

Gépi tanulás lehetőségei a marketingkutatásban

The possibilities of machine learning in marketing research

PÁL BERTOLD CSABA

hallgató, Budapesti Műszaki és Gazdaságtudományi Egyetem, Gazdaság- és Társadalomtudományi Kar,
pal.bertold@edu.bme.hu

IVÁNYI TAMÁS

adjunktus, Budapesti Műszaki és Gazdaságtudományi Egyetem, Gazdaság- és Társadalomtudományi Kar,
ivanyi.tamas@gtk.bme.hu

Absztrakt

Az adattudomány és a mesterséges intelligencia (MI) olyan innovatív területek, amelyek az üzleti világban jelentős hatást gyakorolnak, többek között a marketing tudományában is. Az adattudomány a nagy adathalmazok elemzésével, értelmezésével és az adatok alapján történő predikcióval segíti a vállalkozásokat abban, hogy megértsék a piacot és a fogyasztói viselkedést, valamint személyre szabott tartalmat nyújtsanak.

A tanulmány célja, hogy rövid áttekintést nyújtson a gépi tanulás lehetőségeiről és a marketingkutatásban betöltött szerepéről. A felügyelt tanulási modellek (klasszifikációs és regressziós modellek) segítségével például előre jelezhető, mely ügyfelek hagyják el a szolgáltatást, a nem felügyelt tanulás (klaszterezés, anomália detekció) pedig segít azonosítani a rejtett mintákat és trendeket, hogy a vállalatok jobban megérthessék a fogyasztóikat, és pontosabban szegmentálhassák őket. A megfelelő modell és a kapcsolódó paraméterek kiválasztása pedig kritikus szerepet játszik a sikeres MI-alapú marketingstratégiában.

Kulcsszavak: mesterséges intelligencia, marketingkutatás, modellezés

Köszönetnyilvánítás: A Kulturális és Innovációs Minisztérium ÚNKP-23-1-I-BME-105 kódszámú Új Nemzeti Kiválóság Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült.



Abstract

Data science and artificial intelligence (AI) are innovative fields that significantly impact the business world, especially marketing. Data science aids businesses in understanding the market and consumer behaviour by analysing and interpreting large datasets, and making predictions based on the data, enabling them to offer personalized content.

The study aims to provide a brief overview of the opportunities presented by machine learning and its role in marketing research. Supervised learning models (classification and regression models), for example, can help predict which customers will leave the service, while unsupervised learning (clustering and anomaly detection) helps identify hidden patterns and trends, enabling companies to better understand their consumers and segment them more accurately. Choosing the right model and associated parameters plays a critical role in a successful AI-based marketing strategy.

Keywords: artificial intelligence, marketing research, modelling

Acknowledgments: Supported by the ÚNKP-23-1-I-BME-105 New National Excellence Program of the Ministry for Culture and Innovation from the source of the National Research, Development, and Innovation Fund.

A tanulmány hivatkozása:

Pál Bertold Csaba, Iványi Tamás (2024), Gépi tanulás lehetőségei a marketingkutatásban. In: Szűcs K. - Putzer P. (szerk.), A (marketing) világ megkettőződése. Egyesület a Marketing Oktatásért és Kutatásért XXX. Nemzetközi Konferenciájának Absztrakt- és Tanulmánykötete. Pécsi Tudományegyetem Közgazdaságtudományi Kar, Pécs. 112-118. o. ISBN: 978-963-626-318-8, <https://doi.org/10.62561/EMOK-2024-10>

1. Bevezetés

Az adattudomány egy új tudományterület, ami a nagy méretű adathalmazok elemzésével, értelmezésével próbál reflektálni a jelenlegi állapotra, felfedez anomáliákat, próbál fényt deríteni összefüggésekre, komplex rendszereket modellez, és predikciót alkot jövőbeli eseményekről. Ezeket a folyamatokat akár valós időben is képes elvégezni, így gazdagítva a fogyasztói élményt azzal, hogy a vásárló számára releváns tartalmat tud nyújtani. Bár az adattudomány a menedzsment és az üzleti tudományok számos területén megjelenik, sőt a többi tudományterületen is kiemelt helyet kapott az utóbbi évek kutatásaiban, a marketing és a marketingkutatás terén is egyre erőteljesebben jelen van és számos új eszközzel még pontosabbá tudja tenni a feltételezéseink igazolását, valamint a döntéseink alátámasztását (PASCUCCI et al., 2023).

Az IoT eszközöknek köszönhetően és az online végzett tevékenységeik során a felhasználók hatalmas mennyiségű adatot állítanak elő, amelyet a vállalatok összegyűjthetnek és elemezhetnek (BZAI et al., 2022). Ezek az adatok magukban foglalják a fogyasztói preferenciákat, a vásárlási mintákat, a böngészési viselkedést és az online interakciókat. A big data technológiák lehetővé teszik az adatok strukturálását és gyors, könnyen kezelhető gyűjtését, valamint erős alapot nyújthatnak a megfelelő üzleti döntések meghozatalában. A nagy adathalmazok elemzésével a vállalkozások hatékonyabban tudják személyre szabni kampányaikat, egyedi ajánlatokat nyújthatnak, pontosabban megérthetik a fogyasztói igényeket, a viselkedés során tapasztalható lépések sorozatát, illetve az MI alapú algoritmusok megtanulhatják a különböző fogyasztói cselekvésekhez kapcsolódó mintákat, és előrejelzéseket készíthetnek az ügyfelek preferenciái és a piaci trendek alapján (OKORIE et al., 2024).

A tanulmány feltáró szekunder kutatás segítségével arra vállalkozik, hogy röviden bemutassa a gépi tanulás algoritmusainak működését, amelyek számos mesterséges intelligencia alkalmazás alapját képezik, valamint rámutasson a marketingkutatásra vonatkozó kapcsolódási pontokra. A folyamat és a legfontosabb kategóriák leírása mellett törekszünk arra is, hogy rávilágítsunk arra, hogy bizonyos változtatások (paraméterek, algoritmusok, adatbázis kialakítások, tanulási folyamatok lépéseinek cserélése) milyen hatással tudnak lenni a marketingkutatás során kapott eredményekre és azok értelmezhetőségére. Tanulmányuknak nem célja, hogy szisztematikusan elemezzük a szakirodalmat, inkább vitaindító, figyelemfelkeltő szerepet szánunk neki, amely reméljük, hogy a kvantitatív kutatási módszerekben kevésbé jártas kutatók számára is rávilágít a jelenleg egyre népszerűbbé váló lehetőségek fontosságára.

2. Mesterséges intelligencia lehetőségei a marketingben


A mesterséges intelligencia (MI) segítségével a vállalatok hatékonyabban tudják megcélozni a fogyasztókat, személyre szabott tartalmat és ajánlatokat biztosíthatnak, valamint automatizálhatják a marketing folyamatokat (HALEEM et al., 2022). Az MI által vezérelt chatbotok és virtuális asszisztensek interaktív ügyfélszolgálatot biztosítanak, míg a gépi tanuláson alapuló elemzés segít megérteni az ügyfelek visszajelzéseit és javítani a felhasználói élményt. Az optimális felhasználó élmény szükségessége tagadhatatlan a digitális térben, hiszen a fogyasztó egy új módon jelenik meg, egy úgynevezett mesterséges profilt, személyiséget hoz létre önmagáról és sokkal jobban képes szabályozni a körülötte megjelenő digitális világot (PÜTTER, 2017). Az új fogyasztót elérni azonban jelentősen nehezebb a vállalatok számára, mivel a digitális térben hatalmas a zaj és nagyon sok az impulzus, ezért is szükségesek az olyan megoldások, amelyek jó hatékonysággal képesek az egyén preferenciájára formálni az élményt. Ugyanakkor meg kell említeni a big data és a mesterséges intelligencia alkalmazásából adódó adatvédelmi és etikai kérdéseket is. A megfelelő adatvédelmi szabályzat betartása és az etikus adathasználat biztosítása a fogyasztói bizalom és a hosszú távú siker kulcsa (MITROU, 2018).

HUANG és RUST (2021) definiálása szerint a mesterséges intelligencia egy nem emberi gépezet, amely képes arra, hogy olyan folyamatokat végezzen el, amelyhez emberi intelligenciára lenne szükség, illetve, ha ember végezné el azt, akkor azt a személyt intelligensnek neveznénk. Ez megvalósulhat előre programozva is, vagy olyan algoritmusokkal is, amelyek az intelligens viselkedést minták megfigyelésével „tanulják meg” és utána az újabb beérkező információkat a megtanult mintákhoz hasonlítják. Ezutóbbi esetben úgynevezett gépi tanulásról (machine learning) tudunk beszélni (MA – SUN, 2020). A továbbiakban ennek a különböző algoritmusait és beállításait fogjuk röviden áttekinteni, összekapcsolva a marketingkutatási vonatkozásaikkal.

3. Gépi tanulási és a marketingkutatás kapcsolata

WICKHAM és társai (2023) az 1. ábrán is látható módon helyezik el a gépi tanulást, mint modellezést a MALHOTRA és SIMON (2017) által leírt primer kutatási folyamatba: az adatok összegyűjtése és adattisztítás után az eredmények közzléséig egy hosszabb adatfeldolgozási folyamat következik. Ez klasszikusan leíró jellegű,

1. ábra: A gépi tanulás, mint modellezés helye a marketingkutatásban.



Forrás: WICKHAM et al. (2023) alapján saját szerkesztés

vagy többváltozós összefüggésvizsgálatot jelent. Ez egészül ki egy modellezéssel, amely körkörösé is teszi a folyamatot, ugyanis a modellezésnél számos paramétert szükséges vizsgálni, a változók összetételén kell adott helyzetben változtatni, így többször is szükséges elvégezni ugyanazokat a lépéseket és a kapott eredmények alapján finom hangolni az elkészült modellt a pontosabb végső eredmények eléréséhez.

A különböző gépi tanulási (az 1. ábrán modellezési) eszközöket számos csoportba tudjuk sorolni a működési elvük és a megvalósítandó cél alapján is. A tanulási stratégia szempontjából a gépi tanuláson belül elkülöníthetünk tradicionális gépi tanulási megoldásokat, illetve mély tanulási megoldásokat.

3.1 Tanulási stratégia szerinti csoportosítás

Tradicionális gépi tanulás: A tradicionális gépi tanulási problémák legtöbbször egyszerűbb algoritmusokat használnak és akkor lehetnek optimálisak, ha nagy hangsúlyt akarunk helyezni a modell értelmezhetőségére. Ez jelentősen közelebb hozza a tradicionális gépi tanulási megoldásokat a klasszikus marketingkutatás elgondolásaihoz, ahol a célunk a probléma, a jelenség jobb megértése és leírása (MALHOTRA – SIMON, 2017). Ezek az algoritmusok sok esetben strukturált adatbázist használnak (MA – SUN, 2020), amely azt jelenti, hogy a klasszikus adatgyűjtési megoldásokat (például a kérdőíves megkérdezést) jól kombinálhatjuk egy gépi tanulási adatfeldolgozással.

Mély tanulás (deep learning): A mély tanulás a gépi tanuláshoz egy alcsoporthoz tartozik, amely lehetővé teszi, hogy komplex strukturálatlan adatokat is tudjunk értelmezni, ezt a feladatot az úgynevezett neurális hálókat segítségével próbálja megoldani (VARGAS et al., 2017). A neurális hálókat az emberi agy működését imitálják és így olyan komplex feladatokat tud látni egy számítógép, mint a nyelvi feldolgozás vagy a digitális látás (computer vision).

Mély tanulással megvalósítható például a:

1. Képfelismerés: Arc és objektum beazonosítása.
2. Hangfeldolgozás: Beszédfelismerés.
3. Nyelvfeldolgozás: Automatikus fordítás, szöveg generálás, nyelvi értelmezés, beszélgetés.

A mély tanulás akkor lehet optimális, ha nagy mennyiségű adat áll rendelkezésre. Mivel az adat sok esetben strukturálatlan így a fókusz, inkább arra irányul, hogy a modellünk minél pontosabb predikciót alkosson. Itt az adatokból kevésbé lehetséges leíró statisztikai elemzéseket készíteni és kevésbé a mértékre adhatunk válaszokat. A mély tanulási módok sokkal komplexebbek és interpretálásuk sokkal nehezebb, mint a tradicionális gépi tanulási modelleknek, azonban pontosságuk jelentősen jobb lehet megfelelő mennyiségű adat és számítási kapacitás mellett (TAYE, 2023).

Tulajdonképpen a mély tanulási folyamatok feketedobozként értelmezhetők, ezért a marketingkutatásban nehezebben használhatóak, ezek inkább a fogyasztói élmény fokozására alkalmas funkciók alapjai tudnak lenni. Például a képfelismerés vagy a hangfeldolgozás beépíthető a termékekbe, így hozhatnak létre hangvezérlést alkalmazásokat vagy kiterjesztett valóságot (ZHU-WU, 2020).

Összefoglalva tehát a gépi tanulási megoldások közül elsősorban a tradicionális verziók azok, amelyek a modern marketingkutató eszköztárának a részeivé tudnak válni.

3.2 Tanulási feladat szerinti csoportosítás

Egy másik csoportosítás az algoritmusok által ellátott tanulási feladat alapján képezhető, tehát itt azt vizsgáljuk, hogy a tanulási eljárás milyen output információt fog számunkra adni, hogyan próbálja az adatokat transzformálni az inputként megadott adatbázisból, milyen modellt állít fel eredményként az algoritmus.

Ezen csoportosítás alapján háromféle algoritmust lehet beazonosítani:

A felügyelt tanulás (supervised learning) során a bementeként adott adatbázis tartalmazza a kimeneti ele-

meket is, és a modellezés célja, hogy olyan modell készüljön el, amely a bementi változókat a lehető legjobban kombinálja össze ahhoz, hogy a kimenetként megjelölt változót megkaphassuk (MUMUNI-MUMUNI, 2022). Ezen algoritmusoknál a legtöbb esetben előállítunk egy tanító és egy tesztelő adathalmazt, hogy képesek legyünk elfogulatlanul kiértékelni a modell teljesítményét. Két fő fajtája van, amely alapvetően azon alapul, hogy a célváltozó diszkrétnek (klasszifikáció) vagy folytonosnak (regresszió) tekinthető.

- *Klasszifikációs algoritmusok:* A klasszifikációs modellek az input adatok alapján segítenek nekünk megbecsülni egy diszkrét változót (kategóriát). Ilyen klasszifikációs modellt igényel, például a marketingkutatásban a lemorzsolódás (churn) modellezés, ami alapján az a célunk, hogy megjósoljuk, vajon egy fogyasztó tovább fogja-e használni szolgáltatásunk, vagy elpártol tőlünk. Itt célunk azoknak a fogyasztóknak a beazonosítása predikción keresztül, akiknél nagy a valószínűsége, hogy le fognak morzsolódni. Vannak olyan klasszifikációs modellek is, amelyek (az előző binomiális besorolással szemben) képesek több osztályba is sorolni, tehát a célváltozó több, mint kettő értéket is felvehet. Ezeket multinomiális klasszifikációknak hívjuk. Egy tipikus több osztályos besorolás például, amikor új vásárlókat szeretnénk a meglévő klaszterekhez hozzárendelni és ennek az algoritmusát szeretnénk modellezni. (MA – SUN, 2020)

- *Regressziós algoritmusok:* A regresszió gyakran használt technika, amelynek segítségével egy folytonos célváltozó értékének előrejelzése történik egy input kombináció alapján. Ennél a módszernél tulajdonképpen az történik a gépi tanulási modellezésnél, amit például SAJTOS és MITEV (2007) is bemutat a lineáris regresszió esetében. A folyamat során egy olyan egyenes vagy felület illesztése történik, amely minimalizálja az előrejelzett és a tényleges kimeneti értékek közötti különbségeket, például az egyszerű lineáris regressziós kalkulátorok a „legkisebb négyzetek” módszerét alkalmazzák a legjobban illeszkedő vonal vagy felület meghatározásához (IBM, 2023a). Egy tipikus regressziós feladat az ügyfél-életciklus érték (CLV) meghatározása, ahol az a célunk, hogy egy bizonyos aktivitási időszak után előre jelezzük a vevő által jövőben generált pénzáramokat vagy akár a vevői hűség alakulását.

Felmerülhet a kérdés, hogy miben térnek el ezek egy hagyományos többváltozós vizsgálatától, amelyre például KUHN és SILGE (2022) adják meg a választ: a hagyományos esetben, ahol nem gépi tanulással dolgozunk, ott a kapott modellt a modell illeszkedésével vizsgáljuk, vagyis arra keressük a választ, hogy sokaságot reprezentáló minta adataihoz az elkészült modell mennyire illeszkedik. A gépi tanulás ezzel szemben azt (is) vizsgálja, hogy a modell újabb adatok bevonásával is hasonlóan jól fog-e tudni teljesíteni és nem célja, hogy a modell a lehető legtökéletesebben fedje a minta adatait, hanem arra fókuszál, hogy az új adatokat és a meglévőket is jó aránnyal modellezze. Emiatt a gépi tanulás esetében más mérőszámokat és ellenőrzéseket alkalmazunk, ilyen például a konfúziós mátrix és az abban található értékekből képzett hányadosok (FLACH, 2019).

A felügyelt tanulás mellett egy másik gyakori gépi tanulási módszer a felügyelet nélküli tanulás (unsupervised learning). Ennek a lényege, hogy címkézetlen (tehát célváltozó nélküli) adathalmazon végezzünk mintakereső műveleteket (IBM, 2023b), tehát itt rejtett, általunk eddig még nem definiált mintákat próbál megkeresni az algoritmus.

- *Klaszterezés:* A klaszterezés egy tipikus nem felügyelt tanulási feladat, amely során homogénnek tekinthető csoportokba szeretnénk besorolni az adatbázisban található mintaelemeket (BODON, 2006), tehát eddig nem létező csoportokat szeretnénk alkotni, rejtett mintát szeretnénk keresni. A klaszterezési eljárásokat három csoportba lehet sorolni: vannak a hierarchikus módszerek, a nem hierarchikus módszerek, és az egyéb módszerek, ide tartozik például a 2 lépcsős klaszterezés (MALHOTRA-SIMON, 2017). Ezek a rejtett minták a későbbiekben segíthetnek abban, hogy gépi tanulás segítségével az újabb adatpontokat is be tudjuk sorolni a már meglévő csoportokba, valamint a többváltozós vizsgálatoknál a varianciaanalízis független változóit adhatják.

- *Anomália detektálás:* Az anomália detektálás során megpróbáljuk kiszűrni azokat a jelenségeket, értékeket, amik eltérnek a megszokottól. Ezek tulajdonképpen olyan gépi tanulási módszerek, amelyek a hagyományos marketingkutatásban az outlierek megtalálást segíthetik. A vevőérték növelését vizsgálva pedig ide sorolható az, amikor megpróbáljuk kiszűrni a gyanús bankkártyás tranzakciókat (HILAL et al., 2022).

- *Asszociációs feladatok:* Asszociáció keresés során a cél az, hogy megtaláljuk azokat a mintákat, amik együtt járnak, például mik azok a termékek, amelyeket együtt fogyasztanak, vagy mely termékek illenek a fogyasztó jelenlegi viselkedéséhez (KURNIA et al., 2019). Az ilyen asszociációs feladatok egy jellegzetes marketingkutatási formája a dimenziószám csökkentése, vagyis annak a vizsgálata, hogy a különböző változók együtt járását (mint a termékek együttes vásárlását) próbáljuk megtalálni. Ezt a célt szolgálja a faktoranalízis, a főkomponens-analízis (SAJTOS – MITEV, 2007).

4. A gépi tanulás modellépítésének hatása a marketingkutatásra

Gépi tanulást körülölelő döntési folyamat az üzleti életben lényegében három fő lépésből áll, az üzleti problémából, az üzleti lehetőség felismeréséből a megfogalmazódott helyzetben, és maga a tetteges akcióból, amit a vállalat produkál az előző két pont ismeretében (WAMBA-TAGUIMDJE et al., 2020). Ennek implementálásában a mesterséges intelligencia szükségleteinek piramisa segít (COOLS, 2021). A piramis a Maslow-féle szükséglet piramis alapján épül fel, ahol a felsőbb szintek (modell építés, implementálás) nem tudnak megjelenni anélkül, hogy az alsóbb szintek (adatgyűjtés, adatformázás, -átalakítás, elemzés) maximálisan el lennének végezve (erre utal a korábban bemutatott 1. ábra is), tehát a vállalat csak úgy tud mesterséges intelligenciát (pontosabban gépi tanulási modellezést) alkalmazni effektíven, ha egymás után követi a szinteket és mindegyiket teljesíti is.

A korábban bemutatott feladatok esetében elmondható, hogy mindegyikhez többféle algoritmus is elérhető (például a klasszifikáció esetében ismert algoritmusok a véletlen erdő, a döntési fa, valamint a logisztikus regressziós modell is). Az adott feladatra a megfelelő algoritmus kiválasztása és annak optimalizálása egy nagyon kritikus pontja a modell építésnek és a szükségletpiramisnak is. Ez a fázis legtöbbször „trial and error” módon működik, nincs egy bevált lépéssor vagy recept, ami minden esetben működik. A modellválasztás számos tényezőtől függ, ilyen lehet például a modell értelmezhetőségének a kérdése, a rendelkezésre álló adatmennyiség, az elérhető számítási kapacitás, vagy a kutató ismeretei a modelleket illetően (BREI, 2020).

Ezek a tényezők erősen befolyásolják és alakítják a modellépítési és -alkotási procedúrát, így jelentős korlátok tudnak lenni, különösen a KKV-k számára, ugyanis jelenleg a gépi tanulás egy erősen erőforrás intenzív terület (ESTENSORO et al., 2022).

A modellépítés fázisban akár több különféle algoritmust is összehasonlítunk a teljesítményük szempontjából, vagy akár ugyanazon algoritmusokat különböző paraméter és tényező összetétel mellett is összeállíthatunk. Óvatos és szakértő finomhangolást igényel ezen esetekben az, hogy a modellalkotás során milyen bemeneti változókat és az algoritmusoknak milyen működési paramétereket (úgynevezett hiperparamétereket) adunk meg (NEMATZADEH, et al., 2022). A folyamat ezen részében tulajdonképpen az 1. ábrán bemutatott körkörös szakaszában több párhuzamos kör indul el, amely során különböző modellösszeállítást ellenőrzünk, a nem megfelelőeket elhagyjuk és a megmaradt modelleket finomhangoljuk, hogy a végső modellt megtaláljuk (KUHN – SILGE, 2022).

A tanulási folyamat során az egyik legkritikusabb kérdés az overfitting esete, amikor a modell túl jól „memorizálja” a tanuló adathalmaz pontjait, így a későbbiekben nem képes általánosítani új adathalmazon. Ennek ellentéte is előfordulhat: az underfitting esetében a modell nem képes megragadni az adatok közötti kapcsolatokat, mivel nem lesz elég komplex ahhoz, hogy a későbbiekben új adatokon jó predikciókat képezzen (KOLLURI et al., 2022).

Bár a folyamat sok lépésből áll, két fontos elemet ki lehet ezek közül emelni:

- *Tényező / változó összetétel kiválasztása (feature selection):* A mai marketingkörnyezet rendkívül komplex, számos elemet lehet vizsgálni, rengeteg befolyásoló tényezővel találkozhatunk és a fogyasztót nagy mennyiségben érik a marketing impulzusok (DWIVEDI et al., 2021). A modellezés során ezért is kap nagy hangsúlyt a megfelelő változóösszetétel megtalálása, ami által a cél az, hogy egy olyan modellt tudjunk építeni, amely úgy is képes prediktálni az új adathalmazon, hogy megfelelően kevés változóval dolgozzunk csak a tanítás során. A változósám csökkentése segíti a modell interpretálhatóságát is.

Fontos itt megemlíteni, hogy különböző algoritmusok más és más stratégiát igényelhetnek (SURUCU, et al., 2023). Mély tanulás esetében kevésbé szükséges az előzetes tényező szelekció, hiszen ott az algoritmus maga oldja meg ezt a feladatot. Ezzel szemben a tradicionális gépi tanulási megoldások sok esetben manuális tényező szelektálást kívánnak, ami időigényes, illetve magas szakértői tudásra is szükség lehet. Azonban a kulcsfontosságú adatok, változók kiemelésével a kutatók mélyebben megérthetik azokat az elemeket, amelyek jelentős hatást gyakorolnak a folyamatra, például a vásárlási döntések során.

- *Hiperparaméterek optimalizálása:* A hiperparaméterek a modell tanítási folyamatát szabályozzák, legtöbbször megfelelő tényező (változó) összetétel mellett, ha ezeket az értékeket finom hangoljuk, akkor egy pontosabb modellt tudunk létrehozni, ami jobban képes prediktálni ezáltal pontosabb képet is ad a kutatási probléma megértéséhez. (KUHN – SILGE, 2022)

5. Összefoglalás

Tanulmányunkban szekunder kutatás segítségével körüljártuk a legfontosabb kérdéseket, amelyek a mesterséges intelligencia, a gépi tanulás és a marketingkutatás kapcsolatát érintik.

Az MI a marketing szinte minden területén megjelent az elmúlt években, ezáltal a marketingkutatásban is egyre erőteljesebb hangsúlyt kap. Az MI lehet a marketingkutatás témája is, valamint az eszköze is. Jelen tanulmányban mi kifejezetten a gépi tanulást vizsgáltuk, amely algoritmusokat és adatelemző eszközöket ad a kutató kezébe és segíti a modellalkotás lépését az adatelemzési folyamatnak.

Láthattuk, hogy a mélytanulás inkább a predikciókra fókuszál, azonban a tradicionális gépi tanulás az egyszerűbb algoritmusaival jó kiegészítője lehet a leíró statisztikai lépéseknek és a marketingkutatás adatelemzési fázisát magasabb szintre tudja emelni. Arra is felhívtuk a figyelmet, hogy a bemutatott módszerek között számos olyan van, amelyek a hagyományos marketingkutatás többváltozós elemzéseinek is a részei, azonban a gépi tanulás esetében megváltozik az algoritmusok mögött álló filozófia, ezáltal a modellalkotás optimalizálása is. A gépi tanulás lényege a minták keresésén túl a predikció is, tehát nem az adatbázis nyújtotta mintát akarjuk feltétlenül lefedni és azzal a sokaságot jellemezni, hanem olyan modellt szeretnénk kialakítani, amely újabb adatok estében is jól leírja és ezáltal jól jövendöli meg egyes változók várható értékeit vagy bizonyos változók értékei közötti kapcsolódásokat.

A gépi tanulás algoritmusainak tanulási stratégia szerinti csoportosítása megfelelő keretrendszer tud biztosítani arra, hogy milyen architektúrát lehet választani bizonyos feladatokhoz, az adott erőforrások viszonyában. A tanulási feladat szerinti csoportosítás segít abban, hogy esetleges feladatokhoz milyen típusú algoritmusok alkalmazhatóak.

Tanulmányunkban továbbá rávilágítottunk arra is, hogy a számos eszköz használata komoly szakértelmet igényel. A modellezésnek több buktatójával is találkozhatunk (például az említett overfitting és underfitting) és sok esetben többszöri kísérletezési fázis után kaphatunk csak a marketingkutatási céloknak megfelelő modelleket.

Irodalomjegyzék

- Bodon, F. (2006), Adatbányászati algoritmusok. Budapesti Műszaki és Gazdaságtudományi Egyetem. Elérhető: <https://www.cs.bme.hu/~bodon/magyar/adatbanyaszat/tanulmany/adatbanyaszat.pdf> (hozzáférés: 2024.05.07)
- Brei, V.A. (2020), Machine learning in marketing: Overview, learning strategies, applications, and future developments. *Foundations and Trends® in Marketing*, 14(3), 173-236. <http://dx.doi.org/10.1561/17000000065>
- Bzai, J. – Alam, F. – Dhafer, A. – Bojović, M. – Altowajiri, S.M. – Niazi, I.K. – Mehmood, R. (2022), Machine learning-enabled internet of things (IoT): Data, applications, and industry perspective. *Electronics*, 11(17), 2676. <https://doi.org/10.3390/electronics11172676>
- Cools, W. (2021), The AI Pyramid of Needs. NannyML. Elérhető: <https://www.nannyml.com/blog/the-ai-pyramid-of-needs> (hozzáférés: 2024. 04. 30).
- Dwivedi, Y.K. – Ismagilova, E. – Hughes, D.L. – Carlson, J. – Filieri, R. – Jacobson, J. – Jain, V. – Karjaluoto, H. – Kefi, H. – Krishen, A.S. – Kumar, V. (2021), Setting the future of digital and social media marketing research: Perspectives and research propositions. *International Journal of Information Management*, 59, 102168. <https://doi.org/10.1016/j.ijinfomgt.2020.102168>
- Estensoro, M. – Larrea, M. – Müller, J.M. – Sisti, E. (2022), A resource-based view on SMEs regarding the transition to more sophisticated stages of Industry 4.0. *European Management Journal*, 40(5), 778-792. <https://doi.org/10.1016/j.emj.2021.10.001>
- Flach, P. (2019), Performance evaluation in machine learning: The good, the bad, the ugly, and the way forward. In *Proceedings of the AAAI Conference on Artificial Intelligence*, 33 (01), 9808-9814. <https://doi.org/10.1609/aaai.v33i01.33019808>
- Haleem, A. – Javaid, M. – Qadri, M.A. – Singh, R.P. – Suman, R. (2022), Artificial intelligence (AI) applications for marketing: A literature-based study. *International Journal of Intelligent Networks*, 3, 119-132. <https://doi.org/10.1016/j.ijin.2022.08.00>
- Hilal, W. – Gadsden, S.A. – Yawney, J. (2022), Financial fraud: a review of anomaly detection techniques and recent advances. *Expert Systems With Applications*, 193, 116429. <https://doi.org/10.1016/j.eswa.2021.116429>
- Huang, M. H. – Rust, R. T. (2021), A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*. 49 30–50. <https://doi.org/10.1007/s11747-020-00749-9>

- IBM (2023a), What is linear regression? Available at: <https://www.ibm.com/topics/linear-regression> (hozzáférve: 2023.04.21)
- IBM (2023b), What is unsupervised learning? Available at: <https://www.ibm.com/topics/unsupervised-learning> (hozzáférve: 2024.05.08)
- Kolluri, J. – Kotte, V.K. – Phridviraj, M.S.B. – Razia, S. (2020), Reducing overfitting problem in machine learning using novel L1/4 regularization method. In *2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)*(48184), 934-938. IEEE. <https://doi.org/10.1109/ICOEI48184.2020.9142992>
- Kuhn, M. – Silge, J. (2022), *Tidy modeling with R*. O'Reilly Media, Inc. elérhető: <https://www.tmw.org/> (hozzáférés: 2024.05.07)
- Kurnia, Y. – Isharianto, Y. – Giap, Y.C. – Hermawan, A. (2019), Study of application of data mining market basket analysis for knowing sales pattern (association of items) at the O! Fish restaurant using Apriori algorithm. *Journal of Physics: Conference Series*, 1175(1), 012047. IOP Publishing. <https://doi.org/10.1088/1742-6596/1175/1/012047>
- Ma, L. – Sun, B. (2020), Machine learning and AI in marketing – Connecting computing power to human insights. *International Journal of Research in Marketing*. 37 (3) 481–504. <https://doi.org/10.1016/j.ijresmar.2020.04.005>
- Malhotra, N. K. – Simon, J. (2017), *Marketingkutató*. Budapest: Akadémiai Kiadó. <https://doi.org/10.1556/9789630598675>
- Mitrou, L. (2018), Data protection, artificial intelligence and cognitive services: is the general data protection regulation (GDPR) „artificial intelligence-proof”? Artificial Intelligence and Cognitive Services: Is the General Data Protection Regulation (GDPR) „Artificial Intelligence-Proof”. <http://dx.doi.org/10.2139/ssrn.3386914>
- Mumuni, A. – Mumuni, F. (2022), Data augmentation: A comprehensive survey of modern approaches. *Array*, 16, 100258.
- Nematzadeh, S. – Kiani, F. – Torkamanian-Afshar, M. – Aydin, N. (2022), Tuning hyperparameters of machine learning algorithms and deep neural networks using metaheuristics: A bioinformatics study on biomedical and biological cases. *Computational Biology and Chemistry*, 97, 107619. <https://doi.org/10.1016/j.compbiolchem.2021.107619>
- Okorie, G.N. – Egieya, Z.E. – Ikwue, U. – Udeh, C.A. – Adaga, E.M. – Dara-Ojimba, O.D. – Oriekhoe, O.I. (2024), Leveraging Big Data for personalized marketing campaigns: A review. *International Journal of Management & Entrepreneurship Research*, 6(1), 216-242. <https://doi.org/10.51594/ijmer.v6i1.778>
- Parmentier, G. – Rolland, S. (2009), Consumers in virtual worlds: Identity building and consuming experience in Second Life. *Recherche et Applications en Marketing (English Edition)*, 24(3), 43-55. <https://doi.org/10.1177/205157070902400302>
- Pascucci, F. – Savelli, E. – Gistri, G. (2023), How digital technologies reshape marketing: evidence from a qualitative investigation. *Italian Journal of Marketing*, 2023(1), 27-58.
- Sajtos, L. – Mitev, A. (2007), *SPSS Kutatósi és adatelemzési kézikönyv*. Alinea Kiadó, Budapest.
- Surucu, O. – Gadsden, S.A. – Yawney, J. (2023), Condition monitoring using machine learning: A review of theory, applications, and recent advances. *Expert Systems with Applications*, 221, 119738. <https://doi.org/10.1016/j.eswa.2023.119738>
- Taye, M.M. (2023), Understanding of machine learning with deep learning: architectures, workflow, applications and future directions. *Computers*, 12(5), 91. <https://doi.org/10.3390/computers12050091>
- Vargas, R. – Mosavi, A. – Ruiz, R. (2017), Deep learning: a review. <https://doi.org/10.20944/preprints201810.0218.v1>
- Wamba-Taguimdje, S.L. – Wamba, S.F. – Kamdjoug, J.R.K. – Wanko, C.E.T. (2020), Influence of artificial intelligence (AI) on firm performance: the business value of AI-based transformation projects. *Business Process Management Journal*, 26(7), 1893-1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>
- Wickham, H. – Çetinkaya-Rundel, M. – Grolemund, G. (2023), *R for data science*. O'Reilly Media, Inc. Elérhető: <https://r4ds.hadley.nz/> (hozzáférés: 2024.05.07)
- Zhu, J. – Wu, D. (2020), Application of new artificial intelligence technology in the voice recognition and analysis system of electric power information customer service. In Proceedings of the 2020 International Conference on Computers, *Information Processing and Advanced Education*, 187-193. <https://doi.org/10.1145/3419635.3419686>