

# **SZAKDOLGOZAT**

**Földi Tamás**

**2025**



**Magyar Agrár- és Élettudományi Egyetem  
Szent István Campus**

**Vidékfejlesztés és Fenntartható Gazdaság Intézet**

**Gazdálkodás és Menedzsment szak**

**Takagi-Sugeno neuro-fuzzy modell alkalmazása  
európai bankok részvényárfolyamának  
előrejelzésére**

Application of Takagi-Sugeno-type neuro-fuzzy model for forecasting stock prices of European banks

**Belső konzulens:** Dr. Gáspár Sándor  
Egyetemi adjunktus

**Belső konzulens  
intézete/tanszéke:** Vidékfejlesztés és  
Fenntartható Gazdaság  
Intézet

**Külső konzulens:** -

**Készítette:** Földi Tamás

Gödöllő, 2025

## Tartalomjegyzék:

1. Bevezetés .....	1
2. Szakirodalom feldolgozása .....	3
2.1 Bevezetés a tőzsdei kereskedelem alapjaiba .....	3
2.1.1 Banki teljesítménymutatók szerepe a pénzügyi elemzésben .....	3
2.1.2 Bankok és a tőzsde szimbiotikus kapcsolata .....	4
2.1.3 Banki mutatók jelentősége a tőzsdei előrejelzésekben .....	5
2.1.4 Konkrét banki mutatók ismertetése .....	5
2.2 A mesterséges intelligencia történelmi háttere .....	7
2.2.1 Mesterséges intelligencia típusai .....	9
2.2.2 Hibrid mesterséges intelligencia rendszerek .....	10
2.2.3 Neuro-fuzzy rendszerek: a gépi tanulás és a fuzzy logika kombinációja .....	10
2.2.4 Az ANFIS modell felépítése és működése .....	11
2.2.5 ANFIS alkalmazása pénzügyi előrejelzésekben .....	12
2.2.6 Előnyök, korlátok és további megfontolások .....	13
3. Kutatásmódszertan .....	15
4. Eredmények összegzése.....	18
4.1 A vizsgált modellek és koncepciók bemutatása .....	18
4.2 Modellkonfigurációk értékelése - 3 tagsági függvény.....	23
4.3 Modellkonfigurációk értékelése – 4 tagsági függvény .....	27
5. Következtetések és javaslatok.....	31
5.1 Eredmények összevetése és következtetések .....	31
5.2 Javaslatok .....	35
6. Összefoglalás és személyes reflexió.....	37
6.1 Átfogó összefoglalás .....	37
6.2 Személyes reflexió .....	38
7. Irodalomjegyzék.....	39

## Köszönetnyilvánítás

Ezúton szeretném megköszönni mindazok támogatását, akik segítettek abban, hogy ez a szakdolgozat elkészüljön.

Külön köszönettel tartozom témavezetőmnek, **Dr. Gáspár Sándornak**, aki szakmai iránymutatásával, türelmével és ösztönzésével végig segített a dolgozat megírásában. Sokat jelentett számomra, hogy bármikor fordulhattam hozzá kérdéseimmel, és mindig értékes visszajelzést kaptam.

Hálás vagyok **családomnak** is, amiért végig mellettem álltak, támogattak, és segítettek átlendülni a nehezebb időszakokon. Türelmük és biztatásuk sokat jelentett számomra.

Végül, de nem utolsósorban szeretném megköszönni **barátaimnak** és **hallgatótársaimnak** a közös gondolkodást, a bátorítást, valamint a konstruktív véleményeiket, amelyek hozzájárultak ahhoz, hogy a dolgozat szakmailag és emberileg is teljesebb legyen.

**Köszönöm.**

## 1. Bevezetés

A bankrendszer története egészen az ókori civilizációkig nyúlik vissza, amikor először jelent meg az igény a vagyon biztonságos tárolására és a pénzkölcsönzés lehetőségére. Már Babilóniában és az ókori Egyiptomban is működtek olyan intézmények, amelyek pénzügyi tranzakciókat végeztek, vagy hiteleket nyújtottak. Az ókori Görögországban és Rómában ezek a tevékenységek tovább fejlődtek, és megjelentek az első bankárszerű figurák, akik nemcsak pénzváltással és kölcsönzéssel foglalkoztak, hanem letéti szolgáltatásokat is nyújtottak, sőt, olykor még a tranzakciók írásos dokumentálását is végezték (Cohen, 2011). A középkorban a bankrendszer szerepe jelentősen bővült. Ebben az időszakban jöttek létre a nagy európai kereskedővárosok, mint Firenze, Genova és Velence, amelyekben a bankok kulcsfontosságú szerepet játszottak a nemzetközi kereskedelem finanszírozásában (Goldthwaite, 2009). A bankok kezdeti szolgáltatásai között szerepelt az árukereskedelem finanszírozása, a valutaváltás, valamint a hitelügyletek lebonyolítása is, amelyek hozzájárultak a városállamok gazdasági növekedéséhez és jólétéhez. Az európai bankházak, mint a Medici vagy Fugger család által alapított intézmények, jelentős befolyással bírtak a politikai életre is, gyakran meghatározva államok közötti konfliktusok vagy szövetségek végkimenetelét.

A 17–18. században az európai gazdaságok fejlődésével párhuzamosan a bankok szerepe is folyamatosan átalakult és intézményesült. Ebben az időszakban jöttek létre az első központi bankok, például a svéd Riksbank 1668-ban és később az angol Bank of England 1694-ben, amelyek fontos szerepet kaptak a pénzkibocsátás, a kamatlábak szabályozása és a pénzügyi rendszer stabilitásának biztosítása terén (Lindvall, 2020), (Patrick K. O'Brien, 2023). Ezek a központi bankok képezték az alapját a mai modern monetáris politikának és pénzügyi szabályoknak. A 19. század az ipari forradalom korát hozta el, amely során a bankrendszer további fejlődése elengedhetlenné vált. A bankok elkezdtek befektetni ipari projektekbe, vasútépítésekbe, valamint más infrastruktúra-fejlesztésekbe. Ebben a korban a pénzügyi szektor jelentős mértékben hozzájárult az ipari növekedéshez és a gazdasági innovációk finanszírozásához. A globális kereskedelem és a pénzügyi piacok bővülése miatt szükségessé vált a banki műveletek és szolgáltatások folyamatos innovációja és fejlődése (Stephan Hebllich, 2018).

Napjainkra a banki szektor szorosan összekapcsolódott a globális tőkepiacokkal, különösen a tőzsdei árfolyammozgásokkal. Ez a kapcsolat kiemelten fontossá teszi, hogy a pénzügyi szakemberek pontos előrejelzéseket készítsenek a részvényárfolyamok változásairól, mivel azok közvetlen hatással vannak a bankok profitabilitására, pénzügyi helyzetére és általános működési stabilitására. A banki részvények árfolyamváltozásainak előrejelzése nem csupán befektetői szempontból kritikus jelentőségű, hanem stratégiai fontosságú a banki döntéshozatal szempontjából is, mivel segíthet a kockázatok előzetes kezelésében, a döntések hatékonyságának növelésében és a pénzügyi válságok előrejelzésében is (Shynkevich, 2016). Személyes érdeklődésem a pénzügyi piacok, különösen a tőzsdei világ iránt már egészen fiatal koromban kialakult. Vonzerőt jelentett számomra a piacok kiszámíthatatlansága, a befektetői magatartás összetettsége, valamint annak kihívása, hogy megértem a látszólag kaotikus változások mögött meghúzódó trendeket és mozgatórugókat. Kezdetben a klasszikus elemzési módszerek, így a technikai és fundamentális elemzés tanulmányozásával foglalkoztam, majd idővel érdeklődésem fokozatosan a mesterséges intelligencia irányába fordult.

A mesterséges intelligencia iránti érdeklődésem folyamatosan mélyült az egyetemi tanulmányaim során, mivel egyre inkább felismerem annak potenciálját a pénzügyi előrejelzések pontosságának és hatékonyságának javításában. Az utóbbi időben különösen a neuro-fuzzy rendszerek, ezen belül is az Adaptív Neuro-Fuzzy Következtetési Rendszer (ANFIS) keltette fel a figyelmemet. Ezek a rendszerek egyedülálló módon képesek ötvözni az emberi bizonytalanságkezelést és intuíciót a gépi tanulási technikák erősségeivel, különösen

alkalmasak az összetett és nemlineáris problémák kezelésére, amelyek tipikusan a pénzügyi piacokra jellemzőek. Az ANFIS modell iránti lelkesedésem fő oka, hogy hatékony eszközként szolgálhat a banki teljesítménymutatók, mint például a ROA, ROE, profit margin, és a részvényárfolyamok közötti összetett összefüggések mélyebb megértéséhez és feltárásához.

Szakdolgozatom célkitűzése éppen ezért az, hogy banki teljesítménymutatók segítségével és ANFIS modellek alkalmazásával pontosabb prognózisokat készítsék a tőzsdei mozgásokról, valamint megvizsgáljam, hogyan befolyásolják a különböző tagsági függvények, háromszög, trapéz, Gauss, szigmoid, a predikciós pontosságot. Reményeim szerint kutatásom eredményei értékes hozzájárulást jelentenek majd a banki döntéshozók és a piaci szereplők döntéseinek támogatásában és pontosságának javításában.

## 2. Szakirodalom feldolgozása

### 2.1 Bevezetés a tőzsdei kereskedelem alapjaiba

A tőzsde egy szabályozott piac, amely lehetőséget biztosít különféle értékpapírok, például részvények, kötvények, árutőzsdei termékek adásvételére. Ez a piac központosított keretek között, előre meghatározott szabályok alapján működik, amelyeken keresztül a befektetők tranzakciókat bonyolíthatnak le. A tőzsdei árakat a kereslet és kínálat határozza meg, tükrözve a piaci szereplők aktuális gazdasági várakozásait és a vállalatok teljesítményét. A tőzsdék alapvető szerepet töltenek be a gazdasági rendszerben: segítik a vállalatokat a tőke bevonásában, lehetőséget biztosítanak a befektetők számára a megtakarításaik növelésére, illetve hozzájárulnak a gazdaság hatékony erőforrás-elosztásához (Dhyani, és mtsai., 2023). A vállalatok a tőzsdére lépéskor részvényeket bocsátanak ki, amelyeket a befektetők megvásárolhatnak. Így válhatnak a részvényesek a vállalat tulajdonosaivá, részesedve annak nyereségéből, de egyben vállalva a kockázatot is, amely a részvény árfolyamának változásából adódik. A tőzsdék működése szigorúan szabályozott, és az átláthatóság érdekében szigorú információszolgáltatási kötelezettségek vonatkoznak a tőzsdén jegyzett vállalatokra. A szabályozó hatóságok feladata, hogy biztosítsák a piac tisztességes működését, valamint megvédjék a befektetők érdekeit. A tőzsdei kereskedés technológiai fejlődésének köszönhetően mára nagyrészt elektronikus platformokon zajlik, így lehetővé téve a globális befektetői részvételt és gyors, hatékony tranzakciókat.

#### 2.1.1 Banki teljesítménymutatók szerepe a pénzügyi elemzésben

A tőzsdei előrejelzések története évszázadokra nyúlik vissza, és szorosan összefügg a pénzügyi piacok és kereskedési rendszerek fejlődésével. Már az első modern tőzsdék kialakulásakor, a 17. század elején Amszterdamban felmerült az igény arra, hogy a befektetők valamilyen módon előre tudják jelezni a piaci mozgásokat. Ezen előrejelzések elsődleges célja mindig is a kockázatok csökkentése és a befektetések megtérülésének maximalizálása volt (Oscar Gelderblom, 2004). Kezdetben a tőzsdei szereplők, elsősorban kereskedők és befektetők, a technikai elemzésre támaszkodtak, amely során a múltbeli árfolyammozgásokból próbálták előrevetíteni a jövőbeli piaci trendeket. Ez az elemzési módszer főként a grafikonok és statisztikai indikátorok alkalmazásán alapult, és rövid távú árfolyammozgások előrejelzésére bizonyult hatékornak.

A technikai elemzés dominanciáját fokozatosan megtörte a fundamentális elemzés, amely a 20. század elejétől kezdett jelentősebb figyelmet kapni. Ez utóbbi elemzési módszer a vállalati teljesítmény, gazdasági indikátorok, politikai események és makrogazdasági tényezők átfogó értékelését végzi annak érdekében, hogy hosszabb távú előrejelzéseket adhasson (Slobodianyk, 2021). A fundamentális elemzés egyik legfontosabb területét képezik a banki mutatók, mivel a bankok kulcsszerepet játszanak a gazdaság működésében. A bankok stabilitása vagy instabilitása közvetlen hatással van a teljes pénzügyi rendszerre, sőt az egész gazdaságra is. Ennek megfelelően a bankok pénzügyi állapotát tükröző mutatók figyelemmel kísérése nélkülözhetetlen a gazdaság általános állapotának és kilátásainak értékelése során (Mayis G. Gulaliyev, 2019). A bankok gazdasági indikátorként való működésének alapja, hogy tevékenységük során közvetlen kapcsolatban állnak a gazdaság minden szereplőjével: vállalatokkal, háztartásokkal és más pénzügyi intézményekkel. Egy gazdaságban tapasztalható pozitív változások, mint például gazdasági növekedés, kedvező üzleti környezet, és alacsony kamatkörnyezet, általában a banki mutatók javulásával járnak együtt. Ezzel szemben a bankok mutatóinak romlása előrevetítheti gazdasági problémák kialakulását, recesszió beköszöntét,

vagy akár pénzügyi válság lehetőségét is. Emiatt a banki mutatók elemzése nem csak a pénzügyi elemzők számára, hanem a befektetők és szabályozó hatóságok számára is stratégiai jelentőséggel bír. A banki mutatók nem csupán általános gazdasági információkkal szolgálnak, hanem specifikus betekintést nyújtanak a bankok pénzügyi állapotába, mint például jövedelmezőségükbe, hatékonyságukba, likviditásukba és pénzügyi stabilitásukba is. Ezek a mutatók alapvetően meghatározzák a befektetők bankokról alkotott véleményét és piaci reakcióit, mivel közvetlen összefüggésben állnak a banki részvényárfolyamok változásával.

Ezen mutatók alapos elemzése lehetővé teszi a piaci szereplők számára, hogy mélyrehatóan értékeljék egy adott bank teljesítményét és pénzügyi helyzetét, előrejelezve annak részvényárfolyamára gyakorolt lehetséges hatásait (Caplinska, 2021). Ennek köszönhetően a befektetők jobban tudják kezelni a befektetések kockázatait, illetve hatékonyabban optimalizálhatják portfóliójukat, növelve ezzel befektetéseik várható megtérülését.

## 2.1.2 Bankok és a tőzsde szimbiotikus kapcsolata

A bankok és a tőzsde kapcsolata többretegű és kölcsönösen előnyös természetű. Egyrészt a bankok jelentős szereplői a tőzsdének: részvényeik gyakran a leglikvidebb és legnagyobb forgalmú értékpapírok közé tartoznak. Másrészt a bankok fontos szolgáltatói is a tőzsdének, hiszen finanszírozást nyújtanak a tőzsdei műveletekhez, letétkezelői szolgáltatásokat biztosítanak, valamint közvetítőként működnek a befektetők és a tőzsde között (Augustine C. Arize, 2018). A stabil bankrendszer a hatékonyan működő tőzsde előfeltétele. A bankok biztosítják a tőzsdei műveletek finanszírozását, a likviditást, valamint a fizetési és elszámolási rendszerek gördülékeny működését. A bankrendszer problémái gyorsan átgyűrűznek a tőzsdére, ahogy ezt a 2008-as globális pénzügyi válság is megmutatta. Amikor a bankok között bizalmi válság alakul ki és a bankközi hitelezés befagy, a tőzsdei likviditás is drasztikusan csökkenhet, ami fokozott volatilitáshoz és akár piaci összeomláshoz is vezethet (Aliber, 2019). A tőzsde nemcsak a bankok finanszírozási forrása (részvénykibocsátás révén), hanem folyamatos értékelést is ad teljesítményükről a részvényáron keresztül. A hatékony piaci hipotézis szerint a részvényárak minden nyilvánosan elérhető információt tükröznek, így a bankok részvényárfolyamai is valós idejű visszajelzést adnak a piac véleményéről a bank jelenlegi helyzetével és jövőbeli kilátásaival kapcsolatban (Okur, 2015).

### Kölcsönös hatásmechanizmusok

A bankok és a tőzsde közötti kölcsönhatás számos csatornán keresztül valósul meg:

Monetáris transzmisszió: A jegybanki kamatdöntések először a bankrendszeren keresztül fejtik ki hatásukat, majd ezt követően gyűrűznek át a tőzsdére (Balogh András, 2017).

Hitelezési feltételek: A bankok hitelezési hajlandósága és feltételei befolyásolják a vállalatok beruházási döntéseit, ami hatással van profitabilitásukra és ezáltal részvényárfolyamaikra (Okur, 2015).

Befektetői hangulat: A bankszektor állapota jelentősen befolyásolja a befektetői hangulatot és kockázatvállalási hajlandóságot, ami kihat a tőzsdei árfolyamokra (Elemzéseközpont, 2025).

Piaci likviditás: A bankok által biztosított piaci likviditás elengedhetetlen a tőzsde zavartalan működéséhez és a hatékony árképzéshez (Páles Judit, 2006).

Értékpapírosítás: A bankok által végzett értékpapírosítási tevékenység közvetlen kapcsolatot teremt a hitelpiacok és a tőkepiacok között (MNB, 2024).

### 2.1.3 Banki mutatók jelentősége a tőzsdei előrejelzésekben

A banki teljesítménymutatók elemzése rendkívül értékes eszköz lehet a tőzsdei előrejelzések készítésénél. Ennek több oka is van:

#### Korai figyelmeztető rendszer

A bankszektor gyakran a gazdasági ciklusok korai indikátoraként szolgál. A hitelezési aktivitás változásai, a nemteljesítő hitelek arányának alakulása, vagy a kamatmarzs szűkülése előre jelezheti a gazdasági lassulást, ami később a tőzsdei árfolyamokban is megmutatkozik. Különösen hasznos ez a tulajdonság a gazdasági fordulópontok azonosításában (Ray Barrell E., 2010).

#### Rendszerkockázat mérése

A banki mutatók összesített elemzése segíthet a pénzügyi rendszer stabilitásának felmérésében és a rendszerkockázat szintjének meghatározásában. A túlzott tőkeáttétel, a likviditási problémák vagy a koncentrált kockázatvállalás a bankoknál általában megelőzi a nagyobb piaci korrekciókat (Xin Huang, 2012).

#### Szektorális teljesítmény előrejelzése

A banki hitelezési aktivitás és a finanszírozási feltételek változásai előre jelezhetik egyes szektorok jövőbeli teljesítményét. Például a jelzáloghitelezés feltételeinek szigorítása negatívan hathat az ingatlanszektorra, míg a vállalati hitelezés bővülése pozitív jel lehet az ipari szektor számára (Tuteja, Bhojar, Singh, & Rroy, 2023).

### 2.1.4 Konkrét banki mutatók ismertetése

A bankok teljesítményének értékelésére és pénzügyi egészségének megítélésére számos mutatószámot használnak az elemzők. Ezek a mutatók különböző aspektusokból világítják meg a bankok működését, és mindegyikük sajátos információt nyújt a tőzsdei befektetők számára.

#### **Eszközarányos megtérülés (Return on Assets, ROA)**

##### Definíció és számítás

Az eszközarányos megtérülés azt mutatja meg, hogy a bank milyen hatékonyan használja fel eszközeit jövedelem generálására (Songtao Wu, 2007).

Kiszámítása:

$$ROA (\%) = \frac{\text{Nettó eredmény}}{\text{Eszközök összesen}}$$

##### Értelmezés

A magasabb ROA érték hatékonyabb eszközfelhasználást jelez. A nagyobb kereskedelmi bankok esetében a 1-1,5% körüli ROA érték már jónak számít, míg a kisebb bankoknál ez az érték magasabb is lehet (Songtao Wu, 2007).

##### Korlátok

A ROA nem veszi figyelembe a bank tőkeáttételét és a mérlegen kívüli tevékenységek hatását. Egyes bankok alacsonyabb ROA mellett is működhetnek profitábilisan, ha magasabb tőkeáttétellel dolgoznak.

## Sajáttőke-arányos megtérülés (Return on Equity, ROE)

### Definíció és számítás

A száttőke-arányos megtérülés azt mutatja meg, hogy a bank milyen hatékonyan használja fel a tulajdonosok által rendelkezésre bocsátott tőkét jövedelem generálására (Kira, 2014).  
Kiszámítása:

$$ROE(\%) = \frac{\text{Nettó eredmény}}{\text{Saját tőke}}$$

### Értelmezés

A bankszektor esetében általában a 15% feletti ROE értéket tekintik jónak, bár ez függ a gazdasági környezettől és a kamatkörnyezettől is. A ROE értéke általában magasabb, mint a ROA, mivel figyelembe veszi a tőkeáttétel hatását (Kira, 2014).

### Korlátok

A magas ROE nem feltétlenül pozitív, ha azt túlzott tőkeáttétellel vagy kockázatvállalással érik el. Ezért fontos, hogy a ROE értékét a kockázati mutatókkal együtt értékeljük (Kira, 2014).

## Profit marzs (Profit Margin, PM)

### Definíció és számítás

A profit marzs a bank adózott eredményét viszonyítja a teljes bevételéhez.

Kiszámítása: 
$$\text{Profit Margin} (\%) = \frac{\text{Nettó eredmény (Net profit)}}{\text{Árbevétel (Revenue)}}$$

### Értelmezés

A magasabb profit marzs azt jelzi, hogy a bank hatékonyan kontrollálja költségeit és képes magasabb árréssel működni. A bankoknál a 25-35% közötti nettó profitmarzs általában jónak számít, bár ez jelentősen függ a bank üzleti modelljétől (Dicecco, 2011).

### Korlátok

A profit marzs önmagában nem ad teljes képet a bank teljesítményéről, mivel nem veszi figyelembe az eszközfelhasználás hatékonyságát és a tőkeáttétel hatását (Gai, 2021) (Dicecco, 2011).

## Current Ratio (CR) - Likviditási ráta

### Definíció és számítás

A likviditási ráta a bank rövid távú fizetőképességét méri, azt mutatja meg, hogy a bank mennyire képes eleget tenni rövid távú kötelezettségeinek (Li, 2024).

Kiszámítása:

$$\text{Likviditási ráta} = \frac{\text{Forgóeszközök}}{\text{Rövid lejáratú kötelezettségek}}$$

### Értelmezés

Az 1 feletti érték azt jelenti, hogy a bank rendelkezik elegendő likvid eszközzel rövid távú kötelezettségeinek teljesítéséhez. A bankoknál azonban a likviditás értékelésére gyakran speciálisabb mutatókat, mint például a Likviditásfedezeti Ráta (LCR) használnak.

### Korlátok

A hagyományos likviditási ráta nem veszi megfelelően figyelembe a bankok speciális mérlegszerkezetét és üzleti modelljét, ezért a bankok esetében más, speciálisan a bankszektor sajátosságaira kifejlesztett likviditási mutatókat is alkalmaznak (Li, 2024).

## Egy részvényre jutó eredmény (Earnings Per Share, EPS)

### Definíció és számítás

Az egy részvényre jutó eredmény megmutatja, hogy a bank adózott eredményéből mennyi jut egy darab részvényre (Robbetze, 2017).

Kiszámítása:

$$EPS = \frac{\text{Nettó eredmény} - \text{Elsőbbségi részvények osztaléka}}{\text{Forgalomban lévő törzsrészvények átlagos száma}}$$

### Értelmezés

Az EPS növekedése a bank profitabilitásának javulását jelzi. Az elemzők gyakran figyelik az EPS növekedési ütemét, valamint az előrejelzésekhez képesti teljesítményt.

### Korlátok

Az EPS manipulálható részvény-visszavásárlásokkal, hiszen ezáltal csökken a forgalomban lévő részvények száma. Emellett az EPS nem veszi figyelembe a növekedés eléréséhez szükséges tőke mennyiségét, ami torzíthatja a bank valódi teljesítményének megítélését (Robbetze, 2017).

## 2.2 A mesterséges intelligencia történelmi háttere

A mesterséges intelligencia (MI) az informatika és a számítástudomány egyik leggyorsabban fejlődő, ugyanakkor rendkívül sokszínű területe. Az emberi gondolkodási képességek gépi úton történő szimulálása, legyen szó tanulásról, logikai következtetésről vagy éppen nyelvi megértésről, hosszú évtizedek óta foglalkoztatja a tudományos közösséget. A terület jelentősége abban áll, hogy a fejlett MI-rendszerek olyan megoldásokhoz vezethetnek, amelyek az emberi munkát támogatják vagy akár részben helyettesíthetik, mindezt számos alkalmazási területen: a beszédfelismeréstől a képfeldolgozáson át egészen a komplex döntéshozó rendszerekig.

A mesterséges intelligencia, mint kutatási terület a 20. század közepén született meg, azonban gyökerei sokkal távolabbra nyúlnak: számos tudományos és filozófiai gondolkodó már az ókorban és a középkorban is foglalkozott az emberi elme és a gépek kapcsolódási lehetőségeivel, noha kezdetleges formában. Az MI fejlődése azonban csak a számítógépek megjelenésével és széles körű elterjedésével vált igazán megfoghatóvá és tudományosan is megalapozottá. Az 1950-es és 60-as évek alapkutatásai során később elhíresült kutatók, például John McCarthy, Marvin Minsky, Allen Newell és Herbert A. Simon rakták le a ma ismert mesterséges intelligencia alappilléreit (Lu, 2004). Ezt a korai, úgynevezett „klasszikus” időszakot követték az úgynevezett MI-tél periódusok, amikor a finanszírozás és a lelkesedés is megcsappant (Grabowski, 2024). Mindazonáltal a terület újra és újra képes volt megújulni: a 80-as évek szakértőrendszerei, majd a 90-es években, a 2000-es évek elején a gyorsuló hardverfejlődés és a nagy adathalmazok (big data) megjelenése, végül a neurális hálózatok mélytanulásának (deep learning) térnyerése egyre dinamikusabbá tette a mezőnyt.

A mesterséges intelligencia fejlődéstörténetét több szempontrendszer alapján vizsgálhatjuk, legyen az a különböző kutatási iskolák harca (például a szimbolikus MI kontra konnekcionista megközelítések) (Dong, 2021), a rendelkezésre álló eszközpark (számítógépek teljesítménye, algoritmikus újítások) vagy éppen a társadalmi, gazdasági igények változásai. A 21. században már egyre inkább az integrált, hibrid megoldások kerülnek előtérbe: a gépi tanulás egyesül a klasszikus statisztikai módszerekkel, a nagyvállalati környezetek igényeit kiszolgáló felhőalapú rendszerekkel és olyan új technológiákkal, mint a kvantum-számítástechnika hajnalán körvonalazódó, még gyorsabb adatfeldolgozás. Mindezek közben további lényeges szempontként jelenik meg az etikai és jogi szabályozás, hiszen a társadalmak nagy kérdése, hogy miként tudja összeegyeztetni az emberiség a gépi döntéshozatal hatékonyságát a jogbiztonság, az átláthatóság és az emberi értékek védelmével.

A neuro-fuzzy megközelítés fontos lépést jelent abban, hogy a neurális hálózatok mint hatékony tanulórendszerek és a fuzzy logika, mint emberi gondolkodásmódot modellező eszköz együttesen kínáljanak rugalmas és ugyanakkor jól értelmezhető keretrendszert. Ez a kombináció a pénzügyi előrejelzésektől a képfelismerésen át számos iparágban bizonyította már gyakorlati hasznosságát, ugyanakkor elméleti szempontból is izgalmas, mert a két eltérő szemlélet a folytonos, illetve a nyelvi szabályalapú integrációjáról van szó.

## 2.2.1 Mesterséges intelligencia típusai

1. táblázat. Mesterséges intelligencia típusai.

(Forrás: saját szerkesztés informatedigital.com adatai alapján)

Kategória típusa	Megnevezés	Rövid ismertetés	Példa	Forrás
<u>Képességek szerinti felosztás</u>	Szűk (Gyenge) MI (ANI)	Egyetlen speciális feladat ellátására alkalmas rendszerek, amelyek szűk területen belül képesek magas teljesítményt nyújtani.	Siri virtuális asszisztens, AlphaGo program	(Gai, 2021)
	Általános (Erős) MI (AGI)	Elméletileg képes az emberi intelligenciához hasonló komplex szellemi feladatok ellátására, azonban a gyakorlatban jelenleg még nem létezik.	Jelenleg nincs konkrét példa	(Gai, 2021)
	Mesterséges Szuperintelligencia (ASI)	Az emberi intelligenciát minden szempontból meghaladó, spekulatív intelligenciaforma, amely filozófiai és technológiai kérdéseket vet fel.	Csak elméleti példa létezik	(Gai, 2021)
<u>Működési mód szerinti felosztás</u>	Reaktív rendszerek	Csak az adott pillanatnyi információra reagálnak, múltbeli tapasztalatokat nem tárolnak vagy használnak fel a döntéshozatalban.	Sakkozó programok	(J.M. Davoren, 2006)
	Korlátozott memóriával rendelkező rendszerek	Képesek korábbi információkat és eseményeket felidézni, és ezeket figyelembe venni döntéseik során.	Önvezető autók	(Gerven, 2011)
	Elmeelmélet-alapú rendszerek	Fejlesztés alatt álló rendszerek, amelyek célja, hogy felismerjék és értelmezzék az emberi érzelmeket és társas viszonyokat.	Kísérleti szakaszban lévő fejlesztések	(Winfield, 2018)
	Öntudatos MI	Legfejlettebb és leginkább elméleti forma, amelyben a mesterséges intelligencia öntudattal rendelkezik.	Egyelőre csak sci-fi példák léteznek	(Greenwood, Sundaram, Muirhead, & Copperthwaite, 2020)
<u>Főbb technológiai módszerek és irányok</u>	Gépi tanulás (ML)	Adataalapú tanulási módszer, amelyben a rendszer különféle algoritmusok segítségével tanul meg mintázatokat felismerni és következtetéseket levonni, anélkül, hogy minden döntési lépés előre meghatározott lenne.	Felügyelt és felügyelet nélküli tanulás, megerősítéssel tanulás	(Aziz, 2018)
	Mesterséges neurális hálózatok (ANN)	Az emberi agy neurális hálózatainak mintájára készült számítási modellek, amelyek főleg osztályozási és mintázatfelismerési feladatokban erősek.	Képfelismerő szoftverek	(Lang, 2007)
	Mélytanulás (DL)	Gépi tanulás továbbfejlesztett formája, amely mély, többrétegű hálózatokat használ bonyolult adatminta-felismerésre nagy adathalmazok esetén.	Arcfelismerés, beszéd felismerés	(Narayanan, 2024)
	Konvolúciós neurális hálózatok (CNN)	Különösen alkalmasak képek, videók elemzésére, az adatok térbeli struktúrájának kiemelésére specializálódtak.	Képfelismerő algoritmusok, orvosi képalkotás	(Saleem, 2022)
	Rekurzív neurális hálózatok (RNN)	Időbeli vagy egymást követő adatok elemzésére, modellezésére használt hálózatok, amelyek kiemelten alkalmasak nyelvfeldolgozásra és idősor elemzésre.	Nyelvi fordítóprogramok, idősor elemzés	(DiPietro, 2019)

## 2.2.2 Hibrid mesterséges intelligencia rendszerek

### A hibrid megközelítések szerepe a pénzügyi előrejelzésben

A modern pénzügyi piacok összetettsége és változékonysága miatt a hagyományos előrejelző módszerek, például az idősoros modellek vagy az egyváltozós statisztikai elemzések gyakran nem bizonyulnak elég rugalmasnak vagy pontosnak. Az olyan mesterséges intelligencia alapú technikák, mint a neurális hálózatok vagy a fuzzy logika, jelentős előrelépést hoztak a nemlineáris és bizonytalan viselkedésű pénzügyi adatok kezelésében. Ugyanakkor egyetlen megközelítésnek is megvannak a korlátai: a neurális hálózatok sok adatot igényelnek és eredményeik nehezen értelmezhetők, míg a fuzzy szabályalapú rendszerekhez szakértői tudás kell és önmagukban nem mindig tanulékonyak. Ezért egyre inkább hibrid megoldások kerülnek előtérbe, amelyek kombinálják több módszer előnyeit a hátrányok csökkentése érdekében. Ilyen például a statisztikai modellek és gépi tanulás egyesítése: egy kutatás kimutatta, hogy egy ARIMA modell és egy neurális hálózat kombinálásával sokkal jobb előrejelzési eredmény érhető el a vietnámi tőzsdeindex esetében, mint külön-külön az ARIMA-val vagy az ANN-nel (Quang Hung Do, 2019).

A különböző megközelítések összevonása tehát kézzelfogható javulást hozhat az előrejelzések pontosságában.

A hibrid mesterséges intelligencia rendszerek lényege, hogy két vagy több eltérő algoritmust, módszert integrálnak egyetlen keretrendszerbe. A cél a szinergia kihasználása: az egyes komponensek kompenzálják egymás gyengeségeit és erősítik az összteljesítményt. A pénzügyi előrejelzésekben tipikus hibrid megoldás a neurális hálók ötvözése más technikákkal. Például a neurális hálózatokat gyakran kombinálják fuzzy logikai rendszerekkel, genetikus algoritmusokkal vagy akár gazdasági-statisztikai modellekkel. Ezek az integrált rendszerek képesek a pénzügyi idősorok rejtett mintázatait jobban megragadni és robusztusabb előrejelzéseket adni a gyorsan változó piaci környezetben. Számos bizonyíték utal arra, hogy a mesterséges intelligencia alapú modellek, különösen a kombinált, intelligens hibrid rendszerek felülmúlják a hagyományos statisztikai modelleket a tőzsdei árfolyamok előrejelzésében (Quang Hung Do, 2019).

Az alábbiakban a hibrid megközelítések egy kiemelkedő típusára, a neuro-fuzzy rendszerekre és ezen belül az ANFIS modellre fókuszálunk, amelyek az utóbbi években különösen ígéretesnek bizonyultak a pénzügyi előrejelzések terén.

### 2.2.3 Neuro-fuzzy rendszerek: a gépi tanulás és a fuzzy logika kombinációja

A neuro-fuzzy rendszerek olyan hibrid intelligens rendszerek, amelyek neurális hálózatok és fuzzy logika integrációjával jönnek létre. A fuzzy logika Zadeh (1965) nevéhez köthető, és alap gondolata, hogy az emberi gondolkodásra jellemző bizonytalanságot és homályosságot matematikailag megragadja: nem éles igen/nem kategóriákban gondolkodik, hanem fokozatos tagsági fokokkal (például egy állítás részben igaz vagy nagyrészt igaz lehet) (Zadeh, 1965). A fuzzy rendszerekben szakértők fuzzy szabályokat fogalmazznak meg (pl. „Ha a piaci hangulat enyhén pozitív és a profitráta magas, akkor a részvényárfolyam emelkedni fog.”), és a bemenő változókat tagsági függvények segítségével hozzárendelik ilyen nyelvi kategóriákhoz. Ez a logika nagyon közel áll az emberi gondolkodáshoz, jól kezeli a bizonytalanságot, de önmagában nem tanul: a szabályok megalkotása szakértelmet igényel, és ha a környezet változik, a szabályrendszert kézzel kell módosítani.

Ezzel szemben a neurális hálózatok adaptív, tanulásra képes modellek, amelyek nagy adathalmazokon tréningezve automatikusan felismerik a mintázatokat és összefüggéseket

(Olga Yegoshina, 2024). A neurális háló egy többrétegű, mesterséges neuronokból álló struktúra, amely megfelelő tanítás után bonyolult nemlineáris leképezést tud megvalósítani a bemenetek és kimenetek között. Előnye, hogy nagy tanulási kapacitással bír és nem kell explicit módon megadnunk a szabályokat; hátránya viszont, hogy egy „fekete doboz” jellegű modell, az eredményei mögötti logikát nehéz átlátni, és sokszor hatalmas mennyiségű adat kell a jó teljesítményéhez (Olga Yegoshina, 2024).

A neuro-fuzzy megközelítés arra épül, hogy a két módszert egyesítve kihasználjuk a fuzzy logika interpretálhatóságát és bizonytalanságkezelését, valamint a neurális háló adaptív tanulóképességét. Együttes alkalmazásukkal áthidalhatók a neurális és fuzzy módszerek korlátai, mivel a rendszer egyszerre képes tanulni és a tudást ember által értelmezhető formában megjeleníteni (Quang Hung Do, 2019). Másképpen fogalmazva: a neurális háló megtanítja a fuzzy rendszert a megfelelő szabályokra. A neuro-fuzzy rendszer valójában egy olyan fuzzy hálózat, amelynek működése egy fuzzy következtetési rendszert valósít meg, de a paramétereit automatikusan, tanulással hangolja be. Ennek köszönhetően a neuro-fuzzy rendszerek számos területen, a pénzügyi előrejelzéstől a képfelismerésig sikerrel bizonyítottak.

A neuro-fuzzy rendszerek egyik legismertebb és legszélesebb körben alkalmazott típusa az ANFIS (Adaptive Neuro-Fuzzy Inference System, magyarul Adaptív Neuro-Fuzzy Következtetési Rendszer). Ezt a modellt Jang vezette be 1993-ban (Jang, 1993), és mára a neuron-fuzzy módszerek egyik standard eszközévé vált. Az ANFIS tulajdonképpen egy Takagi–Sugeno típusú fuzzy rendszert valósít meg, melyet egy neurális hálózat tanít be. Míg egy hagyományos fuzzy inference system (FIS) esetében a Ha–akkor szabályokat teljes egészében szakértők határozzák meg, addig az ANFIS-ben a szabályrendszer és a tagfüggvények paramétereit automatikusan, a tanulási folyamat során alakulnak ki a bemeneti–kimeneti adatok alapján. Ezzel a megközelítéssel az ANFIS képessé válik bonyolult, nemlineáris függvények közelítésére, miközben a szabályok formájában történő tudásábrázolás miatt elvileg magyarázható marad a modell működése (Jang, 1993).

#### 2.2.4 Az ANFIS modell felépítése és működése

Az ANFIS modell egy olyan többrétegű hálózatként írható le, amely öt koncepcionális rétegre bontható (Al-Jarrah, 2021). Az első rétegben történik a fuzzifikáció, vagyis a bemeneti változók értékeinek hozzárendelése a megfelelő fuzzy halmazokhoz. Minden bemeneti változóhoz tartoznak előre definiált tagsági függvények (például egy kamatláb változóhoz olyan fuzzy halmazok, mint alacsony kamat, közepes kamat, magas kamat). Az első réteg minden neuronjának kimenete a bemenet egy tagsági fokát adja meg, jelezve, hogy az adott változó értéke mennyire tartozik például a „magas” vagy „alacsony” kategóriába (Al-Jarrah, 2021). A második rétegben a rendszer fuzzy szabályokat alkot, és meghatározza azok tüzelési erősségét. Itt minden neuron egy-egy szabályhoz tartozik, és a bemenetekhez tartozó tagsági fokok kombinálásával kiszámítja, milyen mértékben teljesül az adott, Ha  $x$  és Ha  $y$ , akkor  $z$  típusú szabály. A szabályok tipikusan a bemeneti változók valamely kombinációjára vonatkoznak (például: Ha a GDP növekedés közepes ÉS a munkanélküliség magas, akkor a tőzsdeindex csökken, ebben a szabályban két bemenet van, GDP és munkanélküliség, a kimenet pedig a tőzsdeindex irányára vonatkozó előrejelzés).

A harmadik réteg a normalizációs réteg (Al-Jarrah, 2021), amely biztosítja, hogy a különböző szabályok tüzelési erőssége összehasonlítható legyen. Minden egyes szabály erősségét elosztja a valamennyi szabály összesített erősségével, így a normalizált értékek összege 1 lesz. Ezzel gyakorlatilag súlyozottá válnak a szabályok: a legerősebb (leginkább teljesülő) szabály kapja a legnagyobb súlyt a következő lépésben, de egyik sem dominálhat teljes mértékben indokolatlanul. A negyedik rétegben kerül sor a következmények kiszámítására. Az ANFIS a Takagi–Sugeno fuzzy rendszer elvét követi, így minden fuzzy

Ha...akkor szabályhoz egy lineáris következményfüggvény tartozik. Ez praktikus azt jelenti, hogy minden szabály „akkor” része egy lineáris egyenlet, amely a bemeneti változóktól függ (Li C.G., 2005). A negyedik réteg minden neurona végrehajtja a saját szabályának ilyen következményfüggvényét a bemeneti adatokra, majd megszorozza azt a szabály normalizált tüzelési erősségével (így egy relevánsabb szabály következménye nagyobb súlyt kap). Az ötödik, utolsó rétegben az összegzés történik: a negyedik rétegben kapott (súlyozott) következmény-értékeket a rendszer összeadja, és ez adja a modell végső kimenetét (Li C.G., 2005). Ezzel megkapjuk az előrejelzett eredményt (például a következő időszaki részvényárfolyamot vagy EPS értéket) az adott bemenetek alapján.

A tanulási (tréning) folyamata az, ami igazán adaptívá teszi az ANFIS-t. A modell tanítása során rendelkezésre áll egy múltbeli adathalmaz, ahol ismertek a bemenetekhez tartozó kívánt kimeneti értékek (pl. múltbeli makrogazdasági adatokhoz tartozó tényleges részvényárfolyamok). Az ANFIS tanításakor a cél ezeknek az ismert értékeknek a minél pontosabb visszaadása, miközben a rendszer megtanulja a bemenet-kimenet kapcsolatot (Farhat, 2017). Ehhez általában egy hibrid tanulóalgoritmust alkalmaznak, amely két módszert kombinál: egyrészt least squares (legkisebb négyzetek módszere) az előbb említett lineáris következményfüggvények optimális paramétereinek megtalálására, másrészt gradiens módszer (például visszaterjesztéses hibaminimalizálás) a tagsági függvények paramétereinek finomhangolására (Farhat, 2017).

Az eljárás lényege, hogy felváltva becsüli meg a lineáris és nemlineáris paramétereket: a lineáris rész paramétereit egy lépésben, zárt alakban kiszámítja (amikor a fuzzy tagsági függvények adottak), majd a fuzzy tagsági függvények paramétereit frissíti kicsiny lépésekben a hiba gradiensek irányában. E két lépést ismételve az ANFIS hálózat tanulási algoritmusai igyekeznek minimalizálni az előrejelzési hibát (tipikusan a négyzetes hibát) (Li C.G., 2005).

A megfelelően betanított ANFIS modell ezután alkalmazható új, ismeretlen bemenetekre, és előrejelzéseket ad a kimenetre vonatkozóan.

Az ANFIS modell egyik vonzereje a testreszabhatóság és rugalmasság. A felhasználó maga választhatja meg, hány fuzzy halmazzal írja le az egyes bemeneti változókat, és ezek milyen alakúak legyenek (háromszög, trapéz, Gauss-görbe, szigmoid stb.). Gyakorlati tapasztalat, hogy a tagsági függvények alakja befolyásolhatja a modell teljesítményét, és sok esetben kísérletezéssel kell megtalálni az adott probléma számára legjobban megfelelő fuzzy halmazokat. Például egyes vizsgálatok szerint két-három trapéz alakú tagsági függvény bizonyult optimálisnak bizonyos részvényárfolyam előrejelzési feladatoknál, míg más esetekben a Gauss-féle görbék adtak simább illeszkedést. Az ANFIS előnye, hogy adatvezérelt módon is képes finomítani ezeket a tagsági függvényeket: a tanulás során a függvények paramétereit igazodnak a valós adatokhoz. Ez azt eredményezi, hogy a modell a kezdeti beállításoktól függetlenül a lehető legjobban próbálja közelíteni a megfigyelt összefüggéseket.

## 2.2.5 ANFIS alkalmazása pénzügyi előrejelzésekben

A pénzügyi előrejelzések területén az ANFIS modell alkalmazása ígéretes eredményeket hozott, különösen olyan feladatoknál, ahol a piaci folyamatok nemlinearitása és bizonytalansága meghatározó. A tőzsdei árfolyamok, a vállalati pénzügyi mutatók vagy éppen a piaci volatilitás előrejelzése mind olyan probléma, ahol a hagyományos lineáris modellek gyakran alulteljesítenek. Ezzel szemben a neuro-fuzzy megoldások, az adatvezérelt tanulás és a bizonytalanság kezelés kombinációjának köszönhetően jobban tudnak alkalmazkodni a bonyolult piaci mintázatokhoz. Például (Duy & Cuong, 2014) rámutatott, hogy a fuzzy logika beépítése lehetővé teszi a pénzügyi adatokban meglévő bizonytalanságok kezelését, ami kritikus a tőzsdei előrejelzésekben. Az ANFIS ebben a kontextusban azért különösen hasznos, mert hibrid modellként hatékonyan modellezi a gyakran előforduló, nemlineáris kapcsolatokat

a pénzügyi változók között. A lineáris regresszióval vagy döntési fákkal szemben, melyek csak korlátozottan képesek megragadni a komplex összefüggéseket az ANFIS jól boldogul az olyan bonyolult mintázatokkal és dinamikus kölcsönhatásokkal, amelyek a részvényárfolyamok és makrogazdasági vagy vállalati indikátorok között fennállnak.

Számos esettanulmány és kutatási eredmény támasztja alá az ANFIS hatékonyságát pénzügyi előrejelzésekben. Részvénypiaci előrejelzésekben az ANFIS rendre jobb teljesítményt nyújt, mint a hagyományos modellek (Esfahanipour, 2011). egy iráni tőzsdeindex, a TEPIX adatait vizsgálva kimutatták, hogy az ANFIS modell előrejelzései pontosabbak, mint egy hagyományos neurális hálós ugyanazon adatokon. Hasonlóképpen (Avci, 2010), az isztambuli tőzsdeindex (ISE National 100) havi hozamainak előrejelzésére fejlesztettek ki ANFIS modellt, és az eredmények lenyűgöző 98,3%-os pontosságot értek el. Ez az érték jóval meghaladta mind az ARIMA időjárás modellt, mind az egyszerű visszaterjesztéses neurális háló teljesítményét. Ilyen magas pontossági mutató azt jelzi, hogy az ANFIS ígéretes alternatívát kínál a részvénypiaci előrejelzésekhez, sok esetben felülmúlva a hagyományosabb megközelítéseket. Továbbá más kutatások is beszámoltak arról, hogy az ANFIS még összetett, kaotikus jellegű pénzügyi idősorok (pl. tőzsdei árfolyamok, indexek) esetén is hatékonyan működik, képes a zajos adatokból hasznos mintázatokat tanulni és ezáltal versenyképes előrejelzést adni.

Nemcsak indexek vagy árfolyamok közvetlen előrejelzésében, de pénzügyi mutatószámok és vállalati teljesítmény becslésében is alkalmaztak ANFIS-t. Különösen a banki és vállalati fundamentális mutatók (melyek a vállalat pénzügyi egészségét jellemzik) és a részvényárfolyamok kapcsolata terén bizonyult hasznosnak ez a modell.

Egy átfogó kutatásban a részvényárfolyamok előrejelzéséhez négy kulcsfontosságú mutatót használtak fel: a saját tőke arányos jövedelmezőséget (ROE), az eszközarányos nyereséget (ROA), az egy részvényre jutó eredményt (EPS) és a nyereséghányadot (profit margin). ANFIS modell alkalmazásával azt találták, hogy e négy mutató együttes használata biztosította a legmagasabb előrejelzési pontosságot és megbízhatóságot. Amikor tesztelésképpen a mutatók közül egyet-egyet kihagytak, az előrejelzés pontossága jelentősen romlott, és az eredmények ingadozóbbá váltak. Ez rámutat arra, hogy az ANFIS képes feltárni a pénzügyi mutatók szinergikus hatását, azaz a különböző bemenő változók együtthatása révén jobb előrejelzést ad, mint ha ezeket külön-külön használnánk. Külön kiemelendő az EPS szerepe: több tanulmány is alátámasztja, hogy az EPS az egyik legfontosabb tényező a részvényárfolyamok előrejelzésében.

## 2.2.6 Előnyök, korlátok és további megfontolások

A hibrid neuro-fuzzy modellek (és különösen az ANFIS) számos előnyt kínálnak a pénzügyi előrejelzések terén. Először is, képesek egyidejűleg kezelni a bizonytalanságot és a komplex mintázatokat. A fuzzy komponens révén a modell figyelembe tudja venni, hogy a pénzügyi adatok nem éles határú kategóriákba esnek, hanem gyakran bizonytalanok vagy zajosak. Ennek köszönhetően rugalmasabban reagál olyan helyzetekben, amikor a piaci változást több, nehezen számszerűsíthető tényező befolyásolja (Barlybayev, 2023).

Másodszor, az ANFIS a neurális háló adaptív tanulását használva automatikusan feltárja az összefüggéseket a bemenetek és a kimenet között, mégpedig úgy, hogy közben emberileg értelmezhető szabályok formájában is reprezentálja a tudást. Ez az elvi interpretálhatóság fontos lehet a pénzügyi döntéshozatalban, ahol nemcsak az a lényeg, hogy mi a modell előrejelzése, hanem az is, hogy miért, azaz milyen indokok (szabályok) alapján jutott arra. (Sagir, 2017) Harmadrészt, a gyakorlati tapasztalatok szerint az ANFIS valóban segíthet növelni az előrejelzések pontosságát. Több példát is láttam arra, hogy kisebb hiba, magasabb találati arány érhető el vele, mint más módszerekkel.

Ez különösen igaz olyan helyzetekben, amikor több különböző input tényező együtt határozza meg az eredményt: ilyenkor a neuro-fuzzy modell jobban ki tudja aknázni a változók együttes információtartalmát (Barlybayev, 2023).

Fontos azonban látni az ANFIS korlátait és kihívásait is. Noha a fuzzy szabályok elvileg átláthatóvá teszik a modellt, egy nagy kiterjedésű ANFIS esetében, ahol sok bemenet és ennek nyomán nagyon sok fuzzy szabály van a létrejövő szabályrendszer igen összetetté és nehezen értelmezhetővé válhat. Egyes esetekben épp az lehet a probléma, hogy az ANFIS által generált szabályok száma és bonyolultsága túl nagy, ami megnehezíti a döntéshozók számára az eredmények értelmezését. (Salleh, 2017) Ezért a modellezőnek ügyelnie kell a rendszer felépítésére: a bemenetek számát ésszerű keretek között kell tartani, illetve célszerű lehet klaszterezési módszerekkel vagy szakértői tudás bevonásával csökkenteni a lehetséges szabályok számát (például bemenetenként kevesebb fuzzy halmaz definiálásával vagy a kevésbé fontos változók kiszűrésével) (Salleh, 2017). További kihívás, hogy az ANFIS is, mint minden tanuló algoritmus hajlamos lehet a tútanulásra, ha nem megfelelően validáljuk. Ha túl sok paramétert használ kevés adatra, előfordulhat, hogy a modell túlzottan a történelmi adatok zajára hangolódik rá, és ez a jövőbeli előrejelzéseket rontja. E kockázat csökkentésére bevált gyakorlat az adathalmazokat tréning, validációs és teszt halmazokra bontani, illetve keresztvalidációt alkalmazni, hogy a modell valódi generalizációs képességét mérjük (Salleh, 2017).

Érdeemes azt is megjegyezni, hogy az ANFIS modellek hatékonysága ellenére a gyakorlati alkalmazásukhoz szakértelem szükséges. A felépítés és tanítás folyamatában számos döntést kell meghozni: mely bemenő változókat használjuk, milyen fuzzy halmazokat definiáljunk, hány szabályt engedjük a rendszernek, milyen legyen a tanulási ráta, stb. Ezek a beállítások mind befolyásolhatják a végeredményt. A legújabb kutatások egy része éppen arra fókuszál, hogy ezeket a döntéseket is automatizálja vagy optimalizálja, például genetikus algoritmusokkal keresve meg az optimális tagsági függvény paramétereket az ANFIS számára, illetve, hogy az ANFIS-t más modern technikákkal ötvözze. Léteznek például hierarchikus ANFIS modellek vagy állapotér-alapú ANFIS (State-ANFIS) megközelítések, amelyek még tovább fokozhatják a teljesítményt bizonyos feladatoknál (Do, 2013).

A pénzügyi előrejelzésekben is megjelentek már olyan hibrid megoldások, ahol az ANFIS egy nagyobb keretrendszer része: például előfeldolgozó komponensekkel vagy más tanuló algoritmusokkal együtt dolgozik a még jobb predikció érdekében.

A hibrid mesterséges intelligencia rendszerek új távlatokat nyitottak a pénzügyi előrejelzésekben. Képesek emberközelibb módon megragadni a piac mozgatórugóit, hiszen egyszerre tanulnak a történelmi adatokból és kezelik rugalmasan a bizonytalanságot. Számos kutatás és példa igazolja, hogy ezek a modellek növelni tudják az előrejelzések pontosságát, legyen szó részvényárfolyamokról, banki eredményességi mutatókról (mint az EPS) vagy más pénzügyi idősortokról. Ugyanakkor bevezetésük és használatuk hozzáértést kíván, és nem szabad megfelekedezni a modell összetettségéből fakadó kihívásokról sem. Megfelelő alkalmazás esetén azonban az ANFIS és más hibrid MI technikák értékes eszközt jelentenek a pénzügyi elemzők és döntéshozók kezében, lehetővé téve a pontosabb, megbízhatóbb prognózisokat egy olyan területen, ahol minden információmorzsa és előrejelzési pontosság óriási jelentőséggel bír.

### 3. Kutatásmódszertan

A kutatásom során egy ANFIS (Adaptív Neurális Fuzzy Inferencia Rendszer) modell felépítését és alkalmazását tűztem ki célul, amellyel előrejelzem európai bankok EPS értékét (egy részvényre jutó eredmény). A folyamat több egymásra épülő lépésből állt, saját magam végezve az adatelőkészítést, a modellépítést és a kiértékelést.

Első lépésként az adatok előkészítésére fókuszáltam. Összeállítottam egy adatbázist európai bankok történelmi pénzügyi mutatóiból és EPS értékeiből, több évet és több intézményt felölelve. A cél az volt, hogy elegendő mennyiségű és sokféle adat álljon rendelkezésre a modell tanításához és teszteléséhez. Az adatgyűjtést követően nagy hangsúlyt fektettem az adattisztításra: azonosítottam és kezeltem a hiányzó vagy kirívó értékeket, mivel ezek torzíthatják volna a modell tanulását. Ezt követően normalizáltam a változókat, hogy az eltérő mértékegységű és nagyságrendű pénzügyi mutatók összemérhetőek legyenek. A normalizálás azért is volt kritikus, mert a neurális hálózat és fuzzy logika kombinációjából álló ANFIS érzékeny lehet a nyers adatok skálájára, a skálázással biztosítottam a stabil tanulást és azt, hogy egyik bemeneti tényező se uralja aránytalanul a modellt.

Az ANFIS modell felépítését MATLAB szoftverkörnyezetben végeztem, a Fuzzy Logic Toolbox eszközeit felhasználva. A modell bemeneteit több pénzügyi mutató alkotta, ilyenek például a tőke megtérülés (ROE), az eszközarányos nyereség (ROA), a profitmargó vagy más banki teljesítménymutatók, míg a kimeneti változó a bankok EPS értéke volt. A bemeneti változókhoz fuzzy halmazokat rendeltem, amelyek nyelvi kategóriákkal írják le a mutatók szintjét (például egy mutató értékét tekintve lehet alacsony, közepes vagy magas). Kezdetben három fuzzy halmazzal reprezentáltam minden bemeneti változót, ami tipikusan megfelelt a "alacsony/közepes/magas" kategóriáknak. Később a kísérletet kiterjesztettem négy fuzzy halmazra is, hogy finomabb felbontásban (nagyon alacsony, alacsony, közepes, magas vagy hasonló kategóriákban) is megvizsgáljam a modell teljesítményét. A fuzzy halmazok számának növelésétől azt vártam, hogy pontosabb előrejelzést tesz lehetővé a modell a részletesebb kategorizálás révén, bár tudatában voltam annak is, hogy a több szabály és paraméter magasabb összetettséghez és esetleg túlillesztéshez vezethet.

A kutatás egyik központi kérdése az volt, hogy a tagsági függvények formája hogyan befolyásolja a modell előrejelzési pontosságát. Négy különböző tagsági függvény-típust vizsgáltam meg: háromszög, trapéz, Gauss és szigmoid tagsági függvényeket. Mindegyik tagsági függvény eltérő módon írja le, hogy a bemeneti értékek hogyan tartoznak a fuzzy halmazokba, és így eltérő átmenetet biztosít a fokozatos vagy éles kategória-váltások között. A háromszög és trapéz alakú tagsági függvények viszonylag egyszerű, lineáris lefutásúak, ezek könnyen értelmezhetők, hiszen a tagság foka az érték növekedésével egyenes vonal mentén változik. A Gauss-görbe egy sima, harang alakú függvény, amely finomabb átmenetet ad: az értékek növekedtével fokozatosan éri el a tagság a maximumát, majd csökken, így jól kezeli a szélsőértékeket és a középpérték körüli koncentrációkat. A szigmoid függvény S-alakú lefutása révén aszimmetrikus kategorizálást is megenged: az alacsony és magas értékek felé lassan telítődik 0 illetve 1 értékhez, ami például akkor lehet előnyös, ha egy változó esetében a nagyon alacsony és nagyon magas tartomány is lényeges, de középen egy gyorsabb átmenet indokolt. Tudtam, hogy az ANFIS modell teljesítményét érzékenyen érinti a választott tagsági függvény típusa, ezért minden felsorolt típussal elvégeztem a modellezést. Minden tagsági függvény esetén lefuttattam a modellt a két említett fuzzy halmaz konfigurációval (három, illetve négy halmaz), összesen tehát nyolc különböző konfigurációban. Céлом az volt, hogy kiderítsem, melyik tagsági függvény adja a legjobb előrejelzési pontosságot az EPS-re vonatkozóan.

A modell tanításához és teszteléséhez az előkészített adatbázist kettéosztottam: egy tanító (tréning) halmazra és egy tesztelő (ellenőrző) halmazra. Az adatok véletlenszerű sorrendjét biztosítva 70-30% arányban választottam szét a teljes mintát, ahol a nagyobb rész szolgált a

tanításhoz, a kisebb pedig a független teszteléshez. Így próbáltam garantálni, hogy a modell értékelése valós, ismeretlen adatokon történjen. A MATLAB ANFIS implementációja lehetővé tette, hogy a tanítás során egy hibrid tanulóalgoritmust alkalmazzak: ez felváltva használ legkisebb négyzetek módszerét és visszaterjesztéses hibaminimalizálást a paraméterek frissítésére. Egyszerűen fogalmazva, a tanítási folyamat ismétlődő: a fuzzy szabályrendszer következtetéseit kiigazítja a neurális hálózat tanulása, amíg a modell minél jobban hozzá nem idomul az adatokhoz. Ennek a megközelítésnek nagy előnye, hogy a modell automatikusan hangolja finomra a tagsági függvények paramétereit és a fuzzy szabályok következtetéseit, így emberi beavatkozás nélkül tanul az adatokból. A hibrid algoritmus egyensúlyt teremt a két világ között: a neurális hálózat rugalmasságát kihasználva csökkenti a hibát, miközben a fuzzy logika révén átlátható marad a modell működése. Minden egyes modell-konfiguráció esetén ugyanazt a tanítási beállítást alkalmaztam (ugyanannyi iterációs lépés, ugyanaz a konvergenciakritérium), és ugyanazzal a tanító/teszt adatszettel dolgoztam, hogy az eredmények összehasonlíthatók legyenek. A tanítás folyamán figyeltem arra is, hogy ne forduljon elő túltanulás: ehhez a MATLAB ellenőrző („checking”) adathalmazát is figyelembe vettem, amely segítségével korán észlelhető, ha a modell a zajt próbálná megtanulni ahelyett, hogy az általános mintázatokat sajátítaná el. Amint azt láttam, hogy a tesztalmazon a hiba növekedni kezd (miközben a tréningalmazon még csökken), megállítottam a tanulást, ezzel a stratégiával igyekeztem megóvni a modellt a túlillesztéstől, és biztosítani, hogy az valóban általánosítható tudást szerezzen.

Miután az összes konfiguráció esetében betanítottam az ANFIS modellt, a teljesítmény kiértékelése és összehasonlítása következett. Kvantitatív metrikaként az RMSE-t (Root Mean Squared Error, azaz gyök-négyzetes hiba) alkalmaztam, mivel ez jól összegzi az előrejelzési pontatlanságot: megmutatja, átlagosan mekkora eltérés várható az előrejelzett EPS és a valós érték között. Minden modellnél kiszámoltam az RMSE értékét a tanító adathalmazra és a tesztelő adathalmazra is. A két érték összevetése fontos információkat hordozott: ha egy modell a tanító adatokon nagyon kis hibát ért el, de a tesztadatokon lényegesen nagyobb, az arra utalt, hogy túlillesztés történt (a modell “bemagolta” a tanító adatokat, de az új adatoknál romlik a teljesítmény). Ezzel szemben egy olyan modell, amelynél a tanítási és tesztelési RMSE is hasonlóan alacsony, robosztusabb, általánosabb érvényű előrejelző. Az RMSE számszerű eredményei mellett grafikus módszerekkel is értékeltem a modelleket: minden konfigurációnál ábrát készítettem, amelyen összehasonlítottam az ANFIS által előrejelzett EPS értékeket a tényleges, valós EPS értékekkel. Ezeket a görbéket mind a tanításhoz használt időszakokra, mind a tesztidőszakokra ábrázoltam. A vizuális összehasonlítás segített észrevenni az esetleges trendeket vagy mintázatokat az eltérésekben. Például, rögtön szembeötlő volt, ha egy modell valamelyik bank esetében rendszeresen alulbecsülte vagy felülbecsülte az EPS-t, vagy ha bizonyos években nagyobb kilengéseket mutatott az előrejelzés a tényadatokhoz képest. Ezek a vizuális visszajelzések kiegészítették a számokban kifejezett hibamértékeket: sokszor könnyebb értelmezni egy grafikon alapján, hogy a modell hol teljesít jól és hol gyengébben, mintha csak egyetlen hibaszámot néznénk. Így én magam is jobban megértettem a modellek viselkedését.

Az eredmények összehasonlítása során rendszereztem, hogy melyik tagsági függvény-típus és fuzzy halmaz kombináció hogyan teljesített. Áttekintettem a tréning és teszt RMSE értékeket, valamint a hozzájuk tartozó előrejelzési görbéket. Az értékelés célja az volt, hogy azonosítsam a legjobb modellt az EPS előrejelzésére, valamint következtetéseket vonjak le arra vonatkozóan, miért teljesített jobban az adott konfiguráció. A különböző tagsági függvények összevetése rávilágított bizonyos összefüggésekre: például a bonyolultabb, simább függvények (mint a Gauss vagy a szigmoid) esetében azt vártam, hogy rugalmasabban

trapéz függvények esetleg stabilabbak, de kevésbé pontosak lesznek. Ezek a feltevések részben beigazolódtak a kísérlet során, de a pontos eredmények az egyes modellek hibamértékeiből derültek ki. A kiértékelés során azt tapasztaltam, hogy bizonyos konfigurációk hajlamosak voltak a túlillesztésre: például némely tagsági függvény esetén a tréning hiba gyakorlatilag nullához közeli lett, miközben a teszthiba jóval magasabb maradt. Ez arra utalt, hogy az a modell túl sok szabadságfokkal rendelkezett, túl jól illeszkedett a tanító adatokhoz, de ezzel elvesztette a generalizáló képességét. Ezzel szemben volt olyan konfiguráció, ahol a tréning hiba valamivel magasabb maradt, viszont a tesztalmazon kiemelkedően alacsony hibát értem el. Ez a fajta teljesítmény jelezte, hogy az a modell megtalálta a megfelelő egyensúlyt a tanulásban, és valószínűleg ez az ANFIS konfiguráció adja a legpontosabb előrejelzést a vizsgált EPS adatokra.

## 4. Eredmények összegzése

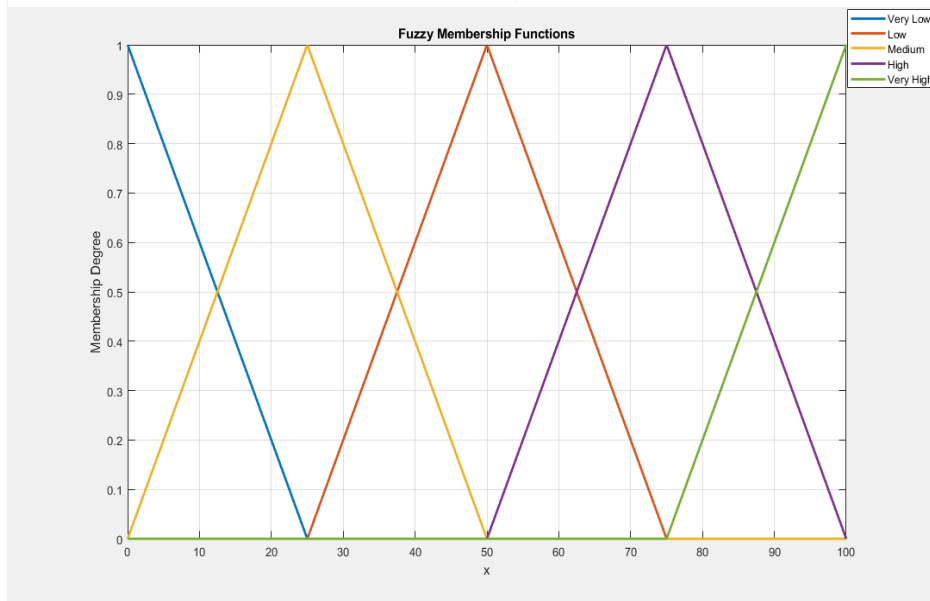
### 4.1 A vizsgált modellek és koncepciók bemutatása

A dolgozat központi célja az volt, hogy összehasonlítsam különböző ANFIS modellek előrejelzési pontosságát, amelyeket eltérő tagsági függvényekkel építettem fel. Négy tagsági függvény-típust vizsgáltam meg: háromszög, trapéz, Gauss és szigmoid alakú tagsági függvényeket. Emellett két különböző fuzzy halmazszám-konfigurációt alkalmaztam: az egyik esetben három fuzzy halmazt (tagsági függvényeket) rendeltem minden bemeneti változóhoz, a másik esetben pedig négy fuzzy halmazt. Így összesen nyolc különböző ANFIS modell-konfigurációt hoztam létre és tanítottam be. Minden modell ugyanazzal a strukturális felépítéssel (Takagi–Sugeno-típusú következtetés, ugyanazok a bemenő változók és kimenet) rendelkezett, az egyetlen különbséget a tagsági függvények formája és a fuzzy halmazok száma jelentette. Ennek köszönhetően az eredmények összehasonlítása objektív lehet: kizárólag a tagsági függvény típusa és a halmazok száma befolyásolja a teljesítmény különbségeit.

A fuzzy halmazok számának növelése mögött az az elképzelés állt, hogy a finomabb kategorizálás révén a modell pontosabban tud alkalmazkodni az adatokhoz. Három fuzzy halmaz esetén a tipikus nyelvi kategóriák például "alacsony", "közepes" és "magas" értékek, míg négy halmaznál bevezethető egy további szint, például "nagyon alacsony" vagy "nagyon magas" kategória a szélsőségek jobb leírására. Arra számítottam, hogy a több kategória részletesebb szabályrendszert eredményez, ami potenciálisan csökkenti az előrejelzési hibát, hiszen a modell finomabban tudja közelíteni a nemlineáris összefüggéseket. Ugyanakkor tudatában voltam annak is, hogy a fuzzy halmazok számának növelése a szabályok számának robbanásszerű növekedéséhez vezet. Ha például  $n$  darab bemeneti változó van, akkor három fuzzy halmaz esetén maximum  $3^n$  darab szabály keletkezhet az ANFIS modellben, négy halmaznál pedig  $4^n$  szabály. Néhány bemenet esetén ez a különbség is jelentős: például négy bemenő változónál 81 szabály helyett 256 szabályt kell a modellnek megtanulnia. Az extra szabályok több paramétert jelentenek, ami megnöveli a modell komplexitását, és ezzel együtt fennáll a túlillesztés (overfitting) veszélye is, vagyis, hogy a modell túlságosan "bemagolja" a tanító adatokat, és ezáltal rosszabbul teljesít új (teszt) adatokon. Már a kísérlet tervezésekor fontos szempont volt ez: vajon a részletesebb fuzzy partíciók mennyit javítanak a pontosságon, és megéri-e esetlegesen feláldozni az egyszerűbb modell előnyét a bonyolultabbért?

A kutatás másik kulcskérdése a tagsági függvények formájának hatása volt. Az ANFIS modellben a tagsági függvények határozzák meg, hogy a bemeneti változók különböző értékei milyen mértékben tartoznak az egyes fuzzy halmazokba. Különböző függvényformák eltérő módon írják le ezt a tagsági fokozatosságot. Az alábbi négy típust vizsgáltam:

**1. ábra** Általános háromszög tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB)

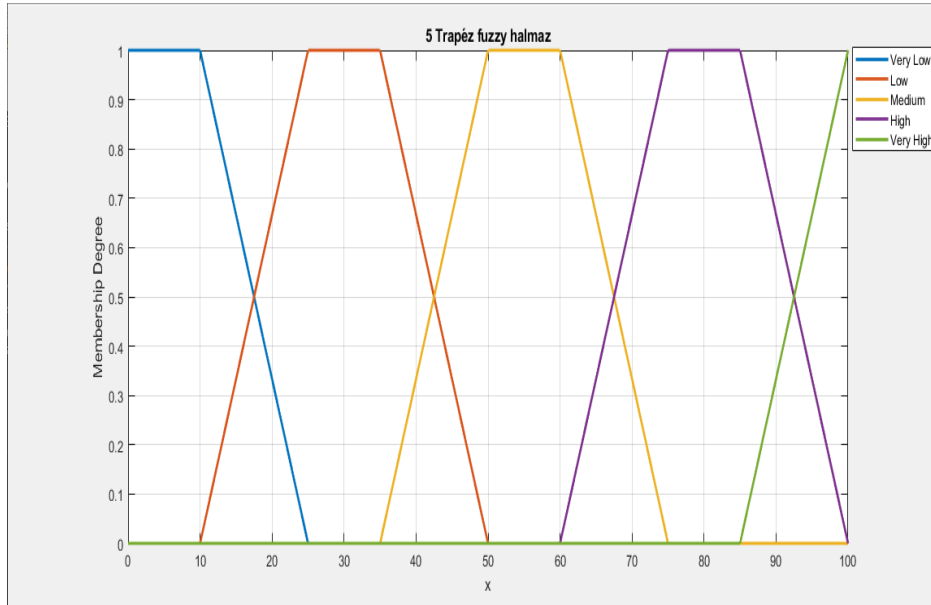


Háromszög alakú tagsági függvény: Egy egyszerű, lineáris lefutású függvény, amely egy adott tartomány közepén éri el a 1 tagsági értéket, és attól balra és jobbra lineárisan csökken 0 felé. Előnye az érthetőség: a tartomány lineáris felosztása miatt könnyű interpretálni, hogy például mely értékeket tekintünk "közepesnek". Ugyanakkor a háromszög függvény éles törésponttal rendelkezik a csúcson és a széleken (ott éri el a 0 értéket), így a kategóriák között viszonylag hirtelen váltást jelent.

$$\mu(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b < x < c \\ 0, & x \geq c \end{cases}$$

**1. Egyenlet** A háromszög tagsági függvény lineárisan növekszik, majd csökken, és három pont (a, b, c) segítségével definiálható. Egyszerű, jól átlátható forma, amely éles kategóriákat alkot.

2. ábra Általános trapéz tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB)




Trapéz alakú tagsági függvény: Hasonló a háromszöghöz, de a csúcsát egy plató jellemzi (tehát nem egy ponton, hanem egy intervallumon át 1 a tagsági érték). Ez azt eredményezi, hogy van egy értéktartomány, amelyet a fuzzy halmaz teljes egészének tekintünk. Például egy "közepes" kategória trapéz függvénnyel azt jelentheti, hogy egy bizonyos intervallumban minden érték teljes joggal közepesnek számít, nem csak egy konkrét érték környezetében. A trapéz függvény előnye, hogy rugalmasabban kezeli a kategóriahatárokat: kevésbé érzékeny a kis változásokra, ha azok a plató tartományában történnek. Arra számítottam, hogy a trapéz alakú tagsági függvények valamelyest pontosabbak lehetnek, mint a háromszög alakúak, mivel kevésbé szigorú a kategóriaváltás, de a különbség nem feltétlenül lesz nagyon nagy, hiszen alapvetően mindkettő lineáris jellegű függvény.

$$\mu(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ 1, & b < x \leq c \\ \frac{d-x}{d-c}, & c < x \leq d \\ 0, & x \geq d \end{cases}$$

**2. Egyenlet** A trapéz tagsági függvény a háromszög általánosítása, amely egy vízszintes „platót” is tartalmaz. Ez a forma robusztusabb, és nagyobb bizonytalansági sávokat kezel.

3. ábra Általános Gauss tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB)

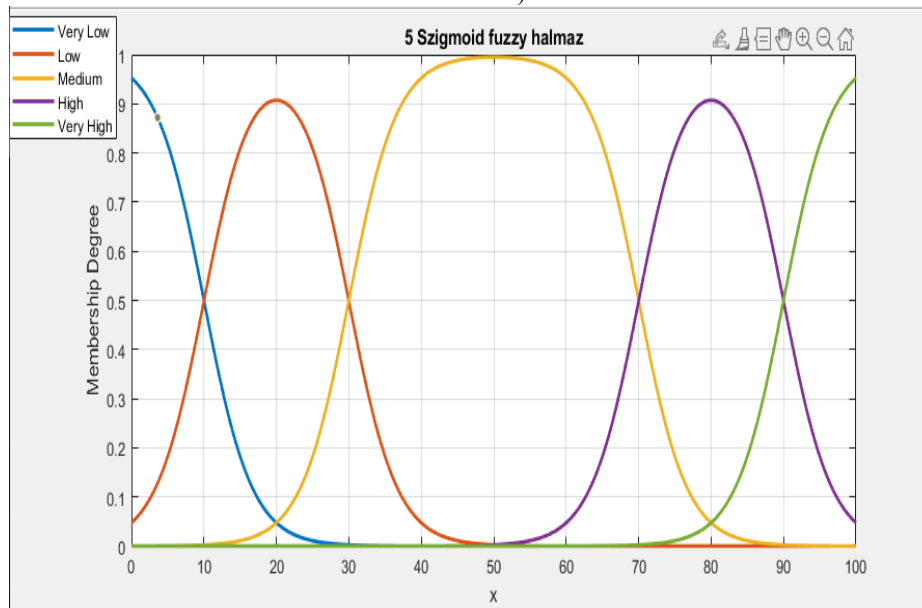


Gauss-görbe (Gauss alakú tagsági függvény): Egy folytonos, harang alakú görbe, amely a statisztikából ismert normál eloszlás sűrűségfüggvényéhez hasonlóan viselkedik. Értéke sosem éri el pontosan a 0-t (csak tart felé a végtelenben), így elméletileg az egész számegyenesen van némi tagsági fok, de a csúc környezetében koncentráliódik a magas tagság. A Gauss-függvény nagyon simán változik, nincsenek benne töréspontok. Az érték növekedtével fokozatosan éri el a maximumot, majd ugyanilyen simán csökken. Ebből fakadóan jól kezeli az olyan eseteket, amikor a bemeneti változó eloszlása vagy a kimenettel való kapcsolata nemlineáris, és nincs éles határ két kategória között. A Gauss tagsági függvények alkalmazásával azt vártam, hogy a modell rugalmasabban tud alkalmazkodni a bonyolult mintázatokhoz, így kisebb előrejelzési hibát érhetünk el, mint a háromszög vagy trapéz esetében. Ugyanakkor a Gauss-függvény alkalmazása kevesebb interpretálható paraméterrel jár (csak a középvértéket és szórását hangolja), így kevésbé átlátható, mint egy háromszög esetében a kategóriahatárok.

$$\mu(x; c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}}$$

**3. Egyenlet** A Gauss tagsági függvény haranggörbe alakú, amely fokozatos és sima átmenetet biztosít a kategóriák között. Különösen hatékony, ha az adatok nem diszkrét, hanem folytonosan változnak.

4. ábra Általános szigmoid tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB)



Sigmoid (S-alakú) tagsági függvény: Az S-görbe egy olyan monoton növekvő függvény, ami az alacsony értékeknél lassan emelkedik nulláról, a középső tartományban meredeken nő, majd a magas értékeknél ismét ellaposodik és közelít az 1 értékhez. Az aszimmetrikus lefutás miatt a szigmoid függvény érdekessége, hogy segítségével különbséget tehetünk a két szélső tartomány eltérő jelentősége között. Például, ha egy bemeneti változónál a nagyon alacsony és a nagyon magas értékek is kritikusak, a szigmoid függvény "két vége" ezt lehetővé teszi: az egyik (bal oldali) szigmoid függvénnyel definiálhatunk egy "alacsony" fuzzy halmazt, a másik (jobb oldali inverz szigmoid) pedig egy "magas" halmazt, a köztes tartományban pedig ezek átfedése adja ki a "közepes" értékeket. A MATLAB Fuzzy Toolbox lehetővé tette ilyen szigmoid függvények használatát a fuzzy halmazok meghatározására. A szigmoid tagsági függvényektől azt vártam, hogy hasonlóan jó (ha nem jobb) eredményt adnak, mint a Gauss-függvények, különösen akkor, ha a bemeneti adatok eloszlása vagy a kimenő EPS-sel való kapcsolata aszimmetrikus. Ugyanakkor a szigmoid függvények paraméterezése is több szabadságfokot ad (esetenként egy fuzzy halmaz definiálásához két szigmoid kombinációja is szükséges lehet), ami szintén a komplexitást növeli.

$$\mu(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$$

$$\mu(x; a, c) = \frac{1}{1 + e^{a(x-c)}}$$

**4. Egyenlet** A szigmoid tagsági függvények monoton növekednek vagy csökkennek. Kombinálva őket dombszerű függvény is kialakítható, ami jól használható középső, átmeneti tartományokhoz.

Tehát a kísérleti keret a következő volt: minden tagsági függvény típussal futtattam egy ANFIS modellt három fuzzy halmazzal, majd négy fuzzy halmazzal is. Így összesen nyolc modell készült el. Minden modell tanításához ugyanazt a tanító és teszt adathalmazt használtam fel, változtatás nélkül. Az adatok európai bankok történelmi pénzügyi mutatóiból és EPS értékeiből álltak össze, 10 év adatait felölelve. A modell kimeneti változója az EPS (egy részvényre jutó nyereség) volt, a bemeneti változók pedig a bankok bizonyos pénzügyi mutatói, amelyekről a korábbi fejezetekben szó esett. Minden modellt ugyanúgy konfiguráltam a tanítási paraméterek szempontjából (ugyanannyi maximális epoch szám, ugyanaz a tanulási ráta stb.),

és alkalmaztam egy korai megállítási kritériumot is a túlillesztés elkerülése érdekében: egy úgynevezett ellenőrző adathalmazt (validation set) is használtam, amelyet a tréning során figyeltem. Amint azt láttam, hogy az ellenőrző halmazon mért hiba elkezd növekedni (miközben a tanító halmazon még csökken), leállítottam a tanulást. Ezzel a módszerrel igyekeztem biztosítani, hogy egyik modell se tanulja túl magát feleslegesen sok iterációval. Természetesen ennek ellenére is előfordulhat, hogy egy bonyolultabb modell már a korai megállítás optimális pontján is túlillesztés jeleit mutatja a kevésbé komplex modellekhez képest, ezt az eredményeknél külön ki fogom emelni.


## 4.2 Modellkonfigurációk értékelése - 3 tagsági függvény

Ebben az alfejezetben a három fuzzy halmazzal (azaz bemeneti változónként három tagsági függvénnyel) felépített ANFIS modellek eredményeit ismertetem. Négy modellt hasonlítok össze, amelyek csak a tagsági függvény típusaiban különböznek: a háromszög, trapéz, Gauss és szigmoid tagsági függvényekkel tanított modellek. Mindegyik esetben megnéztem a tanító adathalmazon elért hibát és a teszt adathalmazon mért hibát, valamint az előrejelzett és tényleges EPS értékek görbéit.

### Lineáris tagsági függvények (háromszög és trapéz)

Elsőként tekintsük a háromszög tagsági függvényekkel működő, 3 fuzzy halmazos modellt, amely egyfajta alapesetnek tekinthető. A modell tanítása során a hibamérték fokozatos csökkenését figyeltem meg, és a tréning végére a háromszög modell megközelítőleg  $RMSE = 0,008$  értéket ért el a tanító halmazon. Ez azt jelenti, hogy átlagosan ennyi egységgel tért el a becsült EPS a valós EPS-től a tanítási adatokon. A modell tesztelésekor az  $RMSE$  érték valamelyest megnőtt, nagyjából 1,066 körüli értéket vett fel a teszt halmazon. Ez a különbség (0,008 vs. 1,066) arra utal, hogy a modell a tanulási adatokhoz képest a tesztadatokon kevésbé

**5. ábra** A háromszög tagsági függvényekkel működő ANFIS modell előrejelzése (3 fuzzy halmaz). A predikció (piros vonal) több ponton is eltér a valós EPS értékektől (kék vonal), különösen az éles változásoknál. (Forrás: Saját szerkesztés, MATLAB.)




pontos. Ez a modell korlátozott komplexitására vezethető vissza, mintsem túlillesztésre, magyarul a háromszög modellem kicsit alul illesztett maradt: nem tudta az összes mintázatot

tökéletesen megragadni, de cserébe nem is adaptálódott túlzottan a zajhoz. Az előrejelzési grafikonon (lásd 5. ábra) jól látszik, hogy a háromszög tagsági függvényekkel dolgozó modell nagyléptékben követi az EPS alakulását, de a finomabb ingadozásokat nem mindig tudja lekövetni. Például amikor az egyik bank EPS-e hirtelen megugrott egy kedvező pénzügyi évben, a modell előrejelzése is emelkedett, de lemaradással és tompítva: csupán a következő negyedév során zárkozott fel a valós értékhez, és a csúcsot is alacsonyabban jelezte előre, mint ami ténylegesen bekövetkezett. Hasonlóképpen, egy visszaesésnél a modell csak részben esett az EPS-sel, utána viszont a trendfordulót is késleltetve érzékelte. Ezek a mintázatok arra utalnak, hogy a háromszög modell előrejelzése hajlamos az átlagos tartományba húzni az értékeket, vagyis a nagyon magas EPS-t alulbecsüli, a nagyon alacsonyt felülbecsüli, ami egy gyakori jelenség a korlátozott komplexitású előrejelző modelleknél.

A trapéz tagsági függvényekkel működő modell eredményei sok szempontból hasonlóak voltak a háromszög modelléhez, hiszen e két függvénytípus rokonságban áll egymással. A trapéz modell tanítási hibája  $RMSE = 0,004$  körül alakult, ami valamivel alacsonyabb, mint a háromszög esetében, tehát a trapéz tagsági függvényekkel a hálózat kicsit jobban rá tudott simulni a tanító adatokra. A tesztalmazon mért hiba kb. 1,015 lett, ami szintén egy árnyalattal jobb, mint a háromszög modell értéke. Ez a kis különbség azt jelzi, hogy a trapéz modell enyhe előnyre tett szert a háromszöghöz képest, feltehetően annak köszönhetően, hogy a trapéz tagsági

**6. ábra** Trapéz tagsági függvényekkel készült ANFIS modell előrejelzése (3 fuzzy halmaz)  
(Forrás: Saját szerkesztés, MATLAB.)



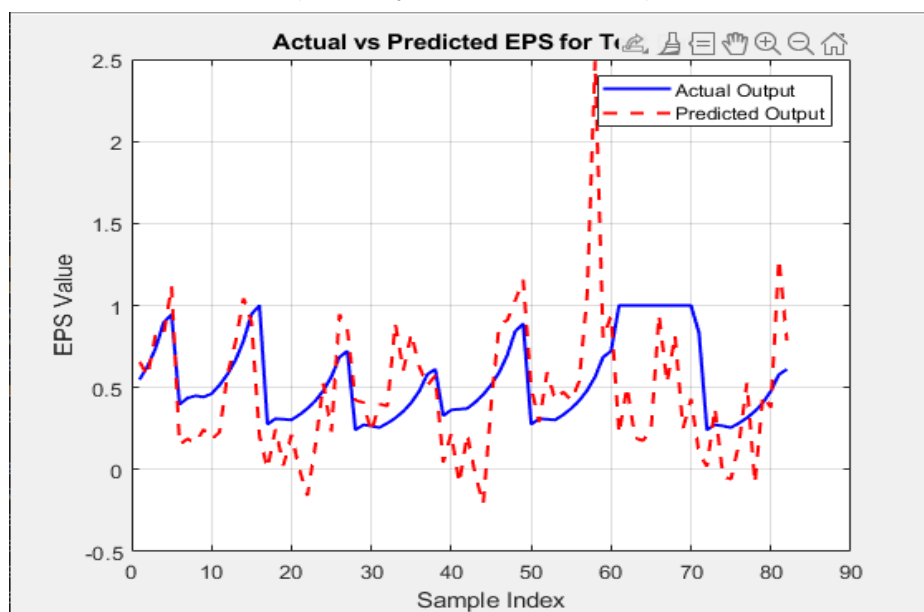
függvény lapos teteje rugalmasabban enged egy-egy bemeneti értéktartományt "teljesen" egy adott fuzzy halmazhoz sorolni. Az előrejelzési grafikon (lásd 6. ábra) azt mutatja, hogy elsősorban azokban az időszakokban szerepelt kiegyensúlyozottan, amikor az EPS értékek kevésbé ingadoztak, azaz egyfajta stabil vagy enyhén emelkedő vagy csökkenő trendet követtek. Az egyik ilyen példát a grafikon középső részén láthatjuk, ahol 45 és 50 közötti mintapontoknál az EPS értékek mérsékelten csökken. A trapéz modell előrejelzései ezeken a pontokon kiszámíthatóan és zökkenőmentesen illeszkedtek a valós adatokhoz. Ez a stabilitás abból ered, hogy a trapéz tagsági függvénynek létezik egy „teljes tagságú” szakasza, amely nem csupán egyetlen pontra, hanem egy egész értéktartományra biztosít 1-es tagsági értéket, így a modell a bemeneti változók hasonló értékei esetén sem kezd el hirtelen módosítani a kimeneten. Kiemelendő azonban, hogy a jelentősebb eltérések nem csak kis amplitúdójú kilengések formájában jelentkeznek. A grafikon jobb szélén, az 55 és 75 közötti mintapontoknál, ahol egy

markáns EPS-ugrás figyelhető meg a valós adatsorban, mindkét modell nehézségekbe ütközött a változás mértékének és ütemének pontos követésében. Itt mind a két modell túlságosan túlreagálta és utána ingadozásokkal korigált, ezzel további hibát halmozva fel.

### Nemlineáris tagsági függvények (Gauss és szigmoid)

Ezzel szemben a Gauss és szigmoid tagsági függvényeket használó modellek már jóval pontosabb előrejelzéseket adtak a három fuzzy halmazú konfigurációban. A Gauss 3-halmazos modell tanítás közben gyorsan csökkentette a hibát, és végül a tanító halmazon az RMSE értéke 0,0019-re zsugorodott. Ez jelentős javulás a lineáris függvényekhez képest, ami arra utal, hogy a Gauss tagsági függvényekkel a modell jobban meg tudta tanulni a bemenet-kimenet összefüggéseket. A valódi próba persze a tesztelés: örömmel láttam, hogy a Gauss modell a tesztadatokon is jó teljesítményt nyújtott, a teszt RMSE=0,581 lett. Ez mintegy 55%-kal

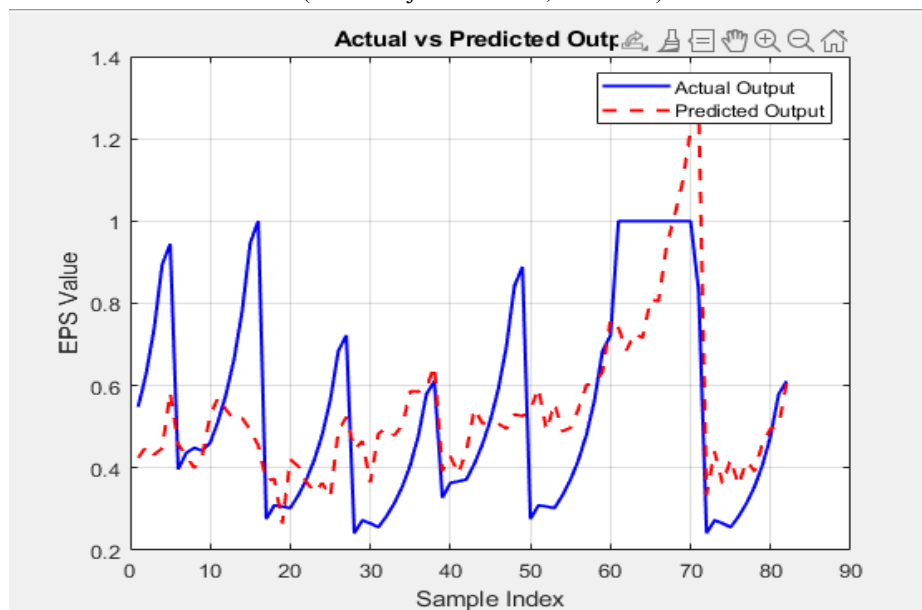
7. ábra A Gauss tagsági függvényekkel dolgozó 3 fuzzy halmazos modell előrejelzése.  
(Forrás: Saját szerkesztés, MATLAB)



alacsonyabb teszthibát jelent, mint a háromszög modellnél mért 1,066, ami már egy számottevő javulás. Az előrejelzési grafikonon (7. ábra) egyértelműen látszik a különbség a Gauss modell javára. Ahol a háromszög modell mondjuk elsimította a valós EPS görbe csúcsait, a Gauss modell sokkal közelebről követte azokat. Hasonlóképpen, egy hirtelen esésnél a Gauss modell hamarabb észlelte a trendfordulót, mint a lineáris modellek, köszönhetően annak, hogy a Gauss tagsági függvények nem kényszerítik a modellt olyan merev kategóriahatárok közé. A Gauss modell előrejelzése simább görbe volt, ami jól illett a valós adatok sokszor folyamatos változásaihoz. Ezzel együtt a Gauss modell sem tökéletes: néhány esetben, amikor az EPS értékében nagyon apró, ciklikus ingadozások voltak, a Gauss modell előrejelzése kissé túl is lenghetett. Ezek az eltérések azonban összességében nem voltak jelentősek, és a Gauss modell így is jelentősen pontosabbnak bizonyult, mint a háromszög vagy trapéz verzió.

A szigmoid tagsági függvényekkel készült ANFIS modell a három fuzzy halmaz kategóriában bizonyult a legjobbnak. A tanító adatokon a szigmoid modell RMSE értéke 0,105-ig csökkent a tanulás végére. A tesztadatokon mért RMSE pedig megközelítőleg 0,225 lett, ami a legkisebb teszthiba a négy modell közül ebben a konfigurációban. Összehasonlításképp: ez 79%-kal alacsonyabb, mint a háromszög modellnél tapasztalt 1,066-os hiba. A Gauss modellhez

**8. ábra** Szigmoid tagsági függvényekkel készült ANFIS modell előrejelzése (3 fuzzy halmaz)  
(Forrás: Saját szerkesztés, MATLAB)



viszonyítva is 38%-kal alacsonyabb teszthibát kaptunk, ami arra utal, hogy a szigmoid függvény apró előnyt jelentett a Gauss-hoz képest ebben az esetben. A szigmoid modell előrejelzési görbéje (8. ábra) szinte egybeesett a valós EPS görbével a legtöbb időszakban. Természetesen voltak kisebb eltérések, de ezek inkább véletlenszerű jellegűek voltak, nem pedig szisztematikus alul- vagy felülbecslések. A szigmoid modellnél azt láttam, hogy sehol nem volt nagy kilengés a tényadatokhoz képest: a legnagyobb előrejelzési tévedés is kisebb volt, mint amit a többi modellnél tapasztaltam. Ennek köszönhetően a szigmoid tagsági függvényes ANFIS 3 fuzzy halmazzal bizonyult a legerősebb előrejelzőnek ebben a csoportban. Már a három fuzzy halmazos eredmények alapján körvonalazódott néhány fontos tanulság. Egyrészt a tagsági függvény típusa valóban jelentősen befolyásolta a modell pontosságát: a nemlineáris, simább lefutású függvények (Gauss, szigmoid) egyértelműen leghatékonyabbak a lineáris (háromszög, trapéz) függvényekhez képest. A különbség a mi esetünkben elég számottevő volt, ami azt jelzi, hogy az EPS előrejelzés egy komplex, nemlineáris kapcsolatot hordoz a bemenetek függvényében, amit a rugalmasabb fuzzy tagságok tudtak jobban megragadni. Másrészt viszont az is látható, hogy a túl bonyolult függvény (szigmoid) esetén sem romlott a teljesítmény, legalábbis a 3 halmazos beállításnál. A szigmoid modell adta a legkisebb hibát, miközben a tréning és teszt hiba közti különbség relatíve kicsi maradt, tehát nem mutatott túlillesztésre utaló jeleket. Ez biztató, mert arra utal, hogy a magasabb komplexitású modell is jól generalizált, feltehetően a megfelelő tanítási beállításoknak (pl. korai megállítást) hála. A 3-halmazos konfigurációk egyikénél sem láttam extrém túlillesztést, inkább az volt a jellemző, hogy a kapacitás plafonja korlátozta a pontosságot (főleg a háromszög és trapéz esetén). A legjobb teljesítményt a szigmoid 3-halmazos modell nyújtotta, de a Gauss modell is csak alig maradt el mögötte. Ez a két modell mindenképp kiemelkedik ebből a csoportból.


### 4.3 Modellkonfigurációk értékelése – 4 tagsági függvény

A kísérlet második részében minden tagsági függvény típusal négy fuzzy halmazra is lefuttattam az ANFIS modelleket. Ez azt jelenti, hogy például a bemeneti változók értékeit már négy kategória írja le (pl. "nagyon alacsony", "alacsony", "közepes", "magas"), ami összetettebb szabályrendszert eredményez. Különösen érdekes kérdés, hogy a plusz egy fuzzy halmaz nyújtotta részletesség javította-e az előrejelzés pontosságát, illetve, hogy jelentkeztek-e a túlillesztés jelei a bonyolultabb modelleknél.

#### Háromszög és trapéz – finomabb felosztás eredményei

Kezdjük ismét a háromszög tagsági függvényű, de ezúttal 4 fuzzy halmazos modellel. A további kategória bevezetése azt eredményezte, hogy a modell több szabályt tanult (a már említett módon a szabályok száma megnőtt), és ennek hatása meg is látszott a tanítási hibán: a négy halmazos háromszög modell RMSE = 0,00048 körüli értéket ért el a tanító adatokon, szemben a 3-halmazos verzió 0,008-as hibájával. Ez mintegy 6%-os javulás a saját korábbi teljesítményéhez képest, vagyis a plusz kategória lehetővé tette, hogy a modell jobban ráilleszkedjen a tanító adatokra. A tesztadatokon mért hiba is csökkent, 0,845-re. Ez ismét egy 20%-os javulást jelent a háromszög 3-halmazos modell 1,066-os teszt hibájához képest. Az

9. ábra A háromszög tagsági függvényekkel működő ANFIS modell előrejelzése (4 fuzzy halmaz) (Forrás: Saját szerkesztés, MATLAB).




előrejelzési grafikon összehasonlítása is arról tanúskodik, hogy a 4-halmazos háromszög modell közelebb jutott a valós értékekhez (lásd 9. ábra). Például egy közepes szintű EPS-tartományban, ahol a 3-halmazos modellnek döntenie kellett, hogy "közepesnek" vagy "magasnak" tekint egy értéket (és lehet, hogy pont a határon nem jól döntött), a 4-halmazos modell be tudott vezetni egy "közép-magas" kategóriát, ami pontosabban fedte le az adott értéket. Így az előrejelzés nem ugrott akkorát, simábban követhette a valós görbét, ez jól mutatja a plusz fuzzy halmaz nyújtotta részletgazdagság előnyét. Ugyanakkor azt is meg kell jegyezni, hogy a javulás abszolút értékben korlátozott maradt. A 0,845-ös teszt RMSE még mindig meglehetősen magasnak mondható, és a háromszög modell ezzel a finomítással sem tudott versenyre kelni a Gauss vagy szigmoid modellek 3-halmazos teljesítményével (amik 0,581, illetve 0,225 voltak). Ez arra utal, hogy a komplexitás növelése itt már elkezdett megmutatkozni: a modell jobban megtanulta a tanító adatokat, de a tesztadatokra relatíve

kevésbé javult. Mindenesetre súlyos túlillesztésről még nem beszélhetünk, hiszen a teszteljesítmény is jobb lett, nem romlott.

A trapéz tagsági függvényes 4-halmazos modell hasonló trendet mutatott, mint a háromszög. A tanulási hiba tovább csökkent, 0,001 RMSE értéket ért el a tréning adatokon, a teszthiba pedig 0,656-ra alakult. A trapéz modell ezzel ismét egy leheletnyivel jobb eredményt produkált, mint a háromszög. Ez a különbség persze nem jelentős, de következetesen megfigyelhető, hogy a trapéz tagsági függvény kis előnyt ad. A 4 halmaz használatával a trapéz modell is profitált a részletesebb felosztásból, ugyanúgy, ahogy a háromszög esetén láttuk. Az előrejelzési görbék

10. ábra Trapéz tagsági függvényekkel készült ANFIS modell előrejelzése (4 fuzzy halmaz)  
(Forrás: Saját szerkesztés, MATLAB).




(10. ábra) alapján a trapéz 4-halmazos modell előrejelzései nagyon közel jártak a háromszög 4-halmazos modelléhez, csupán néhány pontban tapasztaltam különbséget. Ilyen volt például az a szituáció, amikor egy bank EPS-e két egymást követő évben tetőzött, majd enyhén visszaesett. A trapéz modell a platója révén két évig is magasnak tartotta az EPS-t (mert végig az 1 tagsági érték tartományában maradt a változó), és csak a harmadik évben reagált a csökkenésre. A háromszög modell ezzel szemben már a második év végén elkezdte érzékelni a csökkenést, mivel a háromszög csúcsán túl haladva az EPS érték tagsága csökkent. Ez egy érdekes különbség: a trapéz modell késleltette kissé a trendforduló jelzését, mert tovább "hitte", hogy az EPS magas szinten van (amíg az a plató tartományába esett). Ebből fakadóan a harmadik évre a trapéz modell előrejelzése egy kicsivel magasabb maradt, mint a valóság, míg a háromszög már alacsonyabbat jelzett annál. A valós EPS végül középen volt a kettő között, így ebben az esetben egyik modell sem volt tökéletes, de a trapéz egy kicsit jobban tartotta a szintet, ami abban a helyzetben előnyösnek bizonyult, mert kisebb ingadozást vitt bele az előrejelzésbe. Összességében a trapéz 4-halmazos modell a számok alapján is stabilabb maradt a tréning és teszt hiba aránya, valamint az előrejelzési görbe vizsgálata alapján is azt mondhatom, hogy nem mutatott komoly túlillesztést, és valamelyest javult a pontosság a 3-halmazos verzióhoz képest. Azonban még ezzel a javulással is látszott, hogy a lineáris függvények limitációi megvannak: a legjobb trapéz 4-halmazos hiba (0,656) még mindig elmarad a Gauss és szigmoid 3-halmazos hibáitól, így nyilvánvaló, hogy a tagsági függvény formája erősebb tényező, mint a halmazok száma ebben a tartományban.

### Gauss és szigmoid – a komplexitás hatása

A Gauss tagsági függvényű modell 4 fuzzy halmazzal történő futtatása előtt nagy várakozásaim voltak, hiszen a 3-halmazos Gauss modell is nagyon jól teljesített. Azt reméltem, hogy a negyedik halmaz bevezetése tovább csökkenti a hibát, esetleg a szigmoid 3-halmazos modell alá szorítva azt. A valós eredmények azonban árnyaltabbak lettek. A 4-halmazos Gauss modell a tanító adatokon valóban lenyűgözően teljesített: a tréning RMSE értéke egészen 0,0003-ig lement. Ez azt jelenti, hogy a modell szinte hibátlanul megtanulta a tanítókészletben lévő mintákat. Látható volt a tanulási folyamat közben is, hogy a 4-halmazos Gauss modell gyorsan és agresszívan csökkentette a hibát, a plusz szabadságfokokat kihasználva. Ugyanakkor az ellenőrző (validációs) halmazon figyeltem, hogy a hiba alakulása kezdett ingadozóvá válni a tréning vége felé. Ez intő jel volt arra, hogy a modell talán túlságosan is ráfeszül a tanító adatokra. A tesztelés eredménye némileg alátámasztotta ezt: a Gauss 4-halmazos modell teszt RMSE-je 0,528 lett. Ez első ránézésre jobb, mint a Gauss 3-halmazos 0,581-ös hibája (tehát történt némi javulás a teszten is), de az előrelépés sokkal kisebb arányú, mint amit a tanulási halmazon láttunk. A teszthiba ~9%-kal csökkent (0,581 → 0,528), miközben a tréninghiba eleve rendkívül alacsonyra (0,0003) esett. Ráadásul a 0,528-as érték még mindig magasabb, mint a szigmoid 3-halmazos modell 0,225-ös hibája, tehát a Gauss 4-halmazos modell nem döntötte meg az abszolút rekordot. Úgy is fogalmazhatnánk, hogy a Gauss modell esetén a 4. fuzzy halmaz csökkenő hozadékat mutatott: jóval többet segített a tanító hibát csökkenteni, mint amennyit a teszthibán javított. Az eredményből arra lehet következtetni, hogy a Gauss 4-

**11. ábra** A Gauss tagsági függvényekkel dolgozó 4 fuzzy halmazos modell előrejelzése.  
(Forrás: Saját szerkesztés, MATLAB)




halmazos modell már némileg túlillesztett az adatokra. Ezt a feltételezést a vizuális elemzés is megerősítette. A 4-halmazos Gauss előrejelzési görbén (11. ábra) azt vettem észre, hogy bizonyos helyeken a modell furcsán kacskaringózott ahelyett, hogy szép sima lenne. Feltehetően a többlet szabályok között akadt néhány, ami túl specifikus mintázatot tanult meg (talán egy-egy bank egyedi viselkedésére), és ez a tesztadatokon nem általánosult jól, inkább zajként jelent meg. Ilyen jelenségek tipikusan a túlillesztés következményei. Mivel a tanítást korán leállítottam a validációs hiba figyelésével, a túlillesztés csak mérsékelt formában nyilvánult meg, tehát nem arról van szó, hogy a Gauss 4-halmazos modell teljesen "összeomlott" volna az új adatokon, hiszen még mindig jobb tesztresultumot adott, mint a lineáris modellek. De jól kirajzolódott az a tendencia, hogy a plusz kapacitás már nem ad

lineárisan jobb eredményt, sőt, a pontosságjavulásért aránytalanul nagy árat kell fizetni a modell komplexitásában és a generalizációban.

Végül nézzük a szigmoid tagsági függvényű 4-halmazos modellt, amely a legösszetettebb konfiguráció az összes közül. Ennél a modellenl arra számítottam, hogy a komplexebb felépítés vagy további javulást hoz, vagy éppen ellenkezőleg, túlillesztést eredményez. A tréningadatokon azonban meglepő módon nem javult számottevően a modell teljesítménye: a tanítás során elért RMSE érték 0,110 környékén stagnált, ami továbbra is azt jelzi, hogy a modell viszonylag jól tanulta meg az EPS értékeket a tanulási mintákon. Ennek ellenére a teljesítmény nem mutatott további javulást a 3-halmazos verzióhoz képest.

Az ellenőrző adathalmazon már ennél rosszabb képet kaptam. A teszt RMSE körülbelül 0,195 környékén alakult, amely bár valamivel alacsonyabb, mint a 3-halmazos szigmoid modell esetében kapott érték (0,225 körül), mégsem jelentett jelentős javulást, különösen nem olyat, ami indokolta volna a komplexitás növekedését.

12. ábra Szigmoid tagsági függvényekkel készült ANFIS modell előrejelzése (4 fuzzy halmaz)  
(Forrás: Saját szerkesztés, MATLAB).



A grafikus ábrázolás (12. ábra) vizuális elemzése során látható, hogy a 4-halmazos szigmoid modell előrejelzései bár követik a valós EPS értékek általános trendjeit, azonban az előrejelzett értékek gyakran túlzottan kisimítják a valós adatok élesebb kilengéseit. Ez a simítás a modell általánosító képességére nézve kedvezőtlen, mivel a jelentősebb változásokat így kevésbé hatékonyan képes előrejelezni. Az is megfigyelhető, hogy a modell érzékelhető késéssel reagál a kiugró EPS értékekre, különösen az ábra jobb oldalán található nagyobb csúcsok esetében, ahol a predikciók késve követik a valós értékeket. Ez az időbeli eltolódás további bizonyíték arra, hogy a szigmoid 4-halmazos modell túlzott komplexitása inkább hátrányt jelentett a gyakorlatban.

Bár a 4-halmazos szigmoid modell valamelyest csökkentette a teszhalmaz hibáját, a javulás mértéke korántsem indokolja a modell bonyolultságát és számításigényét. A kapott eredmények egyértelműen jelzik, hogy ebben a konkrét alkalmazási helyzetben a modell komplexitásának növelése nem vezetett érdemi előrelépéshez, sőt inkább a praktikus alkalmazhatóságát csökkentette.

A 4 fuzzy halmazos eredmények összegzéseként elmondható, hogy a komplexitás növelése vegyes hatással volt: a lineáris függvényeknél (háromszög, trapéz) határozottan javított a teljesítményen a finomabb felosztás, és nem jelentkezett komoly túlilleszkedés; a Gauss és a szigmoid függvény esetén minimális javulást hozott a plusz halmaz.

## 5. Következtetések és javaslatok

### 5.1 Eredmények összevetése és következtetések

Az előző fejezetben bemutattam az egyes modell-konfigurációk eredményeit. Most itt az ideje, hogy összevegyem ezeket az eredményeket, és általános következtetéseket vonjak le. Az alábbi táblázatban összefoglaltam a nyolc vizsgált modell (négy tagsági függvény-típus, két különböző fuzzy halmazszám) RMSE értékeit a tanító és a teszt adathalmazra vonatkozóan:

2. táblázat Az ANFIS modellek teljesítményének összefoglalása különböző tagsági függvények és halmazszámok esetén. A táblázat a minimális és átlagos tanítási, valamint tesztelési hibákat mutatja, RMSE alapján.

(Forrás: Saját szerkesztés.)

Modell konfiguráció (tagsági függvény – fuzzy halmazok száma)	RMSE (Tréning)	RMSE (Teszt)
Háromszög – 3 halmaz	0,008	1,066
Háromszög – 4 halmaz	0,00048	0,845
Trapéz – 3 halmaz	0,004	1,015
Trapéz – 4 halmaz	0,0012	0,656
Gauss – 3 halmaz	0,0019	0,581
Gauss – 4 halmaz	0,0003	0,528
Szigmoid – 3 halmaz	0,105	0,225
Szigmoid – 4 halmaz	0,110	0,1956

A fenti adatok alapján több fontos megfigyelést lehet tenni:

1. A tagsági függvény formájának hatása: A négy függvénytípust összehasonlítva látható, hogy a Gauss és szigmoid tagsági függvények lényegesen jobb előrejelzési pontosságot eredményeztek, mint a háromszög és trapéz függvények. Ez a különbség mind a 3-halmazos, mind a 4-halmazos esetben fennáll. Például 3 halmaznál a legjobb lineáris modell teszthibája is jóval nagyobb, mint a legrosszabb nemlineáris modell teszthibája. 4 halmaznál hasonló a helyzet: a trapéz 0,656-os hibája elmarad a Gauss 0,528-as hibájától. Ez az eredmény megerősíti a várakozásomat, miszerint a sima lefutású, folytonos tagsági függvények (mint a Gauss vagy szigmoid) jobban tudják kezelni az EPS és a bemeneti változók közötti nemlineáris kapcsolatokat. Az EPS előrejelzése feltehetően összetett függvénye a bemenő pénzügyi mutatóknak, és a lineáris tagsági függvényekkel felépített ANFIS nem tudott elegendő rugalmasságot biztosítani ennek a kapcsolatnak a leírására. Ezzel szemben a Gauss és a szigmoid tagsági függvények finom átmenetei lehetővé tették, hogy a modell apró különbségekre is reagáljon. A grafikus összehasonlítás is ezt támasztotta alá: a Gauss és különösen a szigmoid modellek előrejelzési görbéi sokkal közelebb futottak a tényleges EPS görbékhez, míg a háromszög/trapéz modelleknél gyakrabban láttunk tartós eltéréseket (pl. rendszeres alulbecslést nagy értékeknél). Fontos ugyanakkor hozzátenni, hogy a két lineáris függvénytípus között a trapéz minden esetben jobbnak bizonyult a, míg a két nemlineáris közül a szigmoid volt a jobb. Ez azt mutatja, hogy bár a fő különbség a lineáris vs. nemlineáris között van, az azonos kategóriába tartozó függvények között is van finom eltérés: a trapéz kicsit rugalmasabb a háromszögnél, a szigmoid pedig még a Gaussianál is rugalmasabb (aszimmetrikus jellege miatt).

2. A fuzzy halmazok számának hatása: A táblázatból kiolvasható, hogy a 3-ról 4-re növelt fuzzy halmazszám hatása nem egységes: függ a tagsági függvény típusától. A háromszög és trapéz esetén egyértelmű javulást hozott a 4 halmaz használata mind a tréning, mind a teszt hibában. Például a háromszög modell teszthibája 1,066-ról 0,845-re csökkent, a trapézé 1,015-

ről 0,656-ra. Ezek érzékelhető javulások, amik arra utalnak, hogy a lineáris modellek esetében a 3 halmaz talán nem volt elég a szükséges pontosság eléréséhez, és egy negyedik halmaz (pl. "nagyon magas" kategória) hozzáadása segített jobban kategorizálni a bemeneteket. Ezzel szemben a Gauss függvényénél a javulás csekély: 0,581-ről 0,528-ra ment le a teszthiba, ami alig 10%-os csökkenés. A szigmoidnál pedig a halmazszám növelése részben rontotta az eredményt: a tréninghiba 0,105-ről 0,110-ra nőtt (miközben a teszthiba 0,225-ről 0,1956-ra csökkent). Ez a jelenség jól illusztrálja a komplexitás és generalizáció közti ellentmondást. A lineáris modellek kezdetben alacsony komplexitásúak voltak, így megengedhettünk magunknak némi növelést, az extra fuzzy halmaz még a hasznos tartományban növelte a modell kapacitását, és javította az általánosítást. A Gauss modell már eleve elég rugalmas volt 3 halmazzal is, így a negyedik halmaz inkább csak a tanító adatokhoz való idomulást segítette, de kevésbé javított az új adatokon (sőt, némi túlllesztést vitt a rendszerbe). A szigmoid modell pedig 3 halmaznál már a pontosság határát súrolta az adott adatmennyiség mellett - a 4. halmaz bevezetése túl tolt a modell kapacitását, így ott már enyhe negatív hatás jelentkezett a teszteljesítményben. Tehát a fuzzy halmazok számának növelése nem garantált módja a jobb előrejelzésnek; csak addig hasznos, amíg a modell ezzel nyert plusz szabadságfokait az adatok alátámasztják. Ha nincs elég adat a több szabály "megtanításához", akkor a modell elkezd a zajt is megtanulni, ami a tesztadatokon megbosszulja magát.

**3. Optimális modell és túlllesztés:** Az eredmények alapján fel lehet vázolni, hogy melyik konfiguráció bizonyult a legjobbnak az EPS előrejelzési feladatra. A legalacsonyabb teszt RMSE érték a táblázatban 0,1956, amit a szigmoid – 4 halmazos modell ért el. Nagyon közel van hozzá a 3 halmazos szigmoid modell 0,225-ös hibája, illetve a Gauss - 4 halmazos 0,528-al. Ezek az értékek arra utalnak, hogy a legjobb előrejelző modell nálam a szigmoid tagsági függvényű ANFIS, négy fuzzy halmazzal. Ez a konfiguráció találta meg azt az egyensúlyt, ahol a modell elég rugalmas volt a nemlineáris mintázatok megragadásához, de még nem lépte túl azt a pontot, ahol a felesleges komplexitás már árt. Érdekes módon, a szigmoid 4-halmazos modell tréning hibája magasabb, mint például a Gauss 4-halmazos modellé, de hát a legjobb modell nem az, amelyik a tanító adatokon a legjobban teljesített, hanem az, amelyik a legjobban generalizált a teszt adatokra. Ezt fontos hangsúlyozni, mivel egy gépi tanulási projektben könnyű abba a hibába esni, hogy a tréningteljesítmény maximalizálására törekszünk, holott a valódi cél a teszt (vagy új adatokon való) teljesítmény maximalizálása. Az én eredményeim pontosan rámutatnak erre: volt olyan modell (Gauss 4 halmaz), aminél a tréning hiba elképesztően alacsony (0,0003), de a teszthiba viszont nem a legalacsonyabb és ezzel szemben van a szigmoid 4 halmaz modell, aminél a tréning hiba "csak" 0,110, de a teszthiba a legalacsonyabb (0,1956). Az utóbbi bizonyult tehát a leghasznosabb modellnek az EPS előrejelzésére. Úgy is fogalmazhatok, hogy ennél a modellenél sikerült a legjobban megtalálni a Torzítás–szórás kompromisszum optimális pontját: a modell nem túl egyszerű (hogy torzított legyen a becslése), de nem is túl bonyolult (hogy nagy varianciával tévedjen új adatokon). Az eredmények alapján a második legjobb egyébként a szigmoid - 3 halmaz modell volt, és nagyon szorosán utána a Gauss – 4 halmaz. Ez mutatja, hogy a Gauss függvény is kiválóan teljesített, sőt a 4 halmazzal egy kicsit még javítani is lehetett rajta anélkül, hogy súlyos túlllesztés lépett volna fel. Összességében tehát a legjobb három modell nálam: 1. Sigmoid, 4 halmaz (teszt RMSE 0,1956); 2. Sigmoid, 3 halmaz (teszt RMSE 0,225); 3. Gauss, 4 halmaz (teszt RMSE 0,528). Ezek mind nagyon közel vannak egymáshoz teljesítményben, így azt mondhatjuk, hogy mindhárom alkalmas lehet jó előrejelzésre. A leggyengébb modell pedig a Háromszög, 3 halmaz volt (1,066-es teszt RMSE), ami várható is volt, hiszen ez volt a legegyszerűbb konfiguráció.

4. A modellek viselkedése az előrejelzési görbék alapján: A számok mellett érdemes áttekinteni néhány általános mintázatot, ami az EPS előrejelzési ábrákon volt megfigyelhető, mert ezek mélyebb betekintést engednek a modellek viselkedésébe. Az egyik fontos megfigyelés az volt, hogy a lineáris tagsági függvényekkel dolgozó modellek előrejelzései hajlamosak voltak darabosabbak lenni. Mivel a háromszög és trapéz függvények lineárisan változnak, az ANFIS által felépített összefüggésrendszer is inkább törésvonalakkal tarkított felületként képzelhető el a bemenetek és az EPS között. Ennek vizuális jele volt, hogy a háromszög/trapéz modellek esetében néha az előrejelzés hirtelen változott egyik időszakról a másikra, nem teljesen simulva a folyamatos trendekhez. Különösen igaz volt ez akkor, amikor egy változó értéke átlépett egy fuzzy halmaz határát: ilyenkor a szabályok kimeneteiben is törés jelenhetett meg. Ezzel szemben a Gauss és szigmoid modellek előrejelzései sima görbét adtak, apránként követték a változásokat. Ha az EPS lassan emelkedett, a Gauss/sigmoid modellek is finoman emelkedő előrejelzést adtak; ha hirtelen esett vissza, ők is gyorsan, de nem ugrásszerűen estek, hanem egy elegánsabb görbét leírva. Ez összhangban van azzal, amit a tagsági függvények jellegéről tudunk: a simább tagsági függvények simább output felületet generálnak. Egy másik megfigyelés az volt, hogy a modellhibák eloszlása időben nem véletlenszerű: bizonyos időszakokban több modell is rendre alul becsülte vagy felülbecsülte az EPS-t. Például a Covid-19 válság éveiben (2020 körül) több banknál is az EPS csökkent. A modelljeim, még a legjobbak is ezt a zuhanást nem tudták teljesen előrejelezni. Mindegyik előrejelzés magasabban maradt, mint a valós érték, azaz nem látták előre a mélypontot. Ez arra utal, hogy a válság extrém hatása kívül esett azon a mintázaton, amit a modellek a történelmi adatokból megtanultak. (Hiszen korábban nem tapasztaltak ilyen mértékű esést, így nem is tudtak erre szabályokat kialakítani.) Ugyanakkor érdekes módon a kilábalás időszakában (2021-2022) a modellek közül a rugalmasabbak – főleg a Gauss és a szigmoid – gyorsabban felismerték a trendfordulót, és hamarabb kezdtek emelkedő EPS-t jósolni, míg a háromszög/trapéz modellek tovább vittek magukkal egyfajta pesszimista előrejelzést (alacsony EPS-t jeleztek még akkor is, mikor már növekedés indult). Ez is logikus a mechanizmusukat tekintve: a lineáris modellek egy része talán túl nagy súlyt adott a válság alatti adatoknak (amik mind "alacsony" kategóriába estek, és így az arra vonatkozó szabályok domináltak még utána is), míg a Gauss/sigmoid modellek képesek voltak jobban extrapolálni felfelé is.

5. A modell komplexitása és értelmezhetősége: Bár a fő cél a pontosság összehasonlítása volt, kutatásom során nem mehettem el amellett sem, hogy a modellek értelmezhetőségében is jelentős különbségek vannak. Minél több fuzzy halmazt és minél komplexebb tagsági függvényeket használ egy ANFIS modell, annál több és bonyolultabb fuzzy szabály képződik. Például a 3-halmazos modellek esetén, ha mondjuk 4 bemeneti változó volt (a pontos számot és a változók listáját a módszertan résznél ismertettem), akkor maximum  $3^4 = 81$  szabály jöhetett létre. Ezzel szemben a 4-halmazos modelleknél ugyanennyi bemenetnél már  $4^4 = 256$  szabály is lehet. A valóságban a szabályok száma ennél kevesebb is lehet, ha bizonyos kombinációk nem fordulnak elő vagy összevonhatók, de így is jelentős a különbség. A kimeneti következtetések paramétereinek száma szintén nő a szabályok számával. Ez a komplexitás nem csak a túlillesztés szempontjából probléma, hanem az átláthatóságot is csökkenti. Például a háromszög 3-halmazos modellnél még viszonylag kevés szabályból álló rendszert láttam, amit utólag végig nézve meg lehetett érteni: olyan szabályok jöttek létre, hogy "HA a tőke megfelelés alacsony ÉS a profitabilitás alacsony AKKOR az EPS változás kicsi" stb. Ezek a szabályok valamelyest értelmezhetőek pénzügyi szempontból is. Viszont a szigmoid 4-halmazos modellnél 256 szabály volt, ráadásul a tagsági függvények nem intuitív határpontok mentén osztották fel a változókat, így ezek a szabályok szinte értelmezhetetlenek egy ember számára. Ez azért fontos szempont, mert a banki világban, bár az előrejelzés pontossága nagyon fontos, a modellek magyarázhatósága is lényeges. Egy banki döntéshozó számára például nem biztos, hogy elfogadható egy "fekete doboz" modell, amely bár jó előrejelzést ad, de nem lehet belőle

semmit megtudni arról, hogy mely tényezők hogyan hatnak. Ebben a projektben ugyan a hangsúly a pontosságon volt, de megjegyzem, hogy a háromszög és trapéz modellek előnye a magyarázhatóság terén megmutatkozott: kevesebb szabályuk volt, és a tagsági függvények határértékei konkrét küszöböknek feleltek meg (pl. "EPS növekedés 5% felett magasnak számít"), így a szabályok leírhattak érthető összefüggéseket (pl. "HA a tőkeáttétel magas ÉS a hitelállomány növekedése alacsony, AKKOR az EPS mérsékelt ütemben nő"). Ezzel szemben a Gauss és szigmoid modellek "megtanulták" ugyan ezeket az összefüggéseket – sőt, jobban is becsülték az EPS-t, de a tanult tudásuk nehezebben hozzáférhető, mert nincs egyértelmű emberi nyelven megfogalmazható megfelelőjük minden szabályra. Ez egy általános trade-off a gépi tanulásban: a legjobb előrejelző modellek gyakran kevésbé interpretálhatók.

6. Az ANFIS megközelítés összességében: Az eredményeim tükrében elmondhatom, hogy az ANFIS megközelítés életképes módszernek bizonyult az EPS előrejelzésére. Még a legegyszerűbb ANFIS modell is képes volt megragadni bizonyos trendeket és tendenciákat, a legjobb modell pedig már igen pontosan jelzett előre. A gyök-négyzetes hibák nagyságrendje azt sugallja, hogy az előrejelzések átlagos eltérése a valóságtól a vizsgált bankoknál az EPS adatok skáláján belül maradt elfogadható mértékű. Ha az EPS-t például euróban mérjük és tipikusan néhány euró értékű egy részvényre jutó nyereségről beszélünk, akkor egy 0,5 RMSE azt jelenti, hogy átlagosan 50 cent eltérés van a jóslat és a tény között. Ez banki profit-előrejelzésnél nem rossz, bár természetesen mindig lehetne tovább finomítani. Fontos kiemelni, hogy a modell teljesítménye nagymértékben függött a bevitt információktól: jelen esetben a bemeneti változók a bankok fundamentális mutatói voltak. Ha például makrogazdasági mutatókat, piaci információkat is bevontunk volna, akkor az előrejelzés még pontosabb lehetne. A jelen eredmények mindenesetre jól demonstrálják, hogy a mesterséges intelligencia alapú módszerek, azon belül a neuro-fuzzy rendszerek, a pénzügyi előrejelzésben versenyképesek lehetnek a hagyományos modellekkel. Bár nem végeztem direkt összehasonlítást mondjuk egy hagyományos regressziós vagy idősor-moddellel, az irodalmi hivatkozások alapján (ld. korábbi fejezetek) tudható, hogy egy hasonló adatstruktúrájú regressziós modell tipikusan nagyobb hibával dolgozna, mert nem tudja kezelni az ilyen nemlineáris, komplex kapcsolatokat.

7. Általános tanulságok a tagsági függvényekről: A konkrét eredményeim túl általános tanulságként azt emelném ki, hogy a tagsági függvények megválasztása az ANFIS-ban kritikus tervezési döntés. Előzetesen is sejtettem, hogy számítani fog, de most számszerűen is látom, mekkora különbségeket okozhat. Ugyanaz az ANFIS rendszer, ugyanazzal az adathalmazzal és paraméterekkel, pusztán a tagsági függvények cseréje révén 1,066 vs. 0,1956 RMSE-t produkált a teszten, ami jelentheti azt is, hogy nagy mértékű pontossággal sikerül eltalálni az EPS értékét. Tehát nem elhanyagolható, hogy milyen fuzzy partíciókat tervezünk a bemenetekhez. A lineáris vs. nemlineáris vita itt egyértelműen a nemlineáris függvények javára dőlt el, de azt is látni kell, hogy a nemlineáris függvényekkel könnyebben csúszunk bele a túlillesztésbe, ha nem figyelünk oda. Ez arra vezethető vissza, hogy a nemlineáris függvények paraméterei finomabban hangolhatók, így a modell nagyobb szabadságot kap. Ez áldás és átok is lehet: áldás, mert jobban illeszkedik; átok, mert a zajt is illesztheti. Itt jön be a képbe a megfelelő modellvalidáció és a paraméterezés (pl. hány iterációt tanítunk, milyen hibatűréssel állítjuk le, használunk-e ellenőrző halmazt). Én úgy találtam, hogy a korai megállítást és a megfelelő adatelosztást (tréning vs. teszt) rengeteget segített. Ha ez nem lett volna, valószínűleg a Gauss 4-halmazos és a szigmoid 4-halmazos modell is még jobban túlilleszt, és talán a Gauss 3-halmazos is kicsit "túlhúzza". Az, hogy ez nem következett be nagymértékben, annak köszönhető, hogy a tréninget leállítottam időben, mielőtt a modell teljesen "ráült" volna a tanító adatok zajára.

8. Végső összehasonlítás kontextusban: Ha szélesebb kontextusba helyezzük az eredményeket, akkor elmondható, hogy az ANFIS modellek közti különbségek feltárása sikeres volt, és a legjobb modellel elért előrejelzési hiba alapján az EPS becslés pontossága jól használható lehet gyakorlati célokra is. Persze, mindig lehet javítani. Például érdemes lenne kipróbálni, hogy mi történik 5 vagy több fuzzy halmaz esetén, bár sejthető, hogy az adatmennyiség korlátai miatt ott még erősebb túlillesztést kapnánk, legalábbis a bonyolult függvényeknél. Ugyancsak tanulságos lenne megnézni, hogy egy hibrid modell (pl. genetikussal optimalizált tagsági függvényekkel, ahogy némely tanulmány javasolja) mennyit dobna a teljesítményen. Az én eredményeim azt mutatják, hogy már pusztán a tagsági függvény típusának megválasztásával és a halmazok számának hangolásával is komoly javulást lehet elérni, így azt gondolom, hogy egy optimalizáló algoritlussal tovább finomított ANFIS még jobb eredményt hozhatna. Mindazonáltal a saját eredményeim alapján meghúzható néhány ajánlás: például, ha valaki EPS-t vagy hasonló pénzügyi mutatót szeretne előre jelezni ANFIS-szel, érdemes Gauss vagy szigmoid tagsági függvényeket választania a kezdeti modellhez, és úgy belőni a fuzzy halmazok számát, hogy az se túl kevés, se túl sok ne legyen – az én adataimnál a 3 halmaz bevált, a 4 már néhol sok volt. Természetesen minden probléma más, de egy hasonló jellegű, közepes méretű adatbázisnál (néhány száz adatpont, 3-5 bemenet) a 3 fuzzy halmaz per változó egy jó kiindulási pontnak tűnik a nemlineáris függvények esetén.

A különböző ANFIS modellek összehasonlítása rámutatott a tagsági függvények és fuzzy halmazbeállítások jelentőségére. A legpontosabb előrejelzést a szigmoid függvényű, 4 fuzzy halmazos modell adta, de nagyon közel volt hozzá a Gauss függvényű modell is. A túl sok fuzzy halmaz alkalmazása a legbonyolultabb függvényeknél túlillesztést okozhat, ami intő jel a modellépítőknek, hogy óvakodjanak a "minél komplexebb, annál jobb" csapdától. Az eredmények alapján az ANFIS keretrendszer kiválóan alkalmazkodik a pénzügyi adatok nemlineáris természetéhez, de oda kell figyelni a konfiguráció gondos megválasztására a sikeres előrejelzés érdekében.

## 5.2 Javaslatok

Az alábbi 13 pontot az eredményeim és tapasztalataim alapján javaslom a következő fejlesztési körre. A cél, hogy a modell pontosabb és kezelhető maradjon, miközben a bemutatás is érthetőbb legyen.

1. Időrend szerinti értékelésre érdemes átállni: a véletlen 70/30 helyett időben előre haladó tanítás-validálás–tesztelés bontás, és néhány gördülő teszt.
2. Be lehetne vonni 1–2 egyszerű bázismodellt (naiv, lineáris/ARIMA), csak ellenőrzésre, hogy az ANFIS valóban többet ad-e.
3. Érdemes rögzíteni a célhorizontot (pl. EPS  $t+1$ ), és pár könnyű késleltetést kipróbálni (1–4 időszak); ami nem segít, azt ki lehet venni.
4. A bonyolultságot egyszerűen tartanám: indulásnak 3 fuzzy halmaz; a 4. halmazt csak akkor kapcsolnám be, ha láthatóan javít.
5. Az eredményeket jó lenne több mutatóval is megadni (RMSE mellé pl. MAE), és egy rövid hibasávot is meg lehetne mutatni az ábrákon.
6. Hasznos lehet 2–3 jellegzetes szabályt „emberi nyelven” röviden leírni, hogy könnyebb legyen értelmezni, mit csinál a modell.
7. A futásoknál célszerű lehet rögzíteni a véletlenmagot, a verziókat és az adatdátumokat, hogy ugyanaz a futás később is megismételhető legyen.
8. Kezdő beállításnak a szigmoid, 3 halmazos modellt ajánlom; ha az adatok indokolják, meg lehet próbálni 4 halmazt is. A Gauss, 4 halmaz stabil tartalék.

9. A bemeneteket fokozatosan lehetne bővíteni néhány makrogazdasági és piaci mutatóval (pl. infláció, alapkamat, szektorindex), és csak azt megtartani, ami tényleg hozzáad.
10. Negyedévente, a gyorsjelentések után egy rövid újratanítás jól jöhet, hogy a szabályok kövessék a friss helyzetet.
11. Az ábrákon áttekinthető lenne egy tény–előrejelzés görbe és egy rövid hibagrafikon (időbeli hiba alakulása).
12. Kísérletképp meg lehetne próbálni egy egyszerű automatikus paraméter-hangolást, vagy megnézni, javít-e valamit egy könnyű „rásegítő” modell (pl. utólagos lineáris finomítás).
13. Érdemes külön is megnézni a válságos/stresszes időszakokat; ha nagyon eltérnek, ezeket külön kezelni is lehet.

## 6. Összefoglalás és személyes reflexió

### 6.1 Átfogó összefoglalás

A dolgozat célja az volt, hogy bemutassa: a Takagi–Sugeno típusú, ANFIS-alapú (Adaptive Neuro-Fuzzy Inference System) megközelítés alkalmas-e európai bankok egy részvényre jutó eredményének (EPS) előrejelzésére, és hogy a tagsági függvények formája, illetve száma miként befolyásolja a pontosságot. A modellépítést MATLAB környezetben, a Fuzzy Logic Toolbox segítségével végeztem; az adatelőkészítésben a hiányzó és kirívó értékek kezelése, valamint a normalizálás kapott hangsúlyt, mert az ANFIS érzékeny az eltérő skálákra. A bemenetek között fundamentális banki mutatók szerepeltek (pl. ROE, ROA, profitmárga, likviditási ráta), a kimenet az EPS volt. A vizsgálatban négy tagsági függvény-típust hasonlítottam össze (háromszög, trapéz, Gauss, szigmoid), és mindegyiket két felbontásban teszteltem (3, illetve 4 fuzzy halmaz), vagyis összesen nyolc modellt állítottam elő.

A kísérleti keret egységes volt: azonos tanítási beállítások, 70/30 arányú (véletlen) tréning–teszt szétosztás, a teljesítmény mérésére az RMSE szolgált. A tanulás során hibrid algoritmust alkalmaztam (legkisebb négyzetek + gradiens), és ellenőrző (validation) halmazt figyeltem a korai megállás érdekében. A konzisztens összehasonlíthatóság miatt minden konfiguráció ugyanazon adatkészleten, azonos paraméterezéssel futott, a számszerű eredményeket az RMSE értékek mellett az előrejelzési és ténygörbék vizuális összevetése egészítette ki.

Az eredmények világos rangsort adtak. A legjobb tesztelési eredményt a szigmoid, 4 halmazos modell érte el (teszt RMSE  $\approx 0,1956$ ), szorosán mögötte a szigmoid, 3 halmaz állt ( $\approx 0,225$ ). A Gauss, 4 halmaz harmadik lett ( $\approx 0,528$ ). A lineáris tagsági függvények (háromszög, trapéz) lényegesen gyengébbek voltak; tipikusan 0,65–1,07 közötti teszt RMSE-vel teljesítettek. Ezek a számok azt üzenik, hogy a vizsgált adatok nemlinearitását a sima, folytonos tagsági függvények tudják megbízhatóbban leképezni.

A komplexitás növelésének hatása árnyalt. A lineáris függvényeknél a 3-ról 4 halmaz váltás mérhető javulást hozott (pl. háromszög:  $1,066 \rightarrow 0,845$ ; trapéz:  $1,015 \rightarrow 0,656$ ), míg a Gauss és a szigmoid esetében már csökkenő hozadék látszott. A Gauss-4 modell például a tréningen szinte hibátlanra illeszkedett (RMSE  $\approx 0,0003$ ), azonban a teszten csak kismértékben javult ( $0,581 \rightarrow 0,528$ ), ami a kapacitásnövelésből fakadó túlillesztési kockázatra utal. A szigmoid-4 a teszten ugyan a legalacsonyabb hibát adta ( $\approx 0,1956$ ), de a 3 halmazos változathoz képest a nyereség csekély, és nem minden mintában hozott érdemi többletet. Összességében a legjobb eredmény nem a „lehető legbonyolultabb” modellel született, hanem ott, ahol sikerült jó kompromisszumot találni a torzítás és a szórás között.

A gyakorlati következmények egyértelműek. A tapasztalatok alapján nemlineáris tagsági függvényekkel (szigmoid, Gauss) érdemes kezdeni. 3–4 halmaz közül a választást az adatmennyiség és a kockázati preferencia döntse el. Ha a magyarázhatóság fontos, a lineáris tagsági függvények jó alap, de pontosságban várhatóan elmaradnak. A dolgozat fő hozzájárulása, hogy egységes kísérleti keretben, átlátható metrikákkal és kontrollált paraméterezéssel hasonlította össze a nyolc ANFIS-konfigurációt, és megbízhatóan azonosította a gyakorlatban is jól használható beállítást (szigmoid 3–4 halmaz). A neuro-fuzzy megközelítés életképes alternatívája a hagyományos idősoros eljárásoknak a pénzügyi előrejelzésekben.

## 6.2 Személyes reflexió

A munka során számomra a legtanulságosabb az volt, hogy a „jó modell” valójában sok apró, fegyelmezett döntés eredője. Az adattisztítás, a skálázás, a halmazok és tagsági függvények kiválasztása, a megállítási kritérium, mind olyan lépések, amelyek egyenként is módosítják a végeredményt. Az is világossá vált, hogy a túlzott komplexitás könnyen visszaüt: a tréningen látványos hibaesés nem garancia a jobb előrejelzésre, ha a modell közben ráhangolódik a zajra. Ezt a saját futtatásaim és a tréning–teszt eltérések elemzése is megerősítette. Személyesen sokat adott az, hogy a pénzügyi tartalom és a gépi tanulási technika találkozását „végig a kezem alatt” tapasztaltam meg. Közelebb kerültem ahhoz, hogyan lehet egy szakmai kérdést (EPS-előrejelzés) adatokon, világos kísérleti tervvel, kontrollált összehasonlítással megválaszolni. Úgy érzem, a dolgozat nemcsak konkrét eredményeket ad, melyek közül a szigmoid 4-halmazos modell alacsony teszthibája a legerősebb, hanem munkamódszert is: türelmet, következetességet és azt a szemléletet, hogy a modell célja nem a múlt tökéletes visszamondása, hanem a jövő ésszerű megbecslése.

## 7. Irodalomjegyzék

- Aliber, R. Z. (2019). A Retrospective on the 2008 Global Financial Crisis. In *The 2008 Global Financial Crisis in Retrospect: Causes of the Crisis and National Regulatory Responses*. Palgrave Macmillan, Cham.
- Al-Jarrah, R. A.-O. (2021). A novel adaptive neuro-fuzzy inference system model to predict the intrinsic mechanical properties of various cellulosic fibers for better green composites. *Cellulose*.
- Augustine C. Arize, E. U. (2018). Banks and markets in the financial service industry: are their roles complementary or competitive in Nigeria? *International Journal of Services, Economics and Management*.
- Avci, M. A. (2010). An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the Prediction of Stock Market Return: The Case of the Istanbul Stock Exchange. *Expert System with Applications*.
- Aziz, K. a. (2018). Big Data Processing using Machine Learning algorithms: MLlib and mahout use case. *ACM International Conference Proceeding Series*. Rabat.
- Balogh András, H. Z. (2017). A hagyományos monetáris. *OKTATÁSI FÜZETEK*.
- Barlybayev, A. Z. (2023). DEVELOPMENT NEURO-FUZZY MODEL TO PREDICT THE STOCKS OF COMPANIES IN THE ELECTRIC VEHICLE INDUSTRY. *Eastern-European Journal of Enterprise Technologies*.
- Caplinska, N. K. (2021). Reliability and Statistics in Transportation and Communication. Springer Science and Business Media Deutschland GmbH.
- Cohen, E. E. (2011). *Athenian economy and society: A banking perspective*.
- Dhyani, A., Bisht, D., Kathuria, S., Gehlot, A., Chhabra, G., & Tiwari, P. (2023). Cyber Physical System Role in Stock Market. *IEEE*. Kalyani, India.
- Dicecco, V. (2011). Size doesn't matter... profits do understanding gross margin.
- DiPietro, R. H. (2019). Deep learning: RNNs and LSTM. In *Handbook of Medical Image Computing and Computer Assisted Intervention*. Elsevier.
- Do, Q. H.-F. (2013). A comparative study of hierarchical anfis and ann in predicting student academic performance. *WSEAS Transactions on Information Science and Applications*.
- Dong, T. (2021). Introduction. In *Studies in Computational Intelligence*. Németország: Springer.
- Duy, T. H., & Cuong, N. V. (2014). Enhancement and FPGA implementation of ANFIS algorithm in digital image processing. *IEEE*. Danang, Vietnam.
- Elemzőközpont. (2025. március 5). *Elemzőközpont*. Forrás: <https://elemzeskozpont.hu/befektetoi-hangulat-fogyasztoi-bizalom-hangulatindikatorok>
- Esfahanipour, A. (2011). An ANFIS model for stock price prediction: The case of Tehran stock exchange. *International Symposium on Innovations in Intelligent Systems and Applications*.
- Farhat, A. C. (2017). Improving adaptive network fuzzy inference system with Levenberg-Marquardt algorithm. *IEEE*.
- Gai, F. (2021). When Artificial Intelligence Meets Daoism. In *Intelligence and Wisdom*. Springer Nature.
- Gerven, F. J. (2011). *Dynamic LIMIDS*. IGI Global.
- Goldthwaite, R. (2009). The economy of renaissance Florence. In R. A. Goldthwaite. Cambridge University Press.
- Grabowski, R. (2024). The Future of AI Ain't What It Used To Be. *Annex Business Media*.

- Greenwood, N., Sundaram, B., Muirhead, A., & Copperthwaite, J. (2020). Awareness without Neural Networks: Achieving Self-Aware AI via Evolutionary and Adversarial Processes. *IEEE*.
- J.M. Davoren, T. M. (2006). NON-DETERMINISTIC REACTIVE SYSTEMS, FROM HYBRID SYSTEMS AND BEHAVIOURAL SYSTEMS PERSPECTIVES. *IFAC Secretariat*. Németország.
- Jang, J.-S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Xplore*.
- Kira, M. I. (2014). A framework for analysing the impact of economic variations on return on equity.
- Lang, R. (2007). Neural networks in brief. In *Automated Taxon Identification in Systematics: Theory, Approaches and Applications*. CRC Press.
- Li C.G., Z. H. (2005). Passivity and passification of uncertain fuzzy systems. *IEEE*. Kína.
- Li, K. (2024). Liquidity ratios and corporate failures. *John Wiley and Sons Inc*.
- Lindvall, J. (2020). *Sweden's Riksbank: Guardian of Monetary Integrity*. Springer International Publishing.
- Lu, J. J. (2004). *Logic-based reasoning for intelligent systems*. USA: CRC Press.
- Mayis G. Gulaliyev, N. P.-H. (2019). Stability of the Banking Sector: Deriving Stability Indicators and Stress-Testing. *Polish Journal of Management Studies*.
- MNB. (2024). MNB. Forrás: <https://www.mnb.hu/felugyelet/ertekpapirositas>
- Narayanan, N. A. (2024). Introduction to Deep Learning. In *Artificial Intelligence for Precision Agriculture*. CRC Press.
- Okur, M. G. (2015). *A competitive approach to financial issues: Modern finance theory*. London: IGI Global.
- Olga Yegoshina, S. L. (2024). Research the adaptive neural networks using possibility in control systems for cycle chemistry at thermal power plants., (old.: 8).
- Oscar Gelderbloom, J. J. (2004). Completing a financial revolution: The finance of the Dutch East India trade and the rise of the Amsterdam capital market, 1595-1612. *Journal of Economic History*.
- Páles Judit, V. L. (2006). A magyar pénzügyi piacok likviditásának alakulása. *MNB füzet*.
- Patrick K. O'Brien, N. P. (2023). *Not an ordinary bank but a great engine of state: The Bank of England and the British economy, 1694–1844*. John Wiley and Sons Inc.
- Quang Hung Do, T. V. (2019). Forecasting Vietnamese stock index: A comparison of hierarchical ANFIS and LSTM. *Decision Science Letters*.
- Ray Barrell E., P. D. (2010). Bank regulation, property prices and early warning systems for banking crises in OECD countries. *Journal of Banking & Finance*.
- Robbette, N. H. (2017). The effect of earnings per share categories on share price behaviour: Some South African evidence. *Clute Journals*.
- Sagir, A. M. (2017). A novel adaptive neuro fuzzy inference system based classification model for heart disease prediction. *Universiti Putra Malaysia Press*.
- Saleem, M. A. (2022). Comparative Analysis of Recent Architecture of Convolutional Neural Network. *Mathematical Problems in Engineering*.
- Salleh, M. N. (2017). *Adaptive neuro-fuzzy inference system: Overview, strengths, limitations, and solutions*. Springer Verlag.
- Shynkevich, A. (2016). Predictability of equity returns during a financial crisis.
- Slobodanyk, G. D. (2021). Value Assessment of Shares of Corporate Issuers by Applying the Methods of Fundamental Analysis in the Stock Exchange Market. In *The Challenge of Sustainability in Agricultural Systems*. Springer Science and Business Media Deutschland GmbH.
- Songtao Wu, F. D. (2007). Using the ROA Index to Analyze the Value of Optimum Stock. *IEEE*.

- Stephan Hebllich, A. T. (2018). Banking and Industrialization. *Journal of the European Economic Association*.
- Tuteja, S., Bhoyar, P., Singh, K. K., & Rroy, A. D. (2023). Predicting bank performance using machine learning: a case of troubled banks in India. *International Journal of Pluralism and Economics Education (IJPEE)*.
- Winfield, A. F. (2018). Experiments in artificial theory of mind: From safety to story-telling. *Frontiers Robotics AI*.
- Xin Huang, H. Z. (2012). Assessing the systemic risk of a heterogeneous portfolio of banks during the recent financial crisis. *Journal of Financial Stability*.
- Zadeh, L. (1965). Fuzzy sets. In *Information and Control*.

### Táblajegyzék

<b>1. táblázat.</b> Mesterséges intelligencia típusai. (Forrás: saját szerkesztés informatecdigital.com adatai alapján) .....	9
<b>2. táblázat</b> Az ANFIS modellek teljesítményének összefoglalása különböző tagsági függvények és halmazszámok esetén. A táblázat a minimális és átlagos tanítási, valamint tesztelési hibákat mutatja, RMSE alapján. Forrás: saját szerkesztés .....	31

### Ábrajegyzék

<b>1. ábra</b> Általános háromszög tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB).....	19
<b>2. ábra</b> Általános trapéz tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB).....	20
<b>3. ábra</b> Általános Gauss tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB).....	21
<b>4. ábra</b> Általános szigmoid tagsági függvények ábrázolása. (Forrás: Saját szerkesztés, MATLAB).....	22
<b>5. ábra</b> A háromszög tagsági függvényekkel működő ANFIS modell előrejelzése (3 fuzzy halmaz). A predikció (piros vonal) több ponton is eltér a valós EPS értékektől (kék vonal), különösen az éles változásoknál. (Forrás: Saját szerkesztés, MATLAB.).....	23
<b>6. ábra</b> Trapéz tagsági függvényekkel készült ANFIS modell előrejelzése (3 fuzzy halmaz) (Forrás: Saját szerkesztés, MATLAB.).....	24
<b>7. ábra</b> A Gauss tagsági függvényekkel dolgozó 3 fuzzy halmazos modell előrejelzése. (Forrás: Saját szerkesztés, MATLAB).....	25
<b>8. ábra</b> Sigmoid tagsági függvényekkel készült ANFIS modell előrejelzése (3 fuzzy halmaz) (Forrás: Saját szerkesztés, MATLAB).....	26
<b>9. ábra</b> A háromszög tagsági függvényekkel működő ANFIS modell előrejelzése (4 fuzzy halmaz) (Forrás: Saját szerkesztés, MATLAB). .....	27
<b>10. ábra</b> Trapéz tagsági függvényekkel készült ANFIS modell előrejelzése (4 fuzzy halmaz) (Forrás: Saját szerkesztés, MATLAB).....	28
<b>11. ábra</b> A Gauss tagsági függvényekkel dolgozó 4 fuzzy halmazos modell előrejelzése. (Forrás: Saját szerkesztés, MATLAB).....	29
<b>12. ábra</b> Sigmoid tagsági függvényekkel készült ANFIS modell előrejelzése (4 fuzzy halmaz) (Forrás: Saját szerkesztés, MATLAB). .....	30


## NYILATKOZAT

Dr. Gáspár Sándor (név) (hallgató Neptun azonosítója: GBKBTP) konzulenseként nyilatkozom arról, hogy a szakdolgozatot áttekintettem, a hallgatót az irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól tájékoztattam.

A záródolgozatot/szakdolgozatot/diplomadolgozatot/portfóliót a záróvizsgán történő védésre javaslom / **nem javaslom**.

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen **nem**

Kelt: Gödöllő, 2025.10.27.



belső konzulens

## **MATE Szervezeti és Működési Szabályzat**

### **III. Hallgatói Követelményrendszer**

#### **III.1. Tanulmányi és Vizsgaszabályzat**

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

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

### **NYILATKOZAT**

#### **a szakdolgozat nyilvános hozzáféréseiről és eredetiségéről**

A hallgató neve: Földi Tamás  
A Hallgató Neptun kódja: GBKBTP  
A dolgozat címe: Takagi-Sugeno neurofuzzy modell alkalmazása európai bankok részvényárfolyamaira  
A megjelenés éve: 2025  
A konzulens intézetének neve: Vidékfejlesztés és Fenntartható Gazdaság Intézet  
A konzulens tanszékének a neve: Befektetési, Pénzügyi és Számviteli Tanszék

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

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

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

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

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

- nem titkosított dolgozat a védést követően
- titkosításra engedélyezett dolgozat a benyújtásától számított 5 év eltelte után

nyilvánosan elérhető és kereshető lesz az Egyetem könyvtári repozitori rendszerében.

Kelt: Isaszeg, 2025. 10. 28.



Hallgató aláírása

# Hallgatók, doktoranduszok nyilatkozata mesterséges intelligencia (MI) alkalmazásáról

## 1. Általános adatok

Hallgató neve:	Földi Tamás
Neptun-kódja:	GBKBTP
Képzési szint (a megfelelőt jelölje X-szel):	<input checked="" type="checkbox"/> BSc/BA <input type="checkbox"/> MSc/MA <input type="checkbox"/> Doktori (PhD) <input type="checkbox"/> Egyéb: .....
Tantárgy neve/kódja*:	Szakdolgozat
A munka címe:	Takagi-Sugeno neurofuzzy modell alkalmazása európai bankok részvényárfolyamának előrejelzésére

\* doktori értekezés esetén nem kitöltendő

## 2. Nyilatkozat az MI használatáról

Alulírott, etikai felelősségem teljes tudatában az alábbi nyilatkozatot teszem:

(Kérjük, válasszon egyet az alábbi lehetőségek közül!)

A) Nem alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.

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

B) Alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.

(Kérjük, töltsse ki a vonatkozó táblázatokat!)

## 3. A mesterséges intelligencia használatának részletezése

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

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

A felhasználás célja	Alkalmazott MI-eszköz neve és verziója	Érintett rész (ha nem a szöveg egészére vonatkozik)
Szövegszerkesztés, ötletelés, információgyűjtés, fordítás, MATLAB kódolás	ChatGPT, 4.0	

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

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

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

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

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

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

Oktató vagy témavezető által előírt szabályok:

**„Közvetlen MATLAB kód elfogadása nem ajánlott csak ellenőrzés után.”**

### 4. Minden hallgatóra vonatkozó nyilatkozat:

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

**Kelt:** Isaszeg, 2025. október 27.

Hallgató aláírása

Konzulens/Témavezető aláírása