Materia, energia, informacja i inteligencja

Nauka rozwija się stopniowo, pogrzeb po pogrzebie. - Max Planck

Przyszłość zależy od kogoś, kto jest głęboko podejrzliwy wobec wszystkiego, co powiedziałem. - Geoffrey Hinton, dziadek głębokiego uczenia

Od zmagań różnych szkół sztucznej inteligencji po różne poglądy na sztuczną inteligencję w ogóle, widzimy, że wciąż brakuje naukowego zrozumienia sztucznej inteligencji, a nawet samej inteligencji. Większość obecnych prac nad sztuczną inteligencją pozostaje w fazie akademickich eksploracji, prób i błędów oraz akumulacji i nie ukształtowała jeszcze kompletnego systemu. Surowe normy formalne, podstawy teoretyczne i metody oceny nie zostały nawet rozpoczęte. Z powodu braku jednolitej teorii, obecna sztuczna inteligencja przypomina alchemię przed nadejściem współczesnej chemii i lot przypominający ptaka przed nadejściem aerodynamiki. Dokonamy przeglądu kilku ważnych czynników związanych z historią ludzkiej technologii: materii, energii, informacji i inteligencji. Spojrzenie na historię naszej technologii w tym świetle może dać nam pewne wskazówki dotyczące przyszłego kierunku rozwoju inteligencji. Na koniec omawiamy matematyczne modelowanie inteligencji, aby przenieść sztuczną inteligencję z inżynierii do nauki. Analizujemy kilka ważnych czynników związanych z historią ludzkiej technologii: materię, energię, informację i inteligencję. Spojrzenie na historię naszej technologii z tej perspektywy może dać nam pewne wskazówki dotyczące przyszłego kierunku rozwoju inteligencji. Na koniec omawiamy matematyczne modelowanie inteligencji, aby przenieść sztuczną inteligencję z inżynierii do nauki.

Wynalezienie technologii ułatwiającej stabilność wszechświata

Po rewolucji poznawczej ludzie uzyskali zdolność do tworzenia technologii, które przyczyniają się do tego procesu bardziej efektywnie niż kiedykolwiek wcześniej. Jednocześnie technologie te znacznie wspomagają współpracę między ludźmi. Współpraca leży u podstaw ludzkiego społeczeństwa, od codziennych interakcji po wielkie przedsięwzięcia. Ludzie są gatunkiem społecznym, którego przetrwanie i rozwój zależą od współpracy. Uważa się, że w porównaniu z innymi gatunkami, ludzie są jedynym gatunkiem, który potrafi elastycznie współpracować w dużej liczbie. Aby ułatwić współpracę ludzi w naszych systemach społeczno-gospodarczych, wynaleźliśmy technologie umożliwiające tworzenie sieci materii (sieci transportowej), energii (sieci energetycznej) i informacji (internetu). Technologie te pomogły skutecznie zniwelować nierównowagę materii, energii i informacji, a tym samym ustabilizować wszechświat. Ta historia może dać nam pewne wskazówki dotyczące przyszłych kierunków rozwoju technologii związanych z inteligencją. Rysunek przedstawia ten proces ewolucji.

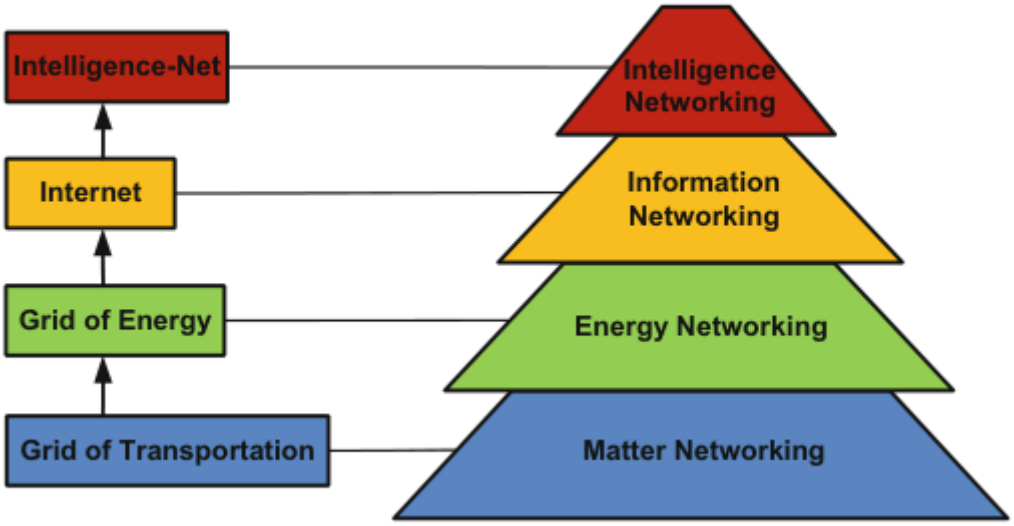

Sieciowanie materii: Siatka transportu

Wszystkie organizmy, w tym ludzie, potrzebują materii i energii do życia. Zasadniczo głównym celem transportu jest przemieszczanie materii z jednego miejsca do drugiego, co jest sieciowaniem materii. Nie ma wątpliwości, że transport odegrał kluczową rolę we współpracy ludzi, w tym w przetrwaniu, aktywności społecznej, handlu, wojnie itd. Połączenie koła i osi zostało wynalezione około 4500 roku p.n.e. i jest często uważane za najważniejszy wynalazek wszech czasów, ponieważ miało fundamentalny wpływ na transport i współpracę ludzi. Wiele nowych technologii transportowych zostało wynalezionych w XVII iXVIII wieku, takich jak rowery, samochody, ciężarówki, pociągi, samoloty itd. W XX wieku samoloty, pociągi dużych prędkości i statki kosmiczne to tylko niektóre przykłady definiujących technologie transportowe.

Sieciowanie energii: Siatka energii

Energia jest miarą zdolności systemu do wywoływania zmian. Pierwsza zasada termodynamiki głosi, że energii nie można stworzyć ani zniszczyć. Można ją jednak przenosić z jednego miejsca do drugiego i z jednej formy do drugiej. Istnieją dwie szerokie kategorie energii: energia kinetyczna (energia poruszających się obiektów) i energia potencjalna (energia, która jest magazynowana). Energię kinetyczną wyraża się jako

$$E_k = \frac{1}{2}mv^2 = \frac{1}{2}m\left(\frac{d}{t}\right)^2,$$

gdzie m to masa obiektu, v to prędkość, d to odległość, a t to czas. Zatem energię kinetyczną można rozumieć jako szybkość, z jaką materia porusza się w procesie. Oprócz technologii umożliwiających sieciowanie materii, kolejną ważną innowacją są technologie umożliwiające sieciowanie energii, które są fundamentalne nie tylko dla przetrwania ludzkości, ale także dla jej rozwoju. Dzięki sieci elektroenergetycznej, która składa się z linii przesyłowych, podstacji, transformatorów i innych elementów, energia elektryczna może być dostarczana z elektrowni do naszych domów i firm. Teraz możemy łatwo uzyskać energię do oświetlenia w nocy, zasilania komputerów, ładowania telefonów i chłodzenia domów, po prostu podłączając się do sieci elektroenergetycznej.

Sieci informacyjne: Internet

Po sieci transportowej i energetycznej, Internet umożliwił ludziom współpracę na nowym poziomie i szacuje się, że do 2023 roku połączy 5,3 miliarda użytkowników i 29,3 miliarda urządzeń. Głównym celem Internetu jest przesyłanie informacji z jednego miejsca do drugiego. To globalny system połączonych sieci komputerowych, który wykorzystuje zestaw protokołów internetowych TCP/IP, łącząc ludzi i maszyny. Internet stał się jednym z głównych fundamentów naszych systemów społeczno-ekonomicznych, umożliwiając sieciowanie informacji. Istnieje silny związek między informacją a energią. Związek ten można wyjaśnić w „demonie" Maxwella , który jest eksperymentem myślowym stworzonym przez fizyka Jamesa Clerka Maxwella w 1867 roku. W eksperymencie myślowym demon jest w stanie przekształcić informację (tj. położenie i prędkość każdej cząstki) w energię, co powoduje spadek entropii układu. Rysunek 2 opisuje ten eksperyment.

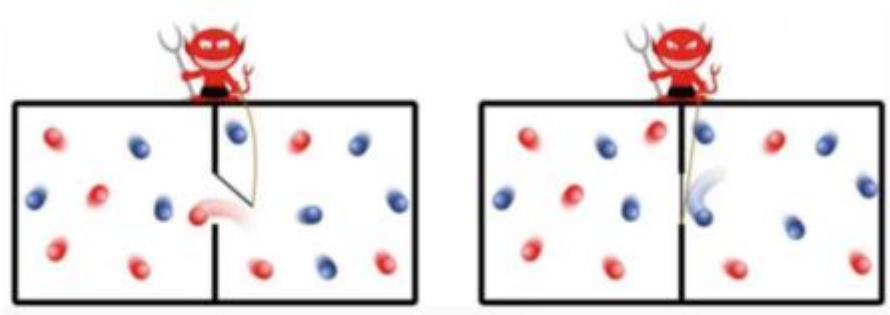

Eksperyment obejmował izolowany układ. Urządzenie składa się z prostego prostopadłościanu zawierającego dowolny gaz. Prostopadłościan jest podzielony na dwa obszary o równej wielkości i jednolitej temperaturze. Na ich granicy mieszka „demon", który starannie filtruje losowo rozproszone cząstki, tak aby wszystkie cząstki o wyższych energiach kinetycznych znalazły się w jednym obszarze. Pozostałe cząstki o niższych energiach kinetycznych wędrują w innym obszarze, jak pokazano na rysunku 2. Wiemy, że zgodnie z drugą zasadą termodynamiki entropia układu izolowanego ma tendencję wzrostową. Jednak ten „demon" Maxwella sprawia, że entropia układu ma tendencję spadkową. Zatem ten eksperyment myślowy zainspirował prace teoretyczne nad związkiem termodynamiki z teorią informacji. Oblężenie demona Maxwella musi poczekać do pojawienia się teorii informacji Shannona. Uzyskanie lub usunięcie informacji również wymaga energii, co oznacza, że demon Maxwella musi zużywać energię, aby uzyskać informacje o prędkości cząsteczek. To zwiększa entropię. Ponadto wzrost entropii jest większy niż ilość, którą demon Maxwella traci, aby zrównoważyć entropię. Demon Maxwella został wyeliminowany, a pozycja drugiej zasady termodynamiki została obroniona. Wysiłki Shannona zmierzające do znalezienia sposobu na ilościowe określenie informacji doprowadziły go do wzoru na entropię o tej samej postaci, co w termodynamice. W termodynamice entropia mierzy spontaniczne rozproszenie energii: ile energii jest rozproszone w procesie lub jak szeroko się ono rozproszy – w określonej temperaturze.

$$\mathrm{d}S = \frac{\delta Q}{T}.$$

gdzie dS to zmiana entropii, δQ to przeniesiona energia, a T to temperatura. Entropia w termodynamice statystycznej została zaproponowana przez Ludwiga Boltzmanna w latach 70. XIX wieku poprzez analizę statystycznego zachowania mikroskopijnych składników układu . Boltzmann wykazał, że ta definicja entropii jest równoważna entropii termodynamicznej w stałym czynniku – znanym jako stała Boltzmanna. Podsumowując, termodynamiczna definicja entropii dostarcza eksperymentalnej definicji entropii, podczas gdy statystyczna definicja entropii rozszerza to pojęcie, zapewniając wyjaśnienie i głębsze zrozumienie jego natury. W termodynamice statystycznej entropię

można interpretować jako miarę niepewności i nieuporządkowania. Dokładniej, entropia w termodynamice statystycznej jest logarytmiczną miarą liczby stanów układu, które mają znaczne prawdopodobieństwo bycia zajętymi:

$$S = -k_B \sum_i p_i \log p_i,$$

p_i to prawdopodobieństwo, że układ znajduje się w i-tym stanie, zazwyczaj dane rozkładem Boltzmanna, a k^B to stała Boltzmanna. Entropia termodynamiczna i entropia Shannona są koncepcyjnie równoważne: liczba układów zliczanych przez entropię termodynamiczną odzwierciedla ilość informacji Shannona potrzebną do zaimplementowania dowolnego konkretnego układu materii i energii. Jedyną istotną różnicą między entropią termodynamiczną fizyki a entropią informacji Shannona są jednostki miary: pierwsza jest wyrażona w jednostkach energii podzielonych przez temperaturę, druga w zasadniczo bezwymiarowych bitach informacji.

Uzyskaj inteligencję tak łatwo, jak informację, energię i materię

Dzięki wynalezieniu sieci transportowej, sieci energetycznej i Internetu, jesteśmy w stanie uzyskać informacje, energię i substancje w wygodniejszy sposób. Czy w przyszłości będziemy w stanie uzyskać inteligencję tak łatwo, jak informację, energię i materię? Oczywiście, takie marzenie nie może być obecnie w pełni zrealizowane.

Wyzwania związane z połączoną inteligencją

Obecne algorytmy sztucznej inteligencji (AI) wykorzystują dużą ilość danych, a ich wiarygodność jest bardzo ważna. Algorytmy AI potrzebują lepszych źródeł w eksploracji danych do modeli szkoleniowych, aby skuteczniej rozwiązywać problemy. Jednak udostępnianie danych/informacji o wysokiej dokładności i z uwzględnieniem prywatności jest trudne za pośrednictwem obecnego Internetu informacji. Dlatego większość istniejących prac nad AI koncentruje się na uczeniu się pojedynczego agenta, który w dużej mierze opiera się na ogromnych, predefiniowanych zbiorach danych z lokalnym środowiskiem. Jednak w praktyce wiele interesujących systemów jest albo zbyt złożonych, aby można je było poprawnie modelować w stałych, predefiniowanych środowiskach, albo dynamicznie zmieniających się. Co więcej, chociaż podejście to można potwierdzić na podstawie niektórych badań nad uczeniem się zwierząt [6], jest ono dalekie od uczenia się człowieka, które wymaga znacznie mniej zestawów danych i jest znacznie bardziej elastyczne w adaptacji do nowych środowisk. Co jest cechą definiującą ludzkie uczenie się? Według Big History Project , uczenie się zbiorowe jest cechą definiującą ludzi. Dzięki uczeniu się zbiorowemu ludzie mogą zachować inteligencję, dzielić się nią ze sobą i przekazywać ją następnemu pokoleniu. Innymi słowy, uczenie się zbiorowe to zdolność do dzielenia się inteligencją tak wydajnie, że idee jednostek mogą być przechowywane w pamięci zbiorowej społeczności i mogą kumulować się przez pokolenia. W rzeczywistości ludzie są jedynym gatunkiem zdolnym do dzielenia się inteligencją z taką wydajnością, że zmiany kulturowe zaczynają przyćmiewać zmiany genetyczne. Uczenie się zbiorowe jest cechą definiującą nasz gatunek, ponieważ wyjaśnia naszą zadziwiającą technologiczną wczesność i dominującą rolę, jaką odgrywamy w biosferze.

Sieciowanie wywiadowcze

Dlatego przewidujemy, że kolejnym paradygmatem sieciowania może być sieciowanie wywiadowcze, które umożliwi łatwe pozyskiwanie informacji, takich jak materia, energia i informacja. Należy pamiętać, że inteligencja nie jest równoznaczna z informacją. Jest ona raczej abstrakcją informacji wyższego poziomu. W erze sieciowania informacyjnego Internet ma udaną architekturę klepsydry o „cienkiej talii”, w której uniwersalna warstwa sieciowa (tj. IP) stanowi centrum. Ta scentralizowana

warstwa implementuje podstawową funkcjonalność globalnych sieci informacyjnych. Dzięki tej architekturze zarówno technologie niższej, jak i wyższej warstwy mogą rozwijać się niezależnie. Ta architektura klepsydry o „cienkiej talii" z powodzeniem umożliwiła gwałtowny rozwój sieciowania informacyjnego. Rysunek 3 przedstawia tę smukłą architekturę klepsydry.

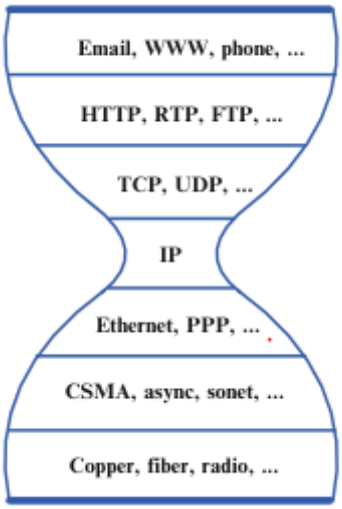

Podobnie, przewidujemy architekturę klepsydry o „cienkiej talii" dla sieciowania wywiadowczego, która wymaga dalszych badań. Odkrywanie informacji wywiadowczych stanowi kolejne wyzwanie. Ponieważ inteligentne tożsamości są rozproszone w różnych lokalizacjach geograficznych w paradygmacie sieciowania wywiadowczego, skuteczne mechanizmy wykrywania informacji wywiadowczych są niezbędne do identyfikacji i lokalizacji informacji wywiadowczych. Mechanizm publikowania i subskrybowania, wywodzący się z sieci zorientowanych na informacje (ICN) [8], może przynieść korzyści w zakresie odkrywania informacji wywiadowczych. Bezpieczeństwo i prywatność to istotne kwestie w sieciach wywiadowczych. Ze względu na kwestie bezpieczeństwa i prywatności użytkownicy obawiają się udostępniania swoich danych wywiadowczych innym. Chociaż problemy te występują w istniejących paradygmatach sieciowych, są one ważniejsze w sieciach wywiadowczych, ponieważ w wywiadach zazwyczaj zaangażowane jest działanie. Niewłaściwe działanie może spowodować więcej szkód niż niewłaściwa informacja. Blockchain może być wykorzystany do rozwiązania tych problemów.

Bezpieczeństwo i prywatność dzięki technologii blockchain

Blockchain to technologia rozproszonego rejestru, która wyewoluowała z Bitcoina i innych kryptowalut. Od czasów starożytnych rejestry stanowiły podstawę działalności gospodarczej – służyły do rejestrowania aktywów, płatności, kontraktów lub transakcji kupna-sprzedaży. Przeszły od rejestrowania na glinianych tabliczkach do papirusu, pergaminu i papieru. Chociaż wynalezienie komputerów i internetu znacznie ułatwiło proces prowadzenia ewidencji, podstawowa zasada pozostała niezmieniona – rejestry są zazwyczaj scentralizowane. Ostatnio, wraz z ogromnym rozwojem kryptowalut (np. Bitcoina), technologia rozproszonego rejestru zyskała znaczną uwagę. Rozproszony rejestr to w istocie konsensus replikowanych, współdzielonych i zsynchronizowanych danych rozproszonych geograficznie w sieci wielu węzłów. Nie ma centralnego administratora ani scentralizowanego magazynu danych. Dzięki algorytmowi konsensusu wszelkie zmiany w rejestrze są odzwierciedlane w kopiach. Bezpieczeństwo i dokładność rejestru są utrzymywane kryptograficznie zgodnie z zasadami uzgodnionymi w ramach sieci. Jedną z form rozproszonego systemu rozliczeniowego jest blockchain, który stanowi serce Bitcoina. Blockchain to stale rosnąca lista

rekordów, zwanych blokami, powiązanych i zabezpieczonych kryptograficznie, jak pokazano na rysunku 4.

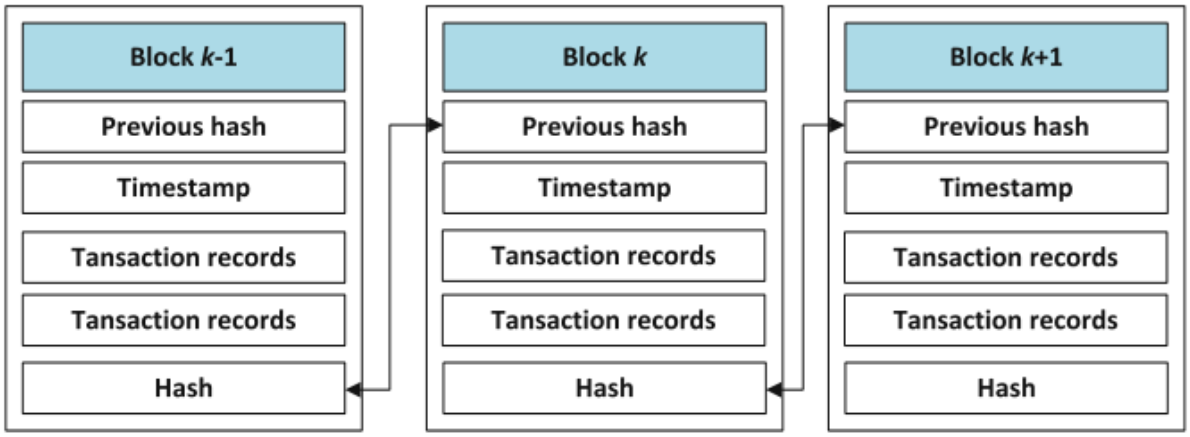

Systemy blockchain dzielą się generalnie na trzy kategorie: publiczne blockchainy, blockchainy konsorcjum i blockchainy prywatne. Publiczne blockchainy to blockchainy bez uprawnień, podczas gdy blockchainy konsorcjum i blockchainy prywatne to blockchainy z uprawnieniami. W publicznym blockchainie każdy może dołączyć do sieci, uczestniczyć w procesie konsensusu, odczytywać i wysyłać transakcje oraz utrzymywać współdzielony rejestr. Większość kryptowalut i niektóre platformy blockchain open source to systemy blockchain bez uprawnień. Bitcoin i Ethereum to dwa reprezentatywne publiczne systemy blockchain. Bitcoin to najsłynniejsza kryptowaluta stworzona przez Satoshi Nakamoto w 2008 roku. Ethereum to kolejny reprezentatywny publiczny blockchain, który obsługuje szeroki zakres zdecentralizowanych języków aplikacji, programowanych za pomocą inteligentnych kontraktów z kompletnością Turinga. Podstawowa architektura blockchaina składa się z sześciu głównych warstw, w tym warstwy danych, warstwy sieciowej, warstwy konsensusu, warstwy zachęt, warstwy kontraktów i warstwy aplikacji. Komponenty architektoniczne każdej warstwy przedstawiono na rysunku 5.

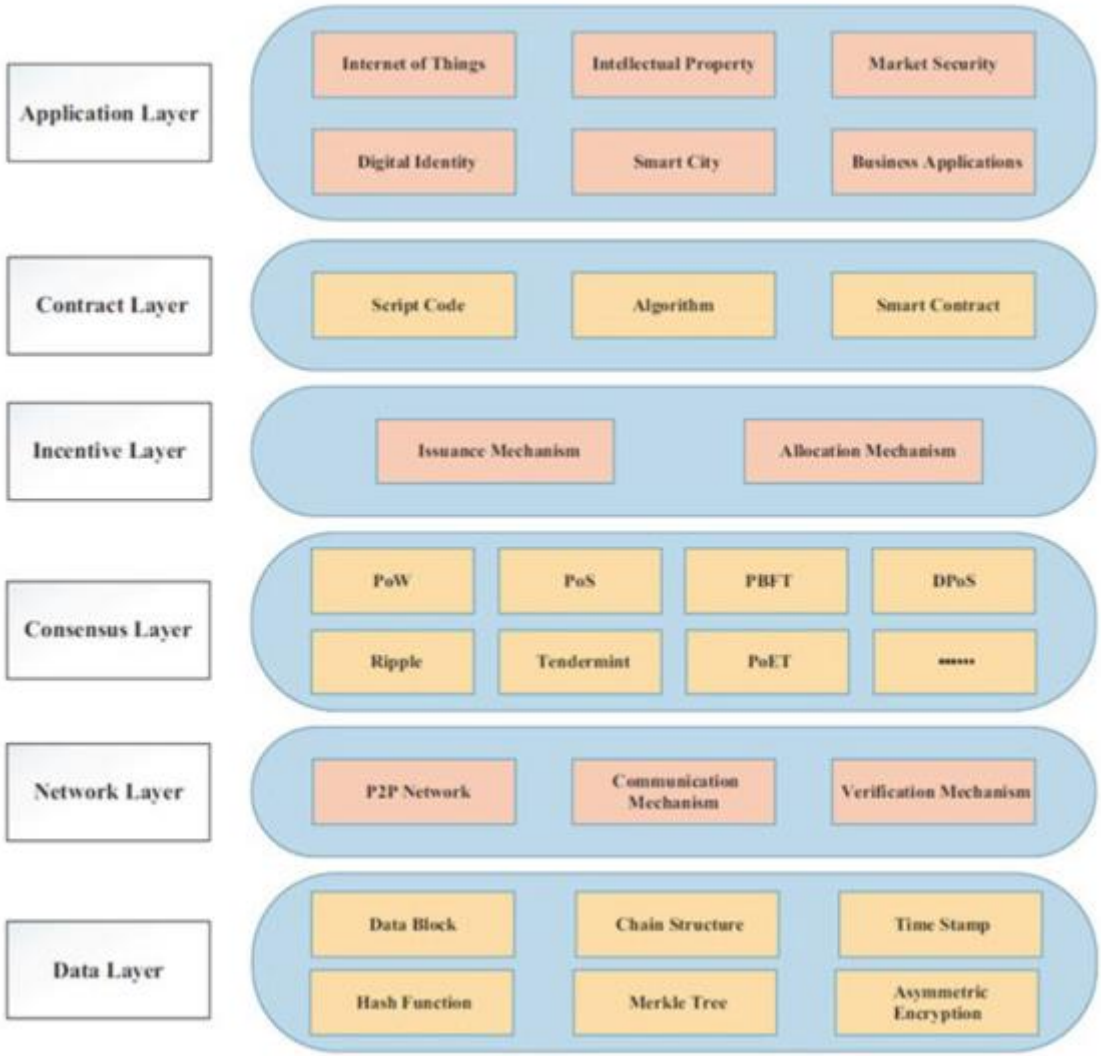

Najniższą warstwą architektury blockchain jest warstwa danych, która hermetyzuje bloki danych ze znacznikami czasu. Każdy blok zawiera niewielki podzbiór transakcji i jest „powiązany" z poprzednim blokiem, co skutkuje uporządkowaną listą bloków. Warstwa sieciowa składa się z rozproszonego mechanizmu sieciowego, mechanizmu komunikacji i mechanizmu weryfikacji danych. Celem tej warstwy jest dystrybucja, przekazywanie i walidacja transakcji blockchain. Topologia sieci blockchain jest zazwyczaj modelowana jako sieć P2P, w której uczestnicy mają równe uprawnienia. Warstwa konsensusu składa się z różnych algorytmów konsensusu. Bardzo istotną kwestią jest sposób osiągnięcia konsensusu między niezaufanymi węzłami w zdecentralizowanym środowisku. W sieci blockchain nie ma zaufanego węzła centralnego. Dlatego potrzebny jest protokół, który zapewni, że wszystkie zdecentralizowane węzły osiągną konsensus przed włączeniem bloku do blockchaina. Popularne mechanizmy konsensusu obejmują Proof of Work (PoW), Proof of Stake (PoS), PBFT i Delegated Proof of Stake (DPoS). Warstwa zachęt jest główną siłą napędową sieci blockchain. Dzięki integracji, czynniki ekonomiczne, takie jak mechanizm emisji i dystrybucji bodźców ekonomicznych, są wprowadzane do sieci blockchain, aby motywować węzły do wniesienia własnego wkładu w weryfikację danych. W szczególności, po utworzeniu nowego bloku, pewna zachęta ekonomiczna (np. waluta cyfrowa) zostanie przyznana jako nagroda w oparciu o ich wkład. Warstwa kontraktu wprowadza programowalność do blockchaina. Różne skrypty i algorytmiczne inteligentne kontrakty służą do implementacji bardziej złożonych, programowalnych transakcji. Konkretnie, inteligentny

kontrakt to zestaw reguł bezpiecznie przechowywanych w blockchainie. Inteligentne kontrakty mogą kontrolować cyfrowe zasoby użytkowników, wyrażać logikę biznesową oraz formułować prawa i obowiązki uczestników. Inteligentne kontrakty można traktować jako samoczynnie wykonujące się programy przechowywane w blockchainie. Podobnie jak transakcje w blockchainie, wejścia, wyjścia i stany inteligentnych kontraktów są weryfikowane przez każdy węzeł. Najwyższą warstwą architektury blockchaina jest warstwa aplikacji, która składa się z aplikacji biznesowych, takich jak Internet Rzeczy, własność intelektualna, bezpieczeństwo rynku, tożsamość cyfrowa itp. Aplikacje te mogą świadczyć nowe usługi oraz umożliwiać zarządzanie i optymalizację działalności. Chociaż technologia blockchain jest wciąż w powijakach, środowisko akademickie i przemysł starają się zastosować tę obiecującą technologię w wielu dziedzinach. Blockchain ma ogromny potencjał, aby stać się nowym fundamentem naszych systemów gospodarczych i społecznych. Technologia blockchain jest szeroko stosowana w różnych dziedzinach, w tym w inteligentnych miastach, inteligentnej opiece zdrowotnej, inteligentnych sieciach energetycznych, inteligentnym transporcie i zarządzaniu łańcuchem dostaw. Rysunek 6 pokazuje, że doskonałe właściwości blockchaina mogą umożliwić tworzenie sieci wywiadowczych, w tym inteligentne udostępnianie, bezpieczeństwo i prywatność, zdecentralizowaną inteligencję, kolektywne uczenie się oraz kwestie zaufania w podejmowaniu decyzji.

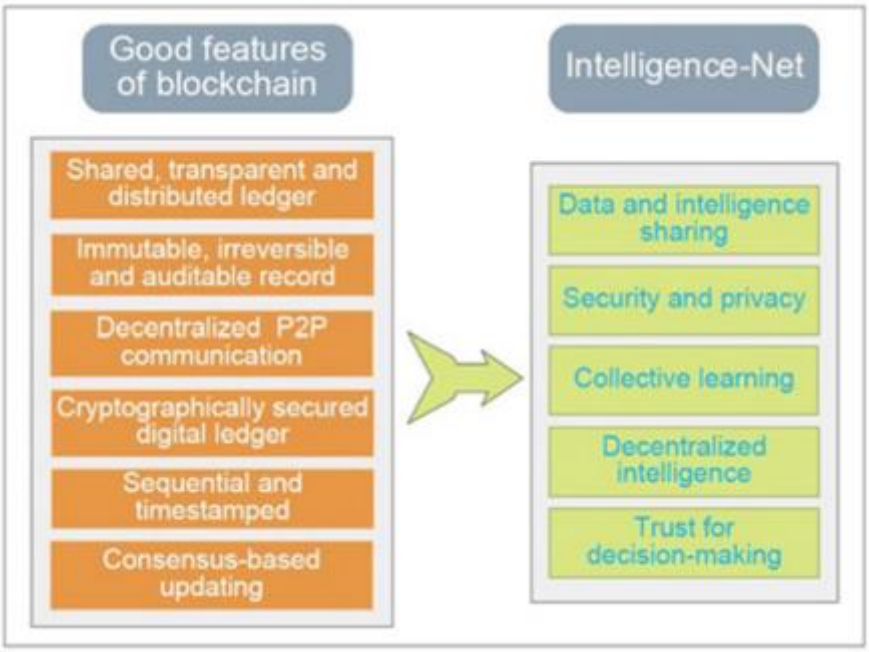

Wykorzystując te doskonałe cechy blockchaina, może on zapewnić wiarygodność, bezpieczeństwo, prywatność i inne parametry połączenia sieciowego inteligentnej sieci. Wiarygodność współdzielonej inteligencji odgrywa ważną rolę w sieci wywiadowczej (Intelligence-Net). Technologia blockchain może zostać wykorzystana do rozwiązania problemu nieefektywnego zarządzania udostępnianiem informacji wywiadowczych, co stanowi kluczowe wąskie gardło sieci wywiadowczych. Ze względu na problemy z zaufaniem i prywatnością, większość użytkowników obawia się udostępniania swoich danych i informacji wywiadowczych innym. Dzięki mechanizmom motywacyjnym wbudowanym w blockchain, rozproszone podmioty są zachęcane do dzielenia się informacjami wywiadowczymi. W szczególności każda transakcja w blockchainie jest weryfikowana i przechowywana w rozproszonym rejestrze w oparciu o jednokierunkowe kryptograficzne funkcje skrótu. Te zawsze wykonywane transakcje są niepodważalne i nieodwracalne po osiągnięciu konsensusu między rozproszonymi podmiotami. Rysunek 8.6 przedstawia zalety technologii blockchain, które mogą umożliwić tworzenie sieci wywiadowczych, w tym udostępnianie informacji wywiadowczych, bezpieczeństwo i prywatność,

zdecentralizowany wywiad, kolektywne uczenie się oraz kwestie zaufania w procesie podejmowania decyzji. Dzięki tym zaletom technologia blockchain może umożliwić identyfikację pochodzenia informacji w sieciach wywiadowczych i znacząco zwiększyć ich wiarygodność.

Jazda autonomiczna oparta na sieciowaniu inteligencji

Jazda autonomiczna

Samochody autonomiczne to niewątpliwie ekscytujący temat, w którym sztuczna inteligencja zmienia nasze życie. Połączone pojazdy autonomiczne to pojazdy, które wykorzystują zaawansowaną technologię do wykrywania otoczenia i działają bez ingerencji człowieka. Dokładność i wydajność technologii sztucznej inteligencji mają kluczowe znaczenie dla rozwoju połączonych pojazdów autonomicznych. Nowoczesne połączone samochody autonomiczne zazwyczaj posiadają ponad 100 czujników (takich jak radar, kamery, lidar itp.). Oczekuje się, że liczba czujników znacznie wzrośnie w najbliższej przyszłości. Pomimo ogromnej ilości informacji, jakie połączony samochód autonomiczny może pozyskać z tych czujników, nadal trudno jest zaprojektować niezawodny i ekonomiczny samochód autonomiczny, który mógłby dostosowywać się do różnych warunków otoczenia. Aby rozwiązać te problemy, istnieją dwie metody: inteligencja rowerowa i scentralizowane uczenie się. W podejściu opartym na inteligencji rowerowej gromadzenie danych z czujników, uczenie się i trenowanie modeli oraz podejmowanie decyzji odbywają się lokalnie na rowerze. Ze względu na swoją prostotę, podejście oparte na inteligencji rowerowej jest popularne wśród badaczy w eksperymentach i testach. Metoda ta ma jednak wady, takie jak ograniczona liczba czujników pokładowych, ograniczone środowisko jazdy i ograniczona moc obliczeniowa. W scentralizowanym podejściu uczenia się, uczenie się i trenowanie modeli odbywa się w chmurze. Kilku producentów, w tym Tesla, przyjęło to podejście. Samochody autonomiczne wykorzystują czujniki pokładowe do gromadzenia danych i przesyłania ich do chmury. Uczenie maszynowe odbywa się w chmurze, a model globalny jest aktualizowany centralnie i jednolicie. Podczas jazdy autonomicznej pojazd autonomiczny podejmuje decyzje w oparciu o dane w czasie rzeczywistym z czujników i model globalny pobrany z chmury. Funkcja pobierania danych z czujników przez pojazd autonomiczny służy do przesyłania danych z czujników i pobierania modelu. Chociaż metoda ta jest bardzo popularna wśród producentów, istnieją pewne obawy: ogromny transfer danych stanowi wyzwanie dla obecnej sieci. Pojedynczy samochód autonomiczny może generować setki terabajtów danych dziennie. Przechowywanie danych dla wszystkich samochodów autonomicznych stanowi kolejne wyzwanie. Ponadto użytkownicy obawiają się kwestii prywatności i bezpieczeństwa związanych z danymi z samochodów autonomicznych. Kilka lat temu ludzie byli optymistycznie nastawieni do perspektywy jazdy autonomicznej. Dlaczego wspomina Pan o jeździe autonomicznej? Jeśli chodzi o sztuczną inteligencję, wiele osób myśli: „w przyszłości nie będziesz musiał prowadzić samochodu sam”.

Wyzwania związane z autonomiczną jazdą

Chociaż ideał jest bardzo ambitny, rzeczywistość wciąż jest okrutna. Być może słyszałeś o wielu przykładach, zwłaszcza o wypadkach spowodowanych przez człowieka w Tesli, Uberze i niektórych dużych fabrykach. Pojawiły się również istotne doniesienia w Chinach, w tym o słynniejszej Tesli, która nie rozpoznaje białych obiektów, co prowadzi do różnych wypadków. Prezes Waymo również ostudził zapał wszystkich. Waymo jest spółką zależną Google Autonomous Driving i ma wpływ na rozwój autonomicznej jazdy. Od 2009 roku autonomiczny samochód prezesa Waymo przejechał ponad 32 miliony kilometrów po prawdziwych drogach i 32 miliardy kilometrów w środowiskach wirtualnych. Prezes Waymo stwierdził jednak, że pojazdy te poruszały się po wyznaczonych trasach i w ograniczonych okolicznościach. Dodał, że autonomiczna jazda nie pojawi się na drogach na dużą skalę przez dziesięciolecia. Gdzie leży problem? Niedawno skomentował: „Technologia jest naprawdę

trudna”, technicznie zbyt trudna. Elon Musk obiecuje robotaksówki Tesli na przyszły rok – i to już od prawie dekady! W lipcu 2021 roku skomentował: „Uogólniona autonomiczna jazda to trudny problem, ponieważ wymaga rozwiązania dużej części problemów związanych ze sztuczną inteligencją w świecie rzeczywistym. Nie spodziewałem się, że będzie to aż tak trudne, ale z perspektywy czasu trudność jest oczywista. Nic nie ma większego stopnia swobody niż rzeczywistość”. Zastanawiałem się więc, na czym polega problem. Każdy ma inne zdanie. Wszyscy mówią o „problemie długiego ogona”. Termin ten pochodzi ze statystyki i opisuje rozkład prawdopodobieństwa jako długi ogon. Bardzo mało prawdopodobne zdarzenie ma małe prawdopodobieństwo, ale się wydarzy, czyli prawdopodobieństwo nie będzie zerowe. Obecnie większość sztucznej inteligencji napotka ten problem, ponieważ nie da się zgromadzić danych do trenowania wszystkich sytuacji w trakcie procesu trenowania. Dlaczego więc ludzie potrafią radzić sobie z tymi niepewnościami? Ponieważ potrafią abstrahować i posiadają inteligencję. Z tego punktu widzenia istnieje więc duża różnica między informacją a inteligencją. Jaka to różnica? Samochód autonomiczny może generować mnóstwo danych dziennie, a wszelkiego rodzaju czujniki, takie jak kamery, GPS, LIDAR itp., generują mnóstwo danych. Jednak w przypadku autonomicznej jazdy tych informacji nie można utożsamiać z inteligencją. Definiuję inteligencję jako „kierowanie tym czymś”, takie jak kierowanie, hamowanie, przyspieszanie itp.

Sieciowanie inteligencji dla autonomicznej jazdy

W oparciu o sieciowanie inteligencji, nowe podejście można zastosować do autonomicznej jazdy. Rysunek 7 przedstawia tę nową ramę.

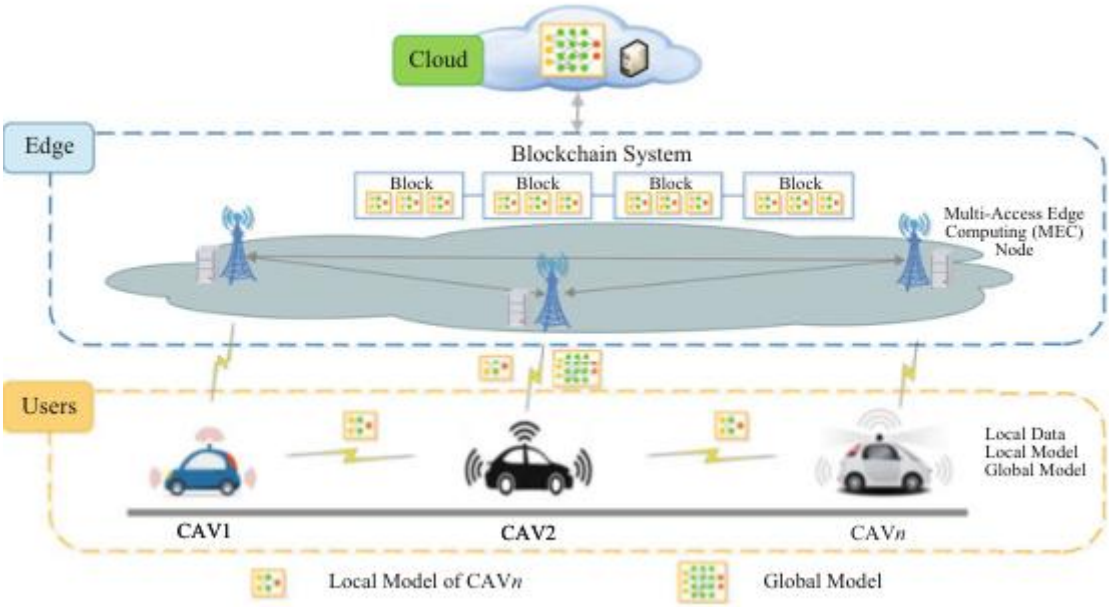

W porównaniu z tradycyjnymi metodami, główną cechą tego nowego podejścia jest to, że pojazd działa jako agent, który może uczyć się na podstawie danych, zapisywać dane i udostępniać je innym pojazdom. W tym kontekście inteligencja odnosi się do sposobu prowadzenia pojazdu w różnych środowiskach. Aby osiągnąć sieciowanie inteligencji, w tym kontekście wykorzystano blockchain.

Kolektywne uczenie się przez wzmacnianie oparte na sieciowaniu inteligencji

W tradycyjnych algorytmach uczenia się przez wzmacnianie agenci mogą optymalizować wskaźniki wydajności w nieznanych wcześniej środowiskach, bazując na własnym doświadczeniu. Na rysunku 8

agent 1 wchodzi w interakcję z lokalnym środowiskiem 1, modelowanym przez proces decyzyjny Markowa (MDP).

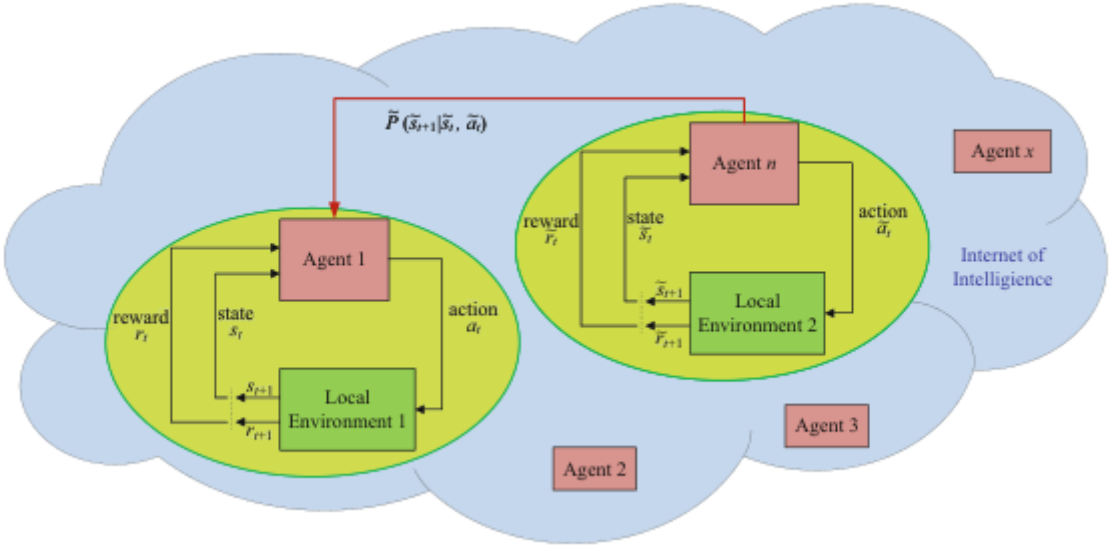

Podobnie, inni agenci wchodzą w interakcje ze swoim lokalnym środowiskiem. Aby to zrobić, agent musi zarządzać kompromisem między „eksploatacją" (maksymalizacją nagrody poprzez znane, skuteczne zachowania) a „eksploracją" (próbowaniem nowych zachowań z nieznanym sukcesem). Dylemat eksploatacji i eksploracji polega na tym, czy wybrać to, co agent już wie i uzyskać coś zbliżonego do oczekiwań, czy wybrać to, czego agent nie wie i ewentualnie dowiedzieć się więcej. Mówiąc bardziej ogólnie, załóżmy, że musisz wybrać restaurację na kolację. Jeśli wybierzesz ulubioną restaurację z historii, korzystasz ze swoich poprzednich, znanych sukcesów; jeśli wybierzesz nową restaurację, której wcześniej nie odwiedziłeś, stosujesz metodę eksploracyjną. Zarówno „eksploatacja", jak i „eksploatacja" odbywają się w środowisku lokalnym, bez pomocy innych agentów. Dlatego też, w literaturze poświęconej uczeniu przez wzmacnianie, trening wymaga dużej liczby predefiniowanych zbiorów danych z lokalnymi kontekstami, takimi jak stany, akcje, nagrody i prawdopodobieństwa przejścia. Co więcej, nawet po intensywnym treningu na dużych zbiorach danych, wyszkolonym agentom trudno jest dostosować się do nowych środowisk. W przykładzie restauracji, gdybyś używał tradycyjnego algorytmu uczenia maszynowego, musiałbyś wypróbować wszystkie pobliskie restauracje, aby znaleźć najlepszą. W oparciu o sieci inteligencji, możemy wykorzystać nową metodę kolektywnego uczenia się przez wzmacnianie (CRL) . W przeciwieństwie do tradycyjnego uczenia się przez wzmacnianie, agenci uczący się przez wzmacnianie mogą nie tylko uczyć się na podstawie własnego doświadczenia w środowisku lokalnym, ale także zachowywać inteligencję i dzielić się nią z innymi. W kolektywnym uczeniu się przez wzmacnianie wprowadzamy „Rozszerzenia", które umożliwiają agentom aktywną współpracę z innymi agentami. Ponownie, odwołując się do przykładu restauracji, możemy wyjaśnić podstawową ideę tego rozszerzenia. Zamiast sprawdzać wszystkie restauracje w okolicy, aby znaleźć najlepszą, zrób to, konsultując doświadczenia/opinie innych osób. Rysunek 8 przedstawia ramy tej koncepcji. Niech α i β będą odpowiednio współczynnikami kompromisu dla eksploracji i rozszerzenia. Niech L(π) będzie miarą wydajności strategii π, a $P(s_t, a_t)$ prawdopodobieństwem przejścia w czasie t, przy danym stanie s_t i działaniu w czasie t. Nowy problem optymalizacyjny przedstawia się następująco.

$$\max_{\pi} \underbrace{L(\pi)}_{\text{Exploitation}} + \alpha \underbrace{\mathop{\mathbb{E}}_{s_t, a_t \sim \pi} \left\{ D_{\mathrm{KL}}(P || P_{\theta_t})[s_t, a_t] \right\}}_{\text{Exploration}}$$

$$+ \beta \underbrace{\mathop{\mathbb{E}}_{s_t, a_t \sim \pi} \left\{ D_{\mathrm{KL}}(P || \tilde{P})[s_t, a_t] \right\}}_{\text{Extension}},$$

gdzie zachętą do eksploracji jest średnia dywergencja KL P od $P_{\theta t}$, czyli modelu, którego uczy się agent. Zachętą do rozszerzenia jest średnia dywergencja KL P od $\tilde{P}$, czyli modelu innego agenta.

Matematyczne modelowanie inteligencji

W każdym paradygmacie sieciowym kluczowe jest modelowanie „rzeczy" połączonych w ramach paradygmatu. Na przykład modelowanie informacji i modelowanie energii odgrywają fundamentalną rolę odpowiednio w internecie i sieciach energetycznych. W szczególności, w teorii informacji Shannona, użycie „entropii" do kwantyfikacji informacji jest kluczowe dla sukcesu internetu. Podobnie, sposób kwantyfikacji inteligencji jest kluczem nie tylko do sukcesu sieciowania inteligencji, ale także do rozwoju sztucznej inteligencji. Test Turinga jest pierwszą poważną propozycją testowania zdolności maszyny do wykazywania inteligentnych zachowań porównywalnych z ludzkimi lub nieodróżnialnych od nich. Jednak test Turinga nie wykorzystuje matematyki do kwantyfikacji inteligencji. Z historii ewolucji paradygmatów sieciowych możemy zauważyć, że paradygmaty sieciowe wyższego poziomu zapewniają wyższy poziom abstrakcji. Kiedy ludzie łatwo pozyskują materię, zależy im na tym, jak szybko mogą ją pozyskywać. Zaproponowano zatem koncepcję energii. Energię mierzy się ilościowo, mierząc szybkość ruchu materii. Ludzie, którzy łatwo pozyskują energię, martwią się ilością energii rozpraszanej. Dlatego zaproponowano koncepcję entropii termodynamicznej. Entropia to abstrakcyjne pojęcie, które pozwala ilościowo mierzyć stopień rozpraszania energii. Entropia reprezentuje ilość energii rozpraszanej w danej temperaturze podczas procesu rozpraszania energii. Ponadto, jak wspomniano wcześniej, entropia informacji i entropia termodynamiczna są równoważne. Zatem informację można również określić ilościowo jako ilość energii rozpraszanej. Podobnie inteligencję można zdefiniować jako miarę procesów „przed i po". W procesie uczenia się jest to miara tego, ile informacji rozprzestrzeniło się w czasie lub jak szeroko informacja rozprzestrzeniła się po uczeniu się w porównaniu z jej poprzednim stanem. Podobnie jak entropia termodynamiczna, inteligencja nie jest wielkością bezwzględną, lecz względną, która opisuje, jak bardzo się zmienia. Dokładniej, inteligencję można ilościowo wyrazić następującym wzorem:

$$\mathrm{d}L = \frac{\partial S}{\partial R}.$$

gdzie dL jest zmianą inteligencji, S jest podobieństwem między bieżącym porządkiem a oczekiwanym porządkiem, a R jest parametrem w ogólności (np. czasem, wolumenem danych itp.). Ponieważ zmiana inteligencji jest związana z wieloma parametrami, reprezentacją matematyczną jest funkcja wielowymiarowa. Gdy rozważamy tempo zmian funkcji wielowymiarowej względem jednej ze zmiennych niezależnych, jest ono zazwyczaj wyrażane przez pochodną cząstkową ∂. Na przykład, treścią uczenia się inteligentnej maszyny jest rozpoznanie obrazka słonia. Jeśli maszyna otrzyma obrazek słonia, oczekiwany porządek to „to jest słoń". Jeśli bieżący porządek maszyny to „to jest kot", co nie jest poprawną odpowiedzią na pytanie „chcieć", występuje gradient. W miarę postępu procesu uczenia się podobieństwo między bieżącym porządkiem a oczekiwanym porządkiem rośnie, a gradient

maleje. Jeśli inteligentna maszyna A wykorzystuje wolumen danych 100 zdjęć, aby zwiększyć podobieństwo do bardzo wysokiego poziomu, podczas gdy inna inteligentna maszyna B wykorzystuje wolumen danych 10 000 zdjęć, aby zwiększyć podobieństwo do tego samego poziomu, oznacza to, że A jest bardziej inteligentna niż B (z perspektywy wolumenu danych). Podobnie, jeśli inteligentna maszyna A potrzebuje 1 godziny, aby zwiększyć podobieństwo do bardzo wysokiego poziomu, innej inteligentnej maszynie B zajmuje to 100 godzin. Oznacza to, że A jest bardziej inteligentna niż B (z perspektywy czasu). Wykorzystanie tego matematycznego modelowania inteligencji powinno umożliwić ujednolicenie różnych szkół sztucznej inteligencji. Pracujemy w tym kierunku.