

LOGISZTIKAI

TRENDEK ÉS LEGJOBB GYAKORLATOK

V. évfolyam 2. szám 2019. december

Fenntartható gazdálkodás

Konnektivitás és komplexitás



Tartalom

Szerkesztőbizottság elnöke:

Prof. Dr. Popp József

MTA levelező tag

Megjelenésért felelős igazgató:

Tóth Róbert

Főszerkesztő:

Dr. habil Oláh Judit

Főszerkesztő helyettes:

Dr. Kozma Tímea

A tudományos folyóirat szerkesztőbizottsága:

Prof. Dr. Benkő János – egyetemi tanár,
Szent István Egyetem

Prof. Dr. Heidrich Balázs – rektor,
egyetemi tanár, Budapesti Gazdasági
Egyetem

Prof. Dr. Illés Béla – egyetemi tanár,
Miskolci Egyetem

Prof. Dr. Szegedi Zoltán – egyetemi
tanár, Széchenyi István Egyetem

Prof. Dr. Zéman Zoltán – egyetemi tanár,
Szent István Egyetem

Dr. Egri Imre – főiskolai tanár,
Nyíregyházi Egyetem

Dr. Gyenge Balázs – egyetemi docens,
szakvezető, Szent István Egyetem

Dr. Kása Richárd – tudományos
főmunkatárs, Budapesti Gazdasági
Egyetem

Dr. Kozma Tímea – egyetemi docens,
Szent István Egyetem

Dr. Kurucz Attila – egyetemi docens,
Széchenyi István Egyetem

Dr. Lakatos Péter – egyetemi docens
Nemzeti Közszolgálati Egyetem

Naárné Dr. Tóth Zsuzsanna – egyetemi
docens, Szent István Egyetem

Dr. habil Oláh Judit – egyetemi docens,
Debreceni Egyetem

Dr. Pataki László – egyetemi docens,
Szent István Egyetem

Dr. Pónusz Mónika – egyetemi docens,
Károli Gáspár Református Egyetem

Dr. Sisa Krisztina – főiskolai docens,
Budapesti Gazdasági Egyetem

Szijártó Boglárka – számviteli mesterszak
mentora, Budapesti Gazdasági Egyetem

Dr. Túróczi Imre – főiskolai tanár,
Neumann János Egyetem

Vajna Istvánné Dr. Tangl Anita –
egyetemi docens, Szent István Egyetem

Előszó

Csizmadia Norbert 2

Oláh Judit: A fenntartható élelemiszerellátás kihívásai az energia- és környezetbiztonság tükrében – székfoglaló előadás, Prof. Dr. Popp József az MTA levelező tagja 3

Ellátásilánc-menedzsment szekció

Szegedi Zoltán - Reicher Regina Zsuzsanna - Kozma Tímea: Hazai vállalkozások ellátási láncon belüli együttműködései 4

DOI: 10.21405/logtrend.2019.5.2.4

Tolnay Anita, Bartus Ildikó - Kerekes Etelka - Lajos Attila: Hatékony ellátási lánc-menedzsment a hazai laboratóriumi műszerforgalmazók piacán 10

DOI: 10.21405/logtrend.2019.5.2.10

Zéman Zoltán - Gáspár Sándor - Thalmeiner Gergő: KPI tree mint controlling módszer alkalmazása a gazdálkodásszervezési folyamatok elemzésére 17

DOI: 10.21405/logtrend.2019.5.2.17

Logisztikai kihívások szekció

Mészáros Kornélia - Mester Enikő - Gyenge Balázs - Kozma Tímea: Jelenlegi és várható jövőbeni logisztikai kihívások az autópárhán generikus megközelítéssel. 23

DOI: 10.21405/logtrend.2019.5.2.23

Kurucz Attila - Kovács Eszter: Digitális alapú logisztikai innováció fogadtatása a fiatalok körében 29

DOI: 10.21405/logtrend.2019.5.2.29

Puskás Eszter - Bertalan Marcell: Mesterséges intelligencia integrálása AnyLogic környezetbe logisztikai problémák megoldására. 32

DOI: 10.21405/logtrend.2019.5.2.32

Zöld logisztika - zöld ellátásilánc-menedzsment szekció

Tiszai Géza - Pónusz Mónika: Környezetbarát csomagolás a zöld ellátási lánc szemszögéből 40

DOI: 10.21405/logtrend.2019.5.2.40

Horváth Adrienn: Körforgásos gazdálkodás eszméi, a körkörös ellátási lánc menedzsment 47

DOI: 10.21405/logtrend.2019.5.2.47

LOGISZTIKAI

TRENDEK ÉS LEGJOBB GYAKORLATOK

Alapító:
Dr. Karmazin György †

BI-KA Logisztika Kft.
alapító tulajdonosa

A Logisztikai trendek és legjobb gyakorlatok kereskedelmi forgalomban nem kapható, zárt terjesztésű szaklap. Megjelenik évente 2 alkalommal.

ISSN 2416-0555 (Nyomtatott) · ISSN 2560-0362 (Online)

Főszerkesztő: Dr. habil Oláh Judit · *Főszerkesztő helyettes:* Dr. Kozma Tímea.

A szerkesztőség címe és elérhetőségei:

5000 Szolnok Városmajor u. 23.

Telefon: +36 30 4224 117; +36 20 480 4177 · E-mail: logisztikaitrendek@gmail.com

Felelős kiadó: BI-KA Logisztika Kft.

Az aktuális lapszámban szereplő szakkikkek a kiadvány hivatalos online-felületén érhetők el.

Mesterséges intelligencia integrálása AnyLogic környezetbe logisztikai problémák megoldására

Puskás Eszter

PhD hallgató

Budapesti Műszaki és Gazdaságtudományi

Egyetem Anyagmozgatási és Logisztikai

Rendszerek Tanszék

E-mail: eszter.puskas@logisztika.bme.hu

Bertalan Marcell

egyetemi tanársegéd

Budapesti Műszaki és Gazdaságtudományi

Egyetem Anyagmozgatási és Logisztikai

Rendszerek Tanszék

E-mail: marcell.bertalan@logisztika.bme.hu

Absztrakt

A logisztikai rendszerek egyre összetettebb és bonyolultabb feladatokkal állnak szemben, melyeknél állandó kihívást jelent a megfelelő működési modell felállítása vagy egy optimum érték meghatározása. A fenntarthatóság és hatékonyság javításának céljából folyamatosan új technológiák alkalmazása válik szükségessé. A mesterséges intelligencia (MI) térhódítása a logisztika területét sem kerülte el, páratlan megoldási lehetőségeket kínálva a tervezési és fejlesztési feladatok során. Cikkünk célja a logisztikai rendszerek vizsgálatához gyakran használt AnyLogic szimulációs program és a mesterséges intelligencia együttes alkalmazási lehetőségeinek vizsgálata a szimulációs modellek új generációjának létrehozásához.

Abstract

In recent years, logistics systems are facing increasingly difficult and complex tasks where the challenge is to create an appropriate operating model or to determine an optimum value. Constantly applying new technologies will be necessary for the purpose of sustainability and efficiency improvements. The rise of Artificial Intelligence (AI) has not escaped its logistical scope, offering unique solutions for design and development projects. The purpose of this paper is to investigate the combined application of the AnyLogic simulation software commonly used to study and examine logistics systems and artificial intelligence to create a new generation of simulation models.

Kulcsszavak:

logisztika, szimuláció, mesterséges intelligencia, AnyLogic, megerősítéses tanulás

Keywords:

logistics, simulation, artificial intelligence, AnyLogic, reinforcement learning

DOI: 10.21405/logtrend.2019.5.2.32

1. Bevezetés

A vevői igények individualizációja, az egyre növekvő kiszolgálási színvonal vagy a rugalmasság, adaptivitás és intelligencia integrációjának szükségességének hatására a logisztikai rendszerek és folyamatok egyaránt jelentős változáson mennek keresztül. A legtöbbször sztochasztikus jellegű rendszer paramétereinek száma, összetettsége, továbbá belső és külső kapcsolatainak egysége egy olyan hálózatot eredményez, melynek paraméterei, működési feltételei és modellje igen ritkán írhatóak le egyszerű analitikai eszközökkel. Ennek hatására mondhatjuk, hogy egyre több vállalat életének részévé vált a szimulációs eszközök alkalmazása, mellyel szakértők munkáját tudják segíteni stratégiai, taktikai és operatív tervezési és működtetési problémák megoldásában.

A felmerülő nehézségek gyors és hatékony kezelésének érdekében egyre több területen alkalmazzák a mesterséges intelligencia adta lehetőségeket. A technológia megjelenése és elterjedése egyre növekvő tendenciát mutat

mind az extralogisztika mind az intralogisztika területén. A digitális ellátási lánc, az intelligens gyárak mind magukban foglalják a mesterséges intelligencia különböző megjelenési formáit.

Egyre több olyan feladat kerül a vállalatok elé, ahol a jelenleg is jellemző egyszerűbb heurisztikák helyett ajánlott a mesterséges intelligencia képességeinek alkalmazása. A módszeren fejlesztéséhez és teszteléséhez elengedhetetlen a környezeti modell felállítása, melyre megfelelő eszköz az AnyLogic szimulációs szoftver. Annak érdekében, hogy a szimulációs modell tükrözni tudja a valós rendszer működését, nem kérdés, hogy a mesterséges intelligenciának is be kell ágyazódnia a szimulációba, ezzel megteremtve a szimulációs modellek új generációját.

Cikkünk első felében a mesterséges intelligencia fogalmi kérdéseit áttekintve megvizsgáljuk a különböző megjelenési formáinak, többek között a gépi tanulás logisztikai alkalmazási területeit. Az ezt követő fejezetben a szimulációs módszerek elvi alapjain

keresztül az AnyLogic szimulációs szoftver mesterséges intelligenciával való integrációját térképezzük fel. Egy mintapéldán keresztül bemutatjuk az előzőekben részletezett mesterséges intelligencia és AnyLogic szoftver együttes alkalmazásában rejlő lehetőséget, kiemelve a technológia egyszerűen alkalmazható oldalát és a szoftver könnyen elérhető tulajdonságait. Végül összefoglaljuk az áttekintésből és eredményekből származó főbb következtetéseinket.

2. Mesterséges intelligencia logisztikai lehetőségei

Az informatika fejlődése, a számítási kapacitások folyamatos növekedése, a társadalom tudásvágya és elkönyvelmesedése egyre inkább előtérbe hozta, szükségessé és lehetővé tette a mesterséges intelligenciák (MI) kutatását és alkalmazását mind az iparban, mind a hétköznapi életben. A logisztika technológiai trendek új szintű automatizálásra törekednek - általában növekvő interakció



1. ábra: Mesterséges intelligencia megvalósítási lehetőségei

Forrás: Saját szerkesztés

igényelnek az MI alkalmazásokkal. (Manuj et al, 2011) Az ilyen újítások technológiai fejlesztése és megvalósítása két összefonódott és párhuzamos folyamat, hiszen az MI logisztikai területekbe való integrálása teljesen újradefiniálhatja a jelenleg alkalmazott gyártási, szállítási és menedzsment döntési koncepciókat, mint például szabványos szolgáltatások válhatnak személyre szabottá vagy intelligens automatizálás javíthatja a működést. (DHL Trend Research, 2018) (Klumppp et al., 2017)

De mit is értünk mesterséges intelligencia alatt? A definícióra több megközelítés is létezik. Az ún. reaktív gépek például képelenek a tanulásra, adott döntéshozatal során csakis egy limitált bemenet-halmazra képesek reagálni, nem tudnak kilépni azon egyszerű feladatok elvégzésének köréből, amelyre programozták őket, és mégis ez az egyik típusa a mesterséges intelligenciáknak, ha úgy tetszik, azok első szintje. Egy másik típus, a limitált memóriák viszont már képesek tanulni és ezáltal a további működést meghatározó döntést támogatni a működés közben megszerzett historikus adatok felhasználásával. Ezek alapján az ilyen rendszerek építenek egy állandó és előre betáplált adathalmazra, de közben figyelik környezetüket, érzékelik a változásokat, majd a megfigyelésekkel nyert információk alapján elvégzik a szükséges módosításokat. Napjainkban a „mesterséges intelligencia” fogalma alatt inkább ez utóbbi csoportot értik, ahogy Cihan H. Dagli is írja „a gépi intelligencia emulálja, vagy lemásolja az emberi ingerfeldolgozást (érzéketfeldolgo-

zást) és a döntéshozó képességet számítógépekkel. Az intelligens rendszereknek autonóm tanulási képességekkel kell bírniuk és alkalmazkodniuk kell tudni bizonytalan, vagy részlegesen ismert környezetekhez.” (Ayon Dey, 2016)

Az MI különféle formáinak fejlesztése alkalmas olyan döntéshozó helyzetekben problémák megoldására, ahol az optimális vagy pontos megoldások túl drágák vagy nehezen előállíthatók. Ennek a képességnek köszönhetően az MI-t sikeresen alkalmazzák olyan területeken, mint például a gépi tanulás, szakértői rendszerek, önvezető járművek, gépi látás, nyelvfelismerés vagy robotika, melyet összefoglalóan az 1. ábra szemléltet. (Luger et al., 2002)


A tanuló intelligencia például könnyen megvalósítható gépi tanulás segítségével, amit komplex, nagy mennyiségű adatot és sok változót tartalmazó feladatok esetén érdemes alkalmazni abban az esetben, ha a problémára jellemző szabályok, egyenletek túl bonyolultak, a feladat szabályai vagy az adatok jellege folyamatosan változik és ehhez a programnak is folyamatosan hozzá kellene igazodnia (pl. energiaigény vagy vásárlási trendek előrejelzése). Tehát gépi tanulás segítségével az MI képes matematikai modellt alkotni egy bemeneti adathalmaz felhasználásával, ezen tanulási szakasz befejeztével pedig ismeretlen adatokra építve is képes lesz majd a program döntéseket hozni. A gépi tanulás módszerei a felügyelt tanulás, megerősítéses tanulás és a nem felügyelt tanulás. (Wuest T. et al., 2016)

Felügyelt tanulás esetén szükségünk van egy

olyan meglévő adathalmazra, amely egyrészt tartalmazza a bemeneteket, másrészt tartalmazza az egyes bemenetekre elvárt válaszokat, kimeneteket is. A program ezt felhasználva tanulja meg, alakítja ki a lehetséges bemenetek és válaszok közötti összefüggéseket, amely alkalmas lesz az ismeretlen bemenetekre épülő válaszok prediktálására, döntések meghozatalára. Nem felügyelt tanulás során a tanuló adatbázisban szereplő bemeneti adatainkhoz nem tartozik elvárt kimeneti érték, ezáltal itt az elsődleges cél a tanulás alapjául szolgáló adatok megértése. Nincs kijelölt helyes válasz, így az algoritmusnak magának kell felfedeznie az adatokban rejlő struktúrát. Leggyakoribb megvalósításuk az ún. klaszterezési algoritmusok amelyek csoportokat alkotnak oly módon, hogy az adott klaszteren belüli adatok nagyobb mértékű hasonlóságot mutassanak, mintha egy másik klaszter adataihoz hasonlítanánk őket. (Wuest T. et al., 2016)

A megerősítéses tanulás alkalmazása esetén nem használnak tanulásra alkalmas kezdeti bemeneti adathalmazt, a program interakciókból tanul, maga szerez tapasztalatokat. Az ágens próba-szerencse alapon megfigyeli és kapcsolatba lép a környezettel, amely alapján pozitív és negatív jutalmakat szerez. Cél, hogy időnként egy-egy új cselekvést/irányt is kipróbáljon, hátha ezzel összességében magasabb jutalmat tud elérni az eddig megtalált megoldásoknál, és ezt tegye meg még akkor is, ha ezzel le kell tennie a járt útról, lemondva ezzel az eddig ismert legjobb megoldásról. Például képzeljünk el egy rakotárépítést, ahol kommissziós feladatok várnak egy targoncára. Amennyiben felkeres és elvégez egy kiszedési feladatot, akkor jutalmat kap, viszont minél hosszabb utakon teszi meg ezeket, annál több negatív pontot is szerez. A cél, hogy a lehető legtöbb pontot szerezzék meg a folyamat során. (Wuest T. et al., 2016) (Kotsiantis S. B., 2007)

Napjainkban a gépi tanulás számos alkalmazását és fejlesztését figyelhetjük meg: Kim et al. (2002) egy intelligens ágens-alapú rendszert mutat be, amely egy zóna alapú kommissziós esetén optimalisan rendeli össze a munkavállalókat a zónákkal, míg Waschneck et al. (2018) cikkükben a megerősítéses tanulás technikáját alkalmazták a termelés ütemezés optimalizálására, mellyel az Ipar 4.0 által elképzelt decentralizált, öntanuló és optimalizáló rendszert valósították meg. A módszertanok együttes alkalmazása további ajtókat nyit meg előttünk. Erre mutat példát a rakodási terv optimalizálására használt ún. hátizsák problémának



2. ábra: Két karú kollaboratív robot által végzett kommissiózási feladat

Forrás: Kimura Nobutaka et al., 2015

fejlesztésére alkalmazott felügyelt és megerősítéses tanulás együttes módszertana is. (Duan et al., 2018)

Nem is olyan régen, a robotika még egyet jelentett egy adott feladat periodikus elvégzésére programozott - többek között a termelésben is gyakran alkalmazott - megoldásokkal. Nem hoztak döntéseket, nem érzékelték a körülöttük lévő világot, a környezettől ezáltal elzártan és repetitíven végezték ugyan azt a betáplált mozdulatsort. Azonban a mesterséges intelligencia folyamatos terjedésével a robotika is megpróbálja hasznosítani az így létrejött tudást. A megerősítéses tanulás lehetővé teszi például, hogy a robot önállóan fedezzen fel egy optimális viselkedést a környezettel történő interakciók révén. A gépi látás lehetőséget ad a robot számára, hogy felismerje a mozgató objektumot, a gépi tapintás segítségével figyelje a megfogás erősségét, majd átmozgassa az objektumot a megfelelő helyre. Kimura et al. cikkükben egy a 2. ábrán látható kétkaros robot prototípust mutatnak be különböző termékeket kiszolgáló raktár kommissiózásának automatizálására. (Kimura et al., 2015) A szenzorok segítségével tanulás útján szintén kialakítható egy „öntudat érzet”, amikor a robot tisztában van saját fizikai mivoltával, figyelni és reagálni a környezetre, ezzel lehetővé téve akár az ember-robot közötti interakciókat egy kollaboratív rendszer kialakítása érdekében. Ezzel a jövőben a feladatok akár két részre oszthatók. Az ismétlődő folyamatokat robotok végzik, így nagyobb energiát fektethetünk az emberi értelmezés és döntéshozatal nehézségeire. (DHL Trend Research, 2018)

Egyre inkább elérhetővé és fontossá válik az emberekkel történő verbális és non-verbális kommunikáció megértése nyelv-felismerés segítségével (NLP, Natural Language Processing). A Hitachi japán elektronikai

csoport kifejlesztett egy „H” nevű MI technológiát, amely a Kaizen, tehát a munkafolyamatok folyamatos fejlesztésének MI verziója. A „H” a mély tanulást és az NLP technikát használja az információk feldolgozására, hogy végül olyan mintákat találjon az adatokban, amelyeket az emberek szem elől tévesztenének. A technológia a kapott információk alapján keresi az üzleti célkitűzések szempontjából releváns feltételeket, majd meghatározza az ezen célok optimalizálásának módszerét. (Bernard Marr, 2019)

A tudásalapú vagy szakértői rendszerek olyan szoftverek, amelyek a felhasználók számára próbálnak javaslatokat tenni, a döntésüket támogatni azáltal, hogy az adott terület szakértői által betáplált tudást hasznosítják. Az olyan MI technikák, mint az említett szakértői rendszerek, ígéretes új megközelítést kínálnak a sokrétű és összetett operatív és tervezési problémákra. (Hokey Min, 2010) Képzeljünk el egy termelő vállalatot, annak vállalatirányítási rendszerét, ahol a beszerző egy felhasználói felületen keresztül lekérdezi a következő héten a termelés során beépülő cikkszámokat. A rendszerünk a korábban a szakértők által megadott képletek, egyszerűbb „ha-akkor” logikák segítségével megvizsgálja, hogy valamelyik cikkből szükséges-e új rendelést leadni és azt a lekérdezést követően jelzi a felhasználónak. A nemzetközi irodalomban számos alkalmazási megoldást találhatunk, például Eastman Kodak egy szabályalapú szakértői rendszert dolgozott ki a raktárban történő optimális megrendelési útvonal kiválasztására. (Hokey Min, 2010)

Járművek tekintetében alapvetően kettő, egymással is kapcsolatban álló területen hasznosul az MI. Az ember-gép közötti interakciók közé sorolhatjuk a nyelvfelismerést alkalmazó virtuális asszisztenseket,

a vezetési szokások monitorozását és azok elemzését. Ezek közvetlenül nem befolyásolják az irányítást, de statisztikákkal, tanácsokkal és figyelmeztetésekkel láthatják el a sofőrt.

A „fejlett sofőr-segítő rendszerek” és az önvezető járművek alkotják a második csoportot, amelyek szenzorok és azok fúziója révén, többek között kamerával történő gépi látás, radar és lidar alapú objektum érzékelés segítségével - az automatizáció fokának függvényében - támogatja vagy végzi a jármű irányítását. Ezen automatizációs szintek megkülönböztetésére a Society of Automotive Engineers International 2014-ben vezetett be egy rendszert, amely 0 és 5 közötti egész számokkal kategorizálja az autonómítás mértékét. Nullás esetben csak figyelmeztet, esetleg - baleset elkerülése érdekében - beavatkozik a rendszer az irányításba, míg az ötös szintnél egyáltalán nem szükséges emberi részvétel, akár a kormánykerék is elhagyható.

Az előző bekezdésekben már többször is megemlítettük a gépi látást, amely a gépi érzékelés lehetőségei (pl. hallás, tapintás, ízlelés) közül az egyik leggyakrabban alkalmazott terület. Például a számítógépes látásrendszerek automatizálhatják a vonalkód-leolvasási folyamatot, és ezzel felgyorsíthatják és egyszerűsíthetik azt. Figyelemmel kísérhetik a raktár területét és nyomon követhetik az alkalmazottakat, elemezhetik az adatokat, és megakadályozhatják a lopásokat vagy a biztonsági szabályok megsértését. A Zenrobotics rendszere a számítógépes látás, a gépi tanulás és a mesterséges intelligencia kombinációját használta szinkronizált robotkarok működtetésére az újrahasznosított anyagok válogatására és kiszedésére mozgó szállítószalagokról. (Kite-Powell, 2017)

A logisztikában, de csakúgy az ipar többi

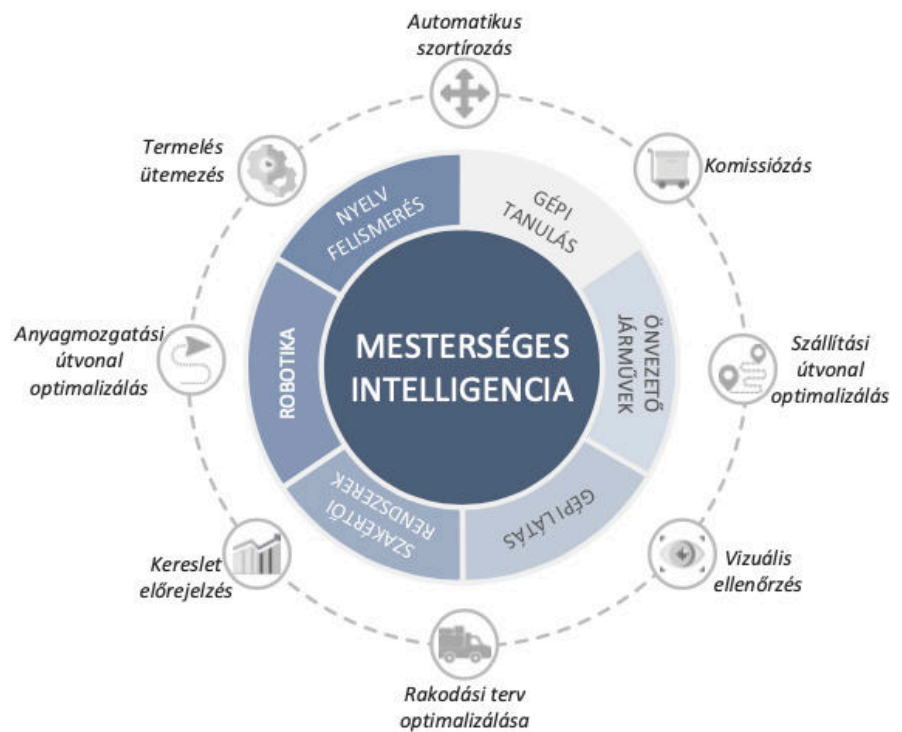
területén az eszközök és alkatrészek idővel történő károsodása és kopása egyszerűen velejáró jellegű. Az IBM Watson nemrégiben sikeresen megvalósította a kamera által történő károk azonosítását és típusának osztályozását ami által meghatározzák a megfelelő korrekciós intézkedéseket a javításához. (DHL Trend Research, 2018)

A robotikában szintúgy meg kell találni a mozgatandó objektumot, azt fel kell ismerni, a méretét az optikai szenzorok alapján meghatározni, a megfogó kart a méretnek megfelelően változtatni és pozícionálni stb. Ahhoz pedig, hogy a tárgyak és objektumok felismerhetővé, azonosíthatóvá váljanak, tanítani kell ezen intelligenciákat.

Összességében jól látszik, hogy a fejzetben tárgyalt területek egymásba fonódnak, a mesterséges intelligencia, a különböző tanulási metódusok, de még a felhasználási területek sem létezhetnek egymás nélkül. A szemléltetett példák bizonyítják, hogy az MI alterületeti, mint a gépi tanulás vagy gépi látás hasznosak lehetnek a 3. ábrán is szemléltetett, a logisztika különféle aspektusainak kezelésére, mint például kommissiózás, készletezés vagy gyártás optimalizálás. (Lugger G. F., 2002)

3. Mesterséges intelligencia és az Anylogic integrációja

A szimulációk alkalmazása egyre több vállalat érdeklődését kelti fel, hiszen rendszereket és megoldásokat vagyunk képesek tesztelni fizikai megvalósítással járó költség-vonlat nélkül. Gyakran előfordul, hogy a termelésben, raktárban vagy az ellátási lánc bármely területén javasolt újításokkal járó




3. ábra: Mesterséges intelligencia logisztikai alkalmazási területei
Forrás: Saját szerkesztés

tesztek túlságosan veszélyesek, drágák vagy sok időbe telnek. Ebben az esetben javasolt a modellezés technikáját alkalmazni, mely leírja az általunk vizsgált mélységi szinten a rendszer struktúráját és viselkedését. A rendszermodell működését alapvetően három módszer határozhatja meg, melyek a rendszerdinamikai (SD), esemény vezérelt (DES), és ágens alapú modellek (ABM). A három módszer teljesen külön alkalmazása helyett a komplex rendszerek megfelelő leírása érdekében megjelentek az ún. hibrid modellek, melyek az SD, DES és ABM eszközök ötvözését jelentik, kombinálva a módszertanok tulajdonságait. (Navonil

Mustafee et al., 2017)
 Az AnyLogic számos funkciót foglal magában ezen hibrid modellek fejlesztéséhez. Például, a modellek dinamikusan képesek adatok olvasására és táblázatokba vagy adatbázisokba való írására a szimulációs futtatás során, valamint dinamikusan ábrázolhatjuk a modell kimenetet. (Crooks et al., 2012)
 A szimuláció bármilyen Java kompatibilis operációs rendszeren futtatható, az AnyLogic pedig nemrégiben bejelentette, hogy a jövőben képes lesz a Python programozási nyelvvel is kommunikálni, amely számos szakember véleménye szerint is a legnépszerűbb programozási nyelv, ha mesterséges



4. ábra: Mesterséges intelligencia és szimuláció integrációja
Forrás: Saját szerkesztés



5. ábra: Szimuláció lefutása
Forrás: Saját szerkesztés

intelligenciáról van szó.

A valós problémák egyre növekvő összetettsége és az információk bősége miatt a gépi intelligencia további felhasználására van szükség a modellezés és szimuláció gyakorlatának elősegítése érdekében. Az MI-t már használó rendszereknek, mint például a digitális ellátási láncoknak, az intelligens gyáraknak és más ipari folyamatoknak - amelyek az ipar 4.0 elemeit alkotják - a mesterséges intelligenciát is be kell építeni a szimulációs modellekbe. Az MI eszközök javíthatják a szimuláció létrehozásának módját azáltal, hogy jobban megértjük, hogyan viselkednek a modellek különböző körülmények között.

Például digitális ikrekkel és „mi lenne, ha” elemző rendszerekkel az MI komponenseket közvetlenül be lehet ágyazni a szimulációs modellbe, hogy teszteléseket és előrejelzéseket lehessen végezni. (Elbattah et al., 2018)

A rendszerek eredendően dinamikus, célorientált és időnként evolúciós viselkedést mutatnak, illetve egy rendszer nem pusztán részeinek összegzéséből áll. Ilyen dinamikus viselkedés esetén a szimulációs modell idővel a valóság elégtelen ábrázolásává válhat. (Elbattah et al., 2018) A jelenségből kifolyólag tehát egy nem helyhez kötött probléma modellezése az idő múlásával eltéréseket okozhat a modell és a tényleges problémák között. Az MI képességeknek a szimulációs modellekbe történő integrálása elősegítheti az adaptív viselkedés megvalósítását minimális emberi ráfordítással. Az MI és a szimulációs modellezés integrációjával létrehozhatóak az ún. új generációs hibrid modellek, melyet a 4. ábra szemléltet.

Érdeemes megjegyezni, hogy a PwC a 2017. évi Téli Szimulációs Konferencián egy esettanulmányon keresztül is bemutatta, hogy a mesterséges intelligencia a szimulációs modellek alkotóelemeként integrálható. (Walsh et al., 2017)

Gyakran túlságosan költséges vagy gyakorlati szempontból nem megvalósítható a tanulásra szolgáló adatok valós tapasztalatokból történő létrehozása. Az MI modellek (például

neuron hálók) tanításához és teszteléséhez ezért szimulációt kell használni. Az MI alkalmazása az optimalizáláshoz és a kalibráláshoz szintén kulcsfontosságú lehetőség a szimulációs modellezésben. Az ágens alapú rendszereknek gyakran nagyon sok paramétere van, és az összes permutáció feltárása túlzott futási időket igényelhet. Mint korábban már említettük, a mester-

séges intelligencia legújabb fejleményei egyértelműen bebizonyították, hogy érdemes a szimulációs modellező környezeteket mesterséges intelligenciával kombinálni, főleg mivel az érdeklődés elmozdul a játékkal kapcsolatos kihívásoktól az üzlet-orientált célok felé.

4. A mintapélda modellje

A mesterséges intelligencia megoldási módszertanai közül a mintapélda bemutatására egy, a szakirodalomban gyakran előforduló problémakört választottunk: egy előre definiált raktári alaprajzon megjelenő igények targoncához való hozzárendelését valósítjuk meg a mesterséges intelligencia megerősítő tanulási módszertanának és a szimulációs technika ötvöztetésével. Az intelligens ügynök alapú rendszer tanulási képessége miatt jobban megbírózik az összetett és változó feladattal a korábban használt egyszerűbb heurisztikákhoz képest. (Min H., 2010)

A felépített minta példa alapjait Dr. Benjamin Schumann által felépített modell adja, melyet a teljes kiszédési ciklus végrehajtása érdekében tovább fejlesztettünk. (Benjamin Schumann, 2018)

4.1. Modell felépítése

A modellt három fő ágens alkotja. Az első a modell egészét összefogó, „Main” ágens, mely az Anylogic szimulációs szoftver alapértelmezett ágense, ami biztosítja a teljes szimulációhoz szükséges platformot. A második létrehozott ágens típus a raktári alaprajzot alkotó cellák. Egy adott cella három különböző tulajdonságú lehet: szürke színnel megjelölt „állvány” típus, amennyiben azon a cellán állvány helyezkedik el, fehér színnel megjelölt „közlekedő út” típus, amennyiben az adott cellán engedélyezett a tovább haladás, illetve sárga színnel jelölt „cél” típus, melyek olyan közlekedésre is alkalmas cellák, amik a targonca által szükséges felkeresendő lokációkat jelölik. A harmadik létrehozott ágens a targoncát reprezentálja, mely a legrövidebb út megtalálása érdekében hoz döntéseket a környezethez alkalmazkodva, melyet a korábban említett cellák alkotnak.

A cellákból álló környezet összekapcsolását az AnyLogic „Connection” funkciója biztosítja, mely képes az ágensek közötti kapcsolatot megteremteni. Minden cellához tartozik egy kapcsolat rendszer, mely a vele szomszédos, „közlekedő út” típusú cellákat tartalmazza.

- Minden más esetben (tehát ha a felkeresendő véletlen cella egy egyszerű közlekedő út része) a jutalom a távolság függvényében változik: $r = -\text{távolság}/10$. (Modellünkben minden cellát egy 70×70 pixeles négyzet jelöl, a távolságot pedig a kiinduló és a cél cellák középpontjai között mért távolságok adják. Ez vízszintes és függőleges mozgás esetén 70, átlós mozgás esetén megközelítőleg 99 pixelt jelent.) A jutalom tehát itt nem is feltétlen jó kifejezés, hiszen a mozgást negatív pontokkal büntetjük.
- A fent ismertetett Bellman-egyenlet első részét ezáltal meghatároztuk, következő lépésként meg kell vizsgálni, hogy a pillanatnyi akcióval elért új cellából (s') indítható lehetséges akciók közül (a') melyik járna a legnagyobb Q értékkel, tehát mekkora lenne a pillanatnyi lépést követő újabb, jövőbeli lépéssel elérhető legmagasabb Q érték. Egy egyszerű „for” ciklus végignézi ezen értékeket és kiválasztja közülük a legnagyobbat.
- A γ (discount factor, magyarul leértékelési tényező) értéke minél alacsonyabb, a Bellman-egyenlet annál kisebb mértékben veszi figyelembe a jövőbeli lépés hatását. 0 érték esetén például csak a pillanatnyi lépéssel nyerhető jutalmat használja fel, ezzel fogja felülrni a cella korábbi Q értékét.
- A fenti két eredmény (jutalom és leértékelt Q-érték), valamint a γ paraméterrel a fenti Bellman-egyenlet szerint kalkulálható a pillanatnyi állapotból (s) a véletlen kiválasztott cellába történő lépéssel (a) a kiinduló cella frissített Q értéke.

Amennyiben az utolsó lépés során felkeresett cella egy kiszedési pont (cél), úgy a targonca ágens visszakerül a tanulási folyamat kiinduló cellájába (ez első körben a bal alsó 240-es sorszámú cella), majd folytatódik a tanulás és a Q-táblázat frissítése. Ez a tanulási iteráció 1000 alkalommal hajtódik végre, a legrövidebb utat pedig az így felépített Q-táblázat értékei fogják meghatározni, melyet a 7. ábra szemléltet: a targoncának csak végig kell mennie a cellákon, egy adott cellából mindig a legnagyobb Q-értéket követve.

4.3. Útvonal kiválasztás

A szimuláció az algoritmus által hozott döntések alapján hatja végre a lépéseket. A

folyamat első lépéseként a targonca a hozzá legközelebb eső igénypontot keresi fel, majd ezt a logikát követve, az összes igény felkeresését követően visszatér kiinduló pontjához. A szimuláció lépéseit az 5. ábra mutatja be, ahol a kiinduló állapottól kezdve az igénypontok felkeresésének útvonalát szemlélteti minden következő igénypontra meghatározva.

Annak érdekében, hogy kiemeljük a MI tanulás teljesítményét, a Q-tanulás algoritmusát a gyakran használt S-shape heurisztikával hasonlítottunk össze.

A két eredményt a megtett távolság alapján jellemeztük egy egységet 1 méternek feltételezve, miszerint a mesterséges intelligenciával bejárt útvonal hossza $\sim 62,97\text{m}$, míg a heurisztikával $\sim 53,79\text{m}$. A két értékből látható a különbség, miszerint a mesterséges intelligenciát alkalmazó algoritmus dinamikusabban tud a változó igényekhez igazodni rövidebb bejárású utat megtétele mellett. Vizsgálatunk jelen cikk keretében nem teljeskörű, nem elemeztük az algoritmus működésének hatékonyságát különböző eloszlású és mennyiségű igénypontok esetén. Várhatóan lehetnek olyan esetek, mikor a heurisztika nem teljesít rosszul, viszont mindenképpen elmondhatjuk, hogy véleményünk szerint a gyakorlatban jellemezően megjelenő szórt elhelyezkedésű igényekhez rugalmasabban képes alkalmazkodni a bemutatott megerősítéses tanulás módszertana.

5. Eredmények és főbb következtetések

A mesterséges intelligencia áttekintésének eredményeként egyérelműen kirajzolódik az újszerű technológiai eszköz sokszínűsége. A különböző megoldási algoritmusok és módszertanok lehetőséget biztosítanak a szerteágazó logisztikai alkalmazási területek problémáinak kezelésére. A mesterséges intelligencia megvalósítási lehetőségeinek együttes felhasználása további ajtókat nyit meg előttünk, mellyel a jelenleg elértekhez képest nagyobb működési hatékonyságot érhetünk el, melyet az iparban megjelent és már alkalmazott rendszerek eredményei is bizonyítják akár a készletezésben, raktározásban vagy a szállítási optimalizálás területén.

A cikk második felében a mesterséges intelligencia képességeinek integrálási lehetőségét vizsgáltuk az AnyLogic szimulációs szoftverrel. A szimulációs technikák alkal-

mazása egy új elrendezés, módszertan vagy bármilyen változtatás tesztelésére és vizsgálatára alapvetően nem újdonság a vállalatok számára, bár a szoftver és szimulációs technika tudásának hiánya sokszor jelent akadályt. A valós rendszer jobb reprezentálása érdekében gyakran érdemes kombinálni a szimulációs technikákat (DES, SD, ABM), melyekre megfelelő környezet biztosít az AnyLogic. A szimuláció és a mesterséges intelligencia integrációjával hozhatjuk létre az ún. új generációs hibrid szimulációkat.

Hisszük, hogy a jövő további érdekes lehetőségeket rejt magában a mesterséges intelligencia szimulációba való integrálásával, a benne rejlő potenciál kihasználásával. A megvalósítási módszerek sokszínűsége rengeteg lehetőséget nyújt a vállalatok számára a megfelelő algoritmus megtalálására és személyre szabására. Véleményünk szerint érdemes időt és energiát befektetni az új generációs hibrid szimulációk lehetőségeinek vizsgálatába a benne rejlő potenciál kiaknázása érdekében.

Összeségében elmondható, hogy egy új kutatási kihívás jelent meg a két terület integrációjával, mely szakterület egyre nagyobb érdeklődésre tesz szert. A mesterséges intelligencia módszertana és a szimulációs modellezés sem egy készen kapható, ún. polcra rakható termék, ezért szakértőkre és pilot projektekre van szükség ahhoz, hogy egy vállalat ne maradjon le és lépést tudjon tartani a feltörekvő logisztikai trendekkel.

6. Felhasznált irodalom

- Ayon Dey (2016): Machine Learning Algorithms: A Review, 1174-1179, International Journal of Computer Science and Information Technologies
- Bernard Marr (2019): The Amazing Ways Hitachi Uses Artificial Intelligence and Machine Learning, Forbes, <https://www.forbes.com/sites/bernardmarr/2019/06/14/the-amazing-ways-hitachi-uses-artificial-intelligence-and-machine-learning/#7210735b3705>, Letöltve: 2019.08.06.
- Dr. Benjamin Schumann, <https://www.benjamin-schumann.com/blog/2018/11/9/how-to-build-a-reinforcement-learning-model-in-anylogic>, Letöltve: 2019.09.20.
- Crooks A. T. – Castle C. J. E. (2012): The Integration of Agent-Based Modelling and Geographical Information for Geospatial Simulation,

- 219-251, A.J.Heppenstall et al. (eds.), Agent-Based Models of Geographical Systems. Springer
- DHL Trend Research (2018): Artificial intelligence in logistics, DHL Customer Solutions & Innovation, Troisdorf, Germany
 - Duan L. et al. (2018): A Multi-task Selected Learning Approach for Solving 3D Flexible Bin Packing Problem, International Conference on Autonomous Agents and Multiagent Systems, Montreal, Canada
 - Elbattah M. – Molloy O. (2018): ML-Aided Simulation: A Conceptual Framework for Integration Simulation Models with Machine Learning, SIGSIM-PADS'18, May 23-25, 2018, Rome, Italy
 - Kim B. et al. (2002): Intelligent agent modeling of an industrial warehousing problem, 601-312, IIE Transactions
 - Kimura N. et al. (2015): Mobile Dual-Arm Robot for Automated Order Picking System in Warehouse Containing Various Kinds of Products, IEEE, International Symposium on System Integrations, Nagoya Japan
 - Kite-Powell, J. (2017): This Recycling Robot Uses Artificial Intelligence To Sort Your Recyclables, <https://www.forbes.com/sites/jenniferhicks/2017/04/04/this-recycling-robot-uses-artificial-intelligence-to-sort-your-recyclables/#1d58dc092d35>, Letöltve: 2017.02.22
 - Klumpp M. (2017): Automation and artificial intelligence in business logistics systems: human reactions and collaboration requirements, 224-242, International Journal of Logistics: Research and applications
 - Kotsiantis S. B. (2007): Supervised Machine Learning: A Review of Classification Techniques, 249-268, Informatica
 - Luger G.F. (2002): Artificial intelligence: structures and strategies for complex problem solving, 4th ed. Essex, England, Pearson Education Limited
 - Manuj I. – Sahin F. (2009): A Model of Supply Chain and Supply Chain Decision-Making Complexity, 511-549, International Journal of Physical Distribution and Logistics Management
 - Min H. (2010): Artificial intelligence in supply chain management: theory and applications, 13-39, International Journal of Logistics: Research and applications
 - Navonil Mustafee et al. (2017): Purpose and benefits of hybrid simulation: Contributing to the convergence of its definition, 1631-1645, Proceedings of the Winter Simulation Conference, IEEE Press
 - V. Mnih et. al. (2013): Playing Atari with Deep Reinforcement Learning, CoRR
 - Wallis, L. – Paich, M. (2017): Integrating artificial intelligence with AnyLogic simulation, Winter Simulation Conference (WSC), IEEE, Las Vegas
 - Waschneck B. et al. (2018): Optimization of global production scheduling with deep reinforcement learning, 1264-1269, 51st CIRP Conference on Manufacturing Systems
 - Wuest T. et al. (2016): Machine learning in manufacturing: Advantages, challenges, and applications, 23-45, Production & Manufacturing Research

