A RADARJELEK DETEKTÁLÁSA NEURÁLIS HÁLÓZAT ALKALMAZÁSÁVAL

Dr. Ludányi Lajos mk. alezredes
egyetemi adjunktus
Zrínyi Miklós Nemzetvédelmi Egyetem
Vezetés- és Szervezéstudományi Kar
Fedélzeti Rendszerek Tanszék

A neurális hálózat egy új számítási paradigma, amely számos előnyös tulajdonsággal rendelkezik. A cikk a neurális hálózat radartechnikai alkalmazhatóságát vizsgálja egy konkrét megoldáson keresztül.

A neurális hálózatok olyan számítási feladatok megoldására létrejött párhuzamos feldolgozást végző adaptív eszközök, melyek eredete a biológiai rendszerektől származtatható.

Ezen hálózatok olyan hardver vagy szoftver megvalósítású párhuzamos, elosztott működésre képes információ feldolgozó megoldások, melyek

- rendelkeznek tanulási algoritmussal (amely általában minta utáni tanulást jelentenek);
- azonos vagy hasonló típusú lokális feldolgozást végző műveleti elemek rendezett topológiájú összekapcsolt rendszeréből áll;
- rendelkeznek a megtanult információ felhasználását lehetővé tevő előhívási algoritmussal.

A neurális hálózat műveleti eleme a neuron, amely egy több bemenetű, egy kimenetű eszköz, rendelkezhet lokális memóriával, melyben akár bemeneti, akár kimeneti értéket tárolhat.

A bemeneti és tárolt értékekből az aktuális kimeneti értéket tipikusan nemlineáris transzfer függvény alkalmazásával hozza létre, melyet aktiváló függvénynek neveznek.

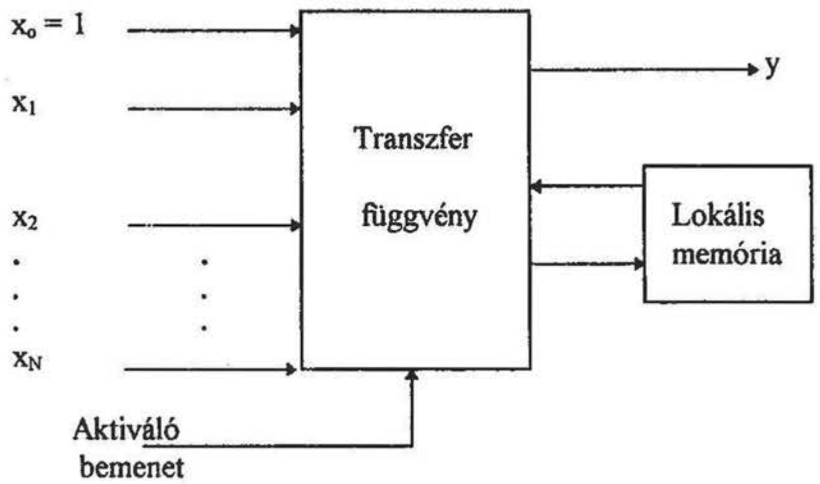

1. sz. ábra
A neuron általános, elvi felépítése

A neuron működését képletben összefoglalva (diszkrét hálózatra):

$$y(k) = f\left[\bar{x}(k), \bar{x}(k-1), \cdots \bar{x}(k-M_x), y(k-1), y(k-2), \ldots y(k-M_y)\right],$$

ahol

$$\bar{x}(k) = \left[x_0(k), x_1(k), \cdots, x_N(k)\right]^T \quad (1)$$

A műveleti elemek legegyszerűbb változata az egyenrangú bemenetekkel rendelkező memória nélküli neuron, melynek felépítése a 2. sz. ábrán látható:

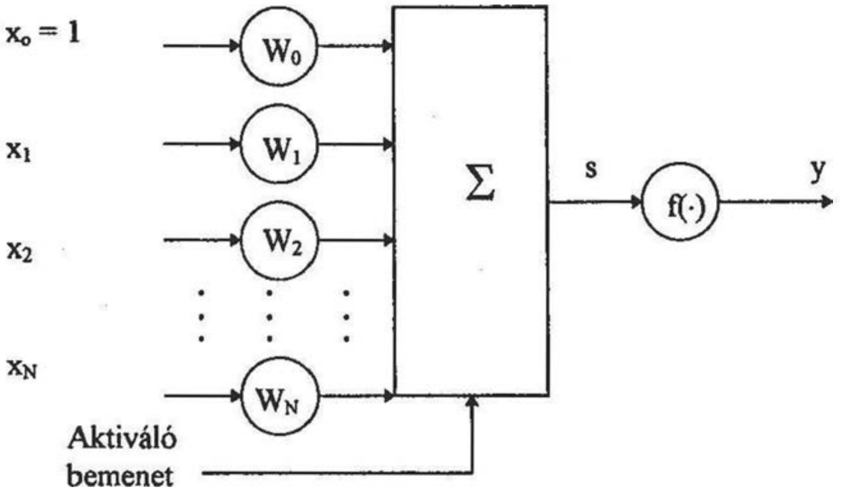

2. sz. ábra
Egyenrangú bemenetű, memória nélküli neuron felépítése

Tehát az x_i skalár bemenetek w_i súlyozással kerülnek összegzésre, majd a súlyozott összeg egy nemlineáris elemre kerül:

$$s = \sum_{i=0}^{N} w_i x_i = \overline{w}^T \overline{x} \quad (2)$$

Az $f(\cdot)$ függvényt aktivációs függvénynek is szokás nevezni, amely tipikusan küszöbfüggény jellegű leképzés, értelmezési tartománya a valós számok halmaza, értékkészlete pedig a valós számok egy korlátos részhalmaza.

A leggyakrabban alkalmazott aktivációs függvények a lépcsőfüggvény, a telítéses lineáris, a tangens-hiperbolkusz és a szigmoid függvény.

A memória nélküli neuronok másik típusát kapjuk, ha a 2. sz. ábrán látható struktúra azon speciális változatát használjuk, amikor minden bemenet közvetlenül a nemlineáris elemre jut, azaz elmarad az összegzés és a nemlinearitás N-bemenetű. Ennek napjainkban használt típusa az RBF (Radial Basis Function) hálózatban használt neuron (3. sz. ábra):

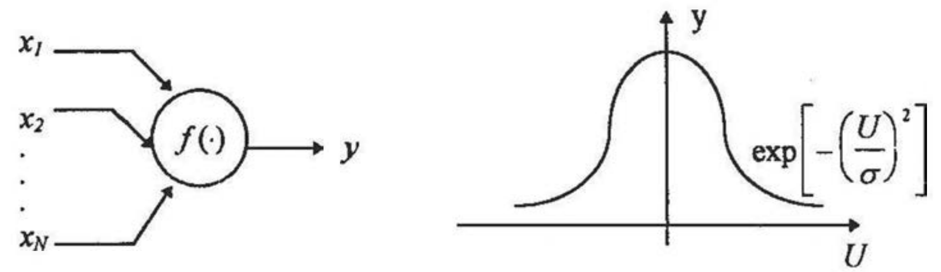

ahol

$$U=\sqrt{(x_1-c_1)^2+(x_2-c_2)^2+\ldots+(x_N-c_N)^2}$$

3. sz. ábra
Bemeneti összegző nélküli neuron

Az ábrából látható, hogy a neuron kimenete a bemeneti $\bar{x}=\lfloor x_1,x_2,\ldots x_N\rfloor$ -vektor és a neuronra jellemző $\bar{c}=\lfloor c_1,c_2,\ldots c_N\rfloor$ -vektor távolságának nemlineáris függvénye. A legelterjedtebb esetben Gauss-görbét használnak nemlinearitásként, melynek nemcsak a $\bar{c}$ -vektor, hanem a statisztikából is ismert σ -szórás is a paramétere.

A vizsgált témakör felveti azt a megfontolást, miszerint a radarjelek detektálását elemezni lehet a neurális hálózat alkalmazásával. A radartechnikában a detektálási feladat klasszikus megfogalmazása a következő: a vevő bemenetére egy meghatározott időintervallumban sztochasztikus folyamat realizációja (mintafüggvény) jut, amely vagy a jel és a zaj együttese, vagy csak a zaj. Valamely szabály alapján dönteni kell, hogy a két, egymást kölcsönösen kizáró feltevés közül (azaz hogy a realizáció tartalmaz, illetve, hogy nem tartalmaz jelet) melyiket fogadjuk el. A döntéshez a mintafüggvény valamely x-paraméterét, például a feszültségét használják fel.

A jelhez keveredő zaj hatására bármely x-érték véges valószínűséggel előfordulhat, függetlenül attól, hogy tartózkodik-e a vizsgált térrészben cél vagy nem, azaz a vevő bemenetén a céljel megjelenik-e vagy nem.

A döntés ezért csak statisztikai megfontolások alapján lehetséges a statisztikus döntéselmélet módszereinek felhasználásával.

A valószínűségi változónak felfogott x-mennyiség jellemzésére meg kell adni annak sűrűségfüggvényét. A jel van és a jel nincs két lehetséges állapotnak két feltételes sűrűségfüggvény felel meg. Ezeket jelöljük $P_0(x)$ $P_1(x)$-szel, ahol $P_0(x)$ legyen a zaj, a $P_1(x)$- pedig a jel+zaj sűrűségfüggvénye (4. sz. ábra):

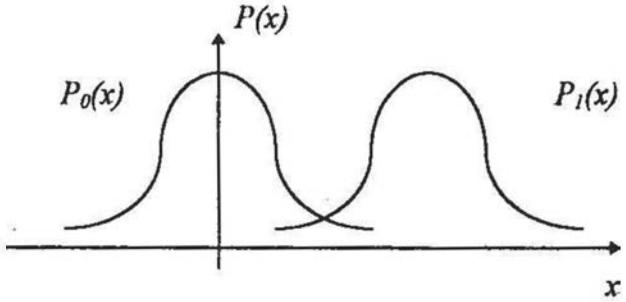

4. sz. ábra
Feltételes sűrűségfüggvények

Az ábrából látható, hogy az x-paraméter ismeretében csak feltételezéssel élhetünk a jel meglétére, vagy hiányára vonatkozóan, mivel a $P_0(x)$ és $P_1(x)$ sűrűségfüggvények átfedik egymást. Ezeket a feltételezéseket hipotéziseknek nevezik.

Mivel a zaj a döntésben hibát okoz, ezért az ábrából látható, hogy bármelyik hipotézist fogadjuk el, döntésünk téves is lehet (5. sz., 6. sz. ábrák):

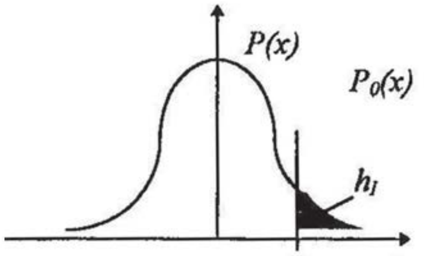

$$h_1 = \int_{x_0}^{\infty} P_0(x)dx$$

x_0 – küszöbérték

5. sz. ábra
Elsőfajú hiba értelmezése

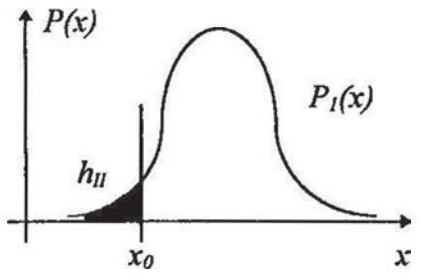

$$h_{II} = \int_{-\infty}^{x_0} P_1(x)dx$$

6. sz. ábra
Másodfajú hiba értelmezése

Az elsőfajú hiba azt jelenti, hogy jelként észleljük a zajt, és nagyságát a P_v-vaklárma valószínűsége vagy az úgynevezett téves detekció valószínűsége határozza meg.

A másodfajú hiba (a zaj elfedi a hasznos jelet) a P_d-detekciós valószínűség csökkenésének mértékét jelenti. A radartechnikában követelmény, hogy a $h_I=P_v$ vaklárma valószínűség egy megadott kicsiny, például 10^{-12} nagyságú, míg a $P_d=1-h_{II}$ detekciós valószínűség a lehető legnagyobb legyen.

Tudvalévő az is, hogy a gyakorlatban a döntést a hipotézis elfogadásáról nem egyetlen mintafüggvény alapján, hanem az egymás után ismétlődő vételi periódusokban vett mintafüggények integrálása után hozzák meg. Az integrálás a jel-zaj viszonyban javulást eredményez, azaz az egyetlen jel vételéhez képest úgynevezett integrálási nyereség keletkezik.

A bevezető részben bemutatott hálók legfontosabb jellemzője, hogy a bemenetükre kerülő adatok és az ezekhez tartozó kívánt kimenetek közötti statikus leképezés megtanulására képesek. A radartechnikában azonban olyan hálóra van szükségünk, ahol a hálózat válasza nem csak a bemenettől, hanem az időtől is függ. Ezek olyan hálózatok lesznek, amelyek emlékezettel, memóriával rendelkeznek, azaz nem csak a pillanatnyi bemeneti értéktől, hanem régebbi bemeneti és/vagy a régebbi kimeneti értékektől is függ.

Egyik megoldási módszer, ha a hálózat bemeneteinek számát megnöveljük és az egyes bemenetekre a tényleges be- illetve kimenőjel késleltetett értékeit adjuk késleltető tagokon keresztül (7. sz. ábra):

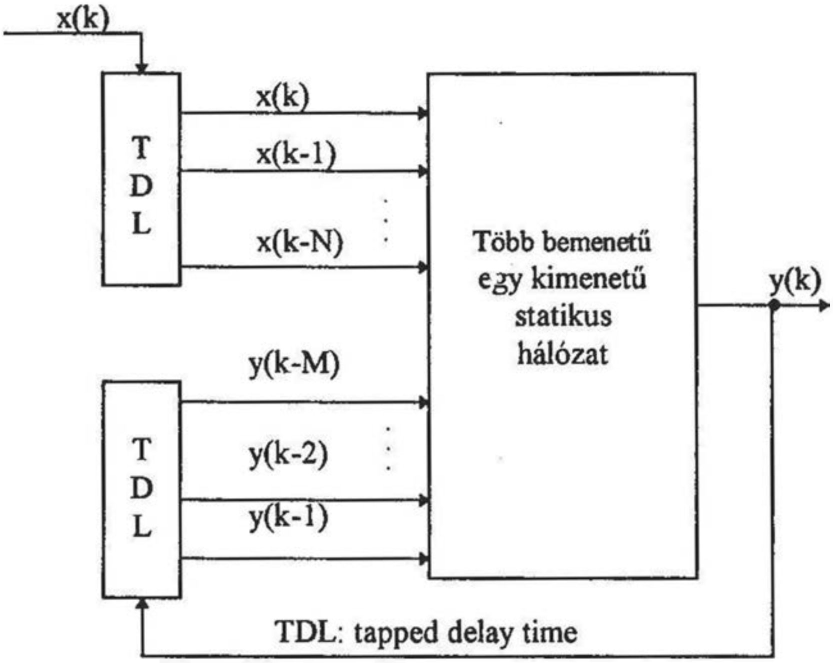

7. sz. ábra
Általános időfüggő neurális hálózat

Az időfüggő neurális hálózat egyik típusa a rekurzív háló, amely emlékezettel rendelkezik, tehát egy bemeneti szekvesnciára egy kimeneti szekvenciával válaszol. A kimenet a k-adik időpillanatban a visszacsatolás miatt:

$$y_i(k) = f\left[\bar{x}(k), \bar{y}(k-1)\right] \tag{3}$$

Tekintsük a következő egyszerű példát.
Legyen egy lineáris szűrő átviteli függvénye:

$$\Phi(s) = \frac{1}{Ts+1} \tag{4}$$

Áttérve a Laplace-operátoros jelölésmódról Z-transzformációs jelölésre:

$$\Phi(Z) = Z\{\Phi(s)\} = \frac{Z \cdot a}{Z - e^{-aT_k}} \tag{5}$$

ahol

$$a = \frac{1}{T}$$

T – a szűrő állandója

T_K – mintavételi idő

Mint ismeretes a rekurzív hálóra, mint szűrőre igaz, hogy:

$$y(k) = \sum_{i=0}^{N} a_i x(k-i) - \sum_{j=1}^{M} b_j y(k-j) \tag{6}$$

Elosztva a (3) egyenletet Z-vel, kapjuk:

$$\Phi(Z) = \frac{a}{1 - e^{-aT_k} \cdot Z^{-1}} = \frac{Y(Z)}{X(Z)} \tag{7}$$

ahol

$$N = 0;\ a_0 = a;\ M = 1;\ b_1 = e^{-aT_k}$$

Ebből következően:

$$y(k) = ax(k) + e^{-aT_k} y(k-1) \tag{8}$$

A (8) egyenlet neurális hálója (8. sz. ábra):

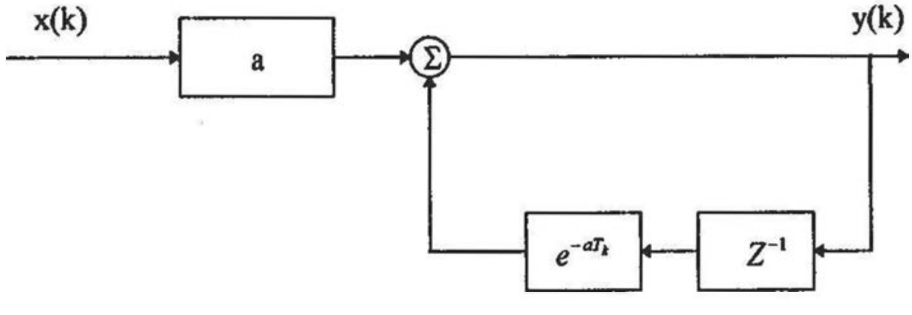

8. sz. ábra
A lineáris szűrő időfüggő neurális hálója

A kapott neurális háló nem más mint a radarjelek detektálásának egyik alapvető eszköze, a jel-zaj viszonyt növelő jelintegrátor.

A neurális háló *y(k)* kimenőjele az integrálási nyereség lesz, melynek értéke függ az *x(k)*-tól, az *a*-tól és a b_l-től..

Mivel

$$b_1 = e^{-aT_k} = e^{\frac{-Tk}{T}} \tag{9}$$

így függ a szűrő $B = \frac{1}{T} = 2\pi\Delta F$ sávszélességétől is. Ha előre adott az integrálási nyereség $[\Delta V(k)]$, akkor visszacsatolt rekurzív neurális hálót kapunk (9. sz. ábra):

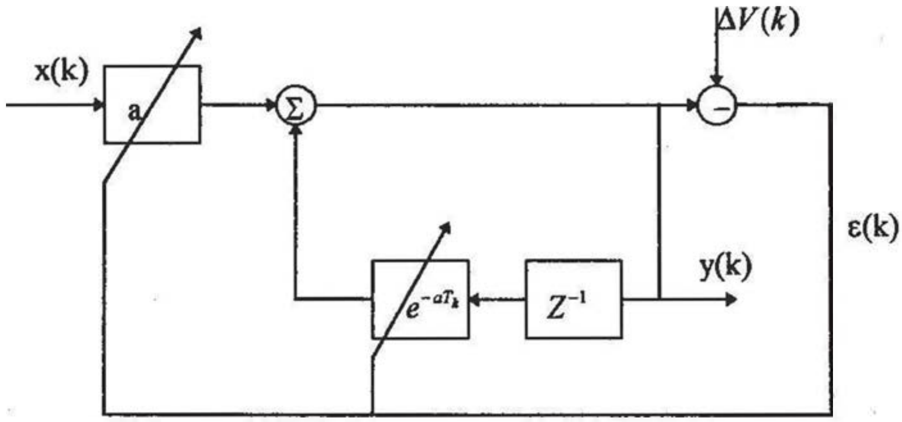

9 sz. ábra
Adott integrálási nyereséget biztosító neurális háló

A 10-11. sz. ábrák: szimulációs futtatás hatásvázlatai zavarással, illetve zavarás nélkül.

A lineáris szűrő és a neurális háló (mint jelintegrátor) összehasonlító szimulációja a 12-21. sz. ábrán látható.

Ábraszámok

	12	13	14	15	16	17	18	19	20	21
β	0,8	0,1	0,4	0,8	0,9	0,94	0,8	0,8	0,8	0,8
T	23,5	2,2	5,52	23,5	49,6	91,4	23,5	23,5	23,5	23,5
T_k	5	5	5	5	5	5	1,5	2	8	15
Zavar	0	1	1	1	1	1	1	1	1	1

Felhasznált irodalom

[1] Dr. Csorba János: A fedélzeti rádiólokátorok működésének elméleti alapjai - KGYRMF, jegyzet, Szolnok, 1986.
[2] Dr. Horváth Gábor: Neurális hálózatok és műszaki alkalmazásaik - BME, Budapest, 1995.

The neural network is a new computational paradigm, which has many advantages. This paper deals with applicability of neural network in radar technics through an example.

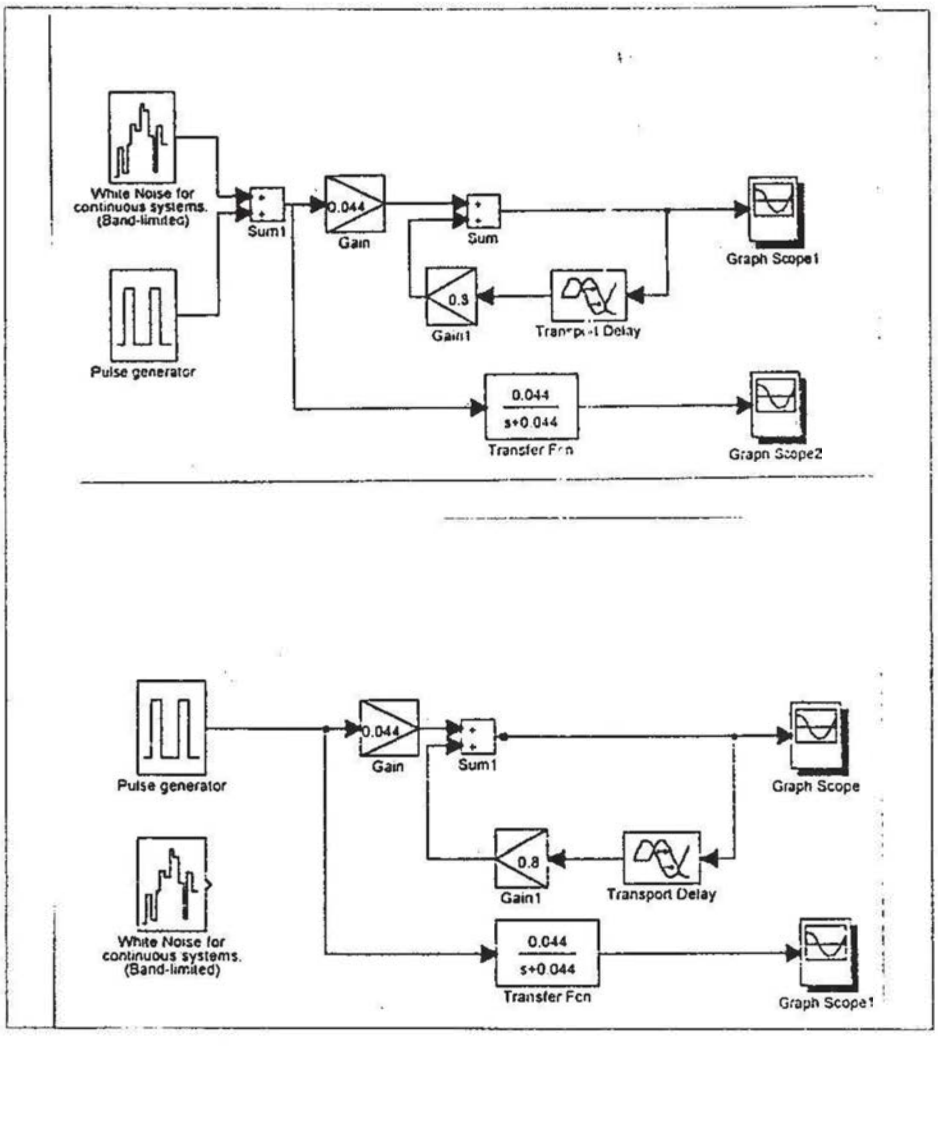
White Noise for
continuous systems.
(Band-limited)
Sum1
0.044
Gain
Sum
Graph Scope1
0.3
Gain1
Transport Delay
Pulse generator
0.044
s+0.044
Transfer Fcn
Graph Scope2
Pulse generator
0.044
Gain
Sum1
Graph Scope
0.8
Gain1
Transport Delay
White Noise for
continuous systems.
(Band-limited)
0.044
s+0.044
Transfer Fcn
Graph Scope1

10-11. sz. ábra

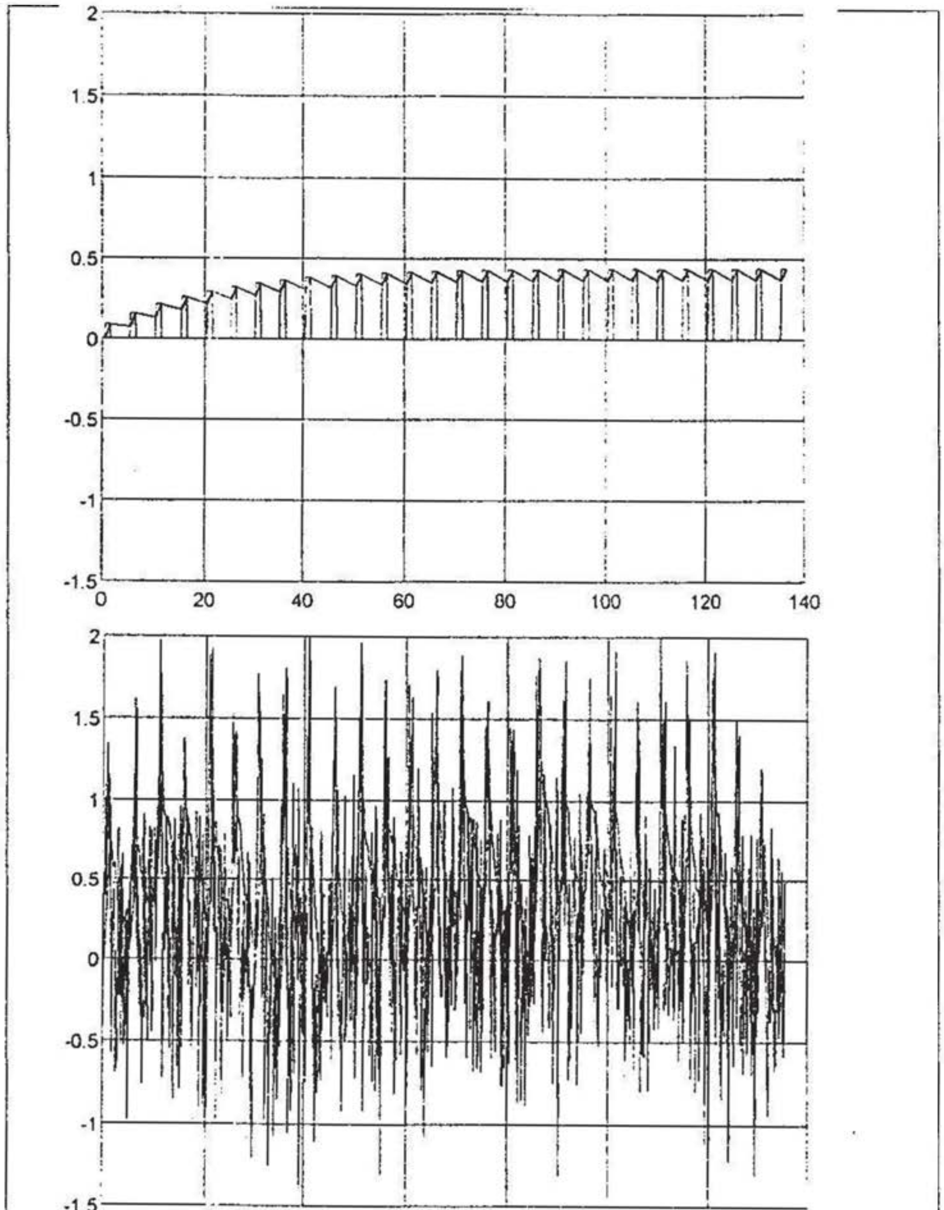
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140

12-13. sz. ábra

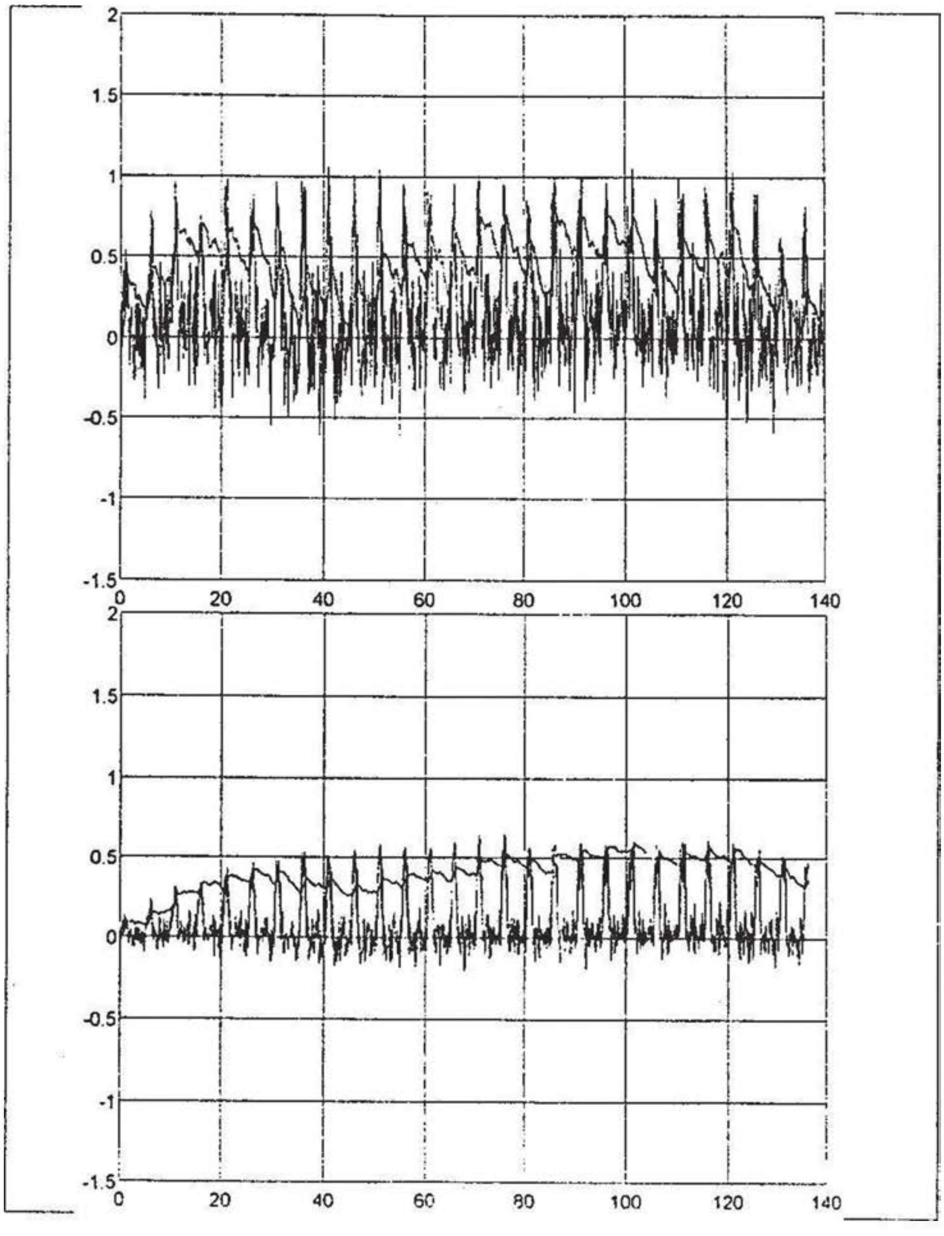

14-15. sz. ábra

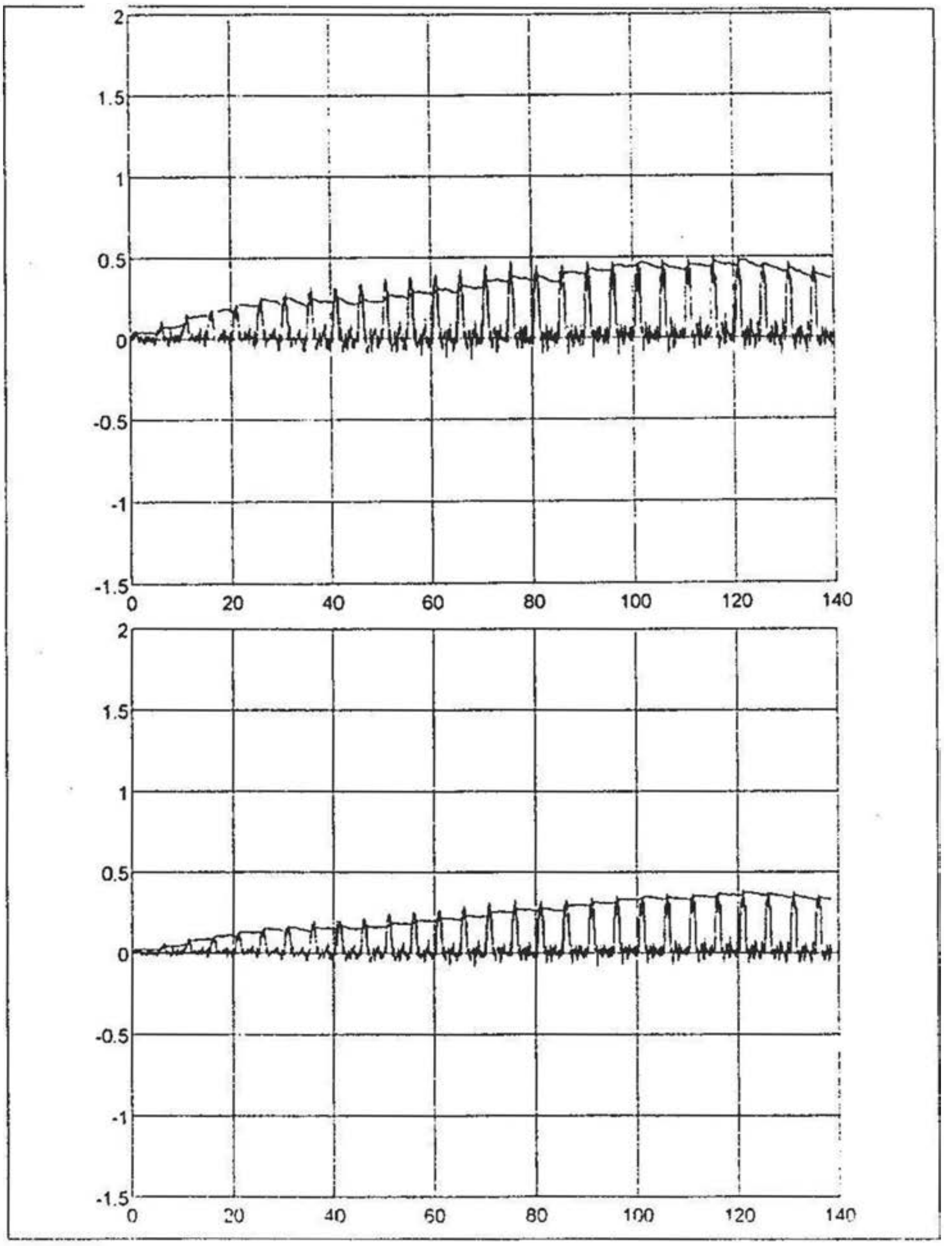
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140

16-17. sz. ábra

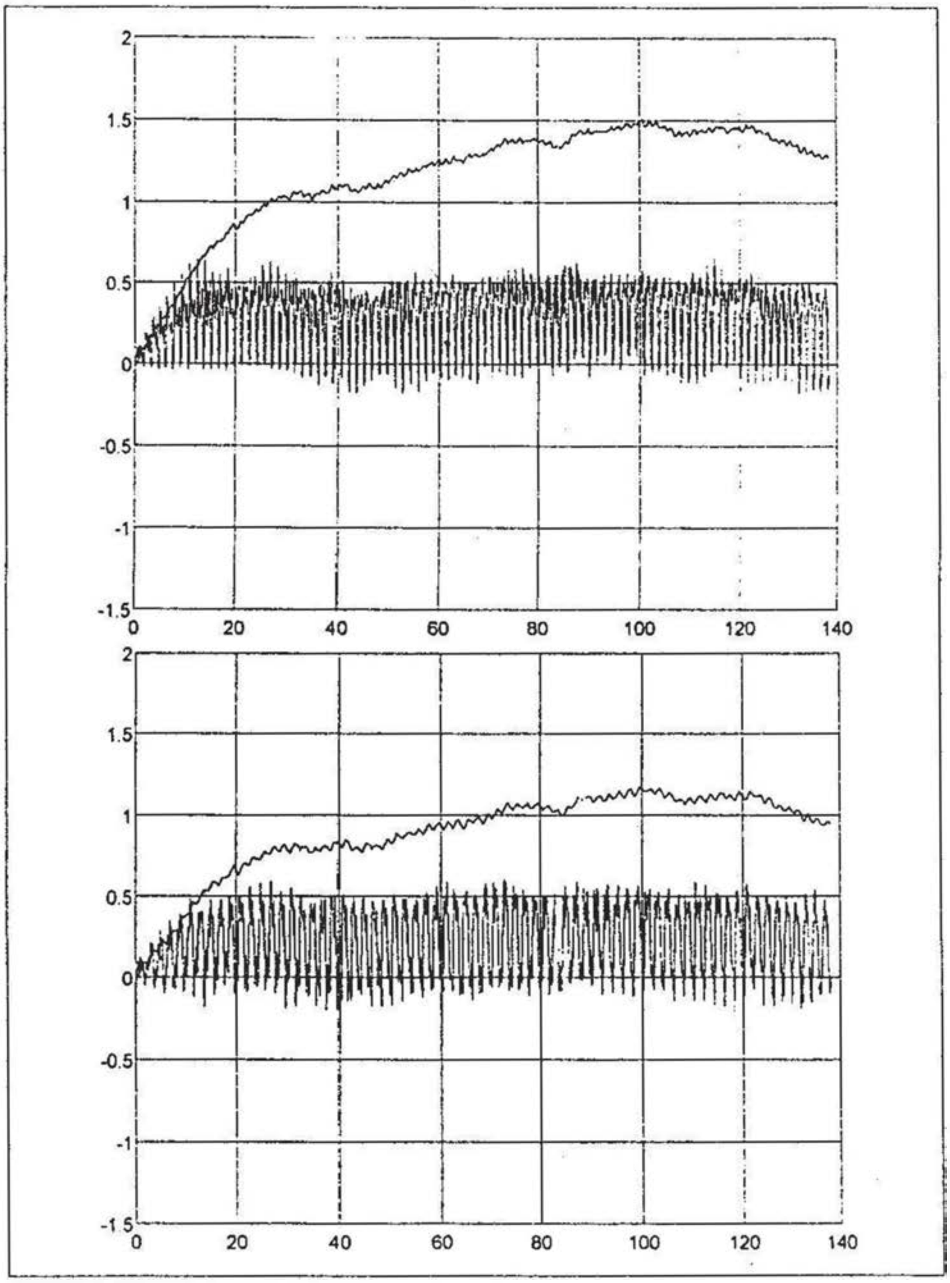
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140

18-19. sz. ábra

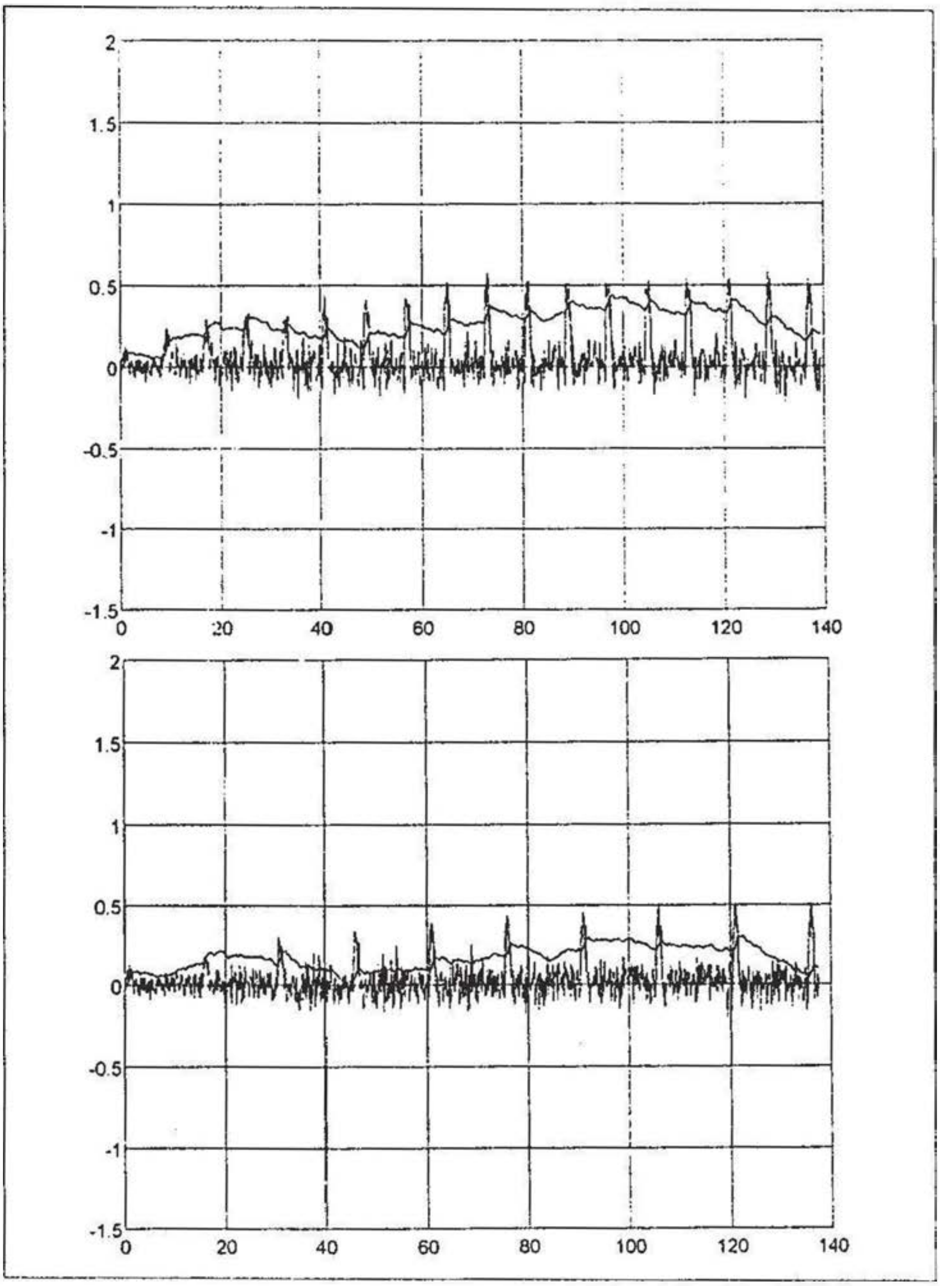
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140
2
1.5
1
0.5
0
-0.5
-1
-1.5
0
20
40
60
80
100
120
140

20-21. sz. ábra