Mesterséges intelligencia - Mesterséges kíváncsiság

Bele sem gondolunk, hogy mindennapi tevékenységeink jelentős része mennyire összetett, a természettudományos törvényszerűségek és a társadalmi elvárások/magatartásformák komplex egyvelegének ismeretét feltételezi. Természetesnek vesszük és a megfelelő reakciót adjuk az akárcsak legapróbb változásokra, melyek jelentős eltérések bekövetkeztét okozhatják. Amennyiben például a volán mögé ülünk, a közeli óvoda, iskola közelében lassítani fogunk, hogy a gyermekekre vigyázzunk. Tisztában vagyunk vele, hogy nedves útszakaszhoz közeledve éberebbnek kell lennünk, hiszen a fékút megnövekszik. És habár ezekre a szempontokra a jogosítvány megszerzése során külön felhívják a figyelmet, itt korántsem csak arról van szó, hogy azért ezt kell tennünk, mert valamilyen hatóság előírta számunkra. Hanem azért, mert a valóság megfigyelése során az volt a tapasztalat, hogy fenti szituációkat előbbi javaslatok betartásával tudjuk biztonságosan kezelni.

Nem rendelkezvén ezzel a tapasztalattal azonban jelentős kárt is okozhatnánk. A világról alkotott tapasztalatainkat levezethetjük jelenlegi tudásunkból, de sok esetben új dolgok kipróbálásával, lehetőségeink/környezetünk felfedezésével is jelentős ismeretekre tehetünk szert – gondoljunk csak a röntgensugárzás felfedezésekor közrejátszó véletlenre. Ezek alapján – még akkor is, ha ezt az adott szituációban nem ismerjük fel – a világ általános működésének megismerése számos szituációban siethet segítségünkre. Gondoljunk bele, hogy amennyiben ez fennáll – a fizikai ismeretek teljes hiányában az autóvezetés a szerző számára igencsak merész vállalkozásnak hat -, akkor mennyire lehet bonyolult olyan mérnöki rendszereket tervezni, amelyek célja hasonlóan komplex feladatok elvégzése, mindezt ráadásul autonóm módon, lehetőség szerint külső beavatkozás nélkül.

A mesterséges intelligencia tudományterülete már a múlt század közepe óta tesz jelentős erőfeszítéseket a fenti cél megvalósítására, azonban az igazán látványos, mindenki számára nyomon követhető fejlődés, az elmúlt másfél évtizedben indult el – ennek oka, hogy immár rendelkezésre állt a szükséges számítási kapacitás, a megfelelő mennyiségű és minőségű adat, valamint az algoritmusok is sokat fejlődtek. Ha belegondolunk, az önvezető járművek esetén rendkívül komplex feladattal állnak szemben a tudósok és mérnökök, hiszen lényegében egy olyan rendszert kell létrehozniuk, amely ismeri a közlekedési szabályokat, azokat az emberi viselkedésnek megfelelően értelmezi, ráadásul olyan komplex világképpel bír, mely a dolgok fizikai, valamint az emberek viselkedési jellemzőit is ismeri.

A dolog bonyolultságát számos további tényező is növeli, ezek ismertetése előtt azonban meg kell ismernünk magát a mesterséges intelligencia-modellek jelen szituációban alkalmazott tanulási paradigmáját, mely az alábbi ábrán látható, és amelyet a szakirodalom megerősítéses tanulás néven ismer.

Adott egy ágens, amely döntéseket hoz, így pedig interakcióba kerül a környezettel, ezáltal pedig tapasztalatokat gyűjt, amit a későbbiek során felhasznál, így jobb eredményeket képes elérni. A megtett lépések hatását megfigyeli, amelyhez számos szenzor áll rendelkezésre, így az emberi érzékeléshez képest nagyobb flexibilitás érhető el (pl. egy lézer-, vagy infraszenzor segítségével). A kihívás viszont abban rejlik, hogy hiába áll nagyobb mennyiségű adat rendelkezésre, az információ más struktúrájú és más módon kerül feldolgozásra, mint az emberek esetében. Tehát úgy kell kinyerni az információt, hogy az emberek által megfogalmazott elvárásoknak megfelelő legyen a végeredmény, sőt bizonyos esetekben az az

elvárt, hogy úgy reagáljon egy rendszer, ahogy egy ember - az autóvezetés tipikusan ilyen példa. Amennyiben viszont feldolgozásra került a megfigyelés, akkor létrejön a visszacsatolás, amely alapján az ágens el tudja dönteni, hogy a meghozott döntés jó volt-e, s ha igen, akkor mennyire.

Valós szituációkban azonban gyakorta nem ez a helyzet. Amikor el kell végeznünk egy feladatot, lehetséges, hogy csak hosszú idő múltán kapunk megerősítést, hogy helyesen döntöttünk-e. Ekkor viszont nem tudjuk, hogy az összes eddigi lépésünk helyes volt-e, s ha nem, akkor mit kellett volna másképp tennünk. Ha viszont nincs visszacsatolás, akkor elbizonytalanodhatunk. Ilyenkor dönthetünk úgy is, hogy rövid távon optimális megoldást keresünk (vagyis mohó módon mindig az adott döntési pillanatban optimális döntést hozzuk, nem tervezünk előre), ami azonban hosszú távon nem vezet kifizetődő megoldáshoz. Az önvezető autók példájánál maradva, csak akkor lesz visszacsatolás, ha sikeresen elértük a célunkat. Ugyanis, ha az a feladata egy autonóm járműnek, hogy eljusson A-ból B-be, ennek sikerességét csak akkor tudjuk megmondani, ha már elérte célját. Vagyis az idő jelentős részében- visszacsatolás híján – nem fogja tudni az algoritmus eldönteni, hogy a meghozott döntés hozzájárult-e a hosszú távú cél eléréséhez. Ebben az esetben alternatívára van szükség. Abból kifolyólag, hogy az ilyen rendszerekben használt algoritmusok oly módon működnek, hogy szükségük van egy adott, számszerűsíthető értékre, amit optimalizálhatnak. Ez lehet például a jármű és a cél távolsága, amit tudunk mérni. Ennek segítségével a jármű már képes lehet elnavigálni a célpozícióba. Azonban nekünk nem csak az a célunk, hogy elérjük a célállomást, hanem hogy biztonságosan érkezzünk oda, hogy közben tartsuk be a szabályokat stb. Ezek jelentős részéről pedig komplikált minden pillanatban visszacsatolást biztosítani, amennyiben viszont a számértékük egyenlő nullával (vagyis nincs sem megerősítő pozitív, sem eltántorító negatív visszajelzés), az algoritmus nem képes hangolni a számítógépes ágens paramétereit.

Az eddigiek során ecsetelt problémára számos megközelítés létezik a szakirodalomban, a Budapesti Műszaki és Gazdaságtudományi Egyetem Irányítástechnika és Informatika Tanszék Számítógépes Látás és Gép Tanulás Laboratóriumában elvégzett kutatásban alapvetően modellalapú megközelítést használtunk, mégpedig ún. kíváncsiságmodelleket. Hogy ezek a modellek mit is takarnak, az a bevezetésben tárgyaltakra visszautalva egyszerűen bemutatható, alapvetően arról van szó, hogy explicit célunk, hogy az általunk kifejlesztett megoldás valamilyen leírást, matematikai összefüggést adjon környezete működésére. Abban az esetben, ha a számítógépes ágens az eredeti mellé egy modellezési feladatot is kap, annak számos előnye van. Egyrészt, a modellezési probléma elősegítheti azt, hogy az ágens minél jobban felfedezze környezetét a tanulási folyamat során, ezáltal pedig általánosabb képességekkel fog rendelkezni valós szituációkban – ezt írja le szemléletesen a kíváncsiságmodell elnevezés, ugyanis ahhoz, hogy jobb modellt tudjon alkotni, az ágens kénytelen olyan döntéseket hozni, amelyek nem az eredeti feladat, hanem a modellezési probléma megoldását szolgálják, mindazonáltal az ágens számára jobb képet biztosít annak környezetéről (ezt nevezik kíváncsiságnak). Másrészt pedig így minden lépésben kap az ágens visszacsatolást, ugyanis egy modell jósága egyszerűen számszerűsíthető, például azáltal, hogy különbséget képzünk a környezet következő időpillanatbeli állapota, valamint az ágens által ugyanarra az időpontra adott becslés között (lásd ábra).

Azonban ahogy az emberi kíváncsiság esetében, mesterséges intelligencia által vezérelt ágensek esetében sem előnyös minden szempontból a kíváncsiság. Ahogy a kisgyermek a

figyelmeztetés ellenére hozzányúl a forró fűtőtesthez, ugyanúgy megteheti azt a számítógépes ágens, hogy „megégeti magát” - túlzott kíváncsiságából kifolyólag. Ez viszont – annak ellenére, hogy a világról pontosabb képet ad – bizonyos esetekben egyszerűen az algoritmus teljesítményét rontja, sok esetben viszont veszélyes is lehet. Ennek lehet például a következménye, hogy az ágens az önvezető autót egy ütközésbe manőverezi. Hiszen ezáltal csak az algoritmus számára előírt célt – minél jobb modell alkotása – viszi véghez, mivel az is a világ egy szeletét írja le, hogy mi történik egy ütközés során. Kutatásunk során az ilyen szituációk elkerüléséhez fejlesztettük tovább a kíváncsiság alapú modelleket, hogy meg tudják különböztetni a „hasznos” kíváncsiságot a „káros” kíváncsiságtól. Az általunk alkalmazott megközelítésre szintén nagyon jó analógiát találunk abból, ahogy az ember saját előrejelzéseit jellemzi. Mindig úgy gondolkodunk ugyanis magunkban, hogy „ha ezt a döntést hozom, akkor az számomra ilyen mértékben lesz hasznos, ennek pedig az esélye ekkora”. Ebben az esetben a skálán, az összehasonlíthatóságon van a hangsúly, illetve az alkalmazott megközelítésen. Ugyanis nem csak egy adott döntést hozunk meg/előrejelzést határozunk meg, hanem ehhez megadunk egy biztonsági tényezőt, egy bizonytalansági faktort annak kifejezésére, hogy mennyire várható az adott kimenetel bekövetkezése.

Mindezt a matematika nyelvére lefordítva nemcsak várható értékben, hanem hozzá tartozó valószínűségekben (valószínűségi eloszlásokban) is gondolkozunk. Ez egyrészt megvalósítható a kíváncsiság modellezése során is, amennyiben azt mindig az adott kontextust figyelembe véve súlyozzuk. Ez abban nyilvánul meg, hogy az ágens, alkalmazkodva az adott szituációhoz, mindig csak egy adott mértékben veszi figyelembe a kíváncsiságból származó visszacsatolást, ezáltal pedig szabályozni tudja, hogy az milyen relatív mértékben jusson érvényre a környezet által biztosított visszacsatoláshoz képest. Ezáltal pedig a modellezési képességet sem veszítjük el teljesen, de biztonságos/racionális keretek közé szorítjuk.

Annak érdekében, hogy a vázolt megközelítést tesztelni tudjuk, elkészítettünk egy fizikai modellezésen alapuló számítógépes szimulátorkörnyezetet, amely lehetővé tette számunkra, hogy komplex, több ágens interakcióján alapuló, hosszú távú tervezési képességeket megkövetelő szituációkban is összehasonlíthassuk az általunk kialakított megközelítést a szakirodalom eredményeivel. Ez egyrészt egy robotfoci-környezet elkészítését jelentette, ahol humanoid robotok két csapata verseng egymással a labda hálóba juttatásáért. Azonban a különbség a labdarúgás emberek által játszott verziójához képest nem csak néhány speciális szabályban nyilvánul meg, hanem például abban is, hogy a robotok a környezetet nem képesek tökéletesen megfigyelni. Ilyenkor előfordul például, hogy esetlegesen több labda jelenlétét érzékelik, vagy adott objektumot nem képesek detektálni. Annak ellenére, hogy ez a jelenség általánosnak mondható valós rendszerek esetén, a jelenleg hozzáférhető szimulátorok általában nem támogatják a realitás ilyen jellegű modellezését.

A másik környezet egy városi közúti kereszteződést modellez, amelyben az akadályokat és a gyalogosokat kikerülve kell az önvezető járműveknek biztonságosan elérniük a céljukat. Ebben az esetben szintén modelleztük a környezet megfigyelési pontatlanságait is, ez ugyanis valós rendszerek esetén kockázatos szituációkhoz vezethet – ahogy azt egy Tesla esetében is láthattuk, amikor annak algoritmusai nem voltak képesek azonosítani egy kamiont, ezáltal pedig, számos más tényező közrejátszása következtében, baleset következett be.

Az eddigiek során elvégzett kísérletek - habár a jelen cikkben ismertetett módszer eredményes alkalmazhatóságáról tettek tanúbizonyságot -, számos fontos következtetés levonásában is jelentős szerepet játszottak. Ezek egyike a környezet által biztosított visszacsatolás megfelelő módon történő figyelembe vétele volt, ugyanis jelentős különbségeket tudott okozni, ha ezeket másképp súlyoztuk. A jövőre nézve fontos kihívás, hogy amennyiben az ágensek csak a környezet egy részéről rendelkeznek információval, akkor abból – kihasználva, hogy a többi ágens más és más részleteket tud megfigyelni – milyen módon lehet hatékonyan a környezetet rekonstruálni. A jelen cikkben bemutatott módszertan számára egyértelműen jelentős fejlődési potenciált fog biztosítani a jövőben a felhasználók és az ipar részéről is mind nagyobb érdeklődés az autonóm járművek, illetve a robotikai alkalmazások iránt, ahol a mesterséges kíváncsisághoz hasonló modellek segíthetnek abban, hogy hatékonyabb, biztonságosabb megoldásokat alakítsunk ki.