

# Kutatási Jelentés

**Téma azonosítója: JKL-P7-T3**

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

**3. munkaszakasz (lezárva: 2011. 06. 25.): A tervezett készletszabályozó mintarendszer modelljének megvalósítása**

- 1.1. Az alkalmazott mesterséges intelligencia megoldások összehasonlítása, értékelése a készletezésben
- 1.2. A kidolgozott rendszerterv alapján a technikai specifikáció készítése a mesterséges intelligencia alapú készletszabályozóra
- 1.3. A technikai specifikációban definiált mintarendszer megvalósítása egy arra alkalmas programozási környezet alkalmazásával
- 1.4. A kifejlesztett mintarendszer validálása és verifikálása, tesztelése normál működés és extrém hatások esetére

**Az összefoglalót készítette:** Lénárt Balázs, PhD hallgató

BME Közlekedésmérnöki Kar, Közlekedésüzemi Tanszék

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

BME Közlekedésmérnöki Kar, Közlekedésüzemi Tanszék

## 1.1. Az alkalmazott mesterséges intelligencia megoldások összehasonlítása, értékelése a készletezésben

A készletezésben alkalmazott szabályzók megvalósítására kettő mesterséges intelligencia megoldást vizsgáltunk, ezek a neurális hálózatok és a Fuzzy rendszerek [1][4]. A neurális hálózatok és a fuzzy rendszerek egyaránt képesek bemenet-kimenet párok leképezésére a matematikai leírásuk ismerete nélkül. Vagyis mindkét rendszer ugyanazt a problémát képes megközelíteni eltérő módon és szinten. A tulajdonságaik összehasonlítására a következő táblázatban kerül sor.

**1. táblázat**  
A fuzzy rendszerek és a neurális hálózatok tulajdonságai [2]

	Tulajdonságok	Fuzzy rendszerek	Neurális hálózatok
<b>Közös tulajdonságok</b>	Inferencia	közelítő	közelítő
	Általánosítás	jó	nagyon jó
	Hiba tolerancia	jó	nagyon jó
	Bizonytalansági tolerancia	jó	jó
	Valós idejű működés	jó	nagyon jó
	Nemlinearitás	jó	jó
<b>Kiegészítő tulajdonságok</b>	Tudás reprezentálás	jó	rossz
	Tanulási képesség	nincs	nagyon jó
	Értelmezhetőség	nagyon jó	nincs
	Szakértői tudás	nagyon jó	nincs
	Numerikus adat	gyenge	nagyon jó
	Matematikai modell	nagyon jó	gyenge
	Optimalizálási képesség	gyenge	nagyon jó

A táblázatból is kiderül, bizonyos tulajdonságok esetén egyezőséget mutatnak, míg másoknál eltérnek (vagy nem rendelkeznek az adott tulajdonsággal). Annak érdekében, hogy ezeket a hiányosságokat csökkentsük, esetleg megszüntessük, valamint előnyeiket összevonjuk, erősítsük, létrehozhatók a kombinációik. Vagyis egy olyan tanulási és általánosító képességgel rendelkező rendszerhez juthatunk, amely pontatlan, valós kijelentésekre építve következtet, gondolkodik. Így a körülmények megváltozásához igazodva új viselkedésformákat tud kialakítani, ezáltal lehetőséget biztosít a valós folyamatok pontosabb modellezésére. Összességében elmondható, hogy a neurális hálózat és a fuzzy rendszer közös

vonásai lehetővé teszi a kombinálásukat, míg a kiegészítő tulajdonságaik kívánatossá, hasznossá.

A fuzzy rendszerek és neurális hálózatok kombinálása két irányban lehetséges:

- neuralizált fuzzy rendszerek,
- fuzzyfikált neurális hálózatok.

A neuralizált fuzzy rendszerek fuzzy rendszert jelent neurális hálózati köntösbe öltöztetve. Az alaprendszert tehát a fuzzy rendszer képezi, miközben a neurális háló csak kiegészítő eszköznek minősül, tanulási képességgel látja el a fuzzy rendszert. Ezáltal lehetővé válik a tagsági függvények és a szabályrendszer kialakítása, tanulása, valamint azok finom hangolása, így jelentősen csökkentve a fejlesztési időt és költségeket. A fuzzy rendszerek tervezhetővé és önadaptívvá válnak, miközben megőrzik a legfontosabb tulajdonságukat az emberi következtetést.

A fuzzyfikált neurális rendszerek alapvetően neurális hálózatok, amelyekbe beépítésre kerülnek a fuzzy elvek. Egy neurális hálózat mindenegyik része (aktivizációs függvény, bemeneti és kimeneti adatok, súlyszámok) topológiája, tanulási algoritmus is fuzzyfikálható, ezáltal javítható az üzeme, és robosztusabb működése érhető el. A neurális hálózat fuzzy logikával való kiegészítése révén növelhetővé válik a rendszer rugalmassága, robosztussága és gyorsassága.

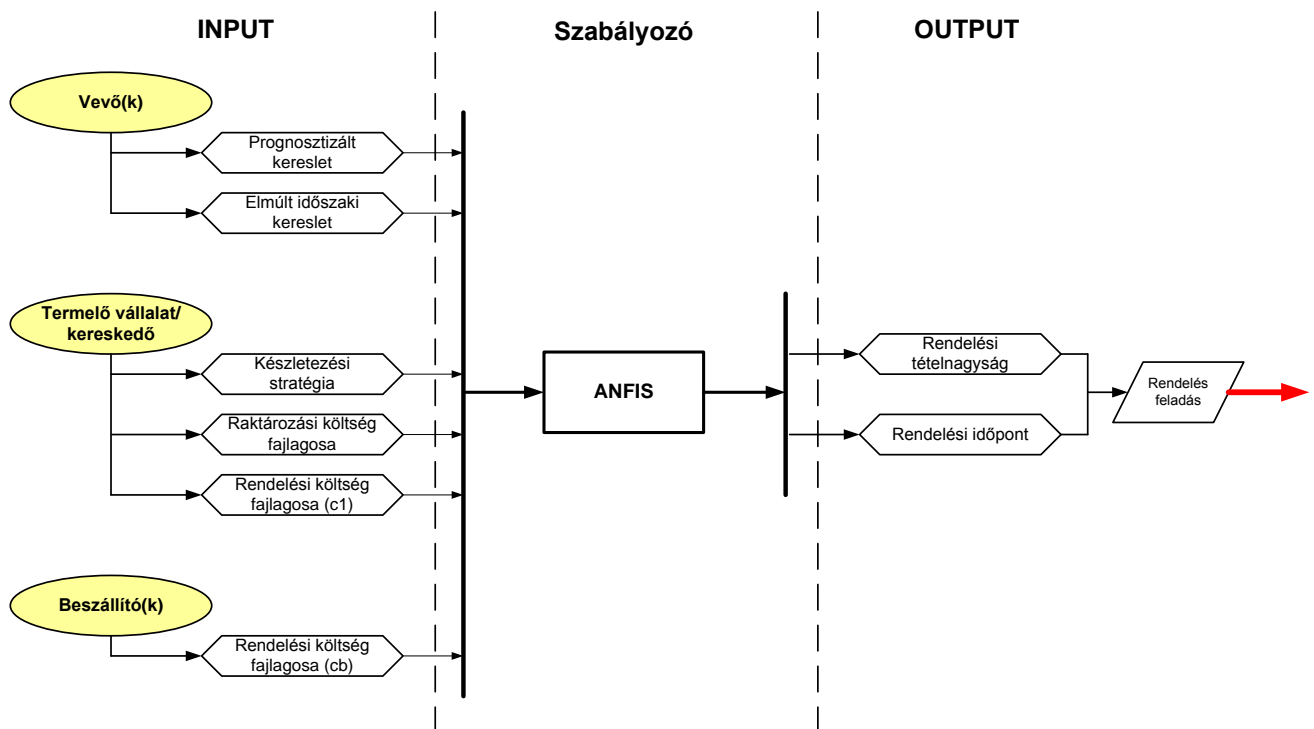
Fontos megjegyezni, hogy a neuralizált fuzzy és a fuzzyfikált neurális rendszerek között jelentősek az átfedések, ezért éles határvonalat nem lehet köztük húzni. Az évek során számos típusukat dolgozták ki: ANFIS, NEFCON, FALCON, FUN, GARIC [5][6][7][8] stb.

Az ANFIS (Adaptív Network-based Fuzzy Inference System) neuralizált fuzzy rendszer, amelynek alaprendszerét a Takagi-Sugeno (Sugeno) fuzzy rendszer jelenti. Az eljárás jól illeszkedik a kutatás céljához, ezért ez a típus került kiválasztásra.

## 1.2. A kidolgozott rendszerterv alapján a technikai specifikáció készítése a mesterséges intelligencia alapú készletszabályozóra

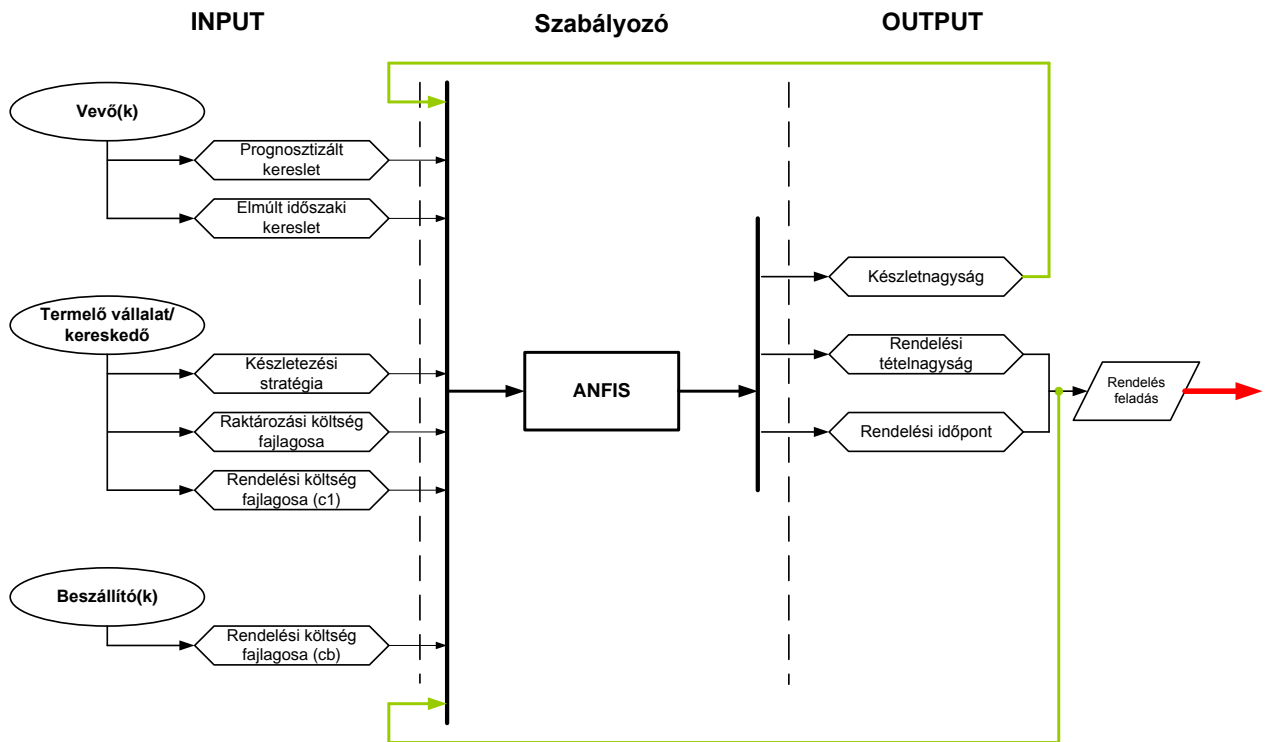
A kitűzött feladat megvalósítása a JKL-P7-T3 1. kutatási jelentés 1.4-es pontjának megfelelően az alábbi lépésekre bonthatók. A leírtak alapján első lépésként egy olyan alrendszer létrehozása valósult meg, melynek folyamatos bővítésével került a kívánt szabályozó kialakításra. Ugyanakkor az alrendszer kialakításának további célja, hogy bizonyítást nyerjen a neuralizált fuzzy rendszer, azon belül is az ANFIS rendszer alkalmazhatósága készletezési problémák megoldására.

Ennek az alapszabályozási folyamatnak a felépítése a 1. ábrán látható.



1. ábra: Visszacsatolás nélküli rendszer

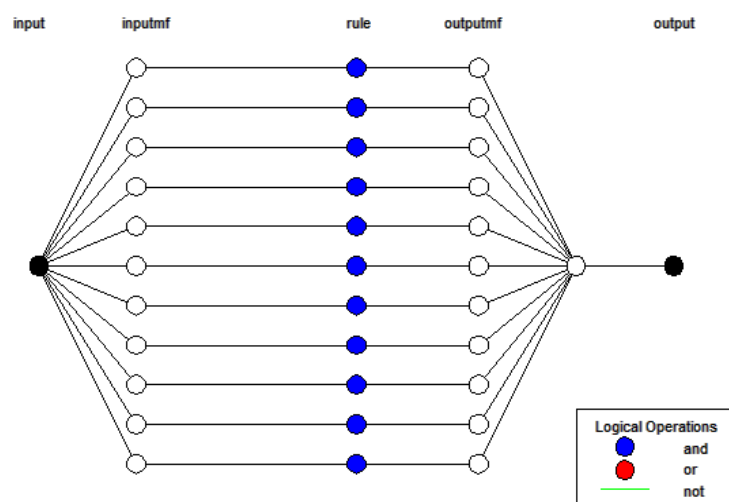
Ezután következett a már visszacsatolást tartalmazó szabályozó tervének kidolgozása, amely már képes dinamikus környezetben is működni, olyan esetekben is, amikor a kereslet időbeli alakulását trendszerűség és/vagy szezonális jelleg jellemzi. Ehhez az alrendszer módosítására volt szükség (2. ábra).



2. ábra: Visszacsatolással rendelkező készletszabályzó rendszer


### 1.3. A technikai specifikációban definiált mintarendszer megvalósítása egy arra alkalmas programozási környezet alkalmazásával

A mintarendszer megvalósítása a MATLAB környezetben történt. Az ANFIS szabályozóban a tanulást megvalósító neurális hálózat (3. ábra) egy SISO (Single Input - Single Output) rendszer.



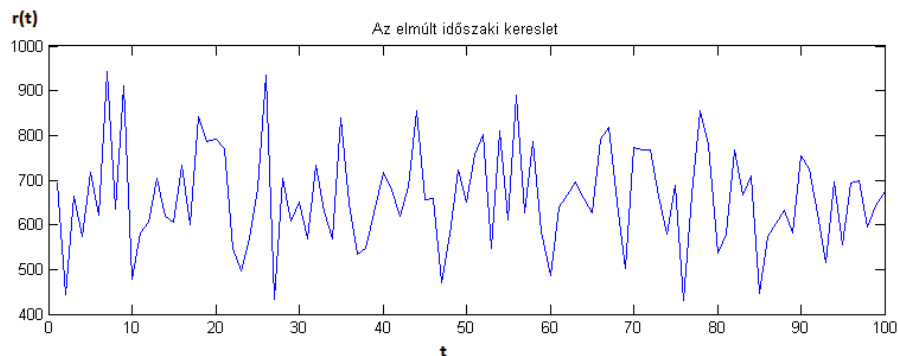
3. ábra: A neurális hálózat struktúrája

A hálózat bemenetét a kereslet várható értéke ( $M(r)$ ) képezi. Ezen várható értéknek, mint alaphalmaznak lefedésére 11 Gauss tagsági függvénnyel ( $\mu_A(x) = e^{-\frac{1}{2}(\frac{x-c}{\sigma})^2}$ ) rendelkező fuzzy halmazt (4. ábra) hozott létre, illetve ennek megfelelően a fuzzy rendszer szabálybázisát 11 „HA-AKKOR” típusú szabály alkotja.



4. ábra: A kereslet várható értékét lefedő fuzzy halmazok


A neurális hálózat a fuzzy szabályok és a fuzzy tagsági függvények tanuláshoz az elmúlt időszak keresleti adatait ( $r_o(t)$ ) (5. ábra) használja fel.



**5. ábra: Az elmúlt időszaki kereslet alakulása az idő függvényében**

Az egyes fuzzy szabályok eredményeinek összegzéséből állítható elő a hálózat kimenete, vagyis ebben az esetben az optimális rendelési tétel nagyság. Ez a rendelési mennyiség egy meghatározott várható értékhez tartozó költségfüggvény (6. ábra) minimális pontját jellemző paraméter. A rendelési tétel nagysághoz tartozó rendelési időköz számítása a következő EOQ képlettel történik:

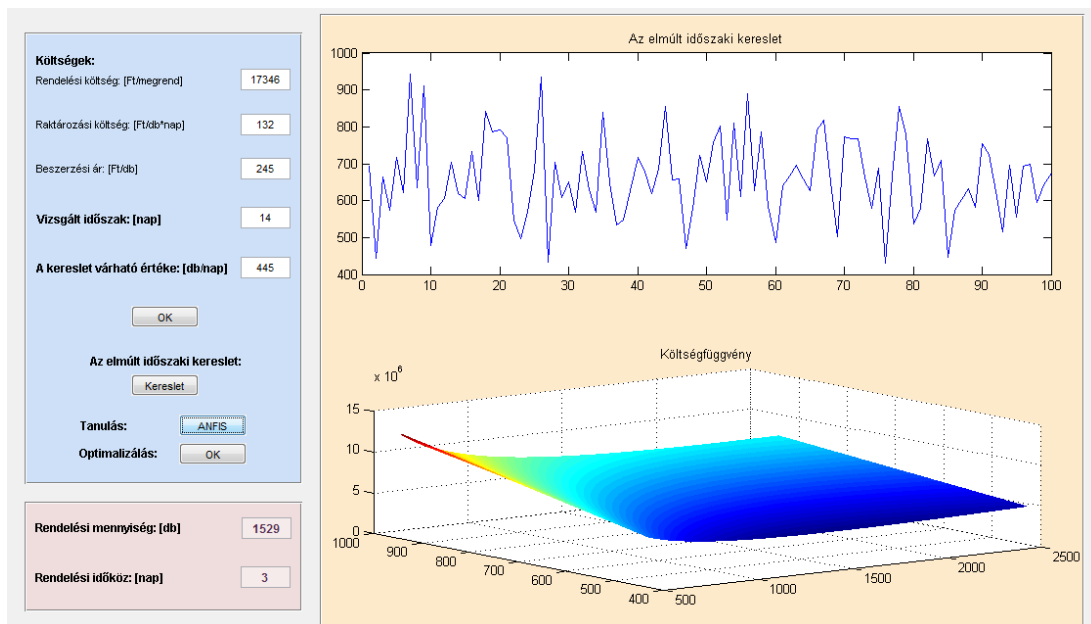
$$t_o = \sqrt{\frac{2 * c_1}{c_2 * M(r)}}$$



**6. ábra: A költségfüggvény**

A készlet szabályozó megvalósítására a MATLAB numerikus matematikai szoftver környezetben került sor. Az említett programrendszer képes mátrix számítások elvégzésére, függvények és adatok ábrázolására, algoritmusok implementációjára és felhasználói

interfészek kialakítására. Így a szabályozó algoritmusának programozása mellett lehetőség nyílt a rendszer felhasználói felületének elkészítésére is.



**7. ábra: A készletszabályozó rendszer felhasználói felülete**

A kezelő felületen (7. ábra) megadhatók az input adatok (költségek, vizsgált időszak hossza, a kereslet várható értéke), valamint az elmúlt időszakot jellemző keresleti értékek egy xlsx típusú fájlból kerülnek beolvasásra. Ezzel megteremtve annak a lehetőségét, hogy későbbiekben a készletszabályozót csatlakoztatni lehessen az adott vállalat vállalatirányítási rendszeréhez.

Továbbá a felületen a tanulást és az optimalizálást követően megjelenik az optimális rendelési mennyiség és időköz értéke. Fontos megjegyezni, hogy a rendszer tanulási folyamatát egyszer kell elvégezni, ezt követően elegendő csak kereslet várható értékét megadni, hogy megkapjuk a rendeléssel kapcsolatos ütemezésére vonatkozó paramétereket.



#### 1.4. A kifejlesztett mintarendszer validálása és verifikálása, tesztelése normál működés és extrém hatások esetére

Az ANFIS rendszeren alapuló készletszabályozó működőképességének bizonyításához, a rendszer tesztelése szükséges. Ehhez normál valószínűségi eloszlással jellemezhető, eltérő várható értékkel és szórással rendelkező, az elmúlt időszakra vonatkozó keresleti adatsor került felhasználásra. Valamint egyes esetekben a költségek fajlagosai is a korábbiaktól eltérő értékeket vettek fel. A szabályozó által meghatározott eredmények, a rendelési mennyiségek helyességének ellenőrzése az optimális rendelési tétel nagyság közelítésére használt EOQ képlet segítségével történik:

$$q_o = \sqrt{\frac{2 \cdot c_1 \cdot M(r)}{c_2}}$$

A 2. táblázatban láthatjuk, hogy a tesztelések során a felhasznált, az elmúlt időszakra vonatkozó keresletet jellemző várható érték milyen intervallumba esett, illetve mekkora szórással rendelkezett. A táblázat harmadik oszlopa pedig a képlettel számított és a szabályozó által meghatározott mennyiségek eltérésének mértékét tartalmazza.


**2. táblázat**  
Tesztelési eredmények

Várható érték	Szórás a várható érték	Eltérés mértéke [%]
200...500	10 %-a	0,0
500...800	10 %-a	0,0
500...800	20 %-a	0,0
800...1100	5 %-a	0,0
800...1100	10 %-a	0,0
800...1100	20 %-a	0,0
800...1100	30 %-a	0,0

A kapott eredmények alapján elmondható, hogy a vizsgált esetek mindegyikében a szabályozó az optimális rendelési mennyiséget szolgáltatva. Így az ANFIS rendszer alkalmasnak bizonyul egy, a fentiekben definiált készletszabályozási feladat megoldására, amely azt vetíti előre, hogy valószínűleg komplexebb készletezési problémák esetén is sikeres

lehet. Ennek bizonyítására a probléma komplexitási fokát tovább érdemes növelni, és a fentihez hasonló módon megtervezett tesztekkel érdemes végrehajtani ennek igazolása céljából.


Az korábbi 1.2-es fejezetben bemutatott, az alapszabályozó rendszerben alkalmazott Neuro-Fuzzy (ANFIS) rendszer bemenetét a vizsgált időszakra vonatkozó, előrejelzett kereslet képezte, melynek ismeretében meghatározhatóvá vált a rendelési mennyiség optimális nagysága. A kereslet statisztikai úton vizsgálható valószínűségi változónak tekinthető, ezért felmerülő vevői igények nagysága egy  $M(r)$  várható érték körül valamilyen valószínűségi eloszlást – ebben az esetben normál eloszlást - követve  $\sigma_r$  értékkel szóródik. Ez a várható érték az időtől független, állandó nagyságú, vagyis a kereslet időbeli alakulását (8. ábra) egy konstans értékkel jellemezhetjük.



**8. ábra: A kereslet időbeli alakulása konstans várható érték esetén**

Azonban fontos megjegyezni, hogy a valós folyamatok többségében a termékek iránti kereslet időbeli változása valamilyen trendszerűséget és/vagy szezonalitást követ. Azaz a keresleti idősorban hosszabb időszakon át tartóan érvényesülő tendencia és/vagy szezonok figyelhető meg. Így a várható érték nem jellemezhető konstanssal, hanem a vevői igények nagysága az időtől függően valamilyen görbe mentén változik.

A fentiek ismeretében szükséges megvizsgálni azokat az eseteket is, amikor a kereslet időbeli alakulását trendszerűség és/vagy szezonális jelleg jellemzi [3]. Ehhez az alaprendszer módosítása szükséges, ugyanis nem a kereslet várható értéke fogja a bemenetet képezni, hanem maga a prognosztizált keresleti görbe (9. ábra).




**9. ábra: A prognosztizált kereslet**

Az adott görbe egy 140 napos intervallumban vizsgálva lineáris és nemlineáris szakaszokat tartalmaz. Ezt az időintervallumot az optimalizálás során további 14 napos időszakokra bontjuk fel. Ennek megfelelően az ANFIS bemenetét a vizsgált 14 napra vonatkozó vevői igények összege fogja képezni:


$$R_{14} = \sum_{i=1}^{14} r(t_i) \text{ [darab]}$$

Az „összkereslet” ( $R_{14}$ ) függvényében meghatározott optimális rendelési tétnagyság és rendelési időpont ismeretében feladható a rendelés. Azonban a rendelési időköz elteltével nem adunk fel újabb rendelést, hanem egy újraoptimalizálási folyamatot hajtunk végre a következő 14 napos időszakra vonatkozólag, és az így kapott, új paramétereknek megfelelően adjuk fel a megrendelést. Ezt szemléltetve láthatjuk 10. ábrán:



**10. ábra: A megrendelés feladásának időpontjai**

Ha modellezzünk a teljes 140 napos időszakot, és megvizsgáljuk, hogy miként is alakult a készlet nagysága ez idő alatt (11. ábra), akkor azt a következtetést vonhatjuk le: bizonyos újrendelési időpontokban az adott termékből a raktárban rendelkezésre álló készletnagyság nem indokolta az ismételt rendeléssel, ezért ez túlkészletezést eredményezett. Ezzel szemben vannak olyan időpontok is, ahol rendelés feladása lett volna indokolt, azonban ez a rendelési időköz nagysága miatt nem történt meg, így ez pillanatnyi készlethiányhoz vezetett. Összegezve az előzőeket egyes esetekben az optimális rendelési időköz nem felelt meg a valós folyamatoknak, ezért túlkészletezés, illetve készlethiány alakult ki, mely a készletezési költségek növekedését okozta.



**11. ábra: A készlet időbeli alakulása**

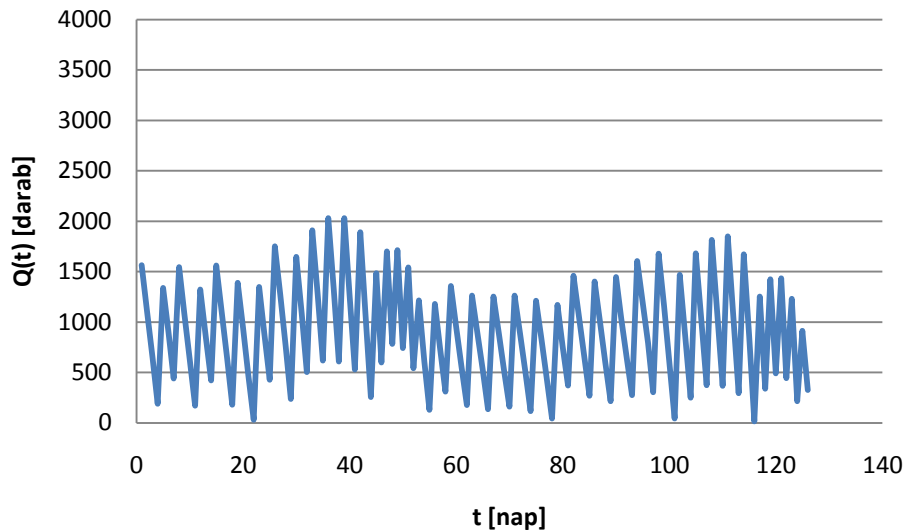
Ennek az elkerülésére, illetve a fellépő probléma kezelése során arra kell törekedni, hogy az újrendelési időpontokban a készlet görbe minél jobban megközelítse az  $Q(t)=0$  egyenest. Azaz a  $t_r$  rendelési időpontban a  $Q(t_r)$  értéknek egy  $[0, \varepsilon]$  intervallumba kell esnie, ahol  $\varepsilon$  egy tetszőlegesen kicsi szám.

A feladat megoldhatóvá válik, ha a szabályozó kimenetét jelentő készletnagyságot és rendelésütemezési paramétereket visszacsatoljuk a bemenetére (2. ábra). Így a szabályozó folyamatosan követni tudja a készlet időbeli alakulását, illetve jelezni amennyiben az előzőleg meghatározott optimális rendelési időköztől eltérően kell rendelést feladni, és ennek megfelelően megadja a paraméterek új optimális értékét. A rendszer tulajdonképpen akkor avatkozik be készletezési folyamatba:

1. ha a soron következő vevői igény kielégítése után a készletgörbe negatív értéket venne fel  $\Rightarrow$  készlethiány elkerülése;

2. ha a következő vevői igény kielégítése még lehetséges az adott pillanatban rendelkezésre álló készletből  $\Rightarrow$  túlkészletezés elkerülése.

A fentieknek megfelelően módosított készletszabályozási folyamat eredményeként előálló készletgörbe (12. ábra) jelentősen eltér a korábitól. Látható, hogy sem túlkészletezés, sem készlethiány nem lépett fel, valamint a görbe alatti terület nagysága is jól láthatóan lecsökkent, melyből a költségek csökkenésére lehet következtetni.



**12. ábra: A készlet időbeli alakulása visszacsatolás esetén**

Ezzel létrehoztunk egy olyan alap-szabályozó rendszert, mely a kereslet jellegétől függetlenül meghatározza a rendelés-feladási paraméterek optimális nagyságát, így minimalizálva a készletezési költségeket. Tulajdonképpen a tervezett szabályozó megvalósításának első fázisát lezárhatjuk, valamint áttérhetünk a második lépésre, ahol a készletszabályozás során megbízhatósági szempontokat is figyelembe veszünk.

## Hivatkozások

- [1] *Retter Gy.* Fuzzy rendszerek – Bevezetés. Invest-Marketing Bt., 2002. ISBN 963 00 9539 4
- [2] *Retter Gy.* Kombinált fuzzy, neurális, genetikus rendszerek – Kombinált lágy számítások. Invest-Marketing Bt., 2007. ISBN 978 963 87401 0 6
- [3] *Bóna K.* Készletezési folyamatos és rendszerek, készletezés-elmélet. 2005.
- [4] *Rotshtein, A. P. – Rakityanskaya, A. B.* Inventory control as an identification problem based on fuzzy logic. *Cybernetics and Systems Analysis*, Vol 42, No. 3, 2006
- [5] *H.R. Berenji and P. Khedkar*, Learning and tuning fuzzy logic controllers through reinforcements, *IEEE Trans. Neural Networks* 3 (5) (1992), pp. 724–740
- [6] *J.R. Jang*, ANFIS: adaptive-network-based fuzzy inference system, *IEEE Trans. Syst. Man Cybern.* 23 (3) (1993), pp. 665–685.
- [7] *S.M. Sulzberger, N.N. Tschicholg-Gurman and S.J. Vestli*, FUN: optimization of rule based systems using neural networks, *Proceedings of the IEEE Conference on Neural Networks* San Francisco (1993).
- [8] *D. Nauck, F. Klawonn and R. Kruse*, Foundations of Neuro-fuzzy Systems, Wiley, New York (1997).