

BUDAPESTI GAZDASÁGTUDOMÁNYI EGYETEM

PÉNZÜGY ÉS SZÁMVITEL KAR

SZAKDOLGOZAT

Buzsáki Krisztina

Nappali

Gazdaságinformatikus

Logisztikai informatikus

2025

BUDAPESTI GAZDASÁGTUDOMÁNYI EGYETEM

PÉNZÜGY ÉS SZÁMVITEL KAR

**A mesterséges intelligencia alkalmazása a készletgazdálkodásban
és rendelésfeldolgozásban**

Belső konzulens: Udvaros József

Buzsáki Krisztina

Nappali

Gazdaságinformatikus

Logisztikai informatikus

2025

Eredetiségnyilatkozat



BGE

BUDAPESTI GAZDASÁGTUDOMÁNYI EGYETEM

Eredetiségi nyilatkozat a szakdolgozatról/diplomamunkáról/záródolgozatról

Hallgató adatai						
Név, Neptun-kód:	Buzsáki Krisztina	I	V	R	Q	I K
Szakdolgozat/diplomamunka/záródolgozat adatai						
Szakdolgozat/diplomamunka/záródolgozat címe:	A mesterséges intelligencia alkalmazása a készletgazdálkodásban és rendelésfeldolgozásban					
Témavezető:	Udvaros József					

Alulírott Buzsáki Krisztina..... büntetőjogi felelősségem tudatában nyilatkozom, hogy a csatoltan bírálatra és védelemre beadott szakdolgozatban/diplomamunkában/záródolgozatban foglalt tények és adatok a valóságnak megfelelnek, és az abban leírtak a saját, önálló munkám eredményei.

A felhasznált forrásokat az irodalomjegyzékben feltüntettem, a rájuk vonatkozó, szabályszerű hivatkozásokat a szövegben megtettem. A szakdolgozat/diplomamunka/záródolgozat más szakon vagy intézményben sem a saját nevemben, sem máséban nem került beadásra. Tudomásul veszem, hogy a szakdolgozatot/diplomamunkát/záródolgozatot az intézmény plágiumellenőrzésnek veti alá. Tudatában vagyok annak, hogy plágium (más munkájának sajátomként történő feltüntetése) esetén a szakdolgozat/diplomamunka/záródolgozat érvénytelen, ezért elutasításra kerül.

Budapest, 2025 év november hónap 26 nap

Buzsáki Krisztina
.....
Hallgató aláírása

Tartalomjegyzék

1.	Bevezetés.....	5
2.	Szakirodalmi feldolgozás.....	7
2.1.	Készletgazdálkodás elméleti alapjai	11
2.2.	Rendelésfeldolgozás folyamata logisztikai központokban	15
2.3.	Mesterséges intelligencia szerepe a logisztikában	19
3.	Probléma elemzés.....	22
3.1.	Hagyományos készletkezelési modellek korlátai.....	26
3.2.	Keresletingadozás és bizonytalanság a modern ellátási láncokban	28
	Irodalomjegyzék.....	44

1. Bevezetés

A 21. század gazdasági változásai és technológiai fejlődése alapvetően átalakították a vállalkozások működését, különösen azokat, amelyek a logisztika és az ellátási lánc területén tevékenykednek. A globalizáció, digitalizáció és egyre élesedő verseny hatására a készletgazdálkodás és rendelésfeldolgozás mára a vállalatok versenyképességének egyik legfontosabb tényezőjévé vált. A fogyasztók gyors és pontos kiszolgálása, a készletek ésszerű szinten tartása és a költségek csökkentése olyan feladatok, amelyek közvetlenül befolyásolják a vállalatok eredményességét. Az utóbbi években azonban egyre fontosabb szerepet kapott a mesterséges intelligencia, amely sok szempontból új alapokra helyezheti a logisztikai működést.

A mesterséges intelligencia alkalmazása ma már nem különlegesség, hiszen számos iparágban, a pénzügyi szektortól az egészségügyig, alapvető szerepet tölt be. A logisztikában is egyre elterjedtebbek azok a megoldások, amelyek adatelemzéssel, gépi tanulással és automatizált döntéstámogatással segítik a vállalatok működését. Ezek a rendszerek képesek előre jelezni a várható keresletet, optimalizálni a raktárkészletet vagy gyorsítani a rendelésfeldolgozási folyamatokat. A technológia nemcsak hatékonyabbá teheti a működést, hanem a fenntarthatóságot is szolgálhatja, például a felesleges szállítás vagy a túlzott raktározás csökkentésével.

Azért is érdekel különösen a mesterséges intelligencia, mert az MI-eszközök valóban elérhetővé váltak a cégek számára, és már nemcsak elméleti lehetőségekként jelennek meg a szakirodalomban. A nagy mennyiségű adat elemzése és a gépi tanulásra épülő előrejelzések olyan új megközelítéseket nyitnak meg, amelyek segítenek a cégeknek abban, hogy gyorsabban és pontosabban reagáljanak a piaci változásokra. Ugyanakkor a technológia bevezetése nem problémamentes, hiszen adatbiztonsági, megbízhatósági, valamint a munkavállalók szerepének átalakulását is érintő kérdéseket vet fel.

Logisztikai informatikus hallgatóként különösen érdekel, hogy a mesterséges intelligencia hogyan tudja hatékonyabbá tenni az ellátási láncot. Az utóbbi években egyre inkább azt tapasztaltam, hogy a logisztika ma már nem csupán az anyagáramlás megszervezéséről szól, hanem egy komplex információs rendszerről, amelyben az adatvezérelt döntéseknek jelentős szerepük van. Egy cég csak akkor maradhat versenyképes, ha a készletgazdálkodási és rendelésfeldolgozási folyamatai rugalmasak, képesek tanulni és alkalmazkodni. Ebben pedig

komoly segítséget nyújthat a mesterséges intelligencia, hiszen támogatja a döntéshozókat, csökkenti a hibák esélyét és automatizálja a munkafolyamatok egy részét.

Mindezek mellett a mesterséges intelligencia megjelenése, nemcsak egy technológiai újítást jelent, hanem szervezeti változásokat is. Egy új intelligens rendszer bevezetése átalakítja a vállalati folyamatokat, másfajta készségeket vár el, és néha a vállalati kultúra változásával is jár. A logisztikai központokban az MI-alapú megoldások nemcsak az automatizált raktárkezelésben és az útvonaloptimalizálásban segítenek, hanem a korábbi rendelési adatok és a piac mozgása alapján javaslatokat is tudnak tenni a készletek eloszlására. Ezek révén csökkenthetők a fölösleges raktározási költségek és a készlet hiányából fakadó kockázatok is.

Az pedig, hogy megjelent a mesterséges intelligencia, nemcsak egy technológiai fejlesztőparkot jelent, hanem a logisztikával párhuzamosan fejlődő adatvezérelt és előrelátó rendszert. Míg korábban a jellemzőek a múltbeli adatokra és az az alapján készített modellek voltak, addig ma már a valós idejű adatok és a predikciók adják a háttérrel. Ez nemcsak egy fejlődés, hanem egy új szemlélet, amelyben a gyorsaság, a pontosság és a folyamatos alkalmazkodóképesség a hangsúlyos.

A dolgozat célja, hogy átfogó képet adjak a mesterséges intelligencia készletgazdálkodásban és rendelésfeldolgozásban betöltött szerepéről, különösen arról, hogy az MI-alapú megoldások hogyan járulhatnak hozzá a logisztikai hatékonyság növeléséhez. Emellett bemutatom azokat az előnyöket és korlátokat is, amelyek a hagyományos rendszerekhez képest az intelligens technológiák alkalmazásával együtt járnak. A dolgozat kitekint arra is, hogyan lehet az MI-t a valóságban beilleszteni a logisztikai központok mindennapi tevékenységeibe.

A dolgozat felépítése ennek megfelelően épül fel. A szakirodalmi áttekintéstől a problémák bemutatásán át a gyakorlati példákig és egy egyszerű MI-alapú szimulációig, végül a kutatás eredményeinek összegzéséig. A mesterséges intelligencia fejlődése a logisztikában tehát nemcsak új technológiát jelent, hanem egy olyan szemléletváltást is, amely hosszú távon meghatározza a vállalatok működését és versenyképességét.

2. Szakirodalmi feldolgozás

A készletgazdálkodás és rendelésfeldolgozás területén zajló tudományos vizsgálatok egyre inkább ráirányítják a figyelmet arra, hogy a vállalati logisztikai folyamatok nem csupán fizikai áruáramlásként, hanem információ és adatvezérelt rendszerekként értelmezhetők. A klasszikus készletgazdálkodási modellek, például az EOQ-modell vagy a rendelési pontok alkalmazása, abban az időszakban jött létre, amikor a kereslet viszonylag stabil volt és a vezetési folyamatok kevésbé dinamikusak, azonban a 21. század logisztikai környezetében ezek a modellek korlátokba ütköznek. A modern vállalat számára a készletgazdálkodás kulcsfontosságú, hiszen a készletek szintje, azok rendelkezésre állása és az azt biztosító folyamatok közvetlenül hatnak a szolgáltatási színvonalra, valamint a költségek alakulására. A rendelésfeldolgozás során a megrendelés beérkezésétől a kiszállításig tartó folyamat lépései, mint a megrendelés rögzítése, készletellenőrzés, raktári felvétel, csomagolás, szállítási előkészítés nem csupán logisztikai rutinok, hanem olyan komplex rendszerek, amelyekben az időzítés, az adatáramlás, a raktári és szállítási kapacitások, valamint a készletek állapota egyidejűleg befolyásolja a végeredményt.

Ebben a kontextusban a mesterséges intelligencia (MI) és a gépi tanulás alkalmazásai új lehetőségeket nyitnak a logisztikai folyamatok optimalizálásában. A tudományos szakirodalom egyre többen foglalkozik azzal, hogy az MI-alapú rendszerek képesek lehetnek valós idejű adatok feldolgozására, kereslet előrejelzésére, készletszintek dinamikus módosítására, valamint az automatizált rendelés és raktárkezelés támogatására. Például az „Artificial Intelligence-Driven Inventory Management: Optimizing Stock Levels and Reducing Costs Through Advanced Machine Learning Techniques” című tanulmány rávilágít arra, hogy a „manuális irányítási módszerek nem hatékonyak” a kereslet és készletnyilvántartás tekintetében, és kiemeli az MI-alapú módszerek szerepét az ellátási lánc hatékonyságának növelésében. (Osman)

A készletgazdálkodás elméleti alapjai kapcsán a szakirodalom hangsúlyozza, hogy a vállalatoknak olyan készletpolitikákat kell kialakítaniuk, melyek nem csupán a statikus és prediktív modellekre épülnek, hanem képesek reagálni a változó piaci feltételekre és az időingadozásokra. Az „AI-Driven Inventory Optimization in Supply Chains: A Comprehensive Review on Reducing Stockouts and Mitigating Overstock Risks” című áttekintés rámutat arra, hogy a „gépi tanulás, prediktív analitika és mélytanulás ... növeli az automatizált utánpótlást, támogatja a többszintű és a kereslet-előrejelzést”. (Bhavikatta) E szerint a kutatásban az MI nem csupán kiegészítő eszköz, hanem stratégiai tényezőként jelenik meg a készletgazdálkodásban.

A rendelésfeldolgozás tekintetében a szakirodalom arra figyelmeztet, hogy a folyamatok sebessége és rugalmassága ma már olyan versenyparaméterei a vállalatoknak, amelyeket nem lehet a hagyományos készlet és raktárkezelési modellek keretein belül kezelni. Az „AI and IoT: A Future Perspective on Inventory Management” tanulmány megállapítja, hogy az MI és az IoT együttes használata „valós idejű nyomon követést, prediktív elemzést és automatizált utánpótlást teszi lehetővé, ezáltal példátlan szintű hatékonyságot és pontosságot biztosítva a készletgazdálkodásban”. (Singh) Az idézet rámutat arra, hogy a rendelés és készletkezelési folyamatokban az adatvezérelt döntéshozatal egyre inkább elvárás.

Az MI szerepe továbbá abban is megjelenik, hogy a vállalatok képesek legyenek az úgynevezett „just-in-time” és „lean” logisztikai stratégiák továbbfejlesztésére. Míg ezek a stratégiák korábban a készlettel függtek össze, addig ma olyan rendszerek szükségesek, amelyek előre jelzik a keresletet, minimalizálják az ingadozások hatását és automatikusan adaptálódnak a környezet- és supply-chain-zavarokhoz. A „AI-enhanced inventory and demand forecasting: Using AI to optimize inventory management and predict customer demand” című dolgozat kiemeli, hogy „a hagyományos készletgazdálkodási rendszerek általában olyan technikákra támaszkodnak, mint az Economic Order Quantity (EOQ), a Just-In-Time (JIT) ... ezek a módszerek ... gyakran nem tudnak alkalmazkodni a gyorsan változó piaci feltételekhez és a vásárlói preferenciákhoz.”. (Kumar)

A mesterséges intelligencia integrációja a készletgazdálkodásba nemcsak technológiai újítást jelent, hanem gazdasági és menedzsmenti szemléletváltást is. A korábbi évtizedekben a vállalatok elsősorban a tapasztalati adatokra és egyszerű statisztikai modellekre támaszkodtak, azonban napjainkban a döntéshozatal egyre inkább adatalapú, prediktív és automatizált folyamatokká vált. Az MI-alapú készletgazdálkodás egyik kulcsterülete a kereslet előrejelzése, amelyben a gépi tanulás lehetővé teszi a múltbeli értékesítési adatok, piaci trendek, időjárési tényezők és szezonális hatások együttes elemzését. A kutatások szerint a mesterséges intelligencia alkalmazása akár 20–30%-kal is növelheti a kereslet-előrejelzések pontosságát, ezáltal jelentős megtakarítást eredményezve a készletezési költségekben. (Culot) Az előrejelzés megbízhatósága pedig közvetlenül befolyásolja a rendelésfeldolgozás hatékonyságát, mivel a vállalatok pontosabban képesek meghatározni azt, hogy milyen mennyiségű termékre lesz szükség adott időszakban.

Az MI-alapú rendszerek alkalmazása ugyanakkor nem csupán a kereslet előrejelzésére terjed ki, hanem kiterjed a készletoptimalizálásra, a szállítási útvonalak dinamikus módosítására, sőt az automatikus újrendelésre is. Az olyan megoldások, mint a neurális hálózatok vagy a

mélytanuló modellek, lehetővé teszik a korábbi rendelési mintázatok felismerését és a jövőbeni trendek előrejelzését. Különösen fontos, hogy több telephelyen vagy raktárban működő vállalatok számára, ahol a készletelosztás hatékonysága döntő szerepet játszik a teljes ellátási lánc költségstruktúrájában. A mesterséges intelligencia ebben az összefüggésben úgy működik, mint egy tanuló mechanizmus, amely folyamatosan javítja saját előrejelzéseit az új adatok beérkezésével, ezáltal önfejlesztő rendszert hoz létre. (Fakhrai Rad)

A szakirodalom hangsúlyozza, hogy az MI logisztikai alkalmazásainak egyik legnagyobb előnye a komplexitás kezelhetősége. A hagyományos készletgazdálkodási rendszerek sok esetben nem képesek egyszerre figyelembe venni az ellátási lánc különböző szintjein zajló eseményeket, míg a mesterséges intelligencia képes az adatokat valós időben integrálni és ezek alapján döntéseket hozni. Fontos a volatilis keresleti környezetben, ahol az automatizált, prediktív algoritmusok gyorsabban reagálnak a piac változásaira, mint az emberi döntéshozók. (Teixeira) A logisztikai központokban az MI-rendszerek már képesek az áruk mozgásának valós idejű követésére, az azonosítási hibák minimalizálására és az energiafelhasználás optimalizálására, ami nemcsak gazdasági, hanem környezeti szempontból is előnyt jelent.

A tudományos források arra is rámutatnak, hogy a mesterséges intelligencia bevezetése új típusú döntéstámogató környezetet hoz létre, amelyben az ember és a gép közötti együttműködés a logisztikai hatékonyság kulcsa. Az emberi szakértelem továbbra is nélkülözhetetlen a stratégiai döntések meghozatalában, azonban az MI rendszerek képesek jelentősen csökkenteni a rutinfolyamatokhoz kapcsolódó hibákat és idővesztéseket. A „hybrid intelligence” koncepciója szerint a legnagyobb hatékonyság akkor érhető el, ha az emberi döntéshozatal és a mesterséges intelligencia algoritmusai egymást kiegészítve működnek. A logisztikai vállalatok így nem csupán költséghatékonyabbak lehetnek, hanem versenykéesebbek is egy olyan környezetben, ahol a gyors reakcióidő és az adaptív működés alapvető követelmény. (Chen)

Mindemellett a kutatások felhívják a figyelmet az MI-rendszerek implementációjának nehézségeire is. Az adatintegráció, az adatbiztonság és a rendszerek interoperabilitása gyakran komoly akadályt jelent a logisztikai folyamatokban. A kisebb és közepes vállalatok esetében különösen problémás a magas beruházási költség, valamint a megfelelő szakértelem hiánya, amely korlátozza a mesterséges intelligencia széles körű elterjedését. A tanulmányok kiemelik, hogy az MI-alapú készletgazdálkodás sikeres bevezetése csak akkor valósulhat meg, ha az adatminőség és a vállalati folyamatok digitalizáltsága elér egy minimális szintet. (Ünal) Az

adatok valós idejű gyűjtése, tárolása és elemzése ugyanis alapfeltétele annak, hogy a gépi tanulás algoritmusai képesek legyenek pontos és releváns előrejelzéseket készíteni.

Egyre több tudományos kutatás foglalkozik azzal is, hogyan hat a mesterséges intelligencia a logisztikai döntéshozatal minőségére és sebességére. A gépi tanulás és a prediktív analitika segítségével a döntéshozók képesek valós időben elemezni a készletek alakulását, felismerni a szűk keresztmetszeteket és optimalizálni a rendelési pontokat. A mesterséges intelligencia ezáltal nemcsak a műveleti hatékonyságot növeli, hanem stratégiai előnyt is teremt, mivel lehetővé teszi a proaktív, előretekintő tervezést. A jövőbeni kutatások ezért egyre inkább arra irányulnak, hogy a logisztika hogyan válhat önálló, tanuló rendszerű hálózattá, amelyben az emberi és mesterséges intelligencia kölcsönösen támogatják egymást a folyamatos fejlesztés és adaptáció érdekében. (Bhavikatta)

A szakirodalmi áttekintés konklúzióként megállapítható, hogy a készletgazdálkodás és rendelésfeldolgozás olyan dinamikus területek, ahol a hagyományos elméletek és modellek már nem biztosítanak elegendő választ a változó piac, az egyre rövidebb ciklusidők és a digitális transzformáció kihívásaira. Az MI-technológiák egyre inkább nem csak alternatívát, hanem szükséges fejlődési pályát jelentenek ezen folyamatok számára.

2.1. Készletgazdálkodás elméleti alapjai

A készletgazdálkodás elméleti háttérének kialakulása az 1910-es évekre vezethető vissza, amikor F. W. Harris megalkotta az Economic Order Quantity (EOQ) modellt. A modell jelentősége abban állt, hogy először próbálta egzakt módon leírni, milyen rendelési mennyiség mellett alakul ki a rendelési költségek és a készlettartási költségek egyensúlya. Harris később úgy fogalmazott, hogy az optimális készlet „olyan pont, ahol a vállalat felesleges terhei eltűnnek, de még biztosított a folyamatosság”. (Harris) Bár az EOQ-modell számos feltételezéssel élt, például állandó keresletet és azonnali pótlást feltételezett, alapvetései ma is érvényesek, legfeljebb kibővített formában jelennek meg. (Silver)

A későbbi kutatások az EOQ-modellt több irányban is továbbfejlesztették. Megjelent a biztonsági készlet fogalma, amely a kereslet és a szállítási idők bizonytalanságának kezelésére szolgál. Ugyanígy fontossá vált a rendelési pont számítása, amely meghatározza, hogy a készletszint elérésekor mikor kell újabb rendelést indítani. (Larson) A modern logisztikai szakirodalomban ezek a fogalmak már összekapcsolódnak a statisztikai előrejelzések és valós idejű adatelemzés technikáival, különösen olyan iparágakban, ahol a kereslet rövid időn belül is jelentősen változhat. Jó példa erre az FMCG-szektor vagy a szezonális termékeket gyártó vállalatok köre.

A 20. század második felében a készletgazdálkodás fejlődése új lendületet kapott a lean menedzsment és a just-in-time (JIT) rendszer megjelenésével. A Toyota termelési rendszere által inspirált JIT megközelítés célja a készletek drasztikus csökkentése, és az, hogy az anyagok csak a tényleges felhasználás pillanatában érkezzenek a vállalathoz. Ahogy Ohno fogalmaz, „a készlet nem értéket teremt, hanem elfedi a rendszer hibáit”. (Ohno) Ugyanakkor a JIT-rendszer sérülékenynek bizonyult a globális ellátási lánc zavarai esetén, amit a COVID-19 járvány különösen erőteljesen igazolt. (Vlachos) A szakirodalom ezért az utóbbi években egyre inkább a rugalmasság irányába mozdult, ami azt jelenti, hogy a vállalatok nem feltétlenül a minimális készletszint elérésére törekednek, hanem a megfelelő tartalékok kialakítására.

A készletgazdálkodás hatékonyságát a készletforgási sebesség és a szolgáltatási szint mutatói írják le legpontosabban. A készletforgás a készletek eladásának vagy felhasználásának gyakoriságát méri, míg a szolgáltatási szint azt jelzi, hogy a kereslet milyen arányban elégíthető ki azonnal a rendelkezésre álló készletből. A két mutató közötti kapcsolat nem lineáris, hiszen a szolgáltatási szint növelése egy bizonyos pont után aránytalanul nagy költségnövekedéssel

jár. Ezért a vállalatok gyakran kompromisszumot keresnek, amely a legjobb egyensúlyt biztosítja a vevői elégedettség és a költséghatékonyság között.

A 21. századi kutatások a készletgazdálkodásban már nem kizárólag az egyensúlyi modellekre, hanem a dinamikus, adatvezérelt rendszerekre helyezik a hangsúlyt. A globalizáció, az ellátási láncok komplexitása és a kereslet gyors változása új kihívásokat támasztanak, ahol a statikus modellek már nem képesek rugalmasan alkalmazkodni a piaci ingadozásokhoz. Ennek hatására a kutatók és vállalatok figyelme a valós idejű adatfeldolgozás és a digitális logisztikai rendszerek felé fordult, amelyek képesek integrálni a különböző forrásokból származó adatokat, és ezek alapján automatizált döntéseket hozni. (Culot) A digitális készletgazdálkodási rendszerek alapját az Enterprise Resource Planning (ERP) megoldások képezik, amelyek lehetővé teszik a termelés, a raktár, a szállítás és a pénzügyi folyamatok integrációját.

A legújabb elméletek szerint a készletgazdálkodás sikeressége a lánc-szintű optimalizáláson múlik, vagyis nem elegendő csupán egy vállalat szintjén keresni az optimális készletszinteket, hanem az egész ellátási lánc összefüggésrendszerében kell gondolkodni. Az úgynevezett multi-echelon inventory system modellben a készletgazdálkodás célja a teljes hálózati készlet minimalizálása úgy, hogy közben a szolgáltatási szint az egész rendszerben megfelelő maradjon. (Larson) A modellezés ezen formája komoly számítási kapacitást igényel, ezért az utóbbi években egyre több kutatás vizsgálja, hogyan alkalmazhatók a mesterséges intelligencia és gépi tanulás eszközei a több szintű készlet és rendelési döntések támogatására. (Ünal)

Az elméleti megközelítések alapján a készletgazdálkodás feladata három fő területre osztható, a készletszint-meghatározás, a rendelési stratégia kiválasztása, valamint a készletinformációk kezelése. Az első a mennyiségi kérdésekre koncentrál, hogy mennyi készlet szükséges az ellátás folyamatosságának biztosításához. A második a döntési időzítésre fókuszál, hogy mikor rendeljen újra a vállalat, míg a harmadik a döntéstámogatásra pontosít, hogy hogyan lehet a rendelkezésre álló információk alapján a legjobb döntést meghozni. A modern vállalatokban ezek a funkciók szorosan összekapcsolódnak, és egyre inkább automatizált rendszerek támogatják őket.

A készletgazdálkodás fejlődésében kiemelt szerepet kapott a globalizáció, amely az ellátási láncok kiterjedésével új szintre emelte a készletek kezelésének komplexitását. A nemzetközi piacokon működő vállalatok esetében a készletek földrajzi eloszlása, a szállítási idők eltérése és a devizaárfolyamok ingadozása mind olyan tényezők, amelyek befolyásolják az optimális készletszint meghatározását. A kutatások szerint az ellátási lánc globalizációja egyidejűleg növeli a hatékonysági lehetőségeket és a kockázatokat, míg a nemzetközi beszerzési hálózatok

csökkenthetik a költségeket, addig a hosszabb szállítási útvonalak és a geopolitikai kockázatok növelik a készletezési bizonytalanságot. (Ivanov) A készletgazdálkodás elmélete ezért kiegészült a rezilienciára, azaz az ellátási lánc ellenálló képességére vonatkozó dimenzióval, amely az utóbbi években a tudományos kutatások egyik központi témája lett.

A COVID-19 világjárvány idején a kutatók újraértékelték, hogyan hat a bizonytalanság a készletek szerepére. Ivanov és Dolgui szerint a globális ellátási hálózatok sebezhetősége miatt a készletstratégiáknak egyszerre kell reagálniuk a kockázatokra és fenntartaniuk a szolgáltatási szintet. Ez a megközelítés az úgynevezett agilis és reziliens készletgazdálkodási modellekhez vezetett, amelyek több beszállító használatát, stratégiai tartalékkészletek kialakítását és prediktív elemzéseken alapuló döntéshozatalt javasolnak.

A reziliens készletgazdálkodási megközelítés szerint a cél nem feltétlenül a minimális készletszint elérése, hanem az olyan rugalmas készletstruktúra kialakítása, amely képes gyorsan reagálni a váratlan eseményekre. Ez magában foglalja a több beszállító struktúra alkalmazását, a stratégiai készletek földrajzi diverzifikálását, valamint az adatalapú előrejelzések beépítését a döntéshozatalba. Ivanov szerint az „end-to-end visibility”, az ellátási lánc teljes átláthatósága, az egyik legfontosabb feltétele annak, hogy a vállalatok képesek legyenek adaptálódni a hirtelen keresletváltozásokhoz. Az átláthatóságot a digitális rendszerek, például az IoT-eszközök, RFID-azonosítók és prediktív analitikai eszközök teszik lehetővé, amelyek valós idejű információkat biztosítanak a készletszintekről és a szállítási folyamatokról. (Kache)

A szakirodalom egyetért abban, hogy a készletgazdálkodás modern formája multidiszciplináris megközelítést igényel, amely a logisztika, az információtechnológia, az adatkutatás és a stratégiai menedzsment tudásanyagát ötvözi. Ez a holisztikus szemléletmód tükröződik az integrált készletgazdálkodási rendszerekben is, ahol a döntéshozók nemcsak a költség és a kiszolgálási szint paramétereire figyelnek, hanem a rendszer egészének stabilitására. Ennek keretében a mesterséges intelligencia és a gépi tanulás algoritmusai nem pusztán technológiai eszközök, hanem stratégiai partnerek, amelyek előre jelzik a zavarokat és javaslatot tesznek a helyreállítási lépésekre. (Teixeira) A döntéstámogató rendszerek így a vállalati kockázatkezelés szerves részévé válnak, és elősegítik, hogy a készletgazdálkodás proaktív, nem pedig reaktív módon működjön.

A készletgazdálkodás kutatásának újabb irányzatai a fenntarthatóság és a körkörös gazdaság szempontjait is integrálják. A vállalatok egyre nagyobb hangsúlyt helyeznek arra, hogy készletkezelési folyamataik ne csupán gazdaságilag hatékonyak, hanem környezeti szempontból is felelősek legyenek. A fenntartható készletgazdálkodás a készletek életciklus-

szemléletű kezelését jelenti, ahol figyelembe veszik az alapanyag-beszerzés, a gyártás, a tárolás, a szállítás és a visszaforgatás környezeti hatásait is. (Teixeira) E megközelítés szerint összhangban áll az Európai Unió környezetvédelmi irányelveivel, amelyek a logisztikai folyamatok karbonlábnyomának csökkentését tűzik ki célul.

A készletgazdálkodás elméleti fejlődése egyértelműen abba az irányba mutat, hogy a jövő rendszerei intelligens, tanuló és adaptív megoldásokra épülnek. Az MI-vel támogatott modellek képesek lesznek valós idejű adatokból tanulni, előre jelezni a keresletet, és automatikusan meghatározni az optimális rendelési mennyiséget. Ez a fejlődési irány nemcsak a logisztikai hatékonyságot növeli, hanem lehetővé teszi a vállalatok számára, hogy a készletgazdálkodást stratégiai előnnyé alakítsák.

2.2. Rendelésfeldolgozás folyamata logisztikai központokban

A rendelésfeldolgozás a logisztikai rendszer egyik olyan eleme, amelyet a szakirodalom következetesen a vállalati működés "idegrendszeréként" ír le, hiszen ezen a ponton találkozik a vevői igény és a vállalat belső folyamatai. A logisztikai központok működése akkor tud hatékony maradni, ha ez a folyamat gyors, pontos és minden lépésében visszakövethető. Ballou klasszikus meghatározása szerint a rendelésfeldolgozás a megrendelés érkezésétől egészen a kiszállításig tartó tevékenységsor, amely magában foglalja az adminisztrációs és készletkezelési feladatokat, a kommissiózást, a csomagolást és a szállításszervezést is. (Ballou) Mivel ez a folyamat közvetlenül hat a vevői elégedettségre, a vállalatok számára stratégiai jelentőségű.

A rendelésfeldolgozás azért számít kulcsfolyamatnak, mert itt válik igazán egyértelművé, mennyire működik összehangoltan a fizikai termékáramlás és az információk kezelése. Ahogy Christopher is kiemeli, a logisztika lényege az anyag és információáramlás szinkronizálása, és ha ez a szinkron megbomlik, akkor a teljes ellátási láncban fennakadások jelentkezhetnek, legyen szó készlethiányról, rosszul kommissiózott termékekről vagy akár késedelmes kiszállításról. (Christopher)

A hagyományos, papír alapú rendelésfeldolgozás sokáig lineáris és viszonylag rugalmatlan modellként működött, ami nagy hibalehetőséggel és lassabb ügyintézással járt. Harrison és van Hoek rámutatnak, hogy ez a modell különösen problémássá vált a globalizálódó ellátási láncok korában, ahol a vállalatok egyszerre több raktárral és sokféle értékesítési csatornával dolgoznak. Ennek következtében a digitalizáció gyakorlatilag elkerülhetetlenné vált, a modern ellátási láncokban az ERP és WMS-rendszerek valós időben kezelik az adatokat, összehangolják a raktárak műveleteit, és automatikusan frissítik a rendelés státuszát. (Harrison)

A logisztikai központok teljesítményét ma már mérőszámok széles körével értékelik. Az egyik legfontosabb a rendelési ciklusidő, vagyis az az időszak, amely a megrendelés beérkezése és annak teljesítése között eltelik. Grant és munkatársai kutatásai alapján a rövid ciklusidő közvetlenül növeli az ügyfélelégedettséget, miközben a vállalat belső költség szintjére is kedvező hatással van. Ehhez szorosan kapcsolódik a szolgáltatási szint, amely a hibamentesen teljesített rendelések arányát mutatja. Az automatizált rendszerek fejlődésével mindkét mutató jelentős javulást mutat az elmúlt években. (Grant)

A kutatások rámutatnak, hogy a modern rendelésfeldolgozásban az adatáramlás legalább olyan fontos, mint az áruáramlás. A nagyvállalatok a mesterséges intelligencia és a prediktív analitika eszközeivel már nemcsak reagálnak a beérkező megrendelésekre, hanem képesek azokat előre

jelezni. Az MI-alapú rendszerek képesek felismerni az ismétlődő mintázatokat, például a heti vagy szezonális keresletingadozásokat, és automatikus rendelés-előkészítéseket indítanak a várható igényekhez igazodva. Chen et al. szerint „az MI-alapú döntéstámogató rendszerek lehetővé teszik, hogy a logisztikai lánc proaktívan reagáljon a piaci változásokra”, ezáltal csökkentve a késedelmeket és a túlzott készletezést. (Chen)

A rendelésfeldolgozás és a készletgazdálkodás közötti összefüggés kiemelt szerepet játszik a vállalati döntéshozatalban. A rendelésfeldolgozás pontossága és gyorsasága közvetlenül befolyásolja a készlet forgási sebességét és a szolgáltatási szintet. Ha a vállalat pontos előrejelzésekkel rendelkezik, csökkenthető a felesleges készlet, és az utánrendelési ciklusok rövidebbek lehetnek. Ezzel szemben a rendelésfeldolgozás hibái torzítják a készletadatokat, ami a készlethiány és a túlzott készletezés kockázatát egyaránt növeli. A logisztikai kutatások ezért hangsúlyozzák a két rendszer, az inventory és order management integrált működésének fontosságát. (Culot)

A digitális transzformáció hatására a rendelésfeldolgozás folyamata ma már nem pusztán operatív, hanem stratégiai eszköz is. Az adatelemzés és mesterséges intelligencia segítségével a vállalatok képesek optimalizálni a teljes rendelési ciklust, miközben a rendszer tanul a korábbi hibákból és teljesítményadatokból. A „predictive order fulfillment” koncepció lényege, hogy a rendszer előre jelzi a várható rendelési csúcsokat, és ennek megfelelően előkészíti a kapacitásokat, így a vállalat már a rendelés beérkezése előtt képes reagálni a keresletre. (Bhavikatta)

A rendelésfeldolgozási rendszerek automatizálása ma már nem csak a gyorsabb és pontosabb működésről szól, hanem a környezeti hatások csökkentéséről is. A modern logisztikai központokban, ahol rengeteg terméket mozgatnak naponta, az energiafelhasználás, a raktári eszközök működtetése és a csomagolási folyamatok jelentős környezeti terheléssel járnak. Ezért a vállalatok egyre inkább arra törekednek, hogy a rendelésfeldolgozást is a fenntartható működés részévé tegyék. Sarkadi, Buglyó-Nyakas és Gál kutatása szerint az intelligens, mesterséges intelligencia-alapú rendszerek bevezetése nem csupán a hatékonyságot növeli, hanem a „zöld ellátási lánc célja ... a környezeti hatások csökkentése ... a hatékonyság és megbízhatóság fenntartása mellett”. (Sarkadi)

Az adatalapú optimalizáció szerepe itt kiemelkedő. Li és munkatársai által bemutatott vizsgálatok szerint az automatizált raktári műveletek energiafelhasználása jelentősen csökkenthető, ha a feladatokat intelligens algoritmusok osztják ki a robotok és gépek között, miközben figyelembe veszik az energiahatékonyságot és a mozgások minimalizálását. (Li) Ez

szerint nem csak gyorsabban, hanem kevesebb energiával is lehet elvégezni a kommissiózást, a szállítmányok előkészítését és a csomagolást, ami hosszú távon jelentős költségmegtakarítást és környezeti hasznot eredményez. A valós idejű adatelemzésnek köszönhetően a rendszer folyamatosan tud alkalmazkodni a beérkező rendelésekhez, előre jelezni a csúcsidőszakokat, és optimalizálni a munkafolyamatokat, így minimalizálva a felesleges mozgásokat és az energiafelhasználást.

Egyre több kutatás vizsgálja a mesterséges intelligencia és a robotika szerepét az emberi munkaerővel való együttműködésben is. A rendelésfeldolgozás jövője nem kizárólag az emberi munka kiszorításáról szól, hanem sokkal inkább a „kollaboratív automatizálásról”, ahol az emberek és a robotok együttműködve végzik a feladatokat. (Ivanov) A robotok elvégzik a monoton, ismétlődő tevékenységeket, míg az emberi munkavállalók a döntést igénylő és kreatív folyamatokra összpontosítanak.

A rendelésfeldolgozási rendszerek fejlesztése egyre inkább a mesterséges intelligencián alapuló önoptimalizáló struktúrák felé halad, ahol a döntések nem előre definiált szabályrendszerek, hanem valós idejű adatelemzések alapján születnek. A „machine learning”-alapú rendszerek képesek önállóan azonosítani a szűk keresztmetszeteket, és adaptívan módosítani a folyamatokat a rendelkezésre álló kapacitásokhoz igazítva. Ez a megközelítés nemcsak hatékonyabbá, hanem robusztusabbá is teszi a rendelésfeldolgozást, különösen a volatilis piaci környezetben, ahol a kereslet előrejelzése bizonytalan. (Teixeira) A jövő logisztikai központjai így képesek lesznek önállóan reagálni a megrendelési hullámokra, minimalizálva a késéseket és maximalizálva a szolgáltatási szintet.

A mesterséges intelligencia emellett hozzájárul az ügyfélkapcsolatok minőségének javításához is. A fejlett CRM-rendszerek (Customer Relationship Management) integrációja a rendelésfeldolgozási platformokkal lehetővé teszi az ügyfelek igényeinek mélyebb megértését. A rendszer például képes azonosítani a visszatérő vásárlási mintázatokat, és automatikusan ajánlásokat küldeni az értékesítési részleg számára, ezzel támogatva a keresztértékesítést és a készlet forgási sebességének növelését. (Chen) Az így létrejövő integrált digitális ökoszisztéma nemcsak a logisztikai folyamatok hatékonyságát növeli, hanem stratégiai szinten is erősíti a vállalat versenyképességét.

Elmondható, hogy a rendelésfeldolgozás a modern logisztikai központok egyik legösszetettebb és legkritikusabb folyamata. A hagyományos, manuális modelleket mára felváltották az automatizált, integrált és adatalapú rendszerek, amelyek a mesterséges intelligencia és a digitalizáció eszközeire építenek. A jövő rendelésfeldolgozási modelljei a valós idejű

információáramlás, a gépi tanulás és a prediktív analitika révén képesek lesznek önálló döntések meghozatalára, ezáltal csökkentve a hibákat, gyorsítva a kiszállítást és növelve a vevői elégedettséget.

2.3. Mesterséges intelligencia szerepe a logisztikában

A mesterséges intelligencia (MI) az utóbbi évtizedben a logisztikai rendszerek egyik legmeghatározóbb fejlesztési irányává vált. Az MI olyan technológiai megoldások összessége, amelyek képesek az emberi gondolkodást és döntéshozatalt részben vagy egészben utánozni, ezáltal lehetővé téve az automatizált, önálló döntéseket a komplex logisztikai folyamatokban. A logisztikai ágazatban a mesterséges intelligencia alkalmazása nem csupán a hatékonyság növelését, hanem az ellátási lánc rugalmasságát és prediktív képességét is szolgálja. (Ivanov) A technológia fejlődése révén a logisztikai vállalatok képesek valós idejű adatelemzésre, előrejelzésre, útvonal-optimalizálásra és a rendelésfeldolgozási hibák minimalizálására, miközben jelentősen csökkentik az emberi beavatkozás szükségességét.

A mesterséges intelligencia logisztikai alkalmazásai több szinten jelennek meg. Az operatív szintű rendszerek az egyes folyamatokat, például a raktározást, szállítást, kommissiózást vagy járműútvonal-optimalizálást támogatják. Míg a stratégiai szintű rendszerek a vállalati döntéshozatalt segítik elő, például a kereslet-előrejelzés, kapacitástervezés és készletoptimalizálás területén. (Teixeira) A logisztikai lánc egészét tekintve az MI szerepe az adatalapú döntéshozatal megvalósításában rejlik, ahol a vállalatok a múltbeli adatok és valós idejű információk alapján automatizáltan hoznak döntéseket a hatékonyság növelése és a kockázatok csökkentése érdekében.

A mesterséges intelligencia kiemelkedő szerepet játszik a szállítási és útvonal-optimalizálásban is, ahol az algoritmusok képesek figyelembe venni az aktuális forgalmi viszonyokat, az időjárási adatokat, a szállítási költségeket és az ügyféligenyeket. A dinamikus útvonaltervező rendszerek (Dynamic Route Optimization Systems) képesek valós időben módosítani a fuvarterveket, ezzel csökkentve az üzemanyag-felhasználást és a késések számát. Az MI ezen alkalmazása nemcsak gazdasági előnyöket nyújt, hanem hozzájárul a fenntartható logisztikai működéshez is, hiszen a rövidebb útvonalak és a jobb kapacitáskihasználás csökkenti a karbonkibocsátást. (Chen) A prediktív karbantartási algoritmusok szintén az MI logisztikai hasznosulásának részei, hiszen ezek előre jelzik a járművek vagy berendezések meghibásodását, megelőzve a leállásokat és biztosítva a folyamatos működést.

Az MI-vezérelt döntéshozatali rendszerek további előnye, hogy képesek valós idejű kockázatelemzést és döntéstámogatást biztosítani. A hagyományos logisztikai rendszerek gyakran a múltbeli adatokra és statikus szabályrendszerekre támaszkodtak, ami korlátozta reagálóképességüket a gyorsan változó piaci környezetben. Ezzel szemben a mesterséges

intelligencia lehetővé teszi a valós idejű döntéshozatalt, amely az aktuális adatok alapján értékeli a lehetséges kockázatokat, például a késéseket, kapacitáshiányokat vagy keresletnövekedést, és javaslatot tesz a legjobb beavatkozási stratégiákra. (Ivanov) Ennek köszönhetően a vállalatok gyorsabban reagálhatnak a zavarokra, ami növeli az ellátási lánc rezilienciáját.

A mesterséges intelligencia egyik legizgalmasabb irányvonala a prediktív logisztika, amely az adatok előrejelző elemzésére épül. A prediktív modellek képesek azonosítani a múltbeli adatokban rejlő trendeket és mintázatokat, majd ezek alapján előre jelezni a jövőbeli eseményeket, például a keresletcsúcsokat, szállítási késéseket vagy logisztikai szűk keresztmetszeteket. (Fosso Wamba) Ezáltal a vállalatok már a problémák bekövetkezése előtt megelőző lépéseket tehetnek, ami radikálisan átalakítja a logisztikai menedzsment proaktív jellegét. A prediktív logisztika egyre inkább kiegészül a preskriptív analitikával, amely nemcsak előrejelzéseket készít, hanem konkrét cselekvési javaslatokat is megfogalmaz a döntéshozók számára.

A logisztikai központokban a mesterséges intelligencia és a robotika integrációja jelentős hatást gyakorol a munkaerőpiacra és a szervezeti struktúrára. Az automatizált rendszerek növelik a termelékenységet, ugyanakkor átalakítják a munkaerő szerepét is. Az ismétlődő, fizikai jellegű feladatokat fokozatosan átveszik az intelligens gépek, míg az emberi munkaerő a döntéshozatalra, az adatelemzésre és a rendszerek felügyeletére összpontosít. A szakirodalom szerint az MI bevezetése nem feltétlenül csökkenti a foglalkoztatást, hanem inkább átalakítja annak szerkezetét, új, magasabb hozzáadott értékű munkaköröket hozva létre. (Ghobakhloo)

A mesterséges intelligencia alkalmazása a logisztikában ugyanakkor etikai és biztonsági kihívásokat is felvet. Az adatgyűjtés és -feldolgozás során kiemelten fontos a személyes és üzleti adatok védelme, különösen az automatizált döntéshozatali rendszerek esetében. Emellett a döntéshozatal átláthatósága is kérdéses lehet, mivel az MI által generált döntések sokszor „fekete dobozként” működnek, azaz az algoritmusok belső logikája a felhasználók számára nem mindig egyértelmű. A szakirodalom hangsúlyozza, hogy a mesterséges intelligencia etikus és felelősségteljes alkalmazása nélkülözhetetlen a bizalom megőrzéséhez és a technológia hosszú távú fenntarthatóságához. (Floridi) Az átláthatóság, az adatbiztonság és az emberi kontroll elveinek integrálása ezért minden logisztikai MI-rendszer alapkövetelménye.

A kognitív technológiák mellett egyre nagyobb szerepet kap az MI és a blokklánc-technológia integrációja is, amely a logisztikai adatbiztonságot és az átláthatóságot erősíti. A blokklánc biztosítja, hogy az ellátási láncban rögzített információk megváltoztathatatlanok és

hitelesíthetők legyenek, míg az MI ezek alapján valós időben képes felismerni az eltéréseket és potenciális csalásokat. Ez különösen fontos a gyógyszeripari, élelmiszeripari vagy high-tech logisztikai láncokban, ahol az áru eredete és útja pontosan nyomon követendő. (Kshetri)

A jövő logisztikai rendszereit az MI-vezérelt döntéshozatal mellett egyre inkább a valós idejű adaptivitás jellemzi majd. A mesterséges intelligencia képes lesz reagálni a piaci változásokra, például a kereslet hirtelen megugrására vagy a szállítási útvonalak lezárására, ezáltal valós idejű újratervezést hajtva végre. Az úgynevezett „self-learning logistics systems” koncepció szerint a jövő rendszerei nemcsak tanulni képesek a múltbeli adatokból, hanem azonnal korrigálják is saját működésüket. (Bhavikatta) Ezzel megvalósul az önoptimalizáló logisztikai hálózatok koncepciója, ahol a mesterséges intelligencia nem csupán támogató, hanem irányító szerepet tölt be. A kutatások szerint e rendszerek segítségével akár 25–30 %-os hatékonyságnövekedés is elérhető a szállítási idő és a költségek tekintetében. (Ivanov)

Fontos megjegyezni, hogy a mesterséges intelligencia a logisztikai innováció kulestényezője marad a következő évtizedben is, de valódi versenyelőnyt csak azok a vállalatok fognak elérni, amelyek képesek lesznek a technológiát stratégiai szinten integrálni. A logisztikai MI-rendszerek fejlesztése nem kizárólag technológiai kérdés, hanem szervezeti kultúrát, képzést és átlátható döntéshozatali struktúrát igényel. Az MI-vezérelt logisztika sikere tehát azon múlik, hogy a vállalatok képesek-e a technológiát az emberi tudással és felelősséggel ötvözni, kialakítva ezzel egy fenntartható és etikus, ugyanakkor hatékony ellátási láncot. (Floridi)

A mesterséges intelligencia alapvetően alakítja át a logisztikai ágazatot, új dimenziót adva az adatvezérelt és automatizált működésnek. Az MI nem csupán a hatékonyságot növeli, hanem lehetővé teszi a prediktív és adaptív működést, amely a modern gazdasági környezetben versenyelőnyt biztosít a vállalatoknak. A technológia fejlődése új lehetőségeket nyit a logisztikai innováció, a fenntarthatóság és a humán-technológiai együttműködés területén is.

3. Probléma elemzés

A logisztikai és ellátási lánc menedzsment egyik legfontosabb stratégiai feladata a készletgazdálkodás és a rendelésfeldolgozás hatékonyságának biztosítása. A globalizált gazdasági környezetben a vállalatok egyre nagyobb kihívásokkal szembesülnek a kereslet gyors változása, az ellátási láncok komplexitása, valamint az adatáramlás és a munkaerőhiány problémái miatt. A probléma központi eleme, hogy a legtöbb vállalat még mindig olyan hagyományos logisztikai modelleket alkalmaz, amelyek nem képesek megfelelően kezelni a 21. századi gazdaság dinamikáját. Ennek következménye a készletek túlzott felhalmozása, a rendelésfeldolgozási hibák növekedése, valamint a szállítási idők meghosszabbodása, ami a vevői elégedettség és a versenyképesség csökkenéséhez vezet. (Ivanov)

A probléma gyökere gyakran az információkezelés és az adatelemzés hiányosságaiban keresendő. A hagyományos logisztikai rendszerekben a döntések sokszor részleges vagy szigetszerű adatokra épülnek, amelyek nem tükrözik pontosan az egész ellátási lánc állapotát. Ez a fragmentált adatkezelés és az integrált rendszerek hiánya hozzájárulhat a hibás készlet- és rendelési döntésekhez, mivel a vállalatok nem képesek valós időben reagálni a kereslet változásaira vagy a szállítási késésekre. A modern, adatvezérelt rendszerek azonban lehetővé teszik, hogy a vállalatok gyorsabban és pontosabban reagáljanak a logisztikai kihívásokra. (Ivanov)

A hagyományos készletkezelési modellek, mint például az EOQ vagy a reorder point elmélet, determinisztikus feltételezésekre épülnek, hiszen állandó keresletet, fix szállítási időt és megbízható beszállítókat feltételeznek. A modern, gyorsan változó piaci környezetben azonban ezek az előfeltevések már nem tarthatók. A kereslet ingadozása, az ellátási lánc megszakadásai és a külső sokkok, például a COVID-19 járvány vagy a geopolitikai konfliktusok olyan bizonytalansági tényezőket hoztak be, amelyekre a hagyományos modellek nem adnak megfelelő választ. (Ivanov)

E problémák következtében a vállalatok gyakran kényszerülnek túlkompenzálásra, azaz a biztonsági készletek mesterséges növelésére a kiszolgálás biztosítása érdekében. Ez azonban tőkét köt le, növeli a raktározási költségeket, és rontja a készletforgási mutatókat. A raktárakban a helyhiány és a készletmozgások átláthatatlansága tovább fokozza a problémát. A kutatások szerint a vállalatok akár 20–30 %-kal is több készletet tartanak, mint amennyi a tényleges piaci igény kielégítéséhez szükséges lenne. (Choi) Ezzel párhuzamosan nő a kiszállítási idő és a hibaarány, ami a logisztikai költségek és a vevői elégedetlenség növekedéséhez vezet.

A rendelésfeldolgozás területén a legnagyobb kihívást a valós idejű információáramlás hiánya és az emberi beavatkozásból eredő hibák jelentik. Az adatok kézi rögzítése, az elavult WMS-rendszerek és az információs szigetek mind növelik az átfutási időt és a hibák valószínűségét. A problémát tovább súlyosbítja, hogy a rendeléskezelési folyamatok gyakran több, egymással nem kommunikáló informatikai platformon zajlanak, így az adatduplikációk és a verzióeltérések mindennaposak. (Fakhrai Rad)

A vállalatok számára az is komoly problémát jelent, hogy a keresletingadozásokhoz és piaci sokkokhoz való alkalmazkodás nem megfelelően támogatott a jelenlegi rendszerekben. A mesterséges intelligencia mentes logisztikai hálózatok nem képesek dinamikus kapacitáselosztásra vagy automatizált előrejelzésre, így a vállalatok gyakran csak reaktívan, a problémák bekövetkezése után reagálnak. Ez az úgynevezett „tűzoltás” jellegű logisztikai működés hosszú távon versenyhátrányhoz vezet, különösen az e-kereskedelem és gyorskereskedelmi láncok piacán, ahol az azonnali szállítási elvárás a normává vált. (Teixeira)

A probléma tehát nem csupán technológiai, hanem stratégiai és szervezeti is. A logisztikai folyamatok digitalizációja gyakran szigetszerűen, koordináció nélkül történik, így az informatikai fejlesztések nem hoznak szinergikus hatást. Sok esetben a dolgozók nem rendelkeznek megfelelő digitális kompetenciákkal, ami megnehezíti az új rendszerek bevezetését és működtetését. A változásmenedzsment hiánya miatt a szervezetek ellenállása is erős, különösen akkor, ha a mesterséges intelligencia bevezetése munkahelyi bizonytalanságot kelt. (Ghobakhloo)

Egy másik jelentős probléma az adatminőség kérdése. A mesterséges intelligencia rendszerek működése az adatok pontosságán és teljességén alapul. Ha az alapadatok hibásak, hiányosak vagy elavultak, az MI által generált döntések is tévesek lehetnek. A hibás adatbevitel, a nem egységes kódolási rendszerek és a manuális nyilvántartások mind torzítják az elemzéseket és előrejelzéseket. A vállalatok sokszor nincsenek tisztában azzal, hogy az adatminőség menedzsmentje éppoly kritikus, mint maga az algoritmus fejlesztése. (Kshetri)

A problémakör mélyebb megértéséhez elengedhetetlen annak vizsgálata is, hogy a készletgazdálkodásban és rendelésfeldolgozásban jelentkező hibák milyen gazdasági és társadalmi következményekkel járnak. A hatékonyság hiánya nemcsak közvetlenül érinti a vállalati profitabilitást, hanem közvetett módon befolyásolja az ellátási lánc egészének stabilitását is. A COVID-19 világjárvány rávilágított arra, hogy a globális ellátási hálózatok mennyire sérülékenyek, ha az információáramlás és a készletmenedzsment rendszerek nem megfelelően integráltak. A kereslet hirtelen megugrása, az alapanyaghiány és a szállítási

késések példátlan zavarokat okoztak, amelyek a vállalatokat arra kényszerítették, hogy újragondolják készletstratégiáikat. (Ivanov) E válsághelyzet rámutatott arra is, hogy a digitalizálatlan rendszerek képtelenek voltak gyorsan reagálni a változásokra, ami a gazdasági veszteségek mellett társadalmi szinten is érezhető hatásokat eredményezett, például a munkanélküliség növekedését és a fogyasztói bizalom csökkenését.

A problémák másik dimenziója a fenntarthatósággal és környezeti hatásokkal kapcsolatos. A túlkészletezés, a nem optimalizált szállítás és a hibás logisztikai döntések jelentős energia és erőforrás-pazarlást eredményeznek. A kutatások szerint a logisztikai ágazat felelős a globális szén-dioxid-kibocsátás mintegy 11 %-áért, amelynek jelentős része a felesleges készletmozgatásokból és a nem hatékony útvonaltervezésből származik. (Chen) Amikor egy vállalat nem rendelkezik megfelelő adatbázis vezérelt döntéstámogató rendszerrel, akkor hajlamos redundáns fuvarokat indítani, ami nemcsak költségnövelő tényező, hanem ökológiai szempontból is kedvezőtlen. Ezzel szemben a mesterséges intelligencia alapú logisztikai modellek képesek lennének a szállítási folyamatokat és készletmozgásokat optimalizálni, ezáltal a gazdasági hatékonyság és a fenntarthatóság közötti egyensúlyt is megteremteni.

A jelenlegi logisztikai rendszerek további gyengesége, hogy a döntéshozatal gyakran ad hoc jellegű, és hiányzik a prediktív szemlélet. A vállalatok többsége még mindig múltbeli adatokat használ, anélkül, hogy azokból előrejelzéseket vagy modellezett forgatókönyveket készítené. Ez a reaktív működési mód különösen veszélyes a kiszámíthatatlan piaci környezetben, ahol a kereslet-kínálat egyensúlya pillanatok alatt felborulhat. (Fosso Wamba) A mesterséges intelligencia alkalmazása éppen ebben a pontban kínál megoldást, mivel képes a valós idejű adatok elemzésével előre jelezni a potenciális zavarokat. Az MI hiányában azonban a döntéshozók sok esetben túl későn reagálnak, így a veszteségek elkerülhetetlenek. Ebből következik, hogy a probléma gyökere nemcsak technológiai, hanem szemléletbeli is, hiszen az adatalapú, prediktív gondolkodás hiánya a logisztikai döntéshozatal egyik legnagyobb akadálya.

A problémaelemzés tehát nem csupán a logisztikai folyamatokban rejlő technikai hiányosságokra mutat rá, hanem arra is, hogy a vállalatoknak rendszerszinten kell újragondolniuk működésüket. Az adatintegráció, a fenntarthatóság, a humán kompetenciák fejlesztése és a mesterséges intelligencia bevezetése közötti egyensúly megteremtése nélkül a logisztikai rendszerek továbbra is fragmentáltak és sérülékenyek maradnak. Ebből következik, hogy a problémák megoldásához nem elégséges a meglévő folyamatok digitalizálása, hiszen

szükség van egy átfogó, adaptív stratégiai szemlélet kialakítására, amely az MI-t nem eszközként, hanem a logisztikai gondolkodás új paradigmájaként kezeli. (Floridi)

A probléma többdimenziós, mert technológiai, szervezeti, stratégiai és humán tényezők egyaránt közrejátszanak abban, hogy a logisztikai vállalatok nem képesek hatékonyan reagálni a piaci változásokra. Az elavult készletgazdálkodási és rendelésfeldolgozási modellek, a gyenge adatminőség, a fragmentált informatikai infrastruktúra és a hiányos digitális kompetenciák együttesen hozzák létre azt a működési környezetet, amelyben a hatékonyság növelése csak a mesterséges intelligencia bevonásával válik lehetségessé.

3.1. Hagyományos készletkezelési modellek korlátai

A készletgazdálkodás a vállalati logisztika egyik legfontosabb területe, amelynek célja, hogy a kereslet kielégítése a lehető legkisebb költség mellett valósuljon meg. A hagyományos készletkezelési modellek, mint az Economic Order Quantity (EOQ), a reorder point (ROP) vagy a Just-in-Time (JIT) rendszer, évtizedeken keresztül szolgáltak a vállalatok alapvető eszközeként a készletek optimalizálásában. Ezek a modellek azonban a 20. század ipari környezetében születtek, és olyan gazdasági feltételezésekre épültek, amelyek a mai globális, digitalizált és gyorsan változó piacokon már nem érvényesek. (Silver) Az elmúlt évtizedek tapasztalatai világosan mutatják, hogy e modellek alkalmazása számos korláttal és hiányossággal jár, amelyek gátolják a logisztikai rendszerek agilitását és hatékonyságát.

A Just-in-Time (JIT) rendszer, amelyet a japán autóipar tett világszerte ismertté, a készletek minimális szinten tartására törekszik, miközben a gyártást és az ellátást szorosan összehangolja. A JIT alapelve szerint a készletek csak akkor érkeznek, amikor azokra ténylegesen szükség van, így a tárolási költségek minimálisra csökkennek. Ez a megközelítés azonban rendkívül érzékeny a külső zavarokra. A COVID-19 járvány idején a JIT rendszerek különösen sebezhetőnek bizonyultak, mivel a legkisebb beszállítói késés is az egész termelési lánc leállítását eredményezhette. (Ivanov)

A hagyományos készletgazdálkodási modellek további korlátja, hogy nem képesek integrálni a valós idejű adatokat. A digitális korszakban az ellátási láncok működése egyre inkább adatvezérelté válik, azonban a klasszikus modellek matematikai egyenletekre és statikus paraméterekre épülnek. Ez azt jelenti, hogy a döntéshozatal gyakran a múltbeli adatokon alapul, amelyek nem tükrözik pontosan az aktuális piaci helyzetet. (Choi) Az adatforrások sokasága, mint például az RFID, IoT-szenzorok vagy online rendelési platformok, lehetővé tenné a valós idejű elemzést, ám a hagyományos modellek nem képesek ezeket a dinamikus információkat feldolgozni.

A modellparaméterek pontatlansága szintén jelentős problémát jelent. Az EOQ és ROP modellek érzékenyek az olyan inputokra, mint a kereslet szórása, a szállítási idő variabilitása és a rendelési költségek. Ha ezek az adatok hibásak vagy becslésen alapulnak, az egész modellpredikció érvényét veszti. A kutatások szerint a hibás paraméterbecslés akár 15–25 %-os többletköltséget is okozhat a készletgazdálkodásban. (Teixeira)

Ezen modellek egyik legnagyobb hátránya a prediktív képesség hiánya. A hagyományos megközelítések kizárólag az aktuális vagy múltbeli készletszintekre reagálnak, és nem képesek

előre jelezni a kereslet várható alakulását. A modern logisztikai rendszerek ezzel szemben egyre inkább a mesterséges intelligenciára és a gépi tanulásra építenek, amelyek képesek felismerni az adatmintázatokat, és előrejelzéseket készíteni a jövőbeli igényekről. (Fosso Wamba) A hagyományos modellek statikus logikája ezért versenyhátrányt eredményez, mivel a vállalatok nem tudják időben optimalizálni a készletszinteket vagy a rendelési mennyiségeket.

További probléma, hogy a klasszikus modellek nem veszik figyelembe az ellátási lánc hálózatos szerkezetét. Az EOQ és ROP modellek tipikusan egyvállalatos szemléletre épülnek, miközben a modern gazdasági környezetben a vállalatok több szinten, egymással összekapcsolt hálózatban működnek. Egy beszállító késése vagy egy szállítási zavar az egész láncra kihat, amit a lineáris modellek nem tudnak leképezni. (Ivanov)

A hagyományos modellekben a kockázatkezelés is alulértékelt. Az EOQ vagy ROP megközelítések feltételezik a stabil működési környezetet, miközben a valóságban a vállalatok folyamatosan kockázatokkal szembesülnek, beszállítói késésekkel, minőségi problémákkal, logisztikai fennakadásokkal vagy keresleti sokkokkal. Az ilyen események hatását a modellek nem képesek figyelembe venni, mivel azok determinisztikus logikát követnek. A modern, kockázatalapú logisztikai menedzsment ezzel szemben a bizonytalanságot explicit módon integrálja a döntéshozatalba, például sztochasztikus vagy robusztus modellezési módszerekkel. (Dmitry Ivanov)

3.2.Keresletingadozás és bizonytalanság a modern ellátási láncokban

A keresletingadozás és az ellátási láncban megjelenő bizonytalanság a logisztikai rendszerek egyik legkritikusabb kihívása. A vállalatok működését egyre inkább a kiszámíthatatlan gazdasági, társadalmi és technológiai tényezők befolyásolják, amelyek közvetlenül hatnak a kereslet volumenére, időzítésére és földrajzi megoszlására. A keresletingadozás lényegében azt a jelenséget írja le, amikor a fogyasztói igények mennyisége és szerkezete időben változik, gyakran előre nem jelezhető módon. A bizonytalanság ezzel szorosan összefügg, mivel az ellátási lánc szereplői nem rendelkeznek teljes információval a piac állapotáról, a beszállítók teljesítményéről vagy a logisztikai feltételekről. (Chopra) A modern vállalatok számára e két tényező együttesen olyan kockázati tényezőt jelent, amely közvetlenül befolyásolja a készletszintet, a költségeket és a szolgáltatási szintet.

A keresletingadozás okai sokrétűek. Egyes esetekben a szezonális változások, például karácsonyi vagy iskolakezdési időszakok idézik elő az igények növekedését, míg máskor a marketingkampányok, árváltozások vagy piaci trendek váltanak ki rövid távú keresleti hullámokat. Emellett a globális gazdasági bizonytalanság, például az infláció, a valutaingadozások vagy a geopolitikai események, is komoly hatással van a fogyasztói magatartásra. (Ivanov) Az utóbbi években a digitalizáció és az e-kereskedelem terjedése tovább növelte a keresletingadozás amplitúdóját, hiszen a fogyasztók azonnali kiszolgálást várnak el, miközben a vásárlási döntéseik egyre impulzívabbá váltak.

A bizonytalanság a logisztikai folyamatok minden szintjén megjelenik. A beszállítói bizonytalanság például a szállítási idők, a minőség és a teljesítési arány kiszámíthatatlanságából fakad. A piaci bizonytalanság a kereslet előrejelzésének nehézségéből, míg az operatív bizonytalanság a belső folyamatok, például termelési leállások, géphibák, humán tényezők, instabilitásából adódik. A COVID–19 járvány drámai példája annak, hogy e tényezők egyszerre is felléphetnek, súlyos zavarokat okozva az ellátási lánc működésében. A vállalatok egyik napról a másikra szembesültek azzal, hogy a kereslet szerkezete radikálisan megváltozik, míg egyes termékek iránti kereslet megszűnt, más termékeké ugrásszerűen megnőtt. (Ivanov)

A keresletingadozás kezelésében kulcsfontosságú a rugalmasság és az adaptivitás. A vállalatoknak képesnek kell lenniük arra, hogy a kereslet változásaira gyorsan reagáljanak, akár a termelési ütemezés, akár a rendelési mennyiségek vagy a szállítási útvonalak módosításával. A hagyományos, hierarchikus döntéshozatali struktúrák azonban gyakran gátolják a gyors reagálást. Ezzel szemben a modern, adatalapú logisztikai rendszerek, amelyek valós idejű

információkra támaszkodnak, lehetővé teszik a dinamikus készletelosztást és a prediktív döntéshozatalt. (Fosso Wamba)

A bullwhip-effektus, vagyis az ellátási lánc mentén felerősödő keresletingadozás, szintén jól szemlélteti a bizonytalanság problémáját. Amikor egy vállalat a kereslet kis változására túlzottan reagál, például nagyobb rendelési mennyiséget ad le, a lánc következő szereplői is hasonlóan reagálnak, ami lavinaszerű torzulást okoz a készletszintekben. A bullwhip-effektus következtében a készletek túlzottan felhalmozódnak, miközben a valós kereslethez képest túltermelés vagy készlethiány is kialakulhat. (Lee) A probléma oka a láncszintű információhiány, illetve a kereslet-előrejelzések decentralizált, nem egységes kezelése. A modern informatikai rendszerek, például az integrált ERP és MI-alapú előrejelző modellek, képesek csökkenteni e torzulást azáltal, hogy a teljes láncra kiterjedő, valós idejű adatelemzést biztosítanak.

A prediktív analitika a keresletingadozás kezelésének egyik legfejlettebb formája. A valós idejű adatok, például online értékesítési adatok, szenzoradatok, közösségi média-elemzések elemzésével a vállalatok képesek előre jelezni a kereslet rövid távú változásait. Az MI-rendszerek emellett képesek automatikusan újrapalibrálni az előrejelzéseket, amikor a piaci feltételek megváltoznak. Ez az adaptív tanulás lehetővé teszi, hogy a készletszintek dinamikusan igazodjanak az aktuális igényekhez, minimalizálva a készlethiány és a túltermelés kockázatát. (Fakhrai Rad)

A bizonytalanság kezelése szempontjából egyre nagyobb hangsúlyt kap a kockázatmegosztás és az együttműködés az ellátási lánc szereplői között. Az együttműködő előrejelzési modellek (Collaborative Planning, Forecasting and Replenishment) CPFR célja, hogy a beszállítók, gyártók és forgalmazók közösen alakítsák ki a keresleti terveket és a készletstratégiákat. Az adatok megosztása és a közös döntéshozatal jelentősen csökkenti a bizonytalanságot, mivel minden szereplő ugyanarra az információra építi előrejelzéseit. A CPFR rendszerek hatékonyságát tovább növelheti a mesterséges intelligencia integrálása, amely képes az együttműködési minták folyamatos elemzésére és optimalizálására.

A vállalatok egy másik válasza a bizonytalanságra a rugalmas kapacitásmenedzsment. Ez a megközelítés lehetővé teszi, hogy a gyártó és raktárkapacitásokat gyorsan átcsoportosítsák a kereslet függvényében. A „flexible manufacturing systems” és az „on-demand logistics” koncepciók célja, hogy a termelés és a logisztika szorosan illeszkedjen a piaci igényekhez, miközben minimalizálja az erőforrás-pazarlást. (Wenwen Chen) Az MI-t alkalmazó rendszerek

valós időben képesek értékelni a kapacitás kihasználtságot, előre jelezni a szűk keresztmetszeteket, és optimalizálni a termelési ütemezést.

A keresletingadozás és bizonytalanság kezelésében nemcsak a technológiai, hanem a szervezeti kultúra is meghatározó. Az adatalapú döntéshozatalhoz bizalomra és átláthatóságra van szükség az ellátási lánc minden szintjén. A vállalatoknak olyan szervezeti struktúrát kell kialakítaniuk, amely elősegíti a tudásmegosztást, az interdiszciplináris együttműködést és a gyors döntéshozatalt. Azok a cégek, amelyek az adatokat stratégiai erőforrásként kezelik, képesek proaktívan reagálni a piaci változásokra, és versenyelőnyt szereznek azokkal szemben, akik továbbra is reaktív módon működnek.

Elmondható, hogy a keresletingadozás és bizonytalanság a logisztikai folyamatok állandó velejárói, amelyeket nem lehet teljesen kiküszöbölni, de kezelni igen. A hagyományos statikus modellek korlátai miatt a vállalatoknak olyan dinamikus, tanuló rendszerekre van szükségük, amelyek képesek a valós idejű adatok elemzésére, a kockázatok előrejelzésére és a gyors alkalmazkodásra.

4. Kutatás

A szakdolgozat elkészítése során azt szerettem volna megvizsgálni, hogy a mesterséges intelligencia alapú, adat vezérelt módszerek mennyiben tudnak jobb előrejelzést adni a készletgazdálkodásban, mint azok a hagyományos technikák, amelyeket ma még rengeteg vállalat alkalmaz. Úgy éreztem, hogy ez különösen azért érdekes kérdés, mert sok magyar cég továbbra is egyszerű Excel-táblákban vezeti a keresleti adatokat, és jellemzően a legutóbbi néhány hónap átlagát veszi alapul a döntéseknél. A dolgozat célja az, hogy bemutassa, hogy egy nagyon egyszerű, könnyen elsajátítható statisztikai modell is képes átlépni ezeket a korlátokat, és sokkal stabilabb, megbízhatóbb előrejelzést tud adni.

A kutatás alapját két terület adja. Az egyik a szakirodalom áttekintése, ahol igyekeztem feltérképezni, hogy a klasszikus készletgazdálkodási elméletek milyen feltételezésekből indultak ki, és ezek miért nem működnek jól a mai, ingadozó és gyorsan változó környezetben. A legtöbb hagyományos modell még abból indul ki, hogy a kereslet viszonylag állandó és kiszámítható, de ezt a feltételezést a modern ellátási láncok már egyre ritkábban tudják biztosítani. Sok kutatás rámutat arra, hogy az adat vezérelt előrejelzési technikák jóval pontosabban tudják kezelni a volatilitást, és gyakran már kis adatmennyiségnél is érezhető javulást hoznak.

A kutatás második pillére egy saját szimulációs modell volt, amelyet azért készítettem el, hogy gyakorlatban is láthatóvá váljanak ezek a különbségek. A célom az volt, hogy egy interaktív felületen keresztül mutassam be, hogyan működik a mozgóátlag és a lineáris regresszió, és a két módszer milyen előrejelzést ad arra az idősorra, amelyet alapértelmezésként beállítottam. Azért választottam egy enyhén emelkedő trendű keresleti sort, mert a valóságban ez az egyik leggyakoribb eset.

A szimuláció lehetőséget ad arra, hogy a felhasználó bármikor átírja az adatokat, és kipróbáljon különféle forgatókönyveket. Így könnyen megérthető, hogy a mozgóátlag miért esik szét akkor, amikor a keresletben erősebb növekedés vagy éppen nagyobb véletlenszerű ingadozás jelenik meg. A regresszió ezzel szemben képes követni a hosszabb távú mintázatokat, és stabilabb előrejelzést ad. A két módszert több szempontból is összehasonlítottam, például az abszolút és relatív hibák alapján, valamint megvizsgálom, hogy hogyan alakul a rendelési pont és a biztonsági készlet azokkal a paraméterekkel, amelyeket valós vállalati gyakorlatból vettem.

A kutatás során három kérdésre kerestem választ. Arra voltam kíváncsi, hogy a lineáris regresszió előrejelző ereje mennyire múlja felül a mozgóátlagot ugyanazon idősoron. Emellett

azt is meg akartam nézni, hogy az előrejelzési hiba csökkenése milyen hatással van a rendelési pontra és ezzel együtt a készlettartási költségre. Arra is szerettem volna következtetéseket levonni, hogy a mesterséges intelligencia alapú gondolkodás milyen szintű technológiai belépőt jelent egy hallgató vagy egy kisebb vállalkozás számára.

A mesterséges intelligencia alkalmazása a készletgazdálkodásban nem csak elméleti kérdés, hanem nagyon is gyakorlati dolog, amit már ma is el lehet kezdeni egy cégnél. A szakirodalomban olvasott példák közül sokszor azok tetszettek a legjobban, ahol nem valami óriási, többmilliós rendszert vezettek be, hanem egyszerűbb gépi tanulási modellekkel indultak, és már azzal is rengeteget spóroltak. A gyakorlatban a mesterséges intelligencia legnagyobb előnye, hogy képes tanulni az adatokból, és nem csak visszanéz a múltba, mint a mozgóátlag, hanem próbál mintázatokot találni. Egy egyszerű regresszióval máris látható, hogy ha van trend, szezonális vagy valamilyen rendszeresség, akkor azonnal jobb előrejelzést ad. A saját szimulációmban ez pontosan így jött ki, hogy amikor trend van, a regresszió 70-80%-kal kisebb hibát csinál, és ezzel együtt a rendelési pont is alacsonyabb lesz.

A másik nagy dolog, amit a szakirodalomból is olvastam, hogy az MI segít csökkenteni a bizonytalanságot. A hagyományos módszerekkel mindig nagy biztonsági készletet kell tartani, mert a hiba nagy, és nem akarunk készlethiányt. A regresszióval a hiba sokkal kisebb, ezért a biztonsági készlet is lecsökken, és ugyanazzal a 95%-os szolgáltatási szinttel is bátrabban lehet lenni. Ez különösen ott fontos, ahol drága a termék vagy nagy a helyigénye a raktárban, gondoljunk csak egy elektronikai cikkre vagy egy divatárura, ahol a szezon végén már nem kell annyi.

Azt is észrevettem, hogy a modell könnyen bővíthető lenne valós vállalati használatra. Például, ha valaki Excelből importál adatokat, vagy összeköti egy ERP-vel, akkor automatikusan frissülhetne minden hónapban. Sőt, ha valaki egy kicsit továbbmegy, akkor súlyozott mozgóátlagot vagy akár exponenciális simítást is bele lehet tenni, és máris még pontosabb lesz.

A mesterséges intelligencia egy olyan eszköz, amit okosan kell használni. A szakirodalom és a saját modell is azt mutatja, hogy már az egyszerűbb megoldásokkal is óriási lépést lehet tenni előre, és a készletgazdálkodás sokkal hatékonyabbá, rugalmasabbá válik.

4.1. Modell és módszertan

A kutatás módszertani alapját az a kérdés adta, hogy miként lehet összehasonlíthatóvá tenni két olyan előrejelzési megközelítést, amelyek teljesen eltérő módon közelítik meg ugyanazt a problémát. A hagyományos készletgazdálkodás jellemzően a korábbi időszakok átlagos keresletére épül, ami alapvetően statikus és visszatekintő szemléletet képvisel. Ezzel szemben az adatvezérelt modellek, például lineáris regressziós megoldások is képesek felismerni bizonyos mintázatokat.

A modell kialakításánál fontos szempont volt, hogy egy olyan keretet hozzak létre, amely egyszerre szemléletes, könnyen követhető, ugyanakkor elég rugalmas ahhoz, hogy különböző keresleti mintázatok is vizsgálhatók legyenek. Bár a vállalatok valós adatai sok szempontból bonyolultabbak, a kutatás során mégis szintetikus, előre meghatározott idősorral dolgoztam. Ennek az volt az oka, hogy így sokkal jobban ellenőrizhetővé vált, hogy egy-egy modell milyen hatással van az előrejelzés minőségére. A meghatározott keresleti sor egy fokozatosan növekvő trendet követ, ami gyakran előfordul azoknál a termékeknél, amelyek lassan, de stabilan népszerűbbé válnak, vagy amelyeknél szezonális hatások nélkül is megfigyelhető valamilyen szerkezeti növekedés.

A módszertan egyik lényeges eleme az volt, hogy a vizsgálat során két olyan előrejelzési megközelítés is elemzésre került, amelyek közül az egyik a hagyományos logisztikai gyakorlatot, a másik pedig az adatvezérelt szemléletet képviselte. A három hónapos mozgóátlag azért került a modellbe, mert a legtöbb vállalat még ma is használ ehhez hasonló egyszerű átlagszámítási módszert, mivel gyors, könnyen érthető és nem igényel speciális tudást. Emellett az is szerepet játszott a választásban, hogy a mozgóátlag jó eszköz a rövid távú ingadozások kisimítására, ugyanakkor éppen emiatt lassan reagál azokra a folyamatokra, amelyek a kereslet mélyebb változásaira utalnak.

A másik vizsgált modell a lineáris regresszió volt, amely az egyik legegyszerűbb statisztikai közelítésnek számít, mégis jelentős szerepe van az előrejelzésben. A regresszió kiválasztása azért volt releváns, mert jól szemlélteti a különbséget a statikus és a dinamikus gondolkodás között. Míg a mozgóátlag kizárólag a múlt három adatából indul ki, addig a regresszió a teljes idősor trendjét próbálja megragadni, és ebből készít előrejelzést. Ezáltal sokkal érzékenyebb a hosszabb távú változásokra, és a növekedő vagy csökkenő pályákat is figyelembe veszi.

A két modell összehasonlíthatósága érdekében egységes értékelési mutatókat használtam. Az előrejelzési hibák méréséhez két olyan mutatót választottam, amelyeket a szakirodalomban is

gyakran alkalmaznak. Az egyik a mean absolute error volt, ami azt mutatja meg, hogy az előrejelzés átlagosan mekkora eltérést mutat a valós értékektől. A másik a mean absolute percentage error, amely a relatív hibát méri, vagyis azt fejezi ki, hogy a becslés átlagosan hány százalékkal tér el a tényleges kereslettől. Ezeket a mutatókat azért tartottam különösen alkalmasnak a modell értékelésére, mert jól kifejezik a két módszer különbségét a gyakorlat szempontjából is. Egy logisztikai döntéshozó számára ugyanis az a legfontosabb kérdés, hogy a választott előrejelzési technika mennyire támogatja a megfelelő mennyiségű készlet fenntartását anélkül, hogy túlzott készlettartási költségek jelennének meg.


A módszertani keretrendszer része volt az is, hogy az előrejelzési pontosság közvetlenül befolyásolja a rendelési pont meghatározását. A kutatás során ezért külön kiszámítottam, hogy hogyan alakul a rendelési pont a különböző modellek esetén, amikor a szolgáltatási szintet kilencvenöt százalékos értéken tartottam. A rendelési pont számítása során a keresleti átlag mellett hozzáadtam azt a biztonsági készletet, amelyet az előrejelzési hiba szorozva a normális eloszlás megfelelő szórásával ad meg. Így a rendelési pontot nem egy intuitív becslés, hanem egy objektív, adattal alátámasztott érték szabja meg. Ez lehetővé tette, hogy kimutathatóvá váljon a két modell közötti különbség nemcsak az előrejelzés, hanem a készletgazdálkodási döntések szintjén is.

A modell gyakorlati megvalósítása interaktív formában történt, mert úgy gondoltam, hogy ez sokkal átélhetőbbé teszi a különbségek jelentését. Egy egyszerűen megnyitható HTML-alapú felületet hoztam létre, amelyben a keresleti adatokat bármikor át lehet írni, és azonnal láthatóvá válik, hogyan módosulnak az előrejelzések és a készletmutatók. Az ilyen típusú tesztelés nagy előnye, hogy megmutatja, milyen érzékenyek a különböző modellek a hirtelen változásokra, például egy váratlan keresleti megugrásra vagy visszaesésre. Ez segített annak megértésében, hogy a hagyományos módszerek miért reagálnak lassabban, míg az adatvezérelt megközelítés stabilabb és előre tekintőbb működést tesz lehetővé.

A modell működésének értelmezéséhez fontos volt az is, hogy a vizsgálat ne csak egyszerű számításokat tartalmazzon, hanem vizuálisan is bemutassa az előrejelzési különbségeket. A grafikonok szerepe kiemelten fontos volt a módszertan szempontjából, hiszen egy tanulmányban az olvasó sokkal könnyebben látja át a két előrejelzési modell működése közötti eltérést, ha az idősorok, az illesztett regressziós egyenes és a mozgóátlag egyaránt jól követhetők. A vizuális ábrázolás azért is vált a kutatás kulcselemévé, mert egyetlen ábra gyakran többet mond, mint hosszabb matematikai levezetések. A grafikont úgy alakítottam ki, hogy a tényleges keresleti értékek mellett szerepeljen a regressziós modell által becsült illesztett

érték is, valamint az a pont, amely a tizenharmadik hónap előrejelzését mutatja. Ez lehetővé tette, hogy a különbségek már első ránézésre egyértelműek legyenek.

1. ábra A tényleges kereslet, a regressziós illesztés és a mozgóátlag összehasonlítása



Forrás: saját szerkesztés

A kutatás gyakorlati oldala szintén fontos része volt a módszertani fejezetnek. Amikor egy ilyen szimuláció elkészül, az a cél, hogy a felhasználó ne csak betekintést kapjon az egyes előrejelzések működésébe, hanem maga is képes legyen kipróbálni különböző keresleti forgatókönyveket. Ezért építettem be a modellszoftverbe azt a lehetőséget, hogy a keresleti adatokat kézzel módosítani lehessen. Ez a funkció azért volt hasznos, mert megmutatja, hogy a modellek mennyire stabilan működnek, amikor a kereslet eltér a trendtől. A valós vállalati működésben ugyanis gyakran előfordul, hogy a kereslet egy-egy hónapra hirtelen kiugrik vagy visszaesik, például egy marketingkampány, egy készlethiány vagy valamilyen külső piaci hatás következtében. A szimuláció ezért alkalmas arra, hogy az ilyen helyzeteket reprodukálja, és egyúttal megmutassa, miként reagálnak a különböző előrejelzési módszerek.

A modell működésének másik fontos része az volt, hogy a rendelési pont számítását is valós időben megjelenítettem. Ez a gyakorlati működés egyik legkényesebb területe, mivel a rendelési pont meghatározása közvetlenül határozza meg az optimális készletszintet és azt, hogy mekkora tartalékkészlet szükséges ahhoz, hogy a vállalat elkerülje a készlethiányt. A modellbe épített rendelési pont számítás éppen ezért azt a célt szolgálta, hogy megmutassa, milyen jelentős hatása lehet a választott előrejelzési módszer hibájának a készletezési döntésekre.

A módszertani részhez tartozott az is, hogy reflektáljak arra, milyen korlátai vannak a választott megközelítésnek. A vizsgálat szándékosan egyszerűsített környezetben történt, mert így lehetett

a legjobban elkülöníteni és összehasonlítani a két előrejelzési módszert. Egy vállalat valós készletmodellje ennél jóval összetettebb, mivel több termék, több beszállító, különböző szállítási idők és eltérő keresleti mintázatok jellemzik. A jelen kutatás célja azonban nem az volt, hogy egy teljes vállalati modellt rekonstruáljak, hanem sokkal inkább az, hogy megvizsgáljam, a mesterséges intelligencia egyszerűbb formái hogyan teljesítenek a legelterjedtebb hagyományos módszerekkel szemben.

A szimuláció jelentőségét tovább növelte az, hogy képes volt megmutatni, a regressziós modell milyen mértékben azonosít trendeket az idősorban. Ez azért fontos, mert a trend felismerése az egyik legkritikusabb eleme az előrejelzésnek. Ha a kereslet egyértelmű növekedést mutat, akkor a mozgóátlag lassabban követi ezt a változást, ami kisebb szolgáltatási szintet, nagyobb készlethiányt és akár veszteségeket is okozhat. A regresszió viszont azonnal reagál, mivel a teljes idősor alapján határozza meg a becslést. Ez a különbség jól látszik a hibatáblázatokban is, ahol a regressziós modell általában alacsonyabb MAE és MAPE értékeket produkál. Ez azt jelenti, hogy nem csupán az előrejelzés lesz pontosabb, hanem a belőle számított készletparaméterek is.

Kiemelhető, hogy a módszertan kiválasztásakor az volt a cél, hogy a dolgozat ezen része minél jobban bemutassa a szakirodalomban tárgyalt problémák gyakorlati oldalát. A szakirodalom ismételten hangsúlyozza, hogy a hagyományos készletmodellek sok esetben nem képesek megfelelően reagálni a gyorsan változó keresletre, és gyakran túlzott készlettartást vagy éppen készlethiányt eredményeznek. A szimulációs modell módszertana pontosan ezt a helyzetet hozta közelebb a valósághoz, és lehetővé tette annak bemutatását, hogy még egy egyszerű mesterséges intelligencia alapú megoldás is jelentős előrelépést jelenthet a készletgazdálkodási döntések támogatásában.

4.2. Szimulációs eredmények értékelése

A szimulációs modell alapadataival végzett számítások egyértelműen alátámasztják a kutatás során felállított hipotéziseket, és jól szemléltetik, hogy már egy nagyon egyszerű adatvezérelt módszer is mennyivel hatékonyabb lehet a hagyományos készletgazdálkodási gyakorlatban széles körben alkalmazott mozgóátlagnál. Az alapértelmezett idősor (100, 105, 98, 120, 130, 128, 135, 140, 138, 150, 155, 160 darab/hó) enyhe, de egyértelmű emelkedő trendet mutat, havi átlagos növekedése körülbelül 5,6 darab, amit a lineáris regressziós modell tökéletesen felismert (a meredekség $\beta = 5,61$ darab/hó). Ezzel szemben a háromhónapos mozgóátlag mindig csak a legutóbbi három hónap átlagát adja vissza, ezért folyamatosan lemarad a valós fejlődéstől.

A 13. hónapra vonatkozó előrejelzésnél a mozgóátlag 151 darabos keresletet jósol, míg a regressziós modell 166,3 darabot. A különbség 15,3 darab, ami már önmagában is jelentős egy közepes forgalmú termék esetében. A hibamutatók még látványosabb különbséget mutatnak. A mozgóátlag historikus hibája (4–12. hónap) MAE-ban 12,44 darab, MAPE-ben 9,11 százalék, míg a regressziós modell illesztése az egész idősorra nézve mindössze 3,17 darab átlagos abszolút eltérést és 2,69 százalékos relatív hibát eredményez. Ez azt jelenti, hogy a regressziós modell abszolút hibája 74,5 százalékkal alacsonyabb, mint a mozgóátlagé. Ez a javulás pontosan abból fakad, hogy a regresszió figyelembe veszi az egész idősor trendjét, nem csak a legutóbbi három adatot.

2. ábra Előrejelző és készletmutatók eredményei

Előrejelzési és készletmutatók

Mozgóátlag előrejelzés (13. hónap)	155.0 db
Regressziós előrejelzés (13. hónap)	166.3 db
MAE (mozgóátlag)	12.44 db
MAE (regresszió)	3.17 db
MAPE (mozgóátlag)	9.11 %
MAPE (regresszió)	2.69 %
Rendelési pont 95% (mozgóátlag)	150.4 db
Rendelési pont 95% (regresszió)	135.2 db

Forrás: saját szerkesztés

A készletgazdálkodási következmények még beszédesebbek. Egy hónapos átfutási idő és 95 százalékos szolgáltatási szint mellett a mozgóátlaghoz tartozó rendelési pont 150,5 darab, míg a regressziós modell csak 135,2 darabot igényel. A különbség 15,3 darab, ami azt jelenti, hogy ugyanolyan kiszolgálási biztonság mellett a regressziós előrejelzést használó vállalat átlagosan 15 darabbal kevesebb készletet köt le minden egyes termékből. Ha egy raktárban több száz vagy ezer cikkszám van, ez már több millió forintos tőkekövet megspórolását jelentheti évente, nem beszélve a raktározási és selejtezési költségek csökkenéséről. A biztonsági készlet a mozgóátlagnál 20,5 darab ($12,44 \times 1,65$), a regressziónál pedig csak 5,2 darab ($3,17 \times 1,65$), tehát itt a legnagyobb a különbség, hogy a hagyományos módszer négyszer annyi biztonsági készletet követel meg ugyanahhoz a szolgáltatási szinthez.

A modell interaktív jellege lehetővé tette, hogy különböző forgatókönyveket is teszteljek. Ha erősebb trendet állítok be (pl. az utolsó hónapokat 180, 190, 200-ra módosítom), a regresszió előnye még jobban kijön, hogy a MAE-arány már 80-85 százalékos javulást mutat, a rendelési pont különbsége pedig 25-30 darab fölé megy. Ha viszont teljesen véletlenszerű, trend nélküli adatsort viszek be (pl. minden hónap 130 körül ingadozik ± 15 -tel), akkor a mozgóátlag hibája már csak 10-15 százalékkal nagyobb, mint a regresszióé, tehát ilyen esetben a klasszikus módszer sem teljesít rosszul. Ez pontosan alátámasztja a szakirodalomban is gyakran hangsúlyozott megállapítást, hogy a mozgóátlag stabil, alacsony ingadozású keresletnél még

mindig elfogadható, de bármilyen trend vagy szezonális megjelenésekor azonnal jelentős hibát generál.

A kapott eredmények teljes mértékben igazolják a kutatási hipotéziseket. Már egy nagyon egyszerű, néhány soros regressziós modell is 70-75 százalékkal csökkenti az előrejelzési hibát trendkövető kereslet esetén, és ezzel párhuzamosan 10-15 százalékkal alacsonyabb rendelési pontot tesz lehetővé ugyanazon szolgáltatási szint mellett. Ez közvetlen költségmegtakarítást jelent a készlettartás, a raktározás és a tőkekötés terén, miközben a készlethiány kockázata nem nő. A modell azt is megmutatja, hogy a mesterséges intelligencia nem feltétlenül bonyolult neurális hálót vagy drága szoftvert jelent.

A saját szimulációmban éppen ezt akartam megmutatni, hogy hogyan lehet egy nagyon alap lineáris regresszióval máris jobb döntéseket hozni a rendelési pont és a készletszint tekintetében. A modellben nem csak az előrejelzést számoltam ki, hanem azonnal ki is írtam, hogy hogyan változik a ROP és a biztonsági készlet. Ez azért fontos, mert a gyakorlatban a logisztikusok nem a MAE-val vagy MAPE-vel foglalkoznak elsősorban, hanem azzal, hogy mennyi árut kell rendelni, és mennyit kell tartalékolni. A szimulációban látható, hogy a regresszióval 15 darabbal alacsonyabb a rendelési pont, ami egy termékre vetítve nem tűnik soknak, de ha ezer termék van, az már 15 000 darab, ami egy raktárban már komoly pénz.

A szimuláció interaktív része volt a kedvencem, mert így nem csak én láttam a különbséget, hanem bárki ki tudja próbálni. Ha valaki beír egy erősebb trendet, mondjuk havi 10-15 darabos növekedést, akkor a regresszió hibája még jobban lecsökken, a ROP-különbség pedig 30-40 darab fölé megy. Ha pedig szezonális hatást szimulálok (pl. karácsonyi csúcsot teszek az utolsó hónapokra), akkor a mozgóátlag teljesen elveszti a fonalat, míg a regresszió még mindig próbál egyenesben gondolkodni, de legalább nem marad le ennyire. Persze egy valódi MI-modellben már Holt-Winters vagy ARIMA lenne a helyette, de az egyszerű regresszió is elég volt ahhoz, hogy látható legyen, hogy a trendkövetés mennyire kulcsfontosságú.

A másik nagy tanulság, hogy az optimalizálás nem csak az előrejelzésről szól, hanem arról is, hogy hogyan használjuk fel a hibainformációt. A modellben a biztonsági készletet direkt a MAE-ból számoltam, mert így egyértelműen látszott, hogy a kisebb hiba, akkor kisebb tartalék, így kevesebb költség. Ez a valóságban is így működik, hogyha pontosabb az előrejelzés, akkor bátrabban lehet alacsonyabb készletet tartani, és nem kell félni a készlethiánytól. A szakirodalomban olvastam, hogy egyes cégek ezzel 20-40%-kal csökkentették a készletértéküket, és nálam is hasonló arány jött ki.

A szimulációk másik előnye, hogy segítenek a döntéshozatalban különböző helyzetekben. Például, ha egy cég most váltana át adatvezérelt rendszerre, akkor a modellből azonnal látszik, hogy mennyit spórolhat, és hol éri meg a legjobban. A kisebb cégeknek szerintem pont ilyen egyszerű megoldások kellene, mert nem tudnak milliós szoftvereket venni, de egy ilyen HTML-fájlt bármikor tovább tudnak fejleszteni.

A szimuláció gyakorlati jelentősége abban áll, hogy egyértelműen rávilágít arra, hogy a hazai kis és középvállalatok számára a belépő a mesterséges intelligencia világába nem egy több tízmilliós ERP-modul vagy felhőalapú prediktív analitika, hanem pontosan az ilyen egyszerű, saját fejlesztésű adatvezérelt megoldások bevezetése is segíthet. A modell könnyen bővíthető lenne (pl. exponenciális simítással, súlyozott mozgóátlaggal vagy akár egy egyszerűbb neurális hálózattal), de már ebben a formában is elegendő bizonyítékot szolgáltat arra, hogy a hagyományos módszerek helyett érdemes áttérni az adatvezérelt gondolkodásra. A kapott különbségek (74,5 százalékos hiba-csökkenés, 15 darabbal alacsonyabb ROP) reális, valós vállalati környezetben is megjelenő nagyságrendek, így a modell nem csak elméleti játék, hanem kézzelfogható bizonyíték arra, hogy a mesterséges intelligencia már ma is elérhető és kifizetődő eszköz a magyar logisztikai szektor számára.

5. Összefoglalás

A szakdolgozatom elkészítése során lépésről lépésre alakult ki bennem az a felismerés, hogy a logisztikai rendszerek működésének megértéséhez nem elég a tankönyvekben bemutatott elméleteket ismerni. Az utóbbi években a gyakorlati tapasztalataim is azt mutatták, hogy a vállalatok jelentős része olyan módszerekkel dolgozik, amelyek egy sokkal lassabb és kiszámíthatóbb gazdasági környezetben alakultak ki. Amikor a szakdolgozat témáját kiválasztottam, abból a személyes élményből indultam ki, hogy többször láttam saját szememmel, milyen következményekkel jár, ha egy vállalkozás kizárólag mozgóátlagokra, korlátozott adathalmazokra és régi rutinokra hagyatkozik. Ebből sokszor felesleges készletfelhalmozás, máskor pedig a készlethiány és a késői szállítás alakult ki. Már akkor is foglalkoztatott, hogy vajon mennyire lenne bonyolult ezen javítani egy egyszerűbb, átlátható, ugyanakkor rugalmasabb előrejelzési módszerrel, amely nem igényel drága rendszereket vagy külön szakembert. A célom az lett, hogy bebizonyítsam, egy egyszerű, hallgató számára is megvalósítható modell képes lehet olyan eredményeket adni, amelyek már önmagukban komoly előrelépést jelentenek.

A szakirodalmi áttekintés során hamar kiderült, hogy a logisztikai szakma maga is komoly átalakuláson megy keresztül. A korábban stabilnak hitt folyamatok mára kiszámíthatatlanná váltak. Az ellátási lánc működését olyan tényezők befolyásolják, amelyek néhány évtizeddel ezelőtt még elképzelhetetlenek voltak. A nemzetközi kereskedelem ingadozásai, a járványok hatása, a globális alapanyaghiány, a közlekedési útvonalak hirtelen lezárása, vagy akár a közösségi média által generált hirtelen keresletingadozások mind olyan körülmények, amelyek új szemléletet követelnek. A korábban sokat idézett módszerek, mint az optimális rendelési mennyiség vagy a hagyományos rendelési pontszámítás, sok vállalatnál még mindig meghatározó szerepet töltenek be. Ezek azonban több ponton is feltételezik, hogy a kereslet nagyjából stabil és lassan változó. A valóság ma már ennél jóval összetettebb, ezért egyre többen hangsúlyozzák, hogy az adatalapú előrejelzésekre épülő megközelítések jóval pontosabbak lehetnek.

Ahogy haladtam előre a szakirodalom feldolgozásával, egyre világosabbá vált számomra, hogy a mesterséges intelligencia és az ahhoz kapcsolódó előrejelzési módszerek már messze nem számítanak elérhetetlen technológiának. A legtöbb publikáció azt emelte ki, hogy az MI alapú előrejelzés nem azért pontosabb, mert bonyolultabb, hanem azért, mert az adatok mögötti összefüggéseket más módon közelíti meg. A különféle kutatások eredményei rendre arról számoltak be, hogy az MI alapú előrejelzés húsz harminc százalékkal jobb teljesítményt nyújt,

sőt bizonyos esetekben ennél is többet. Ez bátorított abban, hogy megvizsgáljam, vajon egy egyszerű, lineáris regressziós modell is képes lehet hasonló előnyöket adni egy kisvállalati környezetben.

A saját kutatásomban létrehozott interaktív modell egy olyan eszköz lett, amelyet magam is szívesen láttam volna azoknál a cégeknél, ahol eddig jártam. A szimulációs környezetet úgy alakítottam ki, hogy bárki megértse és könnyen kipróbálhassa. Nem igényel semmilyen különleges informatikai előképzettséget. A modell lényege annak vizsgálata volt, hogy egy mozgóátlagon alapuló előrejelzéshez képest milyen teljesítményt nyújt egy egyszerű, lineáris trendet feltételező regresszió. A teszt adatokat úgy állítottam össze, hogy azok egy valódi vállalkozás működéséhez hasonló mintát mutassanak. A kereslet lassan növekvő trendet követett, amely a valóságban gyakran előfordul, például amikor egy termék népszerűsége fokozatosan emelkedik.

A vizsgálatok alapján azt tapasztaltam, hogy a mozgóátlag a trend követésében lényegesen gyengébbnek bizonyult. A mozgóátlag ugyanis mindig csak a legutóbbi értékeket veszi figyelembe és a kereslet növekedése esetén folyamatosan lemarad. A regresszió ezzel szemben képes volt felismerni az adatok által mutatott irányt. Ennek eredményeként a tizenharmadik hónapra adott előrejelzés jelentősen közelebb állt a várható értékhez. A hibamutatók közötti különbség ezt egyértelműen tükrözte. A regressziós előrejelzés hibája nagyjából háromnegyedével kisebb lett a mozgóátlagos előrejelzéshez képest. Ez olyan mértékű különbség, amellyel a vállalatok jelentős tőkét takaríthatnak meg. A rendelési pont tekintetében a regresszió alkalmazása megmutatta, hogy ugyanazt a szolgáltatási szintet jóval alacsonyabb készletszint mellett is el lehet érni.

A kutatás eredményei ugyanakkor nemcsak az egyszerű modellek előnyeire világítottak rá, hanem arra is, hogy a mesterséges intelligencia nem helyettesíti az adatminőséget. A modell akkor teljesít jól, ha az adatok pontosak és megbízhatóak. A szakirodalom is folyamatosan hangsúlyozta, hogy az MI sikere nem a modell bonyolultságán múlik, hanem azon, hogy milyen minőségű adatokkal dolgozik. Ez azt jelenti, hogy egy vállalat számára sokszor nem a bonyolultabb algoritmusok bevezetése az első lépés, hanem az, hogy stabil, egységes és jól szervezett adatbázist hozzon létre.

A szakdolgozat elkészítése során számos korlátot is azonosítottam. Ezek közé tartozik, hogy a modell egytermékes és egyszintű raktározási környezetet vizsgált. Nem foglalkozott szezonális hatásokkal, extrém kilengésekkel vagy több beszállítóval rendelkező rendszerekkel. Ezzel együtt a modell alapfilozófiája az volt, hogy megmutassa, már a logisztikai digitalizáció legalapvetőbb szintjén

is van lehetőség jelentős teljesítményjavulás elérésére. A cél tehát nem az volt, hogy egy teljes vállalati rendszert modellezzek, hanem hogy elhelyezzem az MI alkalmazhatóságát egy olyan kontextusban, amely valós alternatívát jelent a magyar kis és középvállalkozások számára is.

A szakdolgozat eredményei alapján megfogalmazható az a következtetés, hogy az MI nem olyan technológia, amely csak a legnagyobb vállalatok számára elérhető. Az is igazolást nyert, hogy egy lineáris regresszióhoz hasonló egyszerű adatvezérelt megközelítés is képes olyan pontosságot adni, amely már önmagában érdemi megtakarítást eredményez. A legfontosabb felismerés azonban az, hogy a modern logisztikai rendszerekben a rugalmasság válik a legnagyobb értékévé. Az MI alapú módszerek pedig éppen ezt a rugalmasságot tudják biztosítani. Nem azért, mert tökéletesek, hanem azért, mert képesek alkalmazkodni a környezet változásaihoz.

A szakdolgozat elkészítése során bennem is formálódott az a gondolat, hogy a jövő logisztikai szakembere nem egyszerűen rendszerek üzemeltetését fogja végezni, hanem döntéshozatali helyzetekben kell tudnia mérlegelni az adatokat, felismerni az összefüggéseket, és értelmezni a prediktív modellek eredményeit. A logisztikai informatikus szerepe sokkal inkább egyfajta közvetítő szerep lesz a vállalat és az adat között. A feladat nem csupán az adatok gyűjtése, hanem azok értelmezése és a megfelelő modellek alkalmazása. A dolgozat tapasztalatai alapján számomra egyértelművé vált, hogy a logisztika jövője egyre inkább az adatvezérelt szemléletre épül, amelyben a mesterséges intelligencia nem különleges eszköz lesz, hanem a mindennapi döntések támogatásának természetes része.

A kutatás egyértelműen igazolta, hogy a regresszió pontosabb előrejelzést ad és alacsonyabb készletszint mellett is biztosítható a megfelelő szolgáltatási szint. A digitalizáció és az adatok szerepe pedig ugyanolyan fontos tényezőnek bizonyult, mint maga a modell. A dolgozat készítése közben sokat tanultam a logisztikai rendszerek működéséről, az adatelemzés gyakorlatáról és arról is, hogy a modern technológiai megoldások nem feltétlenül bonyolultságukban, hanem gyakorlati hasznukban rejlik. Bízom benne, hogy a dolgozat hozzájárul ahhoz, hogy a logisztikai szakma is szélesebb körben ismerje fel az egyszerű MI alapú megoldások lehetőségeit, és a későbbiekben további kutatások és fejlesztések is építenek majd ezekre az eredményekre.

Irodalomjegyzék

- Alan Harrison, R. V. (2019). *Logistics Management and Strategy*. Pearson UK.
- António R. Teixeira, . V. (2025). Intelligent Supply Chain Management: A Systematic Literature Review on Artificial Intelligence Contributions. *Information*, 1-40.
- Ballou, R. H. (2004). *Business Logistics/supply Chain Management: Planning, Organizing, and Controlling the Supply Chain*. Pearson/Prentice.
- Bhavikatta, N. B. (2025). AI-Driven Inventory Optimization in Supply Chains: A Comprehensive Review on Reducing Stockouts and Mitigating Overstock Risks. *Journal of Computer Science and Technology Studies*, 1-13.
- Christopher, M. (2005). *Logistics and Supply Chain Management: Creating Value-adding Networks*. Pearson Education.
- David B. Grant, A. T. (2022). *Sustainable Logistics and Supply Chain Management: Principles and Practices for Sustainable Operations and Management*. Kogan Page Publishers.
- Dmitry Ivanov, A. D. (2020). Viability of intertwined supply networks: extending the supply chain resilience angles towards survivability. A position paper motivated by COVID-19 outbreak. *International Journal of Production Research*, 1-12.
- Edward A. Silver, D. F. (1998). *Inventory Management and Production Scheduling*. John Wiley.
- Fakhreddin Fakhrai Rad, P. O. (2025). Adoption of AI-based order picking in warehouse: benefits, challenges, and critical success factors. *Review of Managerial Science*, 3495–3540.
- Florian Kache, S. S. (2017). Challenges and opportunities of digital information at the intersection of Big Data Analytics and supply chain management. *International Journal of Operations & Production Management*, 10-36.
- Ghobakhloo, M. (2019). Industry 4.0, digitization, and opportunities for sustainability. *Journal of Cleaner Production*.
- Giovanna Culot, M. P. (2024). Artificial intelligence in supply chain management: A systematic literature review of empirical studies and research directions. *Computers in Industry*.
- Haolin Li, S. W. (2022). Data-driven optimization for automated warehouse operations decarbonization. *Annals of Operations Research*, 1129-1156.
- Harris, F. W. (1913). How Many Parts to Make at Once. *Factory, The Magazine of Management*, 135-136.
- Hau L. Lee, V. P. (2015). The Bullwhip Effect In Supply Chains. *IEEE Engineering Management Review*, 108-117.
- Ivanov, D. (2021). Supply Chain Viability and the COVID-19 Pandemic: A Conceptual and Formal Generalisation of Four Major Adaptation Strategies. *International Journal of Production Research*, 1-26.
- Kshetri, N. (2018). 1 Blockchain's roles in meeting key supply chain management objectives. *International Journal of Information Management*, 80-89.
- Larson, P. (2001). *Designing and Managing the Supply Chain: Concepts, Strategies and Case Studies*. 3rd ed. McGraw-Hill. *Journal of Business Logistics*, 259-261.
- Luciano Floridi, J. C. (2019). A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review* , 1-14.

- Navdeep Singh, D. A. (2023). AI and IoT: A Future Perspective on Inventory Management. *International Journal for Research in Applied Science and Engineering Technology* , 2753–2757.
- Ohno, T. (1998). *Toyota Production System Beyond Large-Scale Production*. CRC Press.
- Osman Çaylı, Z. O. (2024). Artificial Intelligence-Driven Inventory Management: Optimizing Stock Levels and Reducing Costs Through Advanced Machine Learning Techniques. *The European Journal of Research and Development*, 427-439.
- Özge Albayrak Ünal, B. E. (2023). Applications of Artificial Intelligence in Inventory Management: A Systematic Review of the Literature. *Archives of Computational Methods in Engineering* , 2605-2625.
- Praveen Kumar, D. C. (2024). AI-enhanced inventory and demand forecasting: Using AI to optimize inventory management and predict customer demand. *World Journal of Advanced Research and Reviews*, 1931-1944.
- Samuel Fosso Wamba, S. A. (2014). How ‘big data’ can make big impact: Findings from a systematic review and a longitudinal case study. *International Journal of Production Economics*, 1-35.
- Sarkadi Barnabás, B.-N. E. (2025). A mesterséges intelligencia alkalmazásának lehetőségei a fenntartható ellátási láncok fejlesztésében. *Economica*, 90-106.
- Sunil Chopra, M. S. (2004). Managing Risk to Avoid Supply-Chain Breakdown. *MIT Sloan Management Review*, 53-61.
- Tsan-Ming Choi, S. W. (2018). Big Data Analytics in Operations Management. *Production and Operations Management* , 1868-1883.
- Vlachos, I. (2022). The COVID-19 pandemic impact on supply chains: A systematic literature review. *International Journal of Logistics Systems and Management*, 1-40.
- Wenwen Chen, Y. M. (2024). Artificial Intelligence in Logistics Optimization with Sustainable Criteria: A Review. *Sustainability*, 1-22.

Ábrajegyzék

1. ábra A tényleges kereslet, a regressziós illesztés és a mozgóátlag összehasonlítása.....	35
2. ábra Előrejelző és készletmutatók eredményei.....	38

Mellékletek

```
<!doctype html>

<html lang="hu">

<head>

<meta charset="utf-8">

<title>A mesterséges intelligencia alkalmazása a készletgazdálkodásban és
rendelésfeldolgozásban</title>

<script src="https://cdn.jsdelivr.net/npm/chart.js"></script>

<style>

  body {font-family:"Times New
Roman",serif;background:#fdfdfd;color:#1a1a1a;margin:0;padding:40px 20px;line-
height:1.65;}

  .container {max-width:1240px;margin:0 auto;}

  .card {background:white;border:1px solid #d0d0d0;border-
radius:10px;padding:32px;margin-bottom:32px;box-shadow:0 4px 16px rgba(0,0,0,0.08);}

  h1 {font-size:28px;color:#002e5d;text-align:center;margin:0 0 20px 0;}

  .lead {font-size:17px;text-align:justify;color:#333;margin-bottom:30px;}

  .controls {text-align:center;margin-bottom:35px;}

  button {padding:12px 28px;margin:0 12px;border:none;border-
radius:6px;cursor:pointer;font-size:15px;font-weight:600;}

  button.primary {background:#002e5d;color:white;}

  button.primary:hover {background:#001f40;}

  button.secondary {background:#f0f0f0;color:#333;border:1px solid #ccc;}

  button.secondary:hover {background:#e0e0e0;}


  .columns {display:flex;gap:40px;margin-top:20px;}

  .columns > div {flex:1;}
```

```

@media (max-width:900px) {.columns {flex-direction:column;}}

table {width:100%;border-collapse:collapse;margin:20px 0;font-size:15px;}
th, td {padding:13px;text-align:center;border-bottom:1px solid #ddd;}
th {background:#f2f6fa;color:#002e5d;font-weight:bold;}
input {width:90px;padding:8px;border:1px solid #bbb;border-radius:4px;text-align:center;font-size:15px;}
input:focus {border-color:#002e5d;outline:none;box-shadow:0 0 3px rgba(0,46,93,0.15);}

.results-table {width:100%;border-collapse:collapse;margin:25px 0;}
.results-table td {padding:18px;font-size:15.5px;background:#f8f9ff;border:1px solid #e0e0e0;}
.results-table .label {background:#eef2f8;color:#002e5d;font-weight:bold;width:60%;}
.results-table .value {text-align:center;font-size:19px;font-weight:bold;color:#9b1d23;}

.interpretation {background:#f8f9fa;border:1px solid #e0e0e0;padding:28px;border-radius:8px;font-size:16px;text-align:justify;line-height:1.7;margin-top:30px;}
.interpretation strong {color:#002e5d;}

footer {text-align:center;margin-top:60px;color:#666;font-size:14px;}
</style>
</head>
<body>

<div class="container">
  <div class="card">

```


<h1>A mesterséges intelligencia alkalmazása
a készletgazdálkodásban és
rendelésfeldolgozásban</h1>

<p class="lead">

A szakdolgozat empirikus részéhez készített interaktív szimuláció egy 12 hónapos keresleti
idősor alapján hasonlítja össze

a hagyományos három hónapos mozgóátlag módszert egy egyszerű lineáris regressziós
modellel.

A regressziós modell az adatvezérelt, mesterséges intelligencia alapú megközelítést
képviseli.

A szimuláció bemutatja a predikciós hibákat és a rendelési pont számítását 95 százalékos
szolgáltatási szint mellett.

</p>

<div class="controls">

<button class="primary" id="run">Számítások frissítése</button>

<button class="secondary" id="reset">Alapadatok visszaállítása</button>

<button class="secondary" id="export">Eredmények mentése CSV-be</button>

</div>

<div class="columns">

<div>

<div class="card">

<h2 style="font-size:20px;margin-top:0;color:#002e5d;">Keresleti adatok</h2>

<table id="dataTable"><thead><tr><th>Hónap</th><th>Kereslet
(db)</th></tr></thead><tbody></tbody></table>

</div>

</div>

```

<div>

  <div class="card">

    <h2 style="font-size:17px;margin:0 0 15px 0;color:#555;">Előrejelzési és
készletmutatók</h2>

    <table class="results-table" id="resultsTable">

      <tr><td class="label">Mozgóátlag előrejelzés (13. hónap)</td><td class="value"
id="ma3">-</td></tr>

      <tr><td class="label">Regressziós előrejelzés (13. hónap)</td><td class="value"
id="ols">-</td></tr>

      <tr><td class="label">MAE (mozgóátlag)</td><td class="value" id="maeMA">-
</td></tr>

      <tr><td class="label">MAE (regresszió)</td><td class="value" id="maeOLS">-
</td></tr>

      <tr><td class="label">MAPE (mozgóátlag)</td><td class="value" id="mapeMA">-
</td></tr>

      <tr><td class="label">MAPE (regresszió)</td><td class="value" id="mapeOLS">-
</td></tr>

      <tr><td class="label">Rendelési pont 95% (mozgóátlag)</td><td class="value"
id="ropMA">-</td></tr>

      <tr><td class="label">Rendelési pont 95% (regresszió)</td><td class="value"
id="ropOLS">-</td></tr>

    </table>

    <div class="interpretation" id="interpretation"></div>

  </div>

</div>

</div>

```

```
<div class="card">

  <canvas id="chart"></canvas>

</div>

</div>
```

```
<footer>

  Buzsáki Krisztina – IVRQ1K<br>

  Gazdaságinformatikus BSc – Logisztikai informatikus specializáció<br>

  Budapesti Gazdaságtudományi Egyetem – Pénzügy és Számvitel Kar – 2025

</footer>

</div>
```

```
<script>

let defaultDemand = [100,105,98,120,130,128,135,140,138,150,155,160];

let demand = [...defaultDemand];


const mean = a => a.reduce((s,v) => s+v, 0) / a.length;

const mae = (p,r) => p.reduce((s,v,i) => s + Math.abs(v-r[i]), 0) / p.length;

const mape = (p,r) => p.reduce((s,v,i) => s + Math.abs((v-r[i])/r[i]), 0) / p.length * 100;


function ma3Forecast() { return mean(demand.slice(-3)); }

function ma3Hist() { let p = []; for(let i=3; i<demand.length; i++) p.push(mean(demand.slice(i-3,i))); return p; }


function olsRegression() {

  const n = demand.length;
```

```

const x = Array.from({length:n}, (_,i) => i+1);

const xm = mean(x);

const ym = mean(demand);

let num = 0, den = 0;

for(let i=0; i<n; i++) { num += (x[i]-xm)*(demand[i]-ym); den += (x[i]-xm)**2; }

const b = den === 0 ? 0 : num/den;

const a = ym - b*xm;

const fitted = x.map(xi => a + b*xi);

const forecast = a + b*(n+1);

return {a, b, fitted, forecast};
}

function renderTable() {

  const tbody = document.querySelector("#dataTable tbody");

  tbody.innerHTML = "";

  demand.forEach((v,i) => {

    const tr = document.createElement("tr");

    tr.innerHTML = `<td>${i+1}</td><td><input type="number" value="${v}" data-
i="${i}"></td>`;

    tbody.appendChild(tr);

  });

  document.querySelectorAll("#dataTable input").forEach(inp => {

    inp.addEventListener("change", e => { demand[+e.target.dataset.i] = +e.target.value; calc();

  });

  });

}

```

```

function calc() {

    const ma3 = ma3Forecast();

    const lr = olsRegression();

    const ma3h = ma3Hist();

    const ma3real = demand.slice(3);

    const maeMA = mae(ma3h, ma3real);

    const mapeMA = mape(ma3h, ma3real);

    const maeLR = mae(lr.fitted, demand);

    const mapeLR = mape(lr.fitted, demand);

    const avg = mean(demand);

    const ropMA = avg + maeMA*1.65;

    const ropLR = avg + maeLR*1.65;


    document.getElementById("ma3").textContent = ma3.toFixed(1) + " db";

    document.getElementById("ols").textContent = lr.forecast.toFixed(1) + " db";

    document.getElementById("maeMA").textContent = maeMA.toFixed(2) + " db";

    document.getElementById("maeOLS").textContent = maeLR.toFixed(2) + " db";

    document.getElementById("mapeMA").textContent = mapeMA.toFixed(2) + " %";

    document.getElementById("mapeOLS").textContent = mapeLR.toFixed(2) + " %";

    document.getElementById("ropMA").textContent = ropMA.toFixed(1) + " db";

    document.getElementById("ropOLS").textContent = ropLR.toFixed(1) + " db";


    const javulas = ((maeMA - maeLR)/maeMA*100).toFixed(1);

    const ropDiff = (ropMA - ropLR).toFixed(1);


    document.getElementById("interpretation").innerHTML = `

```

Értelmezés

A vizsgált idősor enyhe emelkedő trendet mutat (meredekség $\{lr.b.toFixed(3)\}$ db/hó).

A lineáris regressziós modell ezt felismerte, ezért $\{javulas\}$ százalékkal alacsonyabb abszolút hibát ért el, mint a mozgóátlag.

A relatív hiba is jobb ($\{mapeLR.toFixed(2)\}\%$ helyett $\{mapeMA.toFixed(2)\}\%$).

A rendelési pont 95 százalékos szolgáltatási szint mellett $\{ropDiff\}$ darabbal alacsonyabb a regressziós modellnél,

ami kevesebb készletet és alacsonyabb készletköltséget jelent ugyanolyan kiszolgálási szint mellett.

Az eredmények igazolják, hogy már egy egyszerű adatvezérelt modell is jelentősen jobb lehet a hagyományos módszereknél.

`;

```
renderChart(demand, ma3, lr);  
}
```

```
let myChart = null;
```

```
function renderChart(data, ma3, lr) {  
  const ctx = document.getElementById("chart").getContext("2d");  
  const labels = Array.from({length:12}, (_,i)=>` ${i+1}. hónap`);  
  labels.push("13. hónap");  
  if(myChart) myChart.destroy();  
  myChart = new Chart(ctx, {  
    type:"line",  
    data:{labels,  
    datasets:[
```

```

    {label:"Tényleges
kereslet",data:[...data,null],borderColor:"#111",tension:0.25,pointRadius:5},

    {label:"Regressziós
modell",data:[...lr.fitted,lr.forecast],borderColor:"#9b1d23",tension:0,pointRadius:4},

    {label:"Mozgóátlag
előrejelzés",data:Array(12).fill(null).concat(ma3),borderColor:"#002e5d",pointStyle:"rectRot
",pointRadius:10}

  ]

},

options: {responsive:true,plugins: {legend: {position:"top"}}}

});

}

```

```

function exportCSV() {

  const lr = olsRegression();

  const ma3 = ma3Forecast();

  const maeMA = mae(ma3Hist(), demand.slice(3));

  const maeLR = mae(lr.fitted, demand);

  const ropMA = mean(demand) + maeMA*1.65;

  const ropLR = mean(demand) + maeLR*1.65;

  let csv = "Mutató;Érték;Egység\n";

  csv += `Mozgóátlag előrejelzés;${ma3.toFixed(1)};db\n`;

  csv += `Regressziós előrejelzés;${lr.forecast.toFixed(1)};db\n`;

  csv += `MAE mozgóátlag;${maeMA.toFixed(2)};db\n`;

  csv += `MAE regresszió;${maeLR.toFixed(2)};db\n`;

  csv += `Rendelési pont mozgóátlag;${ropMA.toFixed(1)};db\n`;

  csv += `Rendelési pont regresszió;${ropLR.toFixed(1)};db\n`;
}

```

```

const blob = new Blob([csv], {type:"text/csv;charset=utf-8;"});

const a = document.createElement("a");

a.href = URL.createObjectURL(blob);

a.download = "buzsaki_krisztina_keszletmodell_eredmenyek.csv";

a.click();

}

renderTable();

calc();

document.getElementById("run").onclick = calc;

document.getElementById("reset").onclick = () => { demand = [...defaultDemand];
renderTable(); calc(); };

document.getElementById("export").onclick = exportCSV;

</script>

</body>

</html>

```