

SZAKDOLGOZAT

CHRABÁK ATTILA

2023

BUDAPESTI GAZDASÁGI EGYETEM

KÜLKERESKEDELMI KAR

Nemzetközi Gazdálkodás Szak

Üzleti intelligencia és döntések specializáció

MESTERSÉGES INTELLIGENCIA, TERMELÉSOPTIMALIZÁLÁS

KÜLSŐ KONZULENS:
BÁNHALMI ÁRPÁD

BELSŐ KONZULENS:
BUDAI LÁSZLÓ
BUDAPEST, 2023

SZERZŐ:
CHRABÁK ATTILA

1 TARTALOMJEGYZÉK

1	TARTALOMJEGYZÉK.....	3
2	BEVEZETÉS	5
3	TÉMAVÁLASZTÁS INDOKLÁSA.....	7
4	KUTATÁSOM CÉLJAI	7
5	KUTATÁSI KÉRDÉSEIM.....	8
6	HIPOTÉZISEK	9
7	KUTATÁSOM MÓDSZERTANA	10
8	A DOLGOZAT FELÉPÍTÉSE	10
9	ELMÉLETI HÁTTÉR	12
9.1	Mit értünk mesterséges intelligencia és gépi tanulás alatt?.....	13
9.2	A mesterséges intelligencia története	16
9.3	Milyen mértékű Magyarország esetében a mesterséges intelligencia vállalati szintű alkalmazása?	18
9.4	Milyen feladatok, problémák megoldásában lehet a segítségünkre a mesterséges intelligencia, mik az eddig ismert alkalmazásai, milyen hasznai lehetnek még?.....	20
9.5	Mik a vállalati mesterséges intelligencia bevezetésének lépései?.....	22
9.6	Milyen hatással van a mesterséges intelligencia a magyar munkaerőpiacra?	25
10	A TECHNOLÓGIÁK BEMUTATÁSA.....	27
10.1	Microsoft Azure.....	27
10.2	Siemens - Technomatix Plant Simulation	27
10.3	Power BI.....	29
11	AZURE PREDIKTÍV KARBANTARTÁS FELADAT	30
12	PLANT SIMULATION ÉS POWER BI CIKLUSIDŐ OPTIMALIZÁLÁS FELADAT.....	47
13	A MESTERSÉGES INTELLIGENCIA ISMERTSÉGE ÉS A TÁRSADALMI ELFOGADOTTSÁGA.....	63
13.1	A kérdőívek adatainak elemzése:	64
13.2	Elemző diagramok	71
14	ÖSSZEFOGLALÁS	77
15	KÖSZÖNETNYILVÁNÍTÁS	78

16 IRODALOMJEGYZÉK	79
17 ÁBRÁK JEGYZÉKE.....	84

2 BEVEZETÉS

A STEEP elnevezés egy mozaikszót rejt, melyben a betűk az elemzés alapját képező szavakat jelentik.

- **S – Social** = Társadalmi környezet;
- **T – Technological** = Technológiai környezet;
- **E – Economic** = Gazdasági környezet;
- **E – Environmental** = Természeti környezet;
- **P – Political** = Politikai környezet.

Általában a STEEP analízist a vállalkozásokra ható makrokörnyezeti elemek vizsgálatánál használják. Az elnevezést alkotó összetevők azonban megfelelő keretet alkotnak ahhoz, hogy a teljes világot környezeti tényezőkre osszuk és a tényezőket befolyásoló hatásokat megvizsgáljuk. Számptalan tendencia jelent meg az utóbbi évtizedekben, melyek befolyásolják az életünket és kitüntetett figyelem övezi őket.

- Társadalmi környezet: A társadalmi környezetet érintő trendek a népesség szerkezetére, értékeire és magatartására vonatkoznak. Egy olyan jellemző változást figyelhattunk meg az elmúlt évtizedekben, amely főként európai országokat érint. Az előregedő társadalom, amelynek hatása a nyugdíjrendszert érzékenyen befolyásolja. Afrikai országokban, Indiában és Pakisztánban ezzel ellentétes folyamatok figyelhetők meg a születésszámokat tekintve. Sőt a becslések szerint 2027-re India lesz a Föld legnépesebb állama. Egy másik fontos trendet, egyúttal számottevő problémát az egyre kirívóbb társadalmi különbségek jelentik, melyek érzékelhetők globálisan és régiókn belül egyaránt. Például Luxemburgban ugyanazért a munkáért a magyar átlagos havi bruttó bér 3,5-szeresét keresik az emberek. Látványos változást hoz továbbá az Európai Unió lakosságát tekintve a nagymértékű beáramló migráció és ezáltal az őshonos népesség lecserélése. A fogyasztói magatartás egyre inkább a környezetvédelem irányába mozdul el, ami pedig jelentősen befolyásolja a vállalkozások piaci stratégiáját és az árakat.
- Gazdasági környezet: A gazdasági trendek befolyásolják a gazdasági növekedést, a foglalkoztatást és a pénzügyi stabilitást. Az elmúlt évtizedekben a világgazdaság nagymértékben globalizálódott, és a pénzügyi piacok is összekapcsolódtak. Ez lehetővé tette a befektetők számára, hogy szinte bárhol és bármibe a világon befektessenek és diverzi-

fikálják portfólióikat. Globális szinten a GDP-növekedés erőteljes és tartós volt az elmúlt években, de a világjárvány hatására 2020-ban visszaesett, a munkanélküliség és az infláció egyúttal világszerte növekedett.

- Technológiai környezet: A technológiai trendek hatással vannak a munkaerőpiacra, termelési folyamatokra, a termékek és szolgáltatások fejlesztésére és a piaci stratégiákra. Az egyik közismert technológiai trend a távmunka és távoktatás lehetősége, amivel erősen összefügg az internethasználat elterjedése és a digitalizáció, amelynek hatása az üzleti modellre és az ügyfélélményre a mindennapok során is érzékelhető. Az internet és a mobiltelefonok elterjedésének köszönhetően pedig megjelentek a digitális fizetési módok és a blokklánc technológia is ezáltal új lehetőségek adódnak az emberek számára a pénzügyeik kezelésére. A mesterséges intelligencia alapú megoldások, az automatizálás és robotizáció teljes mértékben átformálhatja a jövő iparágait és a munkaerőpiacot.
- Természeti környezet: A környezeti trendek hatással vannak a természeti erőforrásokra, a klímaváltozásra és a fenntartható fejlődésre. Meghatározó trendek a megújuló energiaforrások és a környezetbarát megoldások. Az éghajlatváltozás hatására az országoknak meg kell küzdeniük a negatív hatásokkal, például a földterületek elsivatagosodásával, az ivóvízkészlet eltűnésével vagy az egyre gyakoribb természeti katasztrófákkal. A vállalkozásoknak is új megoldásokat kell találniuk a termelési folyamatok és az áruk szállítása terén.
- Politikai környezet: A kormányzati politikát, a jogi keretrendszereket és a geopolitikai helyzetet vizsgálva az egyik legfontosabb politikai trend manapság a globalizációra adott válaszként a protekcionizmus és a nacionalizmus térnyerése, amely befolyásolja a már meglévő és az újonnan kialakuló gazdasági és kereskedelmi kapcsolatokat.
- Fontos megemlíteni azt a tényt, hogy az Európai Unió és Oroszország közötti kapcsolatok még tovább romlottak a 2021-ben felerősödött orosz-ukrán háború és az EU részéről az Oroszországgal szembeni szankciós politika és az ukrán fél támogatása miatt, aminek következményeként az Európai Unió gazdasági ereje csökkent, valamint a fokozatosan megszűnő kereskedelmi kapcsolatok miatt az európai tagállamoknak újra kell gondolniuk az energiapolitikájukat.

Az STEEP analízis módszere lehetővé teszi számunkra, hogy átfogó képet kapjunk azokról a trendekről, amelyek befolyásolják a világunkat. Az elemzés eredményeképpen felismerhetjük azokat a kihívásokat és lehetőségeket, amelyekre válaszokat kell találnunk a fenntartható fejlődés érdekében. (Dávid, 2023)

Szakedolgozatom témájának a mesterséges intelligenciát választottam és termelési területen fogok vizsgálni.

3 TÉMAVÁLASZTÁS INDOKLÁSA

Napjainkban egy új és különleges ipari forradalom időszakában élünk. A termelés sebességének növekedése és egyre nagyobb mértékű önműködése az információs technológia és automatizált berendezések összekapcsolódásával valósul meg. A munkafolyamatokat intelligens gépek szervezik és optimalizálják, valamint okos gépek rögzítik precízen azokat a releváns adatokat, amik alapján a termelési döntéseket meghozzák. A negyedik ipari forradalom kezdete a szélessávú internet térnyerésének időszakára, a 2000-es évek elejére tehető. Jelenleg az Egyesült Államokban a 100+ főt foglalkoztató ipari vállalkozások 28 százalékában fut valamilyen ipar 4.0.-projekt. Ez az arány Németországban 25, Japánban 20, Franciaországban 8, Kínában pedig 6 százalék.

Képzeljünk el egy hatalmas gyárat, aminek termeiben nincs egyetlen ember sem. Csak különféle gépek, amik szabályos koreográfia szerint dolgoznak, vagy szállítják a termeléshez szükséges anyagokat, és mindeközben folyamatosan kommunikálnak egymással. Csupán akkor jelenik meg a helyszínen a gyártást felügyelő technikus, ha az erre beprogramozott robotok valamelyike értesítést küld, hogy emberi beavatkozásra van szükség. Ideális esetben minden folyamat optimalisan kicsi energiafelhasználással és megújuló forrásokból zajlik, így csökkentve az ökológiai lábnyomunkat. Ilyen és ehhez hasonló okosgyárak potenciálját hordozza magában az ipar 4.0 az elkövetkező évtizedekben, amelynek egyik alappillére többek között a mesterséges intelligencia.

2055-re a munkák 50%-a automatizálva lesz olyan gépekkel, amelyek már most képesek lennének elvégezni a feladatok 30%-át. A közeljövőben tehát várhatóan jelentősen megnő az IT-munkahelyek száma, mert minél nagyobb mértékben fog elterjedni a mesterséges intelligencia, annál több informatikai szakemberre lesz szükség. A jövőre való felkészülés miatt fontosnak tartom és mindenkinek ajánlom, hogy jobban megismerkedjen ezzel a témával. (Tablázat.hu, 2019)

4 KUTATÁSOM CÉLJAI

A kutatásom egyik célja, hogy létrehozok Microsoft Azure rendszerben a rendelkezésemre álló adathalmaz felhasználásával ún. machine learning modelleket (gépi tanulási modellek). A modelleket megvizsgálva, elemezve kiválasztom azt, amelyik a vállalat termelési teljesítménye

szempontjából a legmegfelelőbb. Kutatásom másik célja, hogy egy termelő vállalat szimulációban összegyűjtött adatait Microsoft Power BI dashboard rendszerben elemezve és az adathalmazt megtisztítva Technomatix Plant Simulation rendszerbe implementálva az milyen területeken lehetne javítani az adott vállalat termelési teljesítményén és az elemzéseim pontosan mutassák az elérhető javulás mértékét. A két esettanulmány, amivel dolgozni fogok a következő:

- prediktív karbantartási adathalmaz
- SSFL szimulációs labor eredményei alapján modell építése

Szeretnék továbbá betekintést nyújtani az IPAR 4.0., IPAR 5.0., és a mesterséges intelligencia, ezen belül főként a gépi tanulás egyedi világába, kiemelve az említett kifejezések jelentését és jelentőségét.

5 KUTATÁSI KÉRDÉSEIM

- Milyen megállapításokra, eredményekre jutok az adathalmazokkal folytatott munka kapcsán?
- Mennyire jó befektetés egy vállalat részéről mesterséges intelligenciát alkalmazni?

A hypeciklus fogalom azt jelenti, hogy az új technológiai újítások várható rövid távú hatásaival kapcsolatban a várakozások rendszerint túlzottan is optimisták. A technológia fejlődésének korai szakaszában meglévő optimizmust sokszor kiábrándulás és olyan eredmények követik, amelyeket csalódásnak tekintenek, aminek következtében a hosszú távú hatásokat érintő vélemények alábecsülik az új technológiák indukálta valódi változások erejét. Ez a folyamat a mesterséges intelligencia esetében nagyon hasonlóan zajlott. A McKinsey Institute, amely alapvetően pozitív hozzáállást mutat a becslések terén, a gazdasági növekedés jelentős és intenzív felgyorsulását jósolja a jelentésében (Bughin és szerzőtársai, 2018). A tanulmány alapján a mesterséges intelligencia hatékonyságot növelő, továbbá az innovációs folyamatokat támogató és katalizáló hatása következtében a globális növekedés évente több mint 1,2 százalékkal, 2030-ig összesen 16 százalékkal gyorsul fel.

A PWC-nél ez az érték 14 százaléknak felel meg (vagyis a világ GDP-je 2030-ban 14 százalékkal lesz magasabb annál, mint amennyivel (mesterséges intelligencia híján) egyébként is nőtt volna 2030-ig (PWC, 2018).

Habár a becslések a hypeciklus elmélet szerint túlzottan is optimisták, az AI technológia termelékenységnövekedésre gyakorolt hatása kétségbevonhatatlanul jelentős.

Az AI munkaerőpiacot érintő hatásait tekintve az látható, hogy nagyon kevés olyan állás van, amely teljes egészében automatizálható, ellenben gyakorlatilag az összes állás tartalmaz automatizálható feladatokat, a mesterséges intelligencia pedig rendkívül jól használható az ilyen jellegű feladatok elvégzésre.

Ebből az következik, hogy a munkaadóknak újra kell gondolniuk az alkalmazottak feladatainak összetételét: minden egyes állás esetében újra kell definiálni a feladatköröket, egyes korábbi feladatokat leválasztani és automatizálni, helyettük más feladatokat allokálni, vagyis az összes feladatkört át kell csoportosítani. Ez átfogó munkaszervezési és vállalatszerkezeti átalakítást tesz szükségessé. A feladatkörök optimalizálása kísérletezéssel, visszacsatolások sorozatával, adott esetben képzések indításával, a munkaerő fluktuációjával is jár, amiknek mind idő és költségvonzata van. A munkakörök újragondolása azonban támogatja a szakképzett munkaerőt, hiszen a megmaradt munkaidő nagy részében kreatív, komplex, nagy hozzáadott értékű feladatokat végezhet, ami a dolgozó munkájának termelékenységének növekedését eredményezi.

Vállalattól függően sok esetben a mesterségesintelligencia-megoldások nagy értékű hardver- és szoftverberuházásokat is igényelnek.

Összességében a mesterséges intelligencia vállalati bevezetése hosszútávon kifizetődő és célszerű. Rövidtávon számottevő kiadásokra lehet számítani. A technológia sikeres integrálásához át kell alakítani üzleti folyamatokat, amik jelentős mennyiségű és költségű komplementer beruházásokat igényelnek. Ezen kívül a termelékenységi mutatók javulása későbbre várható, amikor eltelik annyi idő, hogy a kulcsfontosságú komplementer beruházások beérjenek és bevételt eredményezzenek. (Szalavetz, 2019)

6 HIPOTÉZISEK

A fentebb írtak alapján három hipotézist vizsgállok a dolgozatomban:

- H0: Az AI (gépi tanulási modellek) alkalmazása szignifikánsan segítik a munkafolyamatokat
- H1: Az adatvizualizáció szignifikánsan segíti a döntéstámogatást
- H2: Az emberek többségének kevés ismerete és még kevesebb jártassága van az AI-ban

7 KUTATÁSOM MÓDSZERTANA

Kutatási módszereim illeszkednek a választott témámhoz.

Az IPAR 4.0. és IPAR 5.0. fogalmak meghatározásához interneten olvasott cikkek segítségét veszem igénybe. Ezekből a cikkekből statisztikákat gyűjtök, melyek megmutatják, hogy mi a szerepe a mesterséges intelligenciának, hány vállalat használ már valamilyen mesterséges intelligenciát a működése során.

Szakirodalmat elsősorban youtube videók formájában gyűjtök, a keresőszavaim főként a mesterséges intelligencia, gépi tanulási modell, termelésoptimalizálás kifejezések illetve ezen szavak angol nyelvű megfelelői.

Továbbá azokból a szakdolgozatokból, amelyek szorosan kapcsolódnak a választott témámhoz, azokból az értékes információkat megkeresem és kigyűjtöm, ezzel is színesítve a szakdolgozatomat.

Ábrákat, grafikonokat saját magam készítek, hogy bemutathassam a machine learning modellek kiépítésével és a ciklusidőoptimalizálással elért eredményeket. Ezek az illusztrációk többnyire olyan képkivágások lesznek, melyeket az itt felsorolt programok valamelyikével készítek: Microsoft Azure, Microsoft Excel, Power BI, Plant Simulation.

Kérdőívemben a mesterséges intelligencia ismertségét és társadalmi elfogadottságát vizsgálom meg.

8 A DOLGOZAT FELÉPÍTÉSE

A diplomamunkámat logikus módon, részletesen kidolgozott terv szerint építem fel. Ez a terv a következő:

A bevezető részben a STEEP analízis módszert követve egy rövid összefoglalást készítek arra vonatkozóan, hogy melyek azok a globális trendek, amelyek a világ eddig megszokott működését, folyamatait formálják, alakítják. Az ismertető részt témaválasztással zárom. Kifejtem az automatizáció és a mesterséges intelligencia munkaerőpiacra gyakorolt várható hatásait és elemzem a becsült változás irányát, nagyságát ezáltal az olvasó betekintést nyer a témám fontosságába.

Ezután bemutatom az IPAR 4.0., és IPAR 5.0.-át, kifejtem, hogy a vállalatok miért nyitottak a mesterséges intelligenciát használó gépek iránt.

Összefoglalót készítek és ismertetem a mesterséges intelligencia módszereit. Összegyűjtöm a gyakorlati alkalmazási lehetőségeit. Ebből látszódni fog, hogy sok területen alkalmazzák a mesterséges intelligenciát. A sok terület közül egyet vizsgálok meg, ez pedig a termelés lesz. Hogyan és mire használják a mesterséges intelligenciát olyan alapvető területen, mint a termelés? – A dolgozat hátralévő részében ezzel a kérdéssel foglalkozok. A kérdés megválaszolására kettő adathalmaz áll a rendelkezésemre. Ezeket fel fogom használni, azzal a céllal, hogy gyakorlati feladatok megoldásával is szemléltessem a termelés optimalizálásának egy-egy folyamatát.

Ennek a folyamatnak a lépései:

- Meg kell adni ennek az egész termelésoptimalizálási feladatnak a célját és hogy milyen eredményeket szeretnék elérni.
- Át kell tekinteni az adathalmazokat, értelmezni.
- Tiszta adatökoszisztémát kell létrehozni, pontosan le kell írni, hogy hogyan készítettem elő az adatokat a velük elvégzendő munkára?
- Be kell mutatni és végre kell hajtani a feladatmegoldás lépéseit
- Végül értelmezni kell az elért eredményeket

A folyamat lépéseinek értelmezéséhez képkivágásokat, grafikonokat készítek.

A diplomamunkát a kérdőívre érkezett válaszok kiértékelésével zárom.

9 ELMÉLETI HÁTTÉR

Ebben a részben a mesterséges intelligencia fogalmát, annak történeti előzményeit, alkalmazási lehetőségeit, Magyarországra vonatkozóan a jelenlegi és jövőbeli szerepét tárom fel.

Célom, hogy az olvasó betekintést nyerjen a téma alapvető ismereteibe:

1. Mit értünk mesterséges intelligencia és gépi tanulás alatt?
2. A mesterséges intelligencia historikus története
3. Milyen mértékű Magyarország esetében a mesterséges intelligencia vállalati szintű alkalmazása?
4. Milyen feladatok, problémák megoldásában lehet a segítségünkre a mesterséges intelligencia, mik az eddig ismert alkalmazásai, milyen hasznai lehetnek még?
5. Mik a mesterséges intelligencia bevezetésének lépései a vállalatokhoz?
6. Milyen hatással van a mesterséges intelligencia a magyar munkaerőpiacra?

9.1 Mit értünk mesterséges intelligencia és gépi tanulás alatt?

A mesterséges intelligencia (a továbbiakban: AI, MI, mesterséges intelligencia) számítógépes

1. ábra - A mesterséges intelligencia részei



Forrás: Nexius Learning

alkalmazásoknak, algoritmusoknak a gyűjtőfogalma, amelyek az emberi viselkedést, gondolkodást utánozzák (Hold). Továbbá a mesterséges intelligencia számítógépes rendszereknek olyan képessége, amely adatok gépi feldolgozását végezve olyan feladatokat old meg (automatizál, felgyorsít, támogat), amelyekre korábban csak a (természetes intelligenciával rendelkező) ember volt képes.

Ebben a meghatározásban a gépi feldolgozás kifejezés is szerepel, ami az MI fejlődésében bekövetkezett áttörésre, a(z) általános célú) gépi tanulásra utal. A mesterséges intelligencia fejlődése ugyanis akkor gyorsult fel (a 2010-es években), amikor az egyes feladatok explicit kódolása, a gépek feladatspecifikus beprogramozása helyett a gépek nagy tömegű példa segítségével történő betanítására tértek át. Ehhez természetesen arra is szükség volt, hogy rendelkezésre álljon olyan adattömeg, amellyel már a gépeket tanítani lehetett, illetve olyan számítástechnikai kapacitás, amely képes nagy adattömeggel megbirkózni. Ez utóbbi terület fejlődése (az egyre erősebb hardverek, a felhőalapú infrastruktúra, a grafikus feldolgozó egységek, a mesterséges intelligencia futtatására fejlesztett speciális chippek) elengedhetetlen volt és lesz is a mesterséges intelligencia további fejlődéséhez. Összefoglalva a mesterséges intelligencia képes értelmezni, egységesen kezelni, szintetizálni és feldolgozni különböző módokon kódolt (szöveg, szám, kép,

hang, videó, stb.) emberi tudást – és ami szintén a definíciójához tartozó fontos megkülönböztető jellemvonás: megfelelő mennyiségű betanítás után korábban nem betanított bemeneti információ értelmezésére is képessé válik.

A gépi tanulás (angol nevén: Machine Learning, ML) a mesterséges intelligencia azon részhalmaza, amely az emberi intelligens viselkedések csoportjából a tanulás képességére fókuszál.

Minden olyan eset gépi tanulási feladatnak minősül, melynél adott egy számítógépes rendszer és annak teljesítménye tapasztalatok és megfigyelések gyűjtésével javítható.

A gépi tanulással megoldott különböző feladatok száma rengeteg és ez a szám az idő haladtával egyre csak növekedni fog.

Néhány ismertebb példa ML megoldásokra és esettanulmányokra:

- Képfelismerés: gépi tanulási algoritmusok segítségével az elkészített modell képes felismerni képeket és beazonosítani az azokon található objektumokat, a gépi tanulásnak ezt a funkcióját használják önvezető járművek esetében, az arc- és ujjlenyomat azonosításban.
- Nyelvi feldolgozás: a gépi tanulást előszeretettel használják cégek kommunikáció megvalósítására, azaz beszédfelismerésre, gépi fordításra, automatikus válaszadásra, az informatikában programkódok írására.
- Betegség diagnosztizálás: ebben az esetben különféle betegségek és egészségügyi állapotok diagnosztizálásában használják a gépi tanulást, például EKG-jelzések, röntgenfelvételek, MRI-képek értékelésében. Ezáltal lehetséges a betegségek korai diagnosztizálása és a jobb betegkezelés.
- Ajánló rendszerek: az ilyen rendszerek termékeket, szolgáltatásokat, tartalmakat javasolnak a felhasználóknak, ezáltal egyrészt segítve a felhasználót abban, hogy könnyebben megtalálja a keresett dolgokat, másrészt az üzleti cégek ily módon növelik az értékesítésüket. Az ajánló rendszerek létrehozásában a gépi tanulást használják.
- Játékprogramozás: A gépi tanulás azt is képes lehetővé tenni, hogy az algoritmusok önállóan tanuljanak meg játszani. Például az AlphaGo nevű program gépi tanulással ismerte meg a játék szabályait és győzte le a világbajnokot.

- Ipari alkalmazások: a gépi tanulás és az ipari gyártás területei szorosan kapcsolódnak egymáshoz. A gépi tanulás segítségével létrehozhatók olyan megoldások, amelyek képesek hatékonyan fokozni a termelési hatékonyságot. Az anyagmozgatási folyamatok optimalizálása, a gyártás energiaszükségletének csökkentése, termelési idők rövidülése, a gépek karbantartásának előrejelzése és azok élettartamának növeléséhez szükséges megfelelő beállítások megkeresése mind olyan feladat, amiket a gépi tanulás eszközrendszerével meg lehet oldani. :
- Pénzügyi vonatkozások: a pénzügyi szektorban a döntéshozatal folyamatát képes támogatni a gépi tanulás, olyan esetekben, mint például részvényelemzés, portfólióoptimalizálás, árfolyambecslés, vállalati csőd-előrejelzés, pénzügyi termékekre vonatkozóan kereslet-előrejelzés, ügyfélszegmentáció, csalás felderítés, hitelkockázat-értékelés. (Projectpro, 2023)

Feladattípustól függően három ML megközelítés létezik. Ezek a következők:

- **Felügyelt tanulás (supervised learning):** ebben az esetben rendelkezésünkre áll egy adathalmaz és tudjuk azt, hogy mi az elvárt célérték. Az adathalmazt tanító adatbázisnak (training dataset) szokták nevezni. A cél, hogy a tanító adatbázist felhasználva olyan modellt tanuljon meg az MI rendszerünk, amely korábban sosem látott példákon keresztül is helyesen működik.

Egyik gyakorlati alkalmazása az, amikor ügyfélszolgálatra érkező e-mailes panaszleveleket akarunk automatikusan továbbítani a szakmai kompetenciák szempontjából a megfelelő munkatárshoz, aki aztán megfelelő választ tud adni az adott kérdésre. Az adataink sokezer e-mail a múltból és hogy melyik munkatárshoz kellett irányítani a levelet, ez utóbbi az elvárt célérték. Ebből a tanító adatbázisból kell felépítenünk egy modellt, amely a beérkező e-maileket maximális pontossággal automatikusan a megfelelő munkatárshoz irányítja.

- **Felügyelet nélküli tanulás (unsupervised learning):** bizonyos esetekben a gyűjtött adatokhoz nem tartozik elvárt célérték (felügyelet). Ilyen esetben módosul a cél, már nem az, hogy olyan modellünk legyen amely korábban sosem látott példákon keresztül is helyesen működik, hanem az adatok közti mintázatok/összefüggések keresése. A tanítás ebben az esetben a különböző mintázatok/összefüggések definícióit jelenti, melyek mérnöki iterációk sorozatának végrehajtása után fogalmazódnak meg megfelelően. Gyakorlati esettanulmány: egy vállalat ügyfeleinek múltbeli tranzakciós adatait használjuk fel. Találunk olyan ügyfeleket, ügyfélcsoportokat, akik hasonlóan viselkednek.

- **Megerősítéses tanulás (reinforcement learning):** ennél az ML megközelítésnél a tanuló rendszer folyamatosan egy adott műveletet hajt végre. Ha elvégezte a feladatot, megerősítést kap, hogy mennyire jól csinálja a feladatát, és ezekből a megerősítésekből folyamatosan tanul.

Jó példa erre az, amikor egy robotot tanítanak dolgokra, például arra, hogyan kell büntetőt rúgni a fociban. A robot a büntetőrúgás végén visszajelzést kap, hogy sikeres volt-e amit csinált. Ebből fogja aztán önállóan kialakítani a mozgássorozatot, amivel újra megpróbálja a tizenegyest értékesíteni és a sok próbálkozás és visszajelzés után végül sikeres tizenegyesrúgó lesz.

(Farkas, 2022, Szalavetz, 2019)

9.2 A mesterséges intelligencia története

A mesterséges intelligencia (MI) története egészen az 1940-es évekig nyúlik vissza, amikor a tudósok elkezdték kutatni, hogyan lehetne egy gépet olyan módon programozni, hogy az emberi intelligenciához hasonlóan tudjon gondolkodni. A tudományág története hosszú és sokrétű, azonban a lényeges dátumokat érdemes kiemelni. 1943-ban Warren McCulloch és Walter Pitts publikálják "A logikai számítógépek elmélete" című cikküket, amelyben az alapelveket fektetik le a mesterséges neuronhálózatokra.

1950-ben Alan Turing megírta a "Computing Machinery and Intelligence" című cikkét, amelyben megalapozta az AI fogalmát és a Turing-tesztet.

John McCarthy, Marvin Minsky, Claude Shannon és Nathaniel Rochester közösen 1956-ban az MIT-n tartottak egy konferenciát, amelynek célja az volt, hogy összegyűjtse az MI kutatóit és elindítsa a tudományterület fejlődését.

Az 1950-es években és az azt követő évtizedekben az MI kutatása nagyon népszerű volt, és a tudósok sok fontos algoritmust és technológiát fejlesztettek ki, mint például a mesterséges neuronhálózatokat és a szimbolikus AI-t. A további kutatási eredményeket tekintve, 1959-ben Frank Rosenblatt megalkotta a "Perceptron" algoritmust, ami egy egyszerű neurális hálózatot alkalmazott a mintafelismerésre.

Azonban az AI kutatásának kezdeti lendülete hamar megcsappant, amikor kiderült, hogy a korai AI rendszerek képtelenek kezelni a komplex problémákat.

Az 1980-as évek végén és az 1990-es évek elején azonban újabb fejlesztések történtek az MI terén, amelyek lehetővé tették a gépek számára, hogy összetettebb problémákat oldjanak meg,

mint például hangok és képek felismerése. Az általános rendelkezésre álló számítási erő növekedésével és az algoritmusok javulásával az MI fejlődése egyre nagyobb lendületet vett.

A 21. században az MI számos területen hatékonyan alkalmazhatóvá vált, mint például az önvezető járművek, a virtuális asszisztensek és a személyre szabott ajánlórendszerek.

Jelentős sikerek születtek a 2020-as évek elején, például:

2020-ban a koronavírus-járvány idején a Google és a DeepMind segítségével sikerült előrejelzéseket készíteni a járvány terjedéséről. Ugyanebben az évben az Nvidia bemutatja az első mesterséges intelligencia alapú beszédhangkészítőt, amely valósághű hangokat hoz létre.


Az OpenAI pedig bemutatja a GPT-3 nevű, eddigi legnagyobb és legkomplexebb nyelvi modellt, amely emberi szövegek előállítására képes és 2022 végén vált mindenki számára elérhető a frissített, javított verzió, amely gyorsan rendkívül népszerűvé vált.

2021-ben a Tesla önvezető autói az AI által vezérelve megtették az első teljes Budapest-Bécs útvonalat, anélkül, hogy emberi beavatkozásra lett volna szükség, valamint Az AlphaFold nevű gépi tanulási rendszer segítségével a DeepMind tudósai megoldást találnak az egyik legnagyobb kihívásra az élettudományokban, a fehérje szerkezet előrejelzésre.

Ezek csupán a fontosabb események voltak az utóbbi évek kutatási eredményeinek hosszú listájából, azonban az AI fejlődése továbbra is dinamikus és gyors ütemű. A jövőben még számos új mesterséges intelligencia alapú fejlesztés várható az intelligens rendszerek és gépek terén. (Reynoso, 2021)

9.3 Milyen mértékű Magyarország esetében a mesterséges intelligencia vállalati szintű alkalmazása?

2. ábra - MI-t használó vállalkozások aránya az EU-ban és egyes országokban



Forrás: Eurostat, 2021

Magyarországon 2018-ban megalakult a Mesterséges Intelligencia Koalíció nevű szakmai fórum, majd 2020 májusában tették közzé Magyarország Mesterséges Intelligencia Stratégiáját, aminek egyik fő célja, hogy több mesterséges intelligenciát alkalmazó vállalkozás működjön hazánkban.

2021-ben az Eurostat felmérésében Magyarország a sereghajtók között van az MI-t használó vállalkozások listáján. A kutatás szerint Magyarországon (Bulgáriával, Ciprussal, Észtországgal és Lengyelországgal együtt) a vállalkozások 3 százaléka hasznosítja az AI-t, aminél csak egy ország áll rosszabbul, az 1 százalékot elért Románia. Az EU-s átlag 8 százalék, míg a legnagyobb arányban Dánia (24%), Portugália (17%), Finnország (16%), valamint Luxemburg és Hollandia (13-13%) büszkélkedhet AI-t használó vállalkozásokkal.

Az Eurostat azokat a vállalkozásokat tekintette mesterséges intelligenciát használónak, amelyek a következő hét technológiából legalább egyet igénybe vettek:

- írott nyelvet elemző technológiák (szövegbányászat);
- a beszélt nyelvet gépek számára olvasható formátumba alakító technológiák (beszédfelismerés);
- írott vagy beszélt nyelvet generáló technológiák (természetesnyelv-generálás);

- tárgyakat vagy személyeket kép alapján azonosító technológiák (képfelismerés, képfeldolgozás);
- adatelemzésre használt gépi tanulás (pl. mélytanulás);
- különböző munkafolyamatokat automatizáló vagy a döntéshozatalt segítő technológiák (AI-alapú szoftveres, robotizált folyamatautomatizálás);
- illetve olyan technológiák, amelyek lehetővé teszik a gépek fizikai mozgását, miközben megfigyelik környezetüket és autonóm döntéseket hoznak. (Bodnár Zsolt, 2022)

A top tíz vállalat hazánkban melyek élen járnak az AI megoldások megvalósításában, az alábbiak:

1.LEXUNIT

2.TECHNOLYNX

3.WOZIFY

4.CODEANDSODA

5.SCRIPTIDE

6.ROBOROBO

7.YIGSOFT

8.OPTHINK

9.MYRMIDONTECHNOLOGY

10.BRANDITORIAL

A listában szereplő cégekre jellemző, hogy a 2010-es és 2020, 2021. évben alapították meg őket, tehát csupán néhány éve kerültek fel a vállalati térképre. Kis létszámú munkaerőt foglalkoztatnak, ami általában 2-9 fő vagy 10-49 főt jelent. Tevékenységük, szolgáltatáskínálatuk hasonló: webes alkalmazásfejlesztés, felhőalapú szolgáltatásfejlesztés, IT outsourcing, adatelemzés, data science, adatvizualizáció, döntéstámogatás, prediktív karbantartás, gépi látás, természetes nyelvfeldolgozás, tanácsadás, mobil alkalmazásfejlesztés. (THE MANIFEST, 2023)

9.4 Milyen feladatok, problémák megoldásában lehet a segítségünkre a mesterséges intelligencia, mik az eddig ismert alkalmazásai, milyen hasznai lehetnek még?

A technológia alkalmazási lehetőségeit illetően újabb és újabb tudományos közlemények, üzleti tanácsadói elemzések jelennek meg, amelyekben mesterséges intelligencia integrálásával elért eredményekről szólnak, emiatt az alkalmazási lehetőségek listája folyamatosan bővül.

A következőkben a legismertebb alkalmazási területeket ismertetem.

Ma már nincsen olyan iparág, ahol ne lenne jelen egyáltalán a mesterséges intelligencia. Az egészségügyben az adott páciensről készült képeket elemzi a technológia, hogy azonosítsa, felismerje a konkrét betegséget. Például ha a kérdés az, hogy egy röntgen képen egy rákos sejt látható-e, azt a mesterséges intelligencia meg tudja mondani. Használják gyógyszerigények azonosítása céljából is.

A kereskedelemben készletek kifogyásának, pénztárnál kialakuló soroknak az előrejelzésére is használják. Magyarországon működik olyan bolt, ahol arcfelismerésre képes és a vevők banki adataival mobiltelefonos applikációk segítségével összekötött mesterségesintelligencia-rendszereket használnak, amik azt teszik lehetővé, hogy a vásárlónak ne kelljen a pénztárnál sorbaállni és a fizetéssel foglalkozni: amit elvisz az üzletből, annak az ellenértéke automatikusan levonódik a bankszámlájáról.

Ha folyamatosan rendelkezésre állnak értékesítési adatok és amennyiben szükséges, egyéb paraméterek is (például ünnepek, időjárás stb.) akkor a rendszer ezeket figyelembe veszi és képes pontos becslést adni arról is, hogy miként alakul a közeljövőben a kereslet adott termékek iránt. (AI-Hungary, 2020)

A mezőgazdaságban többféle módon alkalmazzák, a mezőgazdasági gépek autonóm irányításától kezdve, drónok készített képekkel történő terményproblémák azonosítására, súlybecslés, beteg állatok kiszűrésére egyaránt alkalmas. Szenzorokkal figyelik a talaj állapotát, a termés fejlődését, hogy optimalizálhassák a növényvédőszeres és öntözés mennyiségét, a kártevők támadását pedig időben lehet észlelni.

A bankszektorban email-ek automatikus megválaszolására, ügyfelek lemorzsolódásának mérésére, pénzügyi kockázatok elemzésével a hitelelemzők támogatására, lehetséges káresemények bekövetkezésének modellezésére, valamint tranzakciók mintázatának elemzésével a csalások, visszaélések azonosítására használják.

Az államigazgatásban a Központi Azonosítási Ügynök mesterséges intelligenciát használva végzi az azonosítási folyamatokat, az önkiszolgáló kormányablaki és online ügyintézés, a bűn-megelőzés adatokon történő viselkedés-elemzéssel, a kiberbiztonsági védekezés mind mesterséges intelligencia segítségével valósulnak meg.

Az energetika, villamos hálózatok területen a fogyasztás előrejelzés mesterséges intelligencián alapul, a számlaképek feldolgozását szoftverrobotok végzik. A távközlésben az ügyfélszolgálat munkáját jelentősen megkönnyítik telefonos és chat robotok. A marketing üzeneteket, értékesítési ajánlatokat mesterséges intelligencia szabja az ügyfél igényéhez, jó példa erre a Netflix személyre szabott filmajánló rendszere.

A mesterséges intelligencia nagyszámú önéletrajz, kísérőlevél, LinkedIn-profil, állásinterjú-leirat (vagy hanganyag) elemzése alapján kiválasztja, hogy egy adott állásra jelentkezők közül melyik lesz a legmegfelelőbb ezzel támogatva a HR-es feladatát.

A közlekedés, logisztika azon belül a termelési logisztika területén ami a vállalati logisztika legmeghatározóbb rendszere, és a termelési folyamatokhoz szükséges anyagok és gyártóeszközök, a termelési folyamat és részfolyamatainak összhangjához, a termelésben létrehozott termékeknek a fogyasztók/felhasználók felé történő biztosításához szükséges anyag- és hozzá kapcsolódó információáramlási folyamatok összességét jelenti, az automatizált raktározási rendszerben önvezető járművek hozzák-viszik az anyagokat, készterméket. A vállalat költségeinek csökkentése érdekében a szállító járművek kapacitáskihasználtságának növelését, a gyorsaság, üzemanyagfelhasználás paramétereit is figyelembe véve folyamatos útvonal optimalizálással végzik. A jövő közlekedésében pedig várhatóan az önvezető járművek vállalnak majd jelentős szerepet.

A gyártásban a technológia többféle módon tud segíteni, például a feldolgozóipari berendezések zajszintje, hőmérséklete, vibrációja és egyéb paramétereit alapján előrejelzi azt, hogy a gyártóegységek mikor hibásodnak meg, ezzel lehetőséget teremtve a prediktív karbantartásra, ami nagyon költséghatékony. Kameraképek alapján a selejtes termékek kiválogatására, minőségellenőrzésre is használják. A termelési kapacitás növelésére valamint ehhez kapcsolódóan a kereslet előrejelzésével a készletek nagyságának optimalizálására is megoldást kínál. (Szalavetz, 2019)

9.5 Mik a vállalati mesterséges intelligencia bevezetésének lépései?

A különböző AI technológiák vállalati bevezetését akadályozzák, sőt akár meggátolják bizonyos problémák. Elég csak arra gondolni, hogy a munkaerőpiacon kevés olyan szakember található, aki rendelkezik a releváns technológiák ismeretével. További gond, hogy a mesterséges intelligencia irányában a bizalom olykor hiányzik a felsővezetők részéről, mivel ők nem tekinthetők technológusnak, inkább csak olvasnak a témában és sokszor csak negatív híreket. Például egy bankot 250 millió Ft-ra büntettek meg, amiért nem tájékoztatta az ügyfeleket, hogy szentimentelemzést használ, és hogy azt pontosan milyen célból. Ilyen hírek hallatán a felsővezető elbizonytalanodik és azt gondolhatja, hogy az AI használata nagy jogi kockázattal jár, amit ő nem tud kezelni.

Problémát jelent az AI kapcsán a szükséges adatok nem megfelelő minősége is, vegyünk példának egy adatbázist, amiben egy adott cég ügyfeleinek adatai vannak. De egy ember, aki az adatok bevitelével foglalkozik néhol hibát vétett, elgépelte a nevet, a személyi igazolvány számot, címet. A rendszer különálló entitásként fogja kezelni az egy személyhez tartozó adatokat, ami jelentős probléma akkor, amikor mesterséges intelligenciát kell tanítani. Általánosságban: ha rossz minőségű az adat, rossz lesz a kimenetel is.

Manapság sok olyan adathalmaz létezik, amiket lehetne elemezni, de még nem foglalkozott velük ebből a célból soha senki. Pénzügyi intézmények esetében például a fizetési szokásainkról az adatokat törvényi előírás miatt gyűjtik, de sok esetben nem végeznek elemzést az adatokon.

Nagyvállalati környezetben, ide sorolhatjuk a bankokat is, átlagosan 120-150 különböző adatbázis van. Az adatbázisokba az adatokat adattárházak gyűjtik aggregáltan, amelyek a legkülönbélebb adatelemzési módszertanok segítségével válnak riportkészítésre, azáltal további üzleti célokra használhatóvá.

A riportkészítés folyamata a IT részleg megkérdezésével kezdődik, hogy el tudják-e küldeni nekünk a szükséges adatokat. Amíg a szakemberek megtalálják a sok adatbázis közül azt, amelyik kell és addig amíg eljutnak hozzánk a megfelelő adatok, sokszor több hét is eltelik. Ezen kívül a megrendelők különböző platformokon kérik az elemzést, Power BI, IBM, Cognos, Tableau és egyéb szoftvereken keresztül, ami egyrészt növeli az elemzés elkészítéséhez szükséges időt, másrészt több BI eszköz ismeretét is megköveteli. A Data Fabric módszertant ehhez hasonló problémák megoldására hozták létre, segíti és felgyorsítja az adatelemzési folyamatokat.

Egy adatvagyon leltárt készít amiben az adatok üzleti felhasználás szempontjából vannak paraméterezve, ezáltal tudni lehet, hogy melyik adatbázisban milyen adatok vannak, így amikor elemzést vagy modellt kell építeni, nem kell rögtön az IT részleghez fordulni, így gyorsítva fel az adatelérés folyamatát.

A Data Fabric architektúrának fontos képessége az adat-virtualizáció, ami azt jelenti, hogy egyszerre több adatbáziskezelő programot képes kezelni.

Az elemzés, AI esettanulmány építés adatok gyűjtésével, rendszerezésével kezdődik, ezt bármilyen adatbáziskezelő programmal el lehet végezni. Ezután az adatok tisztítása, előkészítése a következő lépcsőfok. Ezen a szinten már lesznek olyan adatok, amiket manuálisan kell előkészíteni, de ehhez meg vannak a megfelelő data refinery eszközök, vagy van a nagyvállalati megoldás amikor LPL jelleggel működik az adatelőkészítés. A nagyvállalati megoldásban a hangsúly az adattárház építésen van, amit egyszer kell megcsinálni és egy automatizált, folyamatosan frissülő adatbázist kapunk. De mielőtt a nyers adat bekerülne az adattárházba, írunk egy olyan folyamatot, kódot, ami alapján az adat megfelelő formátumban és minőségben, a szükséges számításokat rajta elvégezve áll rendelkezésre. Innentől fogva magától előáll minden nap az adat. Ezt az adatelőkészítő folyamatot lehet ütemezni, például minden este előkészül nekünk így az adat és másnap reggel már lehet is vele dolgozni. Olyan esetben alkalmazzák az LPL megoldást, amikor napi szinten van szükség az elemzésekre a vezetőknek, például bankok esetében a cash-flow változás vizsgálata során.

Az adattisztítás, előkészítés után utolsó lépésként a modellépítés következik.

Sok változatos és érdekes feladat kapcsán a modellépítés a leggyorsabb és leginkább célravezető megoldás. Olyan feladatokra kell elsősorban gondolni, ahol nagyon sok paramétert kell figyelembe venni.

Néhány példa:


- Kamionsofőrök hogyan tudják minél optimálisabban ellátni a különböző boltokat a megfelelő termékekkel?
- Raktárak létesítése és üzemeltetése esetében mi lenne az optimális megoldás?
- Gyógyszergyár mit gyártson éppen, ha a szokások helyett inkább az ügyfelek igényeit vennék figyelembe?

- Prediktív karbantartás – ebben az esetben például előrejelezhetjük különféle szenzorok meghibásodását így elkerülve a termelés kiesést, megtervezhetjük, hogy a szerelő-karbantartó csapatok mikor jöjjenek ellenőrzésre.

A modellépítés két féle módon történhet, az első esetben saját magunk gépeljük a kódokat, majd a kódrészleteket futtatva építjük a modellünket. A másik esetben a gép végzi helyettünk a modellépítést, nem mi írjuk magunk kódokat, hanem előkészítjük az adatokat, betöltjük a modellépítő programba, kiválasztjuk, hogy milyen adatok és algoritmusok alapján épüljön és milyen szempontok alapján legyen optimalizálva a modellünk. Eredményül 8-10 különböző modellt kapunk, ezek közül pedig akár pontosság alapján kiválaszthatjuk azt, amelyikre szükségünk van. (Huszi, 2022)

9.6 Milyen hatással van a mesterséges intelligencia a magyar munkaerőpiacra?

3. ábra - Az egyes foglalkozási területek várható MI érintettsége



Forrás: KSH 2018, PwC elemzés

Nemzetgazdasági szempontból fontos lépés volna a mesterséges intelligencia minél szélesebb körű elfogadtatása és használata, mert a munkafolyamatok gyorsaságának növelése, a működési és előállítási költségek csökkenése versenyképesebbé tehetné Magyarország gazdaságát. A mesterséges intelligencia magas szintű adaptációja a lakosság életszínvonalának növekedését, az ország népszerűségét eredményezhetné.

A mesterséges intelligencia technológia alkalmazásának az elmulasztása azt jelenthetné, hogy Magyarország nem felzárkózik, hanem még jobban lemarad a versenyképesebb, jobb minőséget gyorsabban előállítani képes gazdaságoktól.

A PwC becslései szerint 2020-tól egészen a 2030-as évek közepéig jelentős és látványos változások várhatóak a fejlettebb iroda hálózattal rendelkező vállalatoknál, valamint a magyar gyártás, szállítás és építőipar területén, elsősorban olyan feladatokra kell gondolni, amik kézi és rutinfeladatok is egyszerre. 2018-ban az aktív dolgozó népesség 4 millió volt, ennek több mint a negyede, körülbelül 1 222 000 dolgozó ember munkájában várható változás, az oktatásban

egészségügyben, szállás-és vendéglátóiparban, mezőgazdaságban és a szociális munkát végző emberek körében mindösszesen 45 000, a nagy-és kiskereskedelem adminisztrációval foglalkozó részén 108 000, a közigazgatásban 96 000, az egyéb adminisztrációs és szolgáltatással foglalkozó munkahelyeken 30 000, míg a feldolgozóiparban az automatizálás 384 500 munkahelyet érint. A szállításnál 107 900, az építőiparban 106 600 fő a változásban érintett munkavállaló. Az automatizálás a kézműves munkásokat és a nem szakképzett dolgozókat is fogja érinteni, ez több mint 195 000 fő. A gépkezelők munkája is valószínűleg meg fog változni, ebben a munkakörben 149 000 alkalmazottról beszélhetünk.

10 A TECHNOLÓGIÁK BEMUTATÁSA

10.1 Microsoft Azure

A Microsoft Azure egy felhőalapú számítási platform, amely megoldást kínál többek között a felhasználó saját alkalmazásainak futtatására, felhőalapú alkalmazások létrehozására, szerver kapacitások bővítésére egyaránt. A platform több mint 100 szolgáltatást kínál, amelyek lehetővé teszik, hogy mindent elvégezhesen a meglévő alkalmazások virtuális gépeken való futtatásától az új szoftver paradigmák, például az intelligens robotok és a vegyes valóság felfedezéséig.

Az Azure továbbá olyan mesterséges intelligenciát alkalmazó és gépi tanulási szolgáltatásokat biztosít, amelyek természetes módon kommunikálnak a felhasználókkal vizuális, audio- és beszédfunkciókon keresztül. A nagy adatmennyiségek tárolása érdekében dinamikusan növekvő kapacitású tárolási megoldásokat is nyújt. Az Azure-szolgáltatásokkal olyan megoldások is létrehozhatók, amelyek a felhő teljesítménye nélkül nem lennének megvalósíthatók.

Ma már szinte minden iparágban használják az Azure alkalmazásait és szolgáltatásait.

(Cloud-szerver.hu, 2023, Infosector.hu, 2023)

10.2 Siemens - Technomatix Plant Simulation

A szoftver lehetővé teszi az anyagáramlás, az erőforrás-felhasználás és a logisztika elemzését a gyártástervezés minden szintjén, a globális termelési létesítményektől a helyi üzemekig és meghatározott gyártósorokig, jóval a gyártás végrehajtása előtt.

Öt pontban foglaltam össze a program jellemzőit, gyakorlati hasznát:

- a. Gyártást végző rendszerek elemzése 2D és 3D szimulációban:
 - A Tecnomatix Plant Simulation szoftver diszkrét eseményszimulációs és statisztikai elemzési képességeket biztosít az anyagmozgatás, a logisztika, a géphasználat és a munkaerőigény optimalizálása érdekében. A szimulációban kimutathatók az alacsony vagy túlzott raktárkészletek, az alul vagy túlterhelt szállítószalagok is. Az objektumorientált és 3D modellezési képességekkel rendelkező sztochasztikus eszközök használatával növelhető a gyártási pontosság és hatékonyság, miközben javul az átviteli sebesség és a rendszer általános teljesítménye. Hatékony grafikus

megjelenítési, diagram- és jelentéskészítő funkciók, genetikai algoritmusok és kísérleti eszközök lehetővé teszik a termelési rendszerek viselkedésének értékelését a gyors, megbízható gyártási döntések meghozatala érdekében, amely döntések vonatkozhatnak például a meglévő gyártósorok megbontására és új gyártósorok megépítése vagy gépek termelési folyamatba illesztésére is.

- b. A szűk keresztmetszetek kiküszöbölése és az áteresztőképesség egyszerűsítése
 - A Tecnomatix Plant Simulation modelleket az áteresztőképesség fejlesztésére, a szűk keresztmetszetek feltérképezésére és azok kezelésére és a munkafolyamatok minimalizálására is használják. A szűk keresztmetszetek automatikus észlelése, a termelés sebességének elemzése, a gépek, erőforrások és pufferek használata, a Sankey-diagramok és a Gantt-diagramok mind egyike azoknak a rendelkezésre álló eszközöknek, amelyekkel a termelési rendszerek teljesítményét fel lehet mérni. A szimulációs modellek figyelembe veszik a belső és külső ellátási láncokat, a termelési erőforrásokat, sőt üzleti folyamatokat is, lehetővé téve a különböző termelési változatok hatásának dinamikus elemzését.
- c. Az energiafelhasználás optimalizálása a jobb teljesítmény érdekében:
 - A Tecnomatix Plant Simulation egy integrált energiaelemzőt tartalmaz, amely mutatja az aktuális, a maximális és a teljes energiafogyasztást. A rendszerben ott lévő energiamutató dinamikusan jeleníti meg az energiafogyasztást a szimuláció során, így lehetővé teszi az energiafogyasztás nyomon követését a munkaidőben és a tervezett szünetekben egyaránt. Ezáltal könnyebben azonosíthatók olyan területek, ahol energiát lehet megtakarítani.
- d. Virtuális modell használatával biztonságosabban megvalósítható a tényleges termelés
 - A Tecnomatix Plant Simulation lehetővé teszi az üzem virtuális modelljének összekapcsolását a valódi üzemirányítással a tényleges termelés szimulációjához. Az integrált szimulációs megközelítéssel a vezérlés, az

automatizálás, az anyagszállítás és a teljes mérnöki művelet tesztelhető és optimalizálható. (Siemens PLM Software, 2023)

e. A szoftver használatával elérhető előnyök listája

- A már kiépített gyártósor rendszer termelékenységse a korábbi tapasztalatok alapján növelhető átlagosan akár 15-20%-kal
- Az új vagy tervezett gyártósorok tervezési összköltsége csökkenthető átlagosan akár 20%-kal
- A raktárkészlet és gyártási idő csökkenése várható átlagosan akár 20-60%-kal
- A rendszerméretek biztosan optimalizálhatóak, a pufferméretek szintén
- Különböző tervezési veszélyek a koncepcióalkotás szakaszában elháríthatók
- Maximalizálhatjuk az egyes gyártási erőforrások felhasználását
- Jelentősen gyorsítható a gyártósor tervezésének és elkészítésének folyamata

(Graphit.hu, 2023)

10.3 Power BI

A Power BI a Microsoft által kínált, széles körben népszerű üzleti intelligencia eszközök és technikák gyűjteménye, amelyek lehetővé teszik a felhasználó számára értékes információk kinyerését, és rejtett minták vagy kapcsolatok felfedezését a nyers üzleti adatokban. A modern iparágaknak a Power BI segít nyomon követni az üzleti teljesítményt, és meglátni azokat a területeket, ahol javításra van szükség. Úgynevezett dashboardok, másnéven vizualizációs vásznak formájában különféle adatvizualizációk gyűjteménye készíthető el, amelyek felhasználhatóak az adatkészletek kulcsfontosságú szempontjainak vagy értékeinek megjelenítésére. Az elkészített dashboardok pedig megoszthatók más felhasználókkal a Power BI alkalmazás webhelyén.

Számos ok miatt a vállalatok világszerte előnyben részesítik a Power BI-t más üzleti intelligencia eszközökkel szemben:

Könnyen csatlakoztatható adatforrásokhoz: A Power BI egyesíti az adatokat azáltal, hogy csatlakozik mind a helyszíni, mind a felhő adatforrásokhoz, például Excel-táblázatokhoz, CSV-fájlokhoz, OneDrive-hoz, Salesforce-hoz, Azure Data Warehouse-hoz, Google Analytics-hez,

Dropboxhoz, SQL-adatbázishoz. stb. A Power BI adathalmaz elérési képességének köszönhetően a felhasználó percekben belül elemezhet hatalmas adatkészleteket.

Egyéni vizualizációk: A Power BI különféle vizualizációs elemeket kínál, például vonalakat, térképeket, sávokat, oszlopokat, grafikonokat, tölcserdiagramokat, szóródiagramokat, táblázatokat és vízszinteseket. Ezek a látványelemek testreszabási lehetőségekkel rendelkeznek, amelyek lehetővé teszik a felhasználó számára, hogy szebb megjelenésű és funkcionális vizualizációs vásznat hozhasson létre.

Natív R-integráció: A Power BI támogatja az R-t, egy nyílt forráskódú programozási nyelvet, amelyet statisztikai modellezésre, gépi tanulásra, adatmanipulációra és vizualizációra használnak. A Power BI lehetővé teszi a felhasználó számára, hogy integrálja az R-t, így teremtve a felhasználó számára lehetőséget a jobb kapcsolatok, minták, hierarchiák és kulcsmátrixok megjelenítéséhez.

Cortana integráció: A Cortana a Microsoft digitális asszisztense, amelyet a Power BI integrál és lehetővé teszi a felhasználó számára, hogy természetes nyelven futtasson hangparancsokat egy dashboard készítése során. Úgy működik, hogy megmondjuk a kívánt vizualizációhoz szükséges oszlopok nevét.

Power BI-alkalmazások: Az alkalmazások betekintést nyújtanak a más felhasználók által megosztott dashboardokról és jelentésekről. A felhasználó beágyazhatja saját Power BI vizualizációit az alkalmazásokba, hogy élő frissítéseket kaphasson mobiltelefonján azok változásairól.

Felhasználói felület: A Power BI-t bárki használhatja, aki alapszintű Excel ismeretekkel rendelkezik. Power BI minta-dashboards és videók segítségével még egy nem műszaki felhasználó is értékes információkat tud előállítani. (IntelliPaat, 2023)

11 AZURE PREDIKTÍV KARBANTARTÁS FELADAT

A termelést olyan gyűjtőfogalomként értelmezhetjük, mely a termelés folyamatát alkotó különböző elemek sokaságát foglalja magába.

Ilyen elemek például a szükséges anyagok, alapanyagok beérkezési idejének hossza, pontossága, a munkaerő és gépek mennyisége, munkavégzésük minősége (gyorsaság, precizitás, darabszám) a gyártási terület kihasználtsága, a raktárak mérete és az ott lévő alapanyagok megléte, a késztermékek gyárból a boltok polcaira jutásának ideje.

Az előállított termékek mennyisége akkor maximális, amikor az összes termelési összetevő, a piacon elérhető legjobb minőségben áll rendelkezésre és annak megfelelően is működik.

Az optimális termelés fogalma ettől eltér. Az egyes termelést alkotó elemeknek azt a hatékony működést eredményező kombinációját jelenti, ami az adott késztermék piaci kereslet-kínálata, valamint a cég gyártási kapacitása szabta feltételeknek megfelelő legyártott termékek mennyiségét és minőségét jelöli, a legkisebb előállítási költség mellett.

A termelést alkotó elemek egyfajta termelési láncként kapcsolódnak össze.

Idővel a lánc egyik szeme megszűnik, elromlik, ezért a termelés leáll.

A termelés megszűnésével, nem várt lassulással, a vállalat jelentős bevételkiesést könyvel el.

Az említett okból fakadó bevételkiesést azonban a láncszemek működésének rendszeres ellenőrzésével, karbantartásával el lehet kerülni.

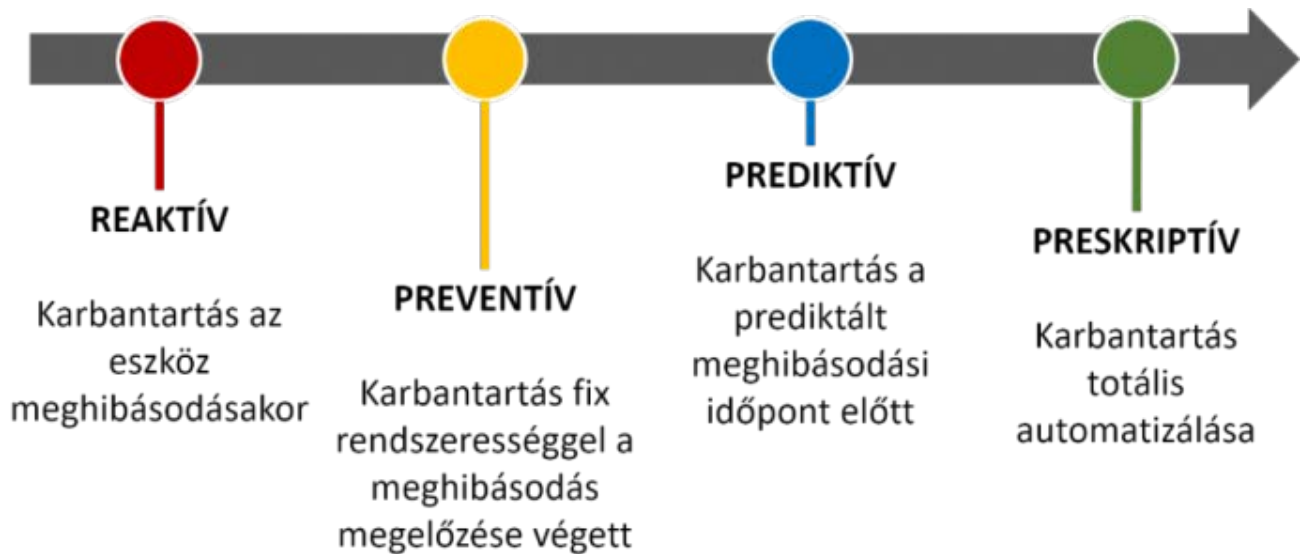
A karbantartási feladatok négy típusát különböztetjük meg, úgy mint reaktív, preventív, prediktív, perspektív.

A **reaktív karbantartást** “megjavításként” értelmezzük. Ebben az esetben a gép addig működik bármilyen karbantartás, felügyelet nélkül, amíg végül meghibásodik. Ezután jönnek a szerelők és megszerelik. A termelésmenedzsment területén a reaktív karbantartás gyakori. Nincs szükség a gépek folyamatos felügyeletére, gépekről gyűjtött adatokra, karbantartást végző munkásra. A stratégia hátránya, hogy nem várt gépleállásokat okoz, bizonytalan időre megszakítva ezzel a termelési folyamatot. A termelés kiesésből jelentős veszteség adódik, amihez hozzáadódik a javítás költsége egyaránt.

A modern értelemben vett karbantartási technikák alkalmazása időigényesebb, mivel a gépek zavartalan működéséről a várható meghibásodás előtt is gondoskodunk, de az esetek többségében összességében költséghatékonyabb megoldás.

Ami a karbantartás költségeit illeti: olyan eszközöket, amik általában havi egyszer igénylik a karbantartást, nem érdemes minden nap átvizsgálni és szerelni. A beavatkozást úgy kell időzíteni, hogy az ne legyen se túl korán se túl későn. Az optimális időpontok megtalálása, becslése a célja a korszerű karbantartási módszereknek.

4. ábra - Karbantartási módszerek típusai



Forrás: CNC, 2019

A **preventív** karbantartási módszer esetében a gyártók javasolnak karbantartási időpontokat. A karbantartás meghatározott időközönként valósul meg, így elkerülhetők a gyártás leállítását eredményező meghibásodások. Tervezőmérnökök határozzák meg az időintervallumokat a gép élettartamát figyelembe véve. A módszer hátrányai a folyamatos tervezés, nyilvántartás és ütemezés. A rutinszerű ellenőrzéseket pedig mindig be kell tartani, függetlenül attól, hogy a gép optimális állapotban üzemel vagy sem. Azonban annak ellenére, hogy a tervezést megkönnyíti, a preventív karbantartás nem a megfelelő megoldás akkor, ha a termelékenység növekedésének rovására válnak túl gyakorivá az ütemezett karbantartási idők.

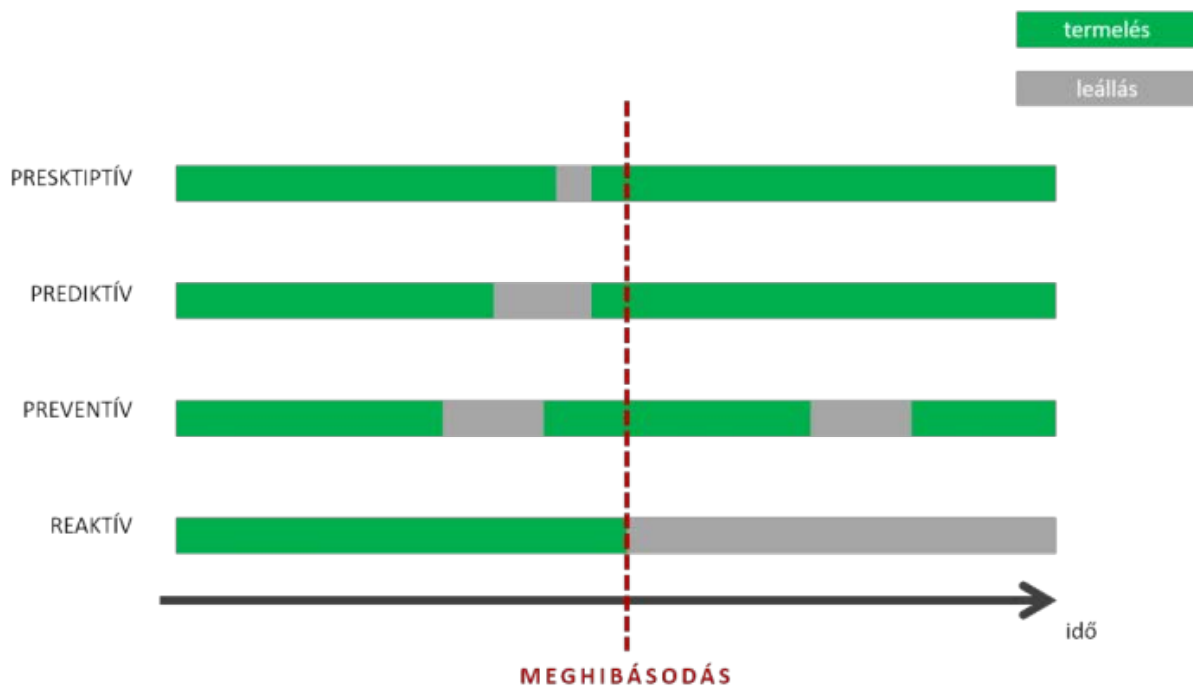
A **prediktív** karbantartás az a technika, amit már a karbantartás minőségi eljárásaként tartanak számon.

Az Ipar 4.0 különféle technológiáit, szenzorok és egyéb állapotfigyelő eszközök használatát igényli melyek segítségével a gépek és berendezések üzemi állapota a nap minden percében megfigyelhető. IoT-eszközök gyűjtenek valós idejű adatokat és az adatok feldolgozása biztosítja a naprakész információkat a berendezések mindenkori karbantartási igényeiről.

Az összegyűjtött, nagy mennyiségű adatokat automatizál módon elemezve a karbantartás-ütemező programok javaslatot tesznek a gépek leállítására és javítására vonatkozóan. Egy ilyen rendszer kiépítése rövidebb leállásokkal és termelékenységnövekedéssel kecsegtet, mivel csupán a legszükségesebb esetekben ütemezi a beavatkozást. A precíz tervezés illetve ütemezés effektívebb erőforrás-felhasználást biztosít, ez pedig redukálja a költségeinket.

A prediktív karbantartás módszer esetében hátráltató tényezők, hogy a karbantartási modell kiépítéséhez szükségesek monitorozást végző kellekek telepítése és az ezekhez köthető digitális infrastruktúra kialakítása. Továbbá nincsenek egyforma karbantartás-ütemező modellek sem. Az adott rendszernek meg kell tanulnia a gyártósor sajátosságait, sőt finomhangolások is szükségesek. Csak így módon érhető el a kívánt eredmény.

5. ábra - A termelés és leállás gyakorisága és hossza az idő függvényében karbantartási mód-szerenként



Forrás: CNC, 2019

A **preskriptív** karbantartás hasonlít a prediktív karbantartáshoz, azonban ebben az esetben a teljes folyamat automatizált. A berendezések állapotának felügyeletének megléte mellett, egy másik célkitűzés a gépi tanulás és AI-technikák használata, azért, hogy a gép saját maga gyűjtse az adatokat és hozza meg a döntéseket a karbantartásra vonatkozóan. A gépek saját maguk döntenek önállóan a karbantartás idejéről és módjáról, sőt bizonyos esetekben megvan a képességük annak automatikus elvégzésére. A hosszabb élettartam eléréséhez a termelés mennyiségét is szabályozhatják. (Bergman, Gyulai, 2019)

A rendelkezésemre álló adathalmazt felhasználva egy prediktív karbantartáshoz köthető feladatot oldok meg.

Az adathalmaz olyan adatok halmaza, amely szenzitív adatokat tartalmaz egy adott gyártósor paramétereire, gyártósori beállítás paraméterek kombinációira vonatkozóan. Az oszlopfejlécek

jelentése nem ismert, a feladatmegoldáshoz nem szükséges ismerni őket, így ezekről több információt nem közlök.

Egy kivétellel - ez pedig a label adatmező. Több mint negyven gyártósori beállítás paraméter kombinációtól függően valamilyen üzemi hőmérséklet keletkezik és a label 2 mutatja az üzemi hőmérsékletnek az intervallumát. Ez az intervallum lehet 0, 1, 2 – színekkel jelölve, esetünkben zöld, sárga, piros. A zöld a megfelelő, a sárga a kritikus, a piros pedig a már túl magas hőmérsékleti tartományt mutatja.

A gyártósori mintáink megmutatják, hogy mikor akad ki a gép üzemi hőmérséklet hiba miatt.

Azért, hogy ez ne történhessen meg, megpróbáljuk előrejelezni, hogy ilyen meg ilyen beállítással, ilyen paraméterezéssel várhatóan hogyan fog alakulni a gép üzemi hőmérséklete.

Célom, hogy olyan beállítási lehetőséget találjak, amely biztosítja az üzemi hőmérséklet normalitását. Ha ez biztosított, akkor a gyártási folyamat a gépek túlhevülése miatt nem állhat le.

A gépi tanulási feladatok leggyakoribb változata az osztályozás (classification), ahol adott egy osztályhalmaz és felügyelt gépi tanulásos megközelítésben a rendszer a tanító adatbázist felhasználva olyan döntési szabályokat tanul meg, melyek segítségével képes ismeretlen példákat a megfelelő osztályba (class/label) sorolni.

Microsoft Azure programot használva, olyan ML modellt építünk, felügyelt gépi tanulásos megközelítéssel, amelyben a háromféle hőmérsékleti tartomány miatt a multiclass, azaz a többszörös osztályos algoritmusokkal vizsgálódunk.

Ez négyféle különböző algoritmust jelent:

- Multiclass Logistic Regression
- Multiclass Neural Network
- Multiclass Decision Forest
- Multiclass Decision Jungle

Működésük ismerete, mechanizmusaik jellemzése egyrészt külön szakdolgozat téma is lehetne, másrészt a feladatmegoldáshoz a megértésük szükségtelen.

Így a különböző algoritmusok értelmezésétől eltekintek.

Mindegyik algoritmushoz tartoznak hiperparaméterek, melyek változtatásával jobb-rosszabb hatékonyságot eredményező modellt kapok eredményül.

A modell hatékonyságát, teljesítményét, pontosságát jóságmutatók és az azokból számított konfúziós mátrix alapján értékeljük.

Azt, hogy milyen kiértékelési metrikákat alkalmazunk, melyek ezek és mit jelentenek, a feladatmegoldás során adok rá választ.

Mivel az Azure ML Studio-ban létrehozott gépi tanulási modellem felépítése megfelel a CRISP-DM eljárásnak, ezért a gépi tanulási modellem építésekor ezt a módszert követem.

Az eljárás hat egymást követő szakaszt tartalmaz, és ahhoz, hogy gépi tanulási modellt építsünk, ezeket teljesíteni kell:

1. Üzleti célok meghatározása (Business Understanding): első lépésben meg kell határozni, hogy a projekt során milyen célokat szeretnénk teljesíteni, a céljainkhoz kapcsolódóan fel kell állítani limiteket, melyek megmutatják többek között az erőforrásaink korlátját.

2. Adatok megértése (Data Understanding): második lépésben a szükséges adatokat össze kell gyűjteni. Ezen kívül fel kell venni a kapcsolatot az adatgazdákkal és üzleti szereplőkkel, mert ők azok, akik tudják, hogy az adatforrásokban lévő adatok mit jelentenek, milyen úton-módon jönnek létre és hogy milyen összefüggések vannak közöttük.

3. Adatok előkészítése (Data Preparation): ebben a fázisban öt feladatot kell elvégezni. Adatok kiválasztása, adattisztítás, adatgazdagítás, célváltozó keresés és végül adat integrálás.

4. Modellezés (Modeling): az elemezni kívánt adatok létrejöttével megépíthető a modell. A folyamatot több algoritmussal is érdemes megismételni és aztán figyelni a kapott eredményeket, mert a különböző algoritmusok különböző eredményeket adnak.

5. Üzleti kiértékelés (Evaluation): ez a rész az első fázisban megállapított üzleti cél, célok teljesülését hivatott vizsgálni. Ha mégsem teljesíti a modell teljes mértékben a céljainkat, amiket megfogalmaztunk, de üzletileg elfogadható az eredmény, akkor nem kell a CRISP-DM módszertan egyik fázisát sem újra elvégezni.

6. Alkalmazás (Deployment): a végső lépésben az elkészített megoldást az üzleti folyamatainkba integráljuk és a modell karbantartását, teljesítményének megfigyelését megtervezzük.

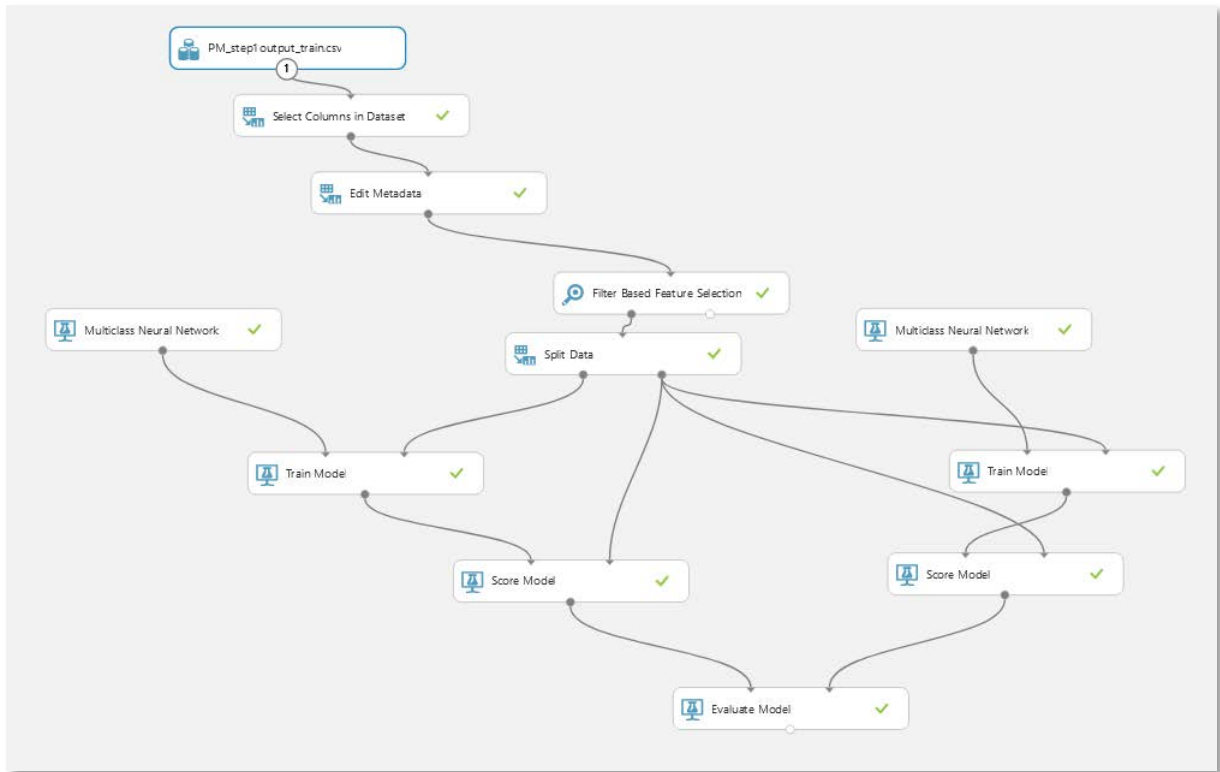
(Lanng, Majed, 2018), (Nagy-Rácz, 2019)

Az alábbi képen az Azure ML Studio-ban elkészített gépi tanulási modell látható:

Azután, hogy meghatároztam a feladatot és a célt, amit el szeretnék érni, és miután a rendelkezésemre álló adathalmazt is megvizsgáltam, folytatom a modellépítés folyamatát.

Score Columns in Dataset

6. ábra - Azure ML modell



Forrás: Saját szerkesztés, Azure ML Studio szoftverrel

Az adatelőkészítés fázisban meg kell győződnünk arról, hogy a kiinduló adataink minőségileg kellőképpen megfelelőek a további adatfeldolgozó munkafolyamatok elkezdéséhez. Mivel az adathalmazt jó minőségben, a hiányzó soroktól megtisztítva kaptam meg, ezért azt vizsgáltam meg, hogy a bemeneti adatbázisban szereplő oszlopok közül vajon tényleg mindegyik szükséges-e.

A nem releváns mezőket, amelyek torzíthatnák a kapott eredményeimet illetve más módon akadályoznák a feladat elvégzését, eltávolítottam – RUL és Label1 oszlopok.

Edit Metadata

A metaadat jelentése: adat az adatról. Az Azure lehetőséget biztosít arra, hogy a gyártósor beállítási paramétereit tartalmazó adatbázisban az oszlopok neveit módosítsuk, az azokban szereplő adatmezők típusait beállítsuk és azt is pontosíthatjuk, hogy kategorikus vagy numerikus értékeként kezelje-e azokat a rendszer.

A Label2 oszlopot átneveztem Label-re.

Filter Based Feature Selection

A modell felépítésének ez a része két szempontból fontos és elengedhetetlen. Egyrészt itt, a szűrő alapú jellemző kiválasztás részben állíthatjuk be a célváltozót, amely azt a változót jelöli, amit a modell futtatása során meg szeretnénk határozni. Esetünkben a Label nevű oszlop lesz a célváltozó. Másrészt ebben a fázisban lehetőség van arra, hogy leválogassuk azokat az attribútumokat, melyek a végeredményt a legerősebb prediktori értékkel határozzák meg.

51 oszlopunk van, ezeket nevezhetjük változónak, dimenziónak vagy attribútumnak is. Ebből egy a target mező, tehát a maradék 50 dimenzió kombinációja határozza meg a végeredményt. Ebből a top 25-öt kiválasztva pontosabb előrejelzést készíthetünk, mintha mind az 50 jellemző alapján futtatnánk később a modellt.

Split Data

Az Azure ML Studio-nak ez a modulja teszi lehetővé az adathalmaz felosztását tanító-és teszt-halmazra. Az adathalmaz tanító-és teszt-halmazra való felosztása azért történik, hogy a modell hatékonyságát, az előrejelzések pontosságát mérni lehessen. Számos opciót kínál fel a rendszer amelyek különbözőképpen osztják fel az adathalmazt. Ezek a lehetőségek a véletlenszerű felosztás, stratifikált felosztás, csoportosított felosztás.

A tanító-és teszt-halmazra való bontást 80-20% arányban a véletlenszerű adatfelosztás módszert választva hajtottam végre.

Train Model

A modell tanítását mind a négy algoritmussal elvégeztem. A folyamat során mindig az a cél, hogy a modell a lehető legpontosabban képes legyen megjósolni a várt eredményeket, ez pedig úgy történik, hogy a modell a művelet végrehajtásakor iteratíván finomítja a súlyokat és paramétereket.

Score Model

A Score Model funkció szolgálja a betanított modell futtatását a teszt adathalmazon, új adatként szimulálva azt. A modell jószágát, pontosságát mutató adatok itt jelennek meg először és ezekből számíthatódnak később az eredmények.

Evaluate Model

Ez a modul a létrehozott gépi tanulási modellek teljesítményének értékelésére szolgál. A modul tartalmazza azokat a jelentős teljesítmény-értékelő mutatószámokat és a konfúziós mátrixot, amelyek segítenek megérteni az osztályozó algoritmus teljesítményét.

A konfúziós mátrix, másik nevén tévesztési vagy keveredési mátrix egy olyan táblázat, amelyet arra használnak az adatbányászatban és a statisztikában, hogy ábrázolni lehessen az osztályozó algoritmusok teljesítményét. Három osztály esetén a konfúziós mátrix egy 3x3-as táblázat, amelyben a sorok a valós osztályokat, az oszlopok pedig az előrejelzett osztályokat jelölik.

Az abban található értékek alapján pillanatok alatt leolvasható és eldönthető, hogy megfelelően teljesített-e az adott modell vagy sem.

Attól függően, hogy melyik osztályra vonatkozó jóságmutatókat szeretnénk kiszámolni, annak megfelelően változnak a TP (True Positive), FP (False Positive), TN (True Negative) és FN (False Negative) cellák helyei. (Bharathi, 2021)

Három eset lehetséges:

7. ábra - Konfúziós mátrix esettípusok

0 =		0	1	2
	0	TP	FN	FN
	1	FP	TN	TN
	2	FP	TN	TN
1 =		0	1	2
	0	TN	FP	TN
	1	FN	TP	FN
	2	TN	FP	TN
2 =		0	1	2
	0	TN	TN	FP
	1	TN	TN	FP
	2	FN	FN	TP

Forrás: saját szerkesztés

A pontosság értéke két különböző metrika alapján számítható, ezek a (precision és accuracy). A precision érték megmutatja, hogy mennyi a helyes döntések aránya az összes pozitív előrejelzést vizsgálva. Az accuracy azt jelzi, hogy az osztályozó algoritmus helyesen osztályozta-e az összes mintát, függetlenül attól, hogy azok pozitívak vagy negatívak.

Az érzékenység (recall) mutató a ténylegesen pozitív minták helyesen prediktált arányát mutatja.

Az Azure ML Studio rendszerben ezek a mutatószámok érhetőek el, azonban léteznek egyéb gépi tanulási modell teljesítményét mérő jelzőszámok is.

A specificitás (specificity) a recall mutatóhoz hasonló. A ténylegesen negatív minták helyesen prediktált arányát vizsgálhatjuk meg a segítségével.

Az F-measure (F1-Score) a precision és a recall értékek harmonikus átlaga.

A Matthew's correlation coefficient (MCC) formula egy hasznos egyértékű osztályozási mutató. Értéke mindig -1 és +1 közötti szám lesz, ahol az +1-hez közeli eredmény azt jelenti, hogy az egyezés aránya nagyon jó az előrejelzett és a tényleges értékek között.

A Fowlkes-Mallows index (FM) a precision és recall értékpár geometrikai átlagaként számítható. Értéke 0 és 1 közé esik, ahol az 1-hez közeli érték mutatja a hatékony klasszifikációt.

A Bookmaker Informedness (BM) a recall és specificity mutatók összegéből 1-et kivonva adható meg.

A Markedness (MK) értékét úgy kapjuk, hogy a precision és a negative predictive value-t összegezzük és azösszezből 1-et kivonunk.

(Wikipédia, 2023)

A modell futtatását mind a négy multiclass típusú algoritmussal elvégeztem. Összesen 60 kísérletet hajtottam végre, mindezt úgy, hogy az egyes metodikákhoz tartozó hiperparamétereket minden esetben megváltoztattam.


Az alábbi táblázatokban algoritmusonként az összes eredmény közül kizárólag a legerősebb teljesítményt elérteket tüntetem fel:

8. ábra - A Multiclass Neural Network algoritmusához tartozó hiperparaméterek és eredmények

Multiclass Neural Network			
Create trainer mode	Single Parameter	Overall accuracy	0.934319
Hidden layer specification	Fully-connected base	Average accuracy	0.956213
Number of hidden nodes	200	Micro-averaged precision	0.934319
The learning rate	0,3	Macro-averaged precision	0.809686
Number of learning iterations	200	Micro-averaged recall	0.934319
The initial learning weights diameter	0,3	Macro-averaged recall	0.851475
The momentum	0		

Forrás: saját szerkesztés

9. ábra - A Neural Network algoritmusához tartozó konfúziós mátrix




Forrás: Azure ML Studio, 2023

10. ábra - A Logistic Regression algoritmusához tartozó hiperparaméterek és eredmények

Multiclass Logistic Regression			
Create trainer mode	Single Parameter	Overall accuracy	0.943044
Optimization tolerance	0,00001	Average accuracy	0.962029
L1 regularization weight	0	Micro-averaged precision	0.943044
L2 regularization weight	0,01	Macro-averaged precision	0.822221
Memory size for L-BFGS	20	Micro-averaged recall	0.943044
		Macro-averaged recall	0.799796

Forrás: saját szerkesztés

11. ábra - A Logistic Regression algoritmusához tartozó konfúziós mátrix




Forrás: Azure ML Studio, 2023

12. ábra - A Decision Forest algoritmusához tartozó hiperparaméterek és eredmények

Multiclass Decision Forest			
Resampling method	Bagging	Overall accuracy	0.944741
Create trainer mode	Single Parameter	Average accuracy	0.96316
Number of decision trees	16	Micro-averaged precision	0.944741
Maximum depth of the decision trees	16	Macro-averaged precision	0.837694
Number of random splits per node	64	Micro-averaged recall	0.944741
Minimum number of samples per leaf node	8	Macro-averaged recall	0.799765

Forrás: saját szerkesztés

13. ábra - A Decision Forest algoritmushoz tartozó konfúziós mátrix



Forrás: Azure ML Studio, 2023

14. ábra - A Decision Jungle algoritmushoz tartozó hiperparaméterek és eredmények

Multiclass Decision Jungle			
Resampling method	Bagging	Overall accuracy	0.946922
Create trainer mode	Single Parameter	Average accuracy	0.964615
Number of decision DAGs	99	Micro-averaged precision	0.946922
Maximum depth of the decision DAGs	19	Macro-averaged precision	0.844906
Maximum width of the decision DAGs	88	Micro-averaged recall	0.946922
Number of optimization steps per decision DAG layer	9999	Macro-averaged recall	0.802944

Forrás: saját szerkesztés

15. ábra - A Decision Jungle algoritmushoz tartozó konfúziós mátrix

Confusion Matrix

		Predicted Class		
		0	1	2
Actual Class	0	98.7%	1.3%	0.0%
	1	34.9%	56.3%	8.8%
	2	0.3%	13.8%	85.9%

Forrás: Azure ML Studio, 2023

A táblázatokban szereplő algoritmusok eredményei közül a Multiclass Logistic Regression, Decision Forest és Decision Jungle hasonlóak, csupán 1-2% a különbség.

A Multiclass Neural Network algoritmussal elért eredmény azonban kitűnik a többi közül! Több mint 20%-kal jobb találati arányt értem el ezzel az algoritmussal és hiperparaméterezéssel a középső labelt tekintve.

16. ábra - A Neural Network algoritmushoz tartozó konfúziós mátrix

		Predicted Class		
		0	1	2
Actual Class	0	95.8%	4.2%	
	1	15.3%	76.3%	8.5%
	2		16.6%	83.4%

Forrás: Azure ML Studio, 2023

17. ábra - A Neural Network algoritmusához tartozó konfúziós mátrix számokkal

Actual Class	Predicted Class		
	0	1	2
0	3364	147	0
1	45	225	26
2	0	53	266

Forrás: saját szerkesztés

A kapcsolódó mutatószámok:

$$\text{Precision for class 0} = 3364 / (3364 + 45 + 0) = 0.9868$$

$$\text{Precision for class 1} = 225 / (147 + 225 + 53) = 0.5294$$

$$\text{Precision for class 2} = 266 / (0 + 26 + 266) = 0.9110$$

$$\text{Recall (Sensitivity) for class 0} = 3364 / (3364 + 147 + 0) = 0.9581$$

$$\text{Recall (Sensitivity) for class 1} = 225 / (45 + 225 + 26) = 0.7601$$

$$\text{Recall (Sensitivity) for class 2} = 266 / (0 + 53 + 266) = 0.8339$$

$$\text{Specificity for class 0} = (225 + 266) / (45 + 225 + 266) = 0.9160$$

$$\text{Specificity for class 1} = (3364 + 266) / (147 + 53 + 3364 + 266) = 0.9478$$

$$\text{Specificity for class 2} = (3364 + 225) / (26 + 3364 + 225) = 0.9928$$

$$\text{F measure for class 0} = 2 * (0.9868 * 0.9581) / (0.9868 + 0.9581) = 0.9722$$

$$\text{F measure for class 1} = 2 * (0.5294 * 0.7601) / (0.5294 + 0.7601) = 0.6241$$

$$\text{F measure for class 2} = 2 * (0.9110 * 0.8339) / (0.9110 + 0.8339) = 0.8707$$

$$\text{Matthew's correlation coefficient for class 0} = (3364 * (225 + 266) - 45 * 147) / ((3364 + 45) * (3364 + 147) * (225 + 266 + 45) * (225 + 266 + 147))^{1/2} = 0.8132$$

$$\text{Matthew's correlation coefficient for class 1} = (225 * (3364 + 266) - (53 + 147) * (45 + 26)) / ((225 + 53 + 147) * (225 + 45 + 26) * (3364 + 266 + 53 + 147) * (3364 + 266 + 45 + 26))^{1/2} = 0.6010$$

$$\text{Matthew's correlation coefficient for class 2} = (266 * (225 + 3364) - 26 * 53) / ((266 + 26) * (266 + 53) * (225 + 3364 + 26) * (225 + 3364 + 53))^{1/2} = 0.8608$$

Fowlkes-Mallows index for class 0 = $(0.9868 * 0.9581)^{1/2} = 0.9724$

Fowlkes-Mallows index for class 1 = $(0.5294 * 0.7601)^{1/2} = 0.6344$

Fowlkes-Mallows index for class 2 = $(0.9110 * 0.8339)^{1/2} = 0.8716$

Bookmaker Informedness for class 0 = $0.9581 + 0.9160 - 1 = 0.8742$

Bookmaker Informedness for class 1 = $0.7601 + 0.9478 - 1 = 0.7079$

Bookmaker Informedness for class 2 = $0.8339 + 0.9928 - 1 = 0.8267$

Markedness for class 0 = $0.9868 + 0.7696 - 1 = 0.7564$

Markedness for class 1 = $0.5294 + 0.9808 - 1 = 0.5102$

Markedness for class 2 = $0.9110 + 0.9854 - 1 = 0.8964$

Összegzés

A feladatmegoldás során random seed mag beállítással futtattam a gépi tanulási modelleket. Seed mag beállításával tudjuk a modell determinisztikusságát biztosítani, ami azt eredményezi, hogy ugyanazzal az input adatokkal ugyanaz az output eredmény keletkezzen többszöri modell futtatás alkalmával is. Ezért fordulhat elő az, hogy ugyanolyan hiperparaméterekkel és metodikával a modell futtatása végeztével az eredetitől maximum néhány százalékkal eltérő eredményt láthatunk.

A négy vizsgált metódus közül a multiclass neural network típusú biztosítja azt, hogy a termelés folyamata a gépek túlhevülése miatt ne szakadjon meg.

A létrehozott gépi tanulási modell átadható a megrendelőnek aki a prediktívkarbantartás során a munkagépeket ennek megfelelően állítja majd be.

A döntéshozatalt az AI és a gépi tanulási modellek alkalmazása megkönnyítették, sőt lehetővé tették.

Mindezek alapján a H_0 hipotézist elfogadjuk.

12 PLANT SIMULATION ÉS POWER BI CIKLUSIDŐ OPTIMALIZÁLÁS FELADAT

A digitális ikerpár egy olyan koncepció, mely a valós világban létező tárgyak, eszközök vagy rendszerek digitális mására utal. Ez a digitális másolat azonos a valós világbeli társával minden lényeges szempontból, beleértve a fizikai jellemzőket, a teljesítményt és a viselkedést is.

Az ikerpár az adatok és az analitika központi helyre állításával lehetővé teszi az eszközök és rendszerek állandó ellenőrzését, valamint a hatékonyabb tervezést és üzemeltetést. A szimulált változat segítségével a tervezők és mérnökök tesztek nélkül is különféle változatokat és terveket hozhatnak létre, amelyeket azután éles helyzetben tesztelhetnek és finomíthatnak.

Az ikerpár létrehozása egyre inkább szükségessé válik az iparban, az egészségügyben, az oktatásban és más területeken is, az új technológiák fejlődésével pedig több lehetőség is kínálkozik a digitális ikerpárok létrehozására.

A Technomatix Plant Simulation programmal egy gyár digitális mását tudjuk elkészíteni és a termelési folyamatot modellezni.

A szoftver sokrétű felhasználási lehetőségeit tekinthetjük át a következő ábrán:

A programban a valóságot hűen tükröző és méretarányos gyártósorok szükségesek ahhoz, hogy a Technomatix Plant Simulation adta lehetőségeket maximálisan kihasználjuk.

Kidolgozhatunk optimalizált vezérlési stratégiákat, melyek lényege a gyártási folyamatok hatékonyságának javítása és a gyártási költségek csökkentése.

A termelésszimulációs során mindig érdemes követni a Lean és Kanban módszertanok alapelveit, azaz a felesleges tevékenységeket meg kell szüntetni, a keletkező hulladék mennyiségét minimalizálni kell. Törekedni kell a folyamatos fejlesztésre, az állandó javulás a meghatározó cél.

Használhatjuk ezt a technológiai eszközt arra is, hogy az egyes munkafázisok számát csökkentjük, egyúttal az átfutási időt is felülvizsgálhatjuk.

Elemzést készíthetünk az erőforrásainkra vonatkozóan és előrejelzést a megrendelői igények teljesítési határidejére.

A digitális ikerpárban történő tervezés elősegíti az új beruházási tervek megtérülésének vizsgálatát is.

képen szereplő változatának. 7 Munkaállomás, 2 raktár és 1 tároló egység, ahova a selejtes termékek kerülnek, alkotják a gyártósort.

Minden egyes munkaállomáson más és más munkafolyamatok zajlanak. Az egyes fázisokon kerülnek rá a házikóra az azt felépítő elemek.

A ház alapját alkotó elemek között található egy úgynevezett RFID tag, avagy Kanban azonosító, amit a munkaállomások között elhelyezett RFID olvasó scanner érzékel és ekkor egy BOSCH-os SAP rendszerben automatikusan rögzül az, hogy a termék milyen állapotában, melyik állomáson volt jelen éppen.

Az RFID jelenlétérzékelés segítségével, a termék útvonalát nyomon lehet követni és az így keletkezett adatok később felhasználhatóvá válnak a feladatmegoldás során, azaz a termelési folyamat hatékonyságának növeléséhez.

Három termelési kört futtatok le. Egy kör mintegy 5 percet vesz igénybe és ez idő alatt 18-22 db házikó késztermék készül el.

A termelési körök futtatása során a BOSCH-os SAP rendszerbe elkönyvelt adatokat használom fel.

Az adatok alapján Plant Simulation, Power BI rendszerekben a termelési sor munkaállomásainak leterheltségét, hatékonyságát vizsgálom meg.

Azonban ahhoz, hogy az adatokkal érdemi munkát végezhessenek, át kell alakítani, elő kell készíteni az adathalmazt úgy, hogy az, Power BI rendszerben dashboard építésre alkalmas és Plant Simulation programba implementálható legyen.

Az adatelőkészítés adatazonosítási, adattisztítási, adatintegrációs és adattranszformációs technikákat foglal magában, amelyek célja az adatok megtisztítása, normalizálása és felkészítése az elemzésre vagy modellalkotásra. Az adatelőkészítési folyamat során az adatokat előzetes feldolgozásnak vetjük alá, amely során különböző adatmanipulációs eszközök használatával, ami lehet az Excel, vagy akár programozási nyelvek is, például Python, R vagy SQL programozási nyelvek.

Az adatelőkészítés egyik legfontosabb lépése az adatok forrásainak azonosítása és azok összegyűjtése. Az adatok gyűjtési forrásai lehetnek különböző adatbázisok, log fájlok, szociális mé-

dia, weboldalak és egyéb adatgyűjtő platformok. Az adatforrásokból származó adatok minősége nagymértékben befolyásolja az adatelőkészítés sikerességét, ezért fontos, hogy a rendelkezésre álló adatforrásom megbízható és pontos értékeket tartalmaz.

Az adattisztítás során az adatokat meg kell tisztítani a redundáns, hiányzó vagy helytelen adatoktól. Az adatok tisztítása a mérési hibák vagy az adatbeviteli hibák javítását is magában foglalja, hogy az adatkészlet minősége magas legyen. Az adattisztítási módszerek közé tartoznak az adatpontok eltávolítása, a hiányzó adatok pótlása és az adatok normalizálása. Az adattisztítás és adatpótlás során használt eszközök között megtalálhatóak a Pandas, NumPy, vagy az Excel programok.

Az adattisztítás során az adathalmazban projekciókat hajtottam végre.

A szükségtelen oszlopokat, például ContrCycle, EPC, ID2 Kanban nevű oszlopok, eltávolítottam.

Az adatintegráció a különböző forrásokból származó adatok összevonása és egységesítése. Az adatintegráció során az adatokat a címkeadás, az egyedi azonosítók és az adatkódolás segítségével egyesítik. Az adatintegráció során az adatokat össze kell hangolni, hogy az azonos adatelemek egymással megfeleljenek, ami biztosítja az adatok megbízhatóságát és a konzisztenciát. Az adatintegráció során alkalmazott technikák között szerepel a record linkage, amely segítségével az azonosítók alapján azonosítják a rekordokat.

Mivel ugyanabból a forrásból származnak az adataink, így a feladatra vonatkozóan adatintegrációt nem hajtottam végre.

Az adattranszformáció során az adatokat a célzott felhasználásra készítik elő. Az adattranszformáció során az adatokat átalakítják, hogy azok kompatibilisek legyenek az adatelemzéshez vagy az adatkitermeléshez szükséges formátumokkal. Az adattranszformáció során a szöveges adatokat például numerikus formátumra alakítják át, ahol szükség van rá, és az adatokat egységes formátumba rendezik.

(Craig, 2023)

(Varga, 2022)

(Senturus youtuber, 2022)

A teljes gyártósorra vonatkozó grafikonok:

20. ábra - Termelés teljes időtartama

időtartam_full



Forrás: Saját szerkesztés Power BI-ban

Az első termelési ciklus kezdetétől az utolsó ciklus végével bezárólag 3513 másodperc telt el. Ebben az időmennyiségben szerepel az egyes termelési körök befejezése és az új fázis közt eltelt szünet időtartama is.

21. ábra –A termékek az egyes munkaállomásokon eltöltött ideje és a leolvasás státusza

időtartam_full, kategória: Status és RFID_ID

Status ● E ● I ● S



Forrás: Saját szerkesztés Power BI-ban

Ez az ábra kifejezi azt, hogy a termékek mennyi időt töltek összesen az egyes munkaállomásokon. Azt is megmutatja még az ábra, hogy a munkaállomásokra telepített RFID érzékelő szenzorok a teljes gyártás ideje alatt a készülő termék munkaállomásokon történő áthaladása után nagyságrendileg az adott leolvasási ponton mekkora mennyiségben, milyen status keletkezett az RFID tagek leolvasása során. Említést érdemel a PP01 és PP02 végű munkaállomások, ezek az előszereldek. Amikor nyersanyagellátási probléma adódott, az ezeken a helyeken jelentkezett először.

Három féle statust különböztetünk meg, melyek az RFID azonosítók érzékelései után könyvelődnek el az SAP rendszerben a többi adattal egyetemben. Az I és S jelzések jelölik azt, hogy az anyagáramlás, vagyis a készülő termék két adott munkaállomás között rendben zajlott. E-vel jelöltük a hibát.

A termelési ciklusok futása során keletkezett hibaüzenetek típusa három féle lehet:

„User CT_6580 is blocking production version HK of mat. HK00.000.001”

Ennek az üzenetnek a jelentése: ugyanazt a SAP tranzakciót hívjuk meg kétszer, és a második hívás az előtt történik meg, mielőtt még az első művelet befejeződött volna, ezért az első tranzakció blokkolja a másodikat és hibára fut.

Az alábbi példa mutatja, hogy a második visszajelentési ponton az RFID-s lejelentés 12:08:17-kor történt meg, és valószínűleg még folyamatban van (a lejelentés időtartama SAP-ban direktben is több másodpercig fut), mikor egy másik kanban kártya első ponton való visszajelentése 12:08:18-kor elindult, és ez hibára fut, mivel ugyanaz a cikkszám az előző lejelentés futása alatt zárva van. A második példa is ugyanezt mutatja:

22. ábra - Első típusú hibaüzenetre példa

I	DG_6580_TRA_AT_002	30.06.2021 12:08:17	HK00.000.001	9997974401	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974401.1	2383048	KVBHKFKKVI
S	DG_6580_TRA_PP_002	30.06.2021 12:08:17	HK00.000.001	9997974375	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974375.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_005	30.06.2021 12:08:18	HK00.000.001	9997974394	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974394.1	2383048	KVBHKFKKVI
E	DG_6580_TRA_PP_001	30.06.2021 12:08:18	HK00.000.001	9997974391	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974391.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_001	30.06.2021 12:08:23	HK00.000.001	9997974397	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974397.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_005	30.06.2021 12:08:24	HK00.000.001	9997974400	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974400.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_001	30.06.2021 12:08:28	HK00.000.001	9997974398	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974398.1	2383048	KVBHKFKKVI
S	DG_6580_TRA_PP_001	30.06.2021 12:08:28	HK00.000.001	9997974392	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974392.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_003	30.06.2021 12:08:29	HK00.000.001	9997974401	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974401.1	2383048	KVBHKFKKVI
E	DG_6580_TRA_PP_002	30.06.2021 12:08:29	HK00.000.001	9997974394	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974394.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_002	30.06.2021 12:08:31	HK00.000.001	9997974391	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974391.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_001	30.06.2021 12:08:31	HK00.000.001	9997974399	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974399.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_AT_003	30.06.2021 12:08:34	HK00.000.001	9997974397	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974397.1	2383048	KVBHKFKKVI
I	DG_6580_TRA_PP_003	30.06.2021 12:08:35	HK00.000.001	9997974394	urn:epc:tag:boschrfdkanban-96:RB.R72.11.9997974394.1	2383048	KVBHKFKKVI

Forrás: Excel adatbázis

„Kanban card 9997974394 read at last at Position 0000000002. Expected was last pos 0000000001”

Amikor ez a hibaüzenet jelenik meg, a rendszer azt várja el, hogy a kanban kártya egy másik visszajelentési ponton legyen lehúzva. Az egyik kanban kártya könyvelését megvizsgálva jól látszik, hogy mi okozta a hibaüzenetet.

- 1. hibaüzenet 11:42-kor: a PP_002-es pont a 2. lejelentési pont, azaz az elsőn valamiért nem lett lehúzva a kártya. Ezért a rendszer a 2. lejelentési ponton hibára fut, hiányolja az első lejelentési pontot.
- 2. könyvelés 12:07-kor: ez egy sikeres visszajelentés az első ponton, a kártya státusza 2-ről 3-ra vált.
- 3. hibaüzenet 12:08-kor: a második ponton nem sikerült a visszajelentés, mert egy másik visszajelentés blokkolja az anyagot. Emiatt a kanban státusza 3-as maradt.
- 4. hibaüzenet 12:28-kor: az előző sikertelen visszajelentés miatt a rendszer még mindig azt érzékeli, hogy a 2-es ponton hiányzik a visszajelentés, ezért az első visszajelentési ponton hibára fut. A hibát az SAP könyvelésben a kanban kártya 3-as státuszról 2-esre történő visszaállítása okozta, anélkül, hogy először 5-ösre lett volna átállítva.
- 5. könyvelés: mivel ez a visszajelentés a második ponton történik, és a rendszer még mindig azt várja, hogy a 12:08-as hibára futott könyvelés megtörténjen, így a 2-es ponton történő visszajelentés sikeres lesz.

23. ábra - Második típusú hibaüzenetre példa

Status	Status	Dev.Group	D&T Read	Material	Kanban ID	Status	Proc. Seq	Confirm	Msg. type	Message
I	I	DG_6580_TRA_AT_001	30.06.2021 11:40:09	HK00.000.001	9997974394	2	0	1		
I	I	DG_6580_TRA_AT_005	30.06.2021 11:41:40	HK00.000.001	9997974394	2	0	1		
E	E	DG_6580_TRA_PP_002	30.06.2021 11:42:06	HK00.000.001	9997974394	5	2	1	E	Kanban card 9997974394 read at last at Position 0000000002. Expected was last pos 0000000001
I	I	DG_6580_TRA_AT_001	30.06.2021 12:07:28	HK00.000.001	9997974394	2	0	1		
S	S	DG_6580_TRA_PP_001	30.06.2021 12:07:42	HK00.000.001	9997974394	5	1	3		30.06.2021 12:07:44
I	I	DG_6580_TRA_AT_003	30.06.2021 12:07:55	HK00.000.001	9997974394	3	0	1		
I	I	DG_6580_TRA_AT_004	30.06.2021 12:08:06	HK00.000.001	9997974394	3	0	1		
I	I	DG_6580_TRA_AT_005	30.06.2021 12:08:18	HK00.000.001	9997974394	3	0	1		
E	E	DG_6580_TRA_PP_002	30.06.2021 12:08:29	HK00.000.001	9997974394	5	2	3	E	30.06.2021 12:08:30
I	I	DG_6580_TRA_AT_001	30.06.2021 12:28:20	HK00.000.001	9997974394	2	0	1		
I	I	DG_6580_TRA_AT_002	30.06.2021 12:28:31	HK00.000.001	9997974394	2	0	1		
I	I	DG_6580_TRA_AT_003	30.06.2021 12:28:42	HK00.000.001	9997974394	2	0	1		
E	E	DG_6580_TRA_PP_001	30.06.2021 12:28:54	HK00.000.001	9997974394	3	1	1	E	Kanban card 9997974394 read at last at Position 0000000001. Expected was last pos 0000000002
I	I	DG_6580_TRA_AT_004	30.06.2021 12:29:15	HK00.000.001	9997974394	2	0	1		
I	I	DG_6580_TRA_AT_005	30.06.2021 12:29:37	HK00.000.001	9997974394	2	0	1		
S	S	DG_6580_TRA_PP_002	30.06.2021 12:29:58	HK00.000.001	9997974394	5	2	3		30.06.2021 12:30:00

Forrás: Excel adatbázis

„The mandatory status ÜRES from status sequence 3 cannot be ignored”

A hibaüzenet arra utal, hogy a kanban kártya státusza nincs sorrendben könyvelve. A kanban státuszok sorrendje kötött: 2-üres, 3-folyamatban, 5-teli, majd újból 2-3-5 és így tovább.

Az alábbi példánál látható, hogy az első lejelentési ponton a 2-es státusz sikeresen 3-as státuszra váltott, a második lejelentési ponton pedig 3-asról 5-re. A következő lépés az lett volna, hogy a kártya 5-ös státuszát visszaállítjuk 2-re, azaz újra lejelenthető lesz a kártya.

Ez a lépés nem történt meg, ugyanis csak egyszer volt visszaállítás, egy későbbi időpontban, 12:19-kor, a második teszt kör után. Az első teszt kör után hiányzik ez a lépés, ezért a második teszt alatt a kártya könyvelése hibára fut, mert 5-ös státusz után nem lehet 3-as státuszt állítani.

24. ábra - Harmadik típusú hibaüzenetre példa

Status	Status	Dev.Group	D&T Read	Material	Kanban ID	Status	Proc. Seq	Confirm	Msg. type	Message
I	I	DG_6580_TRA_AT_001	30.06.2021 11:39:23	HK00.000.001	9997974386	2	0	1		
S	S	DG_6580_TRA_PP_001	30.06.2021 11:39:34	HK00.000.001	9997974386	3	1	3		30.06.2021 11:39:36
I	I	DG_6580_TRA_AT_005	30.06.2021 11:40:21	HK00.000.001	9997974386	3	0	1		
S	S	DG_6580_TRA_PP_002	30.06.2021 11:41:01	HK00.000.001	9997974386	5	2	3		30.06.2021 11:41:03
I	I	DG_6580_TRA_AT_001	30.06.2021 12:08:38	HK00.000.001	9997974386	5	0	1		
E	E	DG_6580_TRA_PP_001	30.06.2021 12:08:49	HK00.000.001	9997974386	3	1	3	E	30.06.2021 12:08:50
I	I	DG_6580_TRA_AT_002	30.06.2021 12:09:01	HK00.000.001	9997974386	5	0	1		
E	E	DG_6580_TRA_PP_002	30.06.2021 12:09:12	HK00.000.001	9997974386	5	2	1	E	Kanban card 9997974386 read at last at Position 0000000002. Expected was last pos 0000000001
I	I	DG_6580_TRA_AT_004	30.06.2021 12:09:24	HK00.000.001	9997974386	5	0	1		
I	I	DG_6580_TRA_AT_003	30.06.2021 12:09:35	HK00.000.001	9997974386	5	0	1		
I	I	DG_6580_TRA_AT_005	30.06.2021 12:09:57	HK00.000.001	9997974386	5	0	1		
I	I	DG_6580_TRA_AT_001	30.06.2021 12:27:10	HK00.000.001	9997974386	2	0	1		
S	S	DG_6580_TRA_PP_001	30.06.2021 12:27:21	HK00.000.001	9997974386	3	1	3		30.06.2021 12:27:24
I	I	DG_6580_TRA_AT_002	30.06.2021 12:27:35	HK00.000.001	9997974386	3	0	1		
S	S	DG_6580_TRA_PP_002	30.06.2021 12:27:46	HK00.000.001	9997974386	5	2	3		30.06.2021 12:27:49
I	I	DG_6580_TRA_AT_004	30.06.2021 12:28:08	HK00.000.001	9997974386	5	0	1		

Forrás: Excel adatbázis

25. ábra - SAP könyvelés kivonat

Table: /RB04/YL7_PKPSVT
 Displayed Fields: 16 of 17 Fixed Columns: 6 List width 0250

Material	ID number	Created on	Document time	User Name	Kanban status	Mat. Doc.Item	Previous status	Reporting Point
<input type="checkbox"/> HK00000001	9997974386	30.06.2021	11:39:36	CT_6580	3	0000	2	0001
<input type="checkbox"/> HK00000001	9997974386	30.06.2021	11:41:03	CT_6580	5	0000	3	0002
<input type="checkbox"/> HK00000001	9997974386	30.06.2021	12:19:12	VAK1HTV	2	0000	5	
<input type="checkbox"/> HK00000001	9997974386	30.06.2021	12:27:24	CT_6580	3	0000	2	0001
<input type="checkbox"/> HK00000001	9997974386	30.06.2021	12:27:49	CT_6580	5	0000	3	0002

Forrás: SAP

Ezek a hibák a termelési idő hosszának növekedését eredményezték az első termelési ciklusnál. A második és harmadik termelési ciklus hatékonyabb volt abból a szempontból is, hogy a hibáüzenetek száma csökkent és a termelés időtartamának hosszát nem, vagy csak minimális mértékben befolyásolták.


26. ábra - Könyvelési pontok aktivitása



Forrás: Saját szerkesztés Power BI-ban

Két könyvelési pontunk van. A 26. ábrán az első pont aktivitása látható, mely közvetlenül az előszerelde után helyezkedik el.

27. ábra - Termelési sor aktivitása

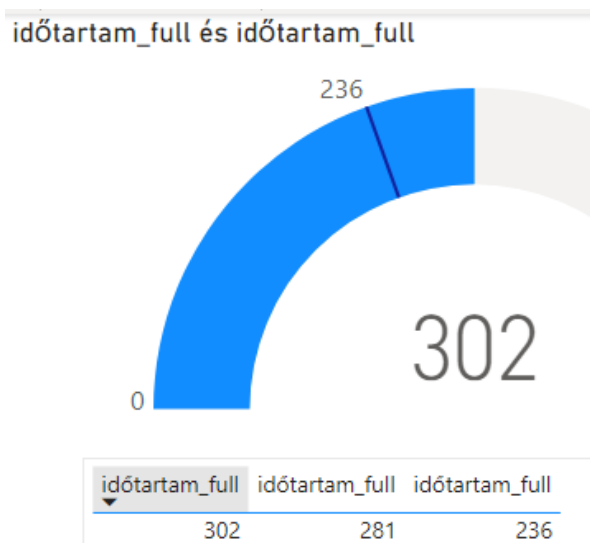


Forrás: Saját készítés Power BI-ban

Az ábrán vizuálisan az RFID olvasók aktivitása jelenik meg: a görbe ki van simulva, amikor a szünet van, a 'dombok' pedig a termelési sor aktivitását mutatják.

Termelési ciklusokra vonatkozó grafikonok:

28. ábra - Termelési ciklusok hossza



Forrás: Saját készítés Power BI-ban

Az első termelési ciklus 302, a második 281, a harmadik 236 másodpercig tartott. Az eltérő ciklusidők oka, hogy bár alapvetően 5 perces (300 másodperc) ciklusok vannak, de ha a csapat hamarabb végez a kiírt cél darabszámmal, akkor az idő ezt megmutatja.

29. ábra – Az első termelési kör során észlelt RFID jelzések között eltelt időtartamok


időtartam_full, kategória: idő



Forrás: Saját készítés Power BI-ban

A legelső termelési kör során az épülő ház munkaállomások közötti mozgása során az RFID érzékelők által adott jelzések közötti eltelt időtartamok hosszát jeleníti meg az ábra. A három ciklus grafikonjait összehasonlítva az első esetben túl sokszor látható az, hogy a jelzések közt eltelt idő hossza meghaladja az 5 másodpercet, amit tekinthetünk egy megfelelő viszonyítási értéknek.

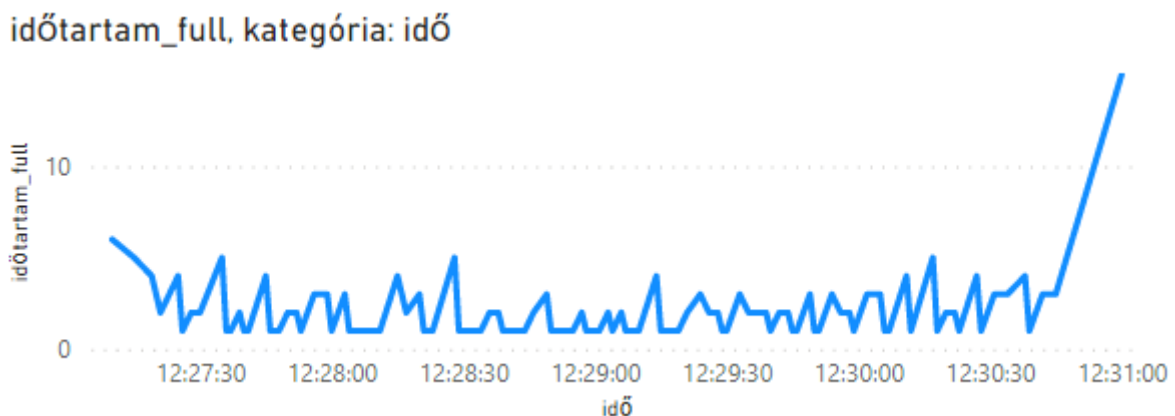
30. ábra - A második termelési kör során észlelt RFID jelzések között eltelt időtartamok



Forrás: Saját készítés Power BI-ban

A második termelési kör során a termék munkaállomások közötti mozgása során az RFID érzékelők által adott jelzések közötti eltelt időtartamok hosszát jeleníti meg ez az ábra.

31. ábra - A harmadik termelési kör során észlelt RFID jelzések között eltelt időtartamok



Forrás: Saját készítés Power BI-ban

A harmadik termelési kör során az épülő ház munkaállomások közötti mozgása során az RFID érzékelők által adott jelzések közötti eltelt időtartamok hosszát jeleníti meg ez az ábra.


A három termelési ciklus közül az utolsónál történt meg az, hogy az érzékelések köz eltelt időtartam hossza szinte kivétel nélkül nagyobb kilengések nélkül a 0 és 4 másodperc tartományban



Forrás: Saját készítés Power BI-ban

Ezek a vonaldiagramok az első ciklus kezdetétől a befejezésig a készülő termék munkaállomásra történő megérkezésekor az RFID szenzorok rögzítette érzékelések, majd az adott munkaállomáson elvégzett munka időtartamának hosszát jelenítik meg, termékenként. A rövidebb görbe inaktivitásra, hibára utalhat.

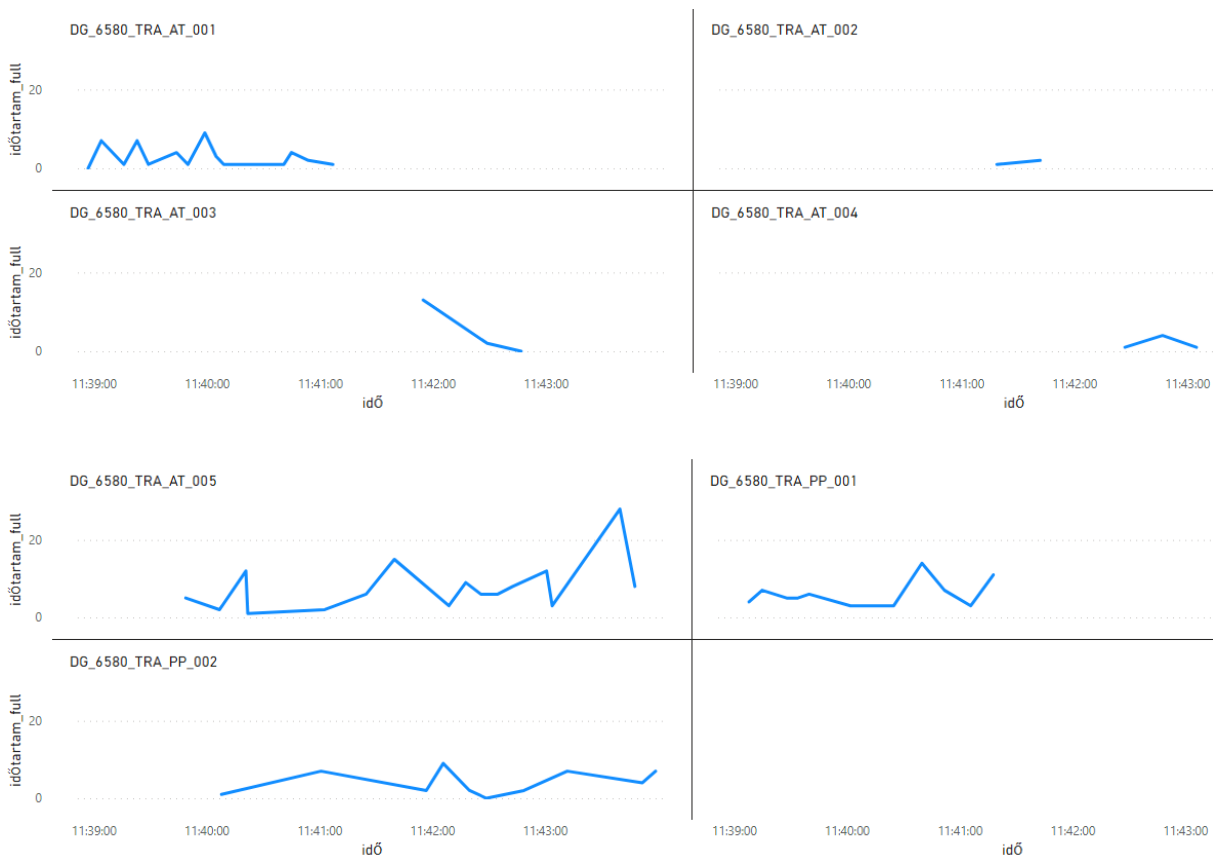
33. ábra - RFID azonosítók leolvasásai közt eltelt időtartamok



Forrás: Saját készítés Power BI-ban

Az ábrán a pontok nagysága mutatja meg azt, hogy az első termelési ciklus során hány másodperc telt az egyes RFID adatleolvasások között. Minél nagyobb egy pont kiterjedése, annál többet várakozott a készülő termék valamelyik munkaállomáson.

34. ábra - Munkaállomások leterheltsége az az első gyártási periódus alatt




Forrás: Saját készítés Power BI-ban

A fentebb látható vonaldiagramok a gyártás első fázisának időtartama alatt a készülő termék munkaállomásra történő megérkezésekor az RFID szenzorok rögzítette érzékelések, majd az

adott munkaállomáson elvégzett munka időtartamának hosszát jelenítik meg. A rövidebb vonal az adott munkaállomás kisebb számú igénybevételét mutatja. A vonaldiagramok mozgásai pedig az adott szenzor érzékelései közt eltelt időtartam hosszát jelöli.

35. ábra - Az egyes RFID olvasók felett áthaladó termékek száma



Forrás: Saját készítés Power BI-ban

A munkaállomásokon elhelyezett RFID szkennerek felett a gyártás során áthaladó termékek darabszámát mutatja az ábra az első termelési kör teljes időtartama alatt. Az eltérések oka, hogy az elkészült termékek egymástól eltérően, különböző építőelemekből állnak össze.

Összegzés

Az első termelési ciklus lezajlása után 16, a második során 26, az utolsó ciklus futása végeztével 28 termék készült el. A termelési szakaszok időtartamait összehasonlítva szintén jelentős különbség figyelhető meg az egyes termelési periódusok között. A termelési ciklusok elindulása között eltelt köztes időben az operátorok megbeszélnek tapasztalatokat, felkészülnek a következő gyártási körre és a termelési sort is optimalizálják, folyamatos hatékonyságnövelő intézkedések zajlanak, például integrálják az i4.0 eszközöket, módosítanak a layout-on. Ez okozza a gyártási fázisok között megfigyelhető hatékonyságbeli különbségeket.

Adatvizualizációkkal szemléltettem az eredményeket és a legfontosabb összefüggéseket az adatok között. Ezek alapján a H1 hipotézist elfogadjuk.

13 A MESTERSÉGES INTELLIGENCIA ISMERTSÉGE ÉS A TÁRSADALMI ELFOGADOTTSÁGA

A dolgozatom eddigi fejezeteit áttekintve elmondhatjuk, hogy áttekintést kaptunk a mesterséges intelligenciáról és konkrét alkalmazási területekbe illetve alkalmazási módokba is érdemi betekintést nyertünk.

Ugyanakkor kijelenthetjük, hogy napjainkban a mesterséges intelligencia – bár már széles körben elterjedt – de felhasználása még mindig a lehetőségek kezdetein tart. Hasonló a helyzet, mint az informatika viszonylatában, a 80-as évek kezdetén, amikor is a 8 bites mikroszámítógépek robbanásszerű elterjedése már éreztette az adott terület lehetőségeinek végtelenségét. Ám ugyanakkor ki gondolt volna arra a mindent elnyelő információözönre, ami napjainkat meghatározza. Arra, hogy ingyenesen videótelefonálhatunk, hogy otthonról dolgozhatunk, hogy műsorcsatornák százaiból válogathatunk, hogy autóink magukat vezetik, hogy a telefonjaink válnak életünk legfontosabb technikai segédeszközeivé. Ugyanakkor legrosszabb álmainkban sem szerepelt a darknet, az online kábítószer- és szervkereskedelem, a terrorista videók, a zsarolóvírusok. Mára már inkább nevetségesnek hatnak az „Adatrablók” című egykori kultfilm szereplőinek sajátos hacker-technikái.

A mesterséges intelligencia ugyanakkor egy sokkal összetettebb és sokkal átfogóbb lehetőségekkel bíró terület, a hatása drámaibb lehet mindennél, amit eddig ismertünk.

Mégis joggal feltételezhetjük, hogy **az emberek többségének elenyészően kevés ismerete és még kevesebb jártassága van az AI-ban.**

Ennek kimutatásához egy kérdőívet tettem közzé, melyet 35-en töltöttek ki.


A kapott adatok elemzésével igazolom, vagy cáfolom majd a fenti állítást

13.1 A kérdőívek adatainak elemzése:

36. ábra - Melyik évben született ?

Melyik évben született ?

34 válasz




Forrás: Saját szerkesztés, Google táblázatok

Az első kérdésre adott válaszok az 1965-2005-ig terjedő tartományba esnek. Adataink tehát egy viszonylag széles válaszadói körtől származnak. Ugyanakkor jól látható a Z generáció (1996-2012) létszámbeli dominanciája.

37. ábra - Hallott már mesterséges intelligenciáról ?

Hallott már a mesterséges intelligenciáról ?

35 válasz



Forrás: Saját szerkesztés, Google táblázatok

A mesterséges intelligencia napjaink egyik slágertémája. Nem véletlen tehát az, hogy már mindenki hallott róla valamit.

„Hol hallott a mesterséges intelligenciáról ?”

A válaszok megfogalmazásukban sokfélék voltak, tartalmukban azonban egységesen az internetet, az informatikai eszközöket jelölték meg. Ezzel is jól megmutatva azt, hogy napjainkat ezer szállal szövik át az online eszközök, médiák.

„Mit tud a mesterséges intelligenciáról ?”

Néhány érdekesség a kapott válaszok közül:

- *Ma az egyik legszélesebb körben használt technológia, amelyben nagy potenciál rejlik.*
- *Létezik és egyszerűbb feladatokra képes. Számítógép magától által generál dolgokat*
- *Különböző tanuló algoritmusok segítségével működő szoftverek, amelyek rengeteg ciklus lefutását követően el tudnak végezni olyan feladatokat, amelyek tradicionálisan emberi gondolkodást igényelnek - például beszédhang utánzása, festmények/képek készítése, szövegek fogalmazása.*
- *Könnyíteni szeretnénk vele az életünket*
- *Rendkívül nagy hatású technikai változás, amelynek a veszélyessége is rendkívüli.*
- *Nagyon okos, hozzáértő emberek is hajlamosak elhinni, hogy vannak érzelmei, pedig logikusan ki van fejtve, hogy miért nincs neki*
- *Mesterségesen állít elő képeket, szövegeket; ehhez valódi emberek munkáit másolja le (magyarul ellopja őket.*
- *Olyan robotok vagy számítógépek, amik mindenre tudják a választ és a megoldást is*
- *Keveseset. Nem sokat. Semmit.*

Bár ez nem egy bonyolult kérdés és nincs is rá jó- vagy rossz válasz – mégis a válaszokban a téma divatossága és a teljes tudatlanság érzékelhető. Magabiztos ismeretek alig. A válaszokból sajnos egyértelműen látható, hogy a témát az emberek fejében inkább homály és misztikum övezi, semmint tárgyyszerű ismeretek vagy tapasztalatok. Egyetlen olyan választ sem láttam, ami akárcsak megfogalmazta volna a mesterséges intelligencia átfogó értelmezését.

„Mit tud a neurális hálókról?”


A korábbi kérdés válaszai alapján nem várhattunk itt sem tartalmas válaszokat. Mégis érkezett néhány:

- *Szimuláció, amelyet az állatok agyi működései ihlettek. A gépi tanulásnál van jelentősége, ahol a mesterséges intelligencia gyakorlati tapasztalatot szerez problémák megoldásában. Neuronrétegekből áll össze, ezek között működnek aktivációs - és veszteségfüggvények is. Gráf alapú rendszer.*
- *Az öntanuló rendszerek egyik alapvető formája.*
- *Idegrendszeri hálózat, a neuronok axon-okkal és dendritekkel létrehozott kapcsolati rendszere, ami lehetővé teszi az agy és az idegrendszer működését.*

Meglepő és elgondolkodtató, hogy egy jelentősen kisebb részterületről mennyivel pontosabb válaszok érkeztek. Ennek valószínűleg az is az oka, hogy a neurális hálók tematikája sokkal régebb óta van a széles köztudatban, míg a mesterséges intelligencia csak napjainkban vált sikertémává. Észre kell vegyünk, a válaszadók igenis képesek jó és tartalmas válaszokat adni. Nem emiatt van tehát, hogy a mesterséges intelligenciával kapcsolatosan a válaszok ennyire értékelhetetlenek.

38. ábra - Ön szerint fenyegetést jelent-e a mesterséges intelligencia az emberekre ?

Ön szerint fenyegetést jelent-e a mesterséges intelligencia az emberekre ?
35 válasz



Forrás: Saját szerkesztés, Google táblázatok


A kérdés alapvető fontosságú, több szempontból is.

Látható, hogy sokféle bizonytalan válasz mellett határozott IGEN-ek és NEM-ek is születtek, közel azonos arányban, lefedve a válaszok mintegy 2/3-át. Mindez jól mutatja a mesterséges intelligencia veszélyeit illetően a nagyfokú bizonytalanságot, illetve a veszély elfogadható kerek között tarthatóságába vetett hitet vagy épp annak az ellenkezőjét. Mivel a határozott válaszok is egymásnak szöges ellentétei, így joggal beszélhetünk inkább hitről, mintsem valós tudásra alapozott válaszokról.

39. ábra - Ha egy MI hibát követ el, Ön szerint kié a felelősség ?

Ha egy MI hibát követ el, Ön szerint kié a felelősség ? Gondoljon az önvezető járművekre !

35 válasz




Forrás: Saját szerkesztés, Google táblázatok

A válaszadók több mint fele a mesterséges intelligencia alkotóját nevezi meg a hibás működés felelőseként. A válaszadókban tehát erősen él az a hit, hogy az MI alkotója képes az MI-t és annak működését szabályok, keretek közt tartani. Sajnos ez is a témában meglévő tájékozatlanságot mutatja. Érdekes módon az MI megszemélyesülése, mint akár felelőssé is tehető tényező sem elhanyagolható mértékben jelent meg. A fatalista „Senki nem felelős” csoport szintén a bizonytalanságot, a tájékozatlanságot mutatja.

40. ábra - Van jövője az emberiségnek MI nélkül ?

Van jövője az emberiségnek MI nélkül ?

35 válasz




Forrás: Saját szerkesztés, Google táblázatok

Az ember és az emberiség biológiai korlátai számos tekintetben hátráltatják a tudományos-technikai fejlődést. Ha az utóbbira úgy tekintünk, mint az emberiség jövőjének egyetlen lehetséges útjára, úgy kétségtelen, hogy a mesterséges intelligencia nélkül az említett korlátok egy idő után átléphetetlen akadállyá válhatnak. Másfelől akár a mesterséges intelligencia is átléphetetlen akadállyá válhat. A válaszok azonban teljesen magabiztos képet mutatnak: ott az a hit látszik, hogy az emberiség képes lesz minden problémáját saját maga megoldani. Kevesen hiszik, hogy elengedhetetlen szükség van a mesterséges intelligenciára.

41. ábra - Szívesen látna mesterséges intelligenciával rendelkező robotokat az otthonában ?

Szívesen látna mesterséges intelligenciával rendelkező robotokat az otthonában ?

35 válasz




Forrás: Saját szerkesztés, Google táblázatok

Az MI elutasítottsága az otthonok szintjén is jelen van és közel 2/3-os arányt mutat. Ugyanakkor jóval szélesebb kör az, aki megengedné a mesterséges intelligencia működését akár az otthonában is.

42. ábra - Ön szerint baj, hogy a mesterséges intelligenciát használó robotokkal helyettesítik az emberi munkaerőt a cégek ?

Ön szerint baj, hogy mesterséges intelligenciát használó robotokkal helyettesítik az emberi munkaerőt a cégek ?

35 válasz



Forrás: Saját szerkesztés, Google táblázatok

Itt közel egyenlő arányt mutatnak az igenek, a nemek és a talánok. A munkánkat jóval kevésbé féltjük, mint az otthonunkat vagy az emberiség jövőjét. A válaszok arra mutatnak, hogy a válaszadók hisznek az MI által megtermelt javakból való részesedésben – holott az egyáltalán nem természetes. Sokkal valószínűbb, hogy míg az MI veszélyét az emberiség közösen viseli, addig annak esetleges hasznát egy-egy cég vagy pénzügyi csoport fölözi majd le.

Néhány érdekesebb válasz az utóbbi grafikonhoz:

- *Ha robotok veszélyes, monoton vagy hiányszakmákat, esetlegesen kiegészítő munkákat töltenek be, minden további nélkül. Ha azonban magasan képzett munkapozíciókat töltenek be, akkor társadalmilag nagyon veszélyes folyamatok indulhatnak be.*
- *Maguktól nem működnek, így hozzájuk is kell fejlesztő, karbantartó.*
- *A mesterséges intelligencia a gépies, monoton, kreativitás nélküli munkákat képes el látni, a művészeteket és kreatív, emberi érzéket igénylő munkákat nem fogja tudni helyettesíteni. Erre jó analógia az ipari forradalom és az edénygyártás: az ipari forradalom után megkezdődött a tányérok, tálak stb. gyors ütemű készítése, de ezeknek a tudatában az emberek által saját kézzel készített edények ma sokkal többet érnek.*
- *Így tudunk több embert más pozíciókban elképzelni és helyettesíteni*
- *Addig nincs gond, amíg az irányíthatóság a kezünkben van.*

- *Mert vannak olyan munkák, amik monotonok, ezeket lehet ezzel helyettesíteni. Az élet rendje az is, hogy jönnek új dolgok, eltűnnek régi dolgok. De meg kell adni a lehetőséget az emberi munkaerőnek, hogy pótolni tudja munkahelyét*
- *Vannak területek, amik az emberek javát szolgálnák, pl. sebészet, vagy mondjuk műszaki tervezés stb., ha minimalizálnák az emberi hibákat vele az jó lenne*
- *Vannak olyan pl. erőteljes fizikai munkát igénylő vagy veszélyes munkakörök, ahol kifejezetten hasznos lenne, ha robotok végeznék emberek helyett a munkát*
- *Egyrészt elveheti a munkáját az embereknek, másrészt viszont lehet, hogy csak könnyítené azt.*
- *Kiszorulnak az emberek a munkahelyükről és már így is nagy válság és szegénység uralkodik világszerte így úgy gondolom az erre használt pénzt jobb módon is fel lehetne használni annak érdekében, hogy az emberek jobb minőségű életet éljenek.*
- *Mert egyre kevesebb szükség lesz az emberekre, és ez hátrány a társadalom számára*
- *Az embert lassan már mindenhol kiiktatják*
- *Feleslegessé válna az ember*
- *Akkor a jövőben mi lesz az emberekkel? Miből fognak élni?*


Ha vannak egyéb gondolatai a témához kapcsolódóan, kérem fejtse ki !

- *MI legnagyobb veszélye a tömegmanipuláció, kémkedésben rejlik szerintem. A cégek is sokkal könnyebben fogják tudni manipulálni az embereket, véleményt formálni, keresletet gerjeszteni a termékeik iránt.*
- *Sokan Hollywood világában élnek és eltúlozzák a MI veszélyeit*
- *A technikai fejlődést az emberiség morális fejlődésének is követnie kellene.*
- *Nyilván a MI nem lesz beteg, nem kell munkabért fizetni*
- *A MI kapcsán nagyon hiányosak, sok esetben tévesek az emberek információi. A legtöbb embernek szerintem a gyilkos robotok jutnak eszébe a hollywoodi filmekből. Ezen mindenképp javítani kell, hogy megbarátkozzon vele a közvélemény. Ugyanakkor viszonylag nehéz közérthetővé tenni a témát, hogy az utca embere is megértse.*

13.2 Elemző diagramok

A következő néhány diagramban az adatok egyes belső összefüggéseit mutatom ki:


43. ábra - Az MI fenyegetésként értékelése életkor szerinti megoszlásban



Forrás: Saját szerkesztés, Microsoft Excel

Látható, hogy a Z generáció (napjaink fiatal felnőttjei) sokkal kevésbé érzik fenyegetésnek a mesterséges intelligenciát, mint a náluk idősebbek. Ők már informatikai eszközök között nőttek fel, természetes számukra a digitális világ.


44. ábra - Veszélyérzet a működési felelős szerint bontásban



Forrás: Saját szerkesztés, Microsoft Excel

A jelen grafikon szerint számottevő eltérés nincs a fenyegetés érzetében azok között, akik az MI esetleges hibás működéséért az alkotóját vagy a használóját tennék felelőssé. A 3. oszlop azonban rendkívül érdekes: az MI-t jóval kisebb arányban érzik biztonságosnak azok, akik egyébként a hibás működésért magát az MI-t tennék felelőssé. A 4. oszlop pedig még érdekesebb: a korábban „fatalistáknak” nevezett csoport véleményét most érthetjük meg igazán: ők egyáltalán nem tartanak attól, hogy az MI hibázhat, nincs tehát fenyegetettség-érzetük. Emiatt nem okoltak senkit, hiszen, ha nincs hiba, nincs felelős sem.


45. ábra - Az MI otthoni elfogadottsága a jövőkép szerinti bontásban



Forrás: Saját szerkesztés, Microsoft Excel

Ez a grafikon is rendkívül jól megmutatja a válaszok bizonyos belső összefüggéseit. Láthatóan alig van eltérés az emberiség jövőjét nem az MI-vel elképzelők csoportja és a bizonytalanok között. Ők egyaránt csak közel 30%-os arányban fogadnák el szívesen az MI-t az otthonukban. Jelentősen mást mutat az emberiség jövőjét az MI-vel elképzelők oszlopa: ott ez az arány éppen fordított: 70% elfogadó, míg a maradék 30% sem elutasító, hanem csak bizonytalan.

46. ábra - A munkahelyek féltésének aránya a jövőkép szerinti bontásban



Forrás: Saját szerkesztés, Microsoft Excel

Hasonlóan az előző grafikonhoz, itt is közel azonosak az MI-val közös jövőt elutasítók és a bizonytalanok arányai a munkahelyek MI által való veszélyeztetettségét illetően. Megdöbbentő azonban a középső oszlop teljes eltérése: a jövőt az MI-vel elképzelők egyáltalán nem látják a munkahelyeket fenyegetve az MI által.

A válaszokból, a grafikonokból és elemzésükből jól láthattuk tehát azt, hogy a mesterséges intelligenciát rendkívüli tájékozatlanság övezi. Kevesen érzik és még kevesebben értik az MI lényegét, lehetőségeit és az általa megjelenő esetleges fenyegetés mibenlétét.

A mesterséges intelligencia kétségtelenül napjaink egyik slágertémája. S bár egyre szélesebb körben alkalmazzák, ám magát a technológiát és az alkalmazását is rendkívüli bizonytalanság és tájékozatlanság övezi.

Már az intelligencia fogalmának általános megértése is kérdéses a legtöbb ember számára. Sokan, a hétköznapiakban az intelligenciát egyfajta lexikális tudással azonosítják. Ebből a nézőpontból nézve a számítógépek valóban intelligensnek tűnhetnek, hiszen az egyszer már rögzített adatokat bármikor előkereshetik és villámgyorsan bemutathatják, ellentétben az emberrel. Ugyanakkor mindennek szinte semmi köze az intelligenciához vagy annak valódi természetéhez.

Az én saját megfogalmazásom szerint az intelligencia az információk begyűjtésének, feldolgozásának képessége és az ezekre alapuló önálló döntéshozatali képesség kiegészülve a meghatározott eredmény információs visszacsatolásával és annak újrafeldolgozásával létrejövő tanulási folyamattal.

Ezt megértve jól látható annak a látszólagos ellentmondásnak a feloldása, amely ellentmondásra jó példa az, hogy miközben „intelligensnek” gondolt dolgok könnyedén leprogramozhatóak (speciális egyenletek matematikai megoldása), addig az életünk természetes részét képező látás (képfértelmezés), hallás (zajfeldolgozás), mozgáskoordináció megvalósítása elképesztően nagy erőforrások igénybevételével is csak erősen korlátozottan valósítható meg napjaink informatikai eszközeivel.

A mesterséges intelligencia megjelenése és beépülése a jelenlegi, egyelőre még kevésbé intelligens informatikai környezetünkbe, eszközeinkbe elképzelhetetlen lehetőségeket és kihívásokat jelent a jövőnkben. Egy olyan új szereplőt az emberiség történelmében, amilyennel még soha nem találkoztunk korábban.

Voltak persze elképzeléseink. Az Isaac Asimov által megfogalmazott 3 alaptörvény a következő:

- 1. A robotnak nem szabad kárt okoznia emberi lényben, vagy tétlenül tűrnie, hogy emberi lény bármilyen kárt szenvedjen.*
- 2. A robot engedelmeskedni tartozik az emberi lények utasításainak, kivéve, ha ezek az utasítások az első törvény előírásaiba ütköznének.*
- 3. A robot tartozik saját védelméről gondoskodni, amennyiben ez nem ütközik az első vagy második törvény bármelyikének előírásaiba.*

(Isaac Asimov (1942): Rundaround című novella)

A fenti mondatokban a „robot” szót bátran helyettesítsük a „mesterséges intelligencia” kifejezéssel. Tekintsük az előbbi az utóbbi fizikai megjelenési formájának. Logikusan gondolkodva a fenti törvények nem is szólhatnak másképp. (Voltak kiegészítések, módosítások, de ezek a lényegesen nem változtattak.) (Felkai, 2020)

Ugyanakkor ma már tudjuk, hogy ezen törvények beprogramozhatatlanok, megvalósíthatatlanok. Olyan mélyen és olyan alapvetően kellene beépülniük a rendszerek alapvető funkciói közé, amely alapvető szinteken mindezek a feltételek megépíthetetlenek.

Asimov törvényei – bár megkerülhetetlenek, de hamis biztonság illúzióját keltik, mivel megvalósíthatatlanok. Napjaink robotjai és mesterséges intelligenciái sem az asimovi törvények betartásával működnek. (Dzindzisz, 2017)

Láttuk azt is, hogy a mesterséges intelligencia kitűnően alkalmazható a gyártásban, az adatfeldolgozásban és ezernyi más területen. Ugyanakkor mindez még gyerekcipőben jár.

Kimutattam továbbá, hogy a mesterséges intelligencia fogalmát nagyfokú tájékozatlanság és jelentős, félelmekkel teli bizonytalanság övezi, melyből gyakorta származik akár teljes elutasítás is.

Van e okunk tehát félni a mesterséges intelligenciától?

Miben más ez a félelem, mint a világunkban létező ezernyi más fenyegetés?

Ha sok veszély közül egyként tekintünk rá, már akkor sem lehetünk teljesen nyugodtak. Ennek oka leginkább az, hogy az eddigi veszélyek kezelése sem megoldott. Gondolhatunk itt az atomfegyverekre, a harci vírusokra, az erőforrások és nyersanyagok koordinálatlan felhasználására, a profit mindenhatóságára, a társadalmak egyénekre való atomizálódására, a háborúkra, a vallási és ideológiai fanatikusokra, a bűnözésre, a kábítószerekre, a prostitúcióra, a rabszolgotartásra és emberkereskedelemre, a fajok kihalására, az invazív fajok károkozására és még sorolhatnám, sajnos. De a fenti problémáktól sokkal jelentéktelenebbnek látszó kérdésekre sem lelt az emberiség megoldást, például: az egyszerhasználatos műanyagok szemétként való megjelenése, vagy a kriptopénzek bányászására ostobán elpazarolt hihetetlen mennyiségű energia.

Ugyanakkor az MI teljesen más, mint az előbb említettek.

Ennek megértéséhez Csányi Vilmos: „Ő ott bent” című könyvét idézném ide röviden.

(Csányi Vilmos: Ő ott bent, 2018 Libri Kiadó)

Egy mesterséges intelligenciával végzett kísérlet során egy tudós idegrendszerét képezik le egy számítógépes rendszerben. A kísérlet azonban rövid időn belül átlépi a korlátait és megfékezhetlenné válik.

Rendkívül jó könyv, melynek felvetései, gondolatainak valósága sajnos megcáfолhatatlanok. Talán csak a legelső lépés, az emberi agy digitális másának létrehozása, ami napjainkban még sci-fi. Ám ettől is szinte csak teljesítménybeli korlátok választanak el.

Akkor hát miért nem tiltjuk be a mesterséges intelligenciát? – kérdezhajjuk joggal.

A válasz kettős. Egyrészt ugyanazért nem tiltható be, amiért az atomenergia harci használata sem volt betiltható soha. És ezért nem az emberiség ostobasága okolható, hanem pusztán csak az a tény, hogy aki becsületesen betartaná ezt a szabályt, az egyértelműen veszítene azokkal szemben, akik nem tartják azt be. Ukrajna és a Budapesti Memorandum (1994) esete idézhető ide.

A válasz másik gondolata az, hogy a mesterséges intelligencia egy olyan lehetséges jövő, ami nemcsak, hogy jót hozhat, de akár az egyedüli megoldás lehet az emberiség számára. Tehát ha akarnánk sem lenne szabad elkerülni.

Ugyanakkor a mesterséges intelligencia akkor tölthetné be ezirányú szerepét, ha a civilizációnk irányítását is átvinné. Ez azonban beláthatatlan és visszafordíthatatlan következményekkel járhat. Következményekkel, melyek lehetnek jók, hasznosak – de lehetnek kártékonyak, pusztítók is az emberiség számára.

Nem véletlen, hogy napjainkban a világ vezető technológiai cégeinek vezetői szinte egységesen kérik a mesterséges intelligencia fejlesztések azonnali felfüggesztését. (Hajagos, 2023)

A kérésnek egyelőre nincs eredménye. És a technológiai lemaradástól való félelem hajtotta fejlesztési versennyel szemben talán nem is lesz soha eredménye.

A mesterséges intelligencia és annak alkalmazása tehát szinte elkerülhetetlen. Új szakemberek tömege és új tapasztalatok könyvtárnyi mennyiségű megértése válik hamarosan szükségessé.

14 ÖSSZEFOGLALÁS

A fentebb írtak alapján három hipotézist vizsgáltam a dolgozatomban:

- H0: Az adatvizualizáció szignifikánsan segíti a döntéstámogatást
- H1: Az AI (gépi tanulási modellek) alkalmazása szignifikánsan segítik a munkafolyamatokat
- H2: Az emberek többségének kevés ismerete és még kevesebb jártassága van az AI-ban

Összegezve a hipotézisekre kapott eredményeket megállapítható, hogy a vizsgált állítások igaznak bizonyultak. A technológiák várható fejlődésével a munkafolyamatokat az AI alkalmazása még inkább támogatni fogja. A mesterséges intelligencia szerepe jelenleg folyamatosan erősödik, ezzel párhuzamosan az emberek ismeretei az AI kapcsán bővülni fognak.

15 KÖSZÖNETNYILVÁNÍTÁS

Örömmel tölt el, hogy a dolgozatom ebben a témában készíthettem. Sokat tanulhattam a már működő rendszerek megismeréséből.

A lehetőségért és a segítségükért ezúton is köszönetet mondok tanárainnak, konzulenseimnek!

16 IRODALOMJEGYZÉK

Bergman, Gyulai (2019): Optimális karbantartásütemezés, avagy az előrelátás 4 szintje

<https://www.cnc.hu/2019/08/optimalis-karbantartasutemezes-avagy-az-elorelatas-4-szintje/> (Megtekintés időpontja: 2023.04.28.)

Bharathi (2021): Latest Guide on Confusion Matrix for Multi-Class Classification

<https://www.analyticsvidhya.com/blog/2021/06/confusion-matrix-for-multi-class-classification/> (Megtekintés időpontja: 2023.03.25.)

Bodnár Zsolt (2022): Magyarországon az egyik legalacsonyabb a mesterséges intelligenciát alkalmazó vállalkozások aránya az EU-ban

<https://qubit.hu/2022/06/09/magyarorszagon-az-egyik-legalacsonyabb-a-mesterseges-intelligenciat-alkalmazo-vallalkozasok-aranya-az-eu-ban> (letöltve: 2022.09.10.)

Bokor Attila László (2020): A mesterséges intelligencia és az átlagember – az ipari forradalom 4.0 és az önvezető járművek. Budapesti Gazdasági Egyetem

Botos Csaba (2017): A magától tanuló gép. CsoPa Mesterséges Intelligencia Műhely

<https://www.youtube.com/watch?v=yWTU5s97I6Q>

Craig Stedman (2023): What is data preparation? An in-depth guide to data prep

<https://www.techtarget.com/searchbusinessanalytics/definition/data-preparation>

Csányi Vilmos (2018): Ő ott bent, Libri Kiadó

Dávid Ádám (-): Mi az a STEEP elemzés?

https://kiszervezettmarketing.hu/online-marketing/steep-elemzes/?fbclid=IwAR01C-siMtMPz-QsahXEJjbsSahZPKWJOPj9QW1YJ96cmMH7L_NBjelyG4Y (Megtekintés időpontja: 2023.04.28.)

Dzindisz Magdaléna (2017): Nem érvényesek ma Asimov-törvényei

<https://index.hu/tech/2017/04/29/asimov-robotika-harom-torvenye/>

Farkas Richárd (2022): Gépi tanulás a gyakorlatban tananyag

<https://www.inf.u-szeged.hu/~rfarkas/ML20/alapfogalmak.html>

Felkai Ádám (2020): Négy új törvény kellene Asimov három robotika törvénye mellé

<https://raketa.hu/negy-uj-torveny-kellene-asimov-harom-robotika-torvenye-melle>

Gulyás István-Dr. Balázs Krisztina-Dr. Levendovszki János-Dr. Istenes Zoltán-Boa László (2020): Ez itt a kérdés – A mesterséges intelligencia és a robotizáció helyzete <https://www.youtube.com/watch?v=Kggbb8u8vtU>

Dr. Gyires-Tóth Bálint (2019): A deep learning iparosodása <https://www.youtube.com/watch?v=pWWIsptjaY0>

Hajagos Andrea és MTI (2023) • A legfrissebb fejlemények: 30/03/2023

<https://hu.euronews.com/2023/03/30/a-mesterseges-intelligencia-fejlesztésenek-felfüggeszteset-követlik-tech-cegek-vezetoi>

Husztai Dániel (2022): Mesterséges Intelligencia (AI) a gyakorlatban

saját előadás jegyzet (készítve: 2022.04.12.)

Isaac Asimov (1942): Rundaround

Dr. Jelasity Márk (2019): Mi a mesterséges intelligencia jövője?. Egyetem TV/Tandem https://www.youtube.com/watch?v=CxpmA2Bo1_U

Jelasity Márk (2021): A mesterséges intelligencia - 10 válasz dr. Jelasity Márktól. Egyetem TV/Választár <https://www.youtube.com/watch?v=zAkrC94FKMg>

Keleti Arthur (2021): A mesterséges intelligencia a világválság egyik nagy nyertese. ATV Magyarország <https://www.youtube.com/watch?v=r1drkRDdpU>

Kiss Gergely (2018): A mesterséges intelligencia kutatása és alkalmazása. TEDxGyőr <https://www.youtube.com/watch?v=XYXANH9HlvY>

Kis Zoltán (2021): MI a mesterséges intelligencia?. Más Világ Klub <https://www.youtube.com/watch?v=bekMAUPMMIs>

Krégl Klementina (2020): Digitális világ: Mesterséges Intelligencia. T-Systems Magyarország Zrt. <https://www.youtube.com/watch?v=FzJHC0E6pDo>

Kunsági-Máté Sándor (2021): Neurális hálózatok a csillagászatban és a pénzügyi világban. ELTE TTK Kutatók éjszakája

<https://www.youtube.com/watch?v=6g-unRuwtL4>

Kutor László (2015): Mesterséges intelligencia fejlesztési irányok. Óbudai Egyetem Neumann János Informatikai Kar <https://www.youtube.com/watch?v=HkpOM1eZWqI>

Lanng Jakob és Majed Ali (2018): Emberi tevékenységek osztályozása gépi tanulási módszerrel

<https://www.diva-portal.org/smash/get/diva2:1479983/FULLTEXT01.pdf>

Dr. Martinek Péter (2019): GYÁRTÁSI FOLYAMATOK ÉS GYÁRTÁSÜTEMEZÉS OPTIMALIZÁLÁSA VÁLLALATIRÁNYÍTÁSI RENDSZEREKBEN. Budapesti Műszaki és Gazdaságtudományi Egyetem Villamosmérnöki és Informatikai Kar Elektronikai Technológia Tanszék

<https://repozitorium.omikk.bme.hu/bitstream/handle/10890/16357/00018005.pdf?sequence=1> (letöltve: 2022.03.24.)

Meskó Bertalan (2020): A mesterséges intelligencia jövőkutatói kihívásai <https://www.youtube.com/watch?v=-ZubQ6nLsZA>

Mikola Péter (2019): Gépi Tanulás #1: Bevezetés

<https://www.youtube.com/watch?v=4JOI3xVz79Y>

Nagy-Rác István (2019): CRISP-DM módszertan – Mi az és hogyan használd?

<https://dmlab.hu/blog/crisp-dm-modszertan-mi-az-es-hogyan-hasznald/>

Neil Jakobstein (2016): Alinda - Neil Jakobstein mesterséges intelligencia-kutató

<https://www.youtube.com/watch?v=6hOY5Yqx3OE>

Póda Csanád (2020): Mi az az AI? És a Machine Learning?. Machine Learning Budapest csatorna <https://www.youtube.com/watch?v=sddfBWKaUNM>

Rebecca Reynoso (2021): A Complete History of Artificial Intelligence

<https://www.g2.com/articles/history-of-artificial-intelligence>

Senturus youtuber (2022): Power BI: Data Cleansing Using Power Query Editor

<https://www.youtube.com/watch?v=pDEJ5citfJA>

Szalavetz Andrea (2019): Mesterséges intelligencia és technológiavezérelt termelékenységemelkedés (letöltve: 2023.01.24.)

http://real.mtak.hu/102427/1/Szalavetz_MI_Final.pdf

Szerző ismeretlen (-):

<https://www.infosector.hu/microsoft-azure/> (Megtekintés időpontja: 2023.04.28.)

Szerző ismeretlen (-): Mi az Azure? – Microsoft-felhőszolgáltatások

<https://cloud.szerver.hu/mi-az-azure-microsoft-felhoszolgalatasok/>

Szerző ismeretlen (2020): Magyarország Mesterséges Intelligencia Stratégiája 2020-2030

<https://ai-hungary.com/api/v1/companies/15/files/137203/view>

Szerző ismeretlen (-):

<https://www.tablázat.hu/cikkek/ipar-4-0/> (letöltve:2022.08.29.)

Szerző ismeretlen (-):

<https://hold.hu/lexikon/mesterseges-intelligencia-strategia-fogalma/> (letöltve:2022.10.25.)

Szerző ismeretlen (-): Confusion Matrix

https://en.wikipedia.org/wiki/Confusion_matrix

Szerző ismeretlen (-): Klasszikus alkalmazások: Termelésoptimalizálás, Hozzárendelési probléma: folytonos eset, Arbitrázsárzás. Budapesti Műszaki és Gazdaságtudományi Egyetem

http://lendulet.tmit.bme.hu/~retvari/courses/VITMD097/hu/08-lecture_appl_classical.pdf (letöltve: 2022.ápr.10.)

Szerző ismeretlen (2019): How will AI impact the Hungarian labour market?

<https://www.pwc.com/hu/en/publications/assets/How-will-AI-impact-the-Hungarian-labour-market.pdf> (letöltve: 2022.07.20.)

Szerző ismeretlen (2020): Mi az MI / What is AI?

<https://www.youtube.com/watch?v=81IakZh-2VQ>

Szerző ismeretlen (2023): Technomatix Plant Simulation

<https://plm.sw.siemens.com/en-US/tecnomatix/products/plant-simulation-software/>

Szerző ismeretlen (2023): What is Power BI?

<https://intellipaat.com/blog/power-bi-dashboard/>

Szerző ismeretlen (2023): 15 Projects on Machine Learning Applications in Finance

<https://www.projectpro.io/article/projects-on-machine-learning-applications-in-finance/510>

Szerző ismeretlen (2023): TOP 10 ARTIFICIAL INTELLIGENCE (AI) COMPANIES IN HUNGARY

<https://themanifest.com/hu/artificial-intelligence/companies> (Megtekintés időpontja: 2023.03.25.)

Dr. Szűcs Gábor (2020): A mesterséges intelligencia és a mély tanulás. Budapesti Műszaki és Gazdasági Egyetem <https://www.youtube.com/watch?v=h67h1kPDN90>

Szűcs Imre (2006): ADATBÁNYÁSZATI MÓDSZEREK ALKALMAZÁSA A PÉNZÜGYI SEKTORBAN <https://doksi.net/hu/get.php?lid=18475> (letöltve:2022.03.21.)

Dr. Tóth László (2019): Mesterséges intelligencia, gépi tanulás, mély tanulás. SZTE TTIK Informatikai Intézet https://www.youtube.com/watch?v=r7hBeiwH_ic

Varga Richárd (2022): Power BI bevezetés / Adatok betöltése és átalakítása <https://www.youtube.com/watch?v=ixLHCzJfbYQ>

17 ÁBRÁK JEGYZÉKE

1. ábra - A mesterséges intelligencia részei.....	13
2. ábra - MI-t használó vállalkozások aránya az EU-ban és egyes országokban	18
3. ábra - Az egyes foglalkozási területek várható MI érintettsége	25
4. ábra - Karbantartási módszerek típusai	32
5. ábra - A termelés és leállítás gyakorisága és hossza az idő függvényében karbantartási módszerekenként.....	33
6. ábra - Azure ML modell.....	36
7. ábra - Konfúziós mátrix esettípusok.....	38
8. ábra - A Multiclass Neural Network algoritmushoz tartozó hiperparaméterek és eredmények	40
9. ábra - A Neural Network algoritmushoz tartozó konfúziós mátrix.....	40
10. ábra - A Logistic Regression algoritmushoz tartozó hiperparaméterek és eredmények	41
11. ábra - A Logistic Regression algoritmushoz tartozó konfúziós mátrix.....	41
12. ábra - A Decision Forest algoritmushoz tartozó hiperparaméterek és eredmények.....	41
13. ábra - A Decision Forest algoritmushoz tartozó konfúziós mátrix	42
14. ábra - A Decision Jungle algoritmushoz tartozó hiperparaméterek és eredmények	42
15. ábra - A Decision Jungle algoritmushoz tartozó konfúziós mátrix	43
16. ábra - A Neural Network algoritmushoz tartozó konfúziós mátrix.....	43
17. ábra - A Neural Network algoritmushoz tartozó konfúziós mátrix számokkal.....	44
19. ábra - Plant Simulation felhasználási lehetőségei	48
20. ábra - Szimulációs labor digitális ikerpárja.....	48
21. ábra - Termelés teljes időtartama	51
22. ábra –A termékek az egyes munkaállomásokon eltöltött ideje és a leolvasás státusza.....	51
23. ábra - Első típusú hibaüzenetre példa.....	53
24. ábra - Második típusú hibaüzenetre példa.....	54
25. ábra - Harmadik típusú hibaüzenetre példa.....	54
26. ábra - SAP könyvelés kivonat	55
27. ábra - Könyvelési pontok aktivitása	55
28. ábra - Termelési sor aktivitása	56
29. ábra - Termelési ciklusok hossza	56
30. ábra – Az első termelési kör során észlelt RFID jelzések között eltelt időtartamok.....	57
31. ábra - A második termelési kör során észlelt RFID jelzések között eltelt időtartamok	58

32. ábra - A harmadik termelési kör során észlelt RFID jelzések között eltelt időtartamok....	58
33. ábra - Az első termelési kör során a termékek munkaállomások közt megtett útjuknak időtartama.....	59
34. ábra - RFID azonosítók leolvasásai közt eltelt időtartamok	61
35. ábra - Munkaállomások leterheltsége az az első gyártási periódus alatt.....	61
36. ábra - Az egyes RFID olvasók felett áthaladó termékek száma.....	62
37. ábra - Melyik évben született ?	64
38. ábra - Hallott már mesterséges intelligenciáról ?.....	64
39. ábra - Ön szerint fenyegetést jelent-e a mesterséges intelligencia az emberekre ?.....	66
40. ábra - Ha egy MI hibát követ el, Ön szerint kié a felelősség ?.....	67
41. ábra - Van jövője az emberiségnek MI nélkül ?.....	67
42. ábra - Szívesen látna mesterséges intelligenciával rendelkező robotokat az otthonában ?	68
43. ábra - Ön szerint baj, hogy a mesterséges intelligenciát használó robotokkal helyettesítik az emberi munkaerőt a cégek ?.....	69
44. ábra - Az MI fenyegetésként értékelése életkor szerinti megoszlásban.....	71
45. ábra - Veszélyérzet a működési felelős szerint bontásban	72
46. ábra - Az MI otthoni elfogadottsága a jövőkép szerinti bontásban.....	73
47. ábra - A munkahelyek féltésének aránya a jövőkép szerinti bontásban.....	74

NYILATKOZAT

Alulírott CHRABÁK ATTILA büntetőjogi felelősségem tudatában nyilatkozom, hogy a szakdolgozatomban foglalt tények és adatok a valóságnak megfelelnek, és az abban leírtak a saját, önálló munkám eredményei.

A szakdolgozatban felhasznált adatokat a szerzői jogvédelem figyelembevételével alkalmaztam.

Ezen szakdolgozat semmilyen része nem került felhasználásra korábban oktatási intézmény más képzésén diplomaszerzés során.

Tudomásul veszem, hogy a szakdolgozatomat az intézmény plágiumellenőrzésnek veti alá.

Budapest, 2023. év 04. hónap 29. nap

Nyilatkozat a szakdolgozat státuszáról (nyilvános, bizalmas)

Alulírott CHRABÁK ATTILA (Neptun kód: AP12U5) a Mesterséges intelligencia és termelés optimalizálás című szakdolgozattal/zárodolgozattal (továbbiakban mű) kapcsolatban az alábbiakról nyilatkozom:

- Kijelentem, hogy a mű BGE Dolgozattár repozitóriumába való feltöltésével más jogát nem sértem. Tudomással bírok arról, hogy az Egyetem a szerzői jogok meglétét nem ellenőrzi.
- Nyilatkozom, hogy a mű *(a megfelelő rész aláhúzendó)*
 - a bizalmas
 - a nyilvánosság számára hozzáférhető.
- Tudomásul veszem, hogy
 - szerzői jogsértés esetén az Egyetem az érintett dokumentum elérhetőségét a szerzői jogsértés tisztázása idejére átmenetileg korlátozza,
 - szerzői jogsértés esetén az érintett művet a Repozitórium adminisztrátora a Repozitóriumból haladéktalanul eltávolítja,
 - amennyiben a dolgozatomat a nyilvánosság számára hozzáférhetővé teszem, az egyetem a dolgozatomat az interneten a nyilvánosság számára hozzáférhetővé teszi. Hozzájárulásom – szerzői jogaim maradéktalan tiszteletben tartása mellett – nem kizárólagos és időtartamra nem korlátozott felhasználási engedély.

Kelt: Budapest, 2023.04.29.