

# Kutatási Jelentés

**Téma azonosítója: JKL-P7-T3**

**Téma megnevezése: Mesterséges intelligencia alapú technológiák alkalmazása a logisztikai rendszerek tervezésében és operatív irányításában jelentkező feladatok támogatására**

**4. munkaszakasz (2011.09.25.): Mintarendszer modelljének megalkotása a keresletelőrejelzés területén**

- 1.1** A keresleti folyamat sajátosságainak vizsgálata, a kereslet modellezésének hagyományos lehetőségei ARIMA, SARIMA módszertanok segítségével
- 1.2** A tervezett keresletelőrejelző modell működésének logikai tervezése, az eddig alkalmazott módszertanok soft computing technikákkal való helyettesítési lehetőségeinek vizsgálata, mintarendszer koncepciójának, illetve rendszertervének kidolgozása
- 1.3** ARIMA, SARIMA paraméterbecslés mesterséges intelligencián alapuló módszereinek vizsgálata, a futási idő csökkentése, illetve az előrejelzési pontosság növelése céljából

**Az összefoglalót készítette:** Lénárt Balázs, tanársegéd

BME Közlekedésmérnöki Kar, Közlekedésüzemi Tanszék

**Témavezető:** Dr. Bóna Krisztián PhD, adjunktus

BME Közlekedésmérnöki Kar, Közlekedésüzemi Tanszék

## 1.1. A keresleti folyamat sajátosságainak vizsgálata, a kereslet modellezésének hagyományos lehetőségei ARIMA, SARIMA módszertanok segítségével

Az ARIMA és annak rokon változatai (ARMA, SARIMA, XARIMA) az idősor elemzésnek egy jól bevált módszere. Az eljárást gyakran nevezik Box-Jenkins féle módszernek [1] is. Az eljárás alkalmazva a kiválasztott ARIMA függvény megfelelő paraméterválasztás után megfelelően tud illeszkedni egy adott  $Y(t)$  idősorra, így lehetővé válik pontos előrejelzések készítése. A modell három fő részre bontható autoregresszív (AR), mozgó átlag (MA) és integráló (I) tagra. Az idősor közelítésére használt modellt ARIMA(p,d,q) módon szokás jelölni, melyben p az autoregresszív tag, d az integráló tag, q a mozgó átlag tag fokszámát jelöli. A modellek matematikai felépítése a p, d, q változóktól függ, amelyet az bemeneti idősor *identifikációjával* állapíthatunk meg. Ezek felhasználásával az ún. operátor egyenlet (1) segítségével építhető fel a vizsgálandó ARIMA modell [8]:

$$\varphi_p(\mathfrak{B}) \cdot \nabla^d \cdot Y(t) = \vartheta_q(\mathfrak{B}) \cdot e(t) , \text{ ahol} \quad (1)$$

$Y(t)$  az eredeti idősor,  $e(t)$  a reziduál sor, más néven fehér zaj (becslési hiba) és  $\mathfrak{B}$  az eltolási operátor. Az operátor egyenlet lehetőséget biztosít arra, hogy a vizsgált modellben szereplő paraméterek közötti matematikai összefüggéseket kifejtjük. A megbecsülendő paraméterek egy tetszőleges ARIMA modell esetében:

- autoregresszív paraméterek:  $\varphi_1 \dots \varphi_p$ ,
- mozgóátlag paraméterek:  $\vartheta_1 \dots \vartheta_q$ .

A paraméterbecslést a legkisebb négyzetek módszere (LSQ) a legelterjedtebb, amely a legtöbb esetben kielégítő eredménnyel szolgál. Azt a megoldást keressük, melyre az LSQ eredménye minimum lesz.

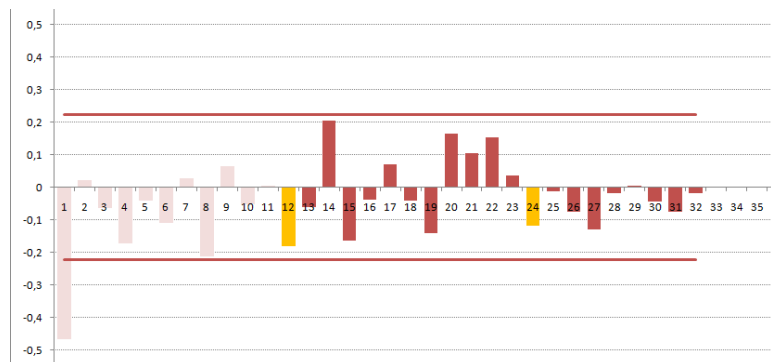
### Identifikáció

Egy keresleti idősor statisztikai identifikációja az idősor jellemző viselkedésének felderítésével az idősort lehető legjobban leíró matematikai-statisztikai modell megkeresését jelenti. Identifikáció nélkül nem áll rendelkezésre elegendő információ arról, hogy egy adott keresleti idősort milyen matematikai statisztikai modellel lehet a leghatékonyabban előrejelezni, így csak a tapasztalatokra lehet hagyatkozni. A keresleti idősor viselkedésének

vizsgálata két, a keresleti idősből előállítható statisztikai függvény jellemzőinek feltárásával valósítható meg. Ez a két függvény:

- a parciális autokorrelációs (PACF), illetve
- az autokorrelációs (ACF) függvény.

Az autokorrelációs függvények vizsgálatával sok területen érhetünk el érdekes eredményeket, ilyen pl. a folyamatok jellemző periodicitásának vizsgálata [5][6][7]. A viselkedés feltárása tehát a fentebb felsorolt két függvény előállítását követően az PACF és a ACF vizsgálatával lehetséges. A parciális autokorrelációs függvény (1. ábra) az autoregressziós tag  $p$  értékét, míg az autokorrelációs függvény (2. ábra) a mozgóátlag tag  $q$  értékét mutatja meg.

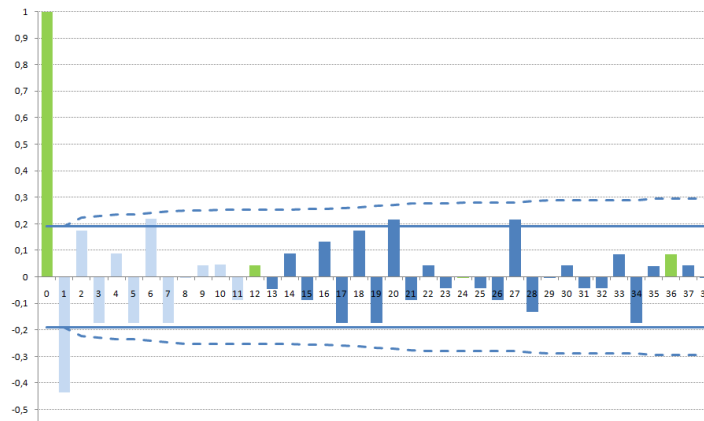


**1. ábra: Parciális autokorrelációs függvény (PACF)**

A két paraméter meghatározásához először az ACF és PACF alsó és felső hibahatár (2) kiszámítása szükséges, melyet 5%-os szignifikancia szint mellett a legegyszerűbben az alábbi módon kapható meg:

$$H \approx \pm \frac{2}{\sqrt{n}}, \text{ ahol} \quad (2)$$

$n$  az elemzendő PACF és ACF idősor hossza. Természetesen létezik más hibaszint meghatározási módszer, azonban jelenleg azok a tárgyalásától eltekintünk. A hibahatár meghatározása azért fontos, mert a továbbiakban a hibahatáron belül elhelyezkedő értékektől eltekintünk.




**2. ábra: Autokorrelációs függvény (ACF)**

A kérdéses paraméterek meghatározásának módjára Box és Jenkins egy egyszerű eljárást javasol, miszerint  $p$  értékét a PACF függvény,  $q$  értékét az ACF függvény utolsó szignifikáns értékének helye (lag) adja meg.

### Automatikus identifikáció nehézségei

Az ismertett idősor identifikációs eljárás „ideális” függvények esetén hibátlanul működik, azonban a való életben ritkán dolgozunk ilyen függvényekkel, az adataink legtöbbször hibával terheltek. A készletgazdálkodásban igen gyakori, hogy a keresleti idősorban gyakran 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 (3. ábra) megjelennek a PACF és ACF függvényekben is, lehetetlenné téve a hagyományos és *automatikus* identifikálási módszert.




**3. ábra: Outlierek PACF függvényben**

Az outlierok kiküszöbölésére számos teszt és módszer ismert, ilyen például Bartlett hibahatár [2] választása, Level-1, Level-2 Distance Test [3], Multi Criteria Identification (MC-ID) [4]. 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.

## 1.2. A tervezett keresletelőrejelző modell működésének logikai tervezése, az eddig alkalmazott módszertanok soft computing technikákkal való helyettesítési lehetőségeinek vizsgálata

Az előrejelzési modell két fő részre bontható, az automatikus identifikációs modulra és az előrejelző modulra (4. 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 paramétereire 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) paramétereire is visszacsatolásra kerülnek a neurális hálózatba, és azt feltételezzük, hogy a folyamatos tanulás hatására az identifikálás pontossága nő.



4. ábra: Előrejelzési modell

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 paraméterkeresési  $(\varphi, \vartheta)$  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) [9], Akaike információs kritérium (AIC) [10] és a normalizált Bayesian információs kritérium (nBIC) [11]. Ezen kritériumok együttes figyelembevételére egy

többkritériumos döntéshozó algoritmus került kidolgozásra, amely segítségével a legjobban illeszkedő modell egyértelműen kiválasztható.

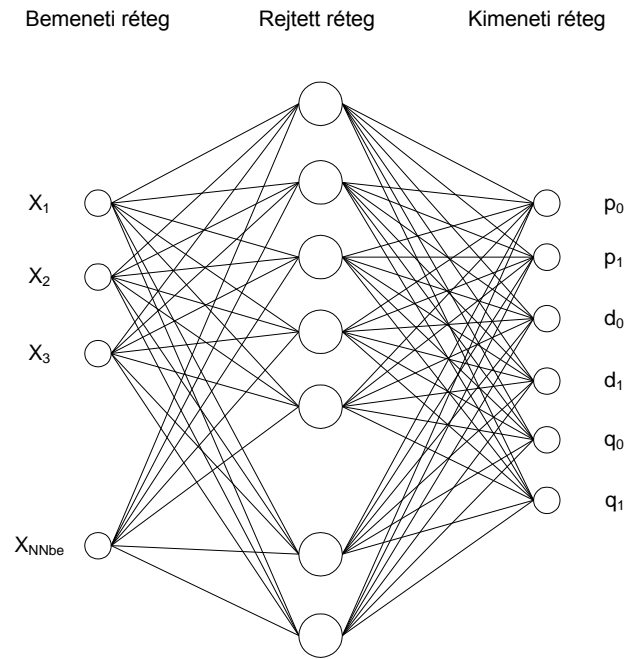
### **A neurális hálózat illesztése a rendszerbe**

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 ismert [12]. A kutatás célja annak kimutatása, hogy az idősor neurális hálózattal való automatikus identifikálása hatékonyabb, hibatűrése nagyobb, mint a - korábban említett - használatban lévő eljárásoknak, továbbá tanulási képessége révén alkalmazkodni tud a folyamatosan változó környezethez.

A modell felállításakor fontos a hálózat be és kimeneteinek definiálása, illetve a struktúra típusának és tanulás módjának kiválasztása (5. ábra). A vizsgálat alapesetében egy teljesen összekapcsolt hálózatot (fully connected ANN) használunk. Tekintsük a neurális hálózat bemeneteinek az időorból képzett PACF és ACF függvények értékeit. A bemenetek száma az idősor hosszától és differenciálás fokszámától függ. Amennyiben az idősor hossza  $T$  és a differenciál képzés fokszáma  $D$ , akkor a neurális hálózat bemeneteinek száma:

$$NN_{BE} = \sum_{d=0}^D (T - d - 1). \quad (3)$$

A rejtett rétegben neuron számát tapasztalati úton választjuk meg, esetünkben azt NNBE kétszeresére választjuk. A kimeneti réteg 6 neuront tartalmaz. A neurális hálózat e kimeneti értékei határozzák meg a lehetséges modelleket. A fentebb vázolt okok miatt egyszerre több ARIMA(p,d,q) modell kiválasztása is megtörténik.



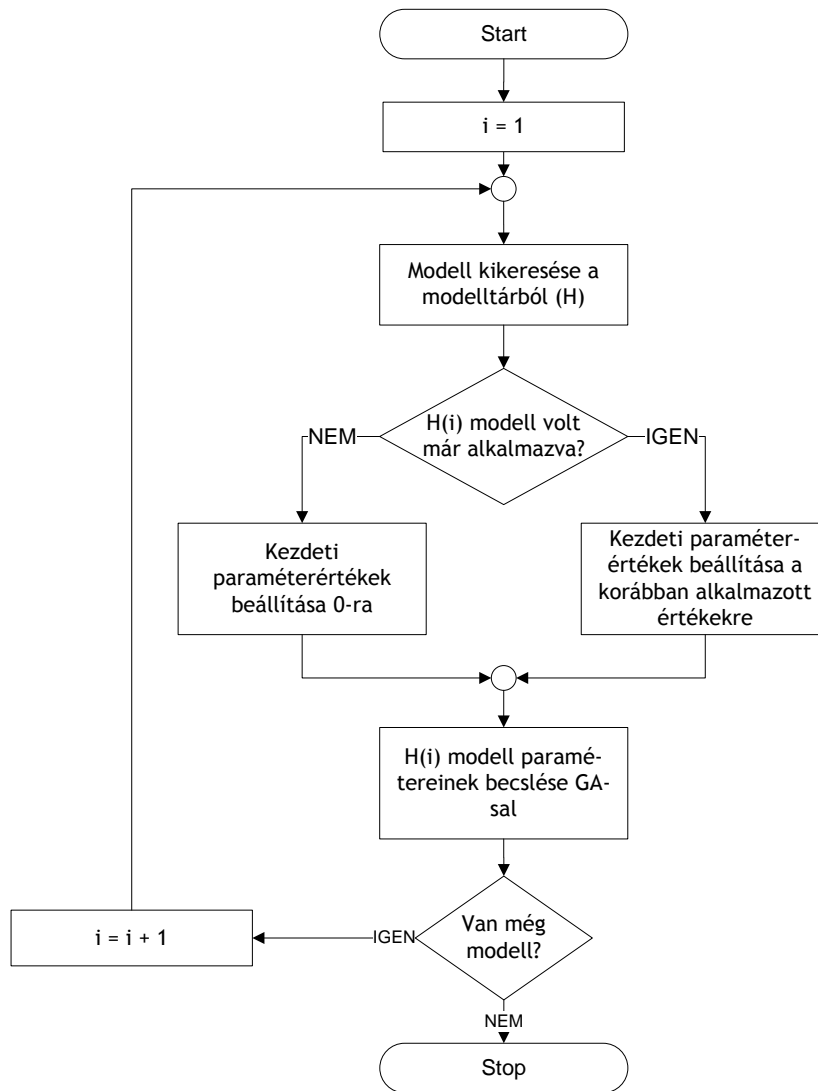
**5. ábra: Neurális hálózat**

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) [13] működő eljárással tervezem megoldani.



### **1.3. ARIMA, SARIMA paraméterbecslés mesterséges intelligencián alapuló módszereinek vizsgálata, a futási idő csökkentése, illetve az előrejelzési pontosság növelése céljából**

A paraméterbecslés megvalósítására a vizsgálat során Genetikus Algoritmus (GA) került kiválasztásra. Az ARIMA modellek matematikai felépítése  $p, d, q$  változóktól függ, amelyet az identifikáció során az identifikációs modul algoritmusai állapítanak meg. Az alkalmazható modellek közül az identifikáció során kiválasztott modelleket jelölje  $H$  halmaz. 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 ( $\phi$ ), illetve a mozgóátlag ( $\theta$ ) paraméterek, melyek kiszámítása a már említett genetikus algoritmus segítségével történik. A genetikus algoritmus egy olyan globális szélsőérték kereső eljárás, amely a legkisebb négyzetek módszerén alapulva, a természetes kiválasztódás elvét matematikailag modellezve keresi meg a vizsgált tervezési egyed keresleti idősorához leginkább illeszkedő (legjobban testreszabott)  $H(i)$  modellbeállítást a modell paramétereinek folyamatos (iteratív) változtatását felhasználva. Az előrejelző modulban alkalmazott GA egy úgynevezett valós vektoros számábrázolású (Floating Point Genetic Algorithm - FPGA) algoritmus. 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 6. ábra szemlélteti.



**6. ábra: A paraméterbecslés folyamata**

## Hivatkozások

- [1] Box, George and Jenkins, Gwilym (1970) *Time series analysis: Forecasting and control*, San Francisco: Holden-Day.
- [2] Bartlett, M. S. (1937). Properties of sufficiency and statistical tests. Proceedings of the Royal Statistical Society Series A 160, 268–282.
- [3] Nancy Tran, Member, Daniel A. Reed: *Automatic ARIMA Time Series Modeling for Adaptive I/O Prefetching*, IEEE TRANSACTIONS ON PARALLEL AND DISTRIBUTED SYSTEMS, VOL. 15, NO. 2, FEBRUARY 2004
- [4] Bóna, K., Lénárt, B. (2009): *Idősor előrejelzés SARIMA módszerrel* (Kutatási összefoglaló)
- [5] Péter T, Prezenszki J, Várlaki P (1984). A rakodási rendszerek dinamikájának vizsgálata, *KÖZLEKEDÉSTUDOMÁNYI SZEMLE XXXIV:(5)* 208-219
- [6] Péter T, Korcsog A (1986) Rakodási rendszerek input-output folyamatainak jellemző periodicitásának vizsgálata, *AUTOMATIZÁLÁS XIX:(6)* 26-33
- [7] Korcsog A, Péter T (1987) Bestimmung der dominanten Periodizität von Input- und Output-Prozessen bei einem Umschlagsystem. *WISSENSCHAFTLICHE ZEITSCHRIFT VON HFV DRESDEN 5*: 840-854
- [8] Michelberger P., Szeidl L., Várlaki P. (2001) Alkalmazott folyamatstatisztika és idősor-analízis, Typotex. ISBN 963-9132-44-6
- [9] Shibata 1984. R. Shibata , Approximate efficiency of a selection procedure for the number of regression variables. *Biometrika 71* (1984), pp. 43–49.
- [10] Akaike, Hirotugu (1974). "A new look at the statistical model identification". *IEEE Transactions on Automatic Control 19* (6): 716–723.
- [11] 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)
- [12] Bishop, C.M. (1995) *Neural Networks for Pattern Recognition*, Oxford: Oxford University Press. ISBN 0-19-853849-9
- [13] Arthur Earl Bryson, Yu-Chi Ho (1969). *Applied optimal control: optimization, estimation, and control*. Blaisdell Publishing Company or Xerox College Publishing. pp. 481.