

SZAKDOLGOZAT

Kecskés Dániel



Magyar Agrár- és Élettudományi Egyetem
Szent István Campus
Gazdálkodás és menedzsment alapképzési szak

A Mesterséges Intelligencia (MI) alkalmazásának lehetőségei
intelligens ellátási láncok területén

Belső konzulens: Dr. Mészáros Kornélia
egyetemi adjunktus

Belső konzulens
intézete/tanszéke: Agrárlogisztika, Kereskedelem
és Marketing Tanszék

Készítette: Kecskés Dániel

Gödöllő
2025

Contents

1	Bevezetés.....	5
2	Szakirodalmi áttekintés	7
2.1	Értékteremtő folyamatok menedzsmentje	7
2.2	Koronavírus hatása SCM-re	8
2.3	MI applikáció az ellátásláncban	9
2.4	Az intelligens ellátási láncok működési elve.....	11
2.5	KPI - Key Performance Indicators	13
2.6	Kereslet előrejelzés pontossága	14
2.7	Készletek szerepe	15
2.8	Kraljic-féle mátrix	16
2.9	Az ABC-XYZ elemzés és a Kraljic-mátrix szinergiája.....	18
2.10	Esettanulmányok	19
2.10.1	Walmart.....	19
2.10.2	SAP Signavio, GenAI:	20
3	Saját kutatás és javaslatok	22
3.1	Előrejelzés és keresletkezelés	22
3.1.1	Előnyök és hátrányok.....	23
3.1.2	Potenciális megoldások metodikája	24
3.1.3	Modell képzése és validáció.....	26
3.1.4	MI-alapú modellterv és fejlesztési koncepció	30
3.1.5	A modell bemutatása	31
3.1.6	A modell integrálása a vállalati tervezési rendszerbe	34
3.2	Készletoptimalizálás a Material Balance jelentés segítségével	35
3.2.1	Készletforgási sebesség elemzése cikkszámanként	38
3.2.2	Minimum készlet szint számítása és biztonsági készlet újradefiniálása	43
3.2.3	Készletérték-csökkentés és forgási hatékonyság növelés	46
4	Következtetések és javaslatok.....	48
5	Összefoglalás.....	51
6	Ábrajegyzék	52
7	Bibliography.....	53

1 Bevezetés

Az ellátási láncok hatékonysága és fenntarthatósága olyan kulcsfontosságú tényezők, amelyek a vállalatok versenyképességét és a globális gazdaság egészének működését is meghatározzák. Az elmúlt évtizedekben az ellátási láncok bonyolultsága és mérete exponenciálisan növekedett, ami új kihívások elé állította a vállalatokat és az iparágakat. A mesterséges intelligencia (Artificial Intelligence, MI) megjelenése és folyamatos fejlődése azonban olyan lehetőségeket teremtett, amelyek alapjaiban formálhatják át ezeket a rendszereket, javítva azok rugalmasságát, hatékonyságát és fenntarthatóságát.

A mesterséges intelligencia egy technológiai innováció, egy stratégiai eszköz, amely képes áthidalni az ellátási láncok működésében meglévő hiányosságokat. Az MI révén az ellátási láncok valós időben képesek reagálni a változó piaci igényekre, az előre nem látható kihívásokra – például természeti katasztrófákra, pandémiákra –, valamint az egyre növekvő fenntarthatósági követelményekre. Az intelligens rendszerek segítségével lehetővé válik a nagy mennyiségű adat gyors és hatékony feldolgozása, ami a döntéshozatal folyamatát felgyorsítja, és annak pontosságát és megalapozottságát is növeli.

Az MI szerepe kifejezetten szembetűnő a kereslet-előrejelzés és a készletgazdálkodás területén. Az olyan technológiák, mint a gépi tanulás, a prediktív analitika és a valós idejű adatfeldolgozás, forradalmasították a vállalatok működését. Az olyan iparági szereplők, mint a Walmart, már bizonyították, hogy az MI-alapú rendszerek alkalmazása drámai módon növelheti a készletkezelés hatékonyságát, csökkentheti a hulladékot és javíthatja a vásárlói élményt. A Walmart példája azt mutatja, hogy az MI által vezérelt rendszerek képesek a múltbeli értékesítési adatok, az időjárás-előrejelzések és egyéb tényezők elemzésével pontos kereslet-előrejelzéseket készíteni, amelyek alapján a készletszintek dinamikusan állíthatók be. Ennek eredményeként csökken a készletfelesleg és a készlethiány, miközben az ügyfelek számára biztosított a szükséges termékek folyamatos elérhetősége.

A COVID-19 világjárvány különösen rávilágított az ellátási láncok sérülékenységre és az adaptáció fontosságára. A pandémia során tapasztalt globális kihívások – például az alapvető árucikkek és egészségügyi eszközök hiánya – rávilágítottak arra, hogy az MI-alapú technológiák milyen kulcsszerepet tölthetnek be a válsághelyzetek kezelésében. Az MI segítségével a vállalatok valós időben monitorozhatják készleteiket, azonosíthatják a problémás pontokat, és gyors, adatvezérelt döntéseket hozhatnak. Ezek a rendszerek nemcsak a válságkezelés hatékonyságát növelik, hanem elősegítik az ellátási láncok hosszú távú rugalmasságát és stabilitását is.

A fenntarthatóság szintén egyre hangsúlyosabb szempont az ellátási láncok tervezésében és működtetésében. Az útvonaloptimalizálás vagy az üzemanyag-fogyasztás csökkentését célzó rendszerek jelentősen hozzájárulhatnak a vállalatok ökológiai lábnyomának mérsékléséhez. Az éghajlatváltozás elleni globális küzdelemben az MI olyan eszközöket kínál, amelyek nemcsak a vállalatok fenntarthatósági céljait támogatják, hanem az iparágak egészének környezeti hatását is csökkenthetik.

Ez a dolgozat az MI alkalmazásának lehetőségeit vizsgálja az intelligens ellátási láncok területén. A dolgozat célja, hogy bemutassam, hogyan képes az MI növelni az ellátási láncok hatékonyságát, miközben hozzájárul a rugalmasság javításához, és javaslatokat teyek az MI gyakorlati használatára. A dolgozat gyakorlati példákon, valamint saját kutatási eredményeimen keresztül mutatja be az MI alkalmazásának konkrét előnyeit és kihívásait.

A kutatás nemcsak a technológia elméleti hátterét tárja fel, hanem gyakorlati megoldásokat is kínál vállalatok számára az MI-alapú rendszerek implementálásához és optimalizálásához. Az eredmények felhasználhatók lesznek mind az operatív, mind a stratégiai döntéshozatal támogatására, lehetőséget teremtve a vállalatok számára, hogy alkalmazkodjanak a gyorsan változó környezet kihívásaihoz. Az MI által nyújtott lehetőségek kiaknázása az egyes vállalatok számára jelenthet versenyelőnyt, hozzájárulhat a globális gazdaság fenntarthatóbb és hatékonyabb működéséhez is.

2 Szakirodalmi áttekintés

2.1 Értékteremtő folyamatok menedzsmentje

Az értékteremtő folyamatok menedzsmentje szorosan kapcsolódik az intelligens ellátási láncok működéséhez, mivel alapvetően befolyásolja a vállalati teljesítményt és a fogyasztói érték létrehozását. Ahogy Chikán és Demeter is hangsúlyozzák, az értékteremtő folyamatok magukban foglalják a termelést, a szolgáltatást és a logisztikát, amelyek együtt biztosítják, hogy a megfelelő termékek és szolgáltatások a megfelelő időben és helyen elérhetőek legyenek a fogyasztók számára. (Chikán & Demeter, 2006)

Az ellátási lánc nem más, mint „Értékteremtő - termelési és logisztikai - folyamatok együttműködő szervezeteken átívelő sorozata, mely fogyasztói igények kielégítésére alkalmas terméket, illetve szolgáltatást hoz létre”. (Chikán & Demeter, 2006)

Ezen láncok hatékonysága a vállalatok versenyképességének egyik alapja, mivel a logisztikai és termelési folyamatok optimalizálása révén csökkenthetők a költségek, javítható a termékek és szolgáltatások minősége, valamint növelhető a fogyasztói elégedettség. A kereslet-előrejelzés, amely az értékteremtő folyamatok egyik kritikus eleme, központi szerepet játszik az intelligens ellátási láncokban. A pontos kereslet-előrejelzés révén a vállalatok jobban tervezhetik erőforrásaikat és optimalizálhatják a készletszinteket, minimalizálva ezzel a készletfelesleget vagy a készlethiányt. Chikán kiemeli, hogy „a fogyasztói érték a fogyasztó szubjektív véleménye arról, hogy a termék milyen mértékben felel meg várakozásainak” az értékteremtés központi fogalma, hiszen a fogyasztói elégedettség közvetlenül befolyásolja a vállalat sikerességét. Az értékteremtő folyamatok az érték, anyagi és információs folyamatok hármasságára épülnek, ahol a termelés, a logisztika és a szolgáltatások mind hozzájárulnak az ügyfélméltány és az üzleti célok megvalósításához. Arra is rávilágítanak, hogy az értékteremtő folyamatoknak alkalmazkodniuk kell a fogyasztói igényekhez és a piaci környezet változásaihoz. A modern gazdasági környezetben az intelligens rendszerek lehetővé teszik, hogy a vállalatok valós időben reagáljanak a piaci változásokra, javítva ezáltal az ellátási láncok rugalmasságát és ellenállóképességét. A modern értékteremtési modell különös hangsúlyt fektet a „fogyasztói igények és fogyasztói érték” megértésére, valamint arra, hogy a termékek megfelelő időben és helyen álljanak rendelkezésre. (Chikán & Demeter, 2006)

Az MI-alapú technológiák, mint például a prediktív analitika és az automatizáció, kritikus eszközöket biztosítanak az ilyen adaptív folyamatok megvalósításához. Ez releváns a mesterséges intelligencia (MI) alkalmazásakor, mivel az MI technológiák révén a vállalatok megérthetik és

gyorsabban reagálhatnak a változó fogyasztói igényekre. Az intelligens rendszerek fejlődése új lehetőségeket kínál az értékteremtő folyamatok hatékonyabbá és rugalmasabbá tételére a technológiák által, lehetővé teszik a keresleti minták pontosabb előrejelzését, a készletek optimális kezelését, valamint az ellátási lánc teljesítményének folyamatos monitorozását. Ezek a rendszerek nemcsak az operatív folyamatok automatizálásában segítenek, hanem az értékteremtési lánc stratégiai szintjén is támogatják a döntéshozatalt.

Az értékteremtő folyamatok egyik legfontosabb eleme a rugalmasság, vagyis az a képesség, hogy a gyors és hatékony reagálásra való képesség a piaci változásokra és a váratlan kihívásokra. Az MI-alapú rendszerek valós idejű adatfeldolgozási képességeikkel és automatizált döntéstámogatási mechanizmusaikkal lehetővé teszik a gyors alkalmazkodást.

2.2 Koronavírus hatása SCM-re

„Az ellátási lánc menedzsment olyan irányítási stratégia, amelynek célja az anyagok, az információk és a pénz áramlásának optimalizálása a költségek csökkentése és a fogyasztó számára a lehető legnagyobb érték biztosítása érdekében (Perkins – Wailgum, 2017; Karmazin – Tóth, 2016).” (Kozma & Ertugrul, 2021) Ebből egyértelműen látszik, hogy a célja, hogy költséghatékonyan működjön az ellátási lánc az ügyfélelégedettség biztosítása mellett.

Ajánlásaik között szerepel "az ellátási lánc kockázatkezelési folyamatait be kell vonni az ellátási lánc-menedzsment digitális átalakításába, amelyet különböző nevekkel neveznek, például intelligens ellátási lánc és ellátási lánc 4.0." (Kozma & Ertugrul, 2021) Ez a kijelentés egyértelműen rámutat az MI-alapú rendszerek szerepére az ellátási lánc modernizációjában már 2021-ben.

Az ellátási lánc 4.0 az ipar 4.0 koncepcióhoz kapcsolódó fejlesztések alkalmazását jelenti az ellátási lánc menedzsmentjében. Az ipar 4.0 a digitális technológiák, például az IoT¹, a big data², a mesterséges intelligencia, a felhőalapú rendszerek és az automatizált robotika integrálására épít, és célja a folyamatok intelligensebbé, rugalmasabbá és hatékonyabbá tétele.

Kozma és Ertugrul a hagyományos ellátási lánc menedzsment korlátaira is rávilágít, különösen a stratégiák okozta törékenységre:

¹ (Internet of Things) vagyis a „dolgok internete” az eszközök, szenzorok és rendszerek hálózati összekapcsolását jelenti, amelyek adatokat gyűjtenek, továbbítanak és dolgoznak fel valós időben, ezzel javítva az automatizációt és a hatékonyságot különböző iparágakban.

² nagy mennyiségű, gyorsan keletkező és különböző forrásokból származó adatok összessége, amelyek elemzése és feldolgozása fejlett technológiákat és eszközöket igényel a döntéshozatal, az előrejelzés és az optimalizáció érdekében.

„Az ellátási lánc menedzsmentje sokféle stratégiával próbálja csökkenteni a vállalatok költségeit, növelni jövedelmezőségüket és az ügyfelek elégedettségét magas versenyfeltételek mellett. Az olyan stratégiák, mint a kiszervezés, az ellátási lánc globalizációja, a beszállítók minimális száma, a magas integráció, a minimális készlet, a minimális termék-várakozási idő és az időben történő szállítás, hozzájárulnak a vállalatok céljainak eléréséhez, ugyanakkor nagy törekénységet okoznak.” (CISION, 2020; Szakály – Kása, 2011)

A "nagy törekénység" abból adódik, hogy az ellátási láncok gyakran túl optimalizáltak, így kevésbé képesek alkalmazkodni a váratlan eseményekhez. Az MI technológiák segítenek előrejelezni a keresleti mintákat, azonosítani a szállítási lánc gyenge pontjait, és automatikusan alkalmazkodni a változó piaci feltételekhez.

2.3 MI applikáció az ellátásláncban

A mesterséges intelligencia (MI) alkalmazása az ellátási lánc menedzsmentjében új perspektívákat nyit meg, különösen az adatvezérelt és prediktív döntéshozatal területén. Az „Artificial Intelligence Applications in Supply Chain”-ben bemutatott elemzés világosan rámutat az MI növekvő szerepére az ellátási lánc különböző folyamataiban, beleértve a kereslet-előrejelzést, a kockázatkezelést, a szállítmányozást és a készletgazdálkodást. (Riahi, Saikouk, Gunasekaran, & Badraoui, 2021)

Az MI technológiák, mint például a gépi tanulás és az adaptív algoritmusok, képesek olyan komplex adatstruktúrákat kezelni, amelyek az ellátási lánc folyamatainak optimalizálásához elengedhetetlenek. Az algoritmusok alkalmazása lehetővé teszi a vállalatok számára, hogy pontos előrejelzéseket készítsenek, minimalizálják a késedelmeket és a hibákat, valamint növeljék a logisztikai hatékonyságot. Például a forrás szerint az adaptív tabu keresési algoritmusok, valamint a genetikus algoritmusok kiemelkedően hatékonyak bizonyultak az útvonal-optimalizálási és a szállítási idő csökkentési problémák kezelésében. A tanulmány arra is rávilágít, hogy az MI alkalmazásának szintjei – leíró, prediktív és előíró analitika – eltérő előnyöket biztosítanak az ellátási lánc különböző szakaszaiban. A prediktív analitika fontos a keresleti minták azonosításában és a kockázatok előrejelzésében, míg az előíró analitika lehetővé teszi az optimális megoldások kialakítását, például a beszállítók kiválasztásában és a készletelosztás tervezésében.

A legnagyobb figyelmet az „Enable” folyamatokban kapták. Az „Enable” folyamatok az ellátási lánc működésének alapvető támogató elemei. Ide tartozik az üzleti szabályok kialakítása és fenntartása, az adatforrások hatékony kezelése, valamint a kockázatkezelési stratégiák kidolgozása. Ezek a folyamatok kulcsfontosságúak, mivel közvetlenül befolyásolják az ellátási lánc

rugalmasságát és gyors reagálóképességét. Az üzleti szabályok MI-alapú kezelése révén a vállalatok képesek voltak valós idejű döntéseket hozni, amelyek például a szállítási útvonalak, készletezési stratégiák vagy szállítói megbízások dinamikus módosítását érintették. Az MI lehetővé tette, hogy ezek a szabályok az aktuális piaci körülményekhez igazodjanak, minimalizálva ezzel a fennakadások kockázatát. Az adatforrások kezelése szintén kritikus terület volt az MI-alapú megoldások alkalmazásában. Az MI technológiák biztosították a hatalmas mennyiségű adat feldolgozását és elemzését, amelyek olyan fontos területeket érintettek, mint a szállítói teljesítmény nyomon követése, a keresleti trendek azonosítása vagy a logisztikai folyamatok hatékonyságának mérése. Ez a megközelítés értékes volt olyan összetett helyzetekben, mint a COVID-19 járvány, amely során a gyorsan változó környezet miatt a pontos és friss adatok elengedhetetlenek voltak. A kockázatkezelési stratégiák terén az MI-alapú megoldások szimulációk és forgatókönyvelemzések futtatásával segítették a vállalatokat a potenciális zavarok előrejelzésében és a megfelelő reakciók kidolgozásában. Például az MI segítségével a vállalatok gyorsan azonosították a szállítói láncok gyenge pontjait, és proaktív intézkedéseket vezettek be a lehetséges fennakadások minimalizálása érdekében. Az „Enable” folyamatok ilyen szintű fejlesztése az MI technológiákkal biztosította az ellátási lánc számára, hogy ne csak a kihívásokhoz alkalmazkodjon, hanem képes legyen megelőző lépéseket tenni, miközben a vállalat működését fenntarthatóbbá és hatékonyabbá tette. Az MI jövőbeli kutatási irányait tekintve a tanulmány azt javasolja, hogy az adatfeldolgozási megközelítéseket még jobban integrálják a valós idejű döntéshozatalba, és hogy az MI algoritmusok szélesebb körű alkalmazását vizsgálják az ellátási lánc egészében, nemcsak a logisztikai, de a termelési és a visszárukezelési folyamatokban is. Az MI integrációja alapjaiban változtatja meg az ellátási láncok működését. Kiemelt jelentőséget kap az adatvezérelt döntéshozatal, amely az MI-technológiák egyik legfontosabb eredménye. Az SCM-ben keletkező hatalmas adatmennyiség feldolgozása és elemzése gyakran meghaladja a hagyományos módszerek kapacitásait. (Riahi, Saikouk, Gunasekaran, & Badraoui, 2021)

Az MI azonban képes automatizáltan és valós időben elemezni az adatokat, amely a hatékonyságot növeli, és a pontosságot is javítja. A kereslet-előrejelzés az egyik ilyen terület, ahol az MI által támogatott prediktív modellek a múltbeli értékesítési adatok és a piaci trendek alapján segítenek a várható kereslet pontosabb meghatározásában. Ezáltal csökkenhetnek a készlethiányok, illetve elkerülhetővé válik a felesleges készletek felhalmozása. A szállítás és logisztika szintén az MI-alapú technológiák kulcsfontosságú alkalmazási területei közé tartozik. Az MI képes a szállítási hálózatok optimalizálására, figyelembe véve az időjárás körülményeket, a közlekedési viszonyokat és a költségek minimalizálásának lehetőségeit. Ez a rugalmasság értékes a váratlan

események, például geopolitikai konfliktusok vagy természeti katasztrófák esetén, amikor a hagyományos rendszerek gyakran lassan vagy egyáltalán nem tudnak reagálni. Az MI tehát hozzájárul ahhoz, hogy az ellátási láncok megbízhatóbban és folyamatosabban működjenek a zavaró tényezők ellenére is. A rugalmasság és alkalmazkodóképesség témaköre különösen hangsúlyos. Az MI technológiák nemcsak a problémák felismerését és kezelését támogatják, hanem proaktív megoldásokat is nyújtanak. A COVID-19 világjárvány példáján keresztül bemutatják, hogy az MI-alapú rendszerek hogyan tették lehetővé a vállalatok számára az ellátási lánc megszakadásainak kezelését. Valós idejű adatfeldolgozás és a kockázatok azonnali azonosítása révén az MI segítette a vállalatoknak gyorsabban reagálni, csökkentve a zavarokból eredő veszteségeket. Az MI alkalmazása nem csupán gazdasági előnyökkel jár, hanem fenntarthatósági szempontból is jelentős fejlődést kínál. Az energiahatékonyság, a szén-dioxid-kibocsátás csökkentése és az erőforrások fenntarthatóbb felhasználása mind olyan területek, ahol az MI alapú optimalizáció érezhető javulást eredményezhet. Az intelligens rendszerek például képesek a szállítási útvonalak és az üzemanyag-felhasználás hatékonyabb megtervezésére, amely egyrészt a költségeket csökkenti, másrészt a környezeti terhelést is mérsékeli. (Riahi, Saikouk, Gunasekaran, & Badraoui, 2021)

2.4 Az intelligens ellátási láncok működési elve

Az intelligens ellátási lánc (smart supply chain) egy olyan fejlett rendszermodell, amely az ipar 4.0 technológiáira – mint például az Internet of Things, mesterséges intelligenciára, big data analitika, felhőalapú számítástechnika és blokklánc – építve képes az adatalapú, automatizált és valós idejű döntéshozatalra. Célja a teljes ellátási lánc átláthatóságának növelése, a hatékonyság fokozása és a kockázatok proaktív kezelése. (Ivanov & Dolgui, 2020)

Ivanov és Dolgui hangsúlyozzák, hogy az intelligens ellátási lánc egyik központi eleme a digitális iker (digital twin) koncepció, amely lehetővé teszi, hogy a vállalatok valós idejű adatokat gyűjtsenek és elemezzenek, ezzel dinamikusan modellezve a valós működés virtuális mását. A digital twin képes szimulálni az ellátási lánc különböző részeinek viselkedését, és előre jelezni a lehetséges kockázatokat, például a készlethiányokat vagy a szállítási késedelmeket.

A rendszer működésének alapja a valós idejű adatáramlás, amely automatikus automatikus válaszreakciókat ad zavaró tényezőkre, például egy természeti katasztrófa vagy logisztikai fennakadás esetén a rendszer azonnal képes újraoptimalizálni a szállítási útvonalakat vagy új

beszállítókat ajánlani, ami által nő a lánc rugalmassága és rezilienciája, azaz ellenálló képessége a külső hatásokkal szemben. (Ivanov & Dolgui, 2020)

A rendszer adaptív, mivel tanul az adatokból: képes felismerni ismétlődő mintákat, anomáliákat, és ezek alapján optimalizálni az ellátási folyamatokat. Ez a tanulóképesség (machine learning és deep learning algoritmusok révén) a kulcsa, hogy az intelligens lánc ne csak reagáljon, hanem előre jelezze a keresletváltozásokat, készlethiányokat vagy logisztikai torlódásokat. (Birkel & Hartmann, 2020)

A „Big data analytics and firm performance: Effects of dynamic capabilities” (2017) című cikkben bemutatott modell szerint az intelligens ellátási lánc három fő rétegben működik (Wamba, és mtsai., 2017):

- adatgyűjtési réteg (érzékelők, RFID, IoT-eszközök);
- adatfeldolgozási és analitikai réteg (AI, big data);
- döntéstámogatási és végrehajtási réteg (automatizálás, robotika, RPA).

Ez a felépítés biztosítja, hogy a rendszer ne csak adatokat halmozzon fel, hanem azokból üzleti értéket teremtsen, és valós időben optimalizálja az egész ellátási lánc működését.

A gyakorlatban ez azt jelenti, hogy:

- a beszerzés, termelés, raktározás és elosztás folyamatai szorosan integráltak;
- az előrejelzések pontosabbak;
- a készletgazdálkodás optimalizált;
- a fenntarthatósági célok könnyebben elérhetők az erőforrás-hatékonyság révén;
- az ügyfélelégedettség növekszik a gyorsabb és megbízhatóbb kiszolgálás következtében

(Wamba, és mtsai., 2017).

Az intelligens ellátási lánc a technológiai újítás mivoltán túl egy stratégiai szemléletváltás is, amelyben az adatok, a rendszerek és az emberek integráltan működnek együtt a vállalati versenyképesség fokozása érdekében.

Ahhoz, hogy az intelligens ellátási láncok hatékonysága elméleti szinten túl gyakorlati szinten is értékelhető legyen, elengedhetetlen a teljesítmény mérésének strukturált rendszere. A modern technológiákkal a lánc működésének mélyebb és valós idejű elemzése kivitelezhető, de ugyanakkor az eredmények értelmezéséhez megbízható és egységes mutatószámokra van szükség.

Ennek megfelelően kulcsszerepet kapnak a teljesítménymutatók (Key Performance Indicators, KPI-k), amelyek segítségével mérhetővé válik az ellátási lánc különböző folyamatai és azok változása

2.5 KPI - Key Performance Indicators

A kulcsteljesítménymutatók (KPI) olyan kvantitatív mérőszámok, amelyeket a szervezetek stratégiai céljaik elérésének nyomon követésére és értékelésére alkalmaznak. A KPI-k szerepe, hogy objektív alapot biztosítsanak a teljesítményértékeléshez, segítve a vezetőket abban, hogy gyorsan azonosítsák az erősségeket, gyengeségeket és azokat a területeket, ahol beavatkozásra van szükség (Parmenter, 2015).

A hatékony KPI-rendszer kialakítása kritikus az üzleti folyamatok átláthatósága és a stratégiai döntéshozatal szempontjából, mivel lehetővé teszi az erőforrások optimalizálását, a hibák korai észlelését, valamint a vevői elvárásokhoz való folyamatos igazodást. (Parmenter, 2015)

A logisztikai és ellátási lánc menedzsment területén alkalmazott KPI-k azért is fontosak, mert ezek segítségével mérhető a készletgazdálkodás hatékonysága, a szállítási megbízhatóság, a megrendelések teljesítésének pontossága és az operatív folyamatok sebessége, továbbá nemcsak a jelenlegi működés optimalizálására alkalmasak, hanem lehetőséget biztosítanak a jövőbeli trendek azonosítására és az előrejelzések pontosságának növelésére is (Melnik, Stewart, & Swink, 2014).

A KPI-okat általában különböző érdekeltek – felsővezetők, operatív vezetők, adat- és logisztikai szakemberek – használják, eltérő célokra. A felsővezetés stratégiai döntéshozatalhoz, a középsővezetők operatív hatékonyság értékelésére, míg az adatelemzők a prediktív modellek validálására támaszkodhatnak ezekre a mutatókra. Fontos továbbá, hogy a KPI-ok dinamikusan kezelhetők legyenek: a piaci környezet változásaival összhangban felülvizsgálatra és kiigazításra szorulhatnak. (Melnik, Stewart, & Swink, 2014)

A KPI-rendszerek hatékonyságát növeli, ha azok automatizált riporting eszközökkel, például mesterséges intelligenciára vagy üzleti intelligencia (BI)³ platformokra épülnek, amelyek a valós idejű adatfeldolgozást, az anomáliák azonosítását, és akár döntéstámogatást is biztosítanak a felhasználók számára.

A magyar vállalati gyakorlatban is egyre inkább előtérbe kerül a teljesítménymérés és a KPI-rendszerek tudatos kialakítása. Csesznák és Wimmer kutatásai alapján a hazai vállalatok körében

³ olyan technológiák, alkalmazások és gyakorlatok összessége, amelyek célja az adatok összegyűjtése, elemzése és átalakítása annak érdekében, hogy a vállalatok megalapozott, adatalapú döntéseket hozhassanak (Ranjan, 2009)

is megerősítést nyert, hogy a kulcsteljesítménymutatók nem csupán a működés nyomon követését szolgálják, hanem aktív szerepet töltenek be a döntéstámogatásban is. A tanulmány alapján a sikeres teljesítménymenedzsment nem választható el a vállalati stratégia világos megfogalmazásától, illetve a releváns mérőszámok kiválasztásától. E mutatók csak akkor lehetnek valóban hasznosak, ha a vállalat képes biztosítani az adatok megbízhatóságát, időbeliségét, és azok rendszeres értelmezését a döntéshozatalban. A KPI-k hatékony alkalmazásához technikai eszközökre és megfelelő szemléletmódra is szükség van, ezzel támogatva az objektív, adatvezérelt menedzsmentet. (Csesznák & Wimmer, 2012)

2.6 Kereslet előrejelzés pontossága

Az átlagos abszolút eltérés (MAD, Mean Absolute Deviation) egy fontos statisztikai mutató az előrejelzési hibák mérésében, amely az előrejelzett értékek (f_i) és a tényleges kereslet (d_i) eltéréseit méri abszolút értékben, majd ezek átlagát adja meg. A képlet szerint az egyes periódusok eltéréseinek összegét osztjuk el a megfigyelések számával (n), így a MAD azt mutatja meg, hogy átlagosan mekkora az eltérés az előrejelzett és a tényleges kereslet között. (Hyndman & Athanasopoulos, 2018)

Ez a mutató hasznos az ellátási láncok tervezésében, mivel az hibák minimalizálásával csökkenthető az ostorcsapás-hatás, amelynek egyik fő oka a keresleti ingadozások túlreagálása vagy nem megfelelő előrejelzési stratégiák alkalmazása, amelyek felesleges készletekhez és magasabb költségekhez vezethetnek. (Chikán & Demeter, 2006)

Az előrejelzési modellek hatékonyságának objektív értékeléséhez elengedhetetlen, hogy azokat ne a tanulási adatokon, hanem külön teszt (test) adatokon vizsgáljuk. A maradéknégyzetek ugyan informatívak lehetnek, de nem nyújtanak megbízható képet a valós előrejelzési hibákról. Ezért a gyakorlatban az adathalmazt gyakran két részre osztják: a tanulási adatokra, melyek segítségével a modell paraméterei meghatározhatók, és a teszt adatokra, amelyeken az előrejelzések pontossága mérhető. (Hyndman & Athanasopoulos, 2018)

A leggyakrabban alkalmazott hibamértékek közé tartozik a MAD (átlagos abszolút eltérés), a MAE (mean absolute error), valamint a RMSE (root mean squared error), amelyek mértékei az eredeti adatok skáláján mozognak, így az összehasonlítás csak azonos egységű sorozatok között lehetséges.

A hibák relatív mértékének vizsgálatához az egyedi százalékos hiba (PE, Percentage Error) és az átlagos abszolút százalékos hiba (MAPE, Mean Absolute Percentage Error) használata elterjedt. A PE minden egyes előrejelzésre az eltérés arányát mutatja a tényleges értékhez viszonyítva:

$$PE_i = \frac{d_i - f_i}{d_i} \times 100$$

A MAPE pedig ezen értékek abszolút értékének átlagát fejezi ki, azaz:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{d_i - f_i}{d_i} \right|$$

A MAPE előnye, hogy skálafüggetlen, így különböző mértékegységű idősorok is könnyen összehasonlíthatók, és százalékos formában kifejezve könnyen értelmezhető menedzsment szinten is. Hátránya viszont, hogy érzékeny a nullához közeli tényleges értékekre, amelyek aránytalanul felnagyíthatják a hibát. Az idősoros keresztvalidáció egy továbbfejlesztett módszer, ahol az előrejelzéseket fokozatosan bővülő tanulási halmazokon értékelik. Ez biztosítja, hogy az előrejelzések valóban csak a múltbeli adatokon alapuljanak, és nem tartalmazzanak jövőbeli információt. Ezen technikával egyaránt tesztelhetőek egy- és többlépéses előrejelzések. (Hyndman & Athanasopoulos, 2018)

A dolgozatban bemutatott FC-validator rendszerben a MAPE a legfontosabb összehasonlító mutató, amely alapján a különböző előrejelzési modellek teljesítménye értékelhető.

2.7 Készletek szerepe

A készletek a vállalatok vagyonának jelentős részét képezik, és kulcsfontosságú szerepet töltenek be a zökkenőmentes működés, a piaci igények kielégítése és a versenyképesség megőrzése szempontjából (Waters, 2011). Az ellátási láncok komplexitásának növekedésével a hatékony készletgazdálkodás stratégiai imperatívusszá vált, amely közvetlenül befolyásolja a vállalatok reagálóképességét, költséghatékonyágát és végső soron a profitabilitását. (Christopher, 2016)

A készletek funkciója túlmutat a csupán puffer szerepen, amely a kereslet és a kínálat bizonytalanságait hivatott áthidalni. A megfelelően menedzselt készletszintek lehetővé teszik a gyors és rugalmas reakciót a piaci változásokra, a szezonális ingadozásokra vagy a váratlan keresleti csúcsokra. Emellett a rendelkezésre álló készletek javítják a vevői kiszolgálás színvonalát, csökkentik a lead time-ot és hozzájárulnak a magasabb szintű vevői elégedettséghez, ami a hosszú távú üzleti siker egyik alapköve. (Kotler & Keller, 2016)

Ahogy Balogh, Lajos és Kozma is hangsúlyozzák, „a jó készlet az, amely támogatja az üzleti célokat, miközben minimalizálja a készlettartási költségeket és nem akadályozza a likviditást.” Ez az idézet rávilágít a készletgazdálkodás kettős céljára: egyrészt biztosítani a termékek vagy szolgáltatások elérhetőségét a vevők számára, másrészt optimalizálni a készletszinteket a felesleges költségek elkerülése és a pénzügyi stabilitás megőrzése érdekében. Az ideális készlet szint megtalálása egyensúlyozást igényel a túlzott készletek (amelyek tőkét kötnek le és tárolási költségeket generálnak) és az alacsony készletek (amelyek áruhiányhoz, elmaradt értékesítéshez és vevői elégedetlenséghez vezethetnek) között. (Balogh, Lajos, & Kozma, 2020)

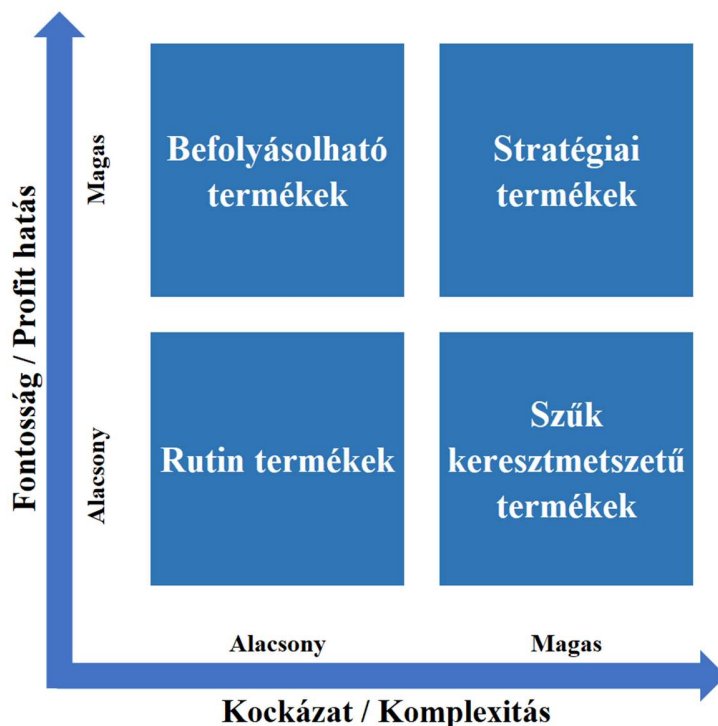
A „jó készlet” fogalma tehát egy dinamikus és optimalizált állapotot jelöl, ahol a termékek vagy szolgáltatások elérhetősege, a költséghatékonyság és a magas szintű vevői kiszolgálás harmonikusan valósul meg. A hatékony készletmenedzsment nem csupán a napi operatív működés simaságát biztosítja, hanem stratégiai versenyelőnyt is teremthet a vállalat számára a gyorsabb reagálóképesség, a jobb vevői kapcsolatok és a hatékonyabb erőforrás-kihasználás révén. (Waters, 2011)

A modern vállalatok számára elengedhetetlen a fejlett készletgazdálkodási technikák és technológiák alkalmazása annak érdekében, hogy maximalizálják a készletek által nyújtott előnyöket és minimalizálják a kapcsolódó kockázatokat. A készletgazdálkodás egy egyre inkább stratégiai jelentőségűvé váló operatív feladat, különösen akkor, ha figyelembe vesszük az egyes anyagok beszerzésének kockázatait és üzleti hatását. A vállalatok számára elengedhetetlen, hogy világosan lássák: nem minden készlet azonos értékű vagy jelentőségű, és az egyes anyag típusokra nem alkalmazható egységes utánpótlási stratégia. Éppen ezért szükség van egy olyan rendszerszintű megközelítésre, amely lehetővé teszi a készletek és alapanyagok fontosság szerinti differenciálását, valamint az ellátási kockázatok tudatos kezelését. E szemlélet kialakításában nyújt alapvető segítséget a Kraljic-féle beszerzési mátrix, amely a készletek típusonkénti szegmentálása révén támogatja a beszerzési és készletstratégiák célirányos kialakítását.

2.8 Kraljic-féle mátrix

Az anyagbeszerzés stratégiai kezelésének fontosságát alátámasztja a Kraljic-féle mátrix alkalmazása, amely a vállalati beszerzési tételeket két kulcsdimenzió – a beszerzés fontossága és a beszerzési piac komplexitása – alapján osztályozza. A mátrix négy kategóriát különít el: rutin termékek, befolyásolható termékek, szűk keresztmetszetű termékek és stratégiai termékek. E csoportosítás révén a vállalat képes célzott beszerzési stratégiát alkalmazni a különböző

terméktípusokra, így növelve a működés biztonságát és csökkentve a kitétséget az ellátási kockázatokkal szemben (Kraljic, 1983).



Ábra 1 Kraljic-féle mátrix (forrás: (Kraljic, 1983) alapján saját szerkesztés)

A stratégiai termékek kategóriája kiemelt figyelmet érdemel, mivel ezek jellemzően olyan nagy értékű, nehezen helyettesíthető alapanyagok, amelyek nélkülözhetetlenek a vállalat működése szempontjából. E termékek utánpótlása gyakran hosszú átfutási idővel vagy szűk beszállítói körrel társul, ami különösen érzékennyé teszi a vállalatot az ellátási zavarokra. Ennek következtében a stratégiai termékek esetén elengedhetetlen a hosszú távú partnerségi kapcsolatok kialakítása, a piaci trendek folyamatos monitorozása és a kockázatelemzésre épülő beszerzési döntéshozatal. A beszerzési portfólió e szegmensében tehát a cél a költségek minimalizálása a fenntartható ellátási biztonság megteremtése mellett (Kraljic, 1983).

Ezzel szemben a befolyásolható termékek bár fontosak lehetnek a működés szempontjából, többnyire alacsony ellátási kockázattal rendelkeznek. Beszerzésük során a vállalatok erős alkuerőt élveznek, így az optimalizált ár- és szerződési feltételek kiaknázása kerül előtérbe. Ugyanakkor nem hanyagolható el a rugalmasság megőrzése, leginkább abban az esetben, ha a piaci dinamika gyors változásokat idézhet elő a beszállítók oldalán (Kraljic, 1983).

A szűk keresztmetszetű termékek esetében – működésére gyakorolt hatásuk mérsékelt – a beszerzési nehézségek miatt magas kockázattal járnak. Ezeknél célszerű a biztonsági készletek

fenntartása, illetve alternatív beszállítók vagy anyagok feltérképezése. E kategória jelenti az egyik legnagyobb kiszámíthatatlanságot, különösen ha a kereslet ingadozó vagy a technológiai változások gyakoriak (Kraljic, 1983).

A rutin termékek pedig viszonylag kis értékű, standardizált tételek, amelyek könnyen elérhetők és alacsony üzleti kockázatot hordoznak. Ezek esetében a cél a hatékony, automatizált beszerzési folyamat kialakítása és a tranzakciós költségek minimalizálása (Kraljic, 1983).

A stratégiai besorolás nem statikus: egy alapanyag piaci helyzete és vállalati szerepe idővel változhat, ezért a beszerzési portfólió folyamatos felülvizsgálata elengedhetetlen. A COVID-19 világjárvány például több nyersanyag esetében idézett elő keresleti sokkot vagy ellátási problémát, amelyek korábban stabilnak ítélt piacokat is stratégiai jelentőségűvé emeltek. Ez a dinamika jól mutatja, hogy a Kraljic-mátrix a jelen helyzet felmérésére alkalmas, egyúttal a hosszú távú beszerzési stratégia megalapozásához is irányt mutat (Kraljic, 1983).

2.9 Az ABC-XYZ elemzés és a Kraljic-mátrix szinergiája

A többdimenziós készletoptimalizálási szemléletet tovább erősíti az ABC és XYZ elemzések alkalmazása, amelyek az anyagok érték és keresleti stabilitás szerinti szegmentálását teszik lehetővé. Az ABC elemzés a Pareto-elvet követve rangsorolja a készleteket az éves felhasználási érték alapján: az „A” kategóriába azok az anyagok tartoznak, amelyek kevés darabszámban fordulnak elő, viszont magas értékűek és kritikusak az üzletmenet szempontjából; a „B” kategória a közepes értékű és mennyiségű tételeket foglalja magába; míg a „C” kategóriába gyakori, de kis értékű anyagok kerülnek. Ezzel párhuzamosan az XYZ elemzés a kereslet előrejelezhetőségét értékeli: az „X” kategória stabil, jól tervezhető felhasználású, a „Y” mérsékelt ingadozó, míg a „Z” kategória erősen változó, bizonytalan keresletű anyagokat tartalmaz. (Oláh, Karmazin, Lakner, & Popp, 2020)

Az ABC és XYZ klasszifikációk kombinációja lehetővé teszi a cikkszámok komplex megítélését, például egy „AZ” típusú alapanyag egyszerre jelent magas értéket és magas keresleti kockázatot, ami fokozott figyelmet igényel mind készletbiztonsági, mind beszerzési stratégiai szempontból. Ilyen esetben elengedhetetlen a hosszú távú partneri kapcsolatok kialakítása, rugalmas rendelési mechanizmusok alkalmazása, vagy akár alternatív források biztosítása. Ezzel szemben egy „CX” típusú, alacsony értékű, de stabil felhasználású anyag kezelése automatizált, költséghatékony beszerzéssel is megoldható. (Oláh, Karmazin, Lakner, & Popp, 2020)

Ez a klaszteralapú megközelítés jól illeszthető a Kraljic-féle mátrixba, amely a beszerzési tételeket stratégiai jelentőségük és a piac komplexitása szerint csoportosítja. A két modell integrált alkalmazása nemcsak a belső készletgazdálkodási hatékonyságot növeli, hanem a külső beszerzési kockázatok mérséklését is támogatja. A vállalat így képes holisztikusan értelmezni anyagportfólióját, és proaktív döntéshozatalt megvalósítani a gyorsan változó piaci és ellátási környezetben. Az FC-validátorral támogatott előrejelzési modell, valamint a készletforgási és rendelési ciklus mutatók révén ezek a klasszifikációk adatvezérelt alapokra építhetők, így biztosítva a megalapozott és rugalmas készletstratégiák kialakítását. (Oláh, Karmazin, Lakner, & Popp, 2020)

2.10 Esettanulmányok

2.10.1 Walmart

A Walmart (Walmart, 2023) által alkalmazott mesterséges intelligencia alapú technológiák az ellátási lánc menedzsmentjében és a vásárlói élmény forradalmasításában egyaránt úttörő szerepet játszanak. A vállalat fejlesztései között kiemelt helyet foglal el a mesterséges intelligenciára épülő nagy nyelvi modell (LLM), amelyet kifejezetten a kiskereskedelem igényeire szabtak, és évtizedekre visszanyúló Walmart-adatokra építettek. Ez a modell természetes nyelvi interfészén keresztül képes valós időben válaszolni az ügyfelek kérdéseire, személyre szabott ajánlásokat nyújtani, és optimalizálni az ügyfélszolgálati folyamatokat.

A generatív mesterséges intelligencia szintén központi szerepet kapott a vállalat stratégiájában. Az online és fizikai boltokban történő vásárlói interakciók személyre szabásától kezdve az egyedi, ügyfélspecifikus termékajánlatokig a Generatív Mesterséges Intelligencia ⁴(Gen AI) alkalmazása lehetővé teszi a hiper-személyre szabott vásárlási élmények létrehozását. A Walmart tartalomdöntési platformja az MI és a GenAI segítségével képes az ügyfélpreferenciák elemzésére, és ezek alapján egyéni ajánlásokat készíteni, ami növeli a vásárlók elégedettségét és a lojalitást.

A kiterjesztett valóság (AR) technológiák alkalmazása szintén forradalmasítja az online vásárlási élményt. Az AR-platform segítségével a vásárlók 3D-s modelleken keresztül vizualizálhatják a termékeket, például bútorokat, és megnézhetik, hogyan illeszkednek azok a saját otthonukba. Ez nemcsak az ügyfélkapcsolatok javításában játszik szerepet, hanem jelentősen csökkenti a visszaküldési arányokat is, mivel a vásárlók már a döntéshozatali folyamat korai szakaszában pontos képet kapnak a termékekről.

⁴ mesterséges intelligencia technológia, amely képes új tartalmak – például szövegek, képek vagy adatelemzések – létrehozására és a meglévő információk alapján kreatív megoldások generálására

A Walmart MI-alapú rendszerei az ellátási lánc optimalizálásában is kulcsszerepet játszanak. Az MI képes előrejelezni a keresletet és azonosítani a szállítmányozási folyamatok potenciális problémáit. Például, ha egy szállítási útvonalon akadály lép fel – legyen szó forgalmi dugóról, időjárás problémáról vagy természeti katasztrófáról –, az MI valós időben elemzi az alternatív lehetőségeket, és javaslatot tesz az optimális megoldásra. Ezáltal a vállalat minimalizálni tudja a késéseket és biztosítani tudja az ellátási lánc zavartalan működését.

Ezek az innovációk növelik a működési hatékonyságot, továbbá a fenntarthatóságot is elősegítik. Az MI és az AR technológiák optimalizálják a szállítási útvonalakat, csökkentik az energiafelhasználást és az üvegházhatású gázok kibocsátását.

A vállalat továbbá az immerszív kereskedelmi élmények fejlesztésével, például az avatár-alapú vásárlási platformok bevezetésével igyekszik elérni az új generációs vásárlókat, akik számára a vásárlás egyre inkább szociális és játékos élménnyé válik.

A Walmart példája mutatja, hogy az MI, a GenAI és az AR integrációja nemcsak az ügyfélélmény javításában, hanem az ellátási lánc rugalmasságának és hatékonyságának növelésében is döntő szerepet játszik. Ezek a technológiák alkalmazásával proaktívan reagáljon a piaci változásokra, és biztosítsa a fenntartható növekedést a globális kiskereskedelemben.

2.10.2 SAP Signavio, GenAI:

Az SAP a mesterséges intelligenciával kapcsolatos kezdeményezései több területet is érintenek, beleértve, de nem kizárólagosan, a gépi tanulást, a természetes nyelvfeldolgozást és az intelligens robotikus folyamat automatizálást⁵ (RPA).

A Gen AI az egyik legmeghatározóbb technológiai újítás, amely alapvetően alakítja át a vállalatok működését és az üzleti folyamatokat, alapjaiban forradalmasíthatja a vállalati működés szinte minden aspektusát – a pénzügyi, értékesítési és marketing alapfunkcióktól kezdve egészen a napi adminisztratív feladatokig. (SAP, 2024)

„Hogy érzékeltessük ennek potenciális hatását, a McKinsey becslése szerint a GenAI évente 2,6-4,4 billió dolláros gazdasági növekedést generálhat. Ez hatalmas változást jelez, ahogy a világ minden táján a különböző méretű vállalatok alkalmazkodnak ehhez az üzleti átalakulás új hullámához. A változás ráadásul gyorsan érkezik: a Morgan Stanley előrejelzése szerint a következő három évben a vállalatok több mint 40%-ára hatással lesz a GenAI. Ami igazán

⁵ olyan technológia, amely mesterséges intelligenciát és gépi tanulást alkalmaz az ismétlődő üzleti folyamatok automatizálására, csökkentve a manuális munkát és növelve a hatékonyságot.

különlegessé teszi, az az, hogy képes összekötni az üzleti transzformációt a technológiával. Demokratizálja a tudásalapú feladatokat, lehetővé téve, hogy több ember generáljon hasznos betekintéseket anélkül, hogy erősen támaszkodnia kellene speciális technológiai csapatokra. Ennek a szélesebb körű bevonásnak köszönhetően várhatóan az üzleti transzformáció szélesebb körű megközelítései jelennek meg, javítva a hatékonyságot, a gyorsaságot, az együttműködést és a magabiztos döntéshozatalt.” (Pandya, 2024)

Az SAP elkötelezett az MI integrálása mellett, hogy releváns, megbízható és felelősségteljes megoldásokat nyújtson, a GenAI lehetőségei segítenek a vállalatoknak agilisebbá válni, piaci pozíciójukat bővíteni és kínálatukat fejleszteni. Bár a hatása még kibontakozóban van, már most látható, hogy kulcsszerepet játszik az üzleti átalakulások felgyorsításában és az innováció előmozdításában. Azok a vállalatok, amelyek alkalmazkodnak ezekhez a változásokhoz, versenyelőnyt szerezhetnek az MI-vezérelt világban.

Az SAP Signavio megoldások, mélyreható változásokat ígérnek az üzleti folyamatok kezelésében és optimalizálásában. Az SAP célja, hogy a vállalatok számára elérhetővé tegye az üzleti átalakulás új generációját, amely hatékonyabb működést biztosít, stratégiai előnyöket nyújt. A GenAI eszközök lehetőséget adnak arra, hogy az üzleti folyamatokat automatizálják, miközben megmarad az emberi kreativitás és stratégiai gondolkodás szerepe. Platformjában integrált eszközök képesek valós időben elemezni az üzleti folyamatokat, ajánlásokat adni a folyamatok optimalizálására, valamint interaktív módon bemutatni az adatokból nyerhető következtetéseket. Ahogy az SAP szakértői is kiemelik, „a generatív mesterséges intelligencia képes összekötni az üzleti transzformációt a technológiával, lehetővé téve a nem technikai háttérű felhasználók számára, hogy releváns betekintéseket nyerjenek és gyors döntéseket hozzanak”. (SAP, 2024)

A kulcsszerepe az üzleti folyamatokban nem csupán a hatékonyság növelésében rejlik, hanem abban is, hogy az adatok felhasználásának módját radikálisan alakítja át. Az MI-asszisztált folyamat-elemzőknek például a felhasználók természetes anyanyelven tehetnek fel kérdéseket, és azonnal releváns válaszokat kapnak.

Az SAP Signavio további újítása, a "folyamat-ajánló" funkció, amely több mint 5000 üzleti gyakorlatot tartalmazó adatbázisra építve segíti a felhasználókat abban, hogy gyorsan és egyszerűen optimalizálják folyamataikat. Ez a funkció előre konfigurált modelleket kínál, amelyeket a felhasználók testre szabhatnak, ezzel jelentősen felgyorsítva az üzleti folyamatok tervezését és megvalósítását. Az SAP e megoldások fejlesztése során hangsúlyt helyezett a relevanciára, a megbízhatóságra és a felelősségteljes alkalmazásra. Ez a szemlélet biztosítja, hogy a hatékony üzleti transzformáció fenntartható és etikus módon valósuljon meg.

3 Saját kutatás és javaslatok

3.1 Előrejelzés és keresletkezelés

Az elméleti kutatás alapján megállapítható, hogy egy vállalat működésében kiemelt szerepet játszik az előrejelzés és keresletkezelés. Ezek elengedhetetlenek a készletgazdálkodás, a termelés, valamint a pénzügyi tervezés területein, és hozzájárulnak a kiszolgálási színvonal fenntartásához, ezáltal növelve az ügyfélelégedettséget. A kereslet pontos előrejelzése biztosítja, hogy mindig elegendő mennyiségű termék álljon rendelkezésre a vevői igények kielégítésére. Fontos azonban kiemelni, hogy ez önmagában még nem elegendő a lojalitás kialakításához: ehhez a termék minőségének, illetve a kapcsolódó szolgáltatások színvonalának is meg kell felelniük a vevői elvárásoknak.

Ahogy Jones és Sasser (Jones & Sasser, 1995), valamint Dumond (Dumond, 2000) is megállapította: a kiváló vevői élmény lojalitáshoz vezet, amely nem csupán az ismételt vásárlásokat ösztönzi, hanem új ügyfelek bevonását is elősegíti. Dumond szerint „a lojalitás az, ami hat a vállalat teljesítményére azáltal, hogy növekszik az újvásárlások száma és a vevőmegtartás mértéke”.

A mesterséges intelligencián alapuló rendszerek alkalmazása a vállalatokat képessé teszi a keresleti igények pontosabb előrejelzésére és a termelési, valamint készletgazdálkodási folyamatok hatékonyabb szabályozására. Ilyen rendszerek például elemzik a múltbeli értékesítési adatokat, az időjárás előrejelzéseket, valamint az aktuális gazdasági trendeket.

Saját vállalati tapasztalatunk is rávilágít a problémára: a felsővezetés döntése értelmében a vasmag gyártásához szükséges nano-kristályos szalagokat immár előre méretre vágva szükséges beszerezni a standard méretek helyett. Ez a lépés költségmegtakarítást eredményezhet a vágási és járulékos költségek – például selejt vagy technológiai hulladék – elkerülésével. Ugyanakkor ehhez elengedhetetlen a kereslet pontos ismerete, amelyhez jelenleg kizárólag a Sales osztály által készített előrejelzések állnak rendelkezésre. Ezek azonban saját bevallásuk szerint csupán „gut feeling” alapon készülnek, és egy „living tool”-ként funkcionálnak.

Ezért döntöttem egy MI-alapú FC-validator rendszer fejlesztése mellett, amely magasabb konfidenciaszint mellett képes figyelembe venni a múltbeli fogyásokat, a meglévő előrejelzéseket, valamint azok teljesülését, és ezek alapján képes a rendelési mennyiségekre vonatkozóan pontosabb ajánlást adni, melynek köszönhetően optimalizálni a készletszinteket.

3.1.1 Előnyök és hátrányok

A fejlesztés megkezdése és megvalósítása előtt szükséges feltárni az előrejelzés és keresletkezelés terén alkalmazni kívánt megoldás várható előnyeit és hátrányait:

Előnyei és lehetőségei:

Adatok gazdagsága: Az előző évek értékesítési adatai rendelkezésre állnak, mint ahogy az akkori előrejelzési adatok is.

Rugalmas szoftver környezet: Excel és Python programok elérhetők, amelyek kiválóan alkalmasak az adatok gyors és akár valós idejű feldolgozására és elemzésére.

Pontosabb előrejelzések: A gépi tanulás alkalmazásával lehetőség nyílik pontosabb és részletesebb előrejelzések készítésére, javíthatja a készletgazdálkodást és a termelési hatékonyságot.

Versenyelőny szerzése: Az előrejelző képességek fejlesztése versenyelőnyt jelenthet a piacon, és növelheti a vállalat piaci részesedését.

Új üzleti lehetőségek: Az MI segítségével akár felfedezhetők olyan új üzleti lehetőségek, amelyekre korábban nem lett volna mód.

Hátrányai és potenciális problémák:

Adatok minősége és pontossága: A rendelkezésre álló adatok helyenként hiányosak vagy hibásak lehetnek, negatívan befolyásolhatja az eredmények pontosságát.

Technológiai készségek hiánya: A vállalatnál nem volt precedens az MI és adatelemzés területén, így az ismeretek hiánya helytelen végeredményeket adhat.

Finanszírozási korlátok: Az új technológiák bevezetése és az infrastruktúra fejlesztése jelentős pénzügyi befektetéseket igényelhet, de a kezdetleges verzió költségei jelentéktelenek.

Piackörülmények változása: A piaci változások és az ügyfélpreferenciák változása befolyásolhatják az előrejelzéseket és a keresletkezelést, amelyre adatok kis mennyiségben állnak rendelkezésre.

Technológiai fejlődés: Más vállalatok is fejleszthetnek hasonló technológiákat, ami versenyhelyzetet teremthet.

Adatvédelmi és biztonsági kockázatok: Az adatok védelme és biztonsága kritikus fontosságú, és a támadások vagy adatvesztések jelentős kockázatot jelenthetnek.

3.1.2 Potenciális megoldások metodikája

3.1.2.1 Adatgyűjtés és tisztítás

Elsősorban adatok gyűjtése és tisztítása a legfontosabb, az összes releváns adat összegyűjtése, beleértve az értékesítési adatokat, a termelési adatokat - későbbiekben a piaci trendeket. A kutatás során az összes releváns adat összegyűjtésére törekedtem, beleértve az értékesítési és termelési adatokat, valamint – a későbbi modellfejlesztéshez – a piaci trendekre vonatkozó információkat is. A dolgozatban felhasznált adatok a Magnetec-Ungarn Kft. vállalati információs rendszeréből (ABAS ERP) származnak, amely a Magnetec Group nemzetközi vállalatcsoport magyarországi gyártóegységeként működik. A cég 1994-ben alakult, székhelye Gyöngyösön található, és mára a csoport egyik kulcsfontosságú termelőbázisává vált.

A Magnetec Group központja Németországban, Hanau városában található, és világszerte több leányvállalattal rendelkezik, többek között USA-ban, Kínában, Vitanámban, Malajziában és Moldovában. A vállalatcsoport több, mint négy évtizedes szakmai tapasztalattal rendelkezik a nanokristályos ötvözetekből készült mágneses anyagok és komponensek fejlesztésében és gyártásában. Termékei, például a feszültség- és áramérzékelők, transzformátorok, fojtótekercek és elektromágneses árnyékolások az elektromos energiaátvitel, az autóipar és az elektronikai ipar korszerű megoldásaiban segítenek,

A vállalat tevékenységi köre elsősorban a fojtók és transzformátormagok gyártására, valamint az ehhez kapcsolódó szerelési, ellenőrzési folyamatokra terjed ki. A vállalat ISO 9001 illetve IATF 16949 szabvány szerinti tanúsítottasága biztosítja a termékek állandó minőségét és a vevői elvárásoknak való megfelelést.

A kutatásom során felhasznált adatok a vállalat termelési, értékesítési, logisztikai és készletgazdálkodási moduljaiból kerültek exportálásra. Az ERP-rendszerben rögzített adatok valós, napi szinten frissített üzleti információkat tartalmaznak, amelyeket a belső kontrolling és riportálási folyamatok rendszeresen validálnak. Az adatok hitelességét tovább erősíti, hogy ezek képezik alapját a saját fejlesztésű vállalati vezetői döntéstámogató és beszámolási rendszereinek is.

Így a felhasznált adathalmaz megbízható, auditált és reprezentatív képet nyújt a vállalat működéséről és megfelelő alapot szolgáltat a mesterséges intelligencia-alapú előrejelző és készletoptimalizáló modell fejlesztéséhez.

Az adattisztítás a mesterséges intelligencia-alapú rendszerek alkalmazásának előkészítő lépése, amely alapvetően meghatározza a további elemzések és előrejelzések pontosságát. A folyamat

célja, hogy az adathalmazokban található hibákat, hiányosságokat és inkonzisztenciákat megszüntesse, így biztosítva a megbízható és értelmezhető adatokkal való munkát. Az egyik első lépés a duplikált vagy irreleváns adatok eltávolítása, hiszen ezek gyakran torzítják az elemzések eredményeit, és növelik a feldolgozás erőforrásigényét (Salesforce, 2025).

Emellett a strukturális hibák, például az elnevezési eltérések, elgépelések vagy formázási problémák javítása is kulcsfontosságú, mivel ezek megakadályozhatják az adatok összekapcsolását és elemzését (Amplitude, 2024).

Fontos feladat a kiugró értékek kezelése is, mivel ezek a szélsőséges adatok jelentősen befolyásolhatják az algoritmusok működését, és téves következtetésekhez vezethetnek. Az ilyen értékek kezelésének módja a kontextustól függően változhat – előfordulhat, hogy érdemes megtartani őket, ha valós folyamatokat tükröznek, de sok esetben célszerű kiszűrni vagy korrigálni őket. A hiányzó adatok kezelése szintén elengedhetetlen: ezek pótlására különböző módszerek alkalmazhatók, például az adott változó átlagának, mediánjának vagy móduszának beillesztése, de bonyolultabb esetekben gépi tanulási algoritmusokkal is történhet interpoláció. Végül, az adatok standardizálása biztosítja, hogy minden adatmező egységes formátumban szerepeljen, például azonos mértékegységek vagy dátumformátumok szerint. Ez elengedhetetlen az összehasonlításokhoz, összesítésekhez és az adatkapcsolatok felismeréséhez (Amplitude, 2024). Tehát az adattisztítás nemcsak technikai lépés, hanem az adatminőség biztosításának záloga.

Adatgyűjtés folyamán előfordult, hogy egy adott hónapra nem volt aktualizálva előrejelzés, így a "Last Observation Carried Forward" (LOCF) módszert alkalmaztam, amely egy klasszikus idősortöltési technika, melyet leggyakrabban orvosi statisztikában, idősortelemzésben és forecast validációban használnak.

3.1.2.2 Algoritmusok és modellek kiválasztása

Az előrejelzések készítéséhez használt MI-algoritmusok és modellek kiválasztása kulcsfontosságú lépés, hiszen az alkalmazott módszer jelentősen befolyásolja az előrejelzés pontosságát és hasznosságát. A modellek közül több típus is elterjedt a gyakorlatban, különösen a kereslet-előrejelzés területén, attól függően, hogy milyen típusú adatok állnak rendelkezésre és mi az üzleti cél. (Brownlee, 2017)

Idősoros modellek (Time Series Forecasting Models):

Az idősoros modellek olyan történeti adatokat használnak, amelyek időrendben rendezettek – például heti vagy havi értékesítési számok. Ide tartoznak:

- **ARIMA** (AutoRegressive Integrated Moving Average): jól alkalmazható, ha az adatok időbeli trendet mutatnak.
- **SARIMA** (Seasonal ARIMA): ARIMA kiterjesztése szezonálitásra. (Brownlee, 2017)

Esetemben, ahol a cél egy MI-alapú FC-validator rendszer fejlesztése, a gépi tanulás alapú regressziós modellek (pl. Random Forest vagy XGBoost) és LSTM neurális hálózatok lehetnének a legmegfelelőbbek. Ezek képesek kezelni a múltbeli eladási adatok, az aktuális forecast és a külső tényezők (pl. naptári hatások, ünnepek) közötti nemlineáris összefüggéseket is.

Azonban én kisebb adatbázisból dolgozom, és kevés külső változó áll a rendelkezésemre, érdemes kezdetben idősoros modellel, ARIMA-val kezdeni, és később továbblépni a bonyolultabb modellekre.

3.1.3 Modell képzése és validáció

Mindenek előtt egy statikus rendszer felépítése szükséges, amivel manuálisan ellenőrizhető, hogy mi is történt. Ez elengedhetetlen része a későbbi prediktív rendszer kialakításának. Training data néven egy adathalmazt hoztam létre valós előrejelzésekből a 2020–2023 közötti időszakot felhasználva. A training adat (Táblázat 1) az előrejelzési fájlokból került kialakításra, ahol minden sor egy adott cikkszámhoz és célidőszakhoz tartozó előrejelzést tartalmaz, valamint azt az időpontot, amikor ez az előrejelzés készült. A training data struktúrája a következő:

Táblázat 1 Training adat

EKS	Artikkel	Attribute	Value	Dataset	Date	Actual Value	Abs error	MAPE	Signed error	PE
10610	180992603_10610	2020.07.01	10800	2020.07.01	2020_7	0	10800	100%	-10800	-100%
10610	180992603_10610	2020.08.01	10800	2020.07.01	2020_8	10800	0	0%	0	0%
10610	180992603_10610	2020.09.01	10800	2020.07.01	2020_9	10800	0	0%	0	0%
10610	180992603_10610	2020.10.01	10800	2020.07.01	2020_10	0	10800	100%	-10800	-100%
10610	180992603_10610	2020.11.01	10800	2020.07.01	2020_11	10800	0	0%	0	0%
10610	180992603_10610	2020.12.01	10800	2020.07.01	2020_12	0	10800	100%	-10800	-100%
10610	180992603_10610	2021.01.01	10800	2020.07.01	2021_1	0	10800	100%	-10800	-100%
10610	180992603_10610	2021.02.01	10800	2020.07.01	2021_2	0	10800	100%	-10800	-100%

Forrás: saját szerkesztés

Az Attribute mezőket konvertáltam szabványos időbélyeggé (YYYY-MM formátumban), így jött létre a Date oszlop, ami már lehetővé teszi a tényleges adatokkal való kapcsolást. A következő lépésként a valós kiszállítási adatokat (Actual Value oszlop) külön adatforrásból töltöttem be,

melyek tartalmazták a cikkszámot, megnevezést, a tényleges szállítás időpontját, valamint a kiszállított mennyiséget. Az értékesítésekhez tartozó dátum adatokat szintén időbélyegre konvertáltam, majd havi szintre aggregáltam, hogy összehasonlíthatóak legyenek az előrejelzésekkel, amely adatot a Value oszlop tartalmazza.

Miután az előrejelzési adatokat és a valós értékesítési adatokat ugyanarra az időtengelyre helyeztem, összekapcsoltam őket cikkszám és hónap alapján. Így minden egyes előrejelzési sorhoz hozzá tudtam rendelni a megfelelő valós kiszállítási adatot, amennyiben az rendelkezésre állt. A kapcsolt adatokból már ki tudtam számítani a legfontosabb hibaértékeket, úgy, mint az abszolút eltérést (abs error), amely a Forecast és az Actual értékek különbségének abszolút értéke, illetve a MAPE-t, amely százalékos eltérésként mutatja meg az előrejelzés pontosságát.

A MAPE érték számítása során nullával való osztás esetén 100%-os eltérést állapítottam meg. Ez egy tudatos döntés volt annak érdekében, hogy a nulla tényleges felhasználás melletti előrejelzés teljes mértékű hibaként jelenjen meg a kiértékelésben. Bár statisztikailag a nullával való osztás nem értelmezhető (a hibák átlagolása során a statisztikailag nem kezelhető esetek torzítják az eredményt), az üzleti gyakorlatban indokolt lehet az ilyen eseteket 100%-os hibaként kezelni, különösen akkor, ha az előrejelzés tévesen jelez keresletet ott, ahol ténylegesen nem történt felhasználás.

A statikus validáció során nemcsak a hibák nagyságát, hanem azok irányát is vizsgáltam. Ehhez az abszolút eltérés mellett kiszámoltam az ún. Signed Error értékeket is, amelyek megőrzik az előjel információját. Ez lehetővé teszi annak az elemzését, hogy az előrejelzések rendszeresen túl- vagy alábecsülik-e a tényleges keresletet. A százalékos változat (Percentage Error, PE) alkalmazásával pontosabb képet kaphatunk a forecast rendszer torzításairól, melyek hosszú távon jelentős készletproblémákat okozhatnak.

Az így létrehozott táblázat lehetővé teszi az előrejelzések minőségének értékelését különböző dimenziók mentén. Egyrészt vizsgálható, hogy egy adott FC fájl – például a 2023. márciusában készült előrejelzés – mennyire pontosan jelezte előre a későbbi hónapok tényleges értékeit.

Másrészt összehasonlíthatók a cikkszámok előrejelzési pontosságai, így feltérképezhető, hogy mely cikkszámokra születnek megbízhatóbb vagy éppen pontatlanabb FC-k. Harmadrészt az is vizsgálható, hogy az előrejelzések megbízhatósága hogyan változik az időhorizont függvényében – például pontosabb-e az FC egy hónappal a célhónap előtt, mint három hónappal korábban.

Ez a statikus validációs rendszer nem csupán kézi ellenőrzésre alkalmas, hanem alapjául szolgál egy későbbi prediktív modellnek is. Egy ilyen modell a múltbeli előrejelzések és eltérések alapján képes lehet megjósolni, hogy egy újonnan beérkezett FC fájl milyen pontossággal becsüli meg a

jövőbeni felhasználást. A jelenlegi rendszer tehát egyfajta „tükör”, amely visszajelzést ad az FC-k minőségéről, és egyúttal ugródeszkeként szolgálhat egy automatizált, gépi tanuláson alapuló FC-értékelő algoritmus felé. Az előrejelzések pontosságát éves és havi bontásban elemeztem a MAPE és PE mutatók segítségével. A vizsgálat alapján megállapítható, hogy 2020–2022 között az FC-k rendszeresen túlbecsülték a valós keresletet, amely különösen a COVID-19 járvány első éveiben, 2020-ban és 2021-ben, valamint 2022-ben öltött extrém méreteket.

A világjárvány okozta keresleti sokkok, ellátási lánc zavarok, valamint az előrejelzési modellek korlátozott alkalmazkodóképessége a bizonytalan környezethez olyan mértékű torzításokat eredményeztek, amelyeket az extrém magas MAPE és a jelentősen negatív PE értékek is világosan tükröznek. A PE mutató értelmében ezekben az időszakokban a vállalat folyamatosan felülbecsülte a keresletet, vagyis nagyobb mennyiségeket jósolt, mint amennyi ténylegesen realizálódott, ami készletfeleslegekhez és indokolatlan gyártási vagy beszerzési kapacitásokhoz vezetett.

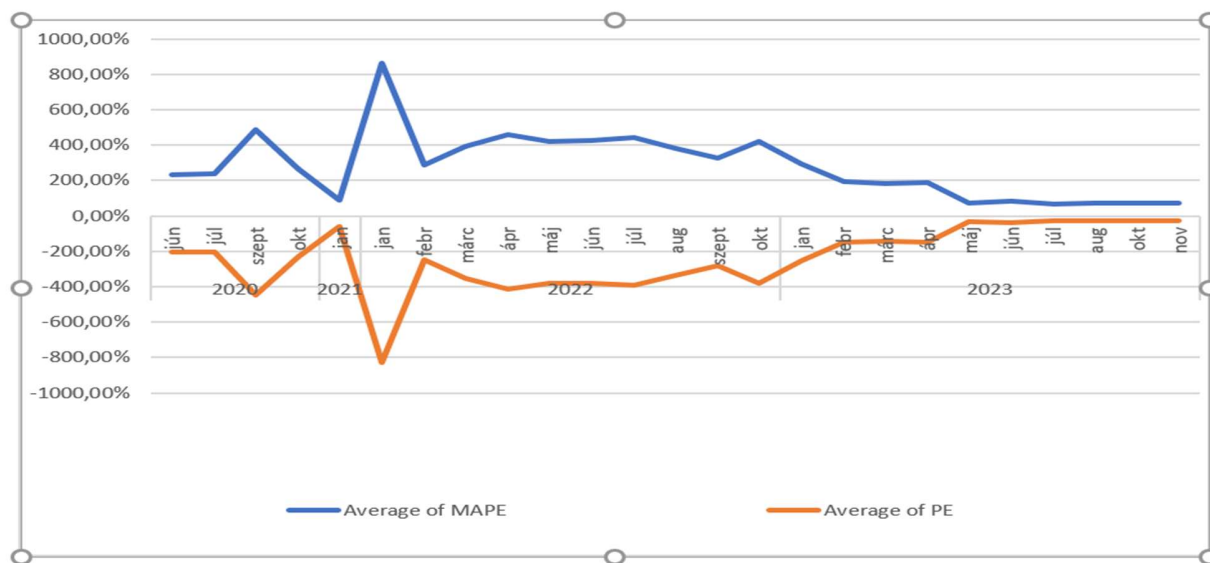
Táblázat 2 Átlagos MAPE és PE értékek havi bontásban (2020–2023)

Dataset	Average of MAPE	Average of PE
2020	302,01%	-267,60%
jún	232,84%	-201,42%
júl	240,10%	-204,49%
szept	487,01%	-448,90%
okt	263,93%	-230,87%
2021	90,71%	-57,76%
jan	90,71%	-57,76%
2022	444,98%	-401,51%
jan	861,46%	-825,23%
febr	286,52%	-247,74%
márc	394,88%	-354,00%
ápr	461,40%	-413,20%
máj	422,46%	-379,14%
jún	426,83%	-380,53%
júl	442,51%	-390,84%
aug	380,88%	-336,72%
szept	324,10%	-279,63%
okt	420,45%	-379,96%
2023	129,59%	-85,74%
jan	294,60%	-254,70%
febr	195,33%	-149,59%
márc	184,73%	-143,07%
ápr	190,31%	-147,42%
máj	73,45%	-30,39%
jún	81,94%	-38,44%
júl	69,62%	-24,84%
aug	73,20%	-28,13%
okt	70,17%	-25,53%

Forrás: saját szerkesztés

A 2023-as év azonban már egyértelműen javuló tendenciát mutatott. Bár az év elején még érzékelhető maradt a túlbecslés, az év második felére a PE értékek jelentősen mérséklődtek, és az MAPE is elfogadható szintre csökkent (Táblázat 2). Ez arra utal, hogy az előrejelzések készítője fokozatosan visszanyerte predikációs képességét a pandémiát követő normalizálódás során. Az előrejelzések egyre inkább közelítettek a valós kereslethez, ugyanakkor a negatív PE értékek továbbra is azt sugallják, hogy – óvatossági vagy más üzleti okokból – még mindig inkább hajlik a túlbecslésre.

Mindezek alapján megállapítható, hogy a MAPE és a PE együttes alkalmazása lehetővé teszi a pontatlanság mértékének és a hibák irányának értelmezését is. Míg a MAPE jól mutatja az eltérés nagyságát, addig a PE feltárja a forecast szisztematikus torzításait (Ábra 2). A PE időbeli elemzése tehát nemcsak hasznos kiegészítő, hanem stratégiai szempontból is indokolt, különösen olyan üzleti környezetben, ahol a kereslet kiszámíthatatlansága fokozott kockázatot jelent az ellátási lánc egészére nézve. A rendszeres PE-alapú visszacsatolás beépítése a forecast validációs gyakorlatba hozzájárulhat a torzítások időbeli felismeréséhez és a hosszú távú előrejelzési stratégia megbízhatóságának növeléséhez.



Ábra 2 A MAPE és PE értékek alakulása 2020–2023 között – A kék vonal a havi átlagos MAPE (átlagos abszolút százalékos hiba) értékek változását mutatja, míg a narancssárga vonal a PE (előrejelzési eltérés) trendjét jelzi. Forrás: saját szerkesztés

Ugyanakkor az elemzés során egy másik, rendszerszintű problémára is fény derült: számos olyan gyártási tétel jelent meg a valós kiszállításokban, amelyhez semmilyen előrejelzés nem társult az FC fájlokban. Ezek a „forecast nélküli” mennyiségek arányukban ugyan kisebbnek tűnnek – átlagosan a teljes gyártott volumen 5–10%-át tették ki –, stratégiai szempontból azonban

jelentőségük messze túlmutat ezen. Az aggregált adatok alapján ezek a nem előrejelzett gyártások a valós Kraljic mátrix szerinti stratégiai alapanyag-felhasználás akár 60%-át is kitehetik, különösen olyan esetekben, ahol kritikus, hosszú beszerzési idejű komponensekről van szó.

Ez a jelenség komoly kockázatot hordoz magában: nem csupán a forecast rendszer prediktív erejét csökkenti, hanem az ellátási lánc többi pontját is veszélyezteti, mivel előre nem jelzett igényekre történő gyártás esetén az alapanyagellátás, kapacitásallokáció és készlettervezés megalapozottsága is kérdésessé válik. Mindez arra utal, hogy az előrejelzés nem csupán pontatlan lehet bizonyos esetekben, hanem inkomplett is, azaz nem fedi le maradéktalanul a tényleges termelési igényeket. Ezért a jövőbeni fejlesztések során nemcsak az előrejelzések pontosságának növelésére kell fókuszálni, hanem azok teljességének biztosítására is. Ennek érdekében célszerű lehet automatizált eszközök bevezetése, amelyek rendszeresen azonosítják a forecast nélküli gyártásokat, és visszacsatolást nyújtanak az előrejelzési rendszer számára. Ezáltal nemcsak a prediktív képesség, hanem az egész ellátási lánc tervezhetősége és reagálóképessége is javítható.

Ezt követően előkészítem az adatokat a modellhez.

3.1.4 MI-alapú modellterv és fejlesztési koncepció

A statikus validációs rendszer kialakítását követően koncepcionális szinten megkezdődött egy mesterséges intelligencia alapú előrejelzés-értékelő rendszer megtervezése. A cél egy olyan algoritmus megalkotása, amely képes automatikusan kiértékelni az FC fájlokban szereplő előrejelzéseket, és ezekhez megbízhatósági szintet rendelni.

A fejlesztési koncepció az alábbi lépések köré épül:

Prediktorváltozók kiválasztása: Elsődlegesen olyan bemeneti tényezők kerülnek figyelembe vételre, mint a forecast készítési ideje, múltbeli MAPE és PE értékek, cikkszám-szintű eltérések, valamint időszaki szezonális hatások.

Algoritmus-jelöltek azonosítása: A legmegfelelőbb algoritmus kiválasztása céljából különböző gépi tanulási megközelítések kerülnek értékelésre – például lineáris regresszió, random forest, valamint idősoros elemzést támogató LSTM-alapú neurális hálózat – de kezdetben ARIMA-t használunk.

Tesztelési és validálási keretrendszer felépítése: Az adatok elkülönítése tanulási és tesztelési halmazra (például 80/20 arányban), valamint az előrejelzések hibáinak értékelése különböző metrikák alapján, mint például RMSE, MAE, MAPE.

A modell jelenleg is tervezési fázisban van. A konkrét implementáció eddig még nem történt meg, azonban a validációs logika és a szükséges bemeneti adatszerkezetek már rendelkezésre állnak. A gyakorlati alkalmazás lehetőségét egy következő fejlesztési szakasz során lehet megvalósítani, ahol Python környezetben történhet meg a modellépítés, betanítás és prediktív funkciók integrálása.

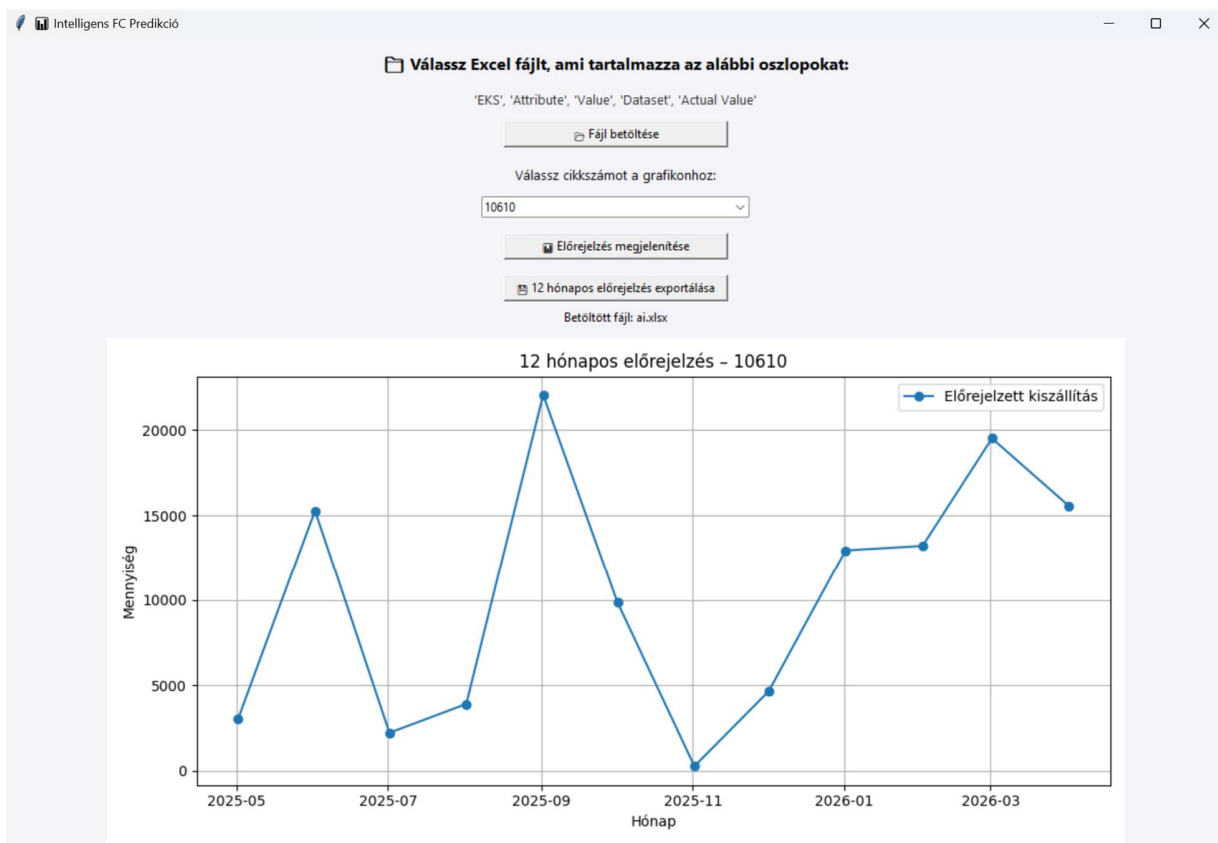
A teljes folyamat időigényességét jól példázza, hogy már az adattisztítás és előkészítés, valamint a megfelelő bemeneti változók kiválasztása is jelentős manuális és elemzői munkát igényelt. A jövőbeni MI-rendszer betanítása (különösen idősoros vagy LSTM modellek esetén) hosszabb tréningidőt és számítási kapacitást is megkövetelhet, ahogyan azt több szerző – például Brownlee (2017) – is kiemeli. Az MI-alapú előrejelzési modellek kialakítása során nem csupán a megfelelő algoritmus kiválasztása a kihívás, hanem a folyamatos kiértékelés, finomhangolás és újratanítás is elengedhetetlen a megbízható működéshez.

A jelenlegi fázis tehát a koncepcióalkotás és az adatkészlet felépítése, amely stabil alapot adhat egy következő szakaszban megvalósítandó automatizált FC-validátor MI-rendszerhez.

3.1.5 A modell bemutatása

A manuális értékelésre és elemzésre alkalmas statikus rendszer kialakítása után elérkezett a pont, ahol az automatizáció és a prediktív modellezés megjelenése indokolttá vált. Az eddigiekben gyűjtött előrejelzési és kiszállítási adatok lehetőséget adnak egy olyan mesterséges intelligencia-alapú alkalmazás megvalósítására, amely nemcsak visszatekintően vizsgálja a forecast teljesülését, hanem aktívan képes prediktív módon becsléseket is adni a jövőbeli várható teljesítésekre.

Ennek érdekében egy Python nyelven fejlesztett, grafikus felhasználói felülettel (GUI) ellátott alkalmazás készült, amely a ARIMA algoritmus segítségével tanulja meg a múltbeli FC viselkedésmintákat, és ez alapján képes előrejelezni a következő 12 hónap várható valós kiszállításait. A modell bemeneti változói között szerepel a forecastált mennyiség (Value), a célhónap (Month) és a leadási idő (azaz a forecast készítésének időpontja és a célhónap közötti különbség, Lead_Time). Ezek a jellemzők elegendő információt nyújtanak ahhoz, hogy a rendszer felismerje azokat a mintázatokat, amelyek alapján a múltban egy előrejelzés teljesült vagy megbukott.



Ábra 3 Az kezdetleges FC-validátor grafikus felülete és 12 hónapos előrejelzési kimenete. Forrás: saját fejlesztés.

Az alkalmazás (Ábra 3) kezelése egyszerű: a felhasználó betölti az előre definiált struktúrájú Excel fájlt, amely tartalmazza az EKS, Attribute, Value, Dataset, és Actual Value mezőket. A rendszer ezután automatikusan kiszámítja a jellemzőket, betanítja a modellt, majd a felhasználó által kiválasztott cikkszámra vonatkozóan 12 hónapos előrejelzést készít. Az eredmények interaktív grafikonon jelennek meg, emellett egyetlen gombnyomással exportálhatóak egy új Excel fájlba is, ami különösen hasznos az üzleti riportolás és döntéstámogatás szempontjából.

A modell működéséből adódóan előnyként emelhető ki, hogy képes figyelembe venni az előrejelzés készítésének időzítését és annak hatását a teljesülésre. Emellett gyors, jól skálázható, és egy cikkszám-szintű forecast validációt is lehetővé tesz. Ugyanakkor a rendszer jelenlegi verziójában korlátozásként jelentkezik, hogy a egyszerre csak egy cikkszámra alkalmazható, és nem képes komplex szezonális mintázatok felismerésére, illetve kezelésére. Továbbá a forecast nélküli, de megtörtént kiszállításokra sem tud predikciót adni, hiszen azokból nem áll rendelkezésre elégséges tanulási minta.

Mindemellett az alkalmazás egyértelműen demonstrálja a gépi tanulási alapú forecast validáció működőképességét, és bizonyítja, hogy a statikus hibaméréstől elmozdulva valós prediktív

modellek is építhetőek a rendelkezésre álló adatállományból. A következő lépésben a modell tökéletesítése, a többszörös cikkszámra történő párhuzamos feldolgozás lehetőségének megteremtése, valamint a szezonalitást és trendeket is figyelembe vevő idősoros modellek, például LSTM-hálózatok integrálása jelentheti a fejlődési irányt. Ezzel a rendszer már nemcsak validátorként, hanem valódi, intelligens FC-támogató eszközként is szolgálhatna a vállalati döntéshozatalban.

A modell bemutatása során meg kell jegyezni, hogy ez még „csak” egy béta verzió, amely ugyan már működőképes, képes előrejelzéseket készíteni, de predikciós pontossága még nem éri el azt a szintet, amely üzleti szempontból teljes mértékben megbízhatónak tekinthető. A rendszer általános logikája és felépítése stabil, azonban a gyakorlati használathoz további tanításra, validációra és finomhangolásra van szükség.

Ennek oka, hogy a tanítás jelenleg teljes mértékben a meglévő történeti adatokra épül, és nem minden cikkszám esetében áll rendelkezésre kellő mennyiségű és minőségű adat ahhoz, hogy a modell megalapozott predikciókat készítsen. Emellett a modell jelenlegi formájában átlagos forecast értékekkel dolgozik a jövőbeni 12 hónap előrejelzéséhez, ami bizonyos cikkszámoknál megfelelő becslést adhat, másoknál viszont alul- vagy túlbecsléshez vezethet.

Ezáltal előfordulhat, hogy az olyan termékeknél, amelyek kereslete erősen időszakos (pl. negyedéves vagy éves ciklikusságot mutat), a modell nem képes megfelelően lekövetni az ingadozásokat. Ezen kívül az outlierok – például egyes extrém magas vagy nulla értékek – kezelése jelenleg nem automatizált, így azok torzíthatják a tanulási folyamatot és a predikciós kimeneteket is.

A modell még nem rendelkezik önellenőrző vagy önjavító mechanizmussal, azaz nem épít visszacsatolást a predikció és a valóság közötti különbségek alapján. Ez jelenleg manuális értékeléssel oldható meg, azonban hosszú távon elengedhetetlen lenne egy olyan rendszer bevezetése, amely képes a saját előrejelzési hibáiból tanulni, és újrahangolni a paramétereit.

Tehát a jelenlegi rendszer már jól szemlélteti a prediktív forecast-elemzés működési lehetőségeit, és alkalmas arra, hogy pilot projekt⁶ként bevezetésre kerüljön egy korlátozott termék- vagy cikkszámkörre. Ugyanakkor széles körű vállalati alkalmazásához elengedhetetlen lesz a modell robusztusabbá tétele, a tanulási folyamat mélyítése, valamint a komplexebb előrejelzési mintázatok

⁶ egy kisméretű, korlátozott körben végrehajtott tesztprojekt, amelynek célja, hogy az éles bevezetés előtt kipróbálásra kerüljön egy új rendszer, módszer vagy eszköz működőképessége, ezáltal lehetőséget biztosít arra, hogy a szervezet kockázatmentesen értékelje a bevezetendő megoldás előnyeit, hátrányait, és azonosítsa az esetleges továbbfejlesztési irányokat.

kezelése. Mindezek figyelembevételével a rendszer továbbfejlesztése nem csupán technikai kihívás, hanem stratégiai lehetőség is, amely hozzájárulhat a teljes ellátási lánc tervezhetőségének és reagálóképességének javításához.

3.1.6 A modell integrálása a vállalati tervezési rendszerbe

A modellből kinyert előrejelzési adatok nem csupán kiértékelésre szolgálnak, hanem aktívan felhasználásra kerülnek a vállalati tervezési folyamatban is. A program outputja – azaz a kiválasztott cikkszámra vonatkozó 12 hónapos forecast – közvetlenül betölthető az ABAS vállalatirányítási rendszer Schul mandantjába⁷, ahol a rendszer ezt már integrált FC-ként kezeli. Az ABAS a vállalat sajátos forecast-logikája szerint az előrejelzéseket dinamikusan összeveti a beérkezett vevői rendelések állományával, és minden időszakra vonatkozóan a magasabb értéket veszi figyelembe a termelési és beszerzési tervezés során. Ez a mechanizmus biztosítja, hogy a tényleges piaci igények – különösen a lekötött rendelések – elsőbbséget élvezzenek az előrejelzéssel szemben, ugyanakkor a forecastok sem vesznek el, hanem pufferként szolgálnak a még nem realizált, de várható igényekre.

Az így előálló aggregált terméki igény-mix továbbításra kerül az ABAS APS modul felé, amely az Advanced Planning & Scheduling rendszer rövidítése. Az APS célja a vállalat teljes termelési és kapacitástervezésének automatizálása és optimalizálása. A modul képes figyelembe venni minden gyártási és logisztikai paramétert – úgymint alapanyagok és késztermékek beszerzési és gyártási átfutási ideje (lead time), emberi és gépi kapacitások, gyártási prioritások, beállítási és ciklusidők –, majd ezek alapján egy realisztikus, időalapú gyártási tervet készít. Az APS gyakorlatilag egy digitális gyártási szimulációs motor, már a tényleges gyártás előtt megvizsgálja, mikor és milyen erőforrásigény mellett tudja kielégíteni az előrejelzett vagy megrendelt keresletet.

A szimuláció eredményeképp az APS modul előállít egy termelési tervet, amelyet visszatölt az ABAS ERP rendszerébe. Ez a terv már figyelembe veszi az összes korlátozó tényezőt és ennek megfelelően optimalizálja a gyártási sorrendet, valamint az anyagbeszerzési és termelési ütemezést is.

A frissített adatokra építve egy saját fejlesztésű ABAS Infosystem (100360) automatizáltan kerül lefuttatásra, amely lehetővé teszi, hogy Excel formátumban, vizuálisan áttekinthető módon

⁷ A vállalatnál használt ERP tanulói modulja, amely megegyezik a mindennapokban használt ERP-vel, de különböző szimulációkat végezhetnek benne key userek.

szimuláljuk az elkövetkező 24 hét anyagfelhasználását cikkszámanként. Az Infosystem nyers adathalmazának használatával automatikusan előállított Material balance elnevezésű saját fejlesztésű riport megmutatja, hogy adott előrejelzés és rendelésállomány mellett milyen fogyás várható minden egyes alapanyag esetében. Ez az információ kulcsfontosságú a beszerzési döntések időzítése, a készletszintek beállítása, valamint a kapacitás- és szállítási tervek finomhangolása szempontjából.

Ez a kialakított rendszer biztosítja, hogy a mesterséges intelligenciával támogatott forecast-modellezés nemcsak elméleti elemzés szintjén működjön, hanem integráltan illeszkedjen a vállalat napi operatív működésébe, és valódi, döntéstámogató funkciót töltsön be az ellátási láncban. A modell nem önmagáért, hanem a gyakorlatban történő alkalmazásáért nyeri el valódi értelmét, hiszen képes befolyásolni a vállalat reakcióidejét, készletszintjeit és végső soron a piacra való reagálási képességét.

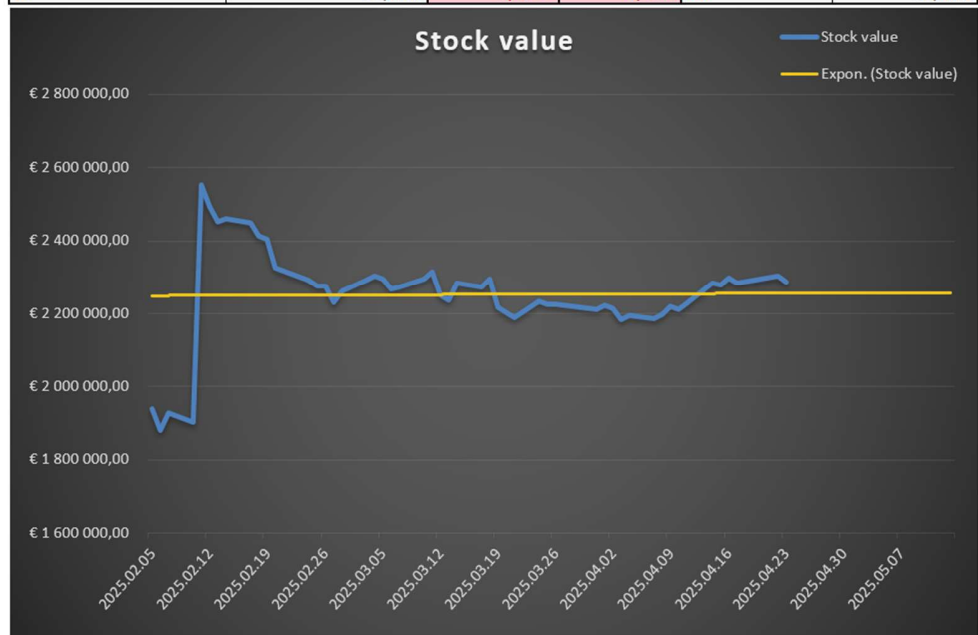
3.2 Készletoptimalizálás a Material Balance jelentés segítségével

A modell integrációját követően a figyelem középpontjába a készletszintek optimalizálása kerül. Ennek gyakorlati megvalósítását a riport (Ábra 4) szolgálja, amely a vállalati döntéshozatal új, automatizált támogatórendszereként jött létre. Az automatizálás célja nemcsak az adatok gyors elérhetősége, hanem azok értelmezhető és stratégiai szintű vizualizálása is volt. A riport az FC-validátor által generált előrejelzéseket, valamint az APS szimulációs eredményeket felhasználva olyan, napi frissítésű jelentést készít, amely átfogó képet nyújt a készletek aktuális és várható állapotáról.

A jelentés utólagos elemzésre is alkalmas, de aktív, proaktív tervezési eszközként is szolgál. A visszatöltött gyártási szimulációk eredményeiből – amelyek már figyelembe veszik az ABAS ERP rendszer teljes beállításkészletét – cikkszám szintű bontásban nyerhetők ki az elkövetkező hetekre vonatkozó pontosított felhasználások. Ez különösen értékes a stratégiai alapanyagok esetében, ahol a beszállítási lead time hosszú, és a készlethiány komoly gyártási kockázatot hordoz. A riport ezért nem pusztán egy készletkimutatás, hanem stratégiai szintű inputot biztosít a vállalat beszerzési és termelési irányításához.

	2025.04.24	Delta	Delta (%)	Last Day	
Stock value	2 301 266,89 €	15 794,85 €	0,69%	Stock value	2 285 472,04 €
CW12 Value	2 742 125,60 €	39 045,88 €	1,42%	CW12 Value	2 703 079,72 €
Avg. Leadtime (days)	24,18	-2,26	-9,36%	Avg. Leadtime	26,45
Minstock (unit)	443 617	0,00	0,00%	Minstock	443 617

Safety stock potential					
	2025.04.24	Delta	Delta (%)	Last Day	
Safety stock value	618 373,82 €	37,47 €	0,01%	Current	618 336,35 €
Optimal safety stock value	145 015,09 €	728,10 €	0,50%	Optimal	144 286,99 €
Optimal if no new safety	42 989,62 €	772,98 €	1,80%	Nominal	42 216,64 €
Possible save on safety	473 358,73 €	- 690,62 €	0,15%	Delta	474 049,36 €
recheck	61,93%	0,00 €	-0,23%	recheck	62,16%
recheck due less	2,36%	0,00 €	0,19%	recheck due less	2,17%
ok	35,71%	0,00 €	0,05%	ok	35,67%




Ábra 4 A készletérték és a biztonsági készlet szint alakulásának napi nyomon követése a Material Balance rendszerben. Forrás: saját szerkesztés

Emellett a rendszer képes operatív döntéstámogatásra is: a beépített algoritmusok figyelik a készlet szinteket, az aktuális fogyást, valamint a már kiadott rendeléseket, és ezek alapján előrejelzik, hogy mely anyagok esetében alakulhat ki ellátási kockázat. Az algoritmus a kalkulált igény és a tényleges beszállítási ütemezés eltéréseiből számított kockázati szint alapján figyelmezteti a beszerzést, ha egy kritikus anyag a vártnál később érkezik, vagy éppen előbb, mint a gyártási terv szerint szükséges lenne. Ezzel a beszerzés képes időben reagálni a potenciális ellátási zavarokra, elkerülve a leállásokat vagy a felesleges készletfelhalmozást.

2025.04.24	OK	PUSH OR DELETE	LATE PO	PO NEEDS	SUM
	10	2	0	0	12
	655	63	2	12	732
	1901	28	0	1	1930
Total	2566	93	2	13	2674
Percentage to SUM	95,96%	3,48%	0,07%	0,49%	

2025.04.24	OK	PUSH OR DELETE	LATE PO	PO NEEDS	Part
	83,33%	16,67%	0,00%	0,00%	0%
	89,48%	8,61%	0,27%	1,64%	27%
	98,50%	1,45%	0,00%	0,05%	72%



Ábra 5 A beszállítói rendelések napi státuszvizsgálata. Forrás: saját szerkesztés

A táblázatok a teljes rendelésállomány aktuális megoszlását mutatják négy kategóriában (Ábra 5): „OK” (időben és a terv szerint teljesülő rendelések), „Push or Delete” (halasztandó vagy törölendő tételek), „Late PO” (késedelmes rendelések) és „PO Needs” (új beszerzési igények). Az alsó oszlopdiagram vizuálisan szemlélteti, hogy a rendelések döntő többsége időben teljesül, míg a problémás tételek aránya alacsony, de folyamatos monitorozást igényel.

A rendszer kialakításakor különös figyelmet fordítottam arra, hogy a vezetői szinteken is könnyen értelmezhető vizualizációk álljanak rendelkezésre, ezért több nézetet is tartalmaz: az egyik a múltbeli készletértékeket és felhasználásokat mutatja időbeli alakulás szerint, a másik pedig a következő 28 hétre előretekintve jeleníti meg a várható fogyásokat, az aktuális készlet szinttel és a

beérkező szállításokkal együtt. Így az operatív napi döntések, továbbá a hosszabb távú készletstratégia és pénzügyi tervezés megalapozását is segíti.

3.2.1 Készletforgási sebesség elemzése cikkszámanként

Ez a rész kvázi bevezeti a készletoptimalizálás mélyebb rétegét. Mivel rendelkezem cikkszintű készletadatokkal és heti fogyási becsléssel, kiszámíthatom az alábbiakat:

Készletforgási sebesség (turnover rate): = évesített felhasználás / átlagos készlet

Készlettartási idő (days of inventory): = (átlagkészlet / heti fogyás) × 7

Ebben a részben az FC-validátorral támogatott előrejelzések alapján kiszámításra kerül a cikkszám szintű készletforgási sebesség (turnover rate) és a készlettartási idő (days of inventory). A cél azonosítani azokat a tételeket, amelyek túl lassan vagy túl gyorsan forognak, és ezzel elősegíteni a készletszintek optimalizálását, valamint az anyagellátás megbízhatóságát és pénzügyi hatékonyságát.

A számítás alapját 12 heti készletszint-adat képezi, amely minden hét első napjára vonatkozik. A heti felhasználás a készletszint különbségéből adódik, vagyis a felhasználás egy adott héten az előző heti készlet és az aktuális heti készlet különbségeként számítható. Ebből a 11 heti fogyás értékéből meghatározható az átlagos heti felhasználás, amely a további mutatók kiindulópontját képezi. Az évesített felhasználás ennek az értéknek 52-vel való szorzata, azaz: Évesített felhasználás = Átlagos heti felhasználás × 52. Az átlagos készletszintet a 12 heti készletszintek számtani átlaga adja meg.

A készletforgási sebesség (turnover rate) az évesített felhasználás és az átlagos készlet hányadosaként értelmezhető, azaz:

Készletforgási sebesség = Évesített felhasználás / Átlagos készlet.

A készlettartási idő (days of inventory) pedig azt mutatja meg, hogy egy adott készletszint meddig elegendő a jelenlegi fogyási ütem mellett. Kiszámítása a következőképpen történik:

Készlettartási idő = (Átlagos készlet / Átlagos heti felhasználás) × 7.

A számított mutatók lehetőséget biztosítanak arra, hogy a cikkszámokat nemcsak abszolút értékük, hanem forgási karakterisztikájuk szerint is rangsoroljuk. Az alacsony forgási sebesség például túlzott készletképzésre utalhat, amely felesleges tőkekötést eredményez, míg a nagyon gyors forgás készlethiányt és gyártási kockázatokat jelezhet.

A forgási mutatók értelmezése tovább mélyíthető az ABC-XYZ osztályozás alkalmazásával. Az ABC elemzés az éves felhasználási érték alapján (darab × egységár) rangsorolja az anyagokat, így három kategóriába sorolhatók:

A: magas értékű, kritikus tételek

B: közepes értékű, jellemzően standard anyagok

C: alacsony értékű, gyakori tételek

Ezzel párhuzamosan az XYZ elemzés a felhasználás stabilitását, azaz a kereslet előrejelezhetőségét méri:

X: stabil, jól tervezhető fogyasztás

Y: mérsékelt változó


Z: erősen ingadozó, nehezen tervezhető igény

Az így létrejövő ABC-XYZ mátrix minden cikkszámot egy kategóriapárba sorol (például: AX, BY stb.), lehetővé téve, hogy azokat érték és keresleti kiszámíthatóság szerint egyaránt vizsgáljuk. Ez a többdimenziós megközelítés különösen hasznos a stratégiai jelentőségű anyagok beazonosítására. Egy „AZ” kategóriájú cikk például nemcsak kiemelkedő értéket képvisel, hanem nehezen is tervezhető – így fokozott beszerzési figyelmet és kockázatkezelési stratégiát igényel. Ezzel szemben egy „CX” típusú cikk esetén elegendő lehet automatizált rendelési mechanizmusok alkalmazása.

A numerikus eredmények elemzését követően érdemes vizuálisan is feltárni az adatokat. Ennek érdekében célszerű top 10 lista készítése a leggyorsabban és lelassabban forgó cikkszámokról.

Bubble chart alkalmazása, amelyben az X tengely a forgási sebesség, az Y tengely a cikkszámhoz tartozó készletérték, a buborékméret pedig az évesített felhasználás.

Row Labels	X	Y	Bubble size	Category
MB-534 primary wire	44,72	125831,77	125831,77	AY
S20 25,7 x 17,2 x 2	43,57	12784,60	12784,60	AY
1798972-00-A	40,85	372237,32	372237,32	AX
Lötzinn SnCu3,0	35,97	59933,47	59933,47	AY
1787621-00-B+3x1091980-00-C	34,83	678535,28	678535,28	AX
Kimetszett tálca 35xd=36mm	16,22	4812,03	4812,03	BY
Kartonlap (3 rétegű) 280x250	15,78	3769,60	3769,60	BY
Kimetszett-rag. tálca 8xd=80r	15,51	1902,48	1902,48	CY
VonRoll51589,12mm,trans,PE	15,46	2879,44	2879,44	BY
FXT30 276x238x2 mm	15,26	4492,35	4492,35	BY



Ábra 6 Buborék diagram TOP10 készletforgási sebességű anyagok buborékdiagramja.
Forrás: saját szerkesztés

A mesterséges intelligencia által támogatott adatelemzési rendszer segítségével elkészült buborékdiagram (Ábra 6) a készletforgási sebesség (X tengely), az éves felhasználási érték (Y tengely) és a készlet nagyságát reprezentáló buborékok segítségével egyértelműen vizualizálja az egyes cikkszámok logisztikai és pénzügyi szempontból való jelentőségét. A vízszintes tengely a forgási sebességet, a függőleges tengely az éves készletértéket mutatja, míg a buborékok mérete az adott anyag készletértékének nagyságát jelzi. Így jól azonosíthatók azok az anyagok, amelyek magas készletértékkel rendelkeznek, de forgási sebességük alacsony, így jelentős tőkét kötnek le a raktárban.

A vizsgálat célja az volt, hogy azonosíthatók legyenek azok az anyagok, amelyek vagy túl gyorsan, vagy túl lassan forognak, illetve kiemelkedően nagy értéket képviselnek, ezáltal stratégiai besorolást igényelnek.

A diagramon jól látható, hogy a „1787621-00-B+3x1091980-00-C” cikkszám mind érték, mind készletforgási sebesség szempontjából kiemelkedő. A rendkívül nagy éves felhasználási érték (678 535,28 €) és viszonylag magas forgási sebesség (34,83) alapján ez a tétel az AX kategóriába tartozik, azaz nagy értékű, gyakran felhasznált és stratégiai jelentőségű alapanyag. Ez arra utal,

hogy a beszerzésének és készletezésének kiemelt prioritást kell élveznie a vállalaton belül, és érdemes lehet hosszú távú partnerségeket kialakítani a beszállítókkal.

Hasonlóan, a „1798972-00-A” cikkszám is kiemelkedik az elemzésből, jelentős éves érték (372 237,32 €) és viszonylag magas forgási sebesség (40,85) mellett. Ez is az AX típusba esik, így egy másik kulcsfontosságú alapanyagról beszélhetünk. A két AX kategóriájú tétel a grafikon jobb-felső szegmensében helyezkedik el, ami a készletgazdálkodás szempontjából optimálisnak mondható: értékesek, de jól tervezhetők és gyorsan forgóak.

A „MB-534 primary wire” és „Loetzin SnCu3,0” cikkszámok alacsonyabb forgási sebesség mellett is jelentős értéket képviselnek (125 831,77 €, illetve 59 933,47 €), viszont a kategóriájuk (AY) arra utal, hogy bár nagy értékűek, a keresletük kevésbé stabil, vagyis inkább szezonális vagy bizonytalan. Ezeknél fokozottan figyelni kell a forecast minőségére és a biztonsági készlet szint helyes beállítására.

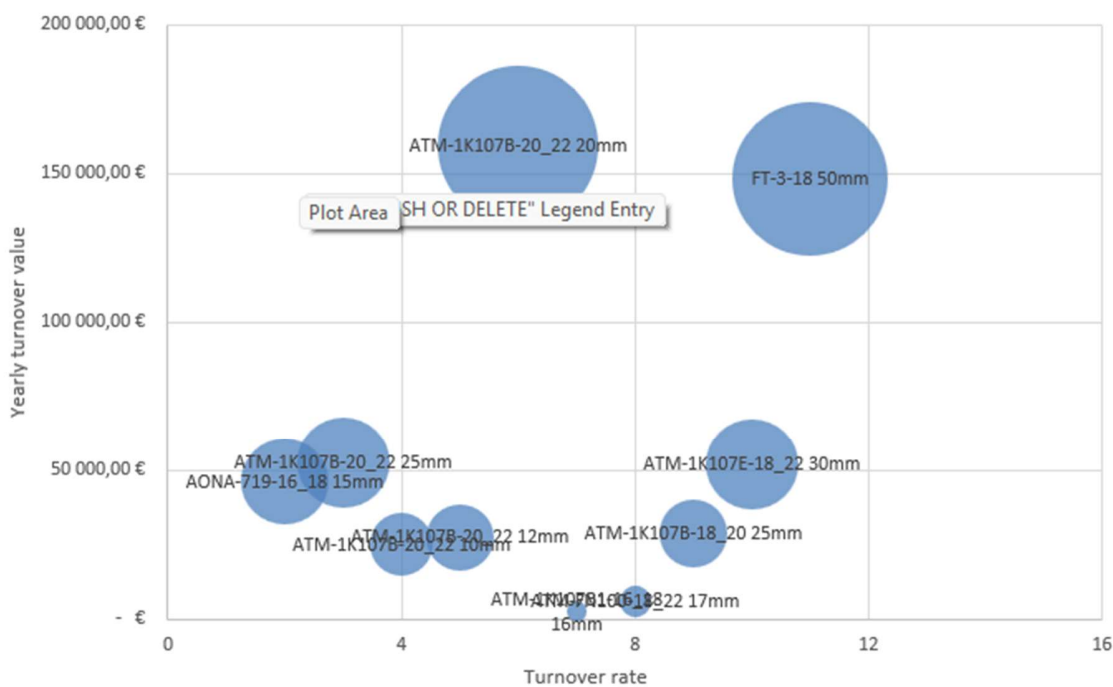
A bal alsó kvadránsban látható cikkszámok, mint a „Kimetszett tálca 35xd=36mm”, a „Kartonalap 3 rétegű 280x250” vagy a „FXT30 276x238x2 mm” viszonylag alacsony értékű és alacsony forgású, jellemzően BY vagy CY kategóriás anyagok. Ezek kezelése automatizált beszerzéssel és minimális adminisztrációval történhet, mivel a pénzügyi és logisztikai kockázatuk alacsony.

A buborékdiagram tehát nemcsak a rangsorolást segíti, hanem vizuális eszközként támogatja az ellátási stratégia finomhangolását. A készletgazdálkodási döntések során figyelembe vehető, hogy mely anyagokhoz szükséges extra biztonsági készletet tartani, melyekhez érdemes automatizált újrarendelést bevezetni, vagy melyekhez indokolt beszállítói diverzifikáció.

A stratégiai jelentőségű cikkszámok esetében (Ábra 7) –a nano-kristályos szalag – különösen indokolt az esettanulmány jellegű vizsgálat, mivel a készletforgási mutatók alapján konkrét döntési javaslatok is megfogalmazhatók. Ilyenek lehetnek például a biztonsági készlet szint újra definiálása, a rendelési gyakoriság módosítása vagy a készletciklus⁸ átszervezése. A készletforgási elemzés tehát nemcsak pénzügyi és logisztikai szempontból értékes, hanem stratégiai döntéshozatal támogató eszközként is szolgál.

⁸ az az időtartam és folyamat, amíg egy vállalat újra feltölti, majd elhasználja vagy eladja a készletét – forrás: (Chikán & Demeter, Az értékteremtő folyamatok menedzsmentje - Termelés, szolgáltatás, logisztika, 2006)

Row Labels	X	Y	Bubble size Category
AONA-719-16_18 15mm	44,03	45937,41	45937,41 AZ
ATM-1K107B-20_22 25mm	24,38	52500,12	52500,12 AZ
ATM-1K107B-20_22 10mm	14,31	25125,61	25125,61 AZ
ATM-1K107B-20_22 12mm	8,86	27462,52	27462,52 AZ
ATM-1K107B-20_22 20mm	8,42	159219,81	159219,81 AZ
ATM-1K107B1-16_18 16mm	5,69	2553,39	2553,39 CZ
ATM-FN100-18_22 17mm	5,67	5875,53	5875,53 BZ
ATM-1K107B-18_20 25mm	4,52	28504,43	28504,43 AZ
ATM-1K107E-18_22 30mm	4,47	52082,89	52082,89 AZ
FT-3-18 50mm	3,80	148140,42	148140,42 AY



Ábra 7 Buborék diagram TOP10 készletforgási sebességű szalag stratégiai alapanyagára. Forrás: saját szerkesztés

A buborékdiagramon kizárólag a szalag típusú alapanyagok szerepelnek, amelyek a vállalat valamennyi termékének előállításához elengedhetetlenek. Ezáltal funkcionálisan egyértelműen stratégiai jelentőségű anyagokról beszélünk – hiszen ezek nélkül a gyártás teljes mértékben ellehetetlenülne. Ugyanakkor a készletforgási sebesség (X tengely), az éves felhasználási érték (Y tengely), valamint az ABC-XYZ kategóriák alapján történő elemzés már árnyaltabb képet ad ezek valódi portfólióbeli szerepéről.

A diagram alapján két cikkszám, az ATM-1K107B-20_22 20mm és a FT-3-18 50mm, a legmagasabb értékű és leggyorsabban forgó tételek közé tartozik. Ezek AY és AZ kategóriás besorolásúak, vagyis nemcsak értékesek (A), hanem előrejelezhetőségük is viszonylag stabil vagy ingadozó, de még kezelhető (Y vagy X). Ez megerősíti, hogy ezek a tételek kiemelt szerepet

töltenek be mind funkcionálisan, és készletstratégiai szempontból is, ezért fokozott figyelmet igényelnek mind a rendelési gyakoriság, mind a biztonsági készletszint tervezésében.

Azonban több szalag típusú cikkszám, például az ATM-1K107B1-16_18 16mm vagy az ATM-FN100-18_22 17mm, CZ illetve BZ kategóriába került, azaz alacsony értékű és kiszámíthatatlan keresletű anyagként szerepelnek a rendszerben. Ez alapján ezek nem minősülnek tipikus „stratégiai tételnek” az ABC-XYZ módszertan szerint, még akkor sem, ha funkcionálisan azok. Ez a kontraszt kiemeli a klasszikus portfólióelemzés és a vállalati működés logikáján alapuló tényleges stratégiai besorolás közti eltéréseket.

Ezért a döntéshozatal során nem elegendő csupán a mutatókra és osztályozásokra hagyatkozni: az anyagok funkcionális szerepét is figyelembe kell venni. Célszerű lehet például a szalag típusú anyagokra egy külön „stratégiai” címkét bevezetni a vállalati rendszerben, függetlenül attól, hogy az adott cikkszám éppen milyen ABC vagy XYZ kategóriába esik.

Ezek az anyagok ugyan eltérő mutatókat mutatnak a grafikonon, de egyöntetűen stratégiai fontosságúak, és ezek készletezése, biztonsági tartalékolása és beszerzési logikája nem hagyatkozhat kizárólag a klasszikus érték alapú osztályozási rendszerekre. Érdeemes külön szabályrendszert kialakítani ezen anyagok kezelésére a vállalati készletstratégia részeként.

3.2.2 Minimum készletszint számítása és biztonsági készlet újradefiniálása

A készletoptimalizálás egyik központi eleme az úgynevezett reorder point – amely az ABAS rendszerben a biztonsági készlet és minimum készlet együttesét jelenti. Ez az érték határozza meg azt a szintet, amely alá csökkenve a rendszer automatikusan rendelési javaslatot generál. A jelenlegi gazdasági környezetben – amelyet alapanyagár-ingadozások, ellátási zavarok és kiszámíthatatlan kereslet jellemez – fontos, hogy ez a szint adatalapon, dinamikusan kerüljön meghatározásra, figyelembe véve a tényleges kockázatokat és anyagfelhasználási mintákat.

Az FC-validátor és a Material Balance riport együttes alkalmazása által lehetséges egy olyan cikkszámszintű, prediktív reorder point-megközelítés, amely képes reagálni az aktuális fogyási trendekre és a beszállítói teljesítmény alakulására.

Az újradefiniált minimum készletszint számítása az alábbi paraméterekre épül:

1. Átlagos napi vagy heti anyagfelhasználás – az FC-validátor előrejelzései alapján.
2. Beszerzési átfutási idő (lead time) – cikkszámszintű adat az ABAS ERP rendszerből.
3. Kockázati besorolás (ABC-XYZ) – érték és előrejelezhetőség alapján.
4. Beszállítói megbízhatóság – késések és mennyiségi eltérések gyakorisága.

A jelenlegi beszerzési tapasztalataink alapján – miszerint a rendelések időben kiadásra kerülnek, és a beszállítók ritkán késnek – feltételezhetjük, hogy egy esetleges zavar maximum 10 munkanapon (két héten) belül kezelhető. Ebből következik, hogy az optimális biztonsági készlet szint (reorder point) a napi felhasználás 10-szerese lehet.

A minimum készlet szint (Ábra 8) újradefiniálása tehát a következő egyszerű képlet alapján:

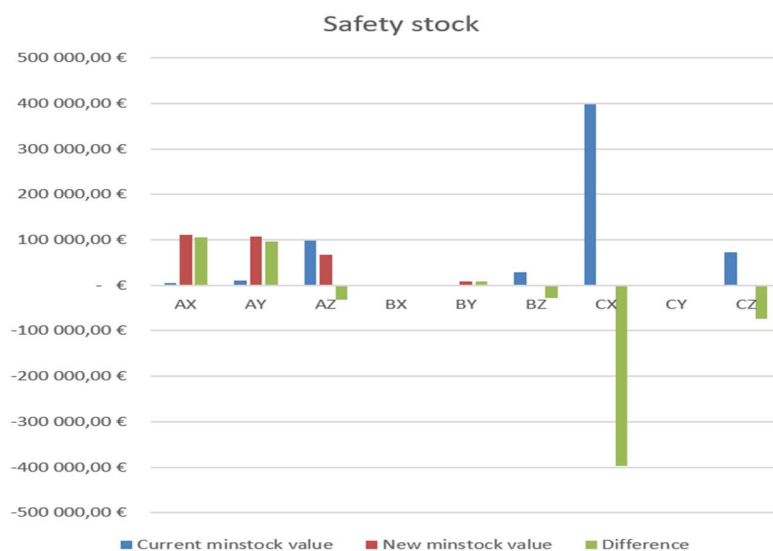
$$\text{Minimum készlet szint} = \text{Átlagos napi felhasználás} \times 10 \text{ munkanap}$$

Az ABC-XYZ mátrix alapján megállapítható, hogy bizonyos kategóriák esetében indokolt a biztonsági készlet szint fenntartása. Kiemelten fontos a jelentős biztonsági készlet tartása az AZ, AY és BY típusú anyagok esetében, mivel ezek vagy magas értékűek és ingadozó fogyasztásúak, vagy közepes értékűek, de keresletük változó. Az AX kategóriájú anyagoknál szintén indokolt közepes szintű biztonsági készlet, tekintettel arra, hogy bár értékesek és stratégiai jelentőségűek, fogyasztásuk jellemzően stabil, így túlzott készletezés nem szükséges. Ezzel szemben a BZ és CZ kategóriákba sorolt anyagoknál fokozott körültekintés szükséges: bár fogyasztásuk ingadozó, értékük alacsony, ezért csak minimális biztonsági készlet fenntartása indokolt.

Szakmai szempontból a magas értékű anyagoknál a készlet hiány súlyos következményekkel járhat, mivel nagy értékvesztést vagy gyártási leállást eredményezhet. Az ingadozó fogyasztású anyagoknál pedig a kereslet előrejelezhetőségének alacsony szintje indokolja a pufferek beépítését. Ezzel szemben az olcsó, stabil fogyasztású anyagoknál (például a CX kategóriában) nem éri meg jelentős készleteket fenntartani; ezeknél a gyakori, kisebb volumenű rendelések alkalmazása célszerűbb. Az 8. ábra a jelenlegi és az új, kategóriánként differenciált minimum készlet szintek összehasonlítását mutatja be az ABC-XYZ mátrix szerinti bontásban. A cél az volt, hogy a készletstratégia a valós felhasználási mintákra és értékalapú besorolásra épüljön, csökkentve a felesleges készletértéket, ugyanakkor biztosítva a stratégiai fontos anyagok ellátását.

Az továbbiakban bemutatott adatok illetve eredmények a 2025. májusában tesztüzembe helyezett rendszer 2025. augusztus 12-i állapotán alapulnak, melyet a Schul mandantból exportáltam. A készlet rendelkezésre állás és fogyás adatait a „éles” rendszerből importáltam, hogy az MI előrejelzett adatai alapján milyen változást indukált volna készletértékben, kifejezetten a biztonsági készlet értékeiben a rendszer bevezetése.

Row Labels	Current minstock value	New minstock value	Difference	Difference (%)
AX	5 323,53 €	110 974,49 €	105 650,97 €	1984,60%
AY	10 759,97 €	107 989,75 €	97 229,78 €	903,63%
AZ	98 889,75 €	67 029,42 €	- 31 860,33 €	-32,22%
BX	1 628,44 €	- €	- 1 628,44 €	-100,00%
BY	1 209,15 €	9 529,95 €	8 320,80 €	688,16%
BZ	27 954,16 €	- €	- 27 954,16 €	-100,00%
CX	397 388,51 €	- €	-397 388,51 €	-100,00%
CY	1 272,99 €	- €	- 1 272,99 €	-100,00%
CZ	72 796,27 €	- €	- 72 796,27 €	-100,00%
Total	617 222,76 €	295 523,61 €	-321 699,15 €	-52,12%



Ábra 8 A jelenlegi és az újraszámított biztonsági készletszintek értékeit, valamint ezek különbsége kategóriánként. Forrás: saját szerkesztés

AX kategória:

A jelenlegi 5 323,53 €-ról az új modell 110 974,49 €-ra emeli a minimum készletszint értékét, ami több, mint 19-szeres növekedést jelent. Ez annak köszönhető, hogy bár ezek az anyagok stabilan fogyó, de értékes és stratégiai szerepet betöltő tételek, eddig alul lettek készletezve.

AY kategória:

Jelentős, 903,63%-os növekedést tapasztalható. Mivel ezek értékes, de bizonytalanul fogyó anyagok, az új biztonsági készlet indokolt.

AZ kategória:

A szabály szerint alacsonyabb biztonsági készlet indokolt, ami 32,22%-os relatív változást jelent. Ez azt jelzi, hogy a jelenlegi készletszint túlzó volt a kereslet stabilitásához képest.

BY kategória:

Bár korábban alacsony értéket képviselt, az új modell 9 529,95 €-os szintet határoz meg, figyelembe véve a magasabb ingadozást. Ez 688,16%-os eltérést mutat a jelenlegihez képest, de a növekedés még így is ésszerű.

BZ, BX, CY, CZ, CX kategóriák:

Ezekben a kategóriákban az új modell gyakorlatilag nullára csökkenti a minimum készletszinteket, 100%-os készletérték-csökkentést generálva. Ezek az anyagok vagy olcsók, vagy instabil keresletűek (pl. BZ, CZ), illetve jól tervezhetők és gyakran rendelhetők (pl. CX). Így itt a biztonsági készlet tartása nem gazdaságos, különösen a jelenlegi gazdasági környezetben.

A teljes minimum készletérték 617 222,76 €-ről 295 523,61 €-ra csökkent, ami 321 699,15 € megtakarítást jelent, azaz 52,12%-os teljes csökkenést. Ez a változtatás pénzügyi szempontból jelentős, továbbá hatékonyabb, kockázatalapú készletgazdálkodást is lehetővé tesz.

3.2.3 Készletérték-csökkentés és forgási hatékonyság növelés

A készletgazdálkodás optimalizálása során kiemelt cél a készletekben lekötött tőke csökkentése, miközben biztosított marad a termelés és a vevői igények folyamatos kiszolgálása. Az előző fejezetekben bemutatott új minimumkészlet-számítási módszertan és biztonsági készletszint-újraderfinálás alkalmazása alapján számszerűsíthető, hogy a vállalatnál milyen mértékű készletérték-csökkentés és forgási sebesség-javulás érhető el.

Az új, ABC–XYZ-alapú minimum készletszint-szabályok bevezetésével a minimum készlet szignifikánsan csökkent, amely idővel felszabadult tőkét jelentene (–52,12%). A csökkenés döntően a BZ, BX, CY, CZ, CX kategóriákban jelentkezik (minimum gyakorlatilag nullára), míg AX/AY esetén a készletszintek célzottan emelkednek a kiszolgálási kockázat mérséklésére.

Az optimalizálási intézkedések hatását a készletforgási sebesség (turnover rate) és a készlettartási idő (days of inventory) kategóriánkénti változása is jól szemlélteti. A fejlesztés előtti és utáni adatok összevetése alapján a legtöbb kategóriában jelentős javulás tapasztalható. (Ábra 9).

Row Labels	Turnover rate			Days of inventory		
	Before	After	%	Before	After	%
AX	16,53	27,70	167,59%	41,42	25,44	61,41%
AY	14,42	15,48	107,35%	49,23	46,61	94,69%
AZ	19,43	29,24	150,46%	158,48	143,66	90,65%
BX	9,38	10,19	108,56%	52,35	40,31	77,00%
BY	9,99	14,64	146,53%	51,60	53,99	104,65%
BZ	18,63	18,24	97,94%	108,11	55,42	51,26%
CX	0,00	0,00	0,00%	0,00	0,00	0,00%
CY	5,32	7,36	138,37%	314,92	130,25	41,36%
CZ	17,93	9,38	52,31%	1394,77	660,17	47,33%

Ábra 9 Az optimalizálás előtti és utáni készletforgási sebesség, valamint a készlettartási idő változása ABC–XYZ kategóriánként. Forrás: saját szerkesztés

A CZ kategóriában ugyan a forgási sebesség 52,31%-kal visszaesett, azonban a rendkívül magas induló készlettartási idő jelentősen mérséklődött (-47,33%), ami a készletszint leépítését tükrözi. A BY kategória esetében a forgási sebesség növekedése mellett a készlettartási idő kis mértékben emelkedett (+4,65%), ami eltérő rendelési stratégia és célzott készletszint-emelés következménye. Ezen adatok megerősítik, hogy az új minimumkészlet-számítási és biztonsági készletszint-újradefiniálási módszertan az anyagcsoportokportok nagy részénél gyorsabb készletforgást és alacsonyabb tőkelekötést eredményezett, miközben a kritikus tételeknél a kiszolgálási biztonság nem csökkent.

4 Következtetések és javaslatok

A dolgozat alapját és a rendszer létrehozását a Magnetec-Ungarn Kft. előrejelzési és készletgazdálkodási folyamataiban tapasztalt adatkezelési és döntéstámogatási hiányosságok indokolták. A vállalat az elmúlt években jelentős mennyiségű értékesítési és termelési adatot halmozott fel, ugyanakkor az adatoknak a strukturált, elemzésre alkalmas feldolgozása és pontosságának rendszeres visszamérése hiányosan vagy nincs beépítve a mindennapi gyakorlatba. Korlátozottan tudták kezelni azokat az eseteket, amikor a valós igények és a prognosztizált értékek között jelentős eltérések léptek fel. Emiatt előfordult, hogy bizonyos termékekből túlkészletezés történt, míg más esetekben hiánycikkek alakultak ki. Ez a készletszintek torzulásához vezetett, továbbá a pénzügyi erőforrások hatékony felhasználását is nehezítette. Ezért fontos, hogy az előrejelzések és a tényleges értékesítési adatok közötti eltéréseket automatikusan mérje, elemze és vizualizálja a program. Az fejlesztés célja: a korábbi manuális, szubjektív megítélések helyett valós statisztikai pontossági mutatókra építve megbízhatóan ellenőrizni a keresletkezelési folyamatokat, későbbiekben a várható fogyást extrapolálni.

A fejlesztett FC-Validator a készletgazdálkodás stratégiai szintű optimalizálását is támogatja. Korábban nem állt rendelkezésre olyan integrált megoldás, amely összekapcsolta volna az előrejelzési hibákat a készletezési döntésekkel, kimutatva, hogy a tervezési eltérések hogyan befolyásolják a készletszinteket, a biztonsági készlet nagyságát és a vállalat pénzügyi teljesítményét. Az MI-alapú fejlesztés feladata, hogy a korábbi időszakok adatai alapján objektív, számszerű visszajelzést adjon az előrejelzések megbízhatóságáról, valamint kimutassa, hol szükséges beavatkozás a készletszabályozásban. A statisztikai eszköz mivoltán túl egy döntéstámogató megoldás is, amely az előrejelzési hibákat közvetlenül összekapcsolja a Material Balance riportban szereplő készletmozgásokkal és gyártási mennyiségekkel rámutatva, hogy az egyes időszakok előrejelzési hibái milyen hatással voltak a tényleges készletszintre és az anyagfelhasználásra.

A fejlesztéshez és kiértékeléshez alkalmazott ABC–XYZ elemzések az anyagokat értékbeli súlyuk (ABC) és keresletük kiszámíthatósága (XYZ) alapján osztályozzák. Az program kimenetei alapján azonosíthatók a kritikus anyagok, amelyeknél a magas értékű és kiszámíthatatlan kereslet miatt fokozott figyelemre van szükség. Ennek révén a rendszer összekapcsolja az előrejelzési hibák statisztikai elemzését a készletstratégiák gyakorlati finomításával, és pontosabb inputot biztosít a Material Balance riport készletegyensúly-számításaihoz.

A modell a részlegesen elkülönülő elemzések közé valós adatkapcsolatot épít, átfogó képet nyújtva a kereslet, a készlet és a termelés kölcsönhatásairól, létrehozva egy adatokon alapuló, proaktív döntéshozatali lehetőséget, ami a készletezési és beszerzési folyamatokat stratégiai szinten is támogathatja.

A rendszer csökkenti az információs aszimmetriát a különböző szervezeti egységek között: az értékesítés, a termelés, a beszerzés és a logisztika ugyanazokra az adatokra és mutatókra támaszkodhat, elősegítve egy összehangolt tervezést, minimalizálva a kommunikációs és koordinációs hibákból fakadó készleteltéréseket.

A következő kézzelfogható működési és pénzügyi előnyökkel járhat:

1. Készletoptimalizálás: a felesleges készletek és elavuló anyagok aránya csökken, miközben a biztonsági készlet szintje a keresleti kockázathoz igazodik;
2. Likviditás javulása: a forgóeszköz-állományban lekötött tőke csökken, így javul a vállalat cash-flow-pozíciója;
3. Pontosság növekedése: a MAPE és PE mutatók alapján az előrejelzések megbízhatósága mérhetően javul, ami stabilabb termelési és beszerzési döntéseket eredményez;
4. Stockout-esetek csökkenése: az előrejelzési hibák gyors felismerése révén megelőzhetők a hiányhelyzetek, ezáltal nő a vevői elégedettség;
5. Erőforrás-hatékonyság: a riportálási és elemzési folyamatok automatizálása csökkenti az emberi hibák kockázatát és az adminisztrációs terheket.

Stratégiai szinten a modell bevezetése a digitális transzformáció felé tett lépés. Egy egységes keretrendszerbe foglalja az előrejelzések, a termelés és a készletkezelés adatait, így megalapozza a későbbi mesterséges intelligencia-alapú prediktív és optimalizáló modellek bevezetését is. Ez a napi működés hatékonyságát is növelné, ráadásul hosszú távon a vállalati versenyképesség és reagálóképesség javulását is elősegítené.

A működési eredmények mérése és a folyamatfejlesztés hatásainak értékelése érdekében szükséges a vállalat teljesítményét objektív, kvantitatív mutatók segítségével lehessen nyomon követni. javulás és a készletszintek optimalizálása csak akkor tekinthető valós eredménynek, ha azok a kulcs-teljesítménymutatókban is kimutathatók. Így a döntéshozók átláthatják, mely folyamatok járulnak hozzá leginkább a hatékonyság növeléséhez, a költségcsökkentéshez és a vevői elégedettség javításához.

A táblázatban (Ábra 10) összefoglaltam a javasolt és a vállalat működése szempontjából legfontosabb készletgazdálkodási, kereslet-előrejelzési és logisztikai KPI-ok, bemutattva, mit mérnek, miért fontosak, és milyen adatforrásokra épülnek.

KPI megnevezése	Mit mér	Miért fontos	Adatforrás
Készletgazdálkodási KPI-k			
Készlethiány arány (Stockout Rate)	A rendelések azon hányada, amely nem teljesíthető készlethiány miatt	Az ügyfélelégedettség növeléséhez elengedhetetlen a megfelelő készletszint fenntartása	ERP-rendszer (rendelés- és készletadatok), Material Balance
Készletforgási sebesség (Inventory Turnover Rate)	Évesített felhasználás és átlagos készlet aránya	Magasabb érték alacsonyabb tőkelekötést és kisebb elavulási kockázatot jelent	Material Balance, FC-validátor
Napok készleten (Days of Inventory)	Az átlagos készlet fedezete napokban	A készlettartási költségek és a kiszolgálási szint egyensúlyának fenntartásához szükséges	Material Balance
Kereslet-előrejelzési KPI-k			
Előrejelzési pontosság (Forecast Accuracy)	Előrejelzett és tényleges kereslet közötti eltérés százalékos pontossága	Az MI-alapú rendszerek egyik fő célja a pontosság növelése	FC-validátor, ERP (értékesítési adatok)
Előrejelzési eltérés (Forecast Bias)	Az előrejelzések tendenciózus alul- vagy túlbecslésének mértéke	A hibák irányának azonosításával javítható az algoritmus	FC-validátor
MAPE (Mean Absolute Percentage Error)	Előrejelzési hibák átlagos százalékos értéke	Skálafüggetlen összehasonlítás különböző termékek és időszakok között	FC-validátor
Szállítási és logisztikai KPI-k			
Időben történő szállítási arány (On-Time Delivery Rate)	Szállítások hány százaléka történik a tervezett határidőn belül	Kritikus ügyfélelégedettségi mutató	ERP (szállítási és rendelésadatok)
Szállítási pontosság (Delivery Accuracy)	Szállítások hány százaléka felel meg a megrendelés specifikációinak	Hibák csökkentésével javul a vevői bizalom és csökkennek a költségek	ERP (szállítási és rendelésadatok)
Szállítási költség a bevétel arányában (Transportation Cost as % of Sales)	Szállítási tevékenységek költsége az árbevétel arányában	A logisztikai költségek optimalizálása javítja a jövedelmezőséget	ERP (pénzügyi és logisztikai adatok)

Ábra 10 automatizált elemzésekhez javasolt KPI-ok rendszere – készletgazdálkodási, kereslet-előrejelzési, valamint szállítási és logisztikai mutatók bemutatása (saját szerkesztés, vállalati adatok és szakirodalom alapján). Forrás: saját szerkesztés

5 Összefoglalás

Az ellátási láncok működésének hatékonysága napjainkban kulcskérdéssé vált, különösen a globális gazdasági bizonytalanságok, a pandémiák és a fenntarthatósági követelmények fényében. A dolgozat központi kérdése az volt, hogy a mesterséges intelligencia milyen módon képes támogatni a kereslet-előrejelzés és a készletgazdálkodás folyamatainak fejlesztését, és ezzel hozzájárulni az ellátási lánc rugalmasságához és versenyképességéhez.

A kutatás első részében a szakirodalmi áttekintés mutatta be a mesterséges intelligencia fejlődését, az intelligens ellátási láncok koncepcióját, valamint a kereslet-előrejelzés és készletoptimalizálás területén alkalmazott módszereket. Külön figyelem került a COVID-19 válság tapasztalataira, amelyek rávilágítottak az adatvezérelt megközelítések szükségességére.

A dolgozat második részében a vállalati adatok feldolgozásával és egy saját fejlesztésű FC-validátor prototípus bemutatásával került sor az elméleti eredmények gyakorlati alkalmazására. Az elemzések bizonyították, hogy a mesterséges intelligencia támogatásával javítható az előrejelzési pontosság és csökkenthető a készletekben lekötött erőforrások. Az új készletszámítási módszertan jelentős tőkelekötés-csökkentést tett lehetővé, miközben az ellátásbiztonság fennmaradt.

A Material Balance jelentés és az automatizált riporting rendszer integrálása lehetővé tette, hogy a döntéshozók naprakész, adatvezérelt információkra támaszkodhassanak, csökkentve a manuális munkaigényt és gyorsítva a reakcióidőt. Az MI-támogatás így nemcsak elemzői eszközként, hanem a napi operatív irányítás részeként vált hasznossá.

Az eredmények alapján kijelenthető, hogy az MI-alapú rendszerek nem csupán technológiai újításként értelmezhetők, hanem a vállalati stratégia részévé válhatnak. Az automatizált adatfeldolgozás és a KPI-ok bevezetése lehetővé teszi a teljesítmény folyamatos mérését és a működés adatvezérelt irányítását.

A dolgozat rámutatott arra, hogy az MI bevezetése az ellátási lánc menedzsmentben nemcsak hatékonyságnövelő tényező, hanem a hosszú távú fenntarthatóság és versenyképesség biztosításának egyik kulcseszköze is. Ugyan az MI további betanítása még hónapokat vehet igénybe, de már 4 hónap alatt a teszt környezetben jelentős változást eredményezett készletszint és likviditás szempontjából.

6 Ábrajegyzék

Ábra 1 Kraljic-féle mátrix (forrás: (Kraljic, 1983) alapján saját szerkesztés)	17
Ábra 2 A MAPE és PE értékek alakulása 2020–2023 között – A kék vonal a havi átlagos MAPE (átlagos abszolút százalékos hiba) értékek változását mutatja, míg a narancssárga vonal a PE (előrejelzési eltérés) trendjét jelzi. Forrás: saját szerkesztés	29
Ábra 3 Az kezdetleges FC-validátor grafikus felülete és 12 hónapos előrejelzési kimenete. Forrás: saját fejlesztés	32
Ábra 4 A készletérték és a biztonsági készletszint alakulásának napi nyomon követése a Material Balance rendszerben. Forrás: saját szerkesztés	36
Ábra 5 A beszállítói rendelések napi státuszvizsgálata. Forrás: saját szerkesztés	37
Ábra 6 Buborék diagram TOP10 készletforgási sebességű anyagok buborékdiagramja. Forrás: saját szerkesztés.....	40
Ábra 7 Buborék diagram TOP10 készletforgási sebességű szalag stratégiai alapanyagra. Forrás: saját szerkesztés.....	42
Ábra 8 A jelenlegi és az újraszámított biztonsági készletszintek értékeit, valamint ezek különbsége kategóriánként. Forrás: saját szerkesztés	45
Ábra 9 Az optimalizálás előtti és utáni készletforgási sebesség, valamint a készlettartási idő változása ABC–XYZ kategóriánként. Forrás: saját szerkesztés	46
Ábra 10 automatizált elemzésekhez javasolt KPI-ok rendszere – készletgazdálkodási, kereslet-előrejelzési, valamint szállítási és logisztikai mutatók bemutatása (saját szerkesztés, vállalati adatok és szakirodalom alapján). Forrás: saját szerkesztés	50
Táblázat 1 Training adat.....	26
Táblázat 2 Átlagos MAPE és PE értékek havi bontásban (2020–2023).....	28

7 Bibliography

- Amplitude, I. (2024). <https://amplitude.com/>. Forrás: What is Data Cleaning? Step-by-step Guide: <https://amplitude.com/explore/data/data-cleaning-guide>
- Balogh, A., Lajos, A., & Kozma, T. (2020). Készletek szerepe az ellátási láncban. *International Journal of Engineering and Management Sciences (IJEMS) Vol. 5. (2020). No. 1*, old.: 515-526.
- Birkel, H. S., & Hartmann, E. (2020). Impact of IoT challenges and risks for SCM. *Supply Chain Management: An International Journal*, 681–699.
- Brownlee, J. (2017). *Introduction to time series forecasting with Python: How to prepare data and develop models to predict the future*. Machine Learning Mastery.
- Chikán, A. (2008). *Vállalatgazdaságtan*. AULA Kiadó.
- Chikán, A., & Demeter, K. (2006). *Az értékteremtő folyamatok menedzsmentje - Termelés, szolgáltatás, logisztika*. aula kiadó kft.
- Christopher, M. (2016). *Logistics & supply chain management*. Pearson UK.
- Csesznák, A., & Wimmer, Á. (2012). Mit mérünk és hogyan?–A vállalati teljesítménymérés szemléletmódja és eszköztára a döntéstámogatás tükrében. *Vezetéstudomány / Budapest Management Review*, 2–12.
- Dumond, E. J. (2000). Value management: an underlying framework. *International Journal of Operation & Production Management*, Vol. 20 No. 9.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- Ivanov, D., & Dolgui, A. (2020). A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0. *Transportation Research Part E: Logistics and Transportation Review*, 142.
- Jones, T. O., & Sasser, W. E. (1995). Why Satisfied Customer Defect? *Harvard Business Review*, November-December.
- K., S. –L. (2017). In *Ellátásilánc-menedzsment* (old.: 182). Budapest: Akadémia Kiadó.
- Khadem, M., Khadem, A., & Khadem, S. (2023). Application of Artificial Intelligence in Supply Chain: Revolutionizing Efficiency and Optimization. *International Journal of Industrial Engineering and Operational Research*, 20-28.
- Kotler, P., & Keller, K. L. (2016). *Marketing management*. Pearson Education.

- Kozma, T., & Ertugrul, C. (2021. November). Logisztikai trendek és legjobb gyakorlatok. *Ellátási láncok a koronavírus-válság idején - A koronavírus hatása a globális ellátási láncokra*, old.: 5-11.
- Kraljic, P. (1983). Purchasing must become supply management. *Harvard Business Review*, old.: 109–117.
- Melnyk, S. A., Stewart, D. M., & Swink, M. (2014). Metrics and performance measurement in operations management: dealing with the metrics maze. *Journal of Operations Management*, 209–217.
- Oláh, J., Karmazin, G., Lakner, Z., & Popp, J. (2020). A készletek szerepe az ellátási láncban. *International Journal of Engineering and Management Sciences*, 517–526.
- Pandya, A. (2024. September 17). *Five predictions on how generative AI can increase the velocity of business process transformation*. Forrás: SAP Signavio: <https://www.signavio.com/post/five-predictions-on-how-generative-ai-can-increase-the-velocity-of-business-process-transformation/>
- Parmenter, D. (2015). *Key Performance Indicators: Developing, Implementing, and Using Winning KPIs*. Hoboken, NJ: Wiley.
- Ranjan, J. (2009). Business intelligence: Concepts, components, techniques and benefits. *Journal of Theoretical and Applied Information Technology*, 60-70.
- Riahi, Y., Saikouk, T., Gunasekaran, A., & Badraoui, I. (2021). Artificial intelligence applications in supply chain: A descriptive bibliometric analysis and future research directions. *Expert Systems with Applications*, 173.
- Salesforce, I. (2025). *Guide To Data Cleaning: Definition, Benefits, Components, And How To Clean Your Data*. Forrás: <https://www.tableau.com/learn/articles/what-is-data-cleaning>
- SAMUELSON, P. A., & NORDHAUS, W. D. (2006). *Közgazdaságtan*. Budapest: Akadémiai Kiadó.
- SAP. (2024). AI Interplays with the Process World_E-book_v4. In SAP. SAP.
- Walmart. (2023). *Walmart reveals plan for scaling artificial intelligence, generative AI, augmented reality and immersive commerce experiences*. Forrás: <https://corporate.walmart.com/news/2024/10/09/walmart-reveals-plan-for-scaling-artificial-intelligence-generative-ai-augmented-reality-and-immersive-commerce-experiences>

Wamba, S. F., Gunasekaran, A., Akter, S., Ren, S. J.-F., Dubey, R., & Childe, S. J. (2017). Big data analytics and firm performance: Effects of dynamic capabilities. *Journal of Business Research*, 356–365.

Waters, D. (2011). *An introduction to supply chain management*. Palgrave Macmillan.

NYILATKOZAT

Kecskés Dániel (név) (hallgató Neptun azonosítója: MOJ4Q6) konzulenseként nyilatkozom arról, hogy a záródolgozatot/szakdolgozatot/diplomadolgozatot/portfóliót¹ áttekintettem, a hallgatót az irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól tájékoztattam.

A záródolgozatot/szakdolgozatot//portfóliót a záróvizsgán történő védeésre **javaslom** / **nem javaslom**².

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem^{*3}

Kelt: 2025 év 10 hó 29 nap

Dr. Némessányi K.
belső konzulens

¹ A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

² A megfelelő aláhúzendó.

³ A megfelelő aláhúzendó.

MATE Szervezeti és Működési Szabályzat

III. Hallgatói Követelményrendszer

III.1. Tanulmányi és Vizsgaszabályzat

6.13. sz. függelék: A MATE egységes szakdolgozat / diplomadolgozat / záródolgozat / portfólió készítési útmutatója

4.2. sz. melléklete: Nyilatkozat a záródolgozat/szakdolgozat/diplomadolgozat/portfólió nyilvános hozzáféréséről és eredetiségéről (módosítva: 2025. október 16.)

NYILATKOZAT

a szakdolgozat¹ nyilvános hozzáféréséről és eredetiségéről

A hallgató neve: Kecskés Dániel

A Hallgató Neptun kódja: MOJ4Q6

A dolgozat címe: A Mesterséges Intelligencia (MI) alkalmazásának lehetőségei
intelligens ellátási láncok területén

A megjelenés éve: 2025

A konzulens intézetének neve: Magyar Agrár- és Élettudományi Egyetem
Szent István Campus

A konzulens tanszékének a neve: Agrárlogisztika, Kereskedelem és Marketing Tanszék

Kijelentem, hogy az általam benyújtott szakdolgozat² egyéni, eredeti jellegű, saját szellemi alkotásom. Azon részeket, melyeket más szerzők munkájából vettem át, egyértelműen megjelöltem, és az irodalomjegyzékben szerepeltettem. Továbbá kijelentem, hogy a dolgozat elkészítése során alkalmazott mesterséges intelligencia-eszközök (pl. szöveggenerálás, nyelvi javítás, fordítás, adatelemzés) használata nem helyettesítette a saját kutatási és alkotói munkámat, azok alkalmazását a források között vagy a módszertani részben feltüntettem, és a szakmai-etikai elvárásoknak megfelelően jártam el.

Ha a fenti nyilatkozattal valótlan állítottam, tudomásul veszem, hogy a záróvizsga-bizottság a záróvizsgából kizár és a záróvizsgát csak új dolgozat készítése után tehetek.

A leadott dolgozat, mely PDF dokumentum, szerkesztését nem, megtekintését és nyomtatását engedélyezem.

Tudomásul veszem, hogy az általam készített dolgozatra, mint szellemi alkotás felhasználására, hasznosítására a Magyar Agrár- és Élettudományi Egyetem mindenkor szellemi tulajdon-kezelési szabályzatában megfogalmazottak érvényesek.

Tudomásul veszem, hogy dolgozatom elektronikus változata feltöltésre kerül a Magyar Agrár- és Élettudományi Egyetem könyvtári repozitori rendszerébe. Tudomásul veszem, hogy a megvédett és

- nem titkosított dolgozat a védést követően
- titkosításra engedélyezett dolgozat a benyújtásától számított 5 év eltelte után nyilvánosan elérhető és kereshető lesz az Egyetem könyvtári repozitori rendszerében.

¹ A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

² A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

II. TÁBLÁZAT: Jelentős tartalmi hozzájárulás (pl. egy teljes ábra vagy egy hosszabb szövegrész generálása)

(Ezekben az esetekben a felhasznált kulcsfontosságú promptok és az MI által adott nyers válaszok dokumentálása és a munka **mellékletében való csatolása szükséges.**)

A felhasználás célja	Alkalmazott eszköz verziója, elérhetősége	MI-neve,	Az érintett fejezet / ábra / táblázat pontos sorszáma	A prompt-naplót tartalmazó melléklet bejegyzésének sorszáma

3/A. Oktató által előírt kiegészítő szabályok (ha vannak)

Amennyiben az adott tantárgy oktatója vagy témavezetője az MI-eszközök használatára vonatkozóan külön szabályokat vagy elvárásokat határozott meg, kérjük, az alábbi mezőben foglalja össze ezeket:

Pl. az MI használatának tilalma bizonyos feladattípusokra; csak konkrét eszköz használata engedélyezett; eltérő hivatkozási elvárások; dokumentációs forma stb.

Oktató vagy témavezető által előírt szabályok:

.....

.....

.....

.....

4. Minden hallgatóra vonatkozó nyilatkozat:

Kijelentem, hogy az MI által esetlegesen generált tartalmakat minden esetben kritikailag felülvizsgáltam, szerkesztettem és a munkába illesztettem. A leadott munka minden eleméért, annak eredetiségéért és tudományos helytállóságáért teljes körű felelősséget vállalok. Tudomásul veszem, hogy a Magyar Agrár- és Élettudományi Egyetem a benyújtott munkát mesterséges intelligencia detektorral ellenőrizheti, és eljárást kezdeményezhet, amennyiben a nyilatkozatom valótlan vagy hiányos.

Kelt: Gyöngyös, 2025. Október 28.

.....
Hallgató aláírása

.....
Konzulens/Témavezető aláírása

Hallgatók, doktoranduszok nyilatkozata mesterséges intelligencia (MI) alkalmazásáról

1. Általános adatok

Hallgató neve:	Kecskés Dániel
Neptun-kódja:	MOJ4Q6
Képzési szint (a megfelelőt jelölje X-szel):	<input checked="" type="checkbox"/> BSc/BA <input type="checkbox"/> MSc/MA <input type="checkbox"/> Doktori (PhD) <input type="checkbox"/> Egyéb:
Tantárgy neve/kódja*:	
A munka címe:	Az Mesterséges Intelligencia (MI) alkalmazásának lehetőségei intelligens ellátási láncok területén

* doktori értekezés esetén nem kitöltendő

2. Nyilatkozat az MI használatáról

Alulírott, etikai felelősségem teljes tudatában az alábbi nyilatkozatot teszem:

(Kérjük, válasszon egyet az alábbi lehetőségek közül!)

A) Nem alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.

(Amennyiben ezt jelölte, a további táblázatok kitöltése nem szükséges.)

B) Alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.

(Kérjük, töltsse ki a vonatkozó táblázatokat!)

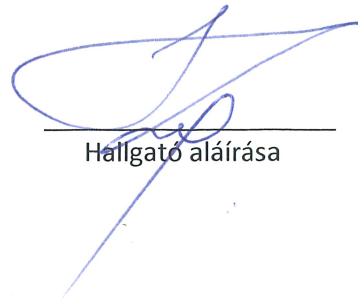
3. A mesterséges intelligencia használatának részletezése

I. TÁBLÁZAT: Asszisztensi vagy kisebb mértékű felhasználás (pl. fordítás, nyelvi korrektúra, ötletelés stb.)

(Ezen felhasználások esetében a konkrét promptok és válaszok csatolása nem szükséges.)

A felhasználás célja	Alkalmazott MI-eszköz neve és verziója	Érintett rész (ha nem a szöveg egészére vonatkozik)
Források releváns részeinek megkeresése, összefoglalása, megírt fejezetek szakmai elemzése, nyelvtani ellenőrzése, segítség fogalmazásban, brain-storming.	OpenAI ChatGPT 5	Forrásfeldolgozás

Kelt: Czyongyás év október hó 28 nap



Handwritten signature in blue ink, consisting of a large, stylized initial 'J' followed by a horizontal line and a diagonal stroke.

Hallgató aláírása