

Lénárt Balázs, Cimer Mónika

## Mesterséges Intelligencián alapuló eljárások az értékteremtő láncok irányításában



Lénárt Balázs a Budapesti Műszaki és Gazdaságtudományi Egyetem Közlekedésmérnöki Karán szerzett okleveles közlekedésmérnöki diplomát, majd a BME közlekedésüzemi tanszékén kezdte meg Ph.D. tanulmányait, melynek témája Üzleti Intelligencia megoldások logisztikai célú alkalmazásának továbbfejlesztése Mesterséges Intelligencia megoldások integrálásával.  
E-mail: lenart@kku.bme.hu



Cimer Mónika a Budapesti Műszaki és Gazdaságtudományi Egyetem V. éves közlekedésmérnök hallgatója. Szakirányként a logisztikát, azon belül is a Logisztikai folyamatok szervezése szakmai blokkot választotta. Tanulmányaihoz kapcsolódóan „Készletszabályozó rendszer megvalósítása Neuro-Fuzzy logika alkalmazásával” címmel a BME Közlekedésüzemi Tanszéken az Innovatív Logisztikai Kutatások Tehetséggondozó Műhely ösztöndíjasakén TDK dolgozatot készít, mely egyben a szakdolgozata alapját is képezi.  
E-mail: monika.cimer@gmail.com

---

Absztrakt: A tanulmány a készletezési problémák korszerű, mesterséges intelligenciával támogatott megoldásaival foglalkozik. A készletezési elmélet a szakirodalom szerint két fő szorosan összetartozó részre bontható, a kereslet előrejelzésre, illetve készletgazdálkodásra. A dolgozatban bemutatásra kerül egy korszerű kereslet előrejelzési eljárás, az integrált autoregressziós mozgóátlag (ARIMA) neurális hálózattal való automatikus függvény identifikációja, illetve egy Neuro-Fuzzy logikával megvalósított készletszabályozó rendszer.

---

### 1.Bevezetés

Az elmúlt évtizedben a mesterséges intelligencia (MI) módszerek számos tudományterületen kerültek előtérbe. Ennek elsődleges oka, hogy a mesterséges intelligencia módszerek alapját a természetben lezajló biológiai folyamatok képezik, illetve az emberi gondolkodást modellezzik. Azaz képesek a környezet bizonytalansága és pontatlansága ellenére is racionális döntések meghozatalára (Borgulya, 1998). Ezt a tulajdonságot felhasználva korszerűsíthetővé válnak a logisztikai rendszerek tervezésében és üzemeltetésében használatos eljárások. Ilyenek lehetnek a teljesség igénye nélkül a készletezési, hozzárendelési, körjárat szerkesztési, továbbá többkritériumos döntési problémák is.

A jelenlegi kutatás a készletezés elmélethez kapcsolódóan két területre terjed ki. Egyrészt foglalkozik a keresleti idősor elemzési módszereinek továbbfejlesztésével az előrejelzés pontosságának növelése érdekében. A vizsgált előrejelzési módszer az integrált autoregressziós mozgóátlag (ARIMA; Box-Jenkins 1970), amellyel kiváló előrejelzési pontosságot lehet elérni abban az esetben, ha sikerül az eredeti idősort megfelelően identifikálni. Cél annak a bemutatása, hogy az automatikus függvény


identifikáció neurális hálózattal is megvalósítható, sőt tanulási képessége révén akár nagyobb a felismerési hatékonysága, mint a hagyományos eljárásoknak.

A kutatás másik területét a készlet szabályozás képezi. Tulajdonképpen egy olyan készlet szabályozó rendszer megvalósítása a cél, amelynek szabályozó algoritmus a Neuro-Fuzzy logikán alapul, vagyis a bemenő paraméterek közötti kapcsolat rendszer matematikai modellezése nélkül kerül meghatározásra az optimális készlet nagyság a költségek és a készlethiány minimalizálása mellett. A rendszer javaslatot ad az adott termékkel kapcsolatos rendelésütemezési paraméterekre, ezáltal támogatható az operatív döntéshozó munkája, és növelhetővé válik a logisztikai folyamatok hatékonysága.

## 2. Az automatikus identifikáció nehézségei

Az ARIMA modell általános identifikációs eljárása „ideális” függvények esetén hibátlanul működik (Péter, Várlaki 1984, 1986), azonban a való életben ritkán dolgozunk ilyen függvényekkel, az adataink legtöbbször hibával terheltek. A készletgazdálkodásban igen gyakori, hogy a keresleti idő sorban megjelennek olyan kiugró értékek vagy hiányok (nem várt eseti megrendelés, készlethiány), amelyek valójában a rendszer működése szempontjából irrelevánsak. Ezek az oda nem illő értékek, mint outlierok (1. ábra) megjelennek a parciális autokorreláció (PACF) és autokorreláció (ACF) függvényekben is, lehetetlenné téve a hagyományos és automatikus identifikálási módszert.

1. ábra: Outlierek PACF függvényben



Forrás: Saját szerkesztés


Az outlierok kiküszöbölésére számos teszt és módszer ismert, ilyen például Bartlett hibahatár választása (Bartlett 1937), Level-1, Level-2 Distance Test (Tran 2004), Multi Criteria Identification (MC-ID; Bóna,

Lénárt 2009). Az itt felsorolt tesztek egyike sem képes arra, hogy az identifikációt minden esetben tökéletesen végrehajtsa. Sok esetben egy szakértő számára az outlier egyértelműen kitűnik, az identifikálás során nem veszi figyelembe, az emberi elme az adatok vizsgálatakor – a legtöbb esetben – egyértelműen meg tudja határozni az legjobb  $p$  illetve  $q$  értékeket. Ez adja az ötletet arra, hogy vétezzük fel tanulási képességgel az identifikációs algoritmusunkat. Ez egy neurális hálózat az identifikációs folyamatba ágyazásával érhető el, majd ennek a neurális hálózatnak át lehet adni a szakértői tudást, ezáltal csökkentve a hibás identifikációk számát.

### 3. Az előrejelzési modell nehézségei

Az előrejelzési modell két fő részre bontható, az automatikus identifikációs modulra és az előrejelző modulra (2. ábra). Az első modul kezdeti lépésében a PACF és ACF függvények előállítását történik, azonban ezután a korábban megemlített logikai identifikációs módszereket (teszteket) egy tanulási képességgel ellátott neurális hálózatra (NEURO AUTO ID) cseréljük. Az identifikációs modul kimenete továbbra is az  $ARIMA(p,d,q)$  függvény paraméterei lesznek. Ilyen paraméterhalmazból a kezdeti tanulási szakaszban több is lehet, azonban később ez a szám előreláthatólag egy függvényre csökken. A kezdeti tudást egy szakértői tréning adatbázis biztosítja, majd működés közben a legjobban illeszkedő  $y(t)$  kimenet  $(p,d,q)$  paraméterei is visszacsatolásra kerülnek a neurális hálózatra, és azt feltételezzük, hogy a folyamatos tanulás hatására az identifikálás pontossága nő.

**2. ábra: Előrejelzési modell**



Forrás: Saját szerkesztés

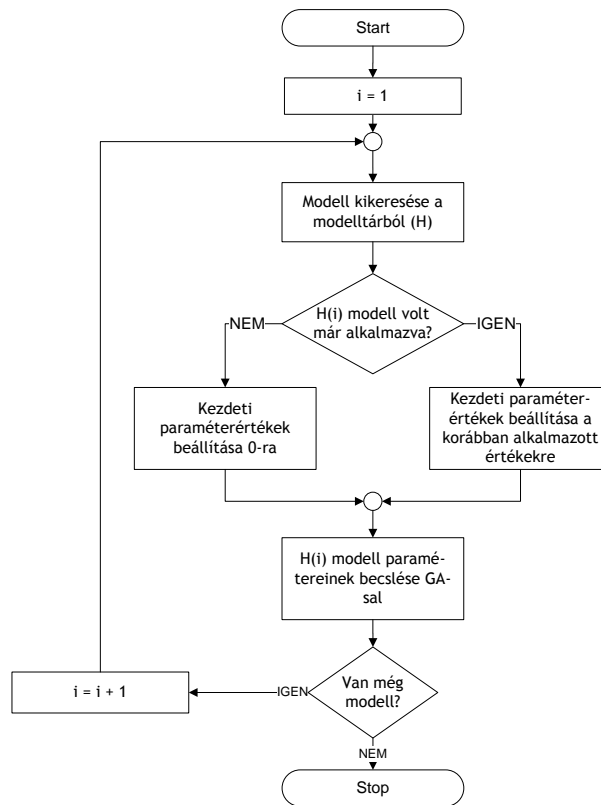
A második modul felelős az előrejelzések elkészítéséért. Kezdetben az identifikációs modul több  $(p,d,q)$  paraméter kombinációt ad át, ezek mindegyike kiszámításra kerül. A kiszámítás egy úgynevezett paraméterbecslési  $(\varphi, \vartheta)$  feladat, melynek célja az  $ARIMA(p,d,q)$  függvény eredeti idősorra való illesztése. Ez egy többparaméteres optimumkeresési feladat, ezért annak valamely evolúciós eljárás, például genetikussal való megoldása javasolt. Ezután a megkapott eredmények közül ki kell

választani azt, amely a legjobban illeszkedik az eredeti idősorra. Az illeszkedés pontosságának meghatározására több eljárás ismert, ezek lehetnek egyszerű statisztikai jellemzők, mint például az abszolút hiba átlaga (MAE), abszolút százalékos hiba átlaga (MAPE), vagy ARIMA specifikus kritériumok, mint a Final Prediction Error (FPE; Shibata 1984), Akaike információs kritérium (AIC; Akaike 1974) és a normalizált Bayesian információs kritérium (nBIC; Liddle). Ezen kritériumok együttes figyelembevételére egy többkritériumos döntéshozó algoritmus került kidolgozásra, amely segítségével a legjobban illeszkedő modell egyértelműen kiválasztható.

#### **4. Paraméterbecslés genetikus algoritmussal**

Az alkalmazható ARIMA modellek közül az identifikáció során kiválasztott modelleket jelölje  $H$  halmaz. A modellek matematikai felépítése  $p, d, q$  változóktól függ, amelyet az identifikáció során az identifikációs modul algoritmusai állapítottak meg. Ezek felhasználásával az ún. operátor egyenletek segítségével építhető fel a vizsgálandó  $H(i)$  ARIMA modell. Az operátor egyenlet lehetőséget biztosít arra, hogy a vizsgált modellben szereplő paraméterek közötti matematikai összefüggéseket kifejtsük. A megbecsülendő paraméterek egy tetszőleges  $H(i)$  ARIMA modell esetében az autoregresszív ( $\varphi$ ), illetve a mozgóátlag ( $\vartheta$ ) paraméterek, melyek kiszámítása a már említett genetikus algoritmus segítségével történik. A genetikus algoritmus egy olyan globális szélsőérték kereső eljárás, amely a jelen eljárásban a legkisebb négyzetek módszerén alapulva, a természetes kiválasztódás elvét matematikailag modellezve keresi meg a vizsgált tervezési egyed keresleti idősorához leginkább illeszkedő  $H(i)$  modellbeállítást a modell paramétereinek folyamatos (iteratív) változtatását felhasználva. A paraméterbecslés utolsó lépése a fent definiált módon optimalizált paraméterértékek mentése az aktuálisan vizsgált  $H(i)$ -hez, hiszen ezeket a későbbi fázisokban újra fel kell használni. Az előbb definiált paraméterbecslési alfolyamatot minden (a vizsgált tervezési egyedhez) identifikált modell esetében végre kell hajtani. A paraméterbecslés nagyvonalú folyamatát a 3. ábra szemlélteti.

### 3. ábra: A paraméterbecslés folyamata



Forrás: Saját szerkesztés

### 5. A neurális hálózat illesztése a rendszerbe

A mesterséges neurális hálózat neuronok összekapcsolt hálózata, lényegében egy biológiai indíttatású eljárás, amely a biológia neurális hálózat néhány tulajdonságát modellezi. A neurális hálózatok legfontosabb tulajdonsága a tanulási képesség, ami azt jelenti, hogy a tanulási folyamat közben úgy tudják változtatni belső paramétereiket, hogy az adott bemeneti mintához a kívánt kimeneti adatokat képezzék le. Ez teszi a neurális hálózatokat különösen hatékonyá olyan területen, ahol a rendszert irányító leképezés nem teljesen egzakt vagy leírható, de az adatok elegendő számú helyes be-kimeneti kombinációja (Bishop 1995). A kutatás célja annak kimutatása, hogy az idősor neurális hálózattal való automatikus identifikálása hatékonyabb, hibátűrése nagyobb, mint a - korábban említett - használatban lévő eljárásoknak, továbbá tanulási képessége révén alkalmazkodni tud a folyamatosan változó környezethez.

A modell felállításkor fontos a hálózat be és kimeneteinek definiálása, illetve a struktúra típusának és tanulás módjának kiválasztása. A vizsgálat alapesetében egy teljesen összekapcsolt hálózatot (fully connected ANN) használunk, amelyben egyszerre több ARIMA(p,d,q) modell kiválasztása is megtörténik. A kiválasztott függvények ezután kiszámításra kerülnek az előrejelző modulban, majd egy többkritériumos döntéshozó algoritmus (MC Information Criteria) kiválasztja a legjobban illeszkedő

változatot. Ez a kiválasztott változat kerül felhasználásra a hálózat tanítása céljából. A tanítást hiba visszaterjesztés elvén (Backpropagation) (Bryson, Yu-Chi Ho 1969) működő eljárással tervezem megoldani.

## **6. Készletszabályozás**

A kutatási célok szempontjából elsőként egy készletszabályozó rendszer működésével kapcsolatban támasztott követelmények definiálása szükséges. Ezek alapján egy szabályozó rendszer feladata az adott (termelési, fogyasztási stb.) folyamatrendszer készletezési stratégia/stratégiák működtetése, gazdasági és/vagy megbízhatósági szempontok alapján optimalizált készletszint meghatározása és annak dinamikus szinten tartása. A szabályozó rendszer közvetlenül az anyagi rendszerhez kapcsolódik, melynek folyamatait térben és időben szabályozza (Bóna, 2005). Pontosabban az ellátási lánc egyes pontjain generált rendelésfeladásokon keresztül hatást gyakorol az egyes pontokon képződő készletmennyiségekre, ezáltal a teljes készletezési folyamat hatékonyságára.

Az optimális készletszint meghatározása a gyakorlatban általában operatív munkavégzés során a készletezési rendszer működése révén szerzett tapasztalatokat felhasználva, illetve készletezési modellek alkalmazásával történik. Az első esetben a döntéshozó szubjektivitása miatt előfordulhat, hogy az általa meghatározott készletszint jelentős mértékben eltér az adott körülmények szempontjából optimális tekinthető készletmennyiséggel, azaz készlethiány vagy túlkészletezés jön létre. A készletmodellek ezzel szemben csak meghatározott szabály- és feltételrendszer esetén alkalmazhatóak. Ezért sok esetben a készletezési probléma megoldását nehezíti a megfelelő készletmodell kiválasztása, vagy éppen az alkalmazandó modell bonyolultsága, és az általa megkívánt számítási kapacitás nagysága.

Összefoglalva a cél egy olyan készletszabályozó rendszer megvalósítása, mely a folyamat jellegétől függetlenül, a folyamatot alkotó elemek közötti matematikai összefüggések ismerete nélkül, költségminimalizáló és megbízhatósági szempontokat figyelembe véve képes a készletmennyiség folyamatos optimalizálására, továbbá annak bizonyítása, hogy e célok megvalósítására alkalmas a Neuro-Fuzzy logika.

## **7. Készletszabályozó elvi felépítése**

A következőkben a megvalósítandó készletszabályozó rendszer (4. ábra) inputjai kerülnek meghatározásra. Azaz a készlet pillanatnyi nagyságát befolyásoló peremfeltételek, egzakt módon vagy valószínűségi változóként leírható paraméterek definiálása szükséges, melyek a későbbiekben a

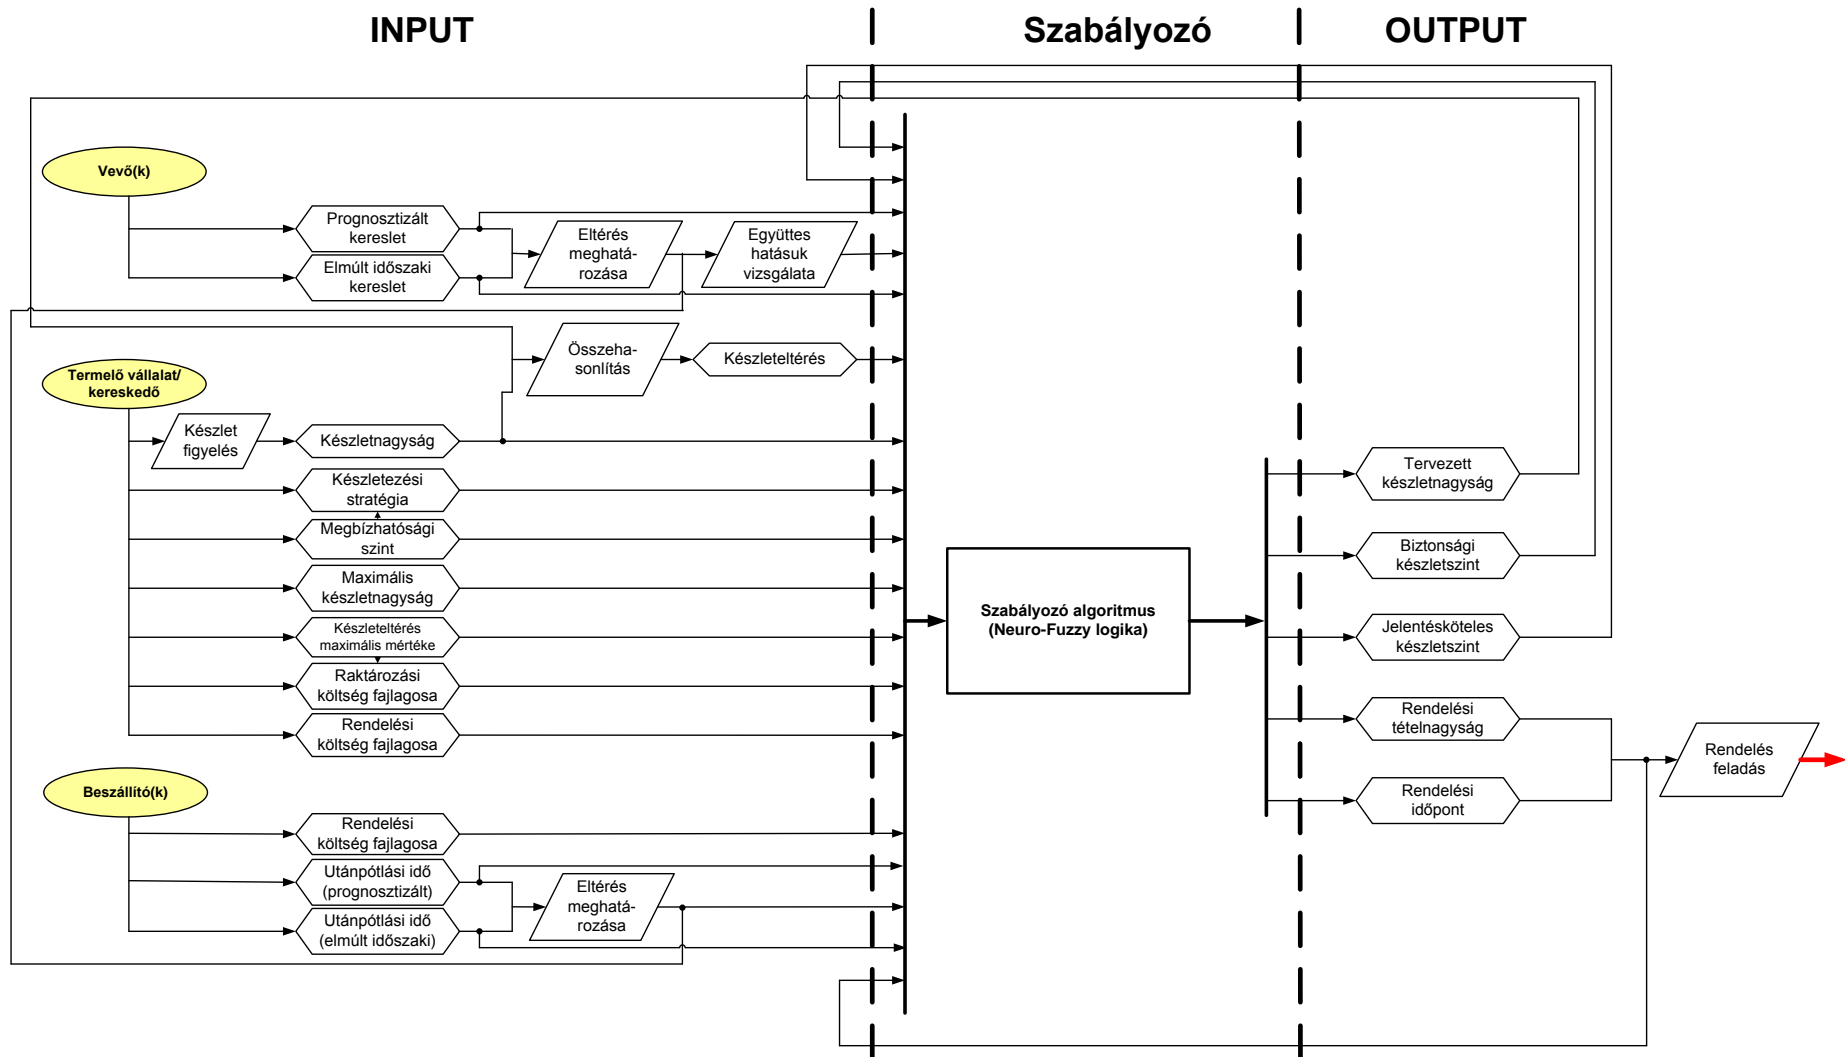
készletszabályozóban integrálásra kerülnek. A vizsgált tényezőket minden esetben a feladat jellege, illetve a szabályozó rendszer működtetésével elérni kívánt célok, továbbá az ez által meghatározott bonyolultsági szint határozhatja meg. Ezen tényezőket csoportosíthatjuk aszerint, hogy a vizsgált anyagáramlási folyamat mely szereplőjéhez köthető. Ez alapján beszélhetünk a vizsgált szereplő szempontjából a beszállító, a termelő (vagy kereskedő) vállalat és a vevők által generált tényezőkről.

Az inputok közé nemcsak a szabályozás szempontjából alapjelnek minősülő tényezők tartoznak, hanem a zavaró jelek, illetve a visszacsatolt jelek is. Zavaró jelnek tekinthető a kereslet és az utánpótlási idő tényleges nagysága. Az említett két tényezőnél összehasonlításra kerül a vizsgált időszakot közvetlenül megelőző időszak prognosztizált értékei a tény értékekkel. Az összehasonlítás eredményeként képződő különbségek nagyságából következtetni lehet a tény érték terv értékétől való eltérés változásának irányra és mértékére, ezáltal lehetőség nyílik az előre nem várt események hatásának mérséklésére.

A készletszabályozás elsődlegesen idővezérelt, a szabályozó által meghatározott optimális rendelési tétel nagyság ( $q_r$ ) optimális nagyságú rendelési időközönként ( $t_r$ ) kerül feladásra. Vagyis a beszállító felé irányuló rendelés feladáson keresztül szabályozhatóvá válik a készletszint nagysága. A megbízhatósági szempontokat szem előtt tartva a szabályozónak meg kell határoznia egy optimális jelentésköteles és biztonsági készletszintet is. Az előzőekben felsorolt, a szabályozó algoritmus által meghatározott változók fogják alkotni a rendszer output oldalát. Egyben ezek outputok jelentik az input oldali visszacsatolt jeleket is. Ennek oka a készletszint dinamikus szinten tartásában rejlik, mely folyamatos optimalizálást követel meg a rendszertől. Ezért nemcsak  $t_r$  idő elteltével kell működésbe lépni a szabályozónak, hanem a folyamatok sztochasztikus jellege miatt a jelentésköteles készletszint, vagy a tervezett és a tényleges készletszint egy előre meghatározott maximális eltérésének elérésékor is.

A szabályozó algoritmus kialakítása mesterséges intelligencia módszerek felhasználásával történik, pontosabban a neurális hálózatok és a fuzzy rendszerek kombinációjából létrejött Neuro-Fuzzy logikán alapul. Az előzetes vizsgálatok alapján a Neuro-Fuzzy rendszerek közül a neuralizált fuzzy rendszer bizonyul a legmegfelelőbbnek a kitűzött célok megvalósítására. Ez a rendszer tulajdonképpen fuzzy rendszernek minősül, azaz bizonytalan jellegű adatokra építve közelítő következtetéssel modellezi a problémamegoldást. Ebben az esetben a neurális hálózat csak javító eszköznek tekinthető, ugyanis a fuzzy rendszer előnyös tulajdonságait erősíti, miközben a hiányosságait részben vagy teljes mértékben megszünteti. A neurális hálózat tanulási képességgel egészíti ki a fuzzy rendszert, így lehetségessé válik annak automatikus tervezése. Vagyis a többréteges neurális hálózat tanulása révén kerül kialakításra a fuzzy modell a hozzákapcsolódó tagsági függvényekkel és szabályrendszerekkel együtt, továbbá lehetővé válik a finom hangolása és optimalizálása, ezáltal jelentősen csökkenthető a fejlesztésre szánt idő és költség, mialatt a rendszer működése javul (Retter, 2007).

4. ábra: A készlet szabályozó elvi felépítése



Forrás: Saját szerkesztés



## 8. Összefoglalás

A kutatás során vizsgált eljárás alkalmas az automatikus ARIMA függvény identifikáció végrehajtására. Láthattuk, hogy a hagyományos identifikációs tesztek sokszor csak nehezen alkalmazhatók „nem ideális” idősorokra, illetve nem tudnak alkalmazkodni az input adatok jellegének változásaihoz. A neurális hálózattal végzett identifikáció ezzel szemben intuitív képessége révén kevésbé érzékeny a bemeneten megjelenő hibákra, továbbá tanulási képességének köszönhetően bizonyos számú tanulási lépést követően képes a rendszer olyan típusú idősorok identifikálására is, amelyekkel korábban még nem találkozott. Ez a képesség teszi különösen alkalmassá a logisztikai folyamatokba való integrálását. A bemutatott kereslet előrejelzési eljáráson kívül természetesen más problémák támogatására is használható. A neurális hálózat „tudását” és intuíciós képességét minden olyan területen felhasználhatjuk, ahol – a váratlanul fellépő változások kezelésére – a korábban megszerzett tapasztalat alapján gyors döntéseket kell hozni. Így például a készletezési döntési probléma megoldására, ahol tulajdonképpen neurális hálózat és fuzzy rendszer kombinációja kerül kialakításra. A neurális hálózat tanuló képességét felhasználva hozzuk létre a fuzzy modellt, mely a módszer lényegéből eredően a folyamatot jellemző paraméterek bizonytalanságára építve közelítő következtetéssel határozza meg az optimális készletnagyságot. Ezáltal a rendszer kiválóan tud alkalmazkodni és reagálni az esetleges váratlan események következtében fellépő hatásokra. Mindkét módszer esetében hatékonysága és pontossága a már korábban megszerzett tudáson múlik, ezért nagy figyelmet kell fordítani az eljárás tervezésére, majd üzemeltetésére. Amennyiben így járunk el, akkor egy robosztus, gyors és rugalmas rendszert kapunk, amelyben jól kezelhetők a véletlen fellépő vagy ismeretlen események.

## HIVATKOZÁSOK

- [1] Borgulya István (1998). *Neurális és fuzzy rendszerek*, Dialóg Campus Kiadó, ISBN 963 9123 27 7
- [2] Box, George and Jenkins, Gwilym (1970). *Time series analysis: Forecasting and control*, San Francisco: Holden-Day.
- [3] Akaike, Hirotugu (1974). *A new look at the statistical model identification*, IEEE Transactions on Automatic Control 19 (6): 716–723.
- [4] Bartlett, M. S. (1937). *Properties of sufficiency and statistical test*,. Proceedings of the Royal Statistical Society Series A 160, 268–282.
- [5] Bóna, K., Lénárt, B. (2009). *Idősor előrejelzés SARIMA módszerrel* (Kutatási összefoglaló)
- [6] Bishop, C.M. (1995). *Neural Networks for Pattern Recognition*, Oxford: Oxford University Press. ISBN 0-19-853849-9
- [7] Bryson Arthur Earl, Yu-Chi Ho (1969). *Applied optimal control: optimization, estimation, and control*, Blaisdell Publishing Company or Xerox College Publishing. pp. 481.
- [8] Liddle, A.R., *Information criteria for astrophysical model selection*, [http://xxx.adelaide.edu.au/PS\\_cache/astro-ph/pdf/0701/0701113v2.pdf](http://xxx.adelaide.edu.au/PS_cache/astro-ph/pdf/0701/0701113v2.pdf)
- [9] Péter T, Prezenszki J, Várlaki P (1984). *A rakodási rendszerek dinamikájának vizsgálata*, KÖZLEKEDÉSTUDOMÁNYI SZEMLE XXXIV:(5) 208-219
- [10] Péter T, Korcsog A (1986) *Rakodási rendszerek input-output folyamatainak jellemző periodicitásának vizsgálata*, AUTOMATIZÁLÁS XIX:(6) 26-33
- [11] Shibata 1984. R. Shibata, *Approximate efficiency of a selection procedure for the number of regression variables*, Biometrika 71 (1984), pp. 43–49.
- [12] Tran Nancy, Member, Reed Daniel A.: *Automatic ARIMA Time Series Modeling for Adaptive I/O Prefetching*, IEEE TRANSACTIONS ON PARALLEL AND DISTRIBUTED SYSTEMS, VOL. 15, NO. 2, FEBRUARY 2004
- [13] Retter Gyula (2007). *Kombinált fuzzy, neurális, genetikus rendszerek*, ISBN 978 963 87401 0 6
- [14] Bóna Krisztián (2005). *Készletezési folyamatok és rendszerek, készletezés-elmélet*, (Egyetemi jegyzet)