

Naturalna droga do sztucznej inteligencji

Autor dowodzi, że badania procesów ewolucyjnych, które skutkują ludzką inteligencją za pomocą modeli matematycznych/komputerowych, mogą stanowić poważną naukową podstawę badań nad sztuczną inteligencją. Przedstawiono „inteligentne wynalazki” ewolucji biologicznej (odruch bezwarunkowy, przyzwyczajenie, odruch warunkowy, . . .) do modelowania, koncepcyjne teorie tła (teoria przejścia metasystemu V.F. Turchina i teoria systemów funkcjonalnych P.K. Anokhina) oraz nowoczesne podejścia (sztuczne życie, symulacja adaptacyjnego zachowania) do takiego modelowania. Opisano dwa konkretne modele komputerowe: „Model ewolucyjnego powstawania celowego adaptacyjnego zachowania” i „Model ewolucji agentów sieciowych”. Pierwszy model to czyste badanie naukowe; drugi model to krok do praktycznych zastosowań. Na koniec przedstawiono możliwą drogę od tych prostych modeli do wdrożenia inteligencji wysokiego poziomu.

Wstęp

Sztuczna inteligencja (AI) jest obszarem badań stosowanych. Doświadczenie pokazuje, że obszar badań stosowanych odnosi sukces, gdy istnieje mocna podstawa naukowa dla tego obszaru. Na przykład fizyka ciała stałego była naukową podstawą mikroelektroniki w drugiej połowie XX wieku. Należy zauważyć, że fizyka ciała stałego jest bardzo interesująca dla fizyków z naukowego punktu widzenia, a zatem fizycy wykorzystali większość naukowych podstaw mikroelektroniki, niezależnie od możliwych zastosowań ich wyników. A wyniki mikroelektroniki są kolosalne, tak jak są teraz wszędzie. Jaka jest możliwa naukowa podstawa dla AI (analogicznie do naukowej podstawy mikroelektroniki)? Możemy rozważyć ten problem w następujący sposób. Naturalna ludzka inteligencja wyłoniła się poprzez ewolucję biologiczną. Z naukowego punktu widzenia bardzo interesujące jest badanie procesów ewolucyjnych, które doprowadziły do ludzkiej inteligencji, badanie ewolucji poznawczej, ewolucji zdolności poznawczych zwierząt. Ponadto badania ewolucji poznawczej są bardzo ważne z epistemologicznego punktu widzenia; takie badania mogłyby wyjaśnić głęboki problem epistemologiczny: dlaczego ludzka inteligencja, ludzkie myślenie i ludzka logika są stosowalne do poznania natury?

Dlatego możemy wnioskować, że badanie ewolucji poznawczej może być naturalną naukową podstawą rozwoju AI. Jakie są możliwe tematy badań ewolucji poznawczej? Jakie są możliwe relacje między badaniami akademickimi ewolucji poznawczej a badaniami nad stosowaną AI? Moim zdaniem naturalne jest:

1. Opracowanie modeli matematycznych/komputerowych „inteligentnych wynalazków” ewolucji biologicznej (takich jak odruch bezwarunkowy, przyzwyczajenie, odruch warunkowy itd.).
2. Przedstawienie za pomocą takich modeli ogólnego obrazu ewolucji poznawczej.
3. Wykorzystanie tych modeli jako naukowego tła dla badań nad AI.

Celem jest zaproponowanie i omówienie kroków takich badań. Struktura rozdziału jest następująca. Sekcja 2 omawia problem epistemologiczny, który może stymulować badania ewolucji poznawczej. Sekcja 3 przedstawia przedmiot tych badań i niektóre podejścia koncepcyjne do badań. Sekcja 4 opisuje dwa konkretne i dość proste modele: „Model ewolucyjnego pojawiania się celowego adaptacyjnego zachowania” i „Model ewolucji agentów sieciowych”. Rozdział 5 przedstawia możliwy sposób implementacji wyższych zdolności poznawczych z tych prostych modeli.

Problem epistemologiczny

Istnieje bardzo interesujący i głęboki problem epistemologiczny: dlaczego ludzka inteligencja ma zastosowanie w poznaniu natury? Aby zilustrować ten problem, rozważmy fizykę, najbardziej podstawową naukę przyrodniczą. Siła fizyki wynika z szerokiego i skutecznego wykorzystania matematyki. Jednak dlaczego matematyka ma zastosowanie w fizyce? Rzeczywiście, matematyk tworzy swoje teorie, wykorzystując swoją inteligencję, zupełnie niezależnie od rzeczywistego świata fizycznego. Matematyk może pracować w ciszy swojego gabinetu, odpoczywając na sofie lub w odizolowanej celi więziennej. Dlaczego jego wyniki mają zastosowanie w prawdziwej naturze? Czy potrafimy rozwiązać te pytania? Moim zdaniem tak. Możemy analizować ewolucyjne korzenie ludzkiej inteligencji i próbować zbadać, dlaczego i w jaki sposób ewolucyjnie pojawiły się wysokopoziomowe inteligentne zdolności poznawcze. Innymi słowy, możemy prześledzić ewolucyjne korzenie zwierzęcych i ludzkich zdolności poznawczych i przedstawić ogólny obraz ewolucyjnego pojawienia się ludzkiego myślenia i ludzkiej inteligencji. Możemy analizować, dlaczego i w jaki sposób pojawiły się zwierzęce i ludzkie cechy poznawcze, jak działają te cechy poznawcze, dlaczego mają zastosowanie w poznaniu natury. Czy naprawdę możemy postępować w ten sposób? Czy możemy znaleźć ewolucyjne korzenie ludzkiej inteligencji we własnościach poznawczych zwierząt? Tak, możemy. Rozważmy elementarną regułę logiczną, którą stosuje matematyk w dedukcyjnych wnioskowaniach, modus ponens: „jeśli A jest obecne, a B jest konsekwencją A, to B jest obecne” lub $\{A, A \rightarrow B\} \Rightarrow B$. Przejdźmy teraz od matematyka do psa Pawłowa. Pies jest poddawany eksperymentowi warunkowania klasycznego. Neutralny bodziec warunkowy (CS), dźwięk, jest poprzedzony biologicznie znaczącym bodźcem bezwarunkowym (US), pokarmem. Bodziec bezwarunkowy wywołuje wydzielanie śliny. Po kilku prezentacjach pary (CS,US) relacja przyczynowa $CS \rightarrow US$ jest przechowywana w pamięci psa. Wykorzystując tę relację w nowej prezentacji CS, pies jest w stanie przeprowadzić elementarną „inferencję”: $\{CS, CS \rightarrow US\} \Rightarrow US$. Następnie, oczekując US, pies ślini się. Oczywiście, zastosowanie reguły modus ponens (czysto dedukcyjnej) przez matematyka i indukcyjne „wnioskowanie” psa są oczywiście różne. Czy jednak możemy pomyśleć o ewolucyjnych korzeniach reguł logicznych stosowanych w matematyce? Tak, z pewnością możemy. Logiczny wniosek matematyka i „inferencja indukcyjna” psa są jakościowo podobne. Co więcej, możemy pójść dalej. Możemy sobie wyobrazić, że w pamięci psa istnieje sieć semantyczna. Ta sieć jest zbiorem pojęć i powiązań między pojęciami. Na przykład możemy sobie wyobrazić, że pies ma pojęcia „jedzenie”, „niebezpieczeństwo”, „pies płci przeciwnej” – pojęcia te odpowiadają głównym potrzebom zwierzęcym: energii, bezpieczeństwu i reprodukcji. Ponadto pojęcie „jedzenie” może mieć semantyczne powiązania z pojęciami „mięso”, „chleb” itd. Możemy sobie również wyobrazić, że semantyczne powiązanie między CS i US jest generowane w pamięci psa podczas warunkowania klasycznego. Na przykład, jeśli CS jest dźwiękiem, a US mięsem, to semantyczne powiązanie między CS i US można zilustrować.



Możemy sobie wyobrazić generowanie i rozwój różnych sieci semantycznych w ciągu życia psa. Sieci te odzwierciedlają doświadczenia psa i są przechowywane w jego pamięci. W pewnym stopniu te sieci semantyczne są podobne do sieci semantycznych badanych w badaniach nad sztuczną inteligencją. Możemy więc pomyśleć o ewolucyjnych korzeniach reguł wnioskowania i logicznych wniosków. Ponadto chciałbym tutaj zwrócić uwagę na interesującą analogię między odruchem warunkowym a rozważaniami Hume’a na temat pojęcia przyczynowości. W 1748 roku David Hume napisał „Philosophical Essays Concerning Human Understanding”, w którym zakwestionował pojęcie przyczynowości, jedno z głównych pojęć naukowych. Krótko mówiąc, argumentacja Hume’a jest następująca. i pewne schematy koncepcyjne, które mogłyby pomóc nam w modelowaniu procesu

ewolucji „inteligentnych” właściwości zwierząt. Ta sekcja próbuje przedstawić taki obraz ewolucji poznawczej i opisać takie schematy koncepcyjne.

„Inteligentne wynalazki” ewolucji biologicznej

Zaczynamy tutaj od samego początku – od najprostszych form życia – i próbujemy wyodrębnić poziomy „inteligentnych wynalazków” ewolucji biologicznej. Wspominamy przykłady „wynalazków” i odpowiadające im modele matematyczne/komputerowe, które zostały już opracowane.

Pierwszy poziom

Organizm postrzega różne stany środowiska zewnętrznego; informacje o tych stanach są zapamiętywane w genomie organizmu i dziedziczone. Organizm adaptacyjnie wykorzystuje informacje o tych stanach, zmieniając swoje zachowanie zgodnie ze zmianami stanów środowiska. Przykładem tego poziomu jest regulacja syntezy enzymów u bakterii zgodnie z klasycznym schematem. Ten schemat regulacji można przedstawić następująco. Bakteria E. Coli wykorzystuje glukozę jako swoje główne pożywienie. Jednak jeśli glukoza jest nieobecna, ale w środowisku obecny jest inny substrat, laktoza, E. Coli włącza syntezę specjalnych enzymów, które przekształcają laktozę w zwykły pokarm, glukozę. Gdy bakteria powraca do środowiska bogatego w glukozę, synteza enzymów transformujących zostaje wyłączona. Ten schemat regulacji można uznać za bezwarunkowy odruch na poziomie molekularno-genetycznym. Można go również uznać za schemat pierwotnego systemu kontroli. Model matematyczny takiego schematu regulacji, „adaptacyjny syser”, został stworzony i przeanalizowany przez [29]. Model ten przedstawia możliwy schemat pochodzenia pierwotnego systemu kontroli na poziomie prebiologicznym.

Drugi poziom

Organizm indywidualnie przechowuje informacje o sytuacjach w środowisku zewnętrznym w swojej pamięci krótkotrwałej. To zapamiętywanie zapewnia nabytą adaptację organizmu do zdarzeń w środowisku. Przykładem tego poziomu jest habituacja infusoria, zademonstrowana przez [19]. Jeśli infusorium jest wielokrotnie poddawane neutralnemu bodźcowi, np. kropli wody, jego reakcja (drżenie) na bodziec jest początkowo duża, ale w dalszym przebiegu eksperymentu reakcja ta maleje. Ta forma adaptacji jest typu krótkoterminowego. Według eksperymentów W. Kinastowskiego, przyzwyczajenie się pierwotniaków kształtuje się w ciągu 10 do 30 minut i utrzymuje się przez 1 do 3 godzin. Automaty Tsetlina to dobrze rozwinięte modele matematyczne, które odpowiadają mniej więcej „poziomowi inteligencji” przyzwyczajenia. Automaty Tsetlina ilustrują proste nabyte właściwości organizmów biologicznych i proste zachowania adaptacyjne w zmieniającym się środowisku zewnętrznym. W ostatniej dekadzie modele przyzwyczajenia są rozwijane w dziedzinie „Zachowania adaptacyjnego”

Trzeci poziom

Organizm indywidualnie przechowuje związki przyczynowe między zdarzeniami w środowisku zewnętrznym. Związki przyczynowe są przechowywane w pamięci długotrwałej. Przykładem tego poziomu jest warunkowanie klasyczne. W znanych eksperymentach I.P. Pawłowa (na psie, neutralny bodziec warunkowy, CS, był poprzedzony biologicznie znaczącym bodźcem bezwarunkowym, US. Bodziec bezwarunkowy wywołał pewną bezwarunkową reakcję. Po kilku prezentacjach pary CS → US, CS samo stało się zdolne do wzbudzenia tej samej (warunkowej) reakcji. Warunkowanie klasyczne ma kilka nietrywialnych osobliwości. Istnieją trzy etapy procedury uczenia się w warunkowaniu klasycznym: pregeneracja, generalizacja i specjalizacja . Podczas pregeneracji reakcja warunkowa jest nadal nieobecna, ale występuje wzrost aktywności elektrycznej w różnych obszarach mózgu

zwierzęcia. Podczas generalizacji zarówno CS, jak i inne (różnicowe) bodźce, które są podobne do CS, wzbudzają reakcję warunkową. Po generalizacji następuje specjalizacja, w której reakcja na bodźce różnicowe stopniowo zanika, podczas gdy reakcja na CS jest zachowana. Związek przyczynowy między CS i US jest przechowywany w pamięci długoterminowej: odruch warunkowy jest zachowywany przez kilka tygodni u kręgowców niskiego poziomu i do kilku lat (a może przez całe życie) u zwierząt wysokiego poziomu. Cechą charakterystyczną warunkowania klasycznego jest spontaniczne ożywienie: odnowienie się warunkowej reakcji, które następuje kilka godzin po wygaśnięciu odruchu warunkowego. Biologicznym znaczeniem warunkowania klasycznego jest przewidywanie przyszłych zdarzeń w otoczeniu i adaptacyjne wykorzystanie tego przewidywania. Istnieje szereg matematycznych i cybernetycznych modeli odruchu warunkowego, stworzonych i zbadanych przez i innych. Jednak moim zdaniem niektóre istotne aspekty warunkowania klasycznego nie zostały jeszcze opisane matematycznie (podobny punkt widzenia wyraził [6]). Dotyczy to głównie cechy spontanicznego ożywienia, roli motywacji w uczeniu się warunkowym i biologicznego znaczenia warunkowania klasycznego.

Istnieje kilka poziomów „inteligentnych wynalazków” pomiędzy warunkowaniem klasycznym a inteligencją człowieka. Tutaj wspominamy tylko o niektórych z nich. Warunkowanie instrumentalne jest podobne do warunkowania klasycznego, ale jest bardziej złożone: zwierzę musi odkryć odpowiednie nowe reakcje warunkowe (które nie są mu znane z góry), aby uzyskać wzmocnienie po prezentacji bodźca warunkowego.

łańcuchy warunkowania to sekwencja reakcji warunkowych, która powstaje na podstawie starych relacji warunkowych, które zostały już zapisane w pamięci zwierzęcia. Zwierzęta wysokiego poziomu wykorzystują nietrywialne modele środowiska zewnętrznego w swoim zachowaniu adaptacyjnym. Z pewnością pewne formy „logiki behawioralnej” są wykorzystywane w takim modelowaniu w celu przewidywania przyszłych sytuacji i osiągnięcia celu. Przykładami takiego „inteligentnego” zachowania są dobrze znane eksperymenty na małpach człekokształtnych. Małpy człekokształtne były w stanie wykorzystać kilka narzędzi (patyków, pudełek), aby pokonać kilka trudności i rozwiązać złożone zadanie dotarcia do pożywienia. Oczywiście jest, że małpy człekokształtne wykorzystują pewne modele i pewną logikę podczas rozwiązywania tych zadań. Ostatnim poziomem, który rozważamy, jest logika ludzka. Teorie matematyczne naszej logiki są dobrze rozwinięte. Istnieje rachunek zdań, rachunek predykatów i teorie wnioskowania matematycznego. Teorie logiki indukcyjnej i rozmytej były intensywnie rozwijane w ostatnich dekadach. W ten sposób możliwe jest wyodrębnienie kilku kluczowych „inteligentnych wynalazków” i rozważenie sekwencji osiągnięć ewolucji biologicznej. Zdolności poznawania zjawisk naturalnych stopniowo wzrastają w tej sekwencji. Analiza istniejących modeli „inteligentnych wynalazków” pokazuje, że jesteśmy bardzo daleko od pełnoskalowej teorii ewolucji poznania. Opracowane modele można traktować jedynie jako pierwsze kroki w kierunku takiej teorii. Modele te mają oczywiście fragmentaryczny charakter; nie ma modeli, które mogłyby opisać etapy przejściowe między inteligentnymi wynalazkami różnych poziomów ewolucyjnych. Tak więc modelowanie „inteligentnych wynalazków” ewolucji biologicznej znajduje się na początkowych etapach rozwoju. Dlatego też zasadne jest rozważenie pomysłów i schematów metodologicznych, które mogłyby pomóc w modelowaniu tych „wynalazków”. Poniżej przedstawimy niektóre podejścia metodologiczne: teorię przejścia metasystemu i teorię systemu funkcjonalnego.

Podejścia metodologiczne

Teoria przejścia metasystemu V.F. Turchina

W książce *The Phenomenon of Science. A Cybernetic Approach to Human Evolution*, Turchin przedstawił ewolucję cybernetycznych właściwości organizmów biologicznych i rozważał ewolucję

poznania naukowego jako kontynuację ewolucji biocybernetycznej [34]. Aby zinterpretować wzrost złożoności systemów cybernetycznych podczas ewolucji, Turchin zaproponował teorię przejścia metasystemu. Teoria ta wprowadziła ogólny schemat cybernetyczny przejść ewolucyjnych między różnymi poziomami organizacji biologicznej. W skrócie, teorię przejścia metasystemu można przedstawić następująco. Przejście z niższego poziomu hierarchii systemowej na następny wyższy poziom jest symbiozą szeregu systemów S_i niższego poziomu w połączony zestaw i S_i ; symbioza jest uzupełniana przez pojawienie się dodatkowego systemu C, który kontroluje zachowanie połączonych zestawu. Ta transformacja metasystemu skutkuje utworzeniem systemu S nowego poziomu ($S = C + i S_i$). System S można włączyć jako podsystem do następnego przejścia metasystemu. Turchin charakteryzuje ewolucję biologiczną następującymi głównymi przejściami metasystemu:

- Kontrola położenia: ruch
- Kontrola ruchu: drażliwość (odruch prosty)
- Kontrola drażliwości: odruch (złożony)
- Kontrola odruchu: asocjacja (odruch warunkowy)
- Kontrola asocjacji: myślenie ludzkie
- Kontrola myślenia ludzkiego: kultura

Turchin opisuje przejście metasystemu jako pewien cybernetyczny analog fizycznej przemiany fazowej. Zwraca szczególną uwagę na ilościową akumulację cech progresywnych w podsystemach S_i tuż przed przejściem metasystemu oraz na mnożenie i rozwój podsystemów przedostatniego poziomu hierarchii po przejściu metasystemu. Teoria przejścia metasystemu dostarcza nam interpretacji ogólnych procesów ewolucyjnego wzrostu złożoności. Bardziej intymne procesy inteligentnego zachowania adaptacyjnego można analizować na podstawie teorii systemów funkcjonalnych, która została zaproponowana i rozwijana w latach 1930-1970 przez rosyjskiego fizjologa P.K. Anokhina.

Teoria systemów funkcjonalnych P.K. Anokhina

System funkcjonalny Anokhina to system neurofizjologiczny, którego celem jest osiągnięcie niezbędnego dla organizmu rezultatu życiowego. Główne mechanizmy działania systemu funkcjonalnego to:

1. Synteza aferentna
2. Podejmowanie decyzji
3. Generowanie akceptora rezultatu działania
4. Generowanie działania (synteza eferentna)
5. Działanie złożone
6. Osiągnięcie rezultatu
7. Aferentacja wsteczna o parametrach rezultatu, porównanie rezultatu z jego modelem, który został wygenerowany w akceptorze rezultatu działania.

Działanie systemu funkcjonalnego można opisać następująco. Synteza aferentna obejmuje syntezę pobudzeń nerwowych, które są spowodowane:

1. Dominującą motywacją

2. Sytuacyjną aferentacją

3. Uruchamiającą aferentacją

4. Odziedziczoną i nabytą pamięcią

Po syntezie aferentnej następuje podejmowanie decyzji, co oznacza redukcję stopnia swobody dla syntezy eferentnej i wybór określonego działania zgodnie z dominującą potrzebą zwierzęcia i innymi składnikami syntezy aferentnej.

Następnym krokiem operacji jest wygenerowanie akceptora wyniku działania. Ten krok to utworzenie prognozy wyniku. Prognoza obejmuje utworzenie konkretnych parametrów przewidywanego wyniku. Synteza eferentna jest przygotowaniem do działania efektorowego. Synteza eferentna oznacza wygenerowanie pewnych pobudeń neuronalnych przed wygenerowaniem polecenia działania. Wszystkie etapy osiągnięcia wyniku są trwale szacowane za pomocą aferentacji wstecznej. Jeśli parametry rzeczywistego wyniku różnią się od parametrów akceptora wyniku działania, wówczas działanie zostaje przerwane i następuje nowa synteza aferentna. W takim przypadku wszystkie operacje układu funkcjonalnego są powtarzane, aż do osiągnięcia ostatecznego potrzebnego wyniku. Zatem działanie układu funkcjonalnego ma cykliczną (z wstecznymi połączeniami aferentnymi) samoregulującą organizację. Najważniejszą cechą szczególną teorii Anokhina jest ukierunkowanie działania dowolnego układu funkcjonalnego na osiągnięcie ostatecznego potrzebnego wyniku. Kolejną cechą szczególną jest dynamika, temporalność. Przy każdym działaniu behawioralnym różne struktury neuronalne i inne struktury regulacyjne organizmu są mobilizowane do systemu funkcjonalnego. Ponadto ważną koncepcją teorii systemów funkcjonalnych jest systemogeneza. Istotą systemogenezy jest to, że systemy funkcjonalne organizmu – potrzebne do adaptacyjnego zachowania zwierząt i ludzi – dojrzewają zarówno w okresie prenatalnym, jak i ontogenezie. Należy podkreślić, że teoria systemów funkcjonalnych została zaproponowana i opracowana w celu zinterpretowania szeregu danych neurofizjologicznych. Teoria została sformułowana w dość ogólnych i intuicyjnych terminach. Moim zdaniem dostarcza nam ona ważnego podejścia koncepcyjnego do zrozumienia działania mózgu. Ta teoria może pomóc nam zrozumieć neurofizjologiczne aspekty prognozowania, przewidywania, tworzenia relacji przyczynowych między sytuacjami i generowania „sieci semantycznych” w mózgach i umysłach zwierząt.

Rola badań „sztucznego życia” i „symulacji adaptacyjnego zachowania”

Wróćmy do kwestii modelowania „inteligentnych wynalazków” ewolucji biologicznej. Na szczęście dwa interesujące kierunki badań – „sztuczne życie” i „symulacja adaptacyjnego zachowania” – pojawiły się 12-15 lat temu, co może nam pomóc. Możemy wykorzystać metody, koncepcje i podejścia tych badań podczas tworzenia i rozwijania modeli „inteligentnych wynalazków”. Sztuczne życie (Alife), jako obszar badań, przybrało swoją formę w późnych latach 80. [24, 25]. Główną motywacją Alife jest modelowanie i zrozumienie formalnych zasad życia. Jak powiedział C.G. Langton, „głównym założeniem w Artificial Life jest to, że „logiczną formę” organizmu można oddzielić od jego materialnej podstawy konstrukcji” [24]. „Organizmy” Alife to stworzone przez człowieka, wyimaginowane byty, żyjące głównie w światach programów komputerowych. Ewolucja, ekologia i pojawianie się nowych cech istot przypominających życie są przedmiotem szczególnej uwagi badań Alife. Symulacja zachowań adaptacyjnych [27] to obszar badań bardzo zbliżony do Alife. Jest jednak bardziej wyspecjalizowany — głównym celem tej dziedziny badań jest projektowanie animatów, tj. symulowanych zwierząt lub prawdziwych robotów, których zasady zachowania są inspirowane zasadami zwierząt. Bezpośrednim celem tego podejścia jest odkrycie architektur lub zasad działania, które pozwalają zwierzęciu lub robotowi wykazywać zachowania adaptacyjne, a tym samym przetrwać lub wypełnić swoją misję nawet w zmieniającym się środowisku. Ostatecznym celem tego podejścia jest osadzenie ludzkiej inteligencji w perspektywie

ewolucyjnej i poszukiwanie sposobu, w jaki najwyższe zdolności poznawcze człowieka można powiązać z najprostszymi zachowaniami adaptacyjnymi zwierząt. Możemy zauważyć, że ostatecznym celem Symulacji zachowań adaptacyjnych jest bardzo bliskie zadanie stworzenia teorii ewolucyjnego pochodzenia ludzkiej inteligencji, jak omówiono powyżej. W ten sposób przedstawiliśmy problem rozwoju naukowej bazy badań nad sztuczną inteligencją i przeanalizowaliśmy ogólne podejścia do odpowiednich badań. Teraz nadszedł czas, aby podjąć pewne konkretne kroki. Aby zilustrować możliwe badania, opisujemy poniżej dwa konkretne modele komputerowe: „Model Alife ewolucyjnego pojawiania się celowego adaptacyjnego zachowania” i „Model ewolucji agentów internetowych”. Modele te mają szereg wspólnych cech i ilustrują możliwe powiązania między czysto akademickimi badaniami ewolucji poznawczej (pierwszy model) a badaniami stosowanymi skierowanymi na sztuczną inteligencję internetową (drugi model).

Dwa modele


Model Alife ewolucyjnego powstawania celowego adaptacyjnego zachowania

Celem tego modelu jest analiza roli motywacji dla prostego adaptacyjnego zachowania. Należy zauważyć, że motywacja jest ważną cechą teorii Anokhin’ systemu funkcjonalnego. Mianowicie dominująca motywacja – odpowiadająca aktualnej potrzebie zwierzęcia – bierze udział w generowaniu działania behawioralnego.

Opis modelu

Główne założenia modelu są następujące:

- Istnieją agenci (organizmy Alife), którzy mają dwie naturalne potrzeby (potrzebę energii i potrzebę reprodukcji).
- Populacja agentów ewoluuje w prostym środowisku, w którym rosną kępy trawy (pożywienie agenta). Agenci otrzymują pewne informacje ze swojego środowiska i wykonują pewne czynności. Agenci mogą się poruszać, jeść trawę, odpoczywać i łączyć się ze sobą. Łączenie się skutkuje narodzinami nowych agentów. Agent ma wewnętrzny zasób energii R; zasób ten zwiększa się podczas jedzenia. Wykonując czynność, agent zużywa swój zasób. Gdy zasób agenta spadnie do zera, agent umiera.
- Każda potrzeba agenta jest charakteryzowana przez parametr ilościowy (parametr motywacji), który określa motywację do osiągnięcia odpowiedniego celu. Np. jeśli zasób energetyczny agenta jest mały, istnieje motywacja do znalezienia pożywienia i uzupełnienia zasobu energii poprzez jedzenie.
- Zachowanie agenta jest kontrolowane przez sieć neuronową, która ma specjalne dane wejściowe z motywacji. Jeśli istnieje pewna motywacja, agent może szukać rozwiązania, aby zaspokoić potrzebę zgodnie z motywacją. Ten typ zachowania można uznać za celowy (istnieje cel, aby zaspokoić potrzebę).
- Populacja agentów ewoluuje. Głównym mechanizmem ewolucji jest formowanie genomów nowych agentów za pomocą krzyżowań i mutacji. Genom agenta koduje wagi synaptyczne sieci neuronowej agenta. Środowisko w naszym modelu jest liniowym jednowymiarowym zestawem komórek.



Zakładamy, że tylko jeden agent może zająć dowolną komórkę.

Czas jest dyskretny. W każdej iteracji czasowej każdy agent wykonuje dokładnie jedną akcję. Zestaw możliwych akcji agentów jest następujący:

1. Odpoczynek
2. Przejście do sąsiedniej komórki (w lewo lub w prawo)
3. Przeskakiwanie (przez kilka komórek w losowym kierunku)
4. Jedzenie
5. Kojarzenie się

Łatki trawy pojawiają się losowo i rosną przez pewien czas w komórkach środowiska. Agenci są „krótkowzroczni”. Oznacza to, że każdy agent widzi sytuację tylko w trzech komórkach: we własnej komórce i w dwóch sąsiednich komórkach. Te trzy komórki określamy jako „pole widzenia” agenta (rys. 5). Wprowadzamy dwa parametry ilościowe, odpowiadające potrzebom agentów:

1. Motywacja do poszukiwania pożywienia ME, która odpowiada potrzebie energii
2. Motywacja do krycia MR, która odpowiada potrzebie reprodukcji

Motywacje są definiowane następująco :

$$M_E = \max\left\{\frac{R_0 - R}{R_0}, 0\right\} \quad M_R = \min\left\{\frac{R}{R_1}, 1\right\}$$

gdzie R_0 jest pewną „optymalną” wartością zasobu energii R , R_1 jest wartością zasobu energii, która jest najbardziej odpowiednia do reprodukcji. Sieć neuronowa agenta kontroluje jego zachowanie. Zakładamy, że sieć neuronowa obejmuje jedną warstwę neuronów. Neurony odbierają sygnały z otoczenia zewnętrznego i wewnętrznego za pośrednictwem bodźców sensorycznych. Istnieją pełne połączenia między bodźcami sensorycznymi a neuronami: każdy neuron jest połączony z dowolnym bodźcem. Wyjścia neuronów określają działania agenta. Każdy neuron odpowiada jednemu działaniu. Biorąc pod uwagę, że działania „poruszania się” i „kojarzenia się” mają dwa warianty (agent może poruszać się w lewo lub w prawo i kojarzyć się z lewym lub prawym sąsiadem), mamy 7 neuronów. Każdy neuron ma 9 bodźców sensorycznych. Ponieważ bodźce i neurony mają wszystkie możliwe połączenia synaptyczne, w sieci neuronowej występuje $9 \times 7 = 63$ wag synaptycznych. Neurony mają typową funkcję aktywacji logistycznej. Zakładamy, że w danym momencie agent wykonuje działanie odpowiadające neuronowi, który ma maksymalny sygnał wyjściowy. Schemat ewolucji jest realizowany w następujący sposób. Zakładamy, że genom agenta koduje wagi synaptyczne sieci neuronowej agenta. Każda waga synaptyczna jest reprezentowana przez liczbę rzeczywistą i uważana za gen genomu. Kiedy rodzi się nowy agent, jego genom jest tworzony w następujący sposób:

1. Tworzy się jednorodna rekombinacja genomów rodzica
2. Ten zrekombinowany genom jest poddawany małym mutacjom

Wyniki symulacji komputerowych

Aby przeanalizować wpływ motywacji na zachowanie agentów, przeprowadziliśmy dwie serie symulacji. W pierwszej serii agenci mieli motywacje (motywacje wprowadzono w sposób opisany powyżej). W drugiej serii agenci nie mieli motywacji (dane wejściowe z motywacji zostały sztucznie stłumione za pomocą specjalnego wyboru parametrów R_0 , R_1). Aby przeanalizować wpływ ilości pożywienia w środowisku zewnętrznym na zachowanie populacji, symulacje w obu seriach przeprowadzono dla kilku prawdopodobieństw pojawienia się trawy w komórkach. Wybierając pewne parametry, które określają zużycie energii podczas działań agentów, zdefiniowaliśmy pewną rozsądną fizjologię agenta. Wybraliśmy również pewne rozsądne wartości parametrów R_0 , R_1 i początkowe wartości zasobów energetycznych agentów w populacji początkowej. Wszyscy agenci populacji początkowej mieli takie same wagi synaptyczne sieci neuronowych. Te wagi określały pewne rozsądne początkowe instynkty agentów.

Pierwszym instynktem był instynkt uzupełniania pożywienia. Instynkt ten był poświęcony wykonywaniu dwóch typów działań:

1. Jeśli agent widzi trawę we własnej komórce, zjada ją
2. Jeśli agent widzi trawę w sąsiedniej komórce, przenosi się do tej komórki

Drugim instynktem był instynkt rozrodu. Instynkt ten oznacza, że jeśli agent widzi innego agenta w jednej z sąsiednich komórek, próbuje się z nim parzyć. Oprócz tych głównych instynktów, agenci zostali wyposażeni w instynkt „strachu przed ciasnotą”: jeśli agent widzi dwóch agentów w obu sąsiednich komórkach, skacze. Wagi synaptyczne z wejść motywacyjnych w sieci neuronowej były równe zeru dla wszystkich agentów w populacji początkowej. Dlatego motywacje zaczęły odgrywać rolę dopiero w toku ewolucji. Głównymi ilościowymi cechami, których użyliśmy w celu opisania jakości procesu ewolucyjnego, była całkowita liczba agentów w populacji N . Otrzymaliśmy zależności $N(t)$ od czasu t dla obu serii eksperymentów: dla populacji agentów z motywacjami i dla populacji agentów bez motywacji. Przeanalizowaliśmy również ewolucyjną dynamikę działań agentów i zarejestrowaliśmy statystykę wag synaptycznych w trakcie procesu ewolucji. Przykłady zależności $N(t)$ pokazano na rys. 7. Przy małej ilości pożywienia (rys. 7a) obie populacje agentów (z motywacjami i bez) wymierają – ilość pożywienia nie jest wystarczająca, aby wesprzeć zużycie energii potrzebnej do działań agentów. Przy średniej ilości pożywienia (rys. 7b) populacja agentów bez motywacji wymiera, podczas gdy populacja agentów z motywacjami jest w stanie znaleźć „dobrą” strategię życia i przetrwać. Przy dużej ilości pożywienia (rys. 7c) obie populacje przeżywają; jednak populacja z motywacjami znajduje lepszy system sterowania siecią neuronową, który zapewnia większą populację końcową. Tak więc dane wejściowe sieci neuronowej z wewnętrznych motywacji dają populacji możliwość znalezienia lepszego systemu sterowania dla agentów w trakcie ewolucyjnego poszukiwania.

Interpretacja wyników symulacji

Przeprowadziliśmy szczegółową analizę ewolucji działań agentów dla populacji z motywacjami i bez motywacji. Na podstawie tej analizy zinterpretowaliśmy kontrolę behawioralną agentów. Schemat kontroli behawioralnej agenta bez motywacji, który został odkryty przez ewolucję. Schemat ten obejmuje trzy reguły, z których agent korzysta w trakcie swojego życia. Pierwsza reguła mówi, że jeśli agent widzi kępę trawy, stara się zjeść to pożywienie. Mianowicie, zjada pożywienie, jeśli pożywienie znajduje się w jego własnej komórce, lub idzie do trawiastej sąsiedniej komórki i zjada pożywienie w następnym momencie. Druga reguła mówi, że jeśli agent widzi sąsiada, łączy się w pary, próbując urodzić potomstwo. Te dwie reguły to po prostu instynkty, które narzuciliśmy agentom początkowej populacji. Ewolucja potwierdziła, że są one przydatne i adaptacyjne. Trzecia reguła mówi, że jeśli agent

nie widzi niczego w swoim polu widzenia, decyduje się odpocząć. Ta reguła została odkryta przez ewolucję i oczywiście ma pewną wartość adaptacyjną. Oczywiście jest, że takie zachowanie agenta jest determinowane wyłącznie przez aktualny stan środowiska zewnętrznego. Te trzy reguły można uznać za proste odruchy. Rozważmy system sterowania agenta z motywacjami. Analiza symulacji pokazuje, że schemat sterowania agenta z motywacjami można przedstawić jako system hierarchiczny. Trzy opisane powyżej reguły stanowią niższy poziom systemu sterowania. Drugi poziom wynika z motywacji. Ten hierarchiczny system sterowania działa w następujący sposób (rys. 9). Jeśli zasób energetyczny agenta jest niski, motywacja do poszukiwania pożywienia jest duża, a motywacja do krycia się jest mała, więc agent używa tylko dwóch z wymienionych reguł, pierwszej i trzeciej – krycie się jest tłumione. Jeśli zasób energetyczny agenta jest wysoki, motywacja do krycia się jest włączona, a więc agent dąży do krycia się – druga i trzecia reguła rządzą głównie zachowaniem agenta, jednak czasami pierwsza reguła również działa. Tak więc przejście ze schematu sterowania bez motywacji (rys. 8) do schematu z motywacjami (rys. 9) można rozpatrywać jako pojawienie się nowego poziomu hierarchii w systemie sterowania agenta. To przejście jest analogiczne do przejścia metasystemu od prostych odruchów do złożonych odruchów w teorii przejścia metasystemu [34]. Tak więc model pokazuje, że prosty hierarchiczny system sterowania, w którym proste odruchy są kontrolowane przez motywacje, może pojawić się w procesach ewolucyjnych, a ten hierarchiczny system jest bardziej efektywny w porównaniu do kontroli behawioralnej rządzonej za pomocą samych prostych odruchów.

Model ewolucji agentów internetowych

Celem modelu 2 jest analiza ewolucji i samoorganizacji agentów Alife w środowisku internetowym. Model jest podobny do poprzedniego. Główne cechy szczególne obecnego modelu to:

- Model zakłada, że istnieje zestaw płatów Web World, w których ewoluuje populacja agentów Alife. Każdy płat zawiera podpopulację agentów. Płaty są rozproszone w środowisku internetowym.
- Agenci mogą się ze sobą komunikować. Agenci mogą latać między różnymi płatami. Agenci mogą wykonywać kilka działań; w szczególności mogą rozwiązywać zadania. Rozwiązując zadanie, agent uzyskuje pewną nagrodę.
- Agenci mają dwie potrzeby: potrzebę energii i potrzebę wiedzy. Każda potrzeba jest charakteryzowana przez ilościowy parametr motywacji.
- Istnieją dwie sieci neuronowe, które kontrolują zachowanie agenta. Pierwsza sieć neuronowa rządzi wyborem działań agenta. Druga sieć neuronowa rządzi rozwiązywaniem zadań. Istnieje procedura uczenia się drugiej sieci neuronowej. Ta nauka opiera się na pewnych modyfikacjach dobrze znanej metody propagacji wstecznej (patrz poniżej). Wagi synaptyczne pierwszej sieci neuronowej nie zmieniają się w trakcie życia agenta.
- Wagi synaptyczne pierwszej sieci neuronowej i początkowe wagi synaptyczne drugiej sieci neuronowej to geny dwóch chromosomów agenta.

Model zakłada, że każdy agent ma swój wewnętrzny zasób energii. Wykonując akcję, agent zużywa swój zasób energii. Kiedy wewnętrzny zasób energii agenta spadnie do zera, ten agent umiera. Każdy agent może jeść jedzenie i uzupełniać swój wewnętrzny zasób energii. Jednak przed jedzeniem agent powinien rozwiązać jakieś zadanie. Wartość nagrody, którą otrzymuje agent, zależy od jakości rozwiązania zadania. Nagrody mogą być dodatnie lub ujemne. Otrzymując pozytywną nagrodę, agent je jedzenie i zwiększa swój zasób energii. Kiedy agent otrzymuje negatywną nagrodę (karę), jego zasób energii ulega zmniejszeniu. Agenci mogą komunikować się ze sobą. Poprzez komunikację agenci pomagają sobie nawzajem w zwiększaniu swojej wiedzy na temat sytuacji w różnych płatach. W

dowolnym płacie agenci mogą się ze sobą kojarzyć. Podczas wykonywania akcji „Kojarzenie się” agent staje się partnerem do kojarzenia. Dwóch partnerów do kojarzenia się w tym samym płacie rodzi dziecko. Każdy rodzic przekazuje potomstwu część swojego zasobu energii. Każdy chromosom potomstwa uzyskuje się poprzez jednopunktowe skrzyżowanie odpowiadających chromosomów obojga rodziców. Dodatkowo występują niewielkie mutacje genów chromosomów. Latając między płatami, agenci są w stanie podróżować po Świecie Sieci. Istnieje dość nietrywialna procedura uczenia się drugiej sieci neuronowej (sieci rozwiązywacza zadań). To uczenie się opiera się na uzupełniającej propagacji wstecznej wzmocnienia. Pomijając pewne nieistotne szczegóły, możemy opisać metodę uczenia się w następujący sposób. Architektura sieci neuronowej jest taka sama jak w zwykłej metodzie propagacji wstecznej : sieć ma strukturę warstwową; neurony mają logistyczną funkcję aktywacji. Załóżmy, że w danym momencie czasu wektory wejściowe i wyjściowe sieci neuronowej to odpowiednio X i Y . Należy zauważyć, że zgodnie z logistyczną funkcją aktywacji neuronów wartości składowych Y_i wektora wyjściowego Y należą do przedziału $(0, 1)$. Rozwiązując zadanie, agent musi wybrać określone działanie. Zakładamy, że działanie odpowiada maksymalnej wartości wyjść neuronowych. W tym przypadku możemy zdefiniować wektor działania A , taki jak $A_j = 1$, jeśli $j = k$, $A_j = 0$, jeśli $j \neq k$, $k = \operatorname{argmax}_i Y_i$. Agent wykonuje k -te działanie. Jeśli rozwiązuje zadanie, agent otrzymuje pozytywną nagrodę, wtedy wektor działania jest uważany za wektor docelowy $T = A$. Jeśli agent otrzymuje negatywną nagrodę, wtedy wektor docelowy jest „komplementarny” do wektora wyjściowego: $T_i = 1 - A_i$. Następnie stosowana jest zwykła procedura propagacji wstecznej, a mapowanie między wektorami wejściowymi i docelowymi X i T jest wzmacniane. Tak więc metoda propagacji wstecznej wzmocnienia uzupełniającego wzmacnia/dewzmacnia takie relacje między X i A , które są nagradzane pozytywnie/negatywnie. Stworzyliśmy program, który implementuje ten model. Wyniki wstępnych symulacji wykazały, że ewoluująca populacja agentów jest w stanie znaleźć proste formy zachowań adaptacyjnych. Możemy również zauważyć możliwy praktyczny kierunek rozwoju modelu. Rozważmy populację firm high-tech. Każda firma ma sieć komputerową; ta sieć jest płatem, w którym ewoluuje odpowiadająca jej subpopulacja agentów. Każda firma ma specjalną osobę, nadzorcę subpopulacji agentów. Ten nadzorca daje agentom w swoim płacie pewne praktyczne zadania i nagradza ich lub karze. Zadania mogą być takie jak „daj mi prognozę tego konkretnego rynku” lub „znajdź mi dobrego partnera do tego rodzaju współpracy” itp. Agenci powinni rozwiązywać zadania i są odpowiednio nagradzani/karani. Agenci mają dostęp do Internetu. Firmy mają strony internetowe, więc agenci są w stanie analizować informacje o populacji firm. Podczas ewolucji populacji agentów internetowych zadania dla agentów mogą być coraz bardziej złożone, co może zapewnić coraz bardziej inteligentne zachowanie agentów. Oczywiście opisane dwa modele są tylko prostymi przykładami konkretnych badań. W następnej sekcji przedstawimy możliwą drogę od tych prostych modeli do wdrożenia wyższych zdolności poznawczych.

W kierunku wdrożenia wyższych zdolności poznawczych

Rozważmy możliwe kroki w kierunku modelowania inteligencji wysokiego poziomu.

Krok 1

Ewolucyjna optymalizacja prostego instynktownego zachowania. Możemy zakodować system sterowania agenta (np. sieć neuronową agenta) za pomocą genomu i zoptymalizować genom za pomocą metody ewolucyjnej. Na przykład możemy wprowadzić parametr zasobu witalnego R agenta; zasób jest zwiększany/zmniejszany przy udanym/nieudanym działaniu agenta. Jeśli zasób agenta spadnie poniżej pewnego progu, agent umiera; jeśli zasób agenta jest duży, agent rodzi dziecko (deterministycznie lub w pewnym stochastycznym procesie reprodukcyjnym), odtwarzając (i modyfikując przez mutacje) jego genom. Model z sekcji 4.1 jest przykładem tego poziomu wdrożenia.

Krok 2

Używając koncepcji wewnętrznego zasobu witalnego R , możemy wprowadzić naturalny schemat uczenia się bez nadzoru. Załóżmy, że układ sterowania agenta jest warstwową siecią neuronową z logistyczną funkcją aktywacji neuronów. Wówczas ten układ sterowania może być optymalizowany przy każdym działaniu agenta za pomocą metody komplementarnej propagacji wstecznej wzmocnienia. Jeżeli działanie agenta jest skuteczne ($\Delta R > 0$), wagi synaptyczne sieci neuronowej są wzmacniane; jeżeli działanie jest nieskuteczne ($\Delta R < 0$), wagi synaptyczne są dereinforcementowane. Tę metodę można uzupełnić zwykłą optymalizacją ewolucyjną: początkowe (uzyskane przy narodzinach agenta) wagi synaptyczne sieci neuronowej mogą stanowić genom agenta. Metoda ewolucyjnej optymalizacji genomu agenta jest taka sama, jak opisana powyżej (krok 1).

Krok 3

Możemy rozważyć kilka istotnych potrzeb agenta (energia, bezpieczeństwo, reprodukcja, wiedza), charakteryzując j -tą potrzebę własnym zasobem R_j i motywacją M_j ($j = 1, 2, \dots, n$). Naturalne jest założenie, że motywacja M_k monotonicznie maleje wraz ze wzrostem odpowiadającego jej zasobu R_k . Zakładając, że w każdym momencie czasu istnieje dominująca motywacja M_d , która determinuje zachowanie agenta, możemy wprowadzić schemat uczenia się bez nadzoru również w tym przypadku. Mianowicie, jeśli zasób R_d , odpowiadający dominującej motywacji, wzrasta/maleje, wówczas wagi synaptyczne sieci neuronowej agenta są wzmacniane/odwzmacniane. Należy zauważyć, że wiedza może być uważana za ważną potrzebę agenta, co oznacza, że ciekawość intelektualna jest motywacją do zwiększania wiedzy.

Krok 4

Możemy wyobrazeniowo zreorganizować schemat modelowania z kroku 3, próbując zbliżyć się do schematu P.K. Układ funkcjonalny Anokhina. Możemy rozważyć animat (lub zwierzę, lub model zwierzęcia), który ma raczej dowolną strukturę sieci neuronowej. W sieci występują różne połączenia o różnych wagach między neuronami. Animat ma potrzeby i odpowiadające im motywacje M_j , jak powyżej. Jednak teraz załóżmy, że animat może mieć również model świata zewnętrznego i może prognozować wyniki swoich działań. Możemy założyć, że przy danej dominującej motywacji M_d (np. motywacji do zdobycia pożywienia) w sieci neuronowej zachodzą pewne procesy pobudzające. Procesy pobudzające mogą przywrócić w pamięci neuronowej wzorce obiektów, które są związane z zaspokojeniem potrzeby (np. wzór mięsa) i wzorce sytuacji, w których te obiekty zostały zaobserwowane. (Nie jest trudno wyobrazić sobie te wzorce - wzorce można przechowywać w postaci zespołów Hebba.) Biorąc pod uwagę te informacje, nasz animat może spróbować prognozować wyniki swoich możliwych działań. Ten proces prognozowania jest raczej nietrywialny. Wyobraźmy sobie jednak, że nasz animat jest w stanie dokonać prognozy. Możemy również wyobrazić sobie, że animat jest w stanie wybrać odpowiednie działanie zgodnie z prognozą. Wtedy możemy naturalnie założyć, że animat jest w stanie uczyć się poprzez modyfikację swojej sieci neuronowej. Jeśli działanie jest udane, czyli osiągnięty został przewidywany wynik, to istniejące połączenia w sieci neuronowej są wzmacniane przez odpowiednią modyfikację wag synaptycznych. W przeciwnym razie mogłaby nastąpić jakaś procedura oduczania, np. w formie pewnego odwzmacnienia, jak omówiono powyżej w krokach 2 i 3. Ponadto możemy wyobrazić sobie zbiór zespołów Hebba w sieciach neuronowych animatów; zespoły przechowują wzorce aktywności neuronów, które charakteryzują pojęcia, nazwy lub koncepcje. Zespoły przechowują wzorce w formie pamięci asocjacyjnej, więc zespoły zapamiętują najbardziej ogólne i statystycznie uśrednione pojęcia [23]. Zestaw zespołów połączonych za pomocą połączeń neuronowych można rozpatrywać jako sieć semantyczną. Możemy sobie wyobrazić, że za pomocą sieci semantycznej animat jest w stanie dokonać pewnych „logicznych” wniosków, podobnych do tych

omawianych w sekcji 2 i w dokumencie roboczym. Możemy zatem wyobrazić sobie nietrywialny system sterowania animatami oparty na sieci neuronowej. Za pomocą tego systemu sterowania animat jest w stanie konstruować modele środowiska, wyciągać „logiczne” wnioski, przewidywać wyniki swoich działań. Animat jest również w stanie się uczyć; połączenia w sieci neuronowej animatu ulegają zmianie podczas uczenia się. Możemy również wyobrazić sobie, że architektura sieci neuronowej animatów może być optymalizowana przez rozwój ontogenetyczny i ewolucyjną optymalizację populacji animatów. Możemy uważać inteligencję takich animatów za inteligencję „na poziomie psa”. Oczywiście, krok 4 jest dość wyimaginowany. Jednak opisany schemat koncepcyjny systemu sterowania animatami jest wystarczająco konkretny i może stymulować badania inteligencji animatów i rozwój rzeczywistych systemów AI. Co więcej, możemy pójść dalej do pewnego fantastycznego kroku

Krok 5

Czy możemy spróbować wyobrazić sobie metasystemową transformację inteligencji z poziomu „psa” (opisanego w kroku 4) do poziomu inteligencji człowieka? Tak, możemy. Załóżmy, że istnieje społeczeństwo animatów, a każdy animat ma system sterowania siecią neuronową. Animaty są w stanie tworzyć modele świata zewnętrznego i wyciągać indukcyjne wnioski logiczne na temat świata; są w stanie formułować prognozy i wykorzystywać prognozowanie w swojej działalności. Załóżmy, że animaty mogą się ze sobą komunikować. Ich komunikacja mogłaby pomóc im w podejmowaniu działań zbiorowych. Dlatego komunikacja mogłaby skutkować jakimś „językiem animatów”; a pojęcia odpowiadające słowom tego języka mogłyby utrzymywać się w pamięci animatów. Te animaty mogłyby również wymyślać cyfry w celu wykorzystania obliczeń w planowaniu działań zbiorowych. Tak więc takie animaty mogłyby mieć prymitywne myślenie, podobne do myślenia plemienia myśliwych starożytnych ludzi. Załóżmy teraz, że istnieje jakieś podspołeczeństwo, które chciałoby stworzyć najsilniejszą formę myślenia, myśleć o myśleniu, stworzyć specjalny język o myśleniu. Takie animaty można by uznać za matematyków i filozofów społeczeństwa animatów (podobnie jak matematycy i filozofowie starożytnej Grecji). Ten krok od myślenia prymitywnego do myślenia krytycznego jest ważnym przejściem metasystemu do inteligencji na poziomie ludzkim [34]. Oczywiście, ten krok jest całkiem fantastyczny; niemniej jednak możemy sobie go wyobrazić, a nawet spróbować go modelować.

Wnioski

Ta sekcja ma głównie charakter koncepcyjny, filozoficzny. Niemniej jednak miałem nadzieję, że może on stymulować rozwój konkretnych modeli „inteligentnego” adaptacyjnego zachowania. Moim zdaniem modelowanie inteligentnych cech opisanych w kroku 4 sekcji 5 byłoby najciekawsze i najważniejsze zarówno z naukowego, jak i z punktu widzenia zastosowań AI.