

# Dinamikus árazórendszerek kialakítása mesterséges intelligenciával egy webáruházban

DOI: [10.29180/978-615-6342-50-8\\_12](https://doi.org/10.29180/978-615-6342-50-8_12)

## SZERZŐK:

Kovács Endre<sup>1</sup>, Erdélyi Karalin<sup>2</sup>, Dobák Dóra<sup>3</sup>, Fauszt Tibor<sup>4</sup>

## ABSZTRAKT

Az online térben a vásárlók számára a legfontosabb döntést befolyásoló tényező a termék ára. Nem véletlen az árfigyelő rendszerek (Árkereső, Árgép) népszerűsége. A dinamikus árazási stratégia olyan modell, amely alkalmazkodik a piaci környezethez, és az árak is gyakran és könnyen változtathatók. Kutatásunk célja egy dinamikus árazási modell kidolgozása volt, amely a mesterséges intelligencia segítségével elvégzi egy webáruház napi árazását, figyelembe véve egyrészt a konkurensek árait, másrészt bizonyos termékadatokat, mint például a beszerzési árat és az eladott mennyiséget. A modellt a mesterséges intelligencia gépi tanuló algoritmusainak (LGBM, neurális hálózatok) a felhasználásával építettük ki, a tanuló és tesztadatokat egy létező webáruház biztosította. Az árazó modell kiértékelését többféle tesztcsoport összehasonlításával végeztük, az eredmény pedig annyira sikeres lett, hogy a webáruház a rendszert azóta is aktívan használja.

**Kulcsszavak:** mesterséges intelligencia, gépi tanulás, dinamikus árazás, rezervációs ár, neurális hálózat

## ABSTRACT

In the online space, the most critical decision factor for shoppers is the product's price. It is no coincidence that price tracking systems (Price Finder, Price Engine) are prevalent. A dynamic pricing strategy is a model that adapts to the market environment and can change prices frequently and quickly. The objective of our research was to develop a dynamic pricing model that uses artificial intelligence to perform daily pricing of an online store, taking into account, on the one hand, the prices of competitors and on the other hand certain product data such as purchase price and quantity sold. The model was built using artificial intelligence machine learning algorithms (LGBM, neural networks), with learning and test data provided by an existing webshop. The pricing model was

---

<sup>1</sup> Budapesti Gazdasági Egyetem, Pénzügyi és Számviteli Kar, Gazdaságinformatica Tanszék, ORCID: 0000-0001-6030-0716, e-mail: [kovacs.endre@uni-bge.hu](mailto:kovacs.endre@uni-bge.hu)

<sup>2</sup> Budapesti Gazdasági Egyetem, Pénzügyi és Számviteli Kar, ORCID: 0000-0001-5010-6688, e-mail: [erdelyi.katalin@uni-bge.hu](mailto:erdelyi.katalin@uni-bge.hu)

<sup>3</sup> Budapesti Gazdasági Egyetem, Pénzügyi és Számviteli Kar, Gazdaságinformatica Tanszék, ORCID: 0000-0002-0857-9999, e-mail: [dobak.dora@uni-bge.hu](mailto:dobak.dora@uni-bge.hu)

<sup>4</sup> Budapesti Gazdasági Egyetem, Pénzügyi és Számviteli Kar, Gazdaságinformatica Tanszék, ORCID: 0000-0003-3590-1100, e-mail: [fauszt.tibor@uni-bge.hu](mailto:fauszt.tibor@uni-bge.hu)

evaluated by comparing several sets of tests, and the results were so successful that online store still actively used the system.

**Keywords:** artificial intelligence, machine learning, dynamic pricing, reservation price, neural network

## **Bevezetés**

A kereskedelemben a vásárlók számára a legfontosabb döntést befolyásoló tényező a termék ára. Ez különösen érvényes az online kereskedelemre, ahol árfigyelő rendszerek (Árukereső, Árgép) segítik a vevőt az árak közötti tájékozódásban. Természetesen a vásárlást nemcsak a termék ára, hanem más tényezők is befolyásolják, mint például a kiszállítási idő vagy a visszavásárlási irányelvek elfogadhatósága. (Karlsson et al., 2005). Nyilvánvaló, hogy minden kereskedő álma az, hogy eltalálja azt az optimális árat, amely alapján a vásárló megveszi a terméket, a terméken pedig a kereskedő a lehető legnagyobb hasznot tudja realizálni. Mivel egyidejűleg két ellentétes irányú folyamat fejt ki hatását, hiszen a vevő vásárlási hajlandósága az alacsony árral növekszik, az eladó profitja pedig a magasabb árral, a termékárak optimumának meghatározása kulcsfontosságú feladat. Ennek a megtalálásában segíthet a mesterséges intelligencia.

## **A kutatás célja, kutatási kérdések**

Kutatásunk célja egy olyan dinamikus termékárzó rendszer kifejlesztése volt, amely automatikus módon, tetszőleges számú terméket képes, tetszőleges gyakorisággal, optimálisan beárzni. Munkánk során a következő kérdésekre kerestük a válaszokat:

- Lehetséges-e olyan dinamikus árazó rendszer létrehozása, amely képes egy webáruház árazási feladatait ellátni?
- Milyen adatok szükségesek egy ilyen árazórendszer kialakításához?
- Az automatizációhoz milyen mesterséges intelligencia algoritmusokat érdemes használni?
- Hogyan mérjük egy ilyen rendszer hatékonyságát?
- Integrálható-e egy ilyen rendszer a vállalat ügyviteli rendszerébe?

## **Statikus és dinamikus árazás a kereskedelemben**

A kereskedők a nagyobb profitot nem csak több termék eladásával vagy több vásárló bevonásával érhetik el, hanem egy jól átgondolt árazási stratégia alkalmazásával is. Az árképzés kivételesen jó lehetőség a cég hatékonyságának fokozására, a vállalat minden szintjére hatással van. A kereskedő cégek ezt a tényt gyakran figyelmen kívül hagyják, mivel az árképzés a marketing, az eladás és a termékreszlegek metszetén helyezkedik el. (Keno, 2018.). Az ár szempontjából azt tekintjük optimálisnak, aminek a megváltoztatása a profit csökkenésével jár egy bizonyos időintervallumon belül (Kovács, 2015).

Az árképzés egyik legegyszerűbb stratégiája a cost-plus árképzés, mely szerint a kereskedő meghatározza a termékek beszerzésére, előállítására és eladására vonatkozó egységköltséget, majd ezt megtoldja egy haszonkulccsal. Az egységköltség a direkt, indirekt és fix költségek összessége, a haszonkulcs pedig a vállalat stratégiája alapján meghatározott százalékos érték (Guilding et al., 2005). Ez alapvetően statikus árazás, hiszen a beszerzési ár és egyéb költségek időben nem gyakran változnak. Igazán statikussá a cost-plus árképzést az állandó haszonkulcs teszi. Ez általában kalkulált haszonkulcs, gyakran a tervezett bevétel, profit alapján számítják ki. Az így meghatározott árak is változhatnak, de általában olyan külső hatások, folyamatok miatt (pl. marketing kampány, kiadások), amelyek nem mindennaposak.

Az 1980-as évek végétől a termékek jellemzőinek egyéniesítése, testre szabási logikája figyelhető meg a gazdaságok szegmenseiben, és napjainkra a gazdaság meghatározó elvévé vált. Az „... egyénhez szabott árképzés az egyik formája annak a jelenségnek, amit manapság dinamikus árazásnak neveznek, szembeállítva azt a hagyományos, statikus árazással, azaz a rögzített árak rendszerével.” (Kocsis & Szabó, 2002. old.: 859). A dinamikus modellek „... rugalmasabban kezelik a változó piaci körülményeket, ezáltal hatékonyabb piacokat teremtenek, az eladók képesek növelni árukészletük értékesítéséből származó bevételeiket, gyorsítani a készletek forgási sebességét, és az értékesítési út lerövidítésével csökkenthetik a költséges közvetítőket, viszonteladók számát.” (Bodor, 2019, old.: 3)

### **Gépi tanulási modellek, neurális hálók a kereslet változásának követésére**

A dinamikus árazás kereslet-kínálat alapú. Olyan modellt kíván, amely alkalmazkodik az idő múlásával dinamikusan változó piacok keresleteihez, és az árak is gyakran és könnyen változtathatók (den Boer, 2015). Ha elég figyelmet fordítva optimalizáljuk az árazást, ez a cég növekedésének mozgató rugója lehet. Az árazási stratégiában megtalálható varianciának egyik legnagyobb faktora a versenytársak árazásért felelős döntése (Shankar & Bolton, 2004). Több tanulmány is foglalkozik a verseny beépítésével a dinamikus árazásba, de ez a feladat kihívás elé állítja a modellezőket, mert bár a versenytársak viselkedése jelentősen befolyásolja az üzlet optimális árazási stratégiáját, viselkedésüket viszont nem lehet előre megjósolni (Den Boer, 2015).

A kereslet gyakori változása kínálja a lehetőséget a mesterséges intelligencián alapuló gépi tanuló algoritmusoknak, hogy lekövezzék a változásokat és megtanulják, hogyan érdemes árazni. A szakirodalomban korábban már megjelentek előrejelzések arról, hogy a mesterséges intelligenciával támogatott hozammenedzselő rendszerek hogyan fogják átalakítani a piacot a következő évtizedekben. Az egyik első ilyen jellegű feljegyzés Phillips és társainak 2006-os szabadalma volt egy dinamikus árazó rendszerről (Phillips et al., 2006). Itt még ugyan nem használtak mesterséges intelligenciát, de csak idő kérdése volt. Napjainkban a gépi intelligenciával támogatott árfigyelés és árazás külön szolgáltatásként jelenik meg a piacokon. Magyarországon például az E-Manager és a PriceKit, külföldön pedig a PriceMole, mint szolgáltatók vannak jelen, hangsúlyozva marketingjükben az általuk létrehozott gépi tanulási algoritmusokat. Sajnálatos módon ezek a vállalkozások nem teszik közzé módszereiket.

A mi vizsgálati és elemzési módszerünk fő gerincét a Google Tensorflow neurális hálói és a Microsoft LightGBM gradiens turbózó eljárása képezi. Általánosságban a neurális hálók párhuzamos, elosztott információfeldolgozási struktúrák, egymással egyirányú kapcsolatban álló feldolgozóegységek

(neuronok) összessége (Szegedy et al., 2014). A neurális hálózat hagyományos matematikai értelemben nem kívánja lemodellezni a jelenségeket, azokra törvényszerűségeket kimondani, hanem a jelenségeket inkább fekete dobozként kezeli, azaz csak a bemenő és kimenő adatokat tekinti (Fazekas, 2013). Minden feldolgozóegységnek egy output portja van, amely tetszőlegesen sok input csatornával áll összeköttetésben (Hecht-Nielsen, 1992). A gradiens turbózás pedig egy viszonylag új gépi tanulási technológia regressziós és osztályozás feladatok megoldására, ami több együttműködő döntési fa segítségével számítja ki a végleges predikciókat. Ezt a módszert a szakirodalom együttes tanulásként említi (Diettrich, 2002). Az együttes tanuló módszerek a megválaszolni kívánt kérdést gyenge prediktorok csoportjának teszik fel, majd az általuk adott válaszokat aggregálják. Kittur és munkatársai szerint ez az effektus a tömeg bölcsessége (Kittur et al., 2007), és azért hatékony, mert ha valamelyik területen az egyik tanuló helytelen, a többi korrigálni képes. Az együttes tanulás olyan modellcsoportot hivatott létrehozni, amely intelligensebb, mint a benne található egyedi modellek bármelyike.

### **A dinamikus árazórendszer működése**

Ha egy vevő megjelenik a piacon vásárlási szándékával, előbb utóbb kialakul benne az elképzelés, hogy mennyit hajlandó fizetni a termékért. Azt az árat, amit még a vevő kifizet az áruért, rezervációs árnak nevezzük. (Danyi, 2019) A rezervációs ár egy vevőnél több összetevőtől függ:


1. A vásárlási igény erősségétől, vagyis a vevőnek mennyire van szüksége a termékre.
2. A vevő személyes preferenciáitól (pl. jövedelmi helyzet)
3. A termék és a hozzá kapcsolódó szolgáltatások bizonyos tulajdonságaitól (szállítási idő, garancia, új vagy elavulóban levő termék stb.)
4. A termék mekkora versenyt generál a piacon, azaz hány konkurens árusítja a terméket és milyen áron.

A felsorolt tényezők erősíthetik vagy gyengíthetik egymást. Egy jó anyagi helyzetben lévő vevőt kevésbé befolyásol az az árverseny, ami a vásárlási hajlandóságot, a rezervációs árban maximált vételi szándékot alakítja. Az 1., 2. és a 3. pont a dinamikus árazást rövid távon nem befolyásolja, viszont a 4. pont vizsgálata segítheti az árazási rendszer kidolgozását.

Az eladó szempontjából tekintve akkor jó a rezervációs ár, ha felette van a beszerzési és a minimum árak. A minimum ár az az ár, ami alatt nem lehet nyereségesen értékesíteni a terméket, vagyis egy fontos alsó korlát az értékesítésnél. A kereskedő kalkulálja ki, általában úgy, hogy megnöveli a termék beszerzési árát az értékesítést terhelő egyéb költségekkel (logisztikai, rezsi, munkabér stb.). Ennek pontos meghatározása nagyon fontos, hiszen, ha alulkalkulált, veszteséges az értékesítés, ha felülbecsült, hátrány keletkezik az árversenyben.

Az 1. ábra az ár alakulását, a vevő vásárlási hajlandóságát és a profitot mutatja. Látható, hogy az ár emelkedésével a vásárlási hajlandóság csökken, viszont a profit nő. Ha az eladó a rezervációs árat egy vevőnél eltalálja, akkor a profitját maximálta. De az is lehet, hogy a vevő rezervációs ára a minimum ár alatt van, és nem jön létre a vásárlás, mert az eladónak nem éri meg.


**1. ábra** Vásárlási hajlandóság és profit alakulása az ár függvényében



Forrás: saját szerkesztés

Az 1. ábrán bemutatott környezet csak a vevők vásárlási hajlandóságát veszi figyelembe. A 4. pontban a konkurens szerepét hangsúlyoztuk a rezervációs ár kialakulásában. Az e-kereskedelemben a piaci környezet egyik legfontosabb jellemzője a verseny, ha egy vevőnek szüksége van egy termékre, amit az interneten szeretne megvásárolni, megnézi több webáruház ajánlatát. Sőt, nagyon gyakran az árfigyelő rendszerek (Árukereső) felé fordul, ahol összegyűjtve megkapja, hogy milyen eladók milyen árakon forgalmazzák a keresett terméket. Ha árérzékeny a vevő (a vevők többsége az), és rendelkezik az árverseny információival, a számára legkedvezőbb árat fogja választani. A 2. ábrán arra látunk példát, hogyan befolyásolhatja a rezervációs árat a konkurens megjelenése.

**2. ábra** Vásárlási hajlandóság és profit alakulása az ár függvényében konkurens



Forrás: saját szerkesztés

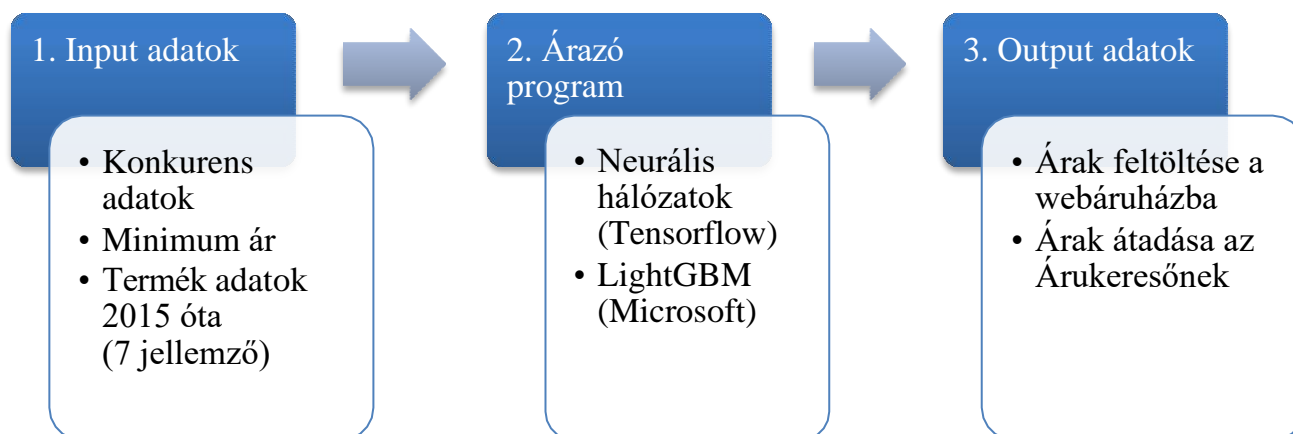
Amennyiben a vevő szeretné a legolcsóbb áron beszerezni a terméket, és elég erős a vásárlási hajlandósága, akkor a rezervációs ár a legalacsonyabb árral jelentkező konkurens ára lesz (feltéve, hogy mi nem szállunk be az árversenybe). Ekkor keletkezik egy szabadságfok arra, hogy a minimum és a konkurens ár közé beárazzunk. Balra, ahol a profit görbe metszi a vásárlási hajlandóságot, lesz az optimális pont, ide érdemes árazni a terméket. Ennek a pontnak érezhetően olcsóbbnak kell lennie a konkurens áránál, hiszen akkor tudja magát a konkurens ártól megkülönböztetni. A vásárlási hajlandóságot befolyásolják a 3. pontban leírt tényezők (pl. szállítási határidő), vagyis a piros görbe ezektől függően mozoghat.

### Dinamikus árazórendszer használata egy webáruházban

Az általunk kifejlesztett árazási rendszer is a versenyt helyezi a középpontba. A cél a verseny beépítése a dinamikus árazásba, azaz az optimális ár megtalálása. Itt segíthet a mesterséges intelligencia. Ha rendelkezünk kellően sok vásárlási adattal, képesek lehetünk betanítani gépi tanuló algoritmusokat, hogy kiválasszák az optimumot. Természetesen előfordulhat az is, hogy a konkurens ár a minimum ártól balra helyezkedik el, mert például a konkurens olcsóbb beszerzési árral rendelkezik, ilyenkor nem tudunk árazni az algoritmussal, hiszen nem mehetünk a minimum ár alá, veszteséges lenne az értékesítés.

Kifejlesztett árazórendszerünk egy szerszámkereskedéssel foglalkozó webáruházban került bevezetésre. A webáruház szerszámokat, műszaki gépeket, kerti gépeket és ezek kiegészítőit, illetve alkatrészeit forgalmazza. Több, mint 15 ezer terméket kínálnak az online térben. A webáruház a nagyobb szerszámkereskedők közé tartozik, 2021-es árbevétele meghaladta a 2 milliárd forintot. Az árazórendszerrel naponta a termékek egyharmadát, kb. 5000 terméket áraznak. Az árazás menetét a 3. ábra mutatja.

3. ábra Az árazás folyamata



Forrás: saját szerkesztés

A folyamat a következőképpen zajlik:

Input adatok begyűjtése

- minden hajnalban az árazó algoritmus begyűjti az adatokat
- szüksége van:
  - a konkurens árakra: ezeket egy programrobot kéri le a konkurens webáruházaktól minden éjjel, emellett elemzi az Árukereső árfigyelő rendszerét. A két adatforrás biztosítja, hogy garantáltan rendelkezünk a konkurens árakkal.
  - a termék minimum árára: a cég ügyviteli rendszerében éjszaka futó program állapítja meg azt a küszöbárát, amin még megéri forgalmazni az árut.
  - a termékadatokra: a webáruház adattárából 2015 óta kerülnek lekérésre az árazható termékek értékesítési adatai. A termék életútja hét fontos jellemzővel kerül felderítésre.

Árazási folyamat

- miután az adatok előálltak, az adattáblák tisztítása és összefésülése következik, amit egy Python Pandas adatelőkészítő programkód végez.
- az árazó program gerincét alkotó két gépi tanuló modul a Google Tensorflow neurális hálói és a Microsoft LightGBM gradiens turbózó eljárása. Ezen algoritmusok segítségével a programok kikalkulálják a termék árát, amely továbbításra kerül az ügyviteli rendszer felé.

Output adatok keletkeztetése

- a kikalkulált dinamikus árakat reggel 8 óra előtt veszi fel az ügyviteli rendszer azokkal a termékárakkal együtt, amelyeket dinamikusán nem árazhatnak (pl. gyártó által kötött árú termékek).
- ezt követi a webáruházban való közzététel és az Árukereső felé való továbbítás szintén 8 óra előtt.

Az árazás konkrét működésére az 1. táblázatban láthatunk példákat.

**4. ábra** Példák árazásra

cikk_kod	min_ar_hu	ar_hu	top1	top2	top3	top4	top5
101000045	53 390	54 950	55 990	55 990	57 500	57 629	57 790
101001491	10 390	13 510	13 890	14 900	14 990	14 990	15 070
101001483	26 490	29 590	43 212	45 100	47 990	64 767	73 990
101000781	336 900	351 150	360 000	361 900	367 060	380 990	386 040
101001303	38 690	41 190	43 648	44 037	44 037	44 037	44 037
101000846	78 590	82 380	84 079	84 890	84 890	86 600	86 900
101001810	79 490	103 630	109 990	110 655	123 989	123 989	130 990

Forrás: saját szerkesztés

Az egyes oszlopok jelentése:

- cikk\_kod: A szerszám azonosító kódja
- min\_ar\_hu: A termék minimális ára.
- ar\_hu: A termék ára az árazóprogrammal.
- top1,...,top5: Az első 5 legerősebb konkurens ár.

Az 1. táblázat tartalmát a következőképpen értelmezhetjük:

- Az algoritmus az árat a min\_ar\_hu és a top1 közé célozza be, mégpedig változó eloszlással, figyelembe véve bizonyos terméktulajdonságokat.
- A 101000045 számú termék átlagos termék, a min-ar-hu és a top1 között kicsi a különbség, a kalkulált ár nagyjából közepesen helyezkedik el.
- A 101001491-s termék népszerű, jól fogyó termék. Az algoritmus úgy ítélte meg, hogy elég csak 380 forinttal a konkurens ár alá menni, ami elég lesz az értékesítéshez.
- A 101001483 számú termék elavultabb, ritkán vásárolt termék, ezért az algoritmus csak 3100 forinttal emeli a minimum árat, holott ennek akár a négyszeresével is emelhetné. De a termék előélete nem igazolja a magasabb ár használatát.
- A 101001810 számú termék árazásánál látszik legjobban az algoritmus előnye. Ha a hagyományos cost-plus árazással például 15%-kal árazunk, akkor 91310 Ft -os árat kapunk. Az algoritmus 103630-ra árazta. A különbség 12320 Ft. Mivel a legerősebb konkurens 109990-n tartja az árat, a 103630-cal még így is 6360 forinttal olcsóbbak vagyunk. Ez érezhető árkülönbség, valószínű a vevő ezen az áron is megveszi a terméket. Ha ez bekövetkezik, 12320 Ft-tal nagyobb nyereségre tehetünk szert.

## **Eredmények, értékelés**

### *Értékelés kontroll termékcsoporttal*

Az árazórendszer első tesztelését egy kontroll csoporttal történő összehasonlítással végeztük. Kiválasztottunk 14 különböző szerszámot, amit az algoritmussal kezdtünk el árazni. Ezekhez kerestünk 14 darab ugyanolyan tulajdonságú (típusban, árban, teljesítményben megegyező) terméket. Legtöbbször ezek konkurens termékek voltak, azaz ugyanazt a funkciót és teljesítményt nyújtották, csak különböző gyártóktól származtak. Ügyeltünk arra, hogy mindkét csoportban jól fogyó, népszerű termékek szerepeljenek. Nem volt nehéz dolgunk, hiszen a webáruház ekkor már több, mint 15 ezer terméket forgalmazott.

A tesztelés másfél éven keresztül zajlott. 2019. januárjában kezdődött, 18 hónap után pedig a 2. táblázat eredményeit kaptuk:



## 2. táblázat *Kontroll csoport összehasonlítás*

	<b>Árazott termékek (14 termék)</b>	<b>Kontroll csoport (14 termék)</b>	<b>Százalékos eltérés</b>
<b>Eladott mennyiség (db)</b>	1 068	632	69%
<b>Bevétel (Ft)</b>	52 021 040	26 769 290	94%
<b>Nyereség (Ft)</b>	4 048 860	2 215 000	83%
<b>Átlagos haszonkulcs (%)</b>	9,45	8,6	

Forrás: Saját szerkesztés

A tesztelés jól mutatja, hogy a bevétel csaknem megduplázódott, a nyereség is több, mint 80%-os növekedést produkált. Elmondható, hogy a kontrollcsoportos összehasonlításban az árazórendszer nagyon jól teljesített.

### *Értékelés adott gyártó időbeni összehasonlításával*

A webáruház több gyártó termékeit is forgalmazza. Ezek közül kiválasztottunk egy gyártót, amelyik értékesítési adatait 500 napos időintervallumban vizsgáltuk úgy, hogy az első 250 napon (2019.05.08.-2020.01.13. között) a hagyományos módon áraztunk. A második 250 nap (2020.01.13.-2020.09.20. között) alatt pedig az árazó algoritmussal. Az 500. nap után a következő értékesítési eredményeket kaptuk (3. táblázat). Az árazó rendszer itt is jelentős növekedést produkált, a bevételek és a nyereség több, mint 70%-os növekedést hozott.

## 3. táblázat *Adott gyártó termékeinek összehasonlítása 250 napos időintervallumban*

	<b>2020.01.13.- 2020.09.20. között</b>	<b>2019.05.08.- 2020.01.13. között</b>	<b>Százalékos eltérés</b>
<b>Eladott mennyiség (db)</b>	1 320	857	54%
<b>Bevétel (Ft)</b>	67 280 560	39 677 340	70%
<b>Nyereség (Ft)</b>	5 048 100	2 912 000	73%
<b>Átlagos haszonkulcs (%)</b>	8,11	7,12	

Forrás: Saját szerkesztés

### *Az árazó rendszer jelenlegi használata*

A két teszt meggyőzte a webáruház menedzsmét, hogy kifizetődő az árazó algoritmus bevezetése. 2021. január első hetétől kezdődően az algoritmus árazta azokat a termékeket, ahol a feltételek adottak voltak. Ez azt jelentette, hogy nem volt gyártó által előírt kötött ár, és az árazásnak volt szabadsága, vagyis a legerősebb konkurens ár nem csúszott a minimális ár alá. A 4. ábra 2020. január 1. és november 14. között mutatja az algoritmussal árazott termékek nyereségének heti alakulását.

## 4. ábra *Árazott termékek nyereségének alakulása (2020.01.01-2022.10.14)*



Forrás: Saját szerkesztés

## Összefoglalás

A kutatás eredményei minden korábbi várakozásunkat felülmúlták. Sikerült létrehozni egy komplex árazó modellt, amely képes ellátni egy webáruház árazási feladatait. Az eredmények újszerűségét az adja, hogy a mesterséges intelligencia és azon belül a gépi tanulás ma még ritkán használt módszer a webáruházak árképzése területén. A megvalósításhoz a legmodernebb machine learning algoritmusokat használtuk, neurális hálózatokat és gradiens turbózást.

A kidolgozott árazási modellt egy nagyon komoly ellenőrzési folyamatnak vetettük alá. A sokrétű tesztek eredményei azt mutatják, hogy ennek az új módszernek az alkalmazása az üzleti életben kimutatható, hasznossága kézzelfogható. Eredménynek tekinthető az is, hogy az árazási rendszert sikerült integrálni a vállalati ügyviteli rendszerbe, és jelenleg is működik.

A kutatást korántsem tekintjük lezártnak. A rendszert folyamatosan monitorozni kell, fel kell készülni a kivételekre, és lehetőség szerint további fejlesztéseket folytatni. Az algoritmusok különböző paraméterein is lehet még finomítani. Érdekes lehet a modellt nemcsak a szerszámoknál, hanem más termékszegmensben is kipróbálni.

## Irodalomjegyzék

1. Bodor, B. (2019): Online aukciók általános árazási modellje, Marketing és Menedzsment, 38(3), o. 17–30.
2. Danyi, P. (2019). A mesterséges intelligencia árazásbeli alkalmazásának várható hatásai. MARKETING & MENEDZSMENT, 1, 17–29.
3. Den Boer, A. V. (2015). Dynamic pricing and learning: Historical origins, current research, and new directions. Surveys in Operations Research and Management Science, 20(1), 1–18. <https://doi.org/10.1016/j.sorms.2015.03.001>
4. Dietterich, T. G. (2002), Ensemble Learning, in M. A. Arbib (ed.), The handbook of brain theory and neural networks, second edition, Bradford Books, The MIT Press, Cambridge, MA, pp.405–408.
5. Fazekas, I. (2013): Neurális hálózatok, Debreceni Egyetem, Informatikai Kar, TÁMOP-4.1.2.A/1-11/1-2011-0103
6. tananyag
7. Guilding, C., Drury, C., & Tayles, M. (2005). An empirical investigation of the importance of cost-plus pricing. Managerial Auditing Journal, Vol. 20 Iss 2 Pp. 125 - 137, 34(1), 1–5. <https://doi.org/http://dx.doi.org/10.1108/02686900510574548>
8. Hecht-Nielsen, R. (1992). Theory of the Backpropagation Neural Network\*\*Based on “nonindent” by Robert Hecht-Nielsen, which appeared in Proceedings of the International Joint Conference on Neural Networks 1, 593–611, June 1989. © 1989 IEEE. In Neural Networks for Perception (Issue June 1989). Academic Press, Inc. <https://doi.org/10.1016/b978-0-12-741252-8.50010-8>

9. Karlsson, T., Kuttainen, C., Pitt, L., & Spyropoulou, S. (2005). Price as a variable in online consumer trade-offs. *Marketing Intelligence and Planning*, 23(4), 350–358. <https://doi.org/10.1108/02634500510603456>
10. Keno, A. (2018.). 2\_12\_Price-Intelligently-SaaS-Pricing-Strategy.
11. <https://anyflip.com/fbqw/ihho>
12. Kittur, A., Chi, E. H., Pendleton, B. A., Suh, B., & Mytkowicz, T. (2007). Power of the few vs. wisdom of the crowd: Wikipedia and the rise of the bourgeoisie. 25th Annual ACM Conference on Human Factors in Computing Systems, November.
13. Kocsis, É., & Szabó, K. (2002): Dinamikus árazás az elektronikus piacereken. *Közgazdasági Szemle*, XLIX. évf., 2002. október (858–874. o.)
14. Kovács, N. (2015). Az optimális ár meghatározásának módszere az értékteremtés szolgálatában. *Vezetéstudomány*, 12, 34–40.
15. Phillips, R. L., Gordon, M. S., Ozluk, O., Alberti, S., Flint, R. A., Andersson, J. K., Rangarajan, K. P., Grossman, T., Cooke, R. M., & Cohen, J. S. (2006). Dynamic pricing system. 2(12). <https://patents.google.com/patent/US7133848B2/en%0Ahttp://www.google.co.uk/patents/US7133848>
16. Shankar, V., & Bolton, R. N. (2004). An Empirical Analysis of Determinants of Retailer Pricing Strategy. *Marketing Science*, 23(1). <https://doi.org/10.1287/mksc.1030.0034>
17. Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., & Fergus, R. (2014). Intriguing properties of neural networks. 2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings, 1–10.