

Paweł Janowski SDS\*

## GENERATORY OBRAZU AI – GENEZA, SPOSÓB DZIAŁANIA I TWORZENIE OBRAZÓW RELIGIJNYCH

AI IMAGE GENERATORS – GENESIS, A MODUS OPERANDI  
AND CREATION OF RELIGIOUS IMAGES

**Abstrakt:** The paper discusses the origins and functioning of artificial intelligence generators, with a particular focus on the Stable Diffusion model. The author demonstrates how successive milestones in the development of artificial intelligence have shaped the current form of the most popular solution for generating religious images. The paper also highlights the issue of generating images with religious content.

**Keywords:** Stable Diffusion, machine learning technique, digital graphics, digital art, religious graphics.

Debiut narzędzi, takich jak Chat GPT-3, *Midjourney*, *Dall-e*, *Bing Chat*, a także licznych pokrewnych modeli, zapoczątkował technologiczną rewolucję. Mimo że termin «sztuczna inteligencja» (AI) nie jest obcy w debacie publicznej, to powszechna dostępność narzędzi AI w aplikacjach internetowych wywołała znaczne poruszenie. Emocje te dotyczą potencjału, przyszłości oraz ryzyka związanego z nowoczesnymi technologiami, a szerzej – kwestii przyszłości ludzkości<sup>1</sup>. Począwszy od 2022 r. jesteśmy świadkami lawiny publikacji naukowych, sympozjów, badań i debat, które koncentrują się nie tylko na teoretycznych możliwościach

---

\* Paweł Janowski SDS – Uniwersytet Papieski Jana Pawła II w Krakowie; e-mail: p.janowski.sds@gmail.com.

<sup>1</sup> Por. S. Soczyński. *Corporate Digital Responsibility w przedsiębiorstwach medialnych*. „Zarządzanie Mediami” 9:2021 nr 4 s. 695-706; I. Oleksiewicz. *Sztuczna inteligencja kontra człowiek – zagrożenie czy konieczność ewolucji?*. „Przegląd Europejski” 2022 nr 3 s. 55-69; B. Siuta-Tokarska. *Przemysł 4.0 i sztuczna inteligencja: szansa czy zagrożenie dla realizacji koncepcji zrównoważonego i trwałego rozwoju?*. „Nierówności społeczne a wzrost gospodarczy” 2021 nr 65 s. 7-26.

tych narzędzi, ale przede wszystkim na analizie i wdrażaniu AI w sektorach biznesowym, artystycznym i edukacyjnym oraz badaniu praktycznych aspektów funkcjonowania tysięcy aplikacji dostępnych dla użytkowników po wpisaniu frazy «darmowe narzędzia AI» w najpopularniejszej wyszukiwarce Google<sup>2</sup>. Dyskusje na temat AI są obecne przy domowym stole, w murach akademickich, a nawet w przestrzeni religijnej<sup>3</sup>. Centralnym zagadnieniem niniejszej analizy jest przedstawienie genetyki generatywnych modeli sztucznej inteligencji w kontekście tworzenia obrazów i sposobu działania najpopularniejszego modelu *Stable Diffusion* oraz odniesienie tych wiadomości do generowania obrazów religijnych.

Powszechne stosowanie sztucznej inteligencji w procesie tworzenia obrazów wynika z ewolucji nowych mediów<sup>4</sup>. Komunikacja wizualna zaczyna niewątpliwie dominować nad werbalną. Współczesny świat, kształtowany w znacznym stopniu przez technologię i media, przywiązuje ogromną wagę do obrazu, co określa się mianem «nowej orientacji kulturowej»<sup>5</sup>. Wpływ sztucznej inteligencji na ten aspekt jest niezaprzeczalny, co potwierdzają liczne i szeroko rozpowszechnione opinie krytyczne, wyrażane przez artystów, grafików, dziennikarzy i naukowców na całym świecie<sup>6</sup>. Sztuczna inteligencja będzie niewątpliwie wpływała na postrzeganie wiary i mediatyzację religii. Już dzisiaj obserwujemy w Kościele szerokie wykorzystanie AI do produkcji obrazów o charakterze religijnym. Zjawisko AI pobudziło rozwój nie tylko w dziedzinie nauki, ale również w etyce i prawie<sup>7</sup>. W ciągu zaledwie jednego roku byliśmy świadkami czwartej rewolucji przemysłowej, która już teraz przekształca wiele aspektów naszej pracy i codziennego życia<sup>8</sup>. Mimo że

<sup>2</sup> Portale, takie jak futurepedia.io publikują do kilkudziesięciu nowych aplikacji AI tygodniowo.

<sup>3</sup> Por. K. Trzęsicki. *Co św. Tomasz z Akwinu miałby do powiedzenia o sztucznej inteligencji?*. „Kieleckie Studia Teologiczne” 19:2020 s. 7-25; K. Dudek. *Papież: sztuczna inteligencja może być szansą, jak i zagrożeniem*. <<https://www.vaticannews.va/pl/papiez/news/2023-12/papiez-sztuczna-inteligencja-moze-byc-szansa-jak-i-zagrozeniem.html>> [dostęp: 9.01.2024]; Ł. Ostruszka. *Na wieki wieków AI. Jak sztuczna inteligencja zmieni naszą wiarę?*. <<https://www.tygodnikpowszechny.pl/na-wieki-wiekow-ai-jak-sztuczna-inteligencja-zmieni-nasza-wiare-183788>> [dostęp: 9.01.2024].

<sup>4</sup> Por. G. Penkowska. *Interpretacja materiałów wizualnych w badaniach naukowych*. „E-mentor” 2017 nr 1 (68) s. 11.

<sup>5</sup> Por. M. Banks. *Materiały wizualne w badaniach jakościowych*. Warszawa 2009 s. 28-29.

<sup>6</sup> Por. S. Bielecka. *Krytycy sztuki mówią „nie” sztucznej inteligencji*. <<https://geekweek.interia.pl/sztuka/news-krytycy-sztuki-mowia-nie-sztucznej-inteligencji-rozszerzenie,nId,6815083>> [dostęp: 15.03.2024]; G. Rogala. *Artysta w świecie sztucznej inteligencji*. „Aspiracje”. 61:2020 nr 3 s. 91-99; A. Wittenberg. *Sztuka kontra AI, czyli o nieetycznych skutkach rozwoju sztucznej inteligencji*. <<https://forsal.pl/lifestyle/technologie/artykuly/8606440,sztuka-kontra-ai-nieetyczne-skutkih-rozwoju-sztucznej-inteligencji.html>> [dostęp: 15.03.2024].

<sup>7</sup> Por. M. Bieroński. *Etyczne i moralne wyzwania związane ze stosowaniem sztucznej inteligencji*. „Kieleckie Studia Teologiczne” 19:2020 s. 7-25; B. Fischer, A. Pązik, M. Świerczyński. *Prawo sztucznej inteligencji*. Warszawa 2021.

<sup>8</sup> Por. A. French, J. Shim, M. Risius. *The 4th Industrial Revolution Powered by the Integration of AI, Blockchain, and 5G*. „Communications of the Association for Information Systems” 49:2021. <<https://doi.org/10.17705/1CAIS.04910>>.

te zmiany są często postrzegane jako całkowita nowość, to koncepcja sztucznej inteligencji oraz technologiczny postęp, który umożliwił jej powszechną dostępność, są znane od połowy XX w.

Podstawą do analizy działania generatywnych modeli AI jest technologia *Stable Diffusion*. Jest to obecnie najskuteczniejszy sposób generowania obrazów przez sztuczną inteligencję<sup>9</sup>. Stanowi podstawę dla działania najpopularniejszych aplikacji, takich jak *Midjourney*, *Firefly* czy *Gpt-4o*. W zasadzie wszystkie komercyjne aplikacje do generowania obrazu wykorzystują *Stable Diffusion*, wprowadzając jedynie zmiany w procesie treningowym, interfejsie użytkownika i stosując autorskie nakładki, które umożliwiają większy wpływ użytkownika na ostateczny wynik.

## 1. KROKI MIŁOWE W ROZWOJU GENERATYWNYCH MODELI AI

Komputer to jeden z najważniejszych wynalazków ludzkości<sup>10</sup>. Funkcjonowanie chyba wszystkich dziedzin naszego życia zostało w jakiś sposób podporządkowane lub uzależnione od działania systemów informatycznych. Zmieniło myślenie i praktykę nawet najbardziej podstawowych codziennych działań. Geneza idei komputera jest wspólna dla sztucznej inteligencji i zawiera się w pytaniu: Czy można stworzyć sztuczny mózg, który naśladowałby myślenie człowieka w tak realistyczny sposób, aby był nieodróżnialny przez trzeciego obserwatora, a więc – czy można stworzyć maszynę, która myśli?<sup>11</sup> To pytanie w latach 40. i 50. ubiegłego wieku rozpaliło naukowców z takich dziedzin, jak matematyka, inżynieria, ekonomia, nauki społeczne czy psychologia. Ówczesne osiągnięcia neurologii pozwoliły na nowo spojrzeć na pracę naszego mózgu jako elektrycznej sieci neuronów. Dzięki pracy takich naukowców jak Norbert Weiner, który opisywał stabilność sieci elektrycznych<sup>12</sup>, Claude Shannon, który opisywał m.in. sygnały cyfrowe<sup>13</sup>, Alan Turing z jego teorią obliczeń<sup>14</sup>, a także dzięki osiągnięciom matematyki, w których ogromny udział ma Polska Szkoła Lwowska<sup>15</sup>, można było stworzyć

---

<sup>9</sup> Por. F. Croitoru, V. Hondru, R. Ionescu. *Reverse Stable Diffusion: What prompt was used to generate this image?*. <arXiv preprint, arXiv:2308.01472> 2023 s. 1.

<sup>10</sup> Por. P. Sienkiewicz. *Od Eniaca do internetu i społeczeństwa wiedzy*. „Zeszyty Naukowe Warszawskiej Wyższej Szkoły Informatyki” 1:2006 s. 9.

<sup>11</sup> Por. A. Turing. *Computing Machinery and Intelligence*. „Mind” 59:1950 nr 236 s. 433.

<sup>12</sup> Por. W. Norbert. *Cybernetics or Control and Communication in the Animal and the Machine*. Cambridge 1948.

<sup>13</sup> Por. C.E. Shannon. *A Mathematical Theory of Communication*. „The Bell System Technical Journal” 27:1948 s. 379-423.

<sup>14</sup> Por. A. Turing. *Computing Machinery and Intelligence* s. 433-460.

<sup>15</sup> Por. W. Wójcik. *Fenomen polskiej szkoły matematycznej a emigracja matematyków polskich w okresie II wojny światowej*. „Zagadnienia Filozoficzne w Nauce” 2013 nr 53 s. 33-34.

realne postulaty potrzebne do faktycznego rozwoju informatyki oraz fundamentów sztucznej inteligencji<sup>16</sup>. Opisanie przez Waltera Pittsa i Warrena McCullocha w 1943 r.<sup>17</sup> funkcji logicznych realizowanych przez sztuczne sieci neuronowe pozwoliły 24-letniemu Marvinowi Minsky'emu stworzyć w 1951 r. pierwszą maszynę opartą o ideę sieci neuronowej – SNARC<sup>18</sup>. Również w 1951 r. Dietrich Prinz napisał pierwszy program do gry w szachy, który pod koniec lat 50. XX w. był w stanie stawić czoła semi-amatorowi<sup>19</sup>. Od tej pory to właśnie gra będzie miarą postępu rozwoju komputera i sztucznej inteligencji<sup>20</sup>. Dostępność pierwszych komputerów poprowadziła dalej zastosowania matematyczne w budowaniu programów i rozwoju idei AI. W 1955 r. Allen Newell i Herbert Simon stworzyli program, który udowodnił 38 z 52 twierdzeń Bertranda Russella i Alfreda Northa Whiteheada – w przypadku niektórych program znalazł łatwiejsze dowody, co zawsze było kryterium doskonałości dowodu matematycznego, i to właśnie prostota i osiągnięta dzięki temu optymalizacja wejdzie do kanonu zasad programowania<sup>21</sup>. Program Newella i Simona był możliwy dzięki zauważeniu, że jeżeli komputer jest w stanie operować liczbami, to może również operować innymi symbolami algebraicznymi. Wcześniejsze osiągnięcia matematyków w dziedzinie algebry, które wydawały się jedynie abstrakcyjne i nie znajdowały zastosowania w technologii, nagle umożliwiły opis potrzebny nowym technologiom. Suponowano, że właśnie manipulacja wariacjami, budowanie relacji symbolicznej i konwertowanie symboli jest podstawą ludzkiej myśli, co stało się nowym podejściem do prowadzenia badań nad maszyną, która może myśleć<sup>22</sup>.

Jednym z pierwszych sposobów działania wczesnych algorytmów, które leżą u podstaw pracy dzisiejszej AI, było rozumowanie jako wyszukiwanie. Aby spełnić cel swojego działania, program wykonuje kolejne kroki zadane przez kod lub dokonuje dedukcji w zakresie określonym przez kod. Ten proces można porównać do poszukiwania wyjścia z budynku, w którym się zgubiliśmy, według zasady sprawdzania kolejnych możliwości – cofamy się za każdym razem, kiedy

---

<sup>16</sup> Por. P. Skalfist, D. Mikelsten, V. Teigens. *Sztuczna inteligencja: czwarta rewolucja przemysłowa*. Cambridge Stanford Books 2020 (e-book) s. 18.

<sup>17</sup> Por. W. McCulloch, W. Pitts. *A logical calculus of the ideas immanent in nervous activity*. „Bulletin of Mathematical Biophysics” 5:1943 s. 115-133. <<https://doi.org/10.1007/BF02478259>>.

<sup>18</sup> Por. P. Skalfist, D. Mikelsten, V. Teigens. *Sztuczna inteligencja: czwarta rewolucja przemysłowa* s. 19-20.

<sup>19</sup> Por. T. Goluch. *Zastosowanie komputerów w dziedzinie wyszukiwania strategii optymalnych w grach logicznych*, „Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej” 31:2012 s. 57.

<sup>20</sup> Por. H. Simon. *Allen Newell: 1927–1992*. „IEEE Annals of the History of Computing” 20:1998 nr 2 s. 67.

<sup>21</sup> Por. tamże s. 68.

<sup>22</sup> Por. C. Zhang, L. Yang. *Study on artificial intelligence: The state of the art and future prospects*. „Journal of Industrial Information Integration” 2021 nr 23 s. 6.

docieramy do zamkniętych drzwi aż do punktu, w którym są jakieś kolejne możliwości sprawdzenia wyjścia<sup>23</sup>. W przypadku dużej liczby danych program napotykał jednak problem – tzw. eksplozję kombinatoryczną, gdzie ilość możliwości, które należałoby sprawdzić krok po kroku była zbyt duża i pochłaniała moce obliczeniowe maszyny lub całkowicie je przekraczała<sup>24</sup>. To doprowadziło naukowców do wprowadzenia w działanie programów heurystyk, czyli metody praktycznych reguł postępowania, które moglibyśmy słownie zapisać: gdy napotkasz zbiór A, zrób krok B. Innymi słowy, naukowcy poprzez przewidywanie ścieżek, które nie dadzą dobrego wyniku, negowali je na początku kroku programu, tym samym optymalizując działanie, a w dalszej fazie rozwoju pozwolili algorytmowi samemu przewidywać prawdopodobieństwo najszybszych ścieżek<sup>25</sup>. W bardziej rozwiniętej formie działał tak pierwszy perceptron, wynaleziony przez Franka Rosenblatta w 1957 r.<sup>26</sup> Działanie perceptronu można by opisać w następujący, uproszczony sposób – do programu wprowadzone są zestawy danych (wartości), następnie zestawy danych są oceniane przez syntetyczny neuron, który przydziela każdemu z nich określoną ocenę przydatności według wag – zasad określonych przez twórcę. Po przyznaniu ocen neuron decyduje, która wartość wygrywa i podaje ją do kolejnego kroku programu. Perceptron stał się podstawą do rozwoju połączeń neuronowych i technologii głębokiego uczenia. Zasada jego działania wskazuje wprost na naturę sieci neuronowych, które automatyzują wybór w stosunku do algorytmu w oparciu o nieliniowe dane. To pozwala na sprzężenie i szukanie reguł pomiędzy danymi, które – choć wyrażone w postaci matematycznej – reprezentują różnego rodzaju dane. Stąd wynika skuteczność zastosowania AI do produkcji wyników, które potrzebują kompilacji różnej wiedzy, np. wyniki językowych modeli, które dla skutecznej odpowiedzi potrzebują danych zarówno z dziedziny budowy języka, jak i psychologii, kultury itd. Podstawa działania wynalazku Rosenblatta pokazuje też, że to twórca sieci ma pełny wpływ na działanie modelu.

Kamieniem milowym była zmiana paradygmatu na zasadę opartą o uczenie maszynowe. Choć możliwość stworzenia algorytmów, które same będą się uczyły, na zestawie danych było już zasygnalizowane przez Alana Turinga w 1950 r., to przez kilka dekad próby stworzenia programów uczących się pozostawały w cieniu rozwoju komputerów<sup>27</sup>. Wynalezienie przez Rosenblatta perceptronu, a także prace m.in. Winstona, Michalskiego, Hunta i Nilssona wprowadziły w latach 80. XX w.

---

<sup>23</sup> Por. H. Simon. *Search and Reasoning in problem solving*. „Artificial Intelligence” 21:1983 nr 1-2 s. 9.

<sup>24</sup> Por. M. Grindal. *Handling Combinatorial Explosion in Software Testing*. Linköping 2007 s. 3.

<sup>25</sup> Por. N. Kokash. *An introduction to heuristic algorithms*. „Department of Informatics and Telecommunications” 1:2005 nr 1.

<sup>26</sup> Por. F. Rosenblatt. *The perceptron: A probabilistic model for information storage and organization in the brain*. „Psychological Review” 65:1958 nr 6 s. 386-408.

<sup>27</sup> Por. Z. Zhou. *Machine learning*. Singapur 2021 s. 12.

rozwój AI w nową erę, nazywaną erą wiedzy<sup>28</sup>. Zmianę tego paradygmatu określa sposób postrzegania programu nie tylko jako narzędzia o potężnej możliwości obliczeniowej, przekraczającej ludzki mózg w zadaniach logicznych, ale także jako narzędzia, które może uczyć się i tworzyć reguły, które później można praktycznie zaimplementować jako wytrenowany model w podejmowaniu przez program decyzji. W tym kontekście pomocna jest definicja uczenia się przedstawiona przez Michalskiego, Carbonella i Mitchella:

[...] uczenie to zmiana w systemie, która pozwala na lepsze funkcjonowanie w kolejnej repetycji tego samego zadania, lub zadania pochodzącego z tego samego zbioru<sup>29</sup>.

Zasadę działania algorytmów uczących się można określić w następujący sposób: programista podaje do programu oczekiwane odpowiedzi (w uczeniu nadzorowanym) i dane treningowe (przykłady), zaś algorytm ma za zadanie znalezienie reguł pomiędzy danymi<sup>30</sup>. Wyniki w postaci reguł są sprawdzane i jeżeli algorytm osiągnie wartościowe reguły (np. dla przypadku rozwiązania jakiegoś problemu), to nazywa się go modelem wytrenowanym. Musimy pamiętać, że dane, na których pracują algorytmy uczące się, to przede wszystkim dane opisane matematycznie – stąd także reguły, które wydzieli algorytm, przekraczają możliwości ludzkiej percepcji i czas, który na to samo zadanie musiałby poświęcić człowiek<sup>31</sup>. To bardzo ważne przy próbie zrozumienia podstaw AI, ponieważ w popularnym rozumieniu, gdy użytkownik posługuje się np. do generowania obrazu językiem naturalnym, ma wrażenie, że model AI działa na poziomie języka naturalnego i generuje obrazy podobnie jak człowiek-grafik<sup>32</sup>. Tymczasem to podstawa matematyczna, szczególnie wykorzystanie macierzy matematycznych, pozwala algorytmom na przeprowadzenie procesu generowania od danych podanych w języku naturalnym przez użytkownika, przez konwersję języka naturalnego na język matematyczny i wygenerowanie na tym poziomie wyników. Użycie wielowymiarowych macierzy pozwala na opisanie jednego punktu za pomocą kilku zmiennych. W przypadku generowania obrazu można dzięki macierzy opisać stały punkt (piksel) za pomocą np. zmiennych RGB. Zrozumienie podstawy działania modeli AI i ich podstawy matematycznej umożliwi ich bardziej skuteczne wykorzystanie. Posiadanie przez algorytm wytrenowany rozpoznanych wzorców pozwala na zautomatyzowanie

<sup>28</sup> Por. tamże s. 13-15.

<sup>29</sup> R. Michalski, J. Carbonell, T. Mitchell. *Machine learning: An artificial intelligence approach*. Berlin 2013 s. 28. Jeśli nie zaznaczono inaczej, wszystkie tłumaczenia z języka angielskiego Paweł Janowski.

<sup>30</sup> Por. A. Król-Nowak, K. Kotarba. *Podstawy uczenia maszynowego*. Kraków 2022 s. 10.

<sup>31</sup> Por. C. Bishop. *Pattern Recognition and Machine Learning*. Nowy Jork 2006 s. 677-684.

<sup>32</sup> Por. A. Sierżantowicz, A. Ptasznik. *Opracowanie koncepcji i implementacja modelu rozpoznawania obrazu z wykorzystaniem elementów sztucznej inteligencji*. „Zeszyty Naukowe WWSI” 23:2020 nr 14 s. 9.

decyzji podejmowanych przez program<sup>33</sup>. Uczenie maszynowe stało się więc od lat 80. XX w. głównym nurtem i mogło być skuteczne tylko dzięki zastosowaniu przez naukowców bardziej skomplikowanych metod matematycznych w reprezentacji danych i programowaniu<sup>34</sup>.

Rozwojowi algorytmów uczenia maszynowego towarzyszyły dwa bardzo ważne fakty: zwiększająca się z roku na rok moc obliczeniowa komputerów i zwiększanie się ilości zgromadzonych danych. Dla porównania, jeden z pierwszych komputerów Ferranti Mark 1, służący jako platforma dla symulatora szachów C. Stracheya, był 10 mln razy wolniejszy niż komputer Deep Blue z 1997 r., który wygrał partię z Garrim Kasparowem, natomiast dzisiejszy smartfon dobrej jakości może być szybszy kilka tysięcy razy od superkomputera Deep Blue<sup>35</sup>. Zwiększone moce obliczeniowe nie tylko otwierały nowe horyzonty przed uczeniem maszynowym, ale także wspomagały pracę naukowców. Zgodnie ze zjawiskiem zauważonym i przewidywanym przez Gordona Moora w 1965 r. (tzw. prawem Moora) każdy kolejny rok rozwoju komputerów skutkowało podwojeniem mocy obliczeniowej procesorów. Dzisiaj możemy ocenić, że jego przewidywania była trafne przez ponad 50 lat<sup>36</sup>. Drugim faktem był ogromny wzrost posiadanych danych, zarówno dzięki trwającemu od kilku dekad rozwojowi cyfryzacji, jak również niewyobrażalnemu zwielokrotnieniu dostępu do danych po wynalezieniu *World Wide Web* w latach 90 XX w.<sup>37</sup> Rozwój Internetu pozwolił na wykorzystanie ogromnej ilości tekstu, grafik i zdjęć oraz danych audio, których nie potrafiliby zgromadzić wszyscy naukowcy świata – pozostawało jedynie użyć tych danych w rozwoju ML. Aby zobrazować różnicę w dostępie do danych na przestrzeni dwóch dekad, można przytoczyć fakty: w 1985 r. na każdego człowieka na świecie przypadało ok. 0,02 mb danych, w 1996 r. już 28 mb, zaś w 2000 r. – 472 mb. Statystyki te, oczywiście, są znormalizowane dla całej populacji, więc

---

<sup>33</sup> Por. K. Regulski. *Metody uczenia maszynowego wspierane semantycznie*. W: *Trendy i rozwiązania technologiczne*. Red. M. Maciąg, K. Maciąg. Lublin 2017 s. 24.

<sup>34</sup> Por. Joint Research Centre UE. *AI Watch Historical Evolution of Artificial Intelligence*. Raport Unii Europejskiej, 2020. <doi:10.2760/801580> s. 11.

<sup>35</sup> Oczywiście, próba określenia mocy obliczeniowej nie jest ostatecznym wynikiem skuteczności komputera – kolejne nowe komputery nie wykazują już wzrostu mocy obliczeniowej względem starszych modeli w takim stosunku, jak np. komputery z lat 90. XX w., ale to nie znaczy, że nie zauważamy rozwoju. Dzisiaj nie chodzi tylko o wzrost siły komputera, ale o zaprojektowanie go do odpowiednich zadań – stąd waga miniaturyzacji (np. rozwój smartfonów), wielowątkowych rdzeni procesorów i funkcjonalności, a także takich spraw, jak chłodzenie. Por. P. Skalfist, D. Mikelsten, V. Teigens. *Sztuczna inteligencja: czwarta rewolucja przemysłowa* s. 30.

<sup>36</sup> Por. M. Roser, H. Ritchie, E. Mathieu. *Technological Change*. <<https://ourworldindata.org/technological-change>> [dostęp: 20.01.2024].

<sup>37</sup> Por. Y. Chen, J. Li, J. Wang. *Machine learning and statistical modeling approaches to image retrieval*. Boston 2006 s. 13.

można sobie wyobrazić, że te liczby były znacznie większe w krajach rozwiniętych w stosunku do całego świata<sup>38</sup>.

Eksplozja informacyjna potrzebowała nowych metod klasyfikacji danych, a także bardziej zoptymalizowanego sposobu ich ekstrakcji z baz. Zjawisko ogromnych zbiorów informacji, często nieliniowych, tzn. zawierających w jednej przestrzeni wiele różnych zbiorów danych, dla których konwencjonalne możliwości algorytmiczne są niewystarczające, określane jest jako *big data*<sup>39</sup>. W przypadku obrazów ich klasyfikacja opierała się głównie na semantycznym opisie i meta-danych. To jednak było rozwiązanie stwarzające problemy i ograniczające możliwości łatwego pobierania danych np. przez algorytmy uczące się. Tagi zdjęć są aspektowe, często podlegają błędom poznawczym lub kontekstowym ich twórcy, np. zdjęcie konia na prerii mogło być opisane tagami: biały koń, mustang, preria, USA, piękne, 2008<sup>40</sup>. Oczywiście, intuicyjnie wiemy, że to zdjęcie mogłoby być również opisane metafizycznie – np. słowem «wolność» i wieloma innymi, które mogłyby poprowadzić do różnorodnego wykorzystania takiego zdjęcia. Znowu z pomocą przyszła matematyka oraz metody statystyczne i probabilistyczne, które umożliwiały bardziej wydajną segregację danych i bardziej precyzyjne matematyczne reprezentacje dla algorytmów. Obraz mógł być odzyskiwany z bazy danych nie tylko poprzez metadane i tagi, ale również poprzez abstrakcję cech zdjęcia – kształtu, tekstury, tematu, stylu intensywności czy kolorów<sup>41</sup>. Uczenie maszynowe odegrało w tej dziedzinie kluczową rolę – w połowie lat 90. XX w., w obliczu ciągle zwiększającego się dostępu do danych, a także kryzysu w rozwoju nurtów ML z poprzednich dekad, przyjęto rozwiązania wykorzystujące teorię statystyczną i probabilistyczną w działaniu algorytmów ML. Znaczący wkład powinien zostać tutaj przypisany Vladimirowi Vapnikowi, który stworzył teorię uczenia statystycznego, leżącą u podstaw zastosowania wektorów nośnych – tzw. *support vector machines* (SVM)<sup>42</sup>. SVM to metoda analityczna, która usprawniła procesy przewidywań i klasyfikacji danych. Była kluczowa w przeprowadzeniu pierwszych

---

<sup>38</sup> Por. L. Sweeney. *Information explosion. W: Confidentiality, disclosure, and data access: Theory and practical applications for statistical agencies*. Red. L. Zayatz, P. Doyle, J. Theeuwes. North-Holland 2001 s. 61.

<sup>39</sup> Por. C.W. Tsai, C.F. Lai, H.C. Chao, A.V. Vasilakos. *Big data analytics: a survey*. „Journal of Big data” 2015 nr 2 (1) s. 2.

<sup>40</sup> Por. J. Fu, Y. Rui. *Advances in deep learning approaches for image tagging*. „Signal and Information Processing” 6:2017 s. 1-2. Znakowanie (tagowanie) zdjęć – próby klasyfikacji zdjęcia poprzez bardziej przyjazny człowiekowi opis jedno- lub wielosłowny wyrażający zawartość wizualną zdjęcia. Tagowanie zdjęć może odbywać się zarówno dzięki manualnemu opisowi człowieka, automatycznemu opisowi przez algorytm lub poprzez łączenie tych metod. Jednakże ostateczna lista tagów posiada często wady i wymaga procesów poprawiających otrzymany wynik.

<sup>41</sup> Por. Y. Chen, J. Li, J. Wang. *Machine learning and statistical modeling approaches to image retrieval* s. 3.

<sup>42</sup> Por. Z. Zhou. *Machine learning* s. 14.



skutecznych prób rozpoznawania obrazu. Pozwalała także na grupowanie danych i ich mapowanie w innej przestrzeni danych za pomocą funkcji Kernela<sup>43</sup>.

## 2. GŁĘBOKIE SIECI NEURONOWE I BIG DATA

Choć przez kilka dekad zastosowanie sieci neuronowych pozostawało w cieniu głównie ze względu na ograniczenia technologiczne i brak wystarczającego dostępu do danych, to w latach 90. XX w. sieci neuronowe wróciły do *mainstreamu* badań i zyskały popularność w zastosowaniu zarówno naukowym, jak i komercyjnym<sup>44</sup>. Głównym problemem, który pokonano w latach 90. XX w. w kontekście wykorzystania wielowarstwowych sieci neuronowych, była trudność w przekazywaniu informacji o błędzie wstecz w sieci, gdzie na różnych poziomach sieć operowała na nieliniowych danych, tak aby umożliwić skuteczne uczenie się modelu. Kluczowy okazał się tzw. algorytm propagacji błędów, który umożliwił przekazywanie błędu do wstecznych kroków sieci, poprawianie wag i ostatecznie regułę działania poszczególnych warstw<sup>45</sup>. Skuteczność głębokich (wielowarstwowych) sieci neuronowych stała się faktem i ukonstytuowała się jako podstawa działania współczesnych aplikacji sztucznej inteligencji. Głębokie sieci neuronowe były ostatnim brakującym elementem do rozwinięcia skrzydeł dla przeszło 50-letniej pracy nad AI. Stworzyły one nowy paradygmat prac nad sztuczną inteligencją, który określamy jako *deep learning*.

Głębokie uczenie wykazało wysoką efektywność w wielu *benchmarkach*<sup>46</sup>. Szczególnie skuteczne okazało się w dziedzinie rozpoznawania i generacji obrazów, a także nieliniowych danych tożsamy z audio i video – czyli w takich aplikacjach, jak rozpoznawanie mowy i generowanie dźwięku czy analizowanie obrazów. Modele DL, pomimo swojej kompleksowości i rozbudowanej struktury, są jednocześnie stosunkowo proste w obsłudze, choć wymagają znacznie więcej pracy nad odpowiednią parametryzacją procesów niż inne nurty uczenia maszynowego<sup>47</sup>. Zdecydowaną przewagą głębokich sieci neuronowych jest możliwość aplikowania

---

<sup>43</sup> Por. P.H. Chen, C.J. Lin, B. Schölkopf. *A tutorial on  $\nu$ -support vector machines*. „Applied stochastic models in business and industry” 21:2005 s. 134.

<sup>44</sup> Por. Z. Zhou. *Machine learning* s. 13-14.

<sup>45</sup> Por. R. Tadeusiewicz. *Sieci neuronowe*. „Postępy Fizyki” 45 1993 nr 3 s. 224.

<sup>46</sup> „*Benchmarking* pochodzi od angielskiego słowa *bench-mark* i oznacza «reper», czyli punkt orientacyjny wyznaczony w widocznym z daleka miejscu, na przykład w formie wieży, wykorzystywany w pomiarach niwelacyjnych. W języku polskim to również punkt odniesienia, wzorzec, norma. Pojęcie następnie przeniesiono na grunt praktyk organizacyjnych i jest uznawane za punkt odniesienia, który pozwala zorientować się, w którym miejscu jesteście w porównaniu do wyniku doskonałego lub tzw. *best in class*”. Por. K. Zimmiewicz. *Współczesne koncepcje i metody zarządzania*. Warszawa 2003 s. 44.

<sup>47</sup> Por. Z. Zhou. *Machine learning* s. 15.

surowych danych bez potrzeby budowania skomplikowanych baz danych wejściowych i odpowiedniego klasyfikatora danych. Przed zastosowaniem głębokich sieci neuronowych zbudowanie skutecznego systemu uczenia maszynowego wymagało starannej i trudnej pracy nad określeniem tzw. ekstraktora, który przekształcał surowe dane (np. zapis binarny) w odpowiednie dla modelu reprezentatywne dane, tak aby klasyfikator algorytmu mógł odnaleźć reguły i wzory w zbiorach danych. Technologia głębokich sieci neuronowych pozwoliła na automatyczne klasyfikowanie i reprezentowanie danych. Sposób działania DL można przedstawić jako strukturę, która na różnych poziomach sieci ciągle przekształca dane i przedstawia je w kolejnej warstwie sieci. Każda kolejna, głębsza sieć procesuje dane według reguł, które wypracowała wcześniej i może je reprezentować w innym wymiarze, w stosunku do poprzednich warstw sieci. Tym samym cała struktura może pracować na danych różnego rodzaju, jednocześnie korzystając z wielu reguł właściwych coraz bardziej skomplikowanym i abstrakcyjnym reprezentacjom danych, kontynuując dalej proces ekstrakcji reguł, które wiążą nie tylko dane z jednego poziomu sieci, ale z całej struktury. Warto podać przykład schematu działania DL na podstawie rozpoznawania obrazu. Dane treningowe w postaci obrazu zostają wprowadzone do sieci, pierwsza warstwa przekształca obraz w odpowiednią macierz i uczy się najogólniejszych cech, np. istniejących lub nieistniejących konturów, kolorów i ich orientacji. Kolejna warstwa wyróżnia już grupy podobnych elementów lub obiektów, które są ze sobą związane poprzez ciągłość linii, a więc przechodzi na wyższy poziom ogólności w stosunku do pojedynczych linii. Trzecia warstwa może grupować poznane wcześniej elementy w większe obiekty i kombinować je w stosunku do np. danych wejściowych lub porównywać z obiektami już znanymi. Dochodzi więc do generalizacji, podobnej do tworzenia ogólnych pojęć obiektów<sup>48</sup>. Proces tworzenia reguł obrazu, a tym samym ekstrakcji uogólnionych obiektów, pozwala na skuteczne i automatyczne rozpoznawanie, co jest na grafice, a tym samym na klasyfikowanie obrazów i ich cech oraz na tworzenie nowych obrazów przy zastosowaniu wyuczonych zasad.

Taki proces uczenia wymaga ogromnych zbiorów danych, z którymi modele mogą porównywać osiągnięte wyniki. Do połowy pierwszej dekady lat 2000. modele oparte o głębokie sieci neuronowe były w stanie rozpoznawać obrazy i obiekty, ale współczynnik błędu był bardzo wysoki, blokując tym samym komercyjne zastosowania. Innymi słowy, modele za często się myliły, stąd nie znajdowały zaufania użytkowników, a ich działanie pozostawiało wiele do życzenia. Naukowcy bazowali na przekonaniu, że jeżeli rozpoznawanie obrazu jest ciągle obarczone wysokim błędem, a pierwsze generatory obrazów dawały mierne wyniki i były dalekie od tworzenia realistycznych grafik, to należy wciąż pracować nad

---

<sup>48</sup> Por. Y. LeCun, Y. Bengio, G. Hinton. *Deep learning*. „Nature” 2015 nr 521 s. 436.

poprawieniem podstaw działania modeli poprzez bardziej skomplikowane programowanie lub pracę na zbiorach danych.

Prof. Fei-Fei Li była jednym z naukowców, którzy proponowali inny sposób rozwoju modeli głębokiego uczenia – jej zdaniem problem odwzorowania realistycznych obrazów nie polegał na przeszkodzie leżącej wewnątrz działania sieci, ale na zbyt małej liczbie danych podawanych modelowi<sup>49</sup>. Więcej danych umożliwi stworzenie lepszych modeli. W 2009 r. wykonała więc projekt *ImageNet*, w którym zgromadzono ponad 3 mln skategoryzowanych zdjęć i stale powiększono bazę danych treningowych dla modeli sieci neuronowych<sup>50</sup>. Coroczny konkurs – *ImageNet Large Scale Visual Recognition Challenge* – stał się odzwierciedleniem postępów w dziedzinie rozpoznawania obrazu. W 2011 r. współczynnik błędu dla modeli wynosił około 25%. W kolejnych latach współczynniki błędów zmalały do około 2%<sup>51</sup>. Skuteczność nowego podejścia w zastosowaniu głębokich sieci i ogromnych zbiorów danych została udowodniona i dała impuls do ogromnego rozwoju AI oraz licznych zastosowań komercyjnych. Kultura publikacyjna badań nad DL to przede wszystkim otwarta wymiana spostrzeżeń i danych, liczne koleżeńskie konkursy na największą skuteczność modeli i rozwiązań. Dostępnych jest wiele darmowych kursów i kolaboracji<sup>52</sup>. Najważniejsi potentaci rynkowi zainwestowali miliardy dolarów w rozwój sztucznej inteligencji opartej na głębokich sieciach neuronowych. To wszystko złożyło się na liczne sukcesy w dziedzinie DL w drugiej dekadzie lat 2000. – autonomiczne pojazdy, wygrane przez AI gry z mistrzami świata jak szachy, GO, Poker, Dota czy Atari, wysoce efektywne roboty, a w końcu GPT-2 i generatory obrazu<sup>53</sup>. Ten moment rozwoju technologicznego dla AI był decydującym rozdziałem pomiędzy różnymi dziedzinami wykorzystania i dalszej pracy nad modelami sztucznej inteligencji. Dla wszystkich podstawą jest *deep learning*, *big data* oraz wspomniane wcześniej osiągnięcia naukowe i technologiczne. Przystosowanie tych technologii do konkretnych dziedzin i zadań wymagało zogniskowanej pracy nad pokonywaniem partykularnych problemów wynikających z problematyki dziedziny.

Dla generatorów obrazu ważnym *novum* było wynalezienie GAN – *Generative Adversarial Networks*. Pomimo licznych sukcesów w rozpoznawaniu obrazów, jak *Cat Experiment*, który udowodnił, że można nauczyć model rozpoznawania obrazów z całkowicie losowych zdjęć dostępnych w Internecie, generacja obrazów

---

<sup>49</sup> Por. <[https://pl.wikipedia.org/wiki/Fei-Fei\\_Li](https://pl.wikipedia.org/wiki/Fei-Fei_Li)>.

<sup>50</sup> Por. <<https://image-net.org/index.php>>.

<sup>51</sup> Por. Joint Research Centre UE. *AI Watch Historical Evolution of Artificial Intelligence* s. 11.

<sup>52</sup> Por. tamże s. 12-13.

<sup>53</sup> Por. tamże s. 14.

wciąż pozostawiała wiele do życzenia<sup>54</sup>. Liczne niepożądane zjawiska, jak *mode collapse* (czyli generowanie jednej lub podobnych do siebie wariacji obrazu), *overfitting* (czyli nadmierne zapamiętywanie danych treningowych, prowadzące do generowania obrazów bardzo podobnych do obrazów treningowych) oraz *artificial textures* (czyli generowanie obrazów ze skazami w postaci nierealistycznych obszarów lub pikseli), wciąż stawiały nowe wyzwania przed naukowcami. Oprócz pogłębiania sieci neuronowych pracujący nad modelami generatywnymi zastosowali liczne ulepszenia, m.in. funkcje strat, normalizację warstw i normalizację reguł (*dropout*), które w sumie dawały bardzo pozytywne wyniki. Wraz z wprowadzeniem GAN-ów realizm generowanych obrazów w końcu zaczął spełniać požądane oczekiwania.

GAN to typ architektury neuronowej, która polega na zastosowaniu jednocześnie uczących się, dwóch sprzężonych sieci neuronowych – tzw. generatora i dyskryminatora. Generator ma za zadanie wygenerować jak najbardziej realistyczny i nowy obraz w odniesieniu do danych wejściowych, natomiast dyskryminator ma sprawdzić, czy wynik nie jest zbyt podobny z danymi treningowymi, danymi wejściowymi lub czy nie jest nierealistyczny. Sprzężenie sieci wprowadziło między nimi rywalizację i wymianę danych. Usprawniło to proces uczenia się i pozwoliło na bardziej uogólnione wyniki, które niwelowały wrażenie braku realizmu i powtarzalności<sup>55</sup>. Należy zauważyć, że problem *overfittingu* poprowadził twórców do konstruowania modeli tak, aby generowane wyniki były obarczone jak najmniejszą powtarzalnością i sprawiały wrażenie „kreatywnych”, niepowtarzalnych. Z drugiej strony było to znaczące ograniczenie modeli generatywnych – nie jesteśmy w stanie wygenerować obrazu, który jest np. wariacją naszego zdjęcia, modele mają problem z generacją np. palców czy tekstu, gdyż sam model nie posiada abstrakcyjnego rozumienia palców, dłoni czy liter, ale generuje je z przyjętym prawdopodobieństwem mapowania pikseli<sup>56</sup>. Oczywiście, ten problem został rozwiązywany przez generowanie obszarowe, czyli możliwości interfejsu do obsługi wybranych obszarów obrazu lub nakładki algorytmów, które nie działają na zasadzie GAN-ów, ale korzystają z klasycznych sposobów obróbki obrazu<sup>57</sup>.

---

<sup>54</sup> Por. Q.V. Le. *Building high-level features using large scale unsupervised learning*. Konferencja naukowa: „In 2013 IEEE international conference on acoustics, speech and signal processing 2013” s. 8595-8598.

<sup>55</sup> Zob. L. Goodfellow, J. Pouget-Abadie, M. Mirza. *Generative adversarial nets*. „Advances in neural information processing systems” 27:2014 s. 1-2.

<sup>56</sup> Zob. S. Mirjalili. *If AI Image Generators Are So Smart, Why Do They Struggle to Write and Count?*. <<https://nftnow.com/features/if-ai-image-generators-are-so-smart-why-do-they-struggle-to-write-and-count>> [dostęp: 4.02.2024].

<sup>57</sup> Zob. możliwości generowania obszarowego w Adobe Firefly: <<https://firefly.adobe.com/generate/inpaint>> [dostęp: 4.02.2024].

### 3. TEXT TO IMAGE – STABLE DIFFUSION

W jaki sposób możliwe jest generowanie obrazu przez żądanie tekstowe tworzone przez użytkownika w najpopularniejszych generatorach typu *text to image*?<sup>58</sup> Tak zwane *prompty*, czyli podpowiedzi użytkownika o przewidywanym wyniku generowania, to słowa kluczowe, dzięki którym model może otrzymać dane wejściowe, jakie obiekty ma wygenerować<sup>59</sup>. Dotyczą one zarówno obiektów, stylu, jak i rodzaju grafiki<sup>60</sup>. Są podawane, oczywiście, w formie języka naturalnego. Aby model pracujący na poziomie macierzy matematycznych mógł korzystać z podanych *promptów*, musi posiadać element, który będzie przekształcał słowa w reprezentatywne wektory. Różne modele wywodzące się z prac nad głębokimi sieciami neuronowymi nurtu *Natural Language Processing* (NLP) pozwalają na operację przekształcenia języka naturalnego na język macierzy, zarówno w generatorach *text to image*, jak i odwrotnym procesie *image automatic caption*, czyli w opisywaniu w języku naturalnym obrazów w zbiorach<sup>61</sup>. Z punktu widzenia użytkownika przy generowaniu obrazów to właśnie *promptowanie* jest najważniejszym punktem komunikacji z modelem generatywnym i od niego najbardziej zależy zgodność wyników z oczekiwaniami<sup>62</sup>. Samemu *promptowaniu* i optymalizacji *promptów* poświęcono już osobną dziedzinę rozwoju sztucznej inteligencji, a na rynku pracy pojawiło się stanowisko *prompt-engineer*. *Prompty* wskazują również na granice możliwości modeli i ich naturę – brak zrozumienia obrazów przez model, a tym samym losowość cech przypisywanych obrazowi, które zostały w czasie treningu skategoryzowane wspólnie – np. niebo, skrzydło anioła, Jezus.

*Stable Diffusion* generuje reprezentatywny obraz ze zbiorów treningowych odpowiadających treści *promptu* – a więc tworzy obiekty i główne cechy obrazu. Otrzymany obraz jest wielokrotnie deskalowany, aby zmniejszyć potrzebne moce obliczeniowe i uogólnić cechy grafiki. Zmniejszony obraz, pomimo straty wielu

---

<sup>58</sup> J. Oppenlaender. *Prompt engineering for text-based generative art*. <arXiv preprint arXiv:2204.13988> 2022 s. 1.

<sup>59</sup> *Promptowanie* (ang. *prompt* – instrukcja, podpowiedź) to umiejętność zadawania pytań modelom językowym w taki sposób, aby otrzymać odpowiedzi jak najbardziej zbliżone do naszych oczekiwań. Jest to dynamicznie rozwijająca się dziedzina nauki o sztucznej inteligencji oraz kompetencja coraz częściej poszukiwana przez pracodawców. Inżynier podpowiedzi (ang. *prompt engineer*) to oficjalna nazwa stanowiska na rynku pracy, odzwierciedlająca rosnące zapotrzebowanie na specjalistów zdolnych do efektywnego komunikowania się z zaawansowanymi systemami AI. Por. <<https://zpe.gov.pl/a/14-inzynieria-podpowiedzi-ang-prompt-engineering/DMfAEMwe2>> [dostęp: 4.02.2024].

<sup>60</sup> Zob. H. Dang, L. Mecke, F. Lehmann. *How to prompt? Opportunities and challenges of zero-and few-shot learning for human-AI interaction in creative applications of generative models*. <arXiv preprint arXiv:2209.01390> 2022 s. 1-2.

<sup>61</sup> Por. J. Oppenlaender. *Prompt engineering for text-based generative art* s. 3.

<sup>62</sup> Por. S. Lee, B. Hoover, H. Strobelt. *Diffusion Explainer: Visual Explanation for Text-to-image Stable Diffusion*. <arXiv preprint, arXiv:2305.03509> 2023 s. 3-4.

informacji, zachowuje ogólne wzorce, np. owal twarzy. Obraz jest zaszumiany, następnie odszumiany. Ten proces, chociaż wydaje się paradoksalny, jest kluczem do zrozumienia, jak działa model *Stable Diffusion*. Odszumianie bowiem odbywa się dzięki wiedzy zdobytej przez głębokie uczenie i pozwala na wygenerowanie kolejnych pikseli w trochę inny sposób niż te, które posiadał pierwotny obraz treningowy. Głęboka sieć nauczona na milionach obrazów jest w stanie według promptów odzyskać prawdopodobny obraz – jest on jednak zawsze różny od danych treningowych. Stąd wrażenie oryginalności obrazu. Następnie obraz jest powiększany do standardowego formatu, równoległe jest poddawany procesom detalizacji, dzięki czemu możemy uzyskać wizualizację bardzo szczegółową, realistyczną i odpowiadającą stylom podanym w promptach. Ta technologia z jednej strony pozwala na uzyskanie wysokiej jakości dowolnych obrazów, z drugiej narzuca ograniczenia – taki model będzie generował obiekty z pewną dozą prawdopodobieństwa. Jeżeli model posiada dużą bazę obrazów odpowiadających obiektom podanym w promptach, jak np. twarz papieża Franciszka, to otrzymany obraz będzie niewątpliwie skutecznie odzwierciedlał w oryginalny sposób żądany przez użytkownika obiekt. W szczegółach jednak będzie różnił się od realnych obiektów. W podanym przypadku generowania portretu papieża Franciszka po starannym zbadaniu wygenerowanego obrazu można zobaczyć, że cechy stałe twarzy są inne niż u prawdziwego papieża – te różnice wynikają właśnie z procesu technologicznego generowania *Stable Diffusion* i są kluczowe w zrozumieniu natury obecnych generatorów sztucznej inteligencji, ich zalet i wad. Jeszcze wyraźniejszym przykładem będzie próba generowania realnych obiektów, takich jak popularne miejsca (czyli miejsca, dla których model może znaleźć reprezentatywne dane treningowe w swojej bazie), np. rynek krakowski. Wynik zawsze będzie się różnił od realnego obrazu.

#### 4. OBRAZY RELIGIJNE I SZTUCZNA INTELIGENCJA

Obrazy religijne są obrazami o głębokiej symbolice, gdzie każdy element ma znaczenie – to istotna trudność dla AI, która nie rozumie treści, a jedynie tworzy ją na bazie swoich zasobów treningowych, promptu i prawdopodobieństwa, wynikającego z popularności rozwiązań estetycznych. Tematyka religijna jest niepopularna, co powoduje niewielki, w porównaniu do innych tematów, zasób danych treningowych i wymaga od modelu przyjęcia pewnych uproszczeń, co często skutkuje tym, że obraz wygenerowany przez AI nie jest prawidłowy. Tematyka religijna jest również niejednorodna w rozumieniu algorytmu i potrzebuje kontekstu – słowo «Bóg» może oznaczać zarówno wyobrażenie Boga chrześcijańskiego w kulturze europejskiej, jak również bóstw mitologicznych czy graficznych rozwiązań znanych z gier komputerowych. Błędy reprezentacji zapytania często

pokazują wewnętrzną strukturę modelu, jego zasoby treningowe i kształt, jednocześnie wskazując ograniczenia. Niewątpliwie daje się również odczuć kontrast pomiędzy technologią a metafizyką, który ujawnia się w próbie generowania obrazów religijnych i odpowiada dyskusjom filozoficznym nad naturą sztucznej inteligencji i możliwościami jej wykorzystania.

Obraz religijny jest gęsty, tzn. bogaty w symbolikę, gdzie każdy element prowokuje interpretację w odniesieniu do przedstawionej na obrazie antropologii i teologii. Przypadkowość elementów w generowanych obrazach powoduje tutaj oczywisty problem. Również sam wizerunek i kontekst przedstawienia osób świętych budzi zawsze pytania o poprawność takiego, a nie innego przedstawienia, wpływ na postrzeganie religii i konstruowanie obrazu Boga czy wartości takich jak świętość. Obraz jest dla wiary bardzo ważny, wręcz kluczowy<sup>63</sup>. Z drugiej strony natura obrazu zawsze sprawiała problem w teologii – wyrażała więcej i jednocześnie mniej precyzyjnie niż to, co wyrażają słowa<sup>64</sup>. Herezja ikonoklazmu, która ogarnęła Kościół w VIII w. i odnawiała się wielokrotnie w kolejnych wiekach, uznawała tworzenie wizerunków świętych za bluźnierstwo i sprzeciwienie się przykazaniu z Księgi Wyjścia (por. Wj 20,4-5). Na szczęście przewyciężono ją i odrzucono. Wystarczające niech będą tu słowa J. Ratzingera:

Całkowity brak obrazów nie daje się pogodzić z wiarą we wcielenie Boga. Bóg w swym historycznym działaniu wkroczył w świat naszych zmysłów po to, aby świat ten stał się dla nas przezroczysty. Obrazy piękna, w których uwidacznia się tajemnica niewidzialnego Boga, przynależą do chrześcijańskiego kultu<sup>65</sup>.

Obraz religijny ma spełniać przede wszystkim funkcję pouczającą i wychowawczą, nadając wartościom i wydarzeniom zbawczym wyobrażenie i możliwość postrzegania przez zmysły<sup>66</sup>. Chociaż w sztuce religijnej Zachodu przez wiele wieków dominowała rzeźba, to dzisiaj zdecydowanie mamy do czynienia z prymatem obrazu, często postmodernistycznym – przedstawiającym z jednej strony elementy wiary, z drugiej dyskutującym z nimi, podającym je w wątpliwość lub przeobrażającym zgodnie z przyjętym, nowym kanonem estetycznym. Jakkolwiek w przeszłości można zauważyć ścieranie się platonizmu i arystotelizmu, co mocno wpływało na dobór form artystycznych w kontekście tworzenia sztuki religijnej, to dzisiaj, zgodnie z prawami postmodernizmu w sztuce, mamy do czynienia z mieszanymi wpływami idei i realizmu. Nieraz odróżnienie tych podstaw staje się bardzo trudne.

Obraz religijny podlega ścisłemu kanonowi, o ile mówimy o sztuce liturgicznej. Ponieważ twórca przez obraz opisuje kluczowe wartości wiary, to kanon,

---

<sup>63</sup> Por. W. Kawecki. *Wizualność współczesnej kultury*. „Roczniki Kulturoznawcze” 1:2022 s. 74.

<sup>64</sup> Por. H. Belting. *Obraz i kult*. Gdańsk 2012 s. 7-8.

<sup>65</sup> J. Ratzinger. *Duch liturgii*. Poznań 2002 s. 119.

<sup>66</sup> Por. tamże s. 105.

nazywany również językiem ikony, jest bardzo potrzebny, aby zachować prawdziwość przesłania<sup>67</sup>. W przypadku obrazu religijnego, rozumianego jako obraz okolicznościowy, powszedni, nieprzeznaczony do wykorzystania liturgicznego, ten kanon nie obowiązuje ściśle. Dyskusyjne jest więc to, czy wszystkie obrazy przedstawiające np. Jezusa są obrazami religijnymi? Co w sytuacji, gdy przedstawiają Jego osobę w sposób nieprawdziwy? Wyniki sztucznej inteligencji generują tu rzeczywiste problemy. Pomijając już kwestie błędów postrzegania, np. niewłaściwie rozłożone cienie postaci na obrazie czy zniekształcone dłonie, model nie rozumie zasad tworzenia obrazu religijnego i zderzy się w interpretacji z poprawnością dogmatyczną. Określona wizja świata zgodna z wiarą i historią jest trudna do odwzorowania w procesie generowania obrazu przez model. Trudno w końcu wymagać, aby ten, kto tworzy model, zawarł w nim zasady kosmologiczne, antropologiczne i teologiczne zgodne z wiarą chrześcijańską.

AI podlega w swojej strukturze zjawisku podobnemu do bańki informacyjnej. Podobnie jak w przypadku użytkowników Internetu, do których przez spersonalizowanie wyszukiwarek internetowych trafiają tylko te dane, które użytkownicy chcą zobaczyć lub z innego powodu są one pożądane przez twórców silnika wyszukiwania, tak i model, korzystając z ograniczonych zasobów treningowych, będzie odpowiadał, korelując dane, które odpowiadają wyższemu prawdopodobieństwu uzyskania pożądanego wyniku<sup>68</sup>. To wystarczy w przypadku generowania obrazów, które nie wymagają skomplikowanej symboliki. Jednak gdy chcemy uzyskać obraz, który będzie prawidłowy nie tylko z perspektywy użytych środków stylistycznych i form, ale również w warstwie symbolicznej, AI zwyczajnie jej nie rozumie. Stworzy poprawny obraz tylko wtedy, jeżeli w dużej mierze wykorzysta odpowiedni obraz z zasobu treningowego. W innym przypadku musi stworzyć brakujące dane z posiadanego zasobu, oczywiście bez zrozumienia warstwy symbolicznej. Dlatego otrzymujemy różne, czasami śmieszne, wyniki AI.

## PODSUMOWANIE

Czy da się stworzyć model, który będzie produkował poprawne obrazy religijne? Z pewnością tak. Czy taki model zostanie stworzony? Dopóki komercyjnie nie będzie opłacalny, może być dziełem tylko tych osób, którym na tym zależy z innych powodów. Na razie obecne modele wystarczająco dobrze radzą sobie z tworzeniem obrazów, również religijnych. Każdy grafik jest w stanie dopracować swoim warsztatem niepasujące elementy obrazu AI.

<sup>67</sup> Por. D. Klejnowski-Różycki. *Sakralna sztuka liturgiczna w nauczaniu Kościoła*. „Roczniki Teologiczne” 65:2018 nr 12 s. 82.

<sup>68</sup> Por. A. Dziekan-Łanucha. *Od personalizacji do profilowania. Opis konsekwencji korzystania z wyszukiwarki internetowej Google*. „Studia Socialia Cracoviensia” 14:2016 s. 126-127.



Wpływ sztucznej inteligencji na postrzeganie obrazu religijnego można porównywać ze zjawiskiem memizacji. Zjawisko wykorzystania memów w połączeniu z treściami religijnymi – czy to w formie prześmiewczej, czy też ewangelizacyjnej – jest już całkiem dobrze zbadane. Badania nad memami pokazują, że ta niepozorna forma wizualna skutecznie wpływa na zmianę mentalności i postrzegania elementów wiary<sup>69</sup>. Można się spodziewać, że wykorzystanie AI w obrazie religijnym upowszechni postmodernistyczny wizerunek osób świętych i różne od klasycznego kanonu postrzeganie wiary w społeczeństwie. Z drugiej strony to kolejny krok ułatwiający ewangelizację w kulturze obrazkowej<sup>70</sup>.

Sztuczna inteligencja to technologia opracowywana i rozwijana od lat 50. ubiegłego wieku. Kolejne kroki w jej rozwoju były równocześnie wyznaczeniem pewnych ograniczeń w zastosowaniach i pracy, co można obserwować chociażby w pracy modelu *Stable Diffusion*. Sam model pozwala na uzyskiwanie zaskakująco satysfakcjonujących wyników w generowaniu obrazów. Na wyniki działania modeli mają wpływ przede wszystkim procesy probabilistyczne, zasoby treningowe, architektura i wewnętrzny sposób rozwiązywania zadań. W kontekście tworzenia obrazów religijnych sztuczna inteligencja napotyka znaczące problemy. Nie rozumie gęstej symboliki religijnej. Tworzy obrazy na podstawie probabilistyki, niechrześcijańskich źródeł w zasobach chrześcijańskich oraz kompiluje nieprzystające często do siebie symbole, obiekty i konteksty. To wszystko jest wielkim wyzwaniem w mediatyzacji religii, gdyż wiele z publikowanych dzisiaj treści religijnych, stworzonych przez generatory AI, zawiera błędy teologiczne i może negatywnie wpływać na postrzeganie wiary. Samo wykorzystanie AI jest jednocześnie dużą szansą, aby przy dbałości o poprawność religijnych reprezentacji podnosić poziom publikacji w świecie Internetu na temat wiary.

## BIBLIOGRAFIA

- Bacho A., Boche H., Kutyniok G.: *Reliable AI: Does the Next Generation Require Quantum Computing?* Monachium 2023.
- Belting H.: *Obraz i kult.* Gdańsk 2012.
- Bieroński M.: *Etyczne i moralne wyzwania związane ze stosowaniem Sztucznej Inteligencji.* „Kieleckie Studia Teologiczne” 19:2020 s. 7-25.
- Bishop C.: *Pattern Recognition and Machine Learning.* Nowy Jork 2006.
- Causey C.: *A Critique of Pure Computation: Against Strong AI and Computationalism.* „Episteme” 31:2021.

---

<sup>69</sup> Por. A. Niekrewicz. *Językowe i wizualne sposoby deprecjonowania polskich symboli narodowych, kulturowych i religijnych w memach internetowych.* „Język. Religia. Tożsamość” 2015 nr 1 s. 109-121.

<sup>70</sup> Por. W. Kawecki. *Wizualność współczesnej kultury* s. 74-77.

- Chen C., Li O., Tao D., Barnett A., Rudin C., Su J.K.: *This looks like that: deep learning for interpretable image recognition*. „Advances in Neural Information Processing Systems” 32:2019 s. 8928-8939.
- Chen P.H., Lin C.J., Schölkopf B.: *A tutorial on  $\nu$ -support vector machines*. „Applied stochastic models in business and industry” 21:2005 s. 111-136. <<https://doi.org/10.1002/asmb.537>>.
- Chen Y., Li J., Wang J.Z.: *Machine learning and statistical modeling approaches to image retrieval*. Boston 2006.
- Cristea I., Sucala M., David D.: *Can you tell the difference? Comparing face-to-face versus computer-based interventions. The „Eliza” effect in psychotherapy*. „Journal of Cognitive & Behavioral Psychotherapies” 13:2013 nr 2 s. 291-298.
- Croitoru F.A., Hondru V., Ionescu R.T., Shah M.: *Reverse Stable Diffusion: What prompt was used to generate this image?*. <arXiv preprint, arXiv:2308.01472> 2023.
- Cycleback D.: *Examining the Intelligence in Artificial Intelligence*. „Center for Artifact Studies” 2020. <<https://philarchive.org/archive/CYCETI>> [dostęp: 10.01.2024].
- Dang H., Mecke L., Lehmann F., Goller S., Buschek D.: *How to prompt? Opportunities and challenges of zero-and few-shot learning for human-AI interaction in creative applications of generative models*. <arXiv preprint arXiv:2209.01390> 2022.
- Devika M.D., Sunitha C., Ganesh A.: *Sentiment analysis: a comparative study on different approaches*. „Procedia Computer Science” 87:2016 s. 44-49.
- Draguła A.: „Staliśmy się bowiem widowiskiem świata, aniołom i ludziom” (1 Kor 4,9). O wiżualności w komunikacji wiary. „Biuletyn Edukacji Medialnej” 2016 nr 1 s. 130-142.
- Dudek K.: *Papież: sztuczna inteligencja może być szansą, jak i zagrożeniem*. <<https://www.vaticannews.va/pl/papiez/news/2023-12/papiez-sztuczna-inteligencja-moze-byc-szansa-jak-i-zagrozeniem.html>> [dostęp: 9.01.2024].
- Dziekan-Łanucha A.: *Od personalizacji do profilowania. Opis konsekwencji korzystania z wyszukiwarki internetowej Google*. „Studia Socialia Cracoviensia” 14:2016 s. 123-136.
- Fischer B., Pązik A., Świerczyński M.: *Prawo sztucznej inteligencji*. Warszawa 2021.
- Flowers J.: *Strong and Weak AI: Deweyan Considerations*. AAAI Spring Symposium: Towards Conscious AI Systems, 2019. <<https://ceur-ws.org/Vol-2287/paper34.pdf>>.
- French A., Shim J., Risius M., Larsen K.R., Jain H.: *The 4th Industrial Revolution Powered by the Integration of AI, Blockchain, and 5G*. „Communications of the Association for Information Systems” 49:2021. <<https://doi.org/10.17705/1CAIS.04910>>.
- Fu J., Rui Y.: *Advances in deep learning approaches for image tagging*. „Signal and Information Processing” 6:2017 s. 1-13.
- Goluch T.: *Zastosowanie komputerów w dziedzinie wyszukiwania strategii optymalnych w grach logicznych*. „Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej” 31:2012 s. 57-60.
- Goodfellow I., Pouget-Abadie J., Mirza M.: *Generative adversarial nets*. „Advances in neural information processing systems” 27:2014 s. 1-9.
- Grindal M.: *Handling Combinatorial Explosion in Software Testing*. Linköping 2007.
- Huang T., Smith C.: *The History of Artificial Intelligence*. Washington 2006.
- Inżynieria podpowiedzi (ang. prompt engineering)*. <<https://zpe.gov.pl/a/14-inzynieria-podpowiedzi-ang-prompt-engineering/DMfaEMwe2>> [dostęp: 4.02.2024].

- Kloch J.: *Kościół w Polsce wobec Web 2.0*. Kielce 2013.
- Jan Paweł II: *Orędzie na XXXVI Światowy Dzień Środków Społecznego Przekazu* (24.01.2002).
- Jęczeń A.: *Profanacja wartości religijnych we współczesnych mediach*. „Biuletyn Edukacji Medialnej” 2011 nr 1 s. 118-126.
- Joint Research Centre UE. *AI Watch Historical Evolution of Artificial Intelligence*. Raport Unii Europejskiej, 2020. <doi:10.2760/801580>.
- Bernat K.: *Media i dziennikarstwo w świetle nauczania papieży: Jana Pawła II i Benedykta XVI*. W: *Formy dziennikarstwa: między odpowiedzialnością a sensacją*. Red. K. Wolny-Zmorzyński [i in.]. Warszawa 2015.
- Kawecki W.: *Wizualność współczesnej kultury*. „Roczniki Kulturoznawcze” 1:2022 s. 65-79.
- Kiełtyka L.: *Wykorzystanie systemów eksperckich w zarządzaniu wiedzą*. „Zeszyty Naukowe Politechniki Łódzkiej. Organizacja i Zarządzanie 2013 nr 53 s. 119-130.
- Klejnowski-Różycki D.: *Sakralna sztuka liturgiczna w nauczaniu Kościoła*. „Roczniki Teologiczne” 65:2018 nr 12 s. 75-88.
- Kloch J.: *Chiński pokój: eksperyment myślowy Johna Searla: studium historyczno-filozoficzne: cz. 2*. „Zagadnienia Filozoficzne w Nauce” 1996 nr 18 s. 67-86.
- Kokash N.: *An introduction to heuristic algorithms*. „Department of Informatics and Telecommunications” 1:2005 nr 1 s. 1-7.
- Koncewicz P.: „*Wolny i niezależny*” – Chat GPT zaczyna się buntować?. <<https://antyweb.pl/chat-gpt-bing-microsoft>> [dostęp: 10.01.2024].
- Król-Nowak A., Kotarba K.: *Podstawy uczenia maszynowego*. Kraków 2022.
- Le Q.V.: *Building high-level features using large scale unsupervised learning*. Konferencja naukowa: „In 2013 IEEE international conference on acoustics, speech and signal processing 2013” s. 8595-8598.
- LeCun Y., Bengio Y., Hinton G.: *Deep learning*. „Nature” 2015 nr 521 s. 436-444. <<https://doi.org/10.1038/nature14539>>.
- Lee S., Hoover B., Strobelt H., Wang Z.J.: *Diffusion Explainer: Visual Explanation for Text-to-image Stable Diffusion*. <arXiv preprint arXiv:2305.03509> 2023.
- Leśniczak R.: *Mediatyzacja religii w czasach globalizacji i neoglobalizacji*. Wybrane refleksje medioznawcze. „Studia Medioznawcze” 91:2022 nr 4 s. 1312-1321.
- Liu B.: „*Weak AI*” is Likely to Never Become „*Strong AI*”. So What is its Greatest Value for us?. 2021. <<https://arxiv.org/pdf/2103.15294.pdf>> [dostęp: 10.01.2024].
- McCarthy J., Minsky M.L., Rochester N., Shannon C.E.: *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955*. „AI Magazine” 27:2006 nr 4 s. 12. <<https://doi.org/10.1609/aimag.v27i4.1904>>.
- McCulloch W.S., Pitts W.: *A logical calculus of the ideas immanent in nervous activity*. „Bulletin of Mathematical Biophysics” 5:1943 s. 115-133. <<https://doi.org/10.1007/BF02478259>>.
- Michalski R.S., Carbonell J.G., Mitchell T.M.: *Machine learning: An artificial intelligence approach*. 2013 Berlin.
- Mirjalili S.: *If AI Image Generators Are So Smart, Why Do They Struggle to Write and Count?*. <<https://nftnow.com/features/if-ai-image-generators-are-so-smart-why-do-they-struggle-to-write-and-count>> [dostęp: 4.02.2024].

- Młodzianowski P., Rostkowski R.: *Podstawy uczenia maszynowego dla menadżerów projektu IT*. „Management and Quality – Zarządzanie i Jakość” 3:2021 nr 4 s. 18-26.
- Niekrewicz A.: *Językowe i wizualne sposoby deprecjonowania polskich symboli narodowych, kulturowych i religijnych w memach internetowych*. „Język. Religia. Tożsamość” 2015 nr 1 s. 109-121.
- Norbert W.: *Cybernetics or Control and Communication in the Animal and the Machine*. Cambridge 1948.
- Oleksiewicz I.: *Sztuczna inteligencja kontra człowiek – zagrożenie czy konieczność ewolucji?*. „Przegląd Europejski” 2022 nr 3 s. 55-69. <<https://doi.org/10.31338/1641-2478pe.3.22.4>>.
- Oppenlaender J.: *Prompt engineering for text-based generative art*. <arXiv preprint arXiv:2204.13988> 2022.
- Ostruszka K.: *Na wieki wieków AI. Jak sztuczna inteligencja zmieni naszą wiarę?*. <<https://www.tygodnikpowszechny.pl/na-wieki-wiekow-ai-jak-sztuczna-inteligencja-zmieni-nasza-wiare-183788>> [dostęp: 9.01.2024].
- Przegalińska A.: *Fenomenologia istot wirtualnych*. Rozprawa doktorska napisana w Instytucie Filozofii Uniwersytetu Warszawskiego 2014.
- Ratzinger J.: *Duch liturgii*. Poznań 2002.
- Regulski K.: *Metody uczenia maszynowego wspierane semantycznie*. W: *Trendy i rozwiązania technologiczne*. Red. M. Maciąg, K. Maciąg. Lublin 2017.
- Rosenblatt F.: *The perceptron: A probabilistic model for information storage and organization in the brain*. „Psychological Review” 65:1958 nr 6 s. 386-408.
- Roser M., Ritchie H., Mathieu E.: *Technological Change*. <<https://ourworldindata.org/technological-change>> [dostęp: 20.01.2024].
- Shannon C.E.: *A Mathematical Theory of Communication*. „The Bell System Technical Journal” 27:1948 s. 379-423.
- Sienkiewicz P.: *Od Eniaca do internetu i społeczeństwa wiedzy*. „Zeszyty Naukowe Warszawskiej Wyższej Szkoły Informatyki” 1:2006 s. 9-23.
- Sierżantowicz A., Ptasznik A.: *Opracowanie koncepcji i implementacja modelu rozpoznawania obrazu z wykorzystaniem elementów sztucznej inteligencji*. „Zeszyty Naukowe WWSI” 23:2020 nr 14 s. 7-26.
- Simon H.: *Allen Newell: 1927-1992*. „IEEE Annals of the History of Computing” 20:1998 nr 2 s. 63-70.
- Simon H.: *Search and Reasoning in problem solving*. „Artificial Intelligence” 21:1983 nr 1-2 s. 7-29.
- Siuta-Tokarska B., *Przemysł 4.0 i sztuczna inteligencja: szansa czy zagrożenie dla realizacji koncepcji zrównoważonego i trwałego rozwoju?*. „Nierówności społeczne a wzrost gospodarczy” 2021 nr 65 s. 7-26.
- Skalfist P., Mikelsten D., Teigens V.: *Sztuczna inteligencja: czwarta rewolucja przemysłowa*. Cambridge Stanford Books 2020 (e-book).
- Sobór Watykański II. *Konstytucja duszpasterska o Kościele w świecie współczesnym Gaudium et Spes*. W: *Sobór Watykański II. Konstytucje. Dekrety. Deklaracje*. Poznań 2002.
- Soczyński S.: *Corporate Digital Responsibility w przedsiębiorstwach medialnych*. „Zarządzanie Mediami” 9:2021 nr 4 s. 695-706.

- Sweeney L.: *Information explosion*. W: *Confidentiality, disclosure, and data access: Theory and practical applications for statistical agencies*. Red. L. Zayatz, P. Doyle, J. Theeuwes. North-Holland 2001 s. 43-74.
- Syczewski T.: *Kult świętych oraz obrazów świętych i relikwii w obowiązującym prawodawstwie Kościoła łacińskiego*. „Rocznik Teologii Katolickiej” 7:2009 s. 143-152.
- Tadeusiewicz R.: *Sieci neuronowe*. „Postępy Fizyki” 45 1993 nr 3 s. 215-236.
- Trzęsicki K.: *Co św. Tomasz z Akwinu miałby do powiedzenia o sztucznej inteligencji?*. „Kieleckie Studia Teologiczne” 19:2020 s. 7-25.
- Tsai C.W., Lai C.F., Chao H.C., Vasilakos A.V.: *Big data analytics: a survey*. „Journal of Big data” 2015 nr 2 (1) s. 1-32.
- Turing A.: *Computing Machinery and Intelligence*. „Mind” 59:1950 nr 236 s. 433-460.
- Boeschoten R. van: *Interactive media: image storytelling*. „Journal of Management Development” 30:2011 nr 3 s. 284-296.
- Wang L.: *Preface*. W: *Support vector machines: theory and applications*. Red. L. Wang. Berlin 2005.
- Wójcik W.: *Fenomen polskiej szkoły matematycznej a emigracja matematyków polskich w okresie II wojny światowej*. „Zagadnienia Filozoficzne w Nauce” 2013 nr 53 s. 11-52.
- Zhang C., Yang L.: *Study on artificial intelligence: The state of the art and future prospects*. „Journal of Industrial Information Integration” 2021 nr 23. <<https://doi.org/10.1016/j.jii.2021.100224>>.
- Zhou Z.H.: *Machine learning*. Singapur 2021.
- Zimmewicz K.: *Współczesne koncepcje i metody zarządzania*. Warszawa 2003.

**Streszczenie:** Praca podejmuje rozważania na temat genezy i sposobu działania generatorów sztucznej inteligencji. W szczególności dotyczy modelu Stable Diffusion. Autor pokazuje, jak kolejne kroki milowe w rozwoju sztucznej inteligencji wpłynęły na obecny kształt najpopularniejszego rozwiązania do generowania obrazów religijnych. Wskazuje również na problem generowania obrazów o treści religijnej.

**Słowa kluczowe:** Stable Diffusion, technika uczenia maszynowego, grafika cyfrowa, sztuka cyfrowa, grafika religijna.