

Historia, motywacje i główne tematy

Przegląd głównych tematów

Historię sztucznej inteligencji najlepiej zrozumieć w kontekście jej głównych tematów i kontrowersji. Poniżej znajduje się krótka lista takich wyróżnień, problemów, tematów i kontrowersji związanych ze sztuczną inteligencją. Dobrze będzie mieć to na uwadze podczas czytania pozostałej części. Każdy z wątków będzie rozwijany i wyjaśniany w miarę postępów. Wiele z nich wynika z braku uzgodnionej do dziś definicji inteligencji w społeczności badaczy sztucznej inteligencji.

Inteligentne oprogramowanie a modelowanie poznawcze. Sztuczna inteligencja zawsze była częścią informatyki, dyscypliny inżynierskiej mającej na celu tworzenie inteligentnych programów komputerowych – czyli inteligentnych produktów programowych spełniających ludzkie potrzeby. Zobaczymy wiele przykładów takiego inteligentnego oprogramowania. Sztuczna inteligencja ma również swoją stronę naukową, która ma pomóc nam zrozumieć ludzką inteligencję. Przedsięwzięcie to obejmuje budowanie systemów oprogramowania, które „myślą” na sposób ludzki, a także tworzenie modeli obliczeniowych aspektów ludzkiego poznania. Te modele obliczeniowe dostarczają hipotez dla badaczy kognitywistyki.

Symboliczna sztuczna inteligencja a sieci neuronowe. Od samego początku AI dzieliła się na dwa dość odrębne nurty badawcze: symboliczną sztuczną inteligencję i sieci neuronowe. Symboliczna sztuczna inteligencja przyjęła pogląd, że inteligencję można osiągnąć poprzez manipulowanie symbolami w komputerze zgodnie z zasadami. Neuronowe sieci, czyli koneksjonizm, jak nazywali to kognitywiści, zamiast tego próbowały stworzyć inteligentne systemy w postaci sieci węzłów, z których każdy zawierał uproszczony model neuronu. Zasadniczo różnica polegała na analogii komputerowej i analogii do mózgu, pomiędzy wdrażaniem systemów AI jako tradycyjnych programów komputerowych i modelowaniem ich na wzór układów nerwowych.

Rozumowanie a percepcja. W tym przypadku rozróżnia się inteligencję jako rozumowanie wysokiego poziomu służące podejmowaniu decyzji, powiedzmy w szachach maszynowych lub diagnostyce medycznej, a przetwarzanie percepcyjne niższego poziomu związane, powiedzmy, z widzeniem maszynowym – rozumieniem obrazów poprzez identyfikację obiektów i ich relacji.

Rozumowanie a wiedza. Wcześni badacze symbolicznej sztucznej inteligencji koncentrowali się na zrozumieniu mechanizmów (algorytmów) używanych do rozumowania w procesie podejmowania decyzji. Założono, że zrozumienie, w jaki sposób można przeprowadzić takie rozumowanie w komputerze, wystarczy do zbudowania użytecznego inteligentnego oprogramowania. Później badacze zdali sobie sprawę, że aby zwiększyć skalę działania w przypadku problemów występujących w świecie rzeczywistym, muszą wbudować w swoje systemy znaczne ilości wiedzy. System diagnostyki medycznej musiał dużo wiedzieć o medycynie, aby móc wyciągać wartościowe wnioski.

Reprezentować lub nie. Wiedza ta musiała być w jakiś sposób reprezentowana w systemie; to znaczy, że system musiał w jakiś sposób modelować swój świat. Taka reprezentacja może przybierać różne formy, w tym zasady. Później powstał spór co do tego, ile takiego modelowania faktycznie należało wykonać. Niektórzy twierdzili, że wiele można osiągnąć bez rozbudowanego modelowania wewnętrznego.

Mózg w kadzi kontra wcielona sztuczna inteligencja. We wczesnych systemach sztucznej inteligencji ludzie wprowadzali dane wejściowe do systemów i oddziaływali na dane wyjściowe systemów. Niczym „mózg w kadzi” systemy te nie mogły ani wyczuwać świata, ani na niego oddziaływać. Później badacze sztucznej inteligencji stworzyli ucieleśnione, czyli umiejscowione systemy sztucznej inteligencji, które

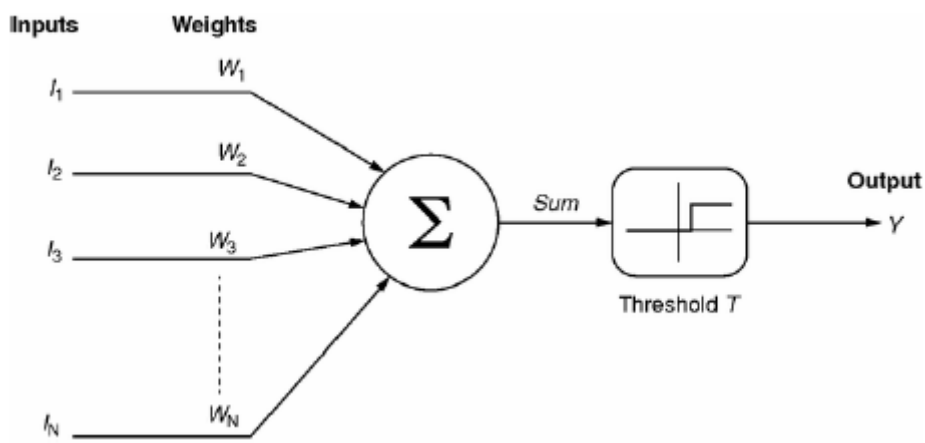
bezpośrednio wyczuwały ich światy, a także bezpośrednio na nie oddziaływały. Roboty ze świata rzeczywistego są przykładami ucieleśnionych systemów sztucznej inteligencji.

Wąska sztuczna inteligencja a inteligencja na poziomie ludzkim. Na początku sztucznej inteligencji wielu badaczy dążyło do stworzenia w swoich maszynach inteligencji na poziomie ludzkim, tak zwanej „silnej sztucznej inteligencji”. Później, gdy nadzwyczajna trudność takiego przedsięwzięcia stała się bardziej oczywista, prawie wszyscy badacze sztucznej inteligencji zbudowali systemy, które działały inteligentnie w stosunkowo wąskiej dziedzinie, takiej jak szachy czy medycyna. Dopiero niedawno nastąpił zwrot w kierunku systemów zdolnych do bardziej ogólnej inteligencji na poziomie ludzkim, która mogłaby być szeroko stosowana w różnych dziedzinach.

Kilka kluczowych momentów w AI

McCulloch i Pitts

Oddział AI zajmujący się sieciami neuronowymi rozpoczął się od bardzo wczesnego artykułu Warrena McCullocha i Waltera Pittsa (1943). McCulloch, profesor na Uniwersytecie w Chicago, i Pitts, wówczas student studiów licencjackich, opracowali znacznie uproszczony model funkcjonującego neuronu, jednostkę McCullocha-Pittsa.



Pokazali, że sieci takich jednostek mogą wykonywać dowolną operację boolowską (i, lub, nie), a co za tym idzie, dowolne obliczenia. Każda z tych jednostek porównała ważoną sumę swoich wejść z wartością progową, aby wygenerować wyjście binarne. W ten sposób narodziła się sztuczna inteligencja sieci neuronowych, a także neuronauka obliczeniowa.

Alan Turing

Za ojca informatyki można uważać Alana Turinga, matematyka z Cambridge żyjącego w pierwszej połowie XX wieku (jego dziadkiem był Charles Babbage w połowie XIX wieku) i dziadka sztucznej inteligencji. Podczas II wojny światowej w latach 1939–1944 Turing walczył z maszyną szyfrującą Enigma, kluczem do niemieckiej komunikacji. Kierował rozwojem brytyjskiej bomby, wczesnej maszyny obliczeniowej, która była wielokrotnie używana do dekodowania wiadomości zakodowanych przy użyciu Enigmy. Na początku XX wieku Turing i inni interesowali się zagadnieniami obliczalności. Chcieli sformalizować odpowiedź na pytanie, które problemy można rozwiązać obliczeniowo, w wyniku czego

kilka osób rozwinęło odrębne formalizmy. Turing zaoferował Maszynę Turinga (1936), Alonzo Church rachunek lambda (1936), a Emil Post system produkcyjny (1943). Te trzy pozornie zupełnie różne systemy formalne wkrótce okazały się logicznie równoważne w definiowaniu obliczalności, to znaczy w określaniu tych problemów, które mogą zostać rozwiązane przez program uruchomiony na komputerze. Najbardziej użyteczną formalizacją i najczęściej stosowaną w informatyce teoretycznej okazała się maszyna Turinga. W 1950 roku Turing opublikował pierwszą pracę sugerującą możliwość istnienia sztucznej inteligencji (1950). Po raz pierwszy opisał w nim to, co obecnie nazywamy testem Turinga, i przedstawił go jako warunek wystarczający istnienia sztucznej inteligencji. W teście Turinga testerzy rozmawiają w języku naturalnym bez ograniczeń za pośrednictwem terminali z programem w języku naturalnym człowieka lub sztuczną inteligencją, oba są ukryte przed wzrokiem. Jeśli testerzy nie są w stanie wiarygodnie odróżnić człowieka od programu, programowi przypisuje się inteligencję. W 1991 r. Hugh Loebner ustanowił Nagrodę Loebnera, która ma przyznać 100 000 dolarów pierwszemu programowi sztucznej inteligencji, który przejdzie test Turinga

Warsztaty w Dartmouth

Warsztaty w Dartmouth umożliwiły spotkanie badaczy z tej nowo powstającej dziedziny w celu interakcji i wymiany pomysłów. Warsztaty, które odbyły się w sierpniu 1956 roku, upamiętniają narodziny sztucznej inteligencji. AI wydaje się osamotniona wśród dyscyplin w zakresie obchodzenia urodzin. Do jej rodziców należeli John McCarthy, Marvin Minsky, Herbert Simon i Allen Newell. Innymi ostatecznie znaczącymi uczestnikami byli Claude Shannon znany z teorii informacji, Oliver Selfridge, twórca teorii Pandemonium i Nathaniel Rochester, główny projektant bardzo wczesnego komputera IBM 701. Za twórcę nazwy „sztuczna inteligencja” uważa się Johna McCarthy’ego, pracującego na wydziale Dartmouth w czasie warsztatów. Był także twórcą LISP-a, dominującego języka programowania AI od pół wieku. Następnie McCarthy dołączył do wydziału MIT, a później przeniósł się do Stanford, gdzie założył laboratorium sztucznej inteligencji. Pozostał aktywnym badaczem sztucznej inteligencji aż do swojej śmierci w 2011 r. Marvin Minsky pomógł założyć laboratorium MIT AI Lab, gdzie pozostał aktywnym i wpływowym badaczem sztucznej inteligencji. Herbert Simon i Allen Newell przywieźli do warsztatu w Dartmouth jedyny działający program sztucznej inteligencji, teoretyka logiki. Działa to na podstawie analizy środków i celów, czyli algorytmu planowania AI. Na każdym kroku próbował wybrać operację (środek), która przybliżyła system do celu (końca). Simon i Newell założyli laboratorium badawcze AI na Uniwersytecie Carnegie Mellon. Newell zmarł w 1992 r., a Simon w 2001 r

Gracz w warcaby Samuela

Każdy informatyk wie, że komputer wykonuje tylko algorytm, do którego działania został zaprogramowany. Można zatem pomyśleć, że może wykonywać tylko to, co kazał mu programista. Nie może wiedzieć niczego, czego nie wiedziałby jego programista, ani robić niczego, czego nie byłby w stanie zrobić. Ten pozornie logiczny wniosek jest w rzeczywistości po prostu błędny, ponieważ ignoruje możliwość zaprogramowania komputera do uczenia się. Takie uczenie maszynowe, które później stało się główną dziedziną sztucznej inteligencji, zaczęło się od programu gry w warcaby Arthura Samuela (1959). Chociaż Samuelowi początkowo udało się pokonać swój program, po kilku miesiącach nauki mówi się, że nigdy więcej z nim nie wygrał. Narodziło się uczenie maszynowe.

Rozprawa Minsky’ego

W 1951 roku Marvin Minsky i Dean Edmonds zbudowali SNARC, pierwszą sztuczną sieć neuronową, która symulowała szczura biegnącego przez labirynt. Praca ta stała się podstawą rozprawy Minsky’ego w Princeton (1954). Dlatego też jeden z założycieli i głównych graczy symbolicznej sztucznej inteligencji

był początkowo bardziej zainteresowany sieciami neuronowymi i przygotował grunt pod ich implementację obliczeniową.

Perceptrony i zima sieci neuronowych

Perceptron Franka Rosenblatta (1958) był jedną z najwcześniejszych sztucznych sieci neuronowych. W przypadku dwuwarstwowej sieci neuronowej, którą najlepiej traktować jako binarny system klasyfikatorów, perceptron odwzorowuje swój wektor wejściowy na sumę ważoną podlegającą progowi, uzyskując odpowiedź „tak” lub „nie”. Przyciąganie perceptronu wynikało z algorytmu nadzorowanego uczenia się, za pomocą którego można było nauczyć perceptron prawidłowej klasyfikacji. W ten sposób sieci neuronowe przyczyniły się do uczenia maszynowego. Badania nad perceptronami zakończyły się niechlubnie wraz z publikacją książki Minsky’ego i Paperta *Perceptrons* (1969), w której wykazano, że perceptron nie jest w stanie nauczyć się klasyfikować jako prawdziwe lub fałszywe danych wejściowych tak prostych systemów, jak wyłączne „lub” (XOR – albo A, albo B, ale nie oba). Minsky i Papert również przypuszczali, że nawet perceptrony wielowarstwowe będą miały podobne ograniczenia. Chociaż przypuszczenie to okazało się w większości fałszywe, agencje rządowe finansujące badania nad sztuczną inteligencją potraktowały je poważnie. Fundusze na badania nad sieciami neuronowymi wyczerpały się, co doprowadziło do zimy sieci neuronowych, która nie ustała aż do opublikowania w połowie lat 80. tomów *Parallel Distributing Processing*.

Geneza głównych obszarów badawczych

Na początku swojej historii badania nad sztuczną inteligencją skupiały się głównie na tworzeniu systemów, które potrafiły analizować problemy wysokiego poziomu, stosunkowo abstrakcyjne, ale sztuczne – problemy, które wymagałyby inteligencji, gdyby próbował je rozwiązać człowiek. Jednym z pierwszych takich systemów był system rozwiązywania problemów Simona i Newella (Newell, Shaw i Simon 1959), który podobnie jak jego poprzednik, teoretyk logiki, wykorzystywał analizę środków i celów do rozwiązywania różnorodnych zagadek. Jeszcze innym wczesnym systemem rozumowania był dowód twierdzenia o geometrii Gelerntera. Inną ważną dziedziną sztucznej inteligencji jest przetwarzanie języka naturalnego, związane z systemami rozumiejącymi język. Do pierwszych takich należał SHRDLU (Winograd 1972), nazwany na cześć kolejności kluczy na maszynie linotypowej. SHRDLU potrafił rozumieć i wykonywać polecenia w języku angielskim, nakazując mu manipulowanie drewnianymi klockami, stożkami, kulami itd. za pomocą ramienia robota w tak zwanym „świecie klocków”. SHRDLU był na tyle wyrafinowany, że mógł wykorzystać zapamiętany kontekst rozmowy do ujednoznacznienia odniesień. Nie minęło jednak dużo czasu, zanim badacze sztucznej inteligencji zdali sobie sprawę, że inteligencja to nie wszystko. Próbuąc skalować swoje systemy, aby radziły sobie z problemami w świecie rzeczywistym, napotkali prosto ścianę braku wiedzy. Problemy w świecie rzeczywistym wymagały, aby osoba rozwiązująca coś wiedziała. Tak narodziły się systemy oparte na wiedzy (często nazywane systemami eksperckimi). Nazwa wzięła się od procesu inżynierii wiedzy: inżynierowie wiedzy mozolnie wydobywają informacje od ludzkich ekspertów, a następnie kodują tę wiedzę w swoich systemach ekspertowych. Kierowany przez chemika Joshuę Lederberga oraz badaczy sztucznej inteligencji Edwarda Feigenbauma i Bruce’a Buchanana pierwszy taki system ekspercki, nazwany DENDRAL, był ekspertem w dziedzinie chemii organicznej. DENDRAL pomógł zidentyfikować strukturę molekularną cząsteczek organicznych, analizując dane ze spektrometru mas i wykorzystując swoją wiedzę z zakresu chemii. Projektanci projektu DENDRAL dodali wiedzę do leżącego u jego podstaw mechanizmu rozumowania, silnika wnioskowania, w celu stworzenia systemu eksperckiego zdolnego uporać się ze złożonym problemem występującym w świecie rzeczywistym. Drugi taki system ekspercki, nazwany Mycin, pomógł lekarzom diagnozować i leczyć zakaźne choroby krwi i zapalenie opon mózgowo-rdzeniowych. Podobnie jak DENDRAL, Mycin opierał się zarówno na ręcznie wykonanej wiedzy eksperckiej, jak i na silniku wnioskowania opartym na regułach. System odniósł sukces,

ponieważ mógł diagnozować trudne przypadki tak samo dobrze jak najbardziej doświadczeni lekarze, ale nie powiódł się, ponieważ nigdy nie został zastosowany. Wprowadzanie informacji do Mycin trwało około dwudziestu minut. Lekarz poświęciłby na taką diagnozę najwyżej pięć minut.

Badania podczas zimy sieci neuronowych

Jak już zauważono, Minsky i Papert's w *Perceptrons* (1969) błędnie przekonali rządowe agencje finansujące, że podejście oparte na sieciach neuronowych nie jest obiecujące, co doprowadziło do trwającej prawie dwadzieścia lat zimy sieci neuronowych. Pomimo tego przerażającego braku funduszy, na całym świecie nadal prowadzono znaczące badania. Do nieustraszonych badaczy, którym w jakiś sposób udało się utrzymać te ważne badania, należeli Shunichi Amari i Satoru Fukushima w Japonii, Stephen Grossberg i John Hopfield w Stanach Zjednoczonych, Teuvo Kohonen w Finlandii i Christoph von der Malsburg w Niemczech. Duża część tych prac dotyczyła samoorganizacji sieci neuronowych i uczenia się w nich. Wiele z nich było również motywowanych doświadczeniem tych badaczy w dziedzinie neurologii.

Powstanie koneksjonizmu

Koniec zimy sieci neuronowych został przyspieszony publikacją dwóch tomów poświęconych równoległemu przetwarzaniu rozproszonemu. Były to dwa obszerne tomy pod redakcją, których autorami byli członkowie grupy badawczej PDP, pracującej wówczas na Uniwersytecie Kalifornijskim w San Diego. Tomy te dały początek zastosowaniu w kognitywistyce sztucznych sieci neuronowych, które wkrótce zostaną nazwane koneksjonizmem. To, czy koneksjonizm jest w stanie wyjaśnić umysł, szybko stało się gorącym tematem debaty wśród filozofów, psychologów i badaczy sztucznej inteligencji. Debata dobiegła końca bez wyłonienia zwycięzcy, ale sztuczne sieci neuronowe stały się uznanym graczem na obecnym polu sztucznej inteligencji. Oprócz sukcesu (pod przykrywką koneksjonizmu) w modelowaniu poznawczym, sztuczne sieci neuronowe znalazły szereg praktycznych zastosowań. Większość z nich obejmuje rozpoznawanie wzorców. Obejmują one inwestowanie w fundusze wspólnego inwestowania, wykrywanie oszustw, scoring kredytowy, wycenę nieruchomości i wiele innych. Tak szerokie zastosowanie wynika przede wszystkim z szeroko stosowanego algorytmu szkoleniowego zwanego propagacją wsteczną. Choć później powiązano ją z dużo wcześniejszymi pracami, grupa badawcza PDP ponownie odkryła propagację wsteczną i stała się ona głównym narzędziem badań opisanych w dwóch tomach PDP.

Zima AI

Z powodu czegoś, co okazało się przesadą w ocenie potencjału i czasu sztucznej inteligencji, symboliczna sztuczna inteligencja przeżyła swoją własną zimę. Na przykład w 1965 roku Herbert Simon przewidział, że „w ciągu dwudziestu lat maszyny będą w stanie wykonać każdą pracę, jaką może wykonać człowiek”. Ta i inne przewidywania nie spełniły się. W rezultacie w połowie lat 80. fundusze agencji rządowych na sztuczną inteligencję zaczęły się wyczerpywać, a inwestycje komercyjne prawie nie istniały. Sztuczna inteligencja stała się słowem tabu w branży komputerowej na dekadę lub dłużej, pomimo ogromnego sukcesu systemów ekspertowych. Wiosna AI nadeszła dopiero wraz z pojawieniem się kolejnej „zabójczej” aplikacji, czyli gier wideo.

Miękkie obliczenia

Termin „miękkie przetwarzanie danych” odnosi się do pstrokatego zestawu technik obliczeniowych zaprojektowanych do radzenia sobie z nieprecyzyznością, niepewnością, przybliżeniami, prawdami cząstkowymi i tak dalej. Jej metody mają raczej charakter indukcyjny niż dedukcyjny. Oprócz sieci neuronowych, o których już mówiliśmy, miękkie obliczenia obejmują obliczenia ewolucyjne, logikę

rozmytą i sieci Bayesa. Rozważymy każdy z nich po kolei. Obliczenia ewolucyjne rozpoczęły się od obliczeniowego odwzorowania doboru naturalnego zwanego algorytmem genetycznym (Holland 1975). Algorytm wyszukiwania populacji. Proces ten zazwyczaj rozpoczyna się od populacji sztucznych genotypów reprezentujących możliwe rozwiązania danego problemu. Członkowie tej populacji podlegają mutacjom (zmianom losowym) i krzyżowaniu (mieszaniu się dwóch genotypów). Powstałe nowe genotypy są wprowadzane do funkcji przystosowania, która mierzy jakość genotypu. Najbardziej udane z tych genotypów tworzą następną populację i proces się powtarza. Jeśli są dobrze zaprojektowane, genotypy w populacji z czasem stają się bardzo podobne, osiągając w ten sposób pożądane rozwiązanie i uzupełniając algorytm genetyczny. Ponadto obliczenia ewolucyjne obejmują również systemy klasyfikatorów, które łączą koncepcje oparte na regułach i wzmocnieniach z algorytmami genetycznymi. Obliczenia ewolucyjne obejmują także programowanie genetyczne, metodę wykorzystywania algorytmów genetycznych do wyszukiwania programów komputerowych, zazwyczaj w LISP-ie, które rozwiążą dany problem. Wywodząca się z teorii zbiorów rozmytych Zadeha, w której przypisuje się stopnie przynależności do zbioru od 0 do 1 (1965), logika rozmyta stała się podstawą miękkiego przetwarzania danych. Wykorzystując reguły „jeśli-to” ze zmiennymi rozmytymi, logika rozmyta została zastosowana w wielu zastosowaniach sterujących, w tym w sprzęcie gospodarstwa domowego, windach, szybach samochodowych, kamerach i grach wideo. (Nie podano odniesień, ponieważ te komercyjne zastosowania są prawie zawsze zastrzeżone). Sieć Bayesa, w której węzły reprezentują sytuacje, wykorzystuje twierdzenie Bayesa o prawdopodobieństwie warunkowym, aby powiązać prawdopodobieństwo z każdym ze swoich ogniw. Takie sieci bayesowskie są szeroko stosowane w modelowaniu poznawczym, sieciach regulacji genów, systemach wspomagania decyzji i tak dalej. Są integralną częścią miękkiego przetwarzania danych.

Kilka ważnych osiągnięć

Zakończymy naszą krótką historię sztucznej inteligencji opisem niektórych jej głównych osiągnięć. Należą do nich systemy eksperckie, szachiści, dowódcy twierdzeń, przetwarzanie języka naturalnego i nowa, zabójcza aplikacja. Każdy zostanie opisany po kolei.

Systemy eksperckie oparte na wiedzy

Chociaż systemy eksperckie oparte na wiedzy pojawiły się stosunkowo wcześnie w historii sztucznej inteligencji, nieco później stały się głównym, znaczącym ekonomicznie zastosowaniem sztucznej inteligencji. Być może najwcześniejszym systemem ekspertowym, który odniósł sukces komercyjny, był R1, później przemianowany na XCON . Firma XCON zaoszczędziła miliony dla firmy DEC (Digital Equipment Corporation), skutecznie konfigurując komputery VAX przed dostawą, zamiast zlecać inżynierom DEC rozwiązywanie problemów po dostawie. Następnie pojawiły się inne tego typu zastosowania, w tym systemy diagnostyki i konserwacji kuchenek Campbell Soups i lokomotyw GE. Reklama Ford Motor Company dotycząca maszyny produkcyjnej przewidywała, że taki ekspercki system diagnostyki i konserwacji będzie częścią każdej oferty. Jedna książka szczegółowo opisała 2500 terenowych systemów eksperckich. Systemy eksperckie stanowiły pierwszą aplikację zabójcy sztucznej inteligencji. I nie miały być ostatnie.

Deep Blue pokonuje Kasparowa

Wcześni badacze sztucznej inteligencji zwykle pracowali nad problemami, które wymagałyby inteligencji, gdyby próbował tego dokonać człowiek. Jednym z takich problemów była gra w szachy. Szachiści AI pojawili się niedługo po warcabach Samuela. Do najdoskonalszych systemów do gry w szachy należał Deep Blue firmy IBM, który w 1997 roku odniósł sukces w pokonaniu mistrza świata Gary’ego Kasparowa w meczu składającym się z sześciu partii, z opóźnieniem spełniając kolejną z wczesnych przewidywań Herberta Simona. Choć działał na specjalnie zbudowanym komputerze i

posiadał dużą wiedzę szachową, gra Deep Blue ostatecznie polegała na tradycyjnych algorytmach gry opartych na sztucznej inteligencji. Mecz z Kasparowem był triumfem AI.

Rozwiązanie hipotezy Robbinsa

Wkrótce miał nastąpić kolejny, jeszcze większy triumf sztucznej inteligencji. W artykule z 1933 roku E. V. Huntington podał nowy zestaw trzech aksjomatów charakteryzujących algebrę Boole'a, formalny system matematyczny ważny dla teoretycznej informatyki. Trzeci z tych aksjomatów był tak skomplikowany, że w zasadzie nie nadawał się do użytku. Zmotywowany w ten sposób Herbert Robbins wkrótce zastąpił ten trzeci aksjomat prostszym i przypuszczał, że ten nowy zestaw trzech aksjomatów charakteryzuje również algebrę Boole'a. Ta hipoteza Robbinsa pozostawała jedną z wielu takich w literaturze matematycznej, dopóki wybitny logik i matematyk Alfred Tarski nie zwrócił na nią uwagi, zamieniając ją w słynny nierozwiązany problem. Po ponad pół wieku opierania się wysiłkom matematyków, hipoteza Robbinsa ostatecznie uległa automatycznemu dowodzeniu twierdzeń AI ogólnego przeznaczenia, zwanemu EQP (EQuational Prover). Tam, gdzie ludzie zawiedli, EQP udało się udowodnić prawdziwość hipotezy Robbinsa.

Watson pokonuje ludzkich mistrzów w Jeopardy

Jeopardy to popularny i emitowany od dawna teleturniej, w którym uczestnicy otrzymują wskazówki w formie odpowiedzi na różnorodne pytania i muszą jak najszybciej odpowiedzieć na odpowiednie pytania. Dwudziesty ósmy sezon rozpoczął się w 2011 roku. W tym samym roku wyemitowano trzy specjalne odcinki Jeopardy, w których dwóch odnoszących największe sukcesy mistrzów i rekordzistów zmierzyło się ze sobą oraz z systemem sztucznej inteligencji o nazwie Watson (na cześć założyciela IBM-a). Wykorzystując algorytmy przetwarzania języka naturalnego AI do przeszukiwania około 200 milionów stron treści i odpowiadając w konwersacyjnym języku angielskim, firma Watson stale pokonywała swoich dwóch ludzkich przeciwników.

Gry – zabójcza aplikacja

Zatrudniając więcej specjalistów zajmujących się sztuczną inteligencją niż jakakolwiek inna, branża gier komputerowych i wideo cieszy się ogromnym sukcesem. Według jednego wiarygodnego źródła, Entertainment Software Association, całkowite wydatki Stanów Zjednoczonych na branżę gier w 2012 roku przekroczyły 20 miliardów dolarów, przy sprzedaży 188 milionów gier. Rola sztucznej inteligencji w tym zdumiewającym sukcesie jest kluczowa; jego użycie jest niezbędne do wytworzenia potrzebnych inteligentnych zachowań ze strony wirtualnych postaci zamieszkujących gry. W Wikipedii znajduje się wpis zatytułowany „Sztuczna inteligencja gier”, który zawiera historię stale rosnącego wyrafinowania technik AI stosowanych w tego typu grach, a także odniesienia do kilku książek na temat stosowania AI w grach.

Główne obszary badań nad sztuczną inteligencją

Istnieje prawie tuzin odrębnych dziedzin badań nad sztuczną inteligencją, każda z własnymi specjalistycznymi czasopismami, konferencjami, warsztatami i tak dalej. W tej części przedstawiono zwięźle zainteresowania badawcze w każdej z tych dziedzin.

Reprezentacja wiedzy

Każdy system sztucznej inteligencji, niezależnie od tego, czy jest to klasyczny system sztucznej inteligencji, w którym ludzie dostarczają dane wejściowe i korzystają z wyników, czy też autonomiczny agent, musi w jakiś sposób przełożyć dane wejściowe (bodźce) na informację lub wiedzę, która zostanie wykorzystana do wyboru wyniku (działania). Ta informacja lub wiedza musi być w jakiś sposób

reprezentowana w systemie, aby można ją było przetworzyć w celu określenia wyników lub działań. Problematyka, jaką stwarza taka reprezentacja, stanowi przedmiot badań w dziedzinie AI, zwanej potocznie reprezentacją wiedzy. W systemach AI spotyka się wiedzę reprezentowaną za pomocą formalizmów logicznych, takich jak logika zdań i rachunek predykatów pierwszego rzędu. Można również znaleźć reprezentacje sieci, takie jak sieci semantyczne, których węzły i łącza mają etykiety dostarczające treść semantyczną. Podstawową ideą jest to, że koncepcja reprezentowana przez węzeł zyskuje znaczenie poprzez swoje relacje (powiązania) z innymi koncepcjami. Stosowane są również bardziej złożone struktury danych, takie jak reguły produkcyjne, ramki i zbiory rozmyte. Każda z tych struktur danych ma swój własny typ aparatu wnioskowania lub podejmowania decyzji, swój silnik wnioskowania. Wydaje się, że kwestia reprezentowania lub nie reprezentowania została w sposób dorozumiany rozstrzygnięta, gdy argumenty ucichły. Wydaje się, że Rodney Brooks z MIT AI Lab stwierdził, że bez reprezentacji można osiągnąć więcej, niż wcześniej sądzono (1991). Jednak jego przeciwnicy przetrwali dzień, ponieważ reprezentacje są nadal szeroko stosowane. Wydaje się, że reprezentacje mają kluczowe znaczenie w procesie podejmowania decyzji, jakie działania podjąć, a tym bardziej w procesie ich wykonywania. To wydaje się być istotą problemu.

Wyszukiwanie heurystyczne

Problemy wyszukiwania są przedmiotem badań informatyki niemal od jej początków. Na przykład w problemie komiwojażera zadaniem jest znalezienie najbardziej efektywnej trasy, jaką sprzedawca może wybrać, aby odwiedzić każde z N miast dokładnie raz. Wszystkie znane algorytmy znajdowania optymalnych rozwiązań takiego problemu rosną wykładniczo wraz z N , co oznacza, że dla dużej liczby miast nie można znaleźć optymalnego rozwiązania. Wystarczająco dobre rozwiązania można jednak znaleźć, korzystając z algorytmów wyszukiwania heurystycznego AI. Algorytmy takie wykorzystują wiedzę z danej dziedziny w formie heurystyk, czyli praktycznych zasad, które nie gwarantują znalezienia najlepszego rozwiązania, ale najczęściej znajdują rozwiązanie wystarczająco dobre. Takie heurystyczne algorytmy wyszukiwania są szeroko stosowane w planowaniu, eksploracji danych (znajdowaniu wzorców w danych), rozwiązywaniu problemów ze spełnieniem ograniczeń, w grach, przeszukiwaniu sieci i wielu innych tego typu zastosowaniach.

Planowanie

Planista AI to system, który automatycznie opracowuje sekwencję działań prowadzących od początkowego stanu rzeczywistego do pożądanego stanu docelowego. Planistów można na przykład używać do planowania pracy w hali produkcyjnej, znajdowania tras dostawy paczek lub przydzielania zadań teleskopu Hubble'a. Badania nad takimi programami planowania stanowią główną dziedzinę sztucznej inteligencji. Zastosowania terenowe obejmują eksplorację kosmosu, logistykę wojskową oraz obsługę i kontrolę zakładów.

Systemy eksperckie

Systemy eksperckie oparte na wiedzy zostały omówione w poprzednich rozdziałach. Jako poddziedzina sztucznej inteligencji badacze systemów ekspertowych zajmują się rozumowaniem (udoskonalaniem silników wnioskowania dla swoich systemów), reprezentacją wiedzy (jak reprezentować potrzebne fakty w swoich systemach) i inżynierią wiedzy (jak wydobywać od ekspertów wiedzę, która czasami jest ukryta). Jak widzieliśmy, ich zastosowań terenowych jest mnóstwo.

Widzenie maszynowe

Widzenie maszynowe lub komputerowe to poddziedzina sztucznej inteligencji poświęcona automatycznemu rozumieniu obrazów wizualnych, zazwyczaj fotografii cyfrowych. Wśród wielu

zastosowań znajduje się kontrola produktów, nadzór ruchu i wywiad wojskowy. Ponieważ obrazy z satelitów, wysoko latających samolotów szpiegowskich i autonomicznych dronów mnożą się co kilka sekund, nie ma wystarczającej liczby ludzi, aby zinterpretować i zindeksować obiekty na zdjęciach, aby można je było zrozumieć i zlokalizować. Badania nad automatyzacją tego procesu dopiero się rozpoczynają. Badania nad sztuczną inteligencją w zakresie widzenia maszynowego zaczynają być również stosowane w kamerach bezpieczeństwa, aby rozpoznawać sceny i w razie potrzeby ostrzegać ludzi.

Nauczanie maszynowe

Poddziedzina sztucznej inteligencji w uczeniu maszynowym³ dotyczy algorytmów, które umożliwiają systemom sztucznej inteligencji uczenie się (patrz gracz w szachownicę Samuela powyżej). Chociaż uczenie maszynowe jest tak stare jak sama sztuczna inteligencja, jego znaczenie wzrosło w miarę, jak coraz więcej systemów sztucznej inteligencji, zwłaszcza agentów autonomicznych, działa w coraz bardziej złożonych i dynamicznie zmieniających się dziedzinach. Duża część uczenia maszynowego to uczenie się nadzorowane, podczas którego system otrzymuje instrukcje na podstawie danych szkoleniowych. Jak wspomniano powyżej, systemy bez nadzoru lub samoorganizujące się stają się powszechne. Uczenie się przez wzmocnienie, realizowane za pomocą sztucznych nagród, jest typowe dla uczenia się nowych zadań. Istnieje nawet nowa dziedzina uczenia maszynowego poświęcona robotyce rozwojowej – robotom, które podobnie jak ludzkie dzieci przechodzą szybką fazę wczesnego uczenia się.

Przetwarzanie języka naturalnego

Poddziedzina AI zajmująca się przetwarzaniem języka naturalnego obejmuje zarówno generowanie, jak i rozumienie języka naturalnego, zwykle tekstu. Jego historia sięga omawianego wcześniej testu Turinga. Dziś jest to kwitnąca dziedzina badań nad tłumaczeniem maszynowym, odpowiadaniem na pytania, automatycznym podsumowaniem, rozpoznawaniem mowy i innymi dziedzinami. Tłumacze maszynowi, chociaż zazwyczaj dokładność wynosi tylko około 90 procent, mogą czterokrotnie zwiększyć produktywność tłumaczy-ludzi. Opracowywane są systemy rozpoznawania tekstu w celu automatycznego wprowadzania historii chorób. Funkcja rozpoznawania głosu umożliwia wydawanie poleceń głosowych na komputerze, a nawet dyktowanie.

Agenci oprogramowania

Agent autonomiczny definiuje się jako system umiejscowiony w środowisku, który wyczuwa to środowisko i działa na nie, realizując swój własny program, w taki sposób, że jego działania mogą wpływać na to, co później wyczuje. Do sztucznych agentów autonomicznych zalicza się agentów programowych i niektóre roboty. Autonomiczni agenci oprogramowania występują w kilku odmianach. Niektórzy, jak autorski IDA, „żyją” w środowisku obejmującym bazy danych i Internet i samodzielnie wykonują określone zadania, takie jak przydzielanie marynarzom nowych stanowisk pracy po zakończeniu służby. Inne, czasami nazywane awatarami, mają wirtualne twarze lub ciała wyświetlane na monitorach, co pozwala im na bardziej naturalną interakcję z ludźmi, często dostarczając informacji. Jeszcze inni, tzw. wirtualnych agentów konwersacyjnych, symulujących ludzi i wchodząc z nimi w interakcję konwersacyjną na czatach, niektóre tak realistycznie, że można je pomylić z ludźmi. Wreszcie istnieją agenci wirtualni jako postacie w grach komputerowych i wideo.

Inteligentne systemy nauczania

Inteligentne systemy nauczania to systemy sztucznej inteligencji, zazwyczaj agenci programowi, których zadaniem jest interaktywne nauczanie uczniów jeden na jednego, podobnie jak zrobiłby to

nauczyciel. Wyniki wczesnych wysiłków w tym kierunku były rozczarowujące. Późniejsze systemy odniosły większy sukces w dziedzinach takich jak matematyka, w których uczeń wymagał krótkich odpowiedzi. Niedawno opracowano inteligentne systemy nauczania, takie jak AutoTutor, które potrafią odpowiednio radzić sobie z pełnymi akapitami napisanymi przez ucznia. Obecnie głównym wąskim gardłem w tych badaniach jest wprowadzanie wiedzy dziedzinowej do systemów nauczania. W rezultacie rozkwitły badania nad różnymi narzędziami autorskimi.

Robotyka

Na początku robotyka była poddziedziną inżynierii mechanicznej, a większość badań skupiała się na opracowywaniu robotów zdolnych do wykonywania określonych czynności, takich jak chwytanie, chodzenie itd. Ich systemy kontroli były czysto algorytmiczne i nie zawierały elementów sztucznej inteligencji. W miarę jak roboty stawały się coraz bardziej wydajne, stało się oczywiste zapotrzebowanie na bardziej inteligentne struktury sterujące i narodziły się badania nad robotyką kognitywną z udziałem struktur kontrolnych opartych na sztucznej inteligencji. Obecnie robotyka i badania nad sztuczną inteligencją w znaczącym i istotnym stopniu pokrywają się.

Najnowsze trendy i kierunki

Wraz z początkiem drugiej dekady XXI wieku sztuczna inteligencja nie tylko wyłoniła się z zimy AI w wiosnę AI, ale ta wiosna przekształciła się w pełnoprawne lato AI z bujnym wzrostem owoców. Ostatnio kwitnące trendy obejmują przetwarzanie miękkie, sztuczną inteligencję do eksploracji danych, sztuczną inteligencję opartą na agentach, przetwarzanie kognitywne (w tym robotykę rozwojową i sztuczną inteligencję ogólną) oraz zastosowanie sztucznej inteligencji w naukach o kognitywistyce. Przyjrzyjmy się po kolei każdemu z nich.

Miękkie przetwarzanie

Oprócz komponentów opisanych wcześniej (mianowicie sieci neuronowych, obliczeń ewolucyjnych i logiki rozmytej) przetwarzanie miękkie rozszerza się na systemy hybrydowe łączące symboliczną i koneksjonistyczną sztuczną inteligencję. Najlepszymi przykładami takich systemów hybrydowych są ACT-R, CLARION i autorska LIDA. Większość takich systemów hybrydowych, łącznie z trzema przykładami, miała służyć jako modele poznawcze. Niektóre z nich leżą u podstaw architektur obliczeniowych praktycznych programów AI. Miękkie przetwarzanie danych obejmuje obecnie również sztuczne układy odpornościowe z ich znaczącym wkładem w bezpieczeństwo komputera, a także zastosowania do optymalizacji i przewidywania struktury białek.

Sztuczna inteligencja do eksploracji danych

Oprócz statystyk sztuczna inteligencja zapewnia niezbędne narzędzia do eksploracji danych, procesu przeszukiwania dużych baz danych w poszukiwaniu przydatnych wzorców danych. Wiele z tych narzędzi wywodzi się z badań nad uczeniem maszynowym. W miarę jak zawartość baz danych szybko rośnie, systemy eksploracji danych stają się coraz bardziej przydatne, co prowadzi do trendu w kierunku badania narzędzi AI do eksploracji danych.

Sztuczna inteligencja oparta na agentach

Usytuowany, czyli ucieleśniony ruch poznawczy (Varela, Thompson i Rosch 1991), w formie sztucznej inteligencji opartej na agentach, wyraźnie zyskał popularność w badaniach nad sztuczną inteligencją. Obecnie większość nowo wprowadzonych systemów sztucznej inteligencji to pewnego rodzaju autonomiczni agenci. Dominujący podręcznik AI (Russell i Norvig 2010), używany na ponad 1000 uniwersytetów w ponad 100 krajach, jest tekstem wiodącym, częściowo dlatego, że jego pierwsze

wydanie było pierwszym podręcznikiem AI opartym na agentach. Istnieje mnóstwo zastosowań agentów AI. Niektóre zostały wspomniane w powyższej sekcji dotyczącej agentów oprogramowania.

Obliczenia kognitywne

Być może najnowszym, a z pewnością jednym z najbardziej uporczywych, obecnych trendów w badaniach nad sztuczną inteligencją jest to, co zaczęto nazywać przetwarzaniem kognitywnym. Obliczenia kognitywne obejmują robotykę kognitywną, robotykę rozwojową, samoświadome systemy komputerowe, autonomiczne systemy obliczeniowe i sztuczną inteligencję ogólną. Pokróćce opiszemy każdy z nich po kolei. Jak wspomniano powyżej, robotyka na początku zajmowała się przede wszystkim wykonywaniem czynności i była głównie dyscypliną inżynierii mechanicznej. Niedawno nacisk przesunął się na wybór działań, to znaczy decydowanie, jakie działanie wykonać. Narodziła się robotyka kognitywna, czyli wyposażanie robotów w większe możliwości poznawcze, która staje się aktywną dziedziną sztucznej inteligencji. Kolejna ściśle powiązana nowa dyscyplina badawcza AI, robotyka rozwojowa, łączy robotykę, uczenie maszynowe i psychologię rozwojową. Pomysł polega na umożliwieniu robotom ciągłego uczenia się, tak jak ludzie. Takie uczenie się powinno pozwolić robotom kognitywnym działać w środowiskach zbyt złożonych i zbyt dynamicznych, aby wszystkie nieprzewidziane okoliczności mogły zostać ręcznie wpisane do robota. Ta nowa dyscyplina jest wspierana przez Komitet Techniczny IEEE ds. Autonomicznego Rozwoju Mentalnego, a także przez jego własne czasopismo Transactions on Autonomous Mental Development. Agencje rządowe inwestują w przetwarzanie kognitywne w postaci samoświadomych systemów komputerowych. DARPA, Agencja Zaawansowanych Programów Badawczych w Obronie, sponsorowała warsztaty na temat samoświadomych systemów komputerowych. Ron Brachman, ówczesny dyrektor biura programowego DARPA IPTO, a odkąd prezes AAI, Stowarzyszenia na rzecz Rozwoju Sztucznej Inteligencji, ujął to w ten sposób: System prawdziwie poznawczy byłby w stanie... wyjaśnić, co robi i dlaczego robił to. Byłoby wystarczająco refleksyjne, aby wiedzieć, kiedy zmierza w ślepią uliczkę lub kiedy musi poprosić o informacje, do których po prostu nie może dotrzeć na drodze dalszego rozumowania. Wykorzystując te możliwości, system poznawczy byłby odporny na niespodzianki. Byłaby w stanie poradzić sobie z nieprzewidzianymi okolicznościami o wiele dojrzalej niż jakakolwiek obecna maszyna. DARPA wspiera obecnie badania nad takimi systemami poznawczymi inspirowanymi biologią. IBM Research oferuje komercyjne wsparcie w zakresie przetwarzania kognitywnego w ramach tak zwanego przetwarzania autonomicznego. Głównym przedmiotem zainteresowania są systemy samokonfigurujące, samodiagnostujące i samonaprawiające. Bardzo nowym i nie w pełni rozwiniętym trendem w badaniach nad sztuczną inteligencją jest przejście w kierunku systemów wykazujących inteligencję ogólną bardziej ludzką, często nazywaną obecnie sztuczną inteligencją ogólną (AGI). Rozwój tego trendu AGI można prześledzić poprzez sekwencję specjalnych utworów, specjalnych sesji, sympozjów i warsztatów:

Jesienne sympozjum AAI'04 zatytułowane Osiągnięcie inteligencji na poziomie ludzkim poprzez zintegrowane systemy i badania

AAI'06 Specjalna ścieżka poświęcona zintegrowanym inteligentnym możliwościom Sesja specjalna WCCI'06 zatytułowana Mapa drogowa do inteligencji na poziomie ludzkim CogSci'06 Sympozjum na temat budowania i oceny modeli inteligencji na poziomie ludzkim.

Wiosenne sympozjum AAI'06 zatytułowane „Między młotem a kowadłem: zasady kognitywistyki spotykają się z trudnymi problemami AI”

Jesienne sympozjum AAI'09 zatytułowane Biologicznie inspirowane architektury poznawcze.

Wiosenne sympozjum AAI'12 zatytułowane Designing Intelligent Robots: Reintegrating AI

Warsztaty AGIRI na temat sztucznej inteligencji ogólnej Warsztaty dotyczące sztucznej inteligencji ogólnej – 2008, 2009, 2010, 2011

Obecnie opracowywane systemy AGI obejmują LIDA, Joshua Blue i Novamente.

Sztuczna inteligencja i kognitywistyka

Naukowa strona sztucznej inteligencji poświęcona jest przede wszystkim modelowaniu ludzkiego poznania. Jego zastosowanie ma na celu dostarczenie, miejmy nadzieję, sprawdzalnych hipotez badaczom kognitywistyki i neurobiologom poznawczym. Oprócz modeli poznawczych o bardziej ograniczonych ambicjach teoretycznych, opracowano zintegrowane modele dużych części poznania. Należą do nich SOAR, ACT-R, CLARION i LIDA. Niektóre z nich zostały zaimplementowane obliczeniowo jako agenci oprogramowania, stając się częścią ucieleśnionego poznania. Jedną z nich, LIDA, realizuje kilka różnych teorii psychologicznych, w tym teorię globalnej przestrzeni pracy, teorię pamięci roboczej, percepcję poprzez afordancje i przejściową pamięć epizodyczną. Znaczenie tej poddziedziny sztucznej inteligencji związanej z modelowaniem poznawczym zostało docenione przez kilka wydziałów informatyki, które zaczęły oferować programy studiów w zakresie nauk o kognitywistyce.

Główne tematy – na jakim etapie się obecnie znajdują?

Inteligentne oprogramowanie a modelowanie poznawcze. : Podobnie jak w całej historii sztucznej inteligencji, oba kierunki są nadal aktywne w badaniach nad sztuczną inteligencją, zarówno po stronie inżynierii, jak i po stronie nauki. Obecnie oba zwracają się w stronę bardziej ogólnego podejścia. Inteligentne oprogramowanie zaczyna uwzględniać AGI. Modelowanie poznawcze zmierza w kierunku bardziej zintegrowanych modeli hybrydowych, takich jak ACT-R, CLARION i LIDA, oprócz tradycyjnego zainteresowania bardziej wyspecjalizowanymi modelami. Kolejnym ważnym krokiem w stronę inteligentnego oprogramowania jest dążenie do bardziej autonomicznych systemów agentów oprogramowania.

Symboliczna sztuczna inteligencja a sieci neuronowe. : Zarówno symboliczna sztuczna inteligencja, jak i sieci neuronowe przetrwały swoje zimy i obecnie kwitną. Żadna ze stron sporu nie zwyciężyła. Obydwa są nadal całkiem przydatne. Łączą się nawet w takich systemach hybrydowych, jak ACT-R, CLARION i LIDA. ACT-R łączy cechy sieci symbolicznej i sieci neuronowej, CLARION składa się z modułu sieci neuronowej połączonego z modułem symbolicznym, a LIDA obejmuje aktywację przechodzącą w całym systemie skądinąd symbolicznym, co czyni go również dość podobnym do sieci neuronowej. Rozumowanie a percepcja. : Badania nad rozumowaniem AI nie słabną w takich dziedzinach, jak wyszukiwanie, planowanie i systemy ekspertowe. Praktycznych zastosowań w terenie jest mnóstwo. Percepcja znalazła zastosowanie w widzeniu maszynowym, przetwarzaniu agentowym i robotyce kognitywnej. Należy zauważyć, że rozumowanie i percepcja łączą się w dwóch ostatnich, a także w zintegrowanym modelowaniu poznawczym i AGI.

Rozumowanie a wiedza. : Oprócz rozumowania wiedza odgrywa kluczową rolę w systemach ekspertowych, a także w przetwarzaniu opartym na agentach, przetwarzaniu samoświadomym i przetwarzaniu autonomicznym. Obydwa znów żyją i kwitną, a znaczenie dodawania wiedzy do praktycznych systemów staje się coraz bardziej widoczne. Eksploracja danych stała się kolejnym sposobem zdobywania takiej wiedzy.

Reprezentować lub nie. : Bez reprezentacji architektura subsumcji Brooksa przyznaje każdej warstwie własne zmysły i zdolność wyboru i wykonania pojedynczego działania. Wyższy poziom może, jeśli to konieczne, przejąć działania następnego, niższego poziomu. Dzięki tej architekturze subsumcji sterującej robotami Brooks z powodzeniem stwierdził, że wiele można i należy zrobić przy niewielkiej

reprezentacji lub bez niej. Mimo to reprezentacja jest niemal wszechobecna w systemach sztucznej inteligencji, ponieważ stają się one w stanie inteligentniej radzić sobie w coraz bardziej złożonych, dynamicznych środowiskach. Wydawać by się mogło, że reprezentacja ma kluczowe znaczenie dla procesu wyboru działań w systemach AI, ale w znacznie mniejszym stopniu dla wykonania tych działań. Wydaje się, że spór o to, czy reprezentować, po prostu ucichł.

Mózg w kadzi kontra wcielona sztuczna inteligencja. : Choć raz wydaje się, że mamy zwycięzcę. Ucieleśniona lub zlokalizowana sztuczna inteligencja po prostu przejęła kontrolę, ponieważ większość nowych badań nad systemami sztucznej inteligencji opiera się na agentach. Lektura tytułów wykładów na którejkolwiek z ogólnych konferencji poświęconych sztucznej inteligencji, takich jak AAAI lub IJCAI (Międzynarodowa Wspólna Konferencja na temat Sztucznej Inteligencji), pokazuje to aż nadto wyraźnie.

Wąska sztuczna inteligencja a inteligencja na poziomie ludzkim. : Wąska sztuczna inteligencja w dalszym ciągu rozwija się nieprzerwanie, a dążenie do inteligencji na poziomie ludzkim w maszynach nabiera tempa dzięki AGI. Z wyjątkiem silnego ruchu badań nad sztuczną inteligencją w kierunku ucieleśnienia, każda strona każdego problemu jest nadal silnie reprezentowana w dzisiejszych badaniach nad sztuczną inteligencją. Badania nad sztuczną inteligencją rozwijają się jak nigdy dotąd i zapewniają ciągły wkład, zarówno praktyczny w inżynierię, jak i teoretyczny w naukę.