

RAPORT POWSTAŁ NA ZLECENIE



ARTIFICIAL INTELLIGENCE

SumUp for Business 2022



Dr Anna Gumkowska, Warner Bros. Discovery

Sebastian Kondracki, Deviniti.com



1. Wprowadzenie	3	5.4 Speech recognition	40
2. Definicje AI	6	5.5 Robotyka	42
3. Krótka historia AI	9	6. Hiper-automatyzacja	44
4. Przegląd technik i algorytmów	14	7. Pułapki AI	46
4.1 Nadzorowane uczenie maszynowe	16	8. Casebook	50
4.2 Nienadzorowane uczenie maszynowe	18	8.1 Reklama internetowa	52
4.3 Uczenie maszynowe ze wzmocnieniem	20	8.2 Zdrowie	62
4.4 Głębokie uczenie	22	8.3 E-commerce	67
GAN – Generative Adversarial Network	25	8.4 Prawo	75
Transformery	26	8.5 Dobro społeczne	80
5. Domeny AI	29	9. Podsumowanie	83
5.1 Data science	31	10. O autorach	86
5.2 NLP	33		
5.3 Computer Vision	37		

S P I S T R E Ś C I

1.

WPROWADZENIE



Celem publikacji jest zebranie wiedzy dotyczącej AI i pokazanie jej praktycznych zastosowań w biznesie.

Według danych Microsoft 2/3 firm w Polsce już wykorzystuje AI¹. Nie zawsze zdajemy sobie nawet z tego sprawę, że w naszej organizacji już kilka zespołów na co dzień pracuje z AI. Nastąpiła cicha rewolucja. Początkowe ogromne oczekiwania i wyobrażenia związane z AI ulegały modyfikacjom. Na pewnych etapach inwestorzy tracili nawet nadzieję, że idee sztucznej inteligencji uda się wcielić w życie. Dzisiaj nie szukamy już jednej inteligencji, która porozmawia z nami o problemach egzystencjalnych przy kawie, za to mamy szereg konkretnych rozwiązań wymagających rozwiązań z zakresu AI, które towarzyszą nam w technologiach codziennego użytku.


Sztuczna inteligencja stała się wszechobecna. Integruje się z wieloma dziedzinami ludzkiego życia: od stawiania diagnoz medycznych, przez marketing, social media, projekty społeczne, odkrywanie leków czy zastosowania w kancelariach prawnych i działach księgowości. AI przekształca naszą rzeczywistość – po cichu, ale systematycznie. To, że mamy w domu rozwiązania GPTs, czyli general-purpose technologies, jak automatyczny odkurzacz, mop czy żelazko rozpoznające materiał i samo dobierające odpowiednio temperaturę, nie dziwi już nikogo. Nieco więcej kontrowersji wzbudza zastosowanie facial recognition, automatyczne tworzenie kontentu czy AI zastosowany w sztuce, gdzie sam generuje obrazy dzięki GAN (Generative Adversarial Network).

¹ <https://przemyslprzyszlosci.gov.pl/microsoft-2-3-duzych-firm-w-polsce-juz-stosuje-ai/>

Ten dokument jest skierowany do osób, które chcą w skrócie zobaczyć najbardziej aktualny „duży obrazek”.

Dotykamy także zagadnień stanowczo obecnych w dyskusjach technologów, ale dopiero „pączkujących” w biznesie, takich jak **Transformery, LLM (ang. Large Language Models, m.in. GPT-3, Cohere, PaLM, Bloom)** i **hiper-automatyzacja**, które w ostatnim czasie całkowicie zrewolucjonizowały AI. Nie ma ambicji wchodzenia w szczegóły technologiczne ani nie wymaga wiedzy programistycznej. Ma za zadanie pomóc rozeznaczyć się w aktualnej sytuacji tak, by wzbudzić uważność, gdzie na co dzień mamy kontakt z AI. Ma także ułatwić zrozumienie, gdzie sami możemy AI zaimplementować z korzyścią dla naszego biznesu. Przede wszystkim jednak ma sprawić, że tematyka AI zostanie odczarowana: oczywiście, to są zaawansowane technologie, trudno wyobrażalne moce obliczeniowe i klastry danych. Natomiast nie jest to czarna magia. Na co dzień spotykamy się ze sztuczną inteligencją, kiedy tylko odpalimy smartfona.

Inspiracją do powstania tego raportu był kurs **Artificial Intelligence Programme for Business na Saïd Business School of Oxford**, a także doświadczenia w firmie Deviniti, która realizuje projekty w duchu strategii hiper-automatyzacji zwłaszcza w obszarze przetwarzania i generowania języka naturalnego ze słynnymi LLM (GPT-3, GPT-NeoX) na czele.



2.

DEFINICJE AI

Zanim dojdziemy do definicji (zwykle definicje są problematyczne, niejednoznaczne i nie są w stanie uchwycić wszystkiego), anegdota z życia znajomego z branży mediów. Jarek, bo to o nim tu mowa, regularnie testuje, czy dzwoniące do niego głosy z różnymi ofertami należą do ludzi czy do botów. Pierwszy etap testu zakłada postawienie pytania: „czy jest pani botem?”. Po ostatnich zmianach w oprogramowaniu odpowiedź brzmi: „nie, tylko tak dzwonię od rana po ludziach, to mój głos tak brzmi. Pewnie do pana też tak różne osoby dzwonią. Botem nie jestem, na dowód mogę powiedzieć, że mój rozmiar buta to 38”. Jarek nie daje jednak za wygraną: „a w jakim kolorze nosi Pani kapelusz?” Tutaj system się zawiesza. Bot nie ma przygotowanego scenariusza na tak skomplikowane pytania. Zapada długotrwała cisza. Jarek już wie, że dzwonił do niego automat oparty o algorytmy.

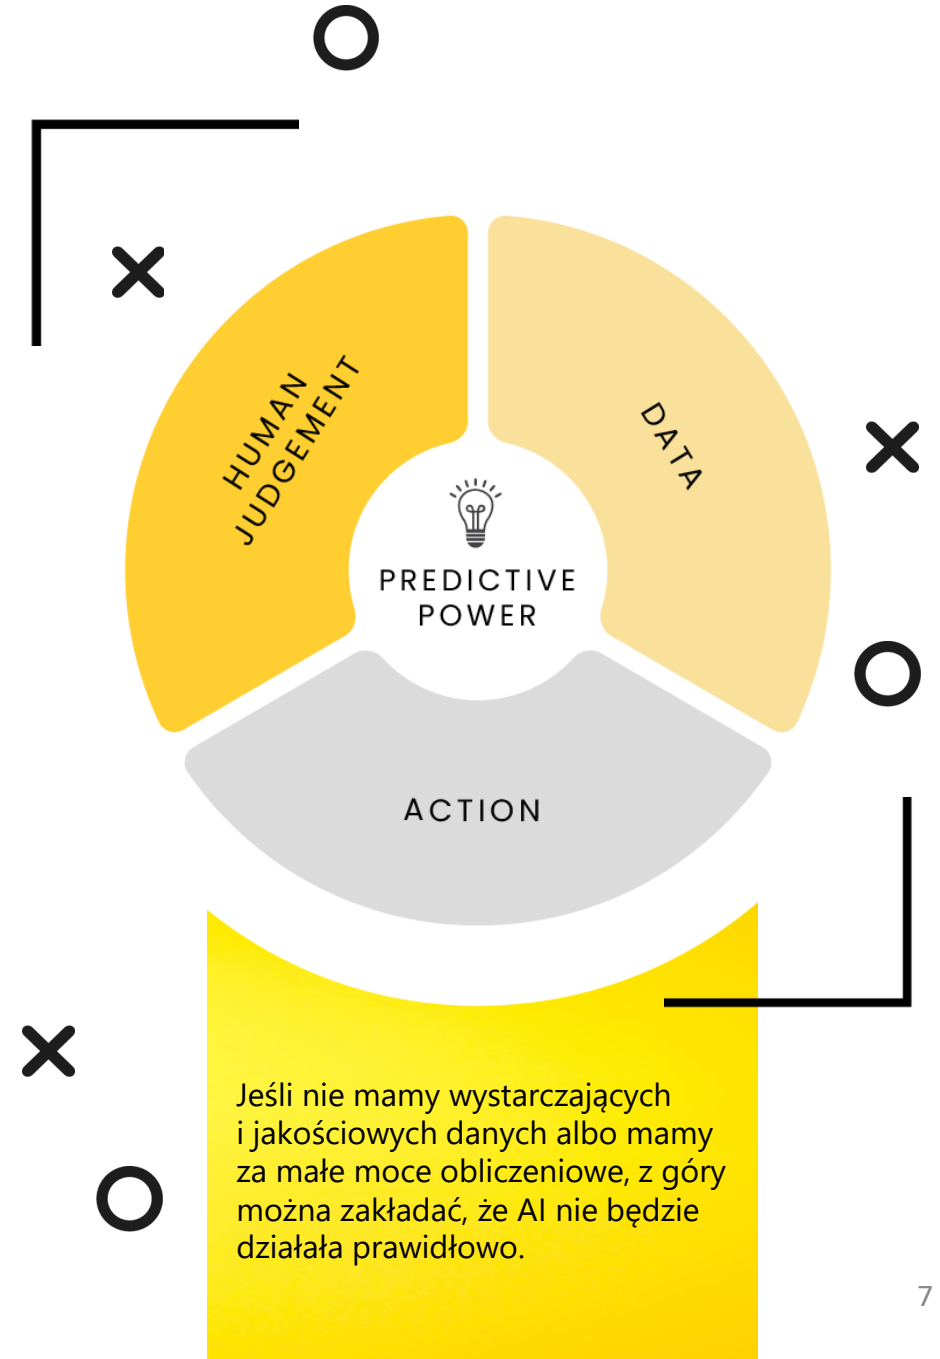
”

Wróćmy zatem do pytania, czym jest AI. Istotą sztucznej inteligencji jest zdolność maszyn do interpretowania danych i uczenia się na ich podstawie po to, by móc lepiej przygotować różnego typu predykcje. Warto podkreślić, że algorytmy uczą się w dużej mierze same: analizują zebrane dane, wyciągają wnioski, testują opcje i rekomendują te optymalne. Z jednej strony algorytmy są jak gotowy przepis napisany po to, by osiągnąć określone cele. Z drugiej strony same uczą się, rozwijają, ewoluują właśnie po to, by ten cel osiągnąć jak najlepiej. **Sztuczna inteligencja ma nam przede wszystkim pomóc w:**

- podejmowaniu decyzji,
- przygotowywaniu predykcji,
- automatyzacji tam, gdzie jest to możliwe, sensowne i ma uzasadnienie biznesowe.

Czego potrzebujemy, by działania AI były optymalne:

- Danych ustrukturyzowanych albo nieustrukturyzowanych – jakość danych, na których bazuje algorytm, jest ogromnie ważna. Obowiązuje tu prosta zasada: shit in, shit out.
- Big data i mocy obliczeniowej. Złożoność obliczeniowa często rośnie wykładniczo. Im więcej zmiennych masz w swojej analizie, tym więcej danych potrzebujesz, aby wyciągnąć prawidłowe wnioski.



Jeśli nie mamy wystarczających i jakościowych danych albo mamy za małe moce obliczeniowe, z góry można zakładać, że AI nie będzie działała prawidłowo.


Czy da się rozwiązać każde zadanie czy problem dzięki AI?

Nie.

Istnieje grupa problemów nazywanych NP-trudnymi, których rozwiązanie w akceptowalnym czasie jest niemożliwe. Algorytm musi przeglądać wszystkie możliwe warianty, a ich liczba jest ogromna. To, że dziś AI nie potrafi sobie z niektórymi poradzić, nie oznacza, że za dziesięć lat będzie to wciąż niemożliwe. Gra w Go uważana była za jeden z najtrudniejszych problemów strategicznych i choć oficjalnie nie jest zaliczana do problemów NP-trudnych, to wielu ekspertów uważało, że AI długo sobie z nią nie poradzi. Jednak w 2016 roku program AlphaGo, stworzony przez OpenAI, pokonał jednego z najlepszych na świecie graczy w grze Go, co było ważnym krokiem w rozwoju AI i pokazało, że modele AI są w stanie pokonać nawet najlepszych ludzkich graczy w trudnych grach strategicznych.

Jeśli chodzi o definicję, przyjmuje się, że AI jest terminem najszerszym, które obejmuje takie kategorie, jak: machine learning (uczenie maszynowe), supervised learning (nadzorowane uczenie maszynowe), unsupervised learning (nienadzorowane uczenie maszynowe), reinforcement learning (uczenie maszynowe ze wzmocnieniem), a także deep learning (głębokie uczenie). Wzajemny układ elementów ilustruje wykres.

Wzajemny układ elementów ilustruje wykres poniżej.




Dla osób głębiej wchodzących w temat AI, z czasem staje się coraz bardziej oczywiste, że nie istnieje jedna, wszechogarniająca definicja sztucznej inteligencji, ale raczej szeroki zakres definicji, które próbują uchwycić, co tak naprawdę ten termin oznacza. Im hasło AI staje się popularniejsze i marketingowo chwytliwe, tym więcej można odkryć sposobów jego użycia. Sensownych i bezsensownych. Nie dziwny się zatem, kiedy hasło AI bywa używane w przypadku, gdy żadnej sztucznej inteligencji (czyli w praktyce uczących się samodzielnie algorytmów) tam nie ma.

A futuristic robot head is shown in grayscale on the left side of the image. The robot has a metallic, reflective surface and a human-like face. A large, semi-transparent yellow rectangle is overlaid on the right side of the robot's face. In the center of this yellow rectangle is a white square containing the number '3.' in a bold, black, sans-serif font. The background is a blurred, grayscale image of a complex, geometric structure, possibly a DNA double helix or a futuristic architectural design.

3.

KRÓTKA HISTORIA AI



Samo pojęcie AI wydaje się brzmieć dosyć nowocześnie.

Natomiast jest to idea rozwijająca się **już 80 lat**. Za początek AI uważa się **rok 1942** roku, kiedy **Isaac Asimov**, autor książek science fiction, ogłosił trzy prawa robotyki. W tamtych czasach AI kojarzyło się przede wszystkim z humanoidalnymi robotami, które będą towarzyszyć nam w życiu i prowadzić z nami dyskusje filozoficzne. Żeby ochronić nas przed możliwymi konsekwencjami zaistnienia nowej świadomości, **Asimov od razu ustalił jasne zasady:**

1. Robot **nie może skrzywdzić** istoty ludzkiej lub – poprzez wstrzymanie się od działania – pozwolić, by stała jej się krzywda.
2. Robot **musi wykonywać rozkazy** wydawane mu przez istoty ludzkie, z wyjątkiem sytuacji, kiedy byłyby one sprzeczne z Prawem Pierwszym.
3. Robot **musi chronić swoje istnienie** dopóty, dopóki taka ochrona nie jest sprzeczna z Prawem Pierwszym lub Drugim.

Z kolei w **1950** roku opublikowano **Test Alana Turinga**. Ten matematyk był zainteresowany zagadnieniem, jak sprawdzić, czy AI działa prawidłowo. Uznał, że jeśli rozmówca kierujący się tylko głosem nie rozpozna, czy ma do czynienia z człowiekiem czy maszyną, możemy mówić o prawdziwej sztucznej inteligencji. Zrównał zatem zdolności komunikacyjne, związane z mową i porozumiewaniem się za istotę AI. Dodajmy, że w tych czasach to były dyskusje stricte filozoficzne i tworzenie science fiction, żadnego AI w praktyce jeszcze nie było. **Koncepty rodziły się w głowach uczonych i pisarzy**, w większości przypadków mężczyzn w mocno średnim wieku.

Lata 1956–1973 uznaje się za złotą epokę AI. Świat naukowy zaczyna otrzymywać dotacje na realizację pierwszych projektów mających urzeczywistnić idee z poprzedniego okresu. W Dartmouth odbywają się pierwsze letnie naukowe warsztaty poświęcone AI. Miało to być wydarzeniem założycielskim sztucznej inteligencji jako dziedziny naukowej. Projekt trwał około sześciu do ośmiu tygodni i był zasadniczo rozszerzoną sesją burzy mózgów. **W 1968 powstał SHRDLU**, czyli system komputerowy służący do przetwarzania języka naturalnego, napisany w ramach doktoratu przez **Terry'ego Winograda** na Massachusetts Institute of Technology.

Co potrafił SHRDLU? Był to pierwszy AI, który wykonywał konkretne zadanie. Dzięki zainstalowanemu ramieniu układał klocki oraz odpowiadał na zadawane pytania na specjalnym monitorze. Po wydaniu komendy „podnieś czerwony klocek”, SHRDLU musiał znaleźć do niego drogę, podnieść go i dopiero wtedy potwierdzał na ekranie „ok”.

1969 to rok premiery robota Shakey, a w latach 70-tych powstały **MYCIN i Prolog**. Celem systemu Mycin było zdiagnozowanie bakteryjnej choroby krwi i zaproponowanie terapii. MYCIN miał wprowadzony zestaw reguł i bazę danych utworzoną przez konsylium lekarskie. Prolog z kolei to jeden z najpopularniejszych języków programowania logicznego, do automatycznej analizy języków naturalnych jako język ogólnego zastosowania.

Po okresie optymizmu i wiary w sukces AI nastąpiło załamanie. **Lata 1973–1980 określa się jako AI Winter**. Inwestorzy zwątpili we włożone w sztuczną inteligencję pieniądze i zwrot z inwestycji. „Artificial Intelligence: A General Survey”, powszechnie znany jako **raport Lighthilla**, został opublikowany w czasopiśmie Artificial Intelligence w 1973 roku. Oceniał stan badań w dziedzinie AI. Raport podał bardzo pesymistyczne prognozy, stwierdzając, że „w żadnej części tej dziedziny odkrycia dokonane do tej pory nie wywarły większego wpływu, jaki obiecywano”. Kolejny znaczący cios przyszedł w 1980 rok. **Zadał go filozof John Searl**. W historii zostanie zapamiętany jako **Argument Chińskiego Pokoju** (Chinese Room Argument). Searl udowadniał, że nawet jeśli komputer wydaje się, że posiada rozum, nie znaczy to, że ma rozum. Wykonywanie określonych zadań nie musi opierać się na rozumieniu ich przez wykonawcę. Przez 7 kolejnych lat w branży AI wiało chłodem.



Na szczęście w 1980 nastąpiła „Nowa Era AI” i nadzieja wróciła do branży. To czas projektów między innymi **CYC** (1984), **Nouvelle AI** (1985) czy **Deep Blue** (1997). Wyjaśniając po kolei: CYC (od ang. 'encyclopedia') został założony i prowadzony przez Douglasa Lenata. Składał się z bazy wiedzy zawierającej ręcznie zakodowane „zdroworozsądkowe” fakty oraz silnik wnioskowania, który pozwalał wydedukować dalsze fakty. Funkcjonuje do tej pory jako AI w wersji komercyjnej i oczywiście po kolejnych upgrade'ach. Natomiast Nouvelle (AI) to podejście do sztucznej inteligencji zapoczątkowane przez **Rodneya Brooksa**, który wówczas pracował w laboratorium sztucznej inteligencji MIT.

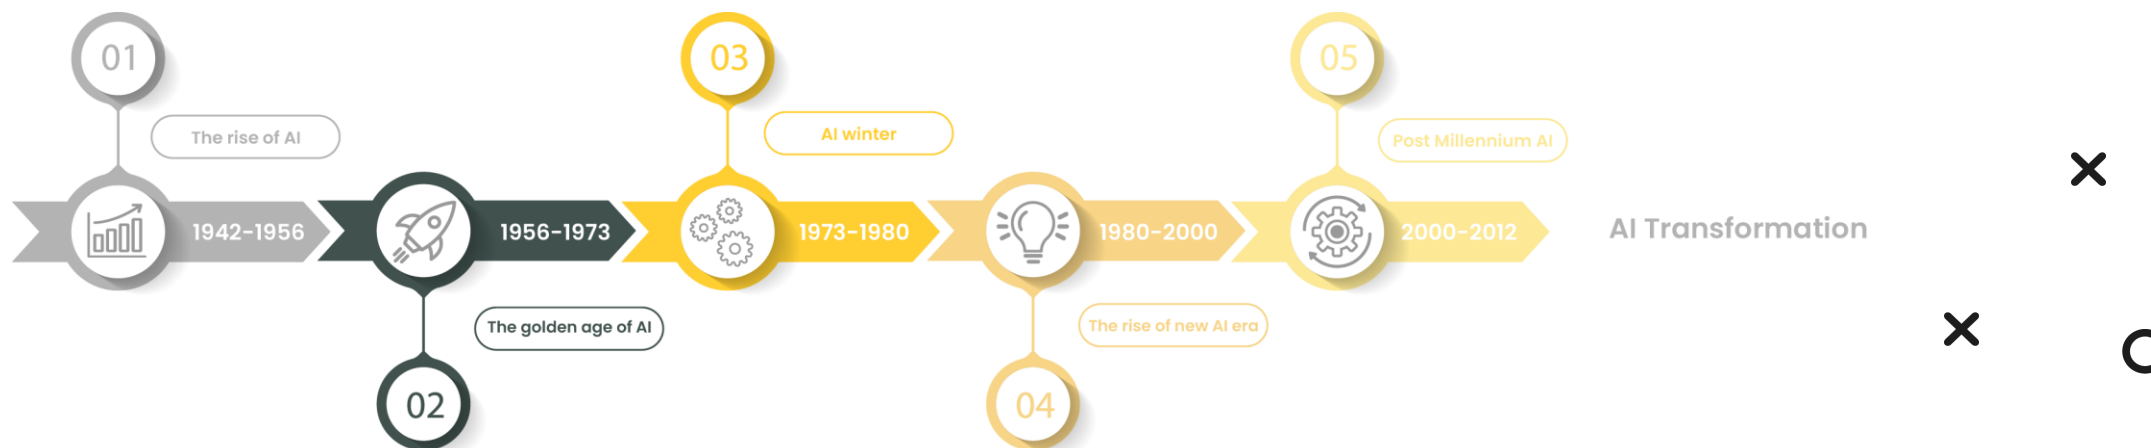
Co różniło Nouvelle AI od innych podejść? Celem tego projektu było stworzenie robotów o poziomie inteligencji podobnym do owadów. Uważano, że inteligencja może wyłonić się organicznie z prostych zachowań, gdy wchodzi w interakcję z „**rzeczywistym światem**”. To dosyć rewolucyjne podejście, ponieważ dotąd AI uczyły się na sztucznie 'skonstruowanych, symbolicznych światach' a nie w świecie rzeczywistym. Niezwykle ciekawym projektem był **Deep Blue**. Tak, to AI wygrało mecz szachów z mistrzem Kasparowem. To także spełnione marzenie firmy IBM o stworzeniu superkomputera. Zwycięstwo Deep Blue zostało uznane za kamień milowy w historii sztucznej inteligencji i było tematem kilku książek i filmów.



Kolejnym etapem rozwoju AI był okres nazywany jako **Post-Millennium AI**, trwający w latach 2000–2012. Sztuczna Inteligencja zaczęła znajdować praktyczne i bardziej opłacalne biznesowo rozwiązania. W 2002 roku powstał **odkurzacz Roomba**, projekty wojskowe, jak pomagający nosić żołnierzom ciężary robot **Big Dog**, natomiast w 2010 roku pojawiła się **Siri** jako asystent głosowy. **Rok później świat poznał Watsona**, czyli sztuczną inteligencję z firmy IBM. Potentat obiecywał, że ich produkt przekształci branżę i będzie generować przychód dla firm. Watson został początkowo opracowany tak, aby odpowiadać na pytania w znanym amerykańskim teleturnieju „Jeopardy!”. Zdobyl nawet nagrodę za pierwsze miejsce w wysokości 1 miliona dolarów, po zwycięstwie nad ludzkimi rywalami. Następnie IBM ogłosił, że system będzie dalej rozwijany w kierunku branży medycznej jako pomoc w **stawianiu diagnoz**. System był używany jako wsparcie np. w leczeniu raka płuc w Memorial Sloan Kettering Cancer Center w Nowym Jorku.

Lata 2000–2012 to też okres, w którym ruszyło **laboratorium badawcze DeepMind** pracujące głównie nad sieciami neuronowymi ANN (Artificial Neural Network). DeepMind uczyło się grać w gry wideo i trafiło na pierwsze strony gazet w 2016 roku po tym, jak jego program AlphaGo pokonał profesjonalnego gracza **Lee Sedola**, mistrza świata w grze w „Go”. Ogólniejszy program, AlphaZero, pokonał najpotężniejsze programy grające w szachy i shogi (japońskie szachy) po kilku dniach gry przeciwko sobie. Sukcesem skomplikowanych prac było finalnie stworzenie komputera naśladowującego pamięć krótkotrwałą ludzkiego mózgu. DeepMind został przejęty przez Google w 2014 roku i rozwija się dalej. W 2020 roku DeepMind poczynił znaczne postępy w problemie fałdowania białek dzięki AlphaFold, a w bazie danych zostało opublikowanych ponad 200 milionów przewidywanych struktur, reprezentujących praktycznie wszystkie znane białka. W 2022 roku DeepMind ogłosił, że rozwija język wizualny (VLM) o nazwie **Flamingo** oraz opracowuje **DeepNash**, czyli wieloagentowy system uczenia się bez modelowania.

W jakiej epoce AI dzisiaj żyjemy po 2012 roku? Nauka nie podaje jeszcze nazwy. Postulujemy nazwę „AI transformation” albo „quiet explosion”. Dodajmy, praktycznie w każdej branży i dziedzinie życia. Prawo Amary mówi, że ludzie mają tendencję do przeceniania wpływu technologii na krótką metę, ale nie doceniają jej na dłuższą metę. My już na tej dłuższej mecie jako społeczeństwo jesteśmy.





4.

PRZEGLĄD TECHNIKI
ALGORYTMÓW

Filarem sztucznej inteligencji, jak już wiemy, jest **uczenie maszynowe** (choć nie jedynym, ale bardzo znaczącym). Uczenie maszynowe (ang. machine learning, ML) to grupa algorytmów, które pozwalają komputerom uczyć się na podstawie danych i poprawiać swoją dokładność w czasie. Jak już wiemy z rozdziału „Definicje AI” machine learning możemy podzielić na następujące rodzaje:

- **nadzorowane** (ang. supervised learning),
- **nienadzorowane** (ang. unsupervised learning),
- **ze wzmocnieniem** (ang. reinforcement learning),
- **uczenie głębokie** (ang. deep learning).

Poszczególne typy zostaną szczegółowo opisane poniżej, jednak na uwagę zasługuje przede wszystkim **deep learning**. Pomimo tego, że jest podtypem uczenia maszynowego, ze względu na swoją szczególną efektywność „opuścił” rodzinne gniazdo uczenia maszynowego i „wyrabia” sobie własną drogę życiową i nazwisko. Warto dodać, że przy ogromnym zapotrzebowaniu na niezbędną ilość danych do uczenia. Ta ekspansja i samodzielność deep learningu spowodowała pewną nieścisłość definicyjną, tzn. **uczenie maszynowe** utożsamiane jest z uczeniem nadzorowanym i nienadzorowanym, natomiast **uczenie głębokie** traktowane jest osobno (mimo, że jest podtypem/dzieckiem uczenia maszynowego). Nie przeszkadza to rozwojowi zarówno klasycznym metodom uczenia maszynowego, jak i głębokiemu uczeniu.



4.1

NADZOROWANE UCZENIE MASZYNOWE

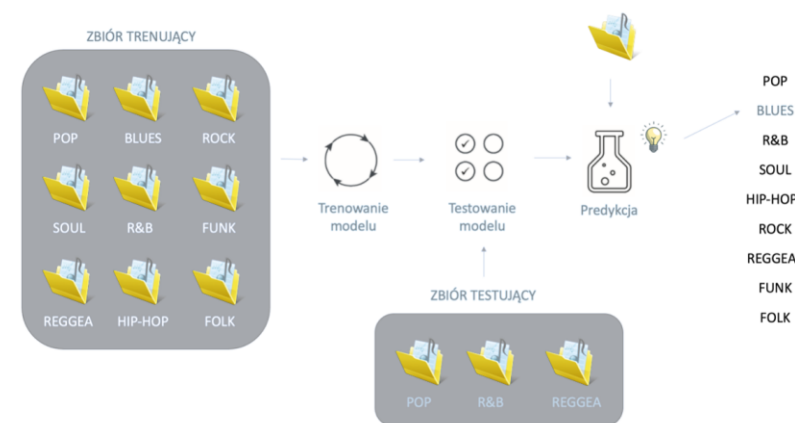
Uczenie takie polega na wskazaniu algorytmowi ciągu danych, np. cech danego obiektu wraz z klasą obiektu lub wartością liczbową (np. ceną). **Im więcej takich danych, tym lepiej.** Po procesie uczenia wystarczy podać zestaw cech bez klasy obiektu lub wartości liczbowej, a algorytm sam wybierze kategorię (klasę) obiektu lub jego wartość. Przewidywanie kategorii klasy nazywamy **klasyfikacją**, a szacowanie wartości – **regresją**.

Spróbujmy to jeszcze lepiej zobrazować na bardzo sugestywnym przykładzie. Zaczniemy od klasyfikacji. Wyobraźmy sobie, że chcemy nauczyć dziecko (a może już nastolatka) rozróżniać style muzyczne. Dziecko/nastolatek jest więc naszym modelem AI, który chcemy odpowiednio wytrenować. Dane wejściowe to zbiór utworów muzycznych przypisanych do jednej kategorii (klasy), np. ROCK, POP, BLUES itd. Czyli obiekty to utwory muzyczne, klasy/kategorie to style muzyczne. Jak wiadomo, każdy obiekt (tj. utwór muzyczny) posiada atrybuty (cechy), np. długość w sekundach, skład zespołu wraz z rodzajami instrumentów, tempo, tekst itp. W zbiorze danych (dataset) mamy ponad 25 000 piosenek ze wszystkimi atrybutami i stylem muzycznym (czyli klasą). Ponieważ klasa jest pewną etykietą danego obiektu, taki zbiór danych jest często określany jako etykietowany (labeled dataset). Niestety, uczenie nadzorowane wymaga etykietowanych zbiorów danych, czyli obiektów opisanych przez atrybuty z przypisanymi klasami. Teraz dzielimy nasz zbiór danych na dane treningowe i testowe, np. 80% danych (20 000 ścieżek) posłuży nam do trenowania modelu, a 20% (5 000 ścieżek) do testowania modelu. Drukujemy więc nasz zestaw danych i wręczamy go dziecku do nauczania. Czyta ono ścieżkę po ścieżce i analizuje, robiąc sobie notatki. Szuka wzorców w danych, np. piosenki PUNK są bardzo krótkie, często występują w nich małe składy i rzadko natomiast instrumenty elektroniczne, tempo jest szybkie, a w tekstach często występuje fraza NO FUTURE. Z kolei w DISCO POLO brakuje gitar i perkusji, a syntezatory są często obecne. Słowa piosenek są zawsze po polsku i jest w nich dużo frywolnych zwrotów wraz z częstymi rymami. Po dwóch miesiącach nasze dziecko ukończyło trening, ma sto stron notatek i wyszukało wiele wzorców. Nadszedł czas na przetestowanie modelu.

Dajemy więc zestaw testowy (5 tys. piosenek), ukrywamy styl muzyczny, a nasze dziecko musi przewidzieć odpowiedni styl muzyczny na podstawie notatek i wzorców. Utwór po utworze z zestawów testowych. Gdy skończy, sprawdzimy i obliczymy dokładność modelu według wzoru:

$$\text{dokładność} = \frac{\text{liczba poprawnych predykcji}}{\text{liczba utworów w zbiorze testowym}}$$

Co jeśli dokładność jest niezadowalająca? Po pierwsze, może za mało danych? Po drugie może dane są słabej jakości? Po trzecie może hmmm... coś jest nie tak z dzieckiem. Ponieważ nasz model przypisywał obiekt do stylu czyli danej kategorycznej (kategorii) to możemy nazwać go klasyfikatorem (zgadywanie kategorii/klasy w naszym przypadku stylu muzycznego).



Uczenie nadzorowane na przykładzie rozpoznawania stylu muzyki


Do czego możemy wykorzystać takie uczenie nadzorowane? Do identyfikacji spamu, analizy emocji, rozpoznania języka, określania ryzyka kredytowego, kategoryzacji dokumentów, określenia wartości mieszkania, samochodu (automatyczna wycena), oszacowania czy klient kupi dany produkt czy nie itp.

4.2

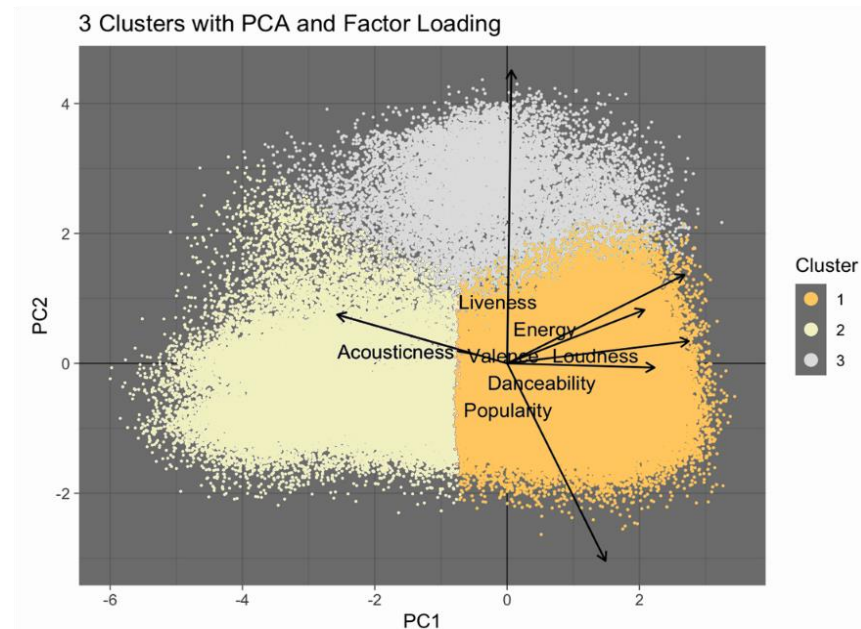
NIENADZOROWANE UCZENIE MASZYNOWE

W przypadku uczenia bez nadzoru, w tzw. **danych treningowych**, mamy tylko cechy obiektów. Możemy więc jedynie „uporządkować” dane, podzielić je na grupy podobnych obiektów (klasteryzacja, analiza skupień – **clustering**) lub zmniejszyć ich wymiary (redukcja wymiarów, dimension reduction), czyli dokonać selekcji cech pod kątem dalszego uczenia maszynowego, łatwiejszej wizualizacji lub zmniejszenia wykorzystania zasobów komputera (np. pamięci RAM).

Jak w praktyce wygląda na przykład analiza skupień (clustering)? Znowu wróćmy do naszego przykładu muzycznego i naszego nastoletniego geniusza. Otóż teraz wyobraźmy sobie, że utwory muzyczne posiadają opisy/cechy tj. np. długość w sekundach, skład zespołu wraz z rodzajami instrumentów, tempo, tekst, ale nic nie wiemy o stylu muzycznym. Dlatego niech nasz dzieciak przejrzy wszystko i podzieli na X grup (np. dziesięć) składających się z podobnych utworów. Nie pokazaliśmy mu przykładowych grup, nie powiedzieliśmy na czym polega dokładnie podobieństwo, po prostu uczenie bez nadzoru – kombinuj. No i mały geniusz biedny siedzi i próbuje, a może oddzielną grupę zrobię utwory szybkie z wokalistką śpiewającą po polsku. Hmm... słabo tylko 20 utworów, a w innych grupach po tysiące. Zatem może inaczej i grupowanie zaczyna się od początku, tak długo, aż wynik będzie zadowalający.



Uczenie nienadzorowane na przykładzie klasteryzacji utworów muzycznych



Klastrowanie utworów muzycznych z Spotify (algorytm K-Means i PCA, uczenie nienadzorowane)

Źródło: <https://www.rpubs.com/ajibudiarto/spotify> [dostęp: 25.08.2022]

Zapewne u wielu niedowiarków zaczyna pojawiać się pytanie, a po co nam grupy (skupiska) utworów muzycznych, zwierząt, ludzi, klientów, skoro są nienazwane? Jednak czy wszystko musimy nazywać? Wyobraźmy sobie, że do algorytmu przekazujemy np. zachowania zakupowe określonych użytkowników, np. informacje o tym, jakie produkty kupują, a jakie tylko przeglądają. Algorytm automatycznie dzieli użytkowników na podaną liczbę grup na podstawie ich podobieństwa. Pamiętajmy, że np. podobni klienci zachowują się podobnie, mają podobne potrzeby zatem czy potrzebujemy ich nazwać czy wystarczy prostą statystyką wyciągnąć z grupy najczęściej kupowane produkty i zarekomendować reszcie grupy. **Dzięki klastrowaniu/grupowaniu można bardzo szybko stworzyć spersonalizowane biuletyny, rankingi i wygląd strony głównej bez potrzeby nazywania danej grupy.**

4.3

UCZENIE MASZYNOWE ZE WZMOCNIENIEM

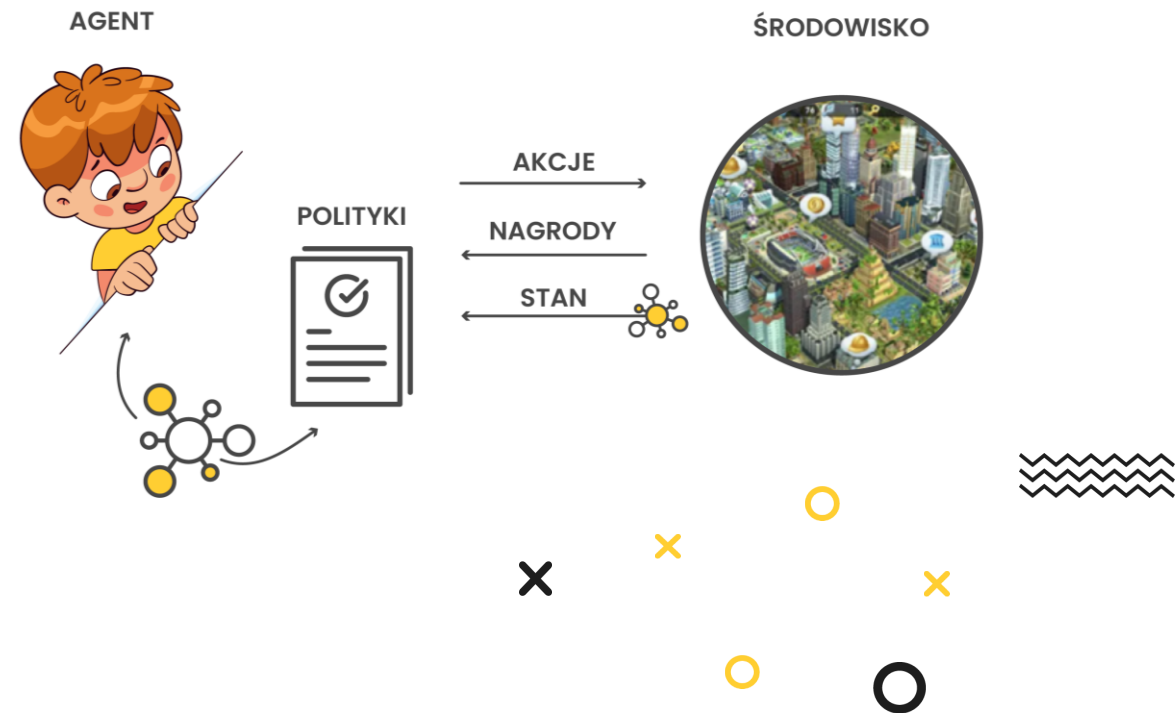
Reinforcement Learning (RL) znalazło zastosowanie głównie w przemyśle (robotyka), motoryzacji (samochody autonomiczne), domach maklerskich oraz w tzw. **GameDev** (branża gier komputerowych), czyli wszędzie tam, gdzie uczenie decyzyjne odbywa się metodą prób i błędów. No i przede wszystkim, między innymi, również w ChatGTP.

Jest to jeden z najmniej popularnych typów uczenia maszynowego, a jego działanie najbardziej różni się od standardowych algorytmów z rodziny maszynowych procesów uczenia. Po pierwsze, brakuje w nim danych treningowych. Pojawiają się tu jednak nowe terminy tj. środowisko (environment), z którego algorytm może automatycznie zbierać dane. Dane te są przekazywane do bufora i służą do trenowania agentów. Głównym celem agenta jest nauczenie się jak najlepiej współdziałać ze środowiskiem.

Może uda nam się też wyjaśnić tę zasadę na przykładzie dziecka i gry komputerowej. Wyobraźmy sobie więc, że kupiliśmy prostą grę strategiczną, w której budujemy i rozwijamy miasta. Oczywiście mogliśmy dokładnie przeczytać instrukcję, ale może jednak metodą prób i błędów nauczymy się zasad gry. Nasze dziecko będzie więc, zgodnie z nomenklaturą RL – agentem, podczas gdy gra – środowiskiem. W początkowej fazie zbierania danych nasz agent rozegra kilka tur w grze, bardzo często opartych na losowych działaniach. Tu coś zbuduje lub zburzy, tam podniesie podatki. Jeśli w danej akcji otrzyma nagrodę (przybędzie punktów lub trochę monet), to skrupulatnie odnotowuje to w notatkach (tzw. polityka) wraz ze stanem środowiska (gry). Oczywiście tych tur (rozgrywek) nasz agent musi trochę pograć, dodatkowo czasem musi dobrze przeanalizować ściągę (politykę), czy np. nie warto pominąć kilku małych nagród, aby zebrać jedną i porządną (akcje długoterminowe). W praktyce więc do tych procesów uczenia się (analizy obserwacji) czy sposobów kolekcjonowania danych, stosuje się inne algorytmy ML (np. sieci neuronowe).



Uczenie maszynowe ze wzmocnieniem na przykładzie odkrywania zasad gry strategicznej






4.4

**GŁĘBOKIE
UCZENIE**

Deep learning (głębokie uczenie) to podtyp uczenia maszynowego, który jest intensywnie rozwijany. Trzeba przyznać, z bardzo dobrymi wynikami. W tym rodzaju uczenia można dostrzec istotne podobieństwa do tradycyjnych metod uczenia maszynowego, np. w obszarze wysokopoziomowych zasad działania (takich jak proces szkolenia/uczenia). Istnieją jednak również istotne różnice, takie jak wymóg dużych zbiorów danych i długi czas uczenia bez konieczności ręcznej ekstrakcji cech.

Nazwa grupy algorytmów, czyli głębokie uczenie (deep learning), pochodzi od wykorzystania struktur **sztucznych sieci neuronowych**, które mogą składać się z wielu warstw (wejściowej, ukrytej i wyjściowej), przez co proces uczenia sprawia charakter bardzo głębokiego. Należy wspomnieć, że nie każde użycie sieci neuronowej jest już głębokim uczeniem, a wszystko zależy od liczby zastosowanych warstw. Tak więc, pomimo funkcjonalnego podobieństwa do nadzorowanego lub nienadzorowanego (klasycznego) uczenia maszynowego, podstawowa różnica polega na tym, że deep learning musi wykorzystywać sieci neuronowe z odpowiednią liczbą warstw (min. 3).




Prosta sieć neuronowa vs algorytm głębokiego uczenia. Liczba warstw ma znaczenie

Źródło: <https://www.pnas.org/doi/10.1073/pnas.1821594116>
[dostęp: 25.08.2022]

Co zatem zapewnia zastosowanie „potężniejszych” algorytmów wzorowanych na ludzkim układzie nerwowym?

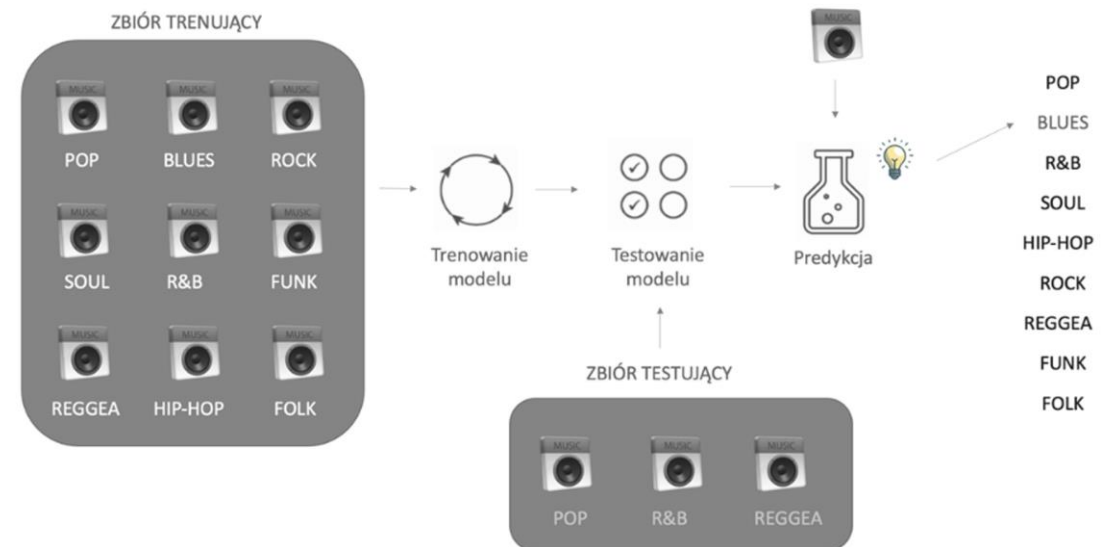
Na przykład wspomniany brak ręcznej ekstrakcji cech czy lepszą dokładność predykcji. Dziecięcy przykład? Czemu nie.

Wróćmy jeszcze raz do naszego muzycznego przypadku i nadzorowanego (klasycznego) uczenia. Na wejściu nasz geniusz miał piosenki „opisane” za pomocą cech np. instrumentarium, tekst, długość piosenki, tempo, czyli ktoś (i nie był to algorytm ML tylko fizyczna osoba) musiał nie tylko przypisać style do piosenek, ale również określić te cechy. Natomiast w deep learningu mamy o wiele **więcej możliwości**. Więc czy nie wystarczy po prostu zagrać daną piosenkę i pozwolić naszemu dziecku posłuchać, aby dowiedziało się jak piosenka brzmi w aranżacji na dwie gitary, bas, perkusję? Z drugiej strony, jak brzmią piosenki dodatkowo na przykład z sekcją dętą? Po **19 234** przesłuchaniu na pewno nauczy się rozpoznawać pewne wzorce w brzmieniu utworu.



W przypadku głębokiego uczenia najczęściej algorytmy samodzielnie radzą sobie z ekstrakcją cech

Zatem automatyczna ekstrakcja cech w przypadku deep learningu jest już obecna, więc najczęściej jako dane wejściowe dla algorytmów mamy obrazy, dźwięk, wideo, długie teksty itp. Natomiast sam proces **wysokopoziomowo** przypomina klasyczne uczenie maszynowe. Przykładowo, proces klasyfikacji naszych utworów wygląda tak samo, tylko na wejściu nie są to np. pliki tekstowe z opisem piosenki, a sama piosenka.



Głębokie uczenie (przykładowy proces klasyfikacji) na przykładzie rozpoznawania stylu muzyki

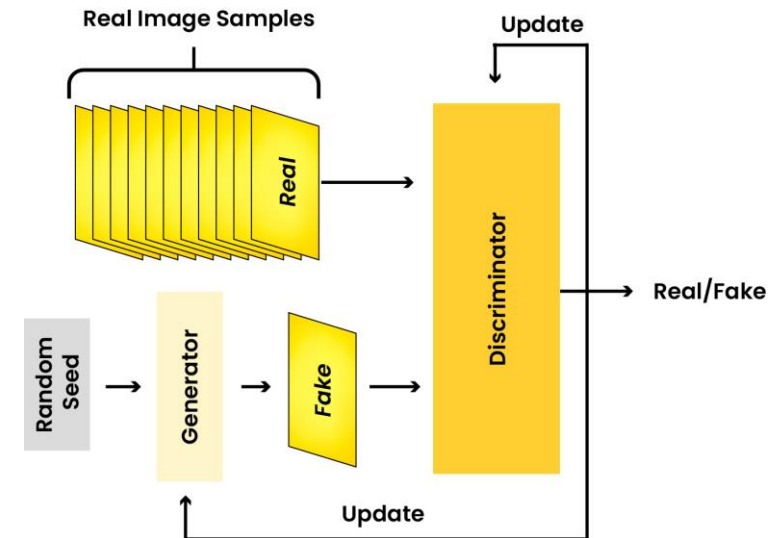
Zanim jednak wywnioskujemy, że klasyczne algorytmy uczenia nadzorowanego niewiele różnią się od deep learningu, przyjrzyjmy się pojęciu tzw. architektury. Wiemy, że aby model należał do rodziny głębokiego uczenia, **musi zawierać sieć neuronową** z co najmniej trzema warstwami. Co nam jednak szkodzi użyć nie tylko zestawu większej ilości warstw, ale także kilku różnych sieci? Albo np. obok sieci neuronowej użyć innego bytu jak algorytmu, naśladującego proces poznawczy organizmu ludzkiego?

GAN – Generative Adversarial Network

Rozwój Internetu oraz wyposażenie każdego telefonu w wysokiej jakości aparat fotograficzny lub kamerę spowodował, że społeczeństwo masowo kręci filmy, robi zdjęcia sobie, rodzinie, znajomym. Nawet jedzenie i paragony stały się ulubionym tematem zdjęć. **Już w 2013 roku użytkownicy zamieszczali w sieci 500 milionów zdjęć dziennie.** Aż się prosiło, by zacząć przetwarzać te obrazy algorytmami uczenia głębokiego. Segregacja (klasyfikacja), wykrywanie emocji (np. uśmiechów) czy znajomych twarzy, wyszukiwanie wizualne (np. powiedz mi algorytmem, co ma na sobie celebryta) to problemy, z którymi szybko poradziło sobie głębokie uczenie za pomocą np. konwolucyjnych sieci neuronowych. Użytkownicy chcieli jednak czegoś więcej, np. jak będę wyglądał za 30 lat albo umieszczenia zdjęcia danej osoby we fragmencie przebojowego filmu. Z drugiej strony naukowcy mieli dostęp do ogromnych zasobów zdjęć, na bazie których można było nauczyć modele, które nie tylko świetnie radzą sobie z klasyfikacją czy identyfikacją obiektów, ale są też kreatywne i wygenerują ze zdjęcia co tylko chcemy.

W 2014 roku, podczas świętowania doktoratu w montrealским barze, grupa przyjaciół poprosiła naukowca **Iana Goodfellow'a** o dyskusję problemu braku wyobraźni w algorytmach AI. **Goodfellow**, przy kuflu piwa, zaproponował prostą koncepcję połączenia dwóch sieci neuronowych, które konkurują ze sobą (w formie gry), tzn. jedna z nich – kreator generuje np. fotorealistyczne obrazy, a druga – dyskryminator próbuje rozpoznać, czy obraz wygląda już prawdziwie, czy dalej „zalatuje” sztucznością. Oba modele poprawiają swoje umiejętności podczas procesu uczenia się. Generator generuje coraz lepsze obrazki, a dyskryminator coraz lepiej rozróżnia obrazy fałszywe od prawdziwych. Podobno większość uczestników była sceptyczna, ale Ian nie poddał się i z dnia na dzień wdrożył rozwiązanie, nazywając je **generatywnymi sieciami współzawodniczącymi (GAN)**.


Dzięki GAN-om **Ian Goodfellow** stał się legendą AI i trafił do pracy w Google (obecnie pracuje w Apple). Z kolei sieci generatywne z jednej strony stały się „silnikiem” imponujących aplikacji generujących np. twarze nieistniejących osób, wygląd ludzi w przyszłości czy obrazy w danym stylu malarskim itp. To nie koniec zastosowań sieci współzawodniczących, gdyż znalazły one swoje miejsce np. w medycynie. Dzięki nim można np. realistycznie „rozmnożyć” zdjęcie rentgenowskie i na nich trenować/testować inne algorytmy, np. do diagnozowania chorób.



Architektura GAN

Źródło: https://semiengineering.com/knowledge_centers/artificial-intelligence/neural-networks/generative-adversarial-network-gan/ [dostęp: 25.08.2022]

Istnieje jednak ciemna strona architektury GAN przy generowaniu takich fotorealistycznych, a jednocześnie nieistniejących obrazów tj. deep fake. Nie trzeba nikomu tłumaczyć, że np. kompromitujące, a jednocześnie fałszywe wideo może zmienić wynik wyborów, pozbawić kogoś pracy lub niesłusznie oskarżyć.




Transformery

Większość informacji i wiedzy przechowywana jest w tekstach (książki, strony internetowe). Dodatkowo coraz więcej tekstów powstaje każdego dnia podczas komunikacji interpersonalnej (maile, SMS-y, czaty). Potrzebujemy coraz wydajniejszych algorytmów/modeli do przetwarzania i generowania języka naturalnego. Jak wiemy tekst składa się ze zdań, a te zdania składają się ze słów o odpowiedniej kolejności, które często mają znaczenie (sekwencje). No i tu zaczyna się problem, bo wszelkie klasyczne algorytmy uczenia maszynowego przetwarzające właśnie język naturalny nie traktowały sekwencji jako całości, a bardziej zmieniały tekst na listę słów z odpowiednimi wagami. Czasem „zapominając” o kontekście, sekwencji i innych istotnych elementach.

Sieci neuronowe typu **RNN (rekurencyjne)** zaczęły obsługiwać dane sekwencyjne (teksty), analizując np. słowo po słowie. Jakość przetwarzania rosła, jednak do rewolucji było jeszcze trochę daleko. W 2017 roku zespół Google Brain stworzył koncepcję transformerów i opisał ją w dokumencie „**Attention Is All You Need**”.

Naukowcy głównie skupili się na mechanizmie uwagi, a dokładniej „samo-uwagi” (self-attention) wzorowanej na uwadze w procesach poznawczych i mocno wspierającym ją kontekście. Dzięki tej pracy naukowej powstała architektura **transformerów**, która „szturmem” wdarła się do laboratoriów BigTech i namieszała początkowo w **NLP**, a obecnie w niemal każdej dziedzinie przetwarzania danych.

Technicznie są to dalej modele korzystające z dobrodziejstwa głębokiego uczenia, ale ulepszone kilkoma dodatkami. Najważniejszym elementem jest „self-attention”, do tego traktowanie sekwencji jako całości oraz szereg technik już dobrze znanych z przetwarzania języka naturalnego, takie jak „word embedding” (osadzanie słów) czy też „positional encoding” (czyli znaczenie pozycji słowa w zdaniu).



Word embedding – wyuczona maszynowo reprezentacja słów (np. w postaci wektora), w której słowa o tym samym znaczeniu mają podobną reprezentację.

Źródło: <https://neptune.ai/blog/word-embeddings-guide> [dostęp: 25.08.2022]

Naukowcy zaczęli prezentować transformatory w postaci gotowych rozwiązań dostępnych w chmurze.

Jak grzyby po deszczu zaczęły powstać modele oparte na architekturze transformera tj.: BERT, T5, GPT itp. Najbardziej znanym przedstawicielem takich architektur jest GPT-3 (Generative Pre-trained Transformer 3) organizacji OpenAI. Organizacja OpenAI założona przez Elona Muska, a obecnie mocno wspierana przez Microsoft pracowała przez 12 miesięcy modelem GPT-3. Przy pracach zatrudnionych było ponad 30 naukowców z całego świata, niektóre z pierwszych wersji „trójki” miały ponad 175 miliardów parametrów. Do treningu użyto ogromnych ilości tekstu z różnych źródeł (książki, strony internetowe). Ilość była tak duża, że np. Wikipedia stanowiła tylko 3% całego zbioru.

GTP-3 służy głównie do generowania tekstu na podstawie kilku pierwszych słów. Potrafi to zrobić w taki sposób, że trudno odróżnić, czy tekst stworzył człowiek, czy maszyna. Dodatkowo możemy zażyczyć sobie, w jakim stylu ma go wygenerować, na przykład urzędowym czy szekspirowskim. Ale to nie koniec, bo transformator ten jest bardzo wszechstronny i może również: tłumaczyć tekst na inne języki, sprawdzać i poprawiać styl oraz gramatykę, wyciągać dane z tekstu, generować pytania do wywiadu, odpowiadać na pytania, wymyślać hasła reklamowe np. na podstawie parametrów produktu.



Przykładowe funkcjonalności (bo jest ich kilka razy więcej) GPT-3

Źródło: <https://beta.openai.com/> [dostęp: 25.08.2022]

-
- Q&A**
Answer questions based on existing knowle...
 - Summarize for a 2nd grader**
Translates difficult text into simpler concep...
 - Text to command**
Translate text into programmatic commands.
 - Natural language to Stripe API**
Create code to call the Stripe API using nat...
 - Parse unstructured data**
Create tables from long form text
 - Python to natural language**
Explain a piece of Python code in human un...
 - Calculate Time Complexity**
Find the time complexity of a function.
 - Advanced tweet classifier**
Advanced sentiment detection for a piece o...
 - Keywords**
Extract keywords from a block of text.
 - Ad from product description**
Turn a product description into ad copy.
 - Grammar correction**
Corrects sentences into standard English.
 - Natural language to OpenAI API**
Create code to call to the OpenAI API usin...
 - English to other languages**
Translates English text into French, Spanish...
 - SQL translate**
Translate natural language to SQL queries.
 - Classification**
Classify items into categories via example.
 - Movie to Emoji**
Convert movie titles into emoji.
 - Translate programming languages**
Translate from one programming language ...
 - Explain code**
Explain a complicated piece of code.
 - Factual answering**
Guide the model towards factual answering ...
 - Product name generator**
Create product names from examples word...

Transformatory mają jeszcze jedną ciekawą cechę, ponieważ można je „dostroić” do konkretnych zadań, o ile dane wejściowe i wyjściowe są zachowane w sekwencji i mamy wystarczająco dużo danych do treningu. Tak więc zespół na podstawie wyników prac nad GPT-3 stworzył model CODEX do automatycznego generowania kodu źródłowego programów lub DALL-E czyli generowanie obrazów z tekstu.




Obraz wygenerowany przez transformer DALL-E na podstawie tekstu „An astronaut riding a horse as pencil style”

Źródło: <https://openai.com/dall-e-2/> [dostęp: 25.08.2022]




Obraz wygenerowany przez transformer DALL-E na podstawie tekstu „An astronaut riding a horse in a photorealistic style”

Źródło: <https://openai.com/dall-e-2/> [dostęp: 25.08.2022]



Obraz wygenerowany przez transformer DALL-E na podstawie tekstu „An astronaut riding a horse in the style of Andy Warhol”

Źródło: <https://openai.com/dall-e-2/> [dostęp: 25.08.2022]




Kończąc podrozdział o transformatach, warto wspomnieć, że Google w 2019 roku wdrożyło do swojej wyszukiwarki transformer BERT (Bidirectional Encoder Representations from Transformers), który nieco zamieszał w branży SEO. W efekcie jednak dał internautom naprawdę świetne narzędzie do wyszukiwania informacji w odpowiednim kontekście. W 2023 roku będziemy świadkami zaciętej rywalizacji pomiędzy opartymi o AI BARDem Google’a a BINGIEM tworzonym przez Microsoft. Alphabet ogłosił plany dodania swojego najnowszego chatbota AI, LaMDA, do wyszukiwarki Google. Microsoft szybko odpowiedział Google, mówiąc, że włączy chatbota ChatGPT do swojej wyszukiwarki Bing. Ten wyścig zmieni oblicze searcha.




5.

DOMENY AI

W poprzednim rozdziale poznaliśmy wybrane techniki, które specjalizują się w pewnych typach danych, np. **konwolucyjne sieci neuronowe** (ang. Convolutional Neural Network), świetnie sprawdzające się w zadaniach związanych z przetwarzaniem obrazów, GAN w generowaniu obrazów, a transformatory m.in. szeroko rozumianym przetwarzaniu tekstów (naturalnych, ale także kodu źródłowego). **Czasami ta specjalizacja była tak silna, że pojawiły się nowe dziedziny lub domeny naukowe łączące tradycyjne podejście do danych problemów i sztuczną inteligencję.** Najlepszym przykładem jest przetwarzanie języka naturalnego (NLP), czyli interdyscyplinarna dziedzina łącząca lingwistykę i sztuczną inteligencję (od metod symbolicznych po uczenie maszynowe). **Przyjrzyjmy się więc szczegółowo tym najpopularniejszym domenom AI wraz z ich zastosowaniem w biznesie.**



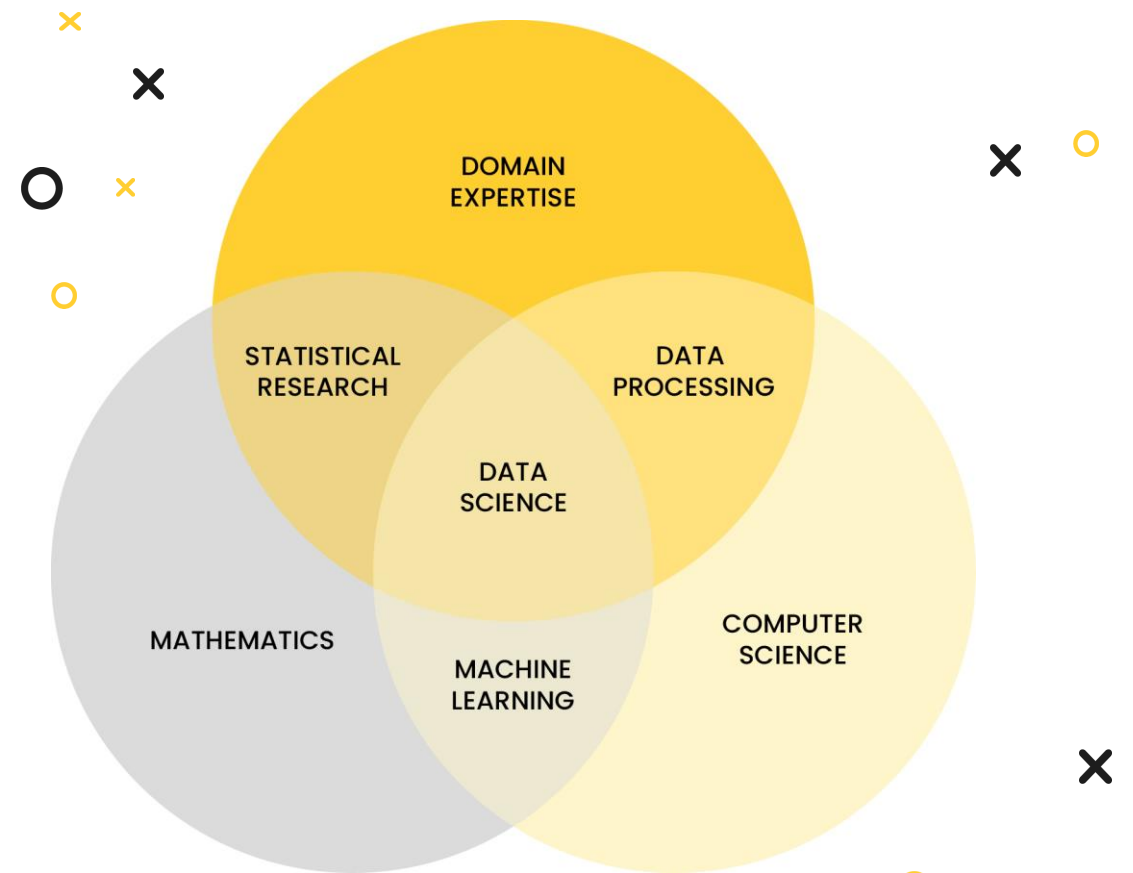


5.1

DATA SCIENCE

Zacznijmy od danologii, choć w praktyce nawet na polskim rynku używa się nazwy anglojęzycznej, czyli data science.

Jest to nurt w przetwarzaniu informacji łączący wiedzę naukową z **zakresu matematyki, statystyki, sztucznej inteligencji** z umiejętnościami programistycznymi w celu wydobywania z danych zarówno ustrukturyzowanych, jak i nieustrukturyzowanych wzorców, prawidłowości, wniosków. Data science jest bardzo mocno **powiązane z eksploracją danych** (ang. data mining), **uczeniem maszynowym** (ang. machine learning) i **analizą dużych zbiorów danych** (ang. big data). Dziedzina na tyle istotna w biznesie, że na rynku pojawia się nowe stanowisko pracy **data scientist** okrzyknięte jednym z topowych zawodów przyszłości.



Data science zależności między poszczególnymi dziedzinami

Źródło: <http://dslab.wne.uw.edu.pl/poznaj-data-science/>



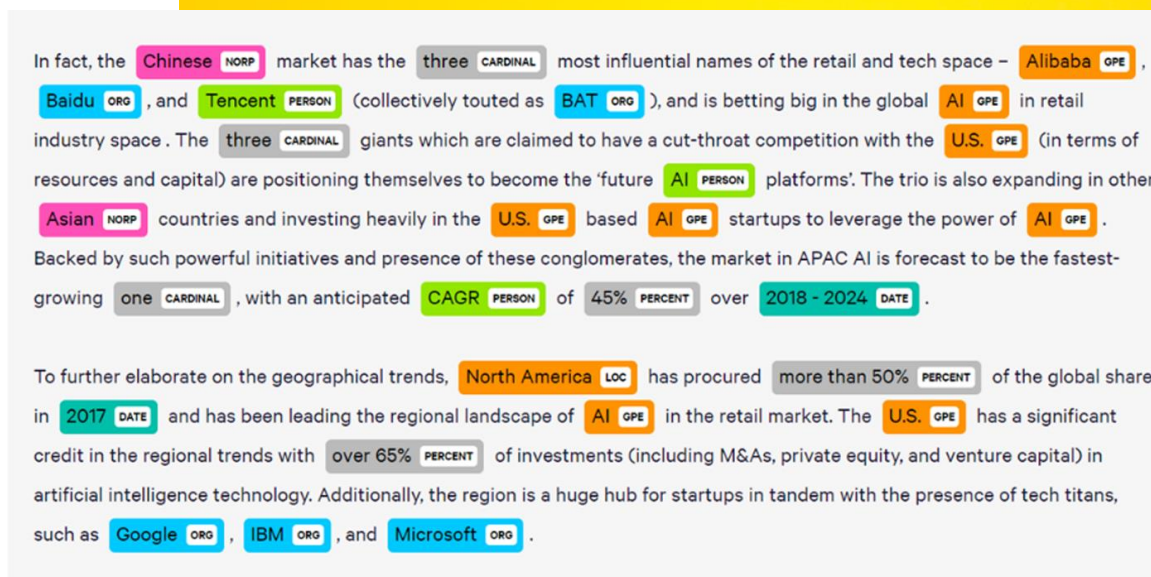
5.2

NLP

Natural Language Processing (NLP), jak już wspomnieliśmy, interdyscyplinarna dziedzina łącząca lingwistykę i sztuczną inteligencję. Bardzo szeroki zakres narzędzi, tj. od technik symbolicznych, statystycznych do tzw. neuronowych (neural NLP) oraz bardzo szeroki zestaw problemów realizowanych przez NLP. Jakie na przykład?

Niskopoziomowa analiza taka jak:

- **analiza morfologiczna**
– czyli struktura słów, rozpoznawanie części mowy danego słowa, wskazywanie formy podstawowej lub rdzenia, itp.,
- **analiza semantyczna**
– wydobywanie informacji z tekstu, np. wykrywanie tzw. bytów nazwanych (ang. named-entity recognition, NER), zwalczanie wieloznaczności w zależności od kontekstu, itd.,
- i uwierzcie – wiele innych analiz na poziomie słowa czy też zdania.



In fact, the Chinese NORP market has the three CARDINAL most influential names of the retail and tech space - Alibaba GPE , Baidu ORG , and Tencent PERSON (collectively touted as BAT ORG), and is betting big in the global AI GPE in retail industry space . The three CARDINAL giants which are claimed to have a cut-throat competition with the U.S. GPE (in terms of resources and capital) are positioning themselves to become the 'future AI PERSON platforms'. The trio is also expanding in other Asian NORP countries and investing heavily in the U.S. GPE based AI GPE startups to leverage the power of AI GPE . Backed by such powerful initiatives and presence of these conglomerates, the market in APAC AI is forecast to be the fastest-growing one CARDINAL , with an anticipated CAGR PERSON of 45% PERCENT over 2018 - 2024 DATE .

To further elaborate on the geographical trends, North America LOC has procured more than 50% PERCENT of the global share in 2017 DATE and has been leading the regional landscape of AI GPE in the retail market. The U.S. GPE has a significant credit in the regional trends with over 65% PERCENT of investments (including M&As, private equity, and venture capital) in artificial intelligence technology. Additionally, the region is a huge hub for startups in tandem with the presence of tech titans, such as Google ORG , IBM ORG , and Microsoft ORG .

Rozpoznanie tzw. bytów nazwanych do dokumentach prawno-finansowych

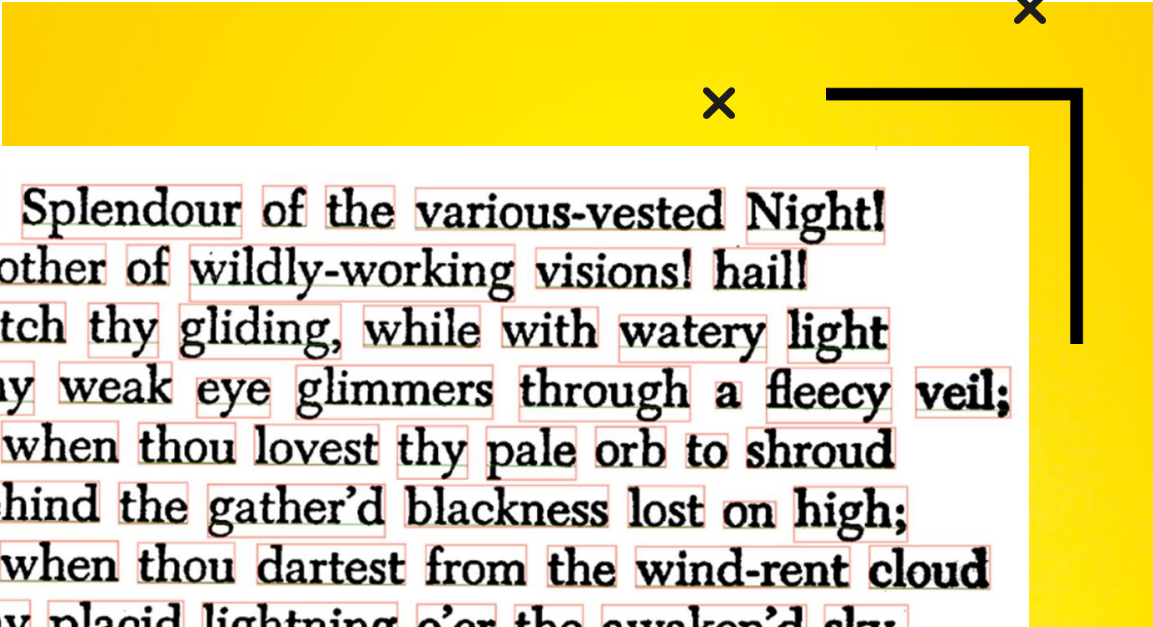
Źródło: <https://www.spotdraft.com/engineering-blog/using-named-entity-recognition-to-extract-legal-information-from-contracts> [dostęp: 22.08.2022]

Kolejny obszar to zadania wysokiego poziomu (w których idealnie sprawdzają się m.in. transformery):

- **podsumowanie tekstu** (ang. automatic summarization)
- **generowanie języka naturalnego** (ang. natural-language generation, NLG) – np. tworzenie tekstu w języku naturalnym na podstawie pól/atributów z bazy danych lub plików,
- **rozumienie języka naturalnego** (ang. natural-language understanding, NLU) – proces odwrotny do NLG tj. zamiana naturalnego tekstu na reprezentację bardziej formalną, czyli rozumienie znaczenia tekstu, rozpoznanie kontekstu. Proces NLG i NLU jest niezbędny do prowadzenia komunikacji człowiek-maszyna. Zatem chatboty, voiceboty bez nich nie będą w stanie „pociągnąć” rozmowy z klientem czy też użytkownikiem;
- **odpowiadanie na pytania** (ang. question answering).

Lista wysokopoziomowych zadań NLP lub ich zastosowań w komunikacji, przetwarzaniu tekstu jest naprawdę ogromna i powyżej wymienione zostały jedynie najczęstsze zastosowania. Dodatkowo, techniki z innych dziedzin AI, takie jak OCR (optical character recognition) czy text-to-speech – konwersja tekstu na mowę, również wpisują się w ten obszar.

Techniki **OCR** (ang. optical character recognition, optyczne rozpoznawanie znaków) służą do ekstrakcji tekstów z plików graficznych. W procesie tym najczęściej wykorzystywane są znane już sieci neuronowe, które potrafią wyodrębnić z obrazu blok tekstu, słowo, pojedynczy znak i przypisać do odpowiedniej klasy (rozpoznać).



Mild Splendour of the various-vested Night!
Mother of wildly-working visions! hail
I watch thy gliding, while with watery light
Thy weak eye glimmers through a fleecy veil;
And when thou lovest thy pale orb to shroud
Behind the gather'd blackness lost on high;
And when thou dartest from the wind-rent cloud
Thy placid lightning o'er the awaken'd sky.

Ekstrakcja tekstu za pomocą technik OCR

Źródło: <https://cognitiv.sg/multilingual-ocr/> [dostęp: 22.08.2022]

Osoby zainteresowane zagadnieniem wysokopoziomowego przetwarzania i generowania tekstu zapraszamy do wypróbowania narzędzi ze „stajni” OpenAI:

<https://beta.openai.com/examples>

Wymagają one karty kredytowej, ale przy pojedynczych zabawach rachunek nie przekroczy kilkudziesięciu centów.



5.3

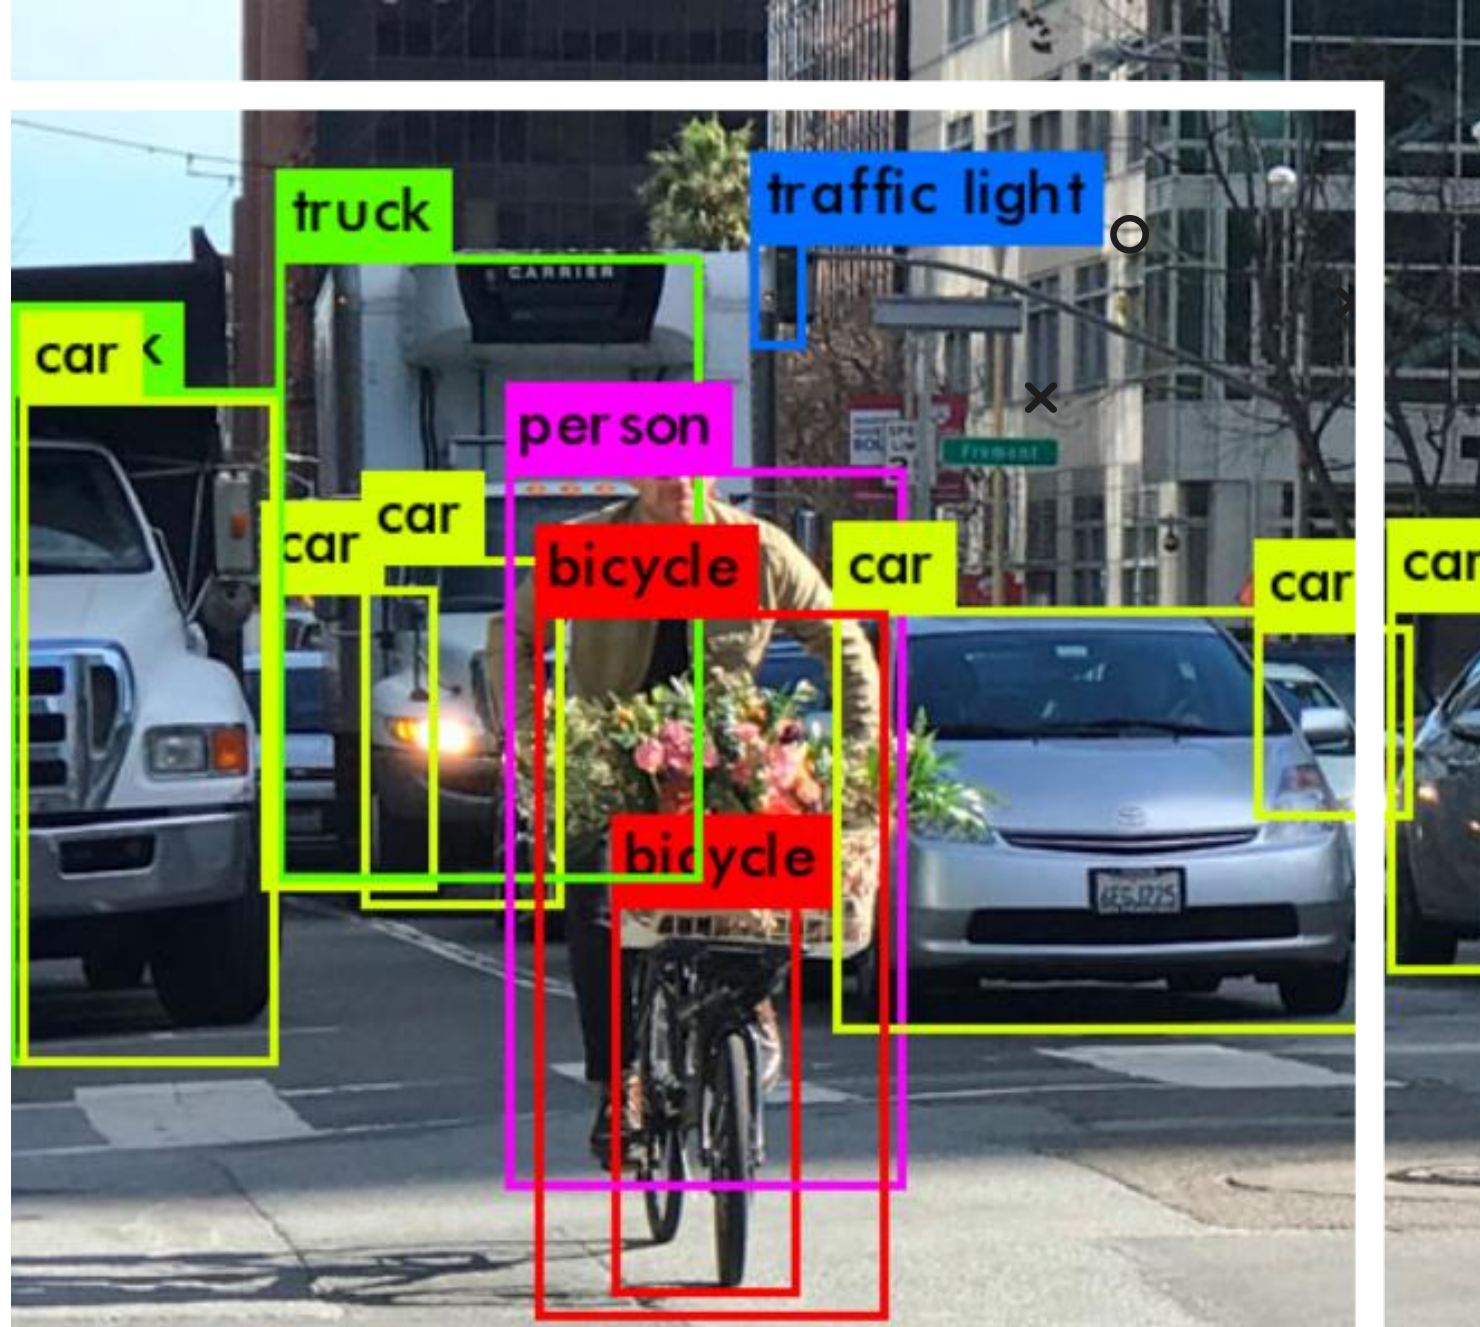
COMPUTER VISION

Widzenie komputerowe (computer vision) to interdyscyplinarna dziedzina nauki, która zajmuje się „rozumieniem” obrazów cyfrowych (w tym wideo), czyli identyfikacją obiektów na zdjęciu, klasyfikacją samego zdjęcia, modelowaniem 3D, analizą ruchu obiektów etc. Zatem obszar ten obejmuje wszystkie zadania realizowane przez narząd wzroku człowieka i związane z nim elementy układu nerwowego. Obejmuje nie tylko algorytmy zajmujące się stricte analizą cyfrową, ale także „przebrojenie” urządzeń rejestrujących obraz (np. kamer przemysłowych, okularów rozszerzonej rzeczywistości) oraz przygotowanie obrazów do analizy, czyli skalowanie, kadrowanie, przekształcanie, wyostanie itp. Pod względem technik i architektur prym wiedzie **głębokie uczenie z wykorzystaniem konwencjonalnych sieci neuronowych** (CNN), rekurencyjnych sieci neuronowych (RNN), architektury GAN oraz modeli dyfuzyjnych.

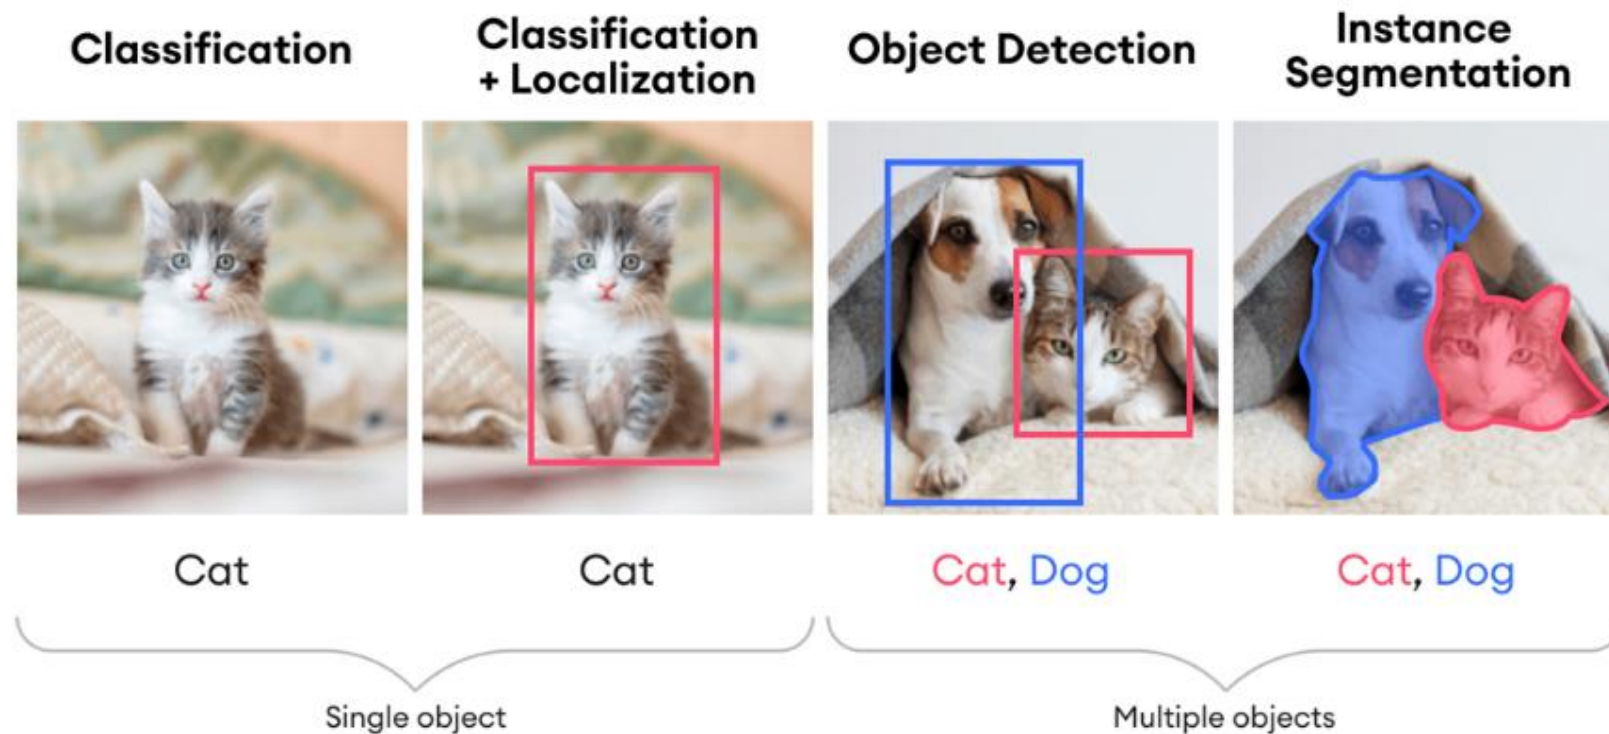
Identyfikacja obiektów na zdjęciu dzięki głębokiemu uczeniu

Źródło:

<https://medium.com/@chhabradiksha12/fundamentals-of-object-detection-e993b0761ada> [dostęp: 28.08.2022]



Widzenie komputerowe to dziedzina bardzo ważna z jednej strony dzięki wszechobecnym aparatom i kamerom w smartfonach, a także rosnącym trendom rozszerzonej rzeczywistości i nadchodzącemu meta-światowi (metaverse).



Różnica pomiędzy głównymi zadaniami CV tj. klasyfikacja obrazu, detekcja obiektu i segmentacja instancji

Źródło: <https://blog.superannotate.com/image-segmentation-for-machine-learning/>



5.4

SPEECH RECOGNITION

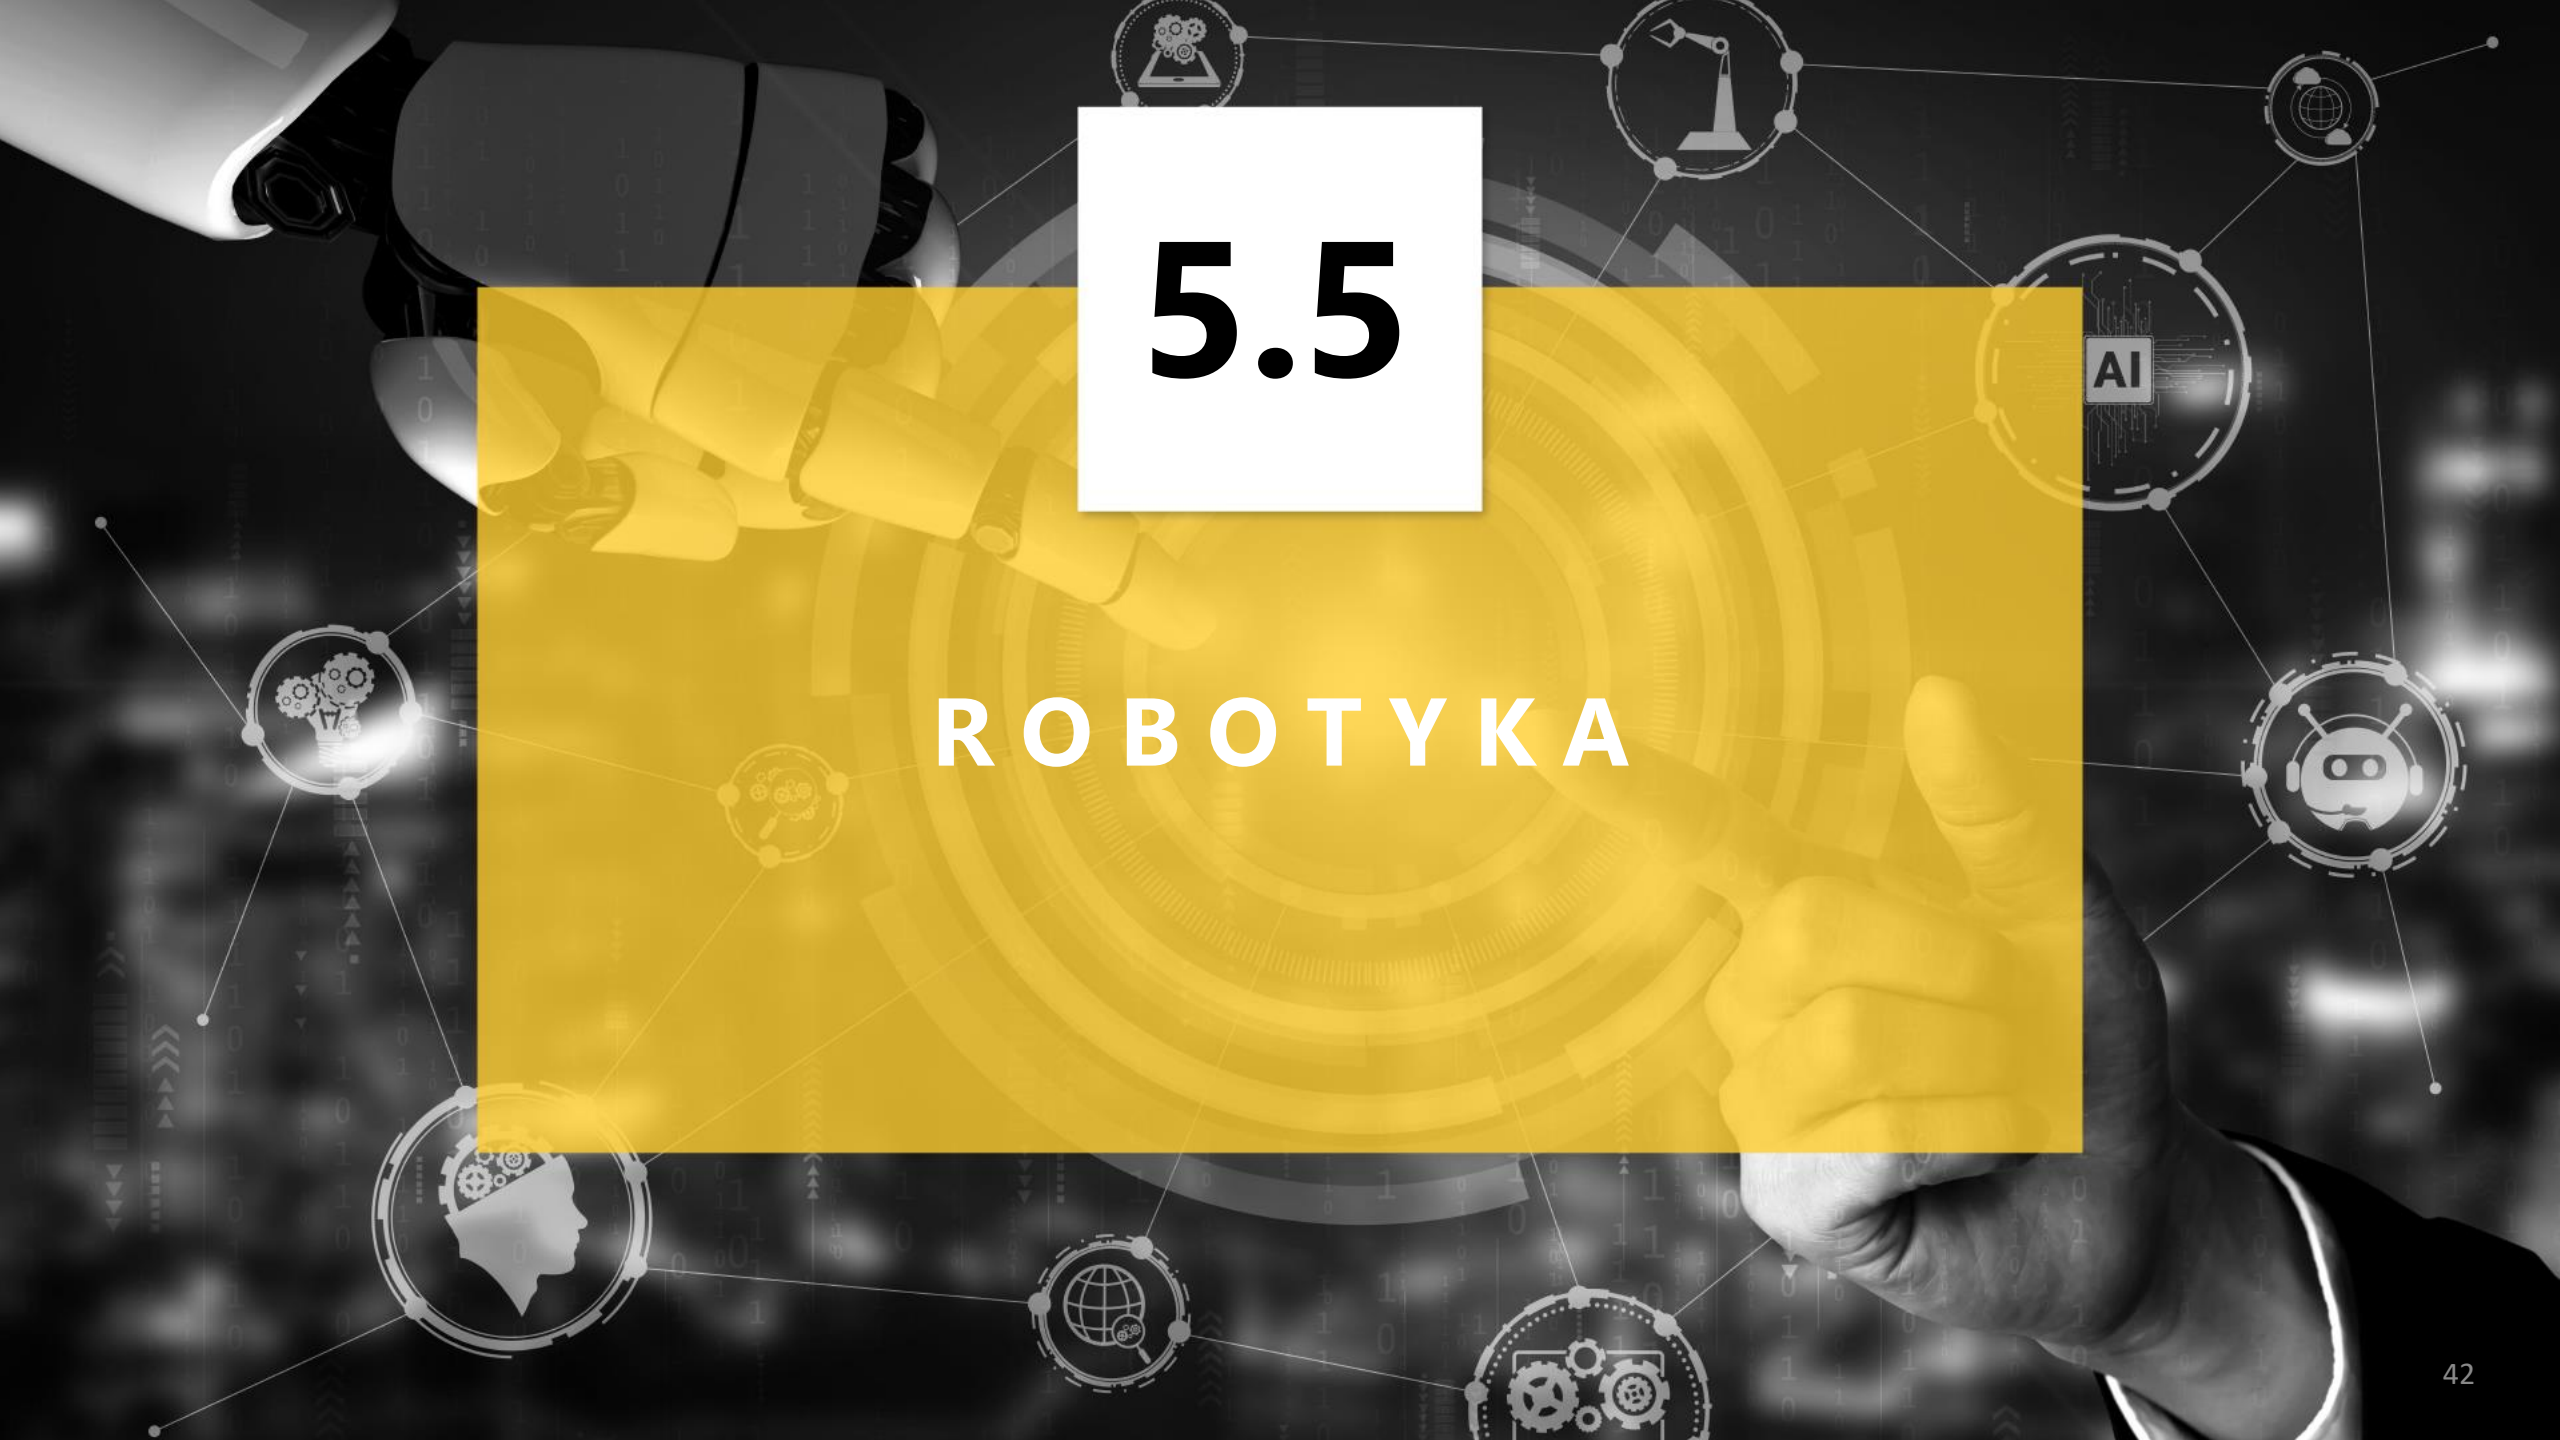
Sterowanie głosowe inteligentnymi domami jest możliwe m. in. dzięki: rozpoznawaniu mowy i uczeniu maszynowemu

Źródło: <https://www.vivint.com/resources/article/google-home-voice-control-your-home> [dostęp: 28.08.2022]

Rozpoznawanie mowy (speech recognition) to (bardzo) **interdyscyplinarna dziedzina informatyki**, która łączy w sobie lingwistykę (językoznawstwo), przetwarzanie języka naturalnego (NLP), uczenie maszynowe (zwłaszcza głębokie) oraz elementy automatyki i elektroniki.

Głównym celem jest **rozpoznanie i przetłumaczenie języka mówionego** na tekst. Dziedzina, która powstała wraz z narodzinami i rozbudową sieci telefonicznych (w tym tej stacjonarnej). Zapotrzebowanie na rozwiązania z tej dziedziny rośnie geometrycznie dzięki np. nowym wynalazkom takim jak **smart home, inteligentne głośniki** (Amazon Echo, Google Home), **asystenci głosowi w samochodach** czy też **potrzebom w nowoczesnych działach sprzedaży** (voice bot).





5.5

ROBOTYKA

Wykorzystanie robotów z AI na pokładzie w rolnictwie

Źródło: <https://www.snowdropsolution.com/machine-learning/how-ai-and-machine-learning-can-help-to-improve-global-agriculture/> [dostęp: 28.08.2022]

Pierwsze roboty przemysłowe zostały uruchomione w fabryce General Motors w Trenton w stanie New Jersey już w **1961 roku!** Od tego czasu obszar ten mocno się rozwija i trudno sobie wyobrazić jakąkolwiek linię montażową bez robota przegubowego.

Jednak **rozwój sztucznej inteligencji** (zwłaszcza głębokiego uczenia, wizji komputerowej i uczenia maszynowego ze wzmocnieniem) oraz jej zastosowanie w robotyce sprawiły, że roboty mogą lepiej przetwarzać informacje z czujników wizyjnych i idealnie rozumieć zmieniającą się scenerię oraz wykrywać i klasyfikować obiekty.

Dlatego dziś dzięki AI możemy spotkać roboty nie tylko na monotonnych liniach produkcyjnych, gdzie wykonują powtarzalne zadania, ale **w sadach zbierające owoce, sortujące plony, gotujące i podające gotowe posiłki czy sprzątające nasze mieszkanie.**





6.

HIPER-AUTOMATYZACJA

Zacznijmy od grubej liczby. Wg raportu Gartnera na hiper-automatyzacji firmy mogą zaoszczędzić 30% swoich kosztów operacyjnych w ciągu najbliższych 4 lat. Interesujące?

Co to zatem jest ta hiper-automatyzacja? Mówiąc najprościej, myślenie o zmianach w całej organizacji pod kątem wdrożenia **AI, automatyzacji i Business Intelligence**. Czyli nie podejście: „wdrożymy Ai tylko do HRów, ten jeden algorytm, a dalej zobaczymy”, a zdecydowanie bardziej: „**sprawdźmy, co w całej naszej organizacji jest nieco przestarzałe albo wymaga optymalizacji, a da się zautomatyzować i stworzymy strategię kompleksowego działania**”. Pracujemy zatem nad transformacją cyfrową w całej organizacji. Do tego celu wykorzystujemy najnowsze rozwiązania i narzędzia: AI i Machine Learning, RPA (Robotic Process Automation), NLP, OCR, zaawansowaną analitykę, DTO (Digital Twin of Organization), narzędzia low-code/no-code oraz do process/task mining, platformy integracyjne jako usługi (iPaaS). Zmierzamy do tego, by zarządzać procesami biznesowymi z wykorzystaniem inteligentnych narzędzi (iBPMS).

Zatem hiper-automatyzacja to strategia, podczas gdy hasło Inteligentna Automatyzacja dotyczy raczej pojedynczych działań operacyjnych.

Hiper-automatyzacja składa się z poszczególnych etapów:

- określenia celów i potrzeb,
- analizy obecnej sytuacji,
- zaplanowania optymalizacji procesów i ścieżek procesowych,
- wyboru zestawu konkretnych technologii, które będą niezbędne do obsługi różnych zespołów i działów w danej organizacji,
- wdrożenia orkiestracji, która obejmuje koordynację zautomatyzowanych zadań i przepływów pracy w różnych narzędziach, zespołach i środowiskach,
- stałej optymalizacji pod kątem aktualnych wymagań biznesowych.

Czy są organizacje, które tak działają? Tak. Przykładowo, **Credit Agricole** zdecydowało się na stopniowe wprowadzanie hiper-automatyzacji we wszystkich swoich działach, tak żeby w przyszłości te procesy zintegrować oraz wykorzystywać te same algorytmy do automatyzacji w różnych zakresach.

30% oszczędności w kosztach operacyjnych osiągamy dzięki uproszczeniu procesów i ujednoczeniu wielu obszarów, między innymi: procesowania danych, komunikacji z klientem, zarządzania projektami czy marketingu. Dlatego spodziewamy się, że w najbliższym czasie coraz więcej firm będzie decydowało się na strategiczne podejście i w związku z tym wejdzie w procesy hiper-automatyzacji w swoich organizacjach.



The background is a complex digital composition. On the left, a woman's face is shown in profile, looking upwards, with a yellow semi-transparent overlay. In the center, a globe is rendered with a yellow semi-transparent overlay. The background is filled with various digital elements: a grid of white dots, a network of white lines, and several floating numbers in white. The overall color palette is dominated by black, white, and yellow.

7.

PULAPKI AI

Technologie AI są coraz częściej stosowane w różnych dziedzinach życia. Już teraz niektóre rozwiązania pomagają **ratować życie**, tak jak ma to miejsce na przykład w sektorze opieki zdrowotnej. Niemniej jednak istnieją również obawy związane ze stosowaniem AI, w szczególności **problemy prawne i etyczne**.

Po pierwsze, praca z AI **wymaga konkretnych umiejętności**. Przyszły sukces w organizacjach będzie zatem zależał od tego, czy ludzie nauczą się pracować z tą technologią. Paradoks polega na tym, że wraz z rosnącą potężną sztuczną inteligencją nastąpi równoległy wzrost popytu na umiejętności uważane za wyłącznie ludzkie. Kto zatem jest potrzebny w organizacjach do pracy z AI? Przede wszystkim człowiek, który **potrafi wybrać odpowiednie narzędzie do rozwiązania konkretnego problemu**.

Nie zawsze AI będzie najlepszym możliwym rozwiązaniem. Algorytmy AI mają swoje ograniczenia. Baza danych, na której pracuje AI także ma swoje ograniczenia. Przykładowo, pierwsze systemy AI pomagające w rekrutacjach bazowały na danych historycznych, czyli kogo najchętniej rekrutowano do tej pory. Baza danych dotyczyła przeszłych zakończonych z powodzeniem rekrutacji amerykańskich managerów z korporacji przez ostatnie 20 lat. Nic dziwnego, że system rekomendował głównie CV białych mężczyzn. Na listę rekomendacji praktycznie nie trafiały kobiety, Afroamerykanie czy osoby z mniejszości narodowych. Czy to wina AI, który okazał się szowinistą i rasistą? Nie. To kwestia założeń przyjętych przez człowieka, który ten algorytm zaprojektował, a następnie innego człowieka, który bez sprawdzenia zasad działania AI, postanowił go wprowadzić do organizacji. **Świadomość, że AI ma swoje zasady działania i limitacje jest absolutnie konieczna.**

Specjaliści z Said Oxford Business School określali ludzi prawdziwie zdolnych do pracy z AI: „**ludźmi centaurami**”. Wykorzystując postać centaury, mitycznego stworzenia, które jest pół człowiekiem, pół koniem, podkreślali, że ludzie muszą nauczyć się, jak **skutecznie wchodzić w interakcje i koegzystować z AI**. Z jednej strony muszą mieć podstawowe zrozumienie danych, statystyk, algorytmów. Z drugiej, **wysokie kompetencje komunikacyjne oraz rozwiązywania problemów o wysokim poziomie skomplikowości i niuansów**.

Po drugie, AI to także potencjalne ryzyka:


- nadużyć naszych prywatnych danych (dane są dla AI żyłą złota),
- replikacji,
- a także stronniczości (o czym przypominała już historia pierwszych algorytmów wspierających proces rekrutacji).



Jak pokazują liczne przykłady, nasze dane nie są zawsze bezpieczne. Wystarczy przypomnieć słynną aferę związaną z Facebookiem, Donaldem Trumpem, wyborami w USA i Cambridge Analytica. Jednocześnie, nasze dane osobowe to dla AI czyste złoto. Dzięki nim AI może się uczyć, trenować modele, robić coraz lepsze predykcje. Dlatego różne projekty prawne starają się nasze dane zabezpieczyć. Prawo jednak ma to do siebie, że działa z opóźnieniem i wymaga nie tylko samych przepisów, ale i kompetentnych organów weryfikujących wdrożenie założeń w życie.

W 2021 r. Unia Europejska opublikowała wniosek dotyczący regulacji sztucznej inteligencji.

Główne założenia ilustruje grafika obok:



W toku prac obecnie znajduje się wiele projektów prawnych, które mają dać internautom prawo i możliwość do decydowania, którymi danymi dzielimy się w necie i w jakim zakresie można z nich skorzystać. W dniu 5.7.2022 r. Parlament Europejski uchwalił **Akt o Usługach Cyfrowych** (Digital Services Act). To najważniejszy od ponad 20 lat akt prawny, dotyczący prowadzenia działalności gospodarczej w Internecie. Ma on szczególne znaczenie dla użytkowników internetowych, przedsiębiorców oraz platform internetowych jako dostawców usług cyfrowych.

Kolejną pułapką sztucznej inteligencji jest **replikacja**, określana jako problem z „czarną skrzynką”. O co w tym chodzi? O niezdolność człowieka do odtworzenia błędnej decyzji podjętej przez maszynę, a tym samym niemożność zidentyfikowania przyczyn, dla których AI podjęła konkretną decyzję czy podała predykcje. Krótko mówiąc, ludzie nie mogą odtworzyć, co się dokładnie wydarzyło, bo struktura AI jest zbyt złożona, a danych za dużo. Dotyczy to zwłaszcza deep learningu. Czyli nie wiemy na przykład, dlaczego samodzielnie jeżdżący samochód w danym momencie postanowił przyspieszyć albo skręcić w lewo (dygresja: gdyby ludzi nie było za kierownicą, automatyczne samochody poradziłyby sobie na drogach świetnie i bez wypadków, bo miałyby dostęp do wszystkich danych o poruszających się pojazdach. Człowiek jest najbardziej nieprzewidywalny na drodze).

Duże firmy technologiczne są coraz bardziej świadome potrzeby podejmowania bardziej przejrzystych decyzji przez AI. Na przykład często pojawiają się w branży głosy o „prawie do wyjaśnienia”, które pozwoliłyby osobom fizycznym zrozumieć, w jaki sposób osiągnięto na przykład prognozę dotyczącą ich wniosku kredytowego. Problem w tym, że niemożliwe jest zapewnienie takiego poziomu wglądu bez ujawnienia wewnętrznych zasad działania systemu sztucznej inteligencji. A ten zazwyczaj jest pilnie strzeżoną informacją handlową. Dlatego w tej kwestii mamy lekki impas.


Microsoft i Google (i wiele innych firm) chcą zapewnić takie narzędzia do wyjaśniania. Firma Microsoft uruchomiła swoje narzędzie Fairlearn, podczas gdy Google oferuje narzędzie What-if. Jeśli byłby to powszechny standard rynkowy, umożliwiłyby zapytanie algorytmu, wizualizację wyników i pokazywał wrażliwość na różne wyniki.

Kolejna pułapka to stronniczość AI, która zazwyczaj wynika z zestawu danych. Jeśli zestawy danych, z których korzysta AI, nie są różnorodne i nie pokazują różnorodności (na przykład pochodzenia społecznego, rasy, wieku, płci i orientacji seksualnej), algorytmy są potencjalnie szkolone z niekompletnych danych. **W efekcie możemy otrzymać stronnicze predykcje lub decyzje.** Krótko mówiąc, decyzja algorytmu będzie tak dokładna, jak pozwalają na to dane. Dodatkowym elementem jest fakt, że algorytmy są tworzone, trenowane i weryfikowane przez ludzi. Czasami nawet my sami, nieświadomie, wprowadzamy do algorytmu nasze ograniczenia i wiedzę o świecie. Istnieją trzy podstawowe sposoby radzenia sobie z uprzedzeniami AI:

- większa ilość i lepsze, bardziej reprezentatywne dane,
- regularna aktualizacja modeli,
- wykorzystanie matematycznych modele debiasingu, w których wektory pewnych cech (np. płeć, rasa itp.) są zmieniane ręcznie po to, by uniknąć stereotypizacji czy tendencyjności prognoz.

Prawdziwy potencjał sztucznej inteligencji w organizacji tkwi w pracy z technologią w celu poprawy produktywności i optymalnego sposobu realizacji zadań.






8.

CASEBOOK

Pora na praktyczne przykłady użycia AI. Poziom użycia rozwiązań sztucznej inteligencji w poszczególnych branżach znacząco się różni. Najbardziej zaawansowane w adaptacji AI są: **zaawansowane technologie i telekomy**, następnie **przemysł i automatyczne pojazdy**, kolejno **usługi finansowe, prawo** oraz szeroko rozumiane **zdrowie**. Wybraliśmy cztery sektory, żeby szerzej omówić najciekawsze naszym zdaniem zastosowania AI w biznesie. Wybór omawianych case study i zagadnień jest stricte autorski, natomiast są to inicjatywy szeroko omawiane przez branżę lub takie, o których naprawdę warto więcej opowiedzieć, by propagować konkretne rozwiązania. W przyszłości planujemy opublikowanie pogłębionych casebooków poświęconych wybranym branżom, w modelu płatnej dystrybucji. Naszym zdaniem, zawarte w tej bezpłatnej publikacji przykłady i praktyczne informacje pozwalają na pozyskanie ogólnej wiedzy i najaktualniejszych kierunków w rozwoju AI na świecie.

AI ADOPTION by INDUSTRY, 2020

Source: McKinsey & Company, 2020 | Chart: 2021 AI Index Report



X



X

8.1

REKLAMA INTERNETOWA

Reklama internetowa, z racji samej nazwy i osadzenia w świecie cyfrowym, od samego początku była oparta na danych. Dlatego bez analizy danych trudno byłoby oczekiwać, że kampanie reklamowe spełnią oczekiwane cele. Oczywiście początkowo cała praca z tym związana była wykonywana ręcznie przez pracowników w ogólnodostępnych programach biurowych, takich jak arkusze kalkulacyjne. **Jednak z biegiem lat przybyło specjalistycznego oprogramowania ułatwiającego analizę danych czy wizualizację efektów kampanii reklamowych.** Równocześnie pojawiały się nowe kanały, formaty reklamowe, modele rozliczeń i strategie reklamowe. Wszystko to spowodowało z jednej strony ogromny przyrost nowych typów danych, a z drugiej – pojawienie się potrzeby automatyzacji procesu analizy oraz większej autonomiczności decyzyjnej systemów. Trudno się więc dziwić, że wraz z szybkim rozwojem AI i mocy obliczeniowej komputerów, krok po kroku zaczęły pojawiać się w procesach biznesowych ekosystemu reklamy cyfrowej: algorytmy ewolucyjne, uczenie maszynowe i głębokie uczenie (w szczególności algorytmy generatywne).

Jednym z przykładów owocnej fuzji świata reklamy i sztucznej inteligencji jest reklama programatyczna (programmatic). Jest to połączenie różnych technologii, takich jak algorytmy, dane, systemy czasu rzeczywistego i AI, w celu stworzenia zaawansowanego systemu, który automatyzuje procesy związane z zakupem i dystrybucją reklamy w Internecie.

Mamy nadzieję, że nie obrazimy przedstawicieli, dostawców i biznesowych użytkowników systemów typu programmatic, ponieważ dziś nie napiszemy o nim więcej w raporcie. **Sukces programmatica i m.in. sztucznej inteligencji w nim zastosowanej jest nie do przecenienia**, co potwierdza jego popularność, udział w budżetach reklamowych oraz świetne studia przypadków prezentowane na największych konferencjach zarówno reklamowych, jak i technologicznych. Chcielibyśmy jednak opisać i pokazać wsparcie AI w procesach biznesowych reklamy internetowej, które dotychczas były trudne do automatyzacji, gdyż wymagały kreatywności, wyobraźni czy też biegłości w języku naturalnym – kompetencje, które dotychczas były zarezerwowane wyłącznie dla ludzi. Aż do 2014 roku, kiedy to powstały pierwsze algorytmy generatywne (GAN), które udowodniły światu, że wyobraźnia również może być „wyposażeniem” systemu komputerowego. Zobaczmy więc, jak „maszynowa” wyobraźnia zmienia lub może zmienić ekosystem reklamy internetowej.





Ta osoba nie istnieje!

Zacznijmy od bardzo prostego zastosowania sztucznej inteligencji w obszarze **reklamy internetowej** – prekursora algorytmów generatywnych, tj. sieci GAN (opisanych w niniejszym raporcie w rozdziale 4.4). Każdy za darmo może sprawdzić możliwości tych rywalizujących sieci. Zatem wielokrotnie projektując reklamy internetowe lub landing page związane z reklamami, potrzebujemy zdjęć osób. Oczywiście możemy kupić dowolną liczbę zdjęć na serwisach typu foto stock. Jednak w niektórych sytuacjach zdjęcia tzw. naturszczyków bardziej wzbudzają zaufanie do produktu i tym samym zwiększają konwersję. No i tutaj jest problem, aby szybko mieć zdjęcia z pozwoleniem na wykorzystanie wizerunku. Chyba, że wspomże nas sztuczna inteligencja. Serwis **thispersondoesnotexist.com** prezentują zdjęcia osób całkowicie wygenerowanych przez AI.

Koniec roku 2022 to głośna **premiera ChatGPT**, cieszącego się tak ogromnym zainteresowaniem, że w ciągu kilku dni skorzystało z niego ponad milion osób. Taki wynik jest rekordem w cyfrowym świecie jeśli chodzi o prędkość zdobywania zainteresowania przez użytkowników. Nawet rewolucyjne produkty jak Netflix czy Google musiały potrzebować na zgromadzenie pierwszych milionów użytkowników znacznie dłuższego czasu. **Sercem (a bardziej mózgiem)** ChatGPT jest tak zwany **duży model językowy** (large language model, w tym przypadku GPT-3) wytrenowany przy użyciu architektury transformer (opisanej w sekcji IV.IV). LLM są wielozadaniowymi modelami najczęściej udostępnionymi po płatnym API oraz kontrolowanemu przez język naturalny za pomocą tzw. prompt engineering. W oparciu o LLM-y różnych producentów (od OpenAI, Microsoft, Google, Cohere po otwarte stowarzyszenia jak EleutherIA) powstało wiele produktów i usług dedykowanych branży reklamy internetowej. Jednym z zadań dla wszechwiedzących dużych modeli językowych jest między innymi automatyczne generowanie opisów reklamowych produktów. Jak to działa? Po prostu – na wejściu podajemy słowa kluczowe, parametry, cechy produktu naciskamy przycisk „GENERATE” i gotowe. Mamy przekaz do reklamy.

LLM – generowanie opisów reklamowych

Midjourney – generowanie reklam i landing page



Przykładowe zdjęcia wygenerowane przez GAN osób, które nie istnieją

Źródło: <https://thispersondoesnotexist.com/> [dostęp: 18.01.2023]

Łatwo sobie wyobrazić, jak prosto zautomatyzować generowanie setki tysięcy reklam tekstowych dla produktów pobranych z tzw. feeda w branży e-commerce.

Gdy mamy już gotowy przekaz reklamowy lub opisy produktów, czas na generowanie reklam pod względem graficznym. Nie tylko chatGPT był bohaterem roku w obszarze AI i algorytmów generatywnych. W generowaniu obrazów też nastąpiła rewolucja. Co ciekawe również na bazie architektury transformer (ale nie tylko) w obszarze modeli tzw. text-to-image. Czyli opisujemy, co jaki obraz chcemy uzyskać i w jakim stylu, np: **„Miska zupy będąca portalem do innego wymiaru w stylu digital art”** i model nam to generuje (patrz dalej).

Keywords (comma separated words) ⓘ

krem, na dzień, kobieta, 30+, ARGANOWY Z WITAMINĄ E, 35 zł

Generate

Generated text

Uwaga kobiety po 30 roku życia! Jeśli szukasz nawilżającego rozwiązania dla swojej skóry, nie szukaj dalej! Nasz Krem Arganowy z Witaminą E to idealny sposób, aby Twoja skóra czuła się i wyglądała zdrowo. Za jedyne 35 zł możesz cieszyć się tym luksusowym kremem każdego dnia i uzyskać odżywienie, na które zasługuje Twoja skóra. Kup swój już dziś!

Generowanie opisu produktu i reklam za pomocą modelu GTP-NeoX

Źródło: <https://nlpccloud.com/> [dostęp: 18.01.2023]




Oczywiście wiele laboratoriów naukowych i biznesowych poszło w tym kierunku, tworząc rzeczywiście wiele wysoko wyspecjalizowanych modeli, które generują np. nie tylko sam obraz, ale wideo czy też model 3D. Zatem trudno się dziwić, że niektóre modele zaczynają specjalizować się również **w generowaniu interfejsu użytkownika, stron typu landing page czy też reklam.**

Oczywiście są to wstępne badania, jak i jeszcze dyskusyjny obszar praw autorskich do wygenerowanych prac. Jednak wyniki są imponujące i mogą zmienić całkowicie personalizację graficznych reklam internetowych.

**Obraz wygenerowany na podstawie tekstu:
„A bowl of soup that is a portal to another dimension
as digital art” przez model Dall-E**

Źródło: <https://openai.com/dall-e-2/> [dostęp: 18.01.2023]



×

×

○



Strony typu landing page zaprojektowane przez system MidJourney

Źródło: <https://twitter.com/marcelpociot/status/1597958880537219072>
[dostęp: 18.01.2023]




Reklamy aplikacji mobilnych wygenerowane przez autorów raportu w systemie MidJourney



Reklamy produktów spożywczych
wygenerowane przez autorów
raportu w systemie MidJourney

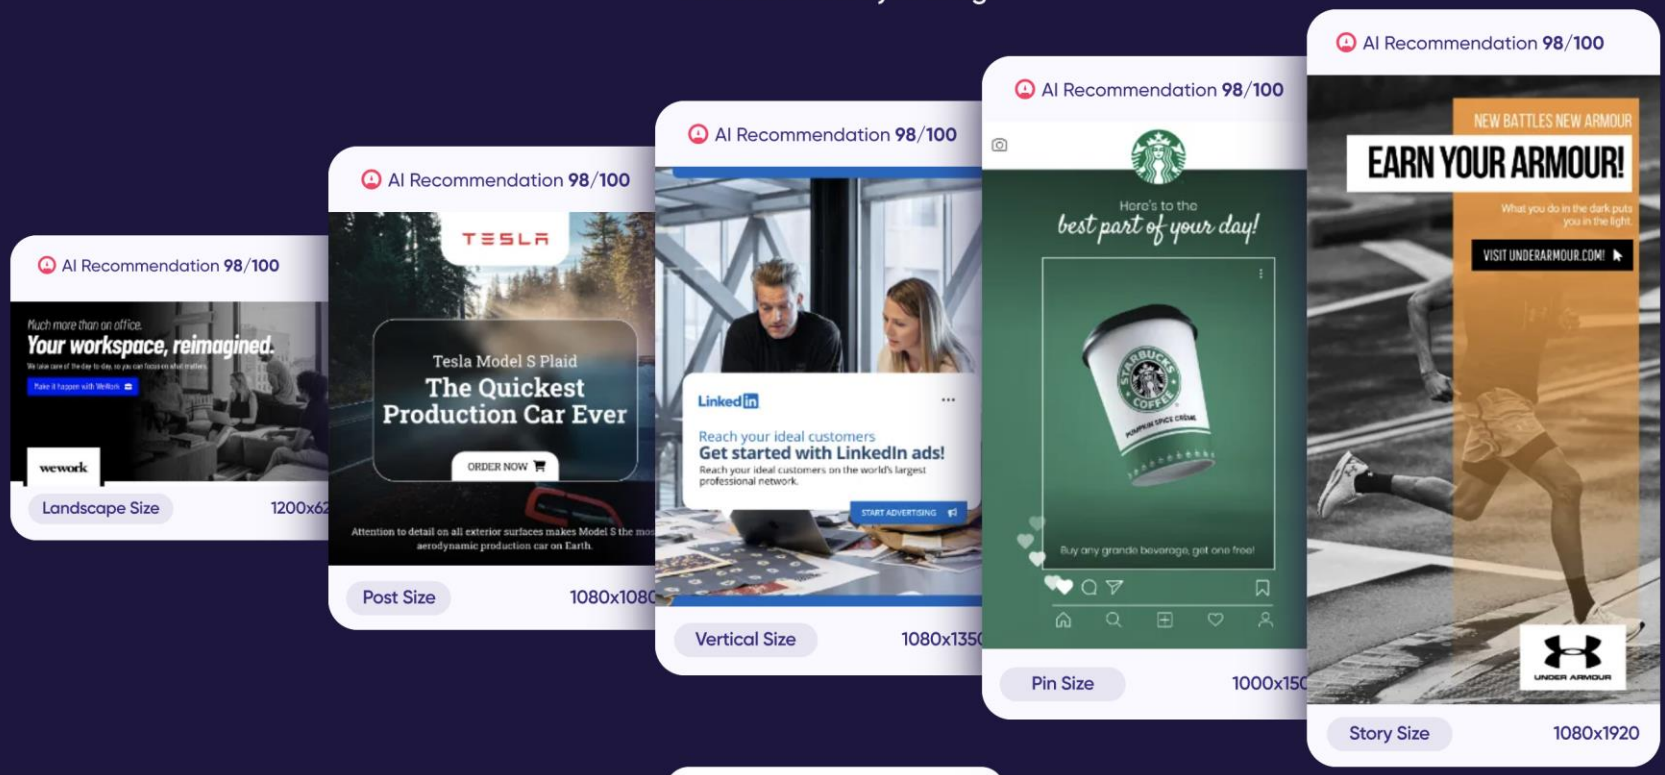
Niestety, pomimo ponadprzeciętnych efektów końcowych generowanych obrazów i kreatywności równej człowiekowi, na w pełni zautomatyzowany proces produkcji przyjdzie nam jeszcze poczekać. **Problemy do rozwiązania to prawa autorskie do wygenerowanych obrazów, brak naruszania praw innych twórców (np. poprzez wykorzystanie choćby małego fragmentu obcej pracy). No i „wstrzykiwanie” opisów produktów, logotypów i tym podobnych elementów. Jednak to kwestia raczej kilku lat niż dekad, kiedy zobaczymy gotowe systemy zintegrowane z ekosystemem reklamowym i feedami produktowymi.**

W tym przypadku mówimy o pełnym generowaniu reklam tylko na podstawie opisu reklamy w języku naturalnym, a na rynku jest wiele systemów nieco mniej kreatywnych, ale bardzo skutecznych. Gdzie generują reklamy wszakże na podstawie setek szablonów lub reguł jednak sztuczna inteligencja dobiera ich zestawy parametrów na podstawie zachowania czy też cech demograficznych użytkownika oglądających. Jednym z takich systemów jest AdCreative.ai, który dzięki sztucznej inteligencji w kilka sekund generuje kreacje reklamowe i posty w mediach społecznościowych. Oczywiście reklamy są mniej „szalone” i kolorowe, jednak system dba zarówno o projekt graficzny, jak i warstwę komunikacyjną (czyli teksty reklamowe).



No Limited Onboard all your clients

Onboard all your clients, regardless of their vertical. Surprise them with your speed in ad creative design and impress them with the conversion rates you bring.



System AdCreative.ai

Źródło: <https://www.adcreative.ai/>
[dostęp: 18.01.2023]

Według producenta system przynosi nawet **14 x lepsze współczynniki konwersji** niż kreacje reklamowe zaprojektowane bez udziału AI i podejścia opartego na danych. Testując tego typu system na żywo, trudno się z nim nie zgodzić. Dobrze zaimplementowana AI w systemie reklamowym z pewnością zmaksymalizuje wszelkie konwersje w lejku sprzedażowym.



8.2

ZDROWIE

Wkraczamy do branży zwanej HealthTech. Pod tą nazwą kryją się wszystkie rozwiązania technologiczne zajmujące się zdrowiem. Mowa tu nie tylko o rozwiązaniach stricte medycznych, lecz także takich, które są związane z profilaktyką, monitorowaniem i poprawą stanu zdrowia, stanem psychicznym czy farmakologią. WHO definiuje HealthTech jako „zastosowanie uporządkowanej wiedzy i umiejętności w formie urządzeń, lekarstw, szczepionek, procedur i systemów rozwijanych w celu rozwiązania problemów ze zdrowiem i poprawy jakości życia”. W ramach HealthTechu można wyróżnić między innymi (w różnych przecięciach):

- MedTech,
- PharmaTech,
- HealthCare,
- MentalHealth,
- Tele-Health,
- mHealth – aplikacje na telefony komórkowe i urządzenia do noszenia.

Mamy więc do czynienia zarówno z analityką zdrowotną, czyli **oprogramowaniem**, które potrafi asymilować duże zbiory danych, jak i z **cyfrowymi systemami opieki zdrowotnej** takimi, jak systemy zarządzania praktyką, systemy elektronicznej opieki zdrowotnej i dokumentacji medycznej. Są tu także rozwiązania służące **wsparciu pacjentów**, np. mogące wspierać świadczenie opieki, pomagać w podejmowaniu decyzji klinicznych, CPOE (Computerized provider order entry), a nawet DICOM, czyli międzynarodowy standard przesyłania, przechowywania, wyszukiwania, drukowania, przetwarzania i wyświetlania informacji z obrazowania medycznego. Do tego dochodzą aspekty **odkrywania i produkcji leków** czy **przewidywanie wybuchów epidemii**.

Zasada ogólna jest dosyć prosta: **szybsza diagnoza i podjęcia leczenia ratują życie**. AI w wielu przypadkach potrafi przeszukać niewyobrażalne ilości danych wielu pacjentów, analizować je pod kątem odchyień od normy i pokazać przewidywane diagnozy wcześniej i szybciej, niż mógłby to zrobić lekarz. To pozwala na **skuteczniejszą klasyfikację**: kogo, kiedy i czym leczyć. Moce obliczeniowe komputera pozwalają na analizę miliona różnych cech u milionów chorych na raz. Dlatego jest duża szansa na to, że system odkryje zależności, proponując na ich podstawie diagnozę i rozwiązania.

To były przewagi AI. Natomiast podstawowym wyzwaniem jest brak danych medycznych lub ograniczenia prawne w wykorzystaniu tych danych. Jest to bariera, którą firmy takie jak IBM już starają się pokonać. Warto zauważyć, że chociaż systemy stosowane w sektorze opieki zdrowotnej mogą pod pewnymi względami przewyższać ludzi-specjalistów, stanowią raczej uzupełnienie i pomoc w podejmowaniu decyzji przez ludzi.



Rozwiązania AI są aktualnie i z powodzeniem stosowane w wykrywaniu nowotworów poprzez zautomatyzowane przetwarzanie obrazu. Algorytm uczy się cech wizualnych związanych z poszczególnymi chorobami, takimi jak różne formy raka, a następnie dokonuje odpowiedniej prognozy lub diagnozy na bazie dostarczonych obrazów. Co ważne, **image recognition** stosowany przez AI **jest skuteczniejszy** niż odczytywanie prześwietleń RTG, USG, tomografii przez człowieka. Algorytm dzieli obraz na piksele i analizuje dokładnie każdy piksel. Dlatego zdarza się coraz częściej, że diagnozy postawione przez algorytmy **już przewyższają diagnozy postawione przez ekspertów.** Dzięki precyzyjnej analizie obrazu pacjent nie jest narażony na dodatkowe biopsje, w celu określenia, czy guz jest łagodny, czy złośliwy. Algorytmy deep learning mogą być również używane do wykrywania nowych guzów i określania zmian w wielkości guza. Dzięki temu lekarze są dobrze poinformowani przed określeniem planu leczenia dla pacjenta.

Zdolność AI do precyzyjnej analizy obrazu jest także wykorzystywana szerzej, nie tylko w onkologii. **Algorytmy mogą być używane do klasyfikowania zdjęć rentgenowskich od krytycznych do prawidłowych.** W Wielkiej Brytanii dziennie wykonuje się około 330 000 zdjęć rentgenowskich, każde wymaga sporządzenia raportu radiologicznego. Zastosowanie AI w tym przypadku pomaga określić, które RTV są najpilniejsze i wymagają natychmiastowej uwagi. Pozwala to również znacznie zmniejszyć obciążenie radiologów poprzez identyfikację zdjęć rentgenowskich bez nieprawidłowości. A to znaczy, że radiologom zostaje skupienie się na problematycznych przypadkach, skoro AI już zaklasyfikował wszystkie poprawne prześwietlenia (Radiological Society of North America, 2019). **Dodatkowo AI potrafi po analizie obrazu od razu typować prawdopodobne choroby.** Taka analiza pomaga lekarzom czytać i dokładnie interpretować raporty radiologiczne i wybrać najlepszy plan leczenia dla pacjenta.

Wraz z pojawieniem się **skanów MRI** (obrazowania metodą rezonansu magnetycznego) lekarze zyskali możliwość wizualizacji i oceny ilościowej przepływu krwi w ludzkich naczyniach krwionośnych. Dodając do tego możliwości algorytmów opartych na deep learning do przetwarzania dużych ilości danych i to z dużą dokładnością, można przeprowadzić diagnozę choroby sercowo-naczyniowej w dużo krótszym czasie niż dotychczas. Wykazano, że inne algorytmy głębokiego uczenia wykrywają cukrzycę u pacjentów z **dokładnością nawet 90%**, więc AI wykrywa cukrzycę znacznie skuteczniej niż człowiek (Ali, 2018).

Podobnie dzieje się z innymi chorobami, jak np. sepsa. **System TREWS** (Targeted, Real-Time Early Warning System) wprowadzony w 5 szpitalach w USA monitorował dane 590 736 pacjentów. W przypadku 6877 włączył alert związany z dużym prawdopodobieństwem sepsy. Po uwzględnieniu tych informacji przez lekarzy i zastosowaniu leczenia, pacjenci w tej grupie, mieli zmniejszony wskaźnik śmiertelności

(<https://www.nature.com/articles/s41591-022-01894-0>).

W Polsce możemy się pochwalić AI, który rozpoznaje epilepsję. Znana na świecie klinika **Neurosphera** rozwija własny system wyposażony w narzędzia sztucznej inteligencji wspomagające samokontrolę pacjenta i wstępną diagnozę dla lekarzy. Ta placówka wykorzystuje „Neuroterminal” jako pierwszy na świecie kompleksowy system komputerowego wsparcia diagnostyki i terapii padaczki. System prowadzi stałą aktualizację historii choroby oraz zdarzeń pacjenta, a następnie – dzięki zaawansowanym narzędziom, zestawienia wyników z najnowocześniejszą wiedzą medyczną i międzynarodowymi zaleceniami eksperckimi – może postawić diagnozę oraz dobrać terapię. Oczywiście nie zastępuje lekarzy, ale jest nieocenionym wsparciem w analizie tysięcy zmiennych. Inicjatorem i pomysłodawcą projektu jest dr n. med. Piotr Zwoliński, a za programowanie i wdrażanie systemu odpowiedzialny jest z kolei cybernetyk płk. dr inż. Mariusz Chmielewski.

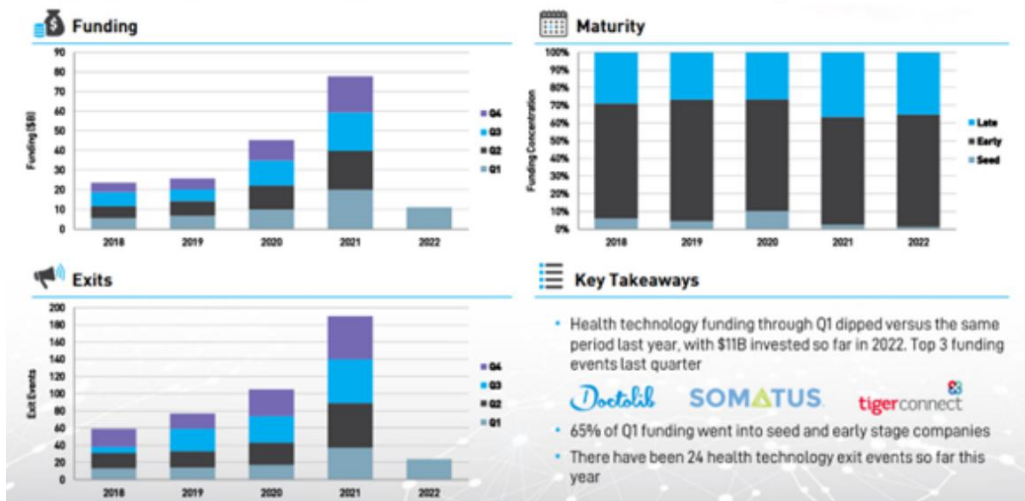
W branży dużo uwagi poświęca się teraz rozwiązaniu binah.ai.

To platforma danych oparta na sztucznej inteligencji, wykorzystująca **rozwiązania wideo**. Twórcy tego rozwiązania podkreślają, że AI łatwo integruje się z dowolną aplikacją, aby umożliwić pomiar szerokiego zakresu parametrów zdrowotnych przy użyciu wyłącznie smartfona, tabletu lub laptopa. **Dostarczana jako Binah SDK (Software Development Kit) mierzy ciśnienie krwi, tętno, zmienność rytmu serca, saturację tlenem, częstość oddechów, stres współczulny, aktywność układu przywspółczulnego i współczynnik oddechu tętna.** Większość tych danych odczytuje dzięki mechanizmom **image recognition**. Po prostu patrząc na kamerę urządzenia w czasie krótszym niż jedna minuta, system mierzy różnorodne parametry zdrowotne. Nie trzeba biec do lekarza czy wyciągać ciśnieniomierza, by poznać podstawowe parametry naszego organizmu. Celem rozwiązania jest dostarczenie nam indywidualnego wyniku dobrego samopoczucia i stały monitoring.

Według Venture Scanner startupy zajmujące się Health Tech są jednymi z najczęściej powstających i finansowanych. W Q1 tego roku w ten sektor zainwestowano 11 miliardów dolarów (<https://www.venturescanner.com/wp-content/uploads/Q1-2022-Health-Technology-Summary-Card-Image.pdf>).

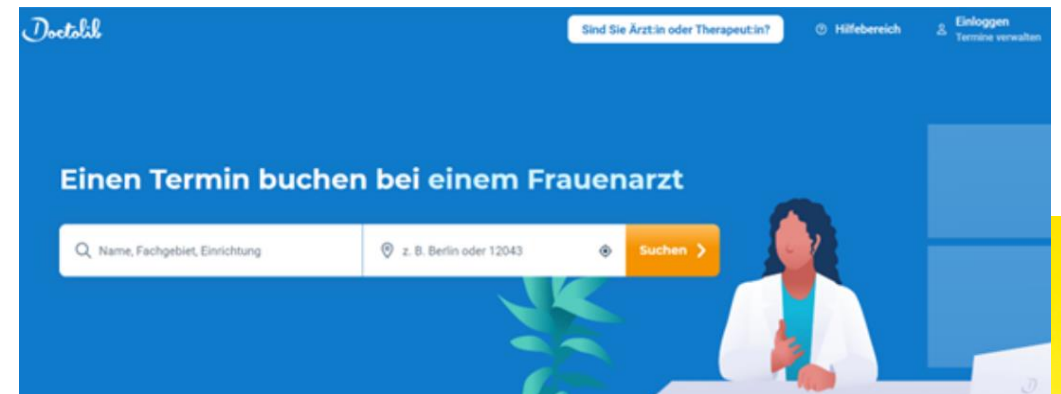
Trzy firmy najchętniej finansowane to: Doctolib, Somatus, Tigger Connect.

Health Technology Q1 Summary



Doctolib to platforma łącząca pacjentów z lekarzami. Korzysta z niego **70 000 lekarzy i 1400 instytucji medycznych** we Francji i Niemczech. Każdy pracownik służby zdrowia płaci 109 euro miesięcznie za dostęp do usługi. Firma twierdzi, że to rozwiązanie pozwala zaoszczędzić czas: nie musisz już stale podnosić telefonu i mówić, kiedy jesteś dostępny, a kiedy nie. **Wszystko pozostaje zsynchronizowane między publiczną witryną internetową a Twoim kalendarzem.**

Dotyczy to zarówno wizyt osobistych, jak i usług telemedycznych. Po skonfigurowaniu usługi pacjenci mogą rozpocząć wideoczat z lekarzem. Po wykonaniu połączenia płacą na stronie internetowej Doctolib. Następnie mogą uzyskać dostęp do recept na swoich kontach użytkowników.



Somatus to z kolei AI skoncentrowany na opiece nad pacjentami z chorobami nerek lub z ryzykiem do rozwoju takich chorób.

Firma działa w kilku zakresach: edukacji, narzędzi, autorskiej technologii oraz zapewnieniu dializ. Skala tego przedsięwzięcia jest naprawdę duża, biorąc pod uwagę szacunki, które mówią, że w USA na choroby nerek cierpi 370 milionów mieszkańców, choć duża ich część nie zdaje sobie z tego sprawy lub nie ma właściwej diagnozy.

SOMATUS
REVOLUTIONIZING KIDNEY CARE

HOME PARTNER PATIENTS ABOUT US CAREERS CONTACT US

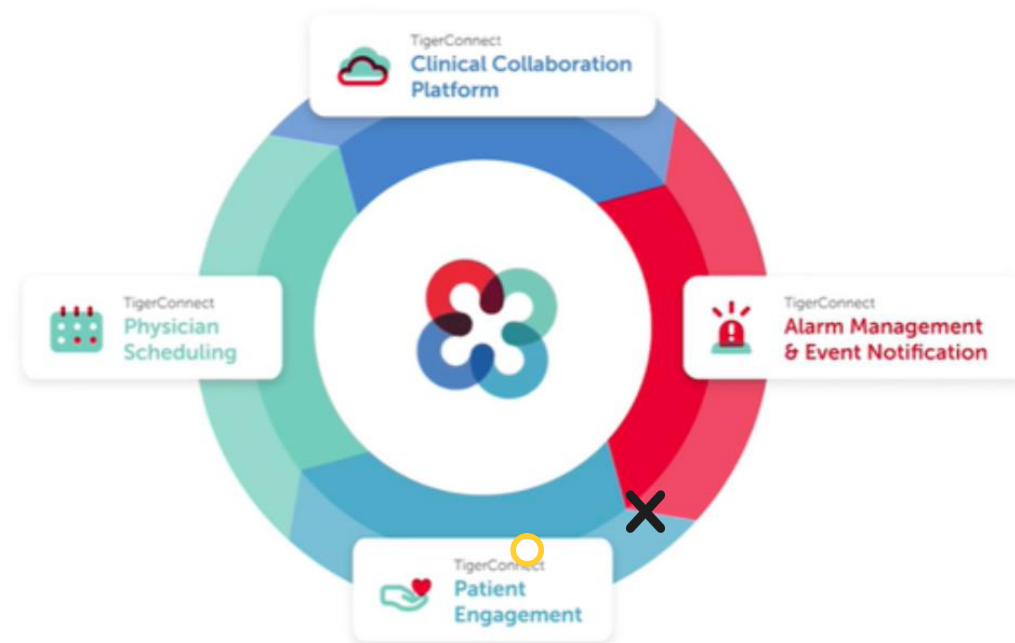
Connected kidney care delivered where it's needed most.

- Field-Based Care**
Evidence-based clinical interventions, education, support, and coaching delivered locally by a team of renal clinicians and operational experts.
- Network Engagement**
Expertise, tools, and data-driven insights needed to drive behavior change, improve quality, and establish mutually beneficial partnerships.
- RenallIQ™ Technology Deployment**
Advanced analytics, predictive methodologies, business intelligence dashboards, and clinical workflows housed in our proprietary technology platform to focus providers, plans, and field team efforts on high impact interventions.
- Dialysis Provisioning**
Value-driven strategies and tailored approaches to dialysis care structured and executed based on market dynamics and population acuity.



Ostatni z wielkiej trójki inwestycyjnej to TiggerConnect, czyli rozwiązanie oparte na chmurze.

Służy jako narzędzie do komunikacji klinicznej i jest skierowane do rynku lekarzy, pielęgniarzy, kadry kierowniczej firm i zespołów IT szpitali czy klinik. Obsługuje szpitale, hospicja, kliniki etc. Umożliwia wysyłanie informacji o pacjencie i innych bezpiecznych wiadomości zgodnie z HIPAA (The Health Insurance Portability and Accountability Act). Jego zadaniem jest ujednoczenie i integracja komunikacji w wielu działach i lokalizacjach w celu zmniejszenia kosztów oraz ryzyka. Hasło firmy mówi: *Tam, gdzie ma miejsce współpraca zespołu medycznego, komunikacja z pacjentem kwitnie, a informacje są zawsze na wyciągnięcie ręki.*



8.3

E-COMMERCE

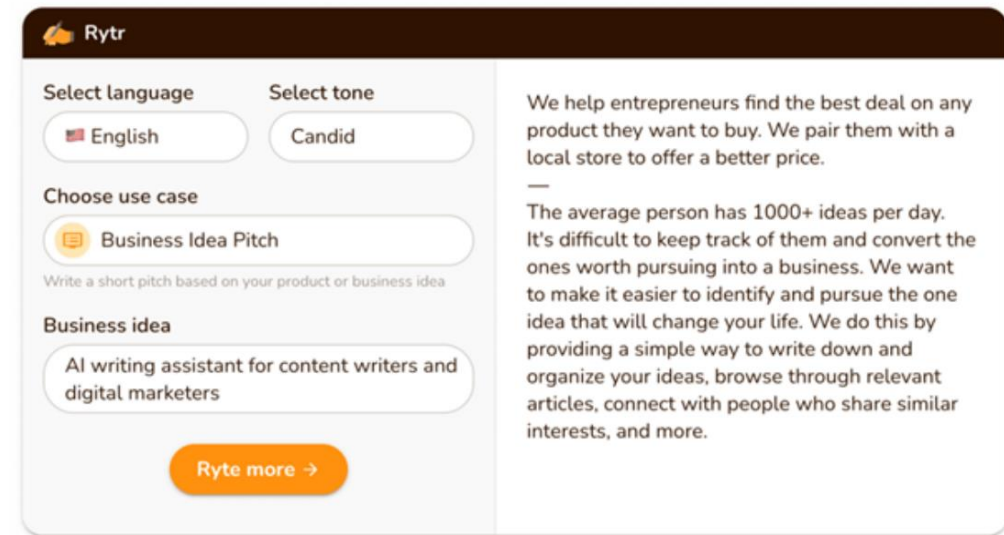
Branży e-commerce nie trzeba chyba nikomu definiować i przedstawiać. Transformacja cyfrowa, a bardziej potrzeby internautów spowodowały, że kategoria po kategorii tradycyjny handel przenosi swoje produkty do Internetu – od książek, zabawek, kosmetyków, ubrań po kosiarki, szpadle i świece. Ponadto pojawiły się zupełnie nowe produkty XXI wieku inkrustowane złotem wirtualne miecze obosieczne czy e-booki, audiobooki i dostęp do telewizji na żądanie.

Zasady zostały niezmiennic: sklepy powinny przyciągać nowych klientów, dbać o nich, być na uczciwej marzy. Różnica: klient jest bardziej nielojalny, bo zmiana sklepu na inny to tylko 10 sekund. **W czym może pomóc AI?** W targetowaniu reklamy sklepu online, wirtualnej obsłudze, wyszukiwaniu, prezentacji produktów, zakupie. Terabajty danych opisujących zachowania i preferencje klientów dają pole do popisu dla sztucznej inteligencji. Przyjrzyjmy się więc kilku ważnym procesom zachodzącym we współczesnym e-commerce.

Automatyczne generowanie opisów produktów i wsparcie SEO

Jak zapewne wiesz **SEO** (Search Engine Optimization), czyli pozycjonowanie, to działania mające na celu zwiększenie widoczności sklepu i jego produktów w wynikach wyszukiwarek internetowych, dla konkretnych słów kluczowych, takich jak „dobry chleb” czy „tani rower dla 5-letniej córki”. Oczywiście zakres tych działań jest szeroki i czasem jest to wiedza tajemna ekspertów, ale nie da się ukryć, że opis produktu jest jednym z najważniejszych elementów skutecznego pozycjonowania. Dodatkowo bardzo często, zwłaszcza w produktach spożywczych szybko zbywalnych, producenci podają nazwę, a jeśli ktoś jest ciekaw szczegółów, może przeczytać skład.

AX Semantics to oprogramowanie, które wykorzystuje generowanie języka naturalnego (**NLG**), aby pomóc firmom e-commerce generować tysiące unikalnych i zoptymalizowanych pod kątem SEO opisów produktów w skalowalny sposób, poprzez automatyzację powtarzalnych części procesu pisania. Co ciekawe umożliwia również personalizację wygenerowanego opisu w czasie rzeczywistym.




AI Writing Assistant w akcji

Źródło: <https://writertag.com/ai-writing-software/> [dostęp 01.09.2022]

Dodatkowo niemal każdy e-sklep posiada własny blog, dzięki czemu za pomocą dodatkowych treści można przekonać potencjalnych klientów do zakupu. Tutaj marketer ma większe możliwości pod SEO, bo na blogu są to dłuższe publikacje, gdzie można opisać wiele produktów, używając wielu ciekawych fraz. **Dostawcy narzędzi SEO połączyli siły z AI i zaczęły pojawiać się jak grzyby po deszczu dedykowane edytory** (ang. **AI writing assistant**) <https://www.g2.com/categories/ai-writing-assistant>. Zasada jest prosta, pracownik e-sklepu w specjalnym edytorze pisze tekst o danym produkcie, AI analizuje wpisywane słowa i proponuje frazy o większym potencjale SEO. Dodatkowo bardziej zaawansowane narzędzia sprawdzają styl i gramatykę. Kiedy tekst będzie gotowy, narzędzie podaje finalny scoring SEO, oceniając tym samym potencjał danego tekstu pod kątem wyszukiwania.


Systemy rekomendacyjne

W tradycyjnym sklepie bardzo często obok są osoby, które szybko coś mogą doradzić lub zarekomendować. Może to być **przyjaciółka z którą wybraliśmy się na zakupy, mąż, żona czy też ekspedientka**. W e-sklepie najczęściej jesteśmy sami i rolę doradcy bardzo często przejmują **systemy rekomendacyjne**: zobacz, co inni jeszcze kupili, podobne produkty czy też uzupełniające, np. polecamy kawior do szampana umieszczonego już w wirtualnym koszyku. **Systemy rekomendacyjne generują w sklepach nawet do 40% dodatkowej sprzedaży**. Początkowo systemy rekomendacyjne opierały się na prostej statystyce tj. „tę książkę kupili/widzieli również”. Jednak rozwój AI, a także coraz lepiej opisanych produktów i mozolnie budowanych profili użytkowników spowodował, że e-commerce sięgnął po coraz mocniejsze i głębsze modele uczenia maszynowego. Na dzisiaj systemy rekomendacyjne potrafią już np. odkrywać nisze i rekomendować produkty nie tylko popularne (bestsellery), a także produkty lepiej dopasowane do użytkownika. Problemem do rozwiązania jest liczba danych „wchodzących” w proces rekomendacji. Tym bardziej, że w sklepach typu marketplace niewyspecjalizowanych, liczba produktów jest liczona w dziesiątkach, a nawet setkach milionów, podobnie liczba użytkowników odwiedzających sklep. Przykładowo **YouTube** używa bardzo zaawansowanych modeli głębokiego uczenia i biblioteki **TensorFlow** (stworzona bez zespół Google Brain) o miliardowej liczbie parametrów i uczonych na setkach miliardów przykładów filmów wideo.



Zasada działania systemu rekomendacji opartego o cechy produktu (ang. content-based filtering)

Źródło: <https://www.be-terna.com/insights/recommendation-systems-in-e-commerce-whats-the-thing-youve-never-known-but-always-wanted-to> [dostęp: 02.09.2022]



Zasada działania systemu rekomendacji opartego na filtrowaniu grupowym (zespołowym, ang. collaborative filtering)


Źródło: <https://www.be-terna.com/insights/recommendation-systems-in-e-commerce-whats-the-thing-youve-never-known-but-always-wanted-to> [dostęp: 02.09.2022]

Wyszukiwanie wizualne i asystenci głosowi

Nie dziwi, że chcielibyśmy, aby system rozpoznawał na podstawie zdjęcia osoby (np. celebrytki), co ma na sobie i mówił nam, gdzie to możemy kupić. Albo, aby lustro w przymierzalni dopasowało nam dodatki do przymierzonej sukienki. A może ja jako konsument opowiem, o co mi chodzi do asystenta głosowego w moim samochodzie, że potrzebuję na szybko białej koszuli do garnituru? Zatem system/algorytm powinien na podstawie zdjęcia lub mowy rozpoznać produkt i jego cechy, a następnie wyszukać dopasowane oferty ze wszystkich (lub wybranych) sklepów na rynku. Zatem w e-commerce angażujemy computer vision, speech recognition i wiele innych algorytmów uczenia maszynowego (zwłaszcza głębokiego).


Wizualna wyszukiwarka na Pinterest

Źródło: <https://medium.com/syncedreview/visual-search-is-revolutionizing-e-commerce-b27a37dbd296>



Eksperti mówią zgodnie, że wyszukiwanie wizualne rewolucjonizuje handel elektroniczny zwłaszcza w kategoriach moda, wyposażenie wnętrz, dom i ogród. Nie byłoby to możliwe bez uczenia maszynowego, a zwłaszcza konwolucyjnych sieci neuronowych.

Top Pinterest Visual Lens Categories



Najbardziej popularne kategorie w wyszukiwaniu wizualnym Pinterest

Źródło: <https://medium.com/syncedreview/visual-search-is-revolutionizing-e-commerce-b27a37dbd296>


Prognozowanie popytu i dynamiczne ustalanie cen (ang. dynamic pricing)

Dla właściciela e-sklepu czy producenta kluczowe jest pytanie, jaka powinna być cena produktu i ile tych produktów wyprodukować czy też sprowadzić do magazynu. Jeśli popyt jest bardzo wysoki, a analiza konkurencji pokazuje nam, że produkt o podobnych cechach jest w cenie 10 zł, to może ustalmy cenę 4 zł (o ile marża na to pozwala) i sprzedajmy ogromne liczby produktu (czyli pozyskajmy nowych użytkowników), albo ustalmy cenę 9,5 zł i sprzedajmy produktów mniej, ale o godziwej marży. Strategii i czynników zewnętrznych jest wiele, np.: liczba produktów konkurencyjnych, parametry makroekonomiczne, pogoda, nastroje społeczne itp.

Dlatego nie ma lepszego zautomatyzowanego wspomagacza podejmowania decyzji niż AI. Taki asystent w ramach dynamicznego ustalania cen podpowie nam, że np. ta konkretna cena może zwiększyć szansę na wygenerowanie większego przychodu, podczas gdy tak zachowa się liczba konsumentów i wszystkie koszty (stałe i zmienne).




Poniższy wykres przedstawia uproszczony model dynamicznego ustalania cen. Po lewej stronie widzimy jedną statyczną cenę niezależną od popytu i czynników zewnętrznych. Wyobraźmy sobie, że sprzedajemy krem do opalania. Są wakacje, pogoda jest piękna i wszystkie prognozy długoterminowe zapewniają, że będzie tak jeszcze przez 14 dni. Można więc żądać wyższej ceny, bo popyt jest bardziej cenowo nieelastyczny. Z drugiej strony, gdy pogoda jest trochę gorsza, albo jesteśmy przed wakacjami, wtedy sklep mógłby zaoferować rabat, aby zachęcić do większej konsumpcji. Ogólnie rzecz biorąc – firma zwiększa przychody.



Uproszczony model dynamicznej ceny

Źródło: <https://www.economicshelp.org/blog/148008/economics/dynamic-pricing/>

W 2021 roku według SearchNode (Nosto) **ponad 21%** sklepów w Ameryce i Europie używa już technologii dynamicznego ustalania cen.



Dynamiczne ustalanie cen to potężne narzędzie. Wymaga jednak szczególnej uwagi podczas wdrożenia, co nie zmienia faktu, że w ciągu najbliższych kilku lat procent jego wykorzystania w e-sklepach pójdzie ostro w górę. Gdy dodamy z powyższego wykresu grupę wciąż testującą i myślącą o przyszłym wdrożeniu, liczba ta robi wrażenie. Cóż, i zarówno technologia się rozwija, jak i dostawcy systemów do dynamicznego ustalania cen nie próżnują.

Źródło: <https://www.vaimo.com/dynamic-pricing-in-ecommerce-how-it-works/>

Customer Data Platform

Pamiętajmy, że skuteczność algorytmów uczenia maszynowego zależy od danych. Jeśli dane będą odpowiedniej jakości, wolumetrii, a także prawidłowo przygotowane do uczenia to możemy być pewni, że predykcje algorytmu będą służyć dobrze naszemu e-biznesowi. Dlatego oprócz wdrożenia samego AI, warto jest wcześniej wdrożyć odpowiednie narzędzie i strategie dotyczących generowanych danych przez sklep.

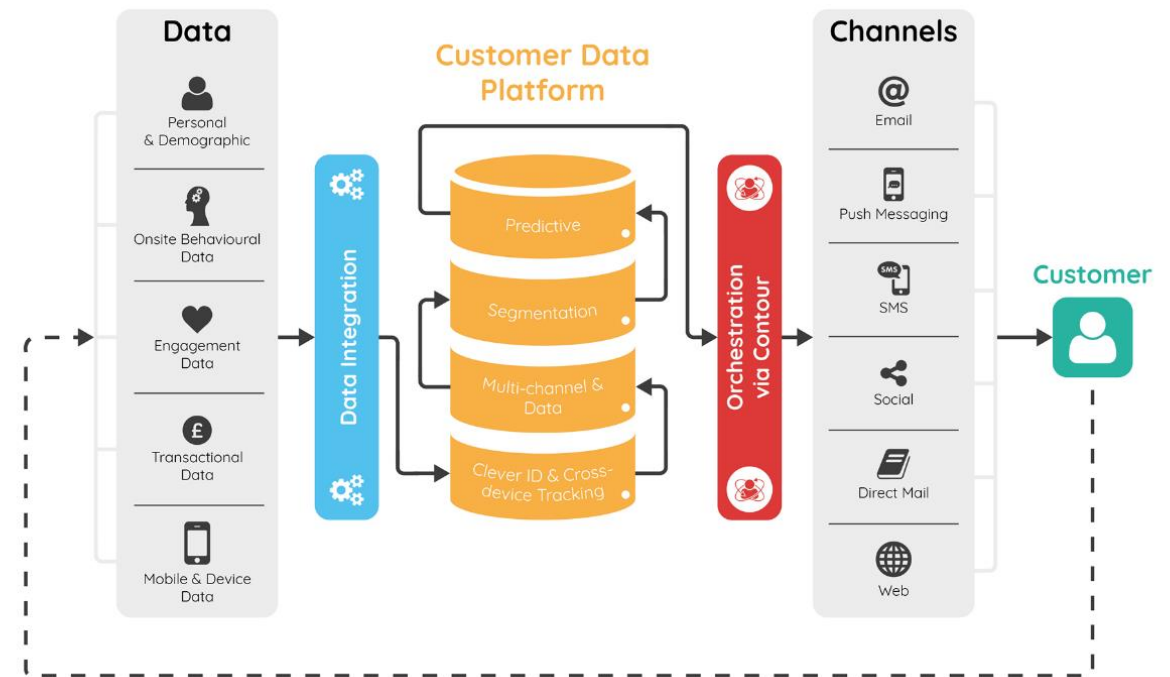
Customer Data Platform to jeden z najważniejszych trendów, o dużej mocy sprawczej w maksymalizacji przychodów e-sklepu, bo jest „paliwem” m.in. dla systemów rekomendacji czy personalizacji. Platforma ta jest bazą danych (a bardziej wiedzy) o klientach, udostępnianych innym systemom. Taki CRM w formie API dla innych systemów, z dużą dawką AI na pokładzie: segmentacja, automatyczna klasyfikacja, ekstrakcja cech klientów np. z przeczytanych artykułów.

Dane źródłowe do CDP powinny być zbierane ze wszystkich źródeł, tj. portali społecznościowych, witryn i blogów sklepu, stron landing page, e-sklepu, m-sklepu czy stron partnerów. Następnie dane są oczyszczane, klasyfikowane (np. zachowanie), wzbogacane o dane zewnętrzne (np. o dane demograficzne, mikroekonomiczne), po czym przeprowadzana jest predykcja danych mających wpływ na sprzedaż (np. wrażliwość na promocję, nowinki, cenę).

Tak ujednoczone profile klientów są udostępniane (najczęściej w postaci API) **innym systemom** — np. systemom mailingowym, systemom notyfikacji aplikacji mobilnych, programom rekomendacyjnym i serwerom reklamowym.

Klasyczna architektura systemów CDP

Źródło: <https://www.element61.be/en/competence/customer-data-platform-cdp>



Według portalu **MarketsandMarkets.com** rynek systemów CDP został wyceniony na **3,5 mld dolarów w 2021 roku**. Głównymi czynnikami napędzającymi globalny rynek platform danych o klientach są zwiększone wydatki przedsiębiorstw na działania marketingowe i reklamowe, zmieniający się krajobraz informacji o klientach oraz powiększanie się liczby kanałów klientów.



Wartość rynku systemów CDP i prognoza na rok 2026

Źródło: <https://www.researchandmarkets.com/reports/5438512/customer-data-platform-market-with-covid-19> [dostęp: 02.09.2022]



Na uwagę zasługuje fakt, że w Polsce grupa programistów stworzyła zaawansowany system CDP z otwartym kodem, który można wykorzystać do zbierania danych e-commerce dla celów uczenia maszynowego. Tracardi (<https://tracardi.com/>) automatyzuje proces zbierania z różnych źródeł, przetwarzania, wzbogacania oraz grupowania danych o klientach. Korzystanie z systemu nie wymaga zdolności programistycznych, gdyż funkcjonuje w modelu **low-code/no-code**.



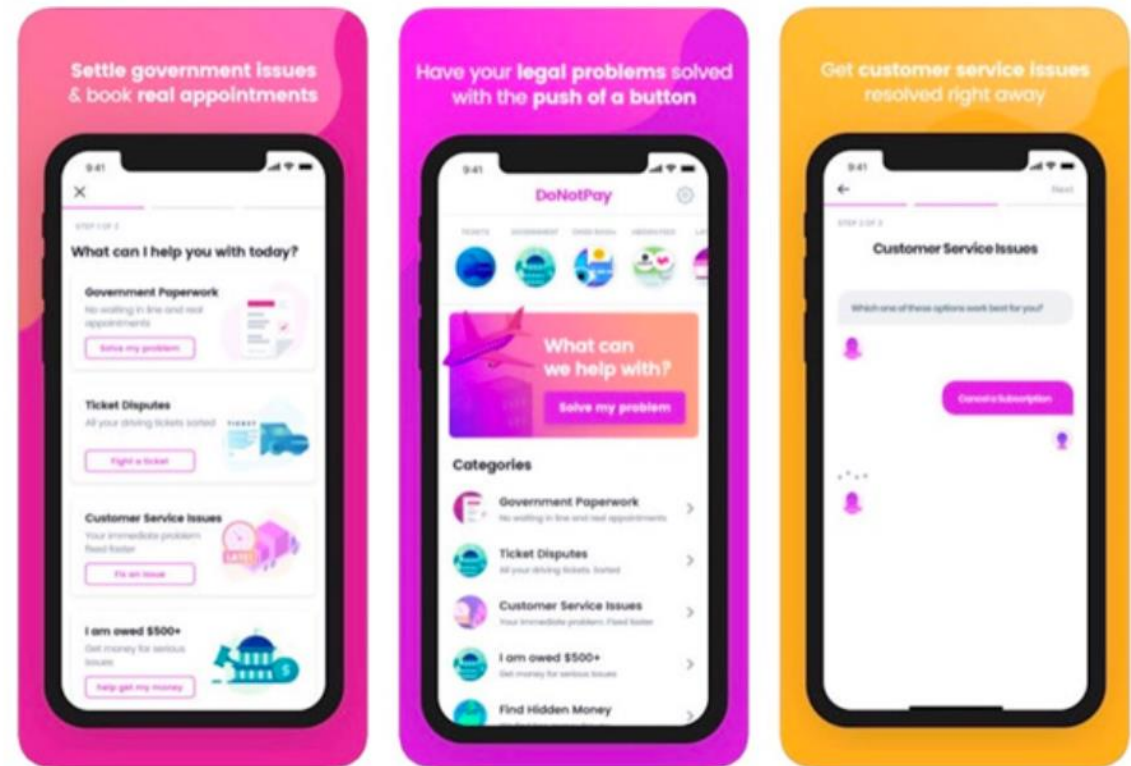
8.4

PRAWO

Jak każdy sektor biznesu, także obszar prawa doczekał się własnej kategorii **Tech**, czyli **LegalTech**. Zatem **Legaltech** to wszelkie narzędzia informatyczne wykorzystywane w branży prawnej przez prawników. Są to zarówno narzędzia wykorzystywane powszechnie (np. edytory tekstu, e-mail) jak i narzędzia specjalistyczne (np. zarządzanie kancelarią, bazy informacji prawnej). No i właśnie w tych narzędziach jest potężne pole do implementacji i wykorzystania sztucznej inteligencji. Wśród technik AI prym wiedzie przetwarzanie i generowanie języka naturalnego (dyrektywy, ustawy, umowy i procedury), ale jak każda branża bez twardych liczb również się nie obejdzie (np. prognozowanie, regresja itp.).

Przegląd firm z branży LegalTech wspieranych przez AI rozpoczniemy od bota reklamowanego jako „**pierwszy na świecie robot-prawnik**”. Stworzony przez Joshuę Browdera w 2015 roku robot o nazwie **DoNotPay** w swojej pierwszej wersji służył do odwoływania się od spraw o mandaty parkingowe. **Aplikacja, w ciągu 21 miesięcy od uruchomienia darmowej usługi w Londynie i Nowym Jorku, złożyła ponad 250 tys. spraw o cofnięcie mandatu parkingowego i wygrała 160 tys. co daje jej wskaźnik wygranych na poziomie 64%, o wartości ponad 4 mln dolarów.**

Po licznych inwestycjach w firmę i bardzo dużym sukcesie medialnym, aplikacja „zajmuje się” szeregiem innych spraw z dziedziny prawa i można go już nazwać „roboto-prawnikiem”.




Aplikacja mobilna DoNotPay - pierwszy na świecie prawnik-robot

Źródło: <https://www.dailydropout.fyi/drops/donotpay> [dostęp: 22.08.2022]

W branży prawniczej w codziennej pracy prawnika istnieją procesy, które charakteryzują się ręcznym przetwarzaniem ton dokumentów.

Mowa tu o tzw. **due diligence** oraz procesie e-discovery, czyli zbieraniu, przetwarzaniu i prezentowaniu dowodów elektronicznych, czyli takich, których podstawą są informacje przechowywane elektronicznie. Zarówno due diligence, jak i e-discovery to idealne obszary do automatyzacji dzięki sztucznej inteligencji – od przetwarzania języka naturalnego po uczenie maszynowe.

Brytyjska firma Luminance stworzyła najbardziej zaawansowane oprogramowanie wykorzystujące AI do analizy i przetwarzania dokumentacji prawnej, od automatyzacji tworzenia, negocjowania i przeglądania umów, po wsparcie procesów due diligence i e-discovery.



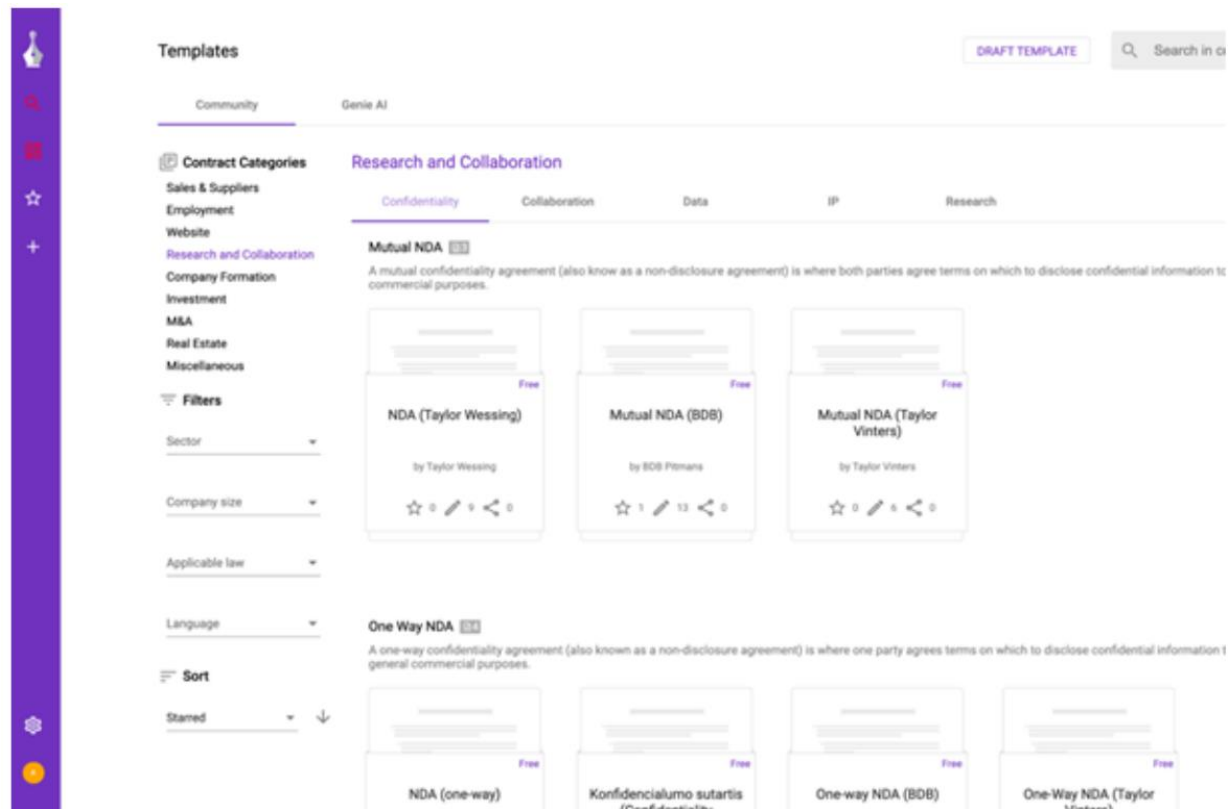
Luminance - AI-powered eDiscovery Platform

Źródło: <https://www.luminance.com/> [dostęp: 22.08.2022]

Kto z nas w firmie nie potrzebował prawnika do przeanalizowania umowy otrzymanej od potencjalnego partnera biznesowego lub do zaproponowania umowy dla potencjalnej transakcji. Oczywiście, nie ma co oszczędzać na umowie inwestycyjnej firmy czy podczas fuzji lub przejęcia. Czy jednak każda prosta umowa NDA lub umowa kupna, sprzedaży, zlecenia wykonania prac wymaga fizycznego prawnika? **Co powiecie na zatrudnienie robota AI, który może pracować 24/7 przy bardzo niskim ryczałcie miesięcznym?**

Taki robot został stworzony przez firmę <https://www.genieai.co/>. **Genie AI** dostarcza roboty, które specjalizują się w przeglądaniu i ocenie umów prawnych, a także tworzeniu umowy z wykorzystaniem formularzy przygotowanych przez doświadczonych prawników.

Co ciekawe, im więcej osób korzysta z systemu, tym lepsze umowy są tworzone, bo w zanonimizowany sposób wiedza przepływa między prawnikami czy firmami i zasila bazę wiedzy dla AI.



The screenshot displays the 'Templates' section of the Genie AI platform. On the left, there is a vertical navigation bar with icons for home, search, favorites, and a plus sign. The main content area is titled 'Templates' and includes a search bar and a 'DRAFT TEMPLATE' button. Below this, there are tabs for 'Community' and 'Genie AI'. The 'Contract Categories' list includes Sales & Suppliers, Employment, Website, Research and Collaboration (selected), Company Formation, Investment, M&A, Real Estate, and Miscellaneous. A 'Filters' section allows users to filter by Sector, Company size, Applicable law, and Language. A 'Sort' section is set to 'Starred'. The main content area shows 'Research and Collaboration' templates, including 'Mutual NDA' and 'One Way NDA'. Each template card displays the title, author, and a 'Free' label. The 'Mutual NDA' section includes a definition: 'A mutual confidentiality agreement (also known as a non-disclosure agreement) is where both parties agree terms on which to disclose confidential information to commercial purposes.' The 'One Way NDA' section includes a definition: 'A one-way confidentiality agreement (also known as a non-disclosure agreement) is where one party agrees terms on which to disclose confidential information to general commercial purposes.'

Genie AI

Źródło: <https://www.genieai.co/> [dostęp: 30.08.2022]

Ostatni business case dotyczy polskiego rynku. Jest bardzo LegalTechowo innowacyjny, nazywa się **inteliLex**. Pomysł na system powstał na międzynarodowym konkursie programistycznym, czyli **Global LegalTech Hackathon** i zdobył pierwsze miejsce w Polsce. Jak działa narzędzie?

Użytkownik (prawnik) wpisuje kilka pierwszych słów pisma prawnego, a algorytm AI w czasie rzeczywistym podpowiada następne słowa lub sentencje, kończąc za niego fragment pisma na podstawie historycznych pism.


Produkt dobrze wpisuje się w trend aplikacji określanych jako **AI Writing Assistant** (oprogramowanie wspomagające pisanie wspierane AI).

Według Growth Market Reports, globalny rynek tego typu oprogramowania ma osiągnąć **1035 milionów dolarów do 2030 roku**, przy CAGR (skumulowany roczny wskaźnik wzrostu, ang. compound annual growth rate) na poziomie 15%.



inteliLex AI-owa wtyczka do edytora tekstu

Źródło: <https://radcaprawny.kirp.pl/archiwum/nowe-technologie/intelilex-czyli-jak-rozwiazanie-technologiczne-usprawnia-prace-prawnika/> [dostęp: 30.08.2022]



8.5

DOBRO SPOŁECZNE

Rozwiązania z zakresu AI można doskonale wykorzystać także dla dobra. Powstała nowa dziedzina badań nazwana AI4SG (AI for social good), która koncentruje się na rozwiązywaniu ważnych problemów społecznych, środowiskowych i zdrowia publicznego. Celem jest wykorzystanie i rozwój sztucznej inteligencji po to, by poprawić dobrostan świata.

Czym jest dobrostan świata?

Cel Zrównoważonego Rozwoju wg ONZ to: brak ubóstwa, zero głodu, dobre zdrowie i dobre samopoczucie, wysokiej jakości edukacja, równość płci, czysta woda i warunki sanitarne, niedroga i czysta energia, godna praca i wzrost gospodarczy, przemysł, innowacja i infrastruktura, zmniejszenie nierówności, zrównoważone miasta i społeczności, odpowiedzialna konsumpcja i produkcja, działania na rzecz klimatu, życie pod wodą, życie na lądzie, silne instytucje służące pokojowi i sprawiedliwości oraz współpraca dla osiągnięcia celów.



Powstało już wiele rozwiązań AI, które właśnie takie idee realizują. Najczęściej AI jest zaangażowany w: **liczenie pingwinów dzięki satelitom z kosmosu** (projekt Heather Lynch, **przeciwdziałanie kłusownictwu słoni** (projekt WWF), **zapobieganie nadużywaniu używek i substancji uzależniających** (Wilder), **przewidywanie pandemii** („Global Immunological Observatory”), **analiza mediów społecznościowych w celu monitorowania zdrowia psychicznego** (Choudhury) **czy projekt Euphonia** (Google). Do tego dochodzą takie rozwiązania jak **TrollPatrol** (Amnesty International + AI for Good Element), aby wykorzystać statystyki i metody przetwarzania języka naturalnego do skwantyfikowania nadużyć wobec kobiet na Twitterze. **Shaqodoon** to z kolei sztuczna inteligencja pomagająca w aktywizacji obywateli w Somalii. Chodzi o to, by społeczność mogła w łatwy sposób wyrazić swój głos. Wprowadzono zatem interaktywną platformę, umożliwiającą obywatelom wypowiedzenie opinii na temat projektów, które ich dotyczą. Swoje stanowisko wyraża się przez nagranie głosowe. Biorąc pod uwagę fakt, że szacunkowo 65% ludności Somalii nie czyta ani nie pisze, nagrania głosowe zapewniają inkluzywny sposób zaangażowania wszystkich obywateli w rozmowę.

Jednym z ciekawszych przykładów jest organizacja **The Deep Learning Indaba** założona w celu propagowania ML i AI w Afryce. Chodziło o rozwijanie kompetencji, pewności siebie i wspieranie się programistów z Afryki. Praca przynosi efekty. Podjęte działania przyczyniły się do pozytywnej zmiany postrzegania programistów, naukowców i inżynierów z tej części świata. Jako grupa specjalistów pracują nad tworzeniem nowych zbiorów danych, badaniami nad tłumaczeniem języków afrykańskich, walką z malarią czy ochroną tamtejszej przyrody. Jedną z inicjatyw tej organizacji, podjęta we współpracy z DeepMind, polegała na stworzeniu potężnej bazy danych służącej do ochrony gatunków zwierząt zagrożonych wyginięciem.

Zebrano tysiące obrazów z fotopułapek w Serengetti, łącznie z dokładną ich geolokalizacją i godziną, aby śledzić migrację zwierząt (wzorce migracyjne). Przekłada się to m.in. na lepszą ochronę tych zwierząt przez strażników parku: wiedzą, gdzie i kiedy mają być, by ochronić dane stado. Kolejną inicjatywą Indaby były prace przeciwko malarii, podjęte wspólnie z IBM. Metody deep learningu pozwalały na predykcje, co zmniejszy prawdopodobieństwo transmisji tej choroby czy jakie będą skuteczne medyczne interwencje. Indaba współpracuje również z wieloma innymi grupami, takimi jak Data Science Africa, Black-in-AI i Women in Machine Learning i razem podejmują projekty na rzecz zrównoważonego rozwoju. Indaba opracowała też wytyczne, którymi należy się kierować. Chodzi o:

- łatwe w integracji i dostępne aplikacje,
- rozwijanie talentów, kompetencji i długoterminowe partnerstwa,
- działanie jako tłumacze między różnymi interesariuszami,
- pracę społeczności potrzebujących prostych i tanich rozwiązań,
- dzielenie się wiedzą i doświadczeniem potrzebnym do zbudowania zaufania i poparcia niezbędnego do współpracy.

Na koniec warto wspomnieć o działaniach Google (<https://ai.google/social-good/>) w ramach AI4SG. Są to między innymi: przewidywanie powodzi w Indiach i Bangladeszu, projekt Euphonia pomagający osobom z zaburzeniami mowy w byciu lepiej rozumianym dzięki metodom speech recognition czy inicjatywie Covid-19 Open Data Repository.

Jak pokazują powyższe przykłady, AI można wykorzystać do zadań związanych z ochroną przyrody, predykcją różnych zagrożeń typu powódzie, wybuchy epidemii oraz podnoszeniem jakości życia mieszkańców naszej planety.

The background features a central wireframe human head with glowing eyes, flanked by two hands holding up several data panels. The entire scene is overlaid with a large, semi-transparent yellow rectangle. A white square is positioned at the top center of this yellow area, containing the number '9.'. Below the square, the word 'PODSUMOWANIE' is written in white, uppercase letters.

9.

PODSUMOWANIE

Kilka interesujących liczb na zakończenie:

Według IDC wydatki na technologię AI wzrosną do 2024 r. do poziomu 110 mld dolarów.

Według Oxford Programme on Technology and Employment: 47% stanowisk pracy może być zautomatyzowanych.

Według raportu „AI & Skills” za 10 lat 55% pracowników w Polsce ma posługiwać się AI.

Nad Wisłą pracuje prawie 1/4 wszystkich programistów z Europy Środkowo-Wschodniej.

Sztuczna inteligencja nie zastąpi całkowicie ludzkiej siły roboczej, ale z pewnością będzie ją uzupełniać, wspierać i przejmować wybrane czynności. AI spowoduje zmianę charakteru pracy, ponieważ będzie w coraz większym stopniu realizować zadania rutynowe i powtarzalne, dając tym samym ludziom czas na pracę nad zadaniami wymagającymi inteligencji emocjonalnej, umiejętności społecznych i komunikacyjnych do pracy z innymi ludźmi.

Zdaniem badaczy automatyzacja pozwoli pracownikom skoncentrować swoją pracę na zadaniach wymagających wyższych umiejętności poznawczych. A kompetencje ludzi centaurów, rozumiejących zarówno świat AI, jak i świat ludzi, pozwolą wybrać odpowiednie narzędzie do rozwiązania konkretnego problemu. Przyszły sukces w organizacjach będzie zatem zależał od tego, czy ludzie nauczą się pracować z technologią, a nie będą się jej całkowicie opierać. **Znacząco urośnie także znaczenie umiejętności interpersonalnych i interpersonalnych w miejscu pracy.**

Wreszcie, jak podkreślono w raporcie Cisco, paradoks polega na tym, że wraz z rosnącą potężną sztuczną inteligencją nastąpi równoległy wzrost popytu na umiejętności uważane za wyłącznie ludzkie.

Poniżej zamieszczamy przydatne linki i źródła, które mogą okazać się pomocne w pogłębianiu poruszanych w tej publikacji zagadnień:

[Oxford Internet Institute's AI research](#)
[Machine Learning Research Group](#)
[The Faculty of Law's AI web page](#)
[The University of Oxford's central page dedicated to AI](#)
[Microsoft's Azure Machine Learning Studio](#)
[Mind Foundry](#)
[Machine Learning Crash Course.](#)
[Andrew Ng has a series of tutorials](#)

Najczęściej używane języki, narzędzia i pakiety:

[R i Python](#)
[Anaconda](#)
[Jupyter notebooks](#)
[Google's Colab](#)
[Kaggle](#)
<https://www.tensorflow.org/>
<https://www.tensorflow.org/install>
<https://keras.io/>
<https://jupyter.org/>
<https://developers.google.com/machine-learning/crash-course/>
<https://www.cs.ox.ac.uk/people/nando.defreitas/machinelearning/>
<http://torch.ch/>

O autorach



dr Anna Gumkowska – menedżer z wieloletnim doświadczeniem w obszarze digital i nowych technologii. Posiada umiejętności w zarządzaniu dużymi zespołami oraz transformacji cyfrowej w organizacjach. Praktyk w zakresie biznesu internetowego – optymalizacji istniejącego biznesu i rozwoju new business.

Od 15 lat „siedzi w mediach cyfrowych i robi internety”. Najpierw w Gazeta.pl, potem w WP.pl, obecnie w TVN Warner Bros. Discovery. Jako Ph. D. bada computer mediated communication, jest autorką szeregu publikacji branżowych oraz książki *Tekst {w} sieci*.

Swój doktorat poświęciła analizom komunikacji (global digital genre-communication forms) na Facebooku, Pinterście i Instagramie. Wykładała na Uniwersytecie Warszawskim, obecnie w Collegium Civitas oraz na Uniwersytecie Ekonomicznym w Poznaniu. Jest mentorem, ekspertem IAB oraz arbitrem Komisji Etyki Reklamy. Certyfikowana w Prestige Business Group. Ukończyła Oxford Artificial Intelligence Programme Said Business School, University of Oxford.



Sebastian Kondracki – szef innowacji w Deviniti, jednej z najdynamiczniej rozwijających się firm tworzących oprogramowanie w Polsce. Członek podgrupy Badań, Innowacyjności i Wdrożeń Grupy Roboczej ds. Sztucznej Inteligencji przy Kancelarii Prezesa Rady Ministrów. Ekspert ds. transformacji cyfrowej zwłaszcza w obszarze jej głównych

akceleratorów, jak: procesy innowacyjne i szeroko rozumiana sztuczna inteligencja. Autor książki *Python i AI dla e-commerce*, a także wykładowca na studiach podyplomowych w Akademii Leona Koźmińskiego i Wyższej Szkole Bankowej we Wrocławiu. Aktywny badacz wpływu „otwartości” (open data, open science, open source) na rozwój innowacyjności i kreatywności w społeczeństwie i biznesie. Współtwórca projektu SpeakLeash/'spix.lęś/a.k.a.Spichlerz – zestawu narzędzi do budowy pierwszego w Polsce tak obszernego (>1TB) zróżnicowanego zbioru danych wysokiej jakości wraz z bibliotekami umożliwiającymi łatwy dostęp i pełną otwartą replikację danych lub ich analizę.

Specjalizuje się w AI: NLP (Natural Language Processing), NLG (Natural Language Generation), Generative AI, Explainable Artificial Intelligence (XAI) w biznesie, a w szczególności w e-commerce. Ekspert w zakresie testowania i weryfikacji pomysłów biznesowych, lean startup, zarządzania projektami eksploracyjnymi. Autor licznych publikacji branżowych, w tym dla magazynu komputerowego CHIP, CHIP Special i Computer World.

O SCMP

Stowarzyszenie Content Marketing Polska

Stowarzyszenie założyliśmy po to, aby promować marketing treści jako skuteczną strategię w procesie budowania świadomości marki i zdobywania lojalnych klientów. Dzielimy się wiedzą i doświadczeniem, by kształtować i upowszechniać wysokie standardy naszej działalności. Od 2007 roku podejmujemy dyskusję na temat content marketingu na organizowanych przez nas konferencjach. Nieustannie szukamy też najlepszych contentowych realizacji, które wraz z ekspertami z branży wyłaniamy spośród zgłoszeń do konkursu Power of Content Marketing Awards. **Chcemy, by dobre wzorce i kreatywne rozwiązania zdominowały rynek treści w Polsce!**

Nasze stowarzyszenie zrzesza agencje marketingowe, wydawców i marketerów, dla których dobry content to punkt honoru. Tworzymy platformę wymiany doświadczeń pomiędzy przedstawicielami wydawców prasy firmowej, mass mediów, twórcami branży wydawniczej, agencjami marketingowymi i klientami. Organizujemy również szkolenia, w czasie których eksperci dzielą się swoim wieloletnim doświadczeniem.

<https://contentmarketingpolska.pl/>

Zarząd



Agnieszka Gajzler

Prezes zarządu Stowarzyszenia Content Marketing Polska

20-lat doświadczenia w branży. Specjalizuje się w obszarze digital, w tym w rozwoju produktów, marketingu, tworzeniu treści oraz modeli biznesowych. Od stycznia 2022 w Wirtualnej Polsce odpowiada za rozwój Produktu Mediowego całego portfolio serwisów WPM oraz Growth Marketing i Media Technology&Innowację. Do 2021 w TVN Media, gdzie odpowiadała za strategię i rozwój Grupy TVN Discovery w nowych obszarach digital. Wcześniej pracowała w Dentsu Aegis Network, gdzie m.in. współzarządzała i odpowiadała za digitalizację domu mediowego Carat oraz zarządzała pionem international social media spółki Isobar.



Katarzyna Sowicka

Wiceprezes zarządu Stowarzyszenia Content Marketing Polska

Chief Communication Officer w [adcookie](#). Edytor z wykształcenia, marketer z zamiłowania i wyboru. Od kilkunastu lat buduje strategie contentmarketingowe dla firm oraz marek osobistych. Entuzjastka metodologii challenger brands, optymalizacji i biznesowego wykorzystania marketingu. Wykładowca na AGH i SWPS. Szczególną uwagą darzy wykorzystanie AI w content marketingu.



Tomasz Wileński

Wiceprezes zarządu Stowarzyszenia Content Marketing Polska

CEO iSlay, jeden z pionierów online marketingu w Europie Centralnej i Wschodniej, członek grupy roboczej IAB ds. Badań. Jest założycielem Interactive Solutions – największej niezależnej agencji interaktywnej w CEE, będącej częścią Publicis Group, a obecnie IS Saatchi & Saatchi.



Grzegorz Miłkowski

Wiceprezes zarządu Stowarzyszenia Content Marketing Polska

Jest współwłaścicielem i prezesem zarządu ContentHouse. Ekspert ds. digital marketingu Business Centre Club. Twórca [Akademii Marketingu](#). Oprócz tego jest właścicielem i redaktorem naczelnym portalu [SOCIALPRESS.pl](#), który specjalizuje się w zagadnieniach łączących komunikację, marketing i nowe technologie. Założył pierwszy polski serwis śledzący możliwości wykorzystania sztucznej inteligencji w biznesie – [AIBusiness.pl](#).

PARTNERZY RAPORTU



PATRONAT HONOROWY

