robotów i poprawiali spontaniczny język podczas sesji terapeutycznych [75]. Dlatego w przypadku usług zdrowia psychicznego dla niektórych pacjentów preferowane

mogą być aplikacje wirtualne lub roboty, które poprzez minimalizowanie kontaktu pacjenta z obcym terapeutą przyczynią się do poprawy zaufania oraz reakcji interpersonalnych [76]. Ponadto narzędzia sztucznej inteligencji mogą skutkować zmniejszeniem zakłopotania lub wstydu, które nierzadko są przyczyną zatajania objawów lub problemów pacjenta i nie pozwalają uzyskać maksymalnego wglądu w chorobę [77]. Istotną kwestią w posiadaniu takiego robota-psychoterapeuty jest fakt, iż jest on zawsze dostępny dla pacjenta i może prowadzić nieskończoną ilość terapii. Ponadto jest zawsze cierpliwy, nie osądza i nie ocenia [75,78].

Zagrożenia wynikające z wykorzystania narzędzi AI w psychiatrii

Pomimo nieustającego rozwoju narzędzi sztucznej inteligencji, niektóre kwestie ich użytkowania są tematem rozważań sceptyków. Większość obecnych zastosowań sztucznej inteligencji polega na podejmowaniu logicznych decyzji lub wyciąganiu wniosków na podstawie zaprogramowanych zasad. Jednak w kwestii podejmowania decyzji klinicznych roboty wciąż wymagają udoskonalenia. Nadzór terapeutyczny nad pacjentem wymaga więcej niż inteligentnego, konkretnego myślenia — uwzględnienia kwestii etycznych, moralnych, empatii oraz uczuć, których roboty nie potrafią zrozumieć. Jest to bariera, która wciąż blokuje wprowadzenia zrobotyzowanych interwencji do opieki psychiatrycznej na szeroką skalę [79]. Brak zdolności robotów do wykazywania uczuć czy troski prowadzi do chłodnej relacji z robotem i nie sprzyja angażowaniu się pacjenta w terapię. W rezultacie osoby, które polegają wyłącznie na interwencjach opartych na sztucznej inteligencji, są często zniechęcane do kontynuowania leczenia [80].

W kwestii narzędzi sztucznej inteligencji poruszane są również obawy dotyczące prywatności pacjentów. Ilość gromadzonych danych przetwarzanych przez SI wciąż rośnie. Jak dotąd nie określono norm prawnych dla aplikacji integrujących dane wideo w kwestii zabezpieczeń prywatności [81]. Nie opracowano również reguł dotyczących przechowywania przez roboty danych wrażliwych pacjenta. Zagrożenie prywatności dotyczy głównie osób starszych lub niepełnosprawnych intelektualnie, które mogą nie rozumieć funkcjonowania robota zainstalowanego w domu [82]. Obecnie istniejące roboty nie zostały przetestowane jak dotąd na szeroką skalę. Dotychczas prowadzone badania nad sztuczną inteligencją w większości są prowadzone przez twórców poszczególnych narzędzi, którzy dążą do wykazania skuteczności swoich produktów, co wiąże się bezpośrednio z korzyścią finansową. Stanowi to ryzyko braku obiektywności testów, ze względu na usilne dążenie do wyników pozytywnych [83].

Długodystansowe korzystanie z inteligentnych robotów jako jedynej formy terapii może powodować ograniczenie kontaktów międzyludzkich z powodu lęku i stresu przed ludźmi [84]. Takie ograniczenia relacji interpersonalnych mogą doprowadzić w przyszłości do powstania nowych zaburzeń psychicznych, które ponownie leczone przy użyciu narzędzi sztucznej inteligencji doprowadzą do wytworzenia błędnego koła.

Podsumowanie

Wciąż istnieje zapotrzebowanie na dokładne, zakrojone na szeroką skalę, rzetelne, szczególnie randomizowane kontrolowane badania kliniczne, które zaprezentują obiektywne wyniki zastosowań sztucznej inteligencji w opiece zdrowotnej. W świetle wykazanych korzyści z zastosowania narzędzi AI i możliwości, jakie te narzędzia za sobą niosą, następuje rozszerzenie zasięgu usług zdrowia psychicznego na populację o słabo rozwiniętej opiece medycznej a także poprawa świadczenia usług przez specjalistów w dziedzinie zdrowia psychicznego. Konieczna jest weryfikacja oraz stworzenie wytycznych dotyczących prawidłowego wykorzystania AI w zakresie usług zdrowia psychicznego oraz zalecenia dotyczące sposobu szkolenia i przygotowania lekarzy do stosowania technik opartych na sztucznej inteligencji najlepiej przez specjalnie powołane organizacje zajmujące się zarządzaniem takimi usługami. Autorzy podkreślają konieczność ustanowienia regulacji prawnych w kwestii zarządzania narzędziami sztucznej inteligencji. Pomimo wdrażania nowoczesnych cyfrowych rozwiązań do opieki zdrowotnej, narzędzia AI nie powinny stanowić podstawy samodzielnej terapii bez nadzoru wysoko wykwalifikowanych specjalistów. Wszelkie aplikacje oferowane poza placówkami ochrony zdrowia psychicznego, takie jak programy i boty, powinny być zobowiązane do przedstawienia niezawodnych ścieżek oceny ryzyka i kierowania do odpowiednich służb w razie zagrożenia utraty życia. Ma to na celu w jak największym stopniu zwiększyć rzetelność prowadzonych usług oraz zniwelować możliwe błędy generowane przez AI.

Podsumowując należy stwierdzić, że istnieje konieczność monitorowania zarówno korzyści jak i skutków wykorzystania narzędzi sztucznej inteligencji w psychiatrii zwracając uwagę, że w centrum analiz powinien znaleźć się człowiek a jego dobrostan zdrowotny powinien być priorytetem.

Conflict of interest

The authors have declared no conflict of interest.

References

1. Fakhoury M, Artificial Intelligence in Psychiatry. *Adv Exp Med*

- Biol 2019(1192):119-125.
2. Kaul V, Enslin, S, Gross SA. History of artificial intelligence in medicine. *Gastrointestinal endoscopy*, 2020;92(4):807-812.
 3. Muthukrishnan N, Maleki F, Ovens K, Reinhold C, Forghani B, Forghani R, Brief History of Artificial Intelligence. *Neuroimaging Clin N Am*. 2020;30(4):393-399.
 4. Ravi D, Wong C, Deligianni F, Berthelot M, Andreu-Perez J, Lo B, Yang GZ. Deep Learning for Health Informatics. *IEEE J Biomed Health Inform*. 2017;21(1):4-21.
 5. Antczak K. Uczenie głębokie w diagnostyce medycznej. *Symulacja w Badaniach i Rozwoju*, 2016;7(3-4).
 6. Patel VL, Shortliffe EH, Stefanelli M, Szolovits P, Berthold MR, Bellazzi R, et al. The coming of age of artificial intelligence in medicine. *Artif Intell Med*. 2009;46(1):5-17.
 7. Bedi G, Carrillo F, Cecchi GA, Slezak DF, Sigman M, Mota NB, et al. Automated analysis of free speech predicts psychosis onset in high-risk youths. *NPJ Schizophr*, 2015;1:15030.
 8. Elvevåg B, Foltz PW, Rosenstein M, Delisi LE. An automated method to analyze language use in patients with schizophrenia and their first-degree relatives. *J Neurolinguistics*, 2010; 23(3):270-284.
 9. Angermeyer MC, Kuhn L, Goldstein JM. Gender and the course of schizophrenia: differences in treated outcome. *Schizophr Bull*, 1990; 16:293-307.
 10. Nagarhalli TP, Vaze V, Rana NK. Impact of Machine Learning in Natural Language Processing: A Review. In proceedings of the 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV). Tirunelveli, India, 2021; 4:1529-1534.
 11. Bae YJ, Shim M, Lee WH. Schizophrenia Detection Using Machine Learning Approach from Social Media Content. *Sensors (Basel)*, 2021; 21(17):5924.
 12. Thorstad R, Wolff P. Predicting future mental illness from social media: A big-data approach. *Behav Res Methods*, 2019; 51:1586-1600.
 13. Birnbaum ML, Norel R, Van Meter A, Ali AF, Arenare E, Eyigoz E, et al. Identifying signals associated with psychiatric illness utilizing language and images posted to Facebook. *NPJ Schizophr*. 2020; 3(1):38.
 14. Mitchell M, Hollingshead K, Coppersmith G. Quantifying the Language of Schizophrenia in Social Media; Association for Computational Linguistics: Denver, CO, USA, 2015; 11-20.
 15. Glen Coppersmith, Mark Dredze, Craig Harman, and Kristy Hollingshead. From ADHD to SAD: Analyzing the Language of Mental Health on Twitter through Self-Reported Diagnoses. In Proceedings of the 2nd Workshop on Computational Linguistics and Clinical Psychology: From Linguistic Signal to Clinical Reality, Denver, CO, 2015, Association for Computational Linguistics.
 16. Salvador R, Canales-Rodríguez E, Guerrero-Pedraza A, Sarró S, Tordesillas-Gutiérrez D, Maristany T et al. Multimodal Integration of Brain Images for MRI-Based Diagnosis in Schizophrenia. *Front Neurosci*, 2019; 13:1203.
 17. de Filippis R, Carbone EA, Gaetano R, Bruni A, Pugliese V, Segura-Garcia C et al. Machine learning techniques in a structural and functional MRI diagnostic approach in schizophrenia: a systematic review. *Neuropsychiatr Dis Treat*, 2019; 19:1605-1627.
 18. Shi D, Li Y, Zhang H, Yao X, Wang S, Wang G, Ren K. Machine Learning of Schizophrenia Detection with Structural and Functional Neuroimaging. *Dis Markers*, 2021; 9:9963824.
 19. Zhu L, Wu X, Xu B, Zhao Z, Yang J, Long J, Su L. The machine learning algorithm for the diagnosis of schizophrenia on the basis of gene expression in peripheral blood. *Neurosci Lett*, 2021; 6;745:135596.
 20. Polanczyk G, de Lima MS, Horta BL, Biederman J, Rohde LA. The worldwide prevalence of ADHD: a systematic review and meta-regression analysis. *Am J Psychiatry*, 2007; 164(6):942-8.
 21. Wender PH. Attention-deficit hyperactivity disorder in adults. *Psychiatric Clinics of North America*, 1998; 21:761-774.
 22. Drigas AS, Joannidou RE. A review on artificial intelligence in special education. *World Summit on Knowledge Society*, 2011; 385-391.
 23. Christiansen H, Chavanon ML, Hirsch O, Schmidt MH, Meyer C, Müller A et al. Use of machine learning to classify adult ADHD and other conditions based on the Conners' Adult ADHD Rating Scales. *Sci Rep*, 2020; 2;10(1):18871.
 24. Mueller A, Candrian G, Kropotov JD, Ponomarev VA, Baschera GM. Classification of ADHD patients on the basis of independent ERP components using a machine learning system. *Nonlinear Biomed Phys*, 2010; 3;4(1):1.
 25. Tenev A, Markovska-Simoska S, Kocarev L, Pop-Jordanov J, Müller A, Candrian G. Machine learning approach for classification of ADHD adults. *Int J Psychophysiol*, 2014; 93(1):162-6.
 26. Wiltfang J, Esselmann H, Barnikol UB. The Use of Artificial Intelligence in Alzheimer's Disease - Personalized Diagnostics and Therapy. *Psychiatr Prax*, 2021; 48(1):31-36.
 27. Wall DP, Kosmicki J, Deluca TF, Harstad E, Fusaro VA. Use of machine learning to shorten observation-based screening and diagnosis of autism. *Transl Psychiatry*, 2012; 10:2(4)100.
 28. Bertocelli CM, Altamura P, Vieira ER, Bertocelli D, Solla F. Using Artificial Intelligence to Identify Factors Associated with Autism Spectrum Disorder in Adolescents with Cerebral Palsy. *Neuropediatrics*, 2019; 50(3):178-187.
 29. Choi ES, Yoo HJ, Kang MS, Kim SA. Applying Artificial Intelligence for Diagnostic Classification of Korean Autism Spectrum Disorder. *Psychiatry Investig*, 2020; 17(11):1090-1095.
 30. Wall DP, Dally R, Luyster R, Jung JY, Deluca TF. Use of artificial intelligence to shorten the behavioral diagnosis of autism. *PLoS One*, 2012; 7:43855.
 31. Andrade E, Portela S, Pinheiro PR, Nunes LC, Filho MS, Costa WS et al. A Protocol for the Diagnosis of Autism Spectrum Disorder Structured in Machine Learning and Verbal Decision Analysis. *Comput Math Methods Med*, 2021; 30:1628959.
 32. Lavagnino L, Amianto F, Mwangi B, D'Agata F, Spalatro A, Zunta-Soares GB et al. Identifying neuroanatomical signatures of anorexia nervosa: a multivariate machine learning approach. *Psychol Med*, 2015; 45(13):2805-12.
 33. Brunn M, Diefenbacher A, Courtet P, Genieys W. The Future is Knocking: How Artificial Intelligence Will Fundamentally Change Psychiatry. *Acad Psychiatry*, 2020; 44(4):461-466.
 34. Fitzpatrick KK, Darcy A, Vierhile M. Delivering cognitive behavior therapy to young adults with symptoms of depression and anxiety using a fully automated conversational agent (Woebot): a randomized controlled trial. *JMIR Ment Health*, 2017; 06:4(2):19.
 35. Sachan D. Self-help robots drive blues away. *Lancet Psychiatry*, 2018; 5(7):547.
 36. Fiske A, Henningsen P, Buyx A. Your Robot Therapist Will See You Now: Ethical Implications of Embodied Artificial Intelligence in Psychiatry. *Psychology, and Psychotherapy, J Med Internet Res*, 2019; 9:21(5):13216.
 37. Fulmer R, Joerin A, Gentile B, Lakerink L, Rauws M. Using Psychological Artificial Intelligence (Tess) to Relieve Symptoms of Depression and Anxiety: Randomized Controlled Trial. *JMIR Ment Health*, 2018; 13:5(4):64.
 38. Warren Z, Zheng Z, Das S, Young EM, Swanson A, Weitlauf A,

- Sarkar N. Brief Report: Development of a Robotic Intervention Platform for Young Children with ASD. *J Autism Dev, Disord*, 2015; 45(12):3870-6.
39. Petersen S, Houston S, Qin H, Tague C, Studley J. The Utilization of Robotic Pets in Dementia Care. *J Alzheimers Dis*, 2017; 55(2):569-574.
 40. Leff J, Williams G, Huckvale MA, Arbuthnot M, Leff AP. Computer-assisted therapy for medication-resistant auditory hallucinations: proof-of-concept study. *Br J Psychiatry*, 2013; 202:428-33.
 41. Johns LC, Hemsley D, Kuipers E. A comparison of auditory hallucinations in a psychiatric and non-psychiatric group. *British Journal of Clinical Psychology*, 2002; 41(1):81-86.
 42. Dellazizzo L, Percie du Sert O, Phraxayavong K, Potvin S, O'Connor K, Dumais A. Exploration of the dialogue components in Avatar Therapy for schizophrenia patients with refractory auditory hallucinations: A content analysis. *Clin. Psychol. Psychother*, 2018; 25(6):878-885.
 43. Craig TK, Rus-Calafell M, Ward T, Leff JP, Huckvale M, Howarth E, et al. AVATAR therapy for auditory verbal hallucinations in people with psychosis: a single-blind, randomised controlled trial. *Lancet Psychiatry*, 2018; 5(1):31-40.
 44. Saleh MA, Hanapiah FA, Hashim H. Robot applications for autism: a comprehensive review. *Disabil Rehabil Assist Technol*, 2021; 16(6):580-602.
 45. Scassellati B, Admoni H, Matarić M. Robots for use in autism research. *Annu Rev Biomed Eng*, 2012; 14:275-94.
 46. Feil-Seifer D, Matarić MJ. Defining socially assistive robotics. *Proc. IEEE 9th Int Conf Rehabil Robot*, 2005; 28:465-68.
 47. Kozima H, Nakagawa C, Yasuda Y. Interactive robots for communication-care: a case-study in autism therapy. *Proc 14th IEEE Int Workshop Robot Hum Interact Commun*, 2005; 13:341-46.
 48. Woźniacka A, Patrzyk S, Mikołajczyk M. Artificial intelligence in medicine and dermatology. *Postepy Dermatol Alergol*, 2021; 38(6):948-952.
 49. Ohio State University. Virtual patient: Avatar shows emotions as he talks to med students. *ScienceDaily*, 25 February 2015.
 50. Ienca M, Wangmo T, Jotterand F, Kressig RW, Elger B. Ethical design of intelligent assistive technologies for dementia: a descriptive review. *Sci Eng Ethics*, 2018; 24(4):1035-1055.
 51. Rein BA, McNeil DW, Hayes AR, Hawkins TA, Ng HM, Yura CA. Evaluation of an avatar-based training program to promote suicide prevention awareness in a college setting. *J Am Coll Health*, 2018; 66(5):401-411.
 52. Wada K, Shibata T. Living with seal robots—its sociopsychological and physiological influences on the elderly at a care house. *IEEE Trans Robot*, 2007; 23(5):972-980.
 53. D'Alfonso S, Santesteban-Echarri O, Rice S, Wadley G, Lederman R, Miles C et al. Artificial Intelligence-Assisted Online Social Therapy for Youth Mental Health. *Front Psychol*, 2017; 2:8:796.
 54. Mehta A, Niles AN, Vargas JH, Marafon T, Couto DD, Gross JJ. Acceptability and Effectiveness of Artificial Intelligence Therapy for Anxiety and Depression (Youper): Longitudinal Observational Study. *J Med Internet Res*, 2021; 22:23(6):26771.
 55. Jenkins AL, Singer J, Conner BT, Calhoun S, Diamond G. Risk for suicidal ideation and attempt among a primary care sample of adolescents engaging in nonsuicidal self-injury. *Suicide Life Threat Behav*, 2014; 44(6):616-28.
 56. Song J, Song TM, Seo DC, Jin JH. Data Mining of Web-Based Documents on Social Networking Sites That Included Suicide-Related Words Among Korean Adolescents. *J Adolesc Health*, 2016; 59(6):668-673.
 57. Ma-Kellams C, Or F, Baek JH, Kawachi I. Rethinking suicide surveillance: Google search data and self-reported suicidality differentially estimate completed suicide risk. *Clinical Psychological Science*, 2016; 4:480-484.
 58. Ryu S, Lee H, Lee DK, Park K. Use of a Machine Learning Algorithm to Predict Individuals with Suicide Ideation in the General Population. *Psychiatry Investig*, 2018; 15(11):1030-1036.
 59. Liu Y, Sareen J, Bolton JM, Wang JL. Development and validation of a risk prediction algorithm for the recurrence of suicidal ideation among general population with low mood. *J Affect Disord*, 2016; 15:193:11-7.
 60. Jordan P, Shedden-Mora MC, Lowe B. Predicting suicidal ideation in primary care: An approach to identify easily assessable key variables. *General Hospital Psychiatry*, 2018; 51:106-111.
 61. de Ávila Berni G, Rabelo-da-Ponte FD, Librenza-Garcia D, Boeira MV, Kauer-Sant'Anna M, Passos IC et al. Potential use of text classification tools as signatures of suicidal behavior: A proof-of-concept study using Virginia Woolf's personal writings. *PLoS One*, 2018; 24;13(10):0204820.
 62. Pestian J, Nasrallah H, Matykiewicz P, Bennett A, Leenaars A. Suicide Note Classification Using Natural Language Processing: A Content Analysis. *Biomed Inform Insights*, 2010; 4;2010(3):19-28.
 63. Cherry C, Mohammad SM, de Bruijn B. Binary classifiers and latent sequence models for emotion detection in suicide notes. *Biomed Inform Insights*, 2012; 5(1):147-54.
 64. Spasić I, Burnap P, Greenwood M, Arribas-Ayllon M. A naïve bayes approach to classifying topics in suicide notes. *Biomed Inform Insights*, 2012; 5(1):87-97.
 65. Mehta A, Niles AN, Vargas JH, Marafon T, Couto DD, Gross JJ. Acceptability and Effectiveness of Artificial Intelligence Therapy for Anxiety and Depression (Youper): Longitudinal Observational Study. *J Med Internet Res*, 2021; 22;23(6):e26771.
 66. Jeste DV, Graham SA, Nguyen TT, Depp CA, Lee EE, Kim HC. Beyond artificial intelligence: exploring artificial wisdom. *Int Psychogeriatr*, 2020; 32(8):993-1001.
 67. Carroll KM, Rounsaville BJ. Computer-assisted therapy in psychiatry: be brave-it's a new world. *Curr Psychiatry Rep*, 2010; 12(5):426-32.
 68. Fiske A, Henningsen P, Buyx A. Your Robot Therapist Will See You Now: Ethical Implications of Embodied Artificial Intelligence in Psychiatry, Psychology, and Psychotherapy. *J Med Internet Res*, 2019; 9:21(5):13216.
 69. Torous J, Bucci S, Bell IH, Kessing LV, Faurholt-Jepsen M, Whelan P et al. The growing field of digital psychiatry: current evidence and the future of apps, social media, chatbots, and virtual reality. *World Psychiatry*, 2021; 20(3):318-335.
 70. Henson P, Wisniewski H, Hollis C, Keshavan M, Torous J. Digital mental health apps and the therapeutic alliance: initial review. *BJPsych Open*, 2019; 5(1):15.
 71. Tremain H, McEnery C, Fletcher K, Murray G. The Therapeutic Alliance in Digital Mental Health Interventions for Serious Mental Illnesses: Narrative Review. *JMIR Ment Health*, 2020; 7;7(8):17204.
 72. Frank AF, Gunderson JG. The role of the therapeutic alliance in the treatment of schizophrenia. Relationship to course and outcome. *Arch Gen Psychiatry*, 1990; 47:228-36.
 73. Lucas GM, Gratch J, King A, Morency L. It's only a computer: Virtual humans increase willingness to disclose. *Comput Hum Behav*, 2014; 37, 94-100.
 74. Erden YJ, Hummerstone H, Rainey S. Automating autism assessment: What AI can bring to the diagnostic process. *J Eval Clin Pract*, 2021; 27(3):485-490.
 75. Fiske A, Henningsen P, Buyx A. Your Robot Therapist Will See You

- Now: Ethical Implications of Embodied Artificial Intelligence in Psychiatry. *Psychology, and Psychotherapy J Med Internet Res*, 2019; 9:21(5):13216.
76. Stix C. 3 ways AI could help our mental health. *World Economic Forum*. 2018.
 77. Houston TK, Cooper LA, Ford DE. Internet support groups for depression: a 1-year prospective cohort study. *Am J Psychiatry*, 2002; 159(12):2062-8.
 78. Gionet K. Meet Tess: the mental health chatbot that thinks like a therapist. *The Guardian*, 2018.
 79. Graham SA, Lee EE, Jeste DV, Van Patten R, Twamley EW, Nebeker C et al. Artificial intelligence approaches to predicting and detecting cognitive decline in older adults: A conceptual review. *Psychiatry Res*, 2020; 284:112732.
 80. Carroll KM, Rounsaville BJ. Computer-assisted therapy in psychiatry: be brave-it's a new world. *Curr Psychiatry Rep*, 2010; 12(5):426-32.
 81. American Academy of Child and Adolescent Psychiatry: Practice parameters for the assessment and treatment of children and adolescents with depressive disorders. *J Am Acad Child Adolesc Psychiatry*, 1998; 37(10):63-83.
 82. Vandemeulebroucke T, Dierckx de Casterlé B, Gastmans C. The use of care robots in aged care: a systematic review of argument-based ethics literature. *Arch Gerontol Geriatr*, 2018; 74:15-25.
 83. Sachan D. Self-help robots drive blues away. *Lancet Psychiatry*, 2018; 5(7):547.
 84. Johnston A. Robotic seals comfort dementia patients but raise ethical concerns. *KALW Local Public Radio*. 2015.

Corresponding author

Klaudia Kister

e-mail: klaudia2178@gmail.com

Students Research Group at the I Department of Psychiatry, Psychotherapy and Early Intervention of Medical University in Lublin, Poland

Otrzymano: 02.12.2022

Zrecenzowano: 21.12.2022

Przyjęto do druku: 24.01.2023