Paraméterbecslő módszerek alkalmazása szívaritmiák felismerésére

Szilágyi László és Szilágyi Sándor Miklós

The recognition of QRS complexes and the detection of arrhythmias and artifacts represent one of the main tasks within the scope of the process of ECG analysis. This paper presents parameter estimation algorithms for both of these methods. The QRS complex recognition is accomplished in two steps: first an adaptive matched filter based upon an artificial neural network is performed in order to obtain an adequately filtered signal, which then will be compared with an averaged QRS complex template generated by an adaptive database. The problem of arrhythmia detection can be easily accomplished using a power spectrum generated by the Kalman filter estimation method. The length of successive R-R intervals can be modeled as an autoregressive (AR) process, the parameters of which vary in time. The values of the AR parameters are estimated using the Kalman filter. Based on the parameters computed for each R wave, a local power spectrum is built up. The presence of several kinds of arrhythmias can be noticed in the local spectrum using different criteria for their characterization.

Neurális hálózaton alapuló adaptív szűrés és R hullám felismerés

A mintavételezett EKG jel magában hordoz a hasznos jel mellett számos zavart. Az R hullámok felismerésének feladata során hasznos jelnek tekinthetjük az R hullámokból összeálló jelet, míg minden más jelenség alkotja az additív zajt. Az additív zaj azonban nem tekinthető fehér zajszerű véletlen folyamatnak, hiszen tartalmazza a korrelált P és T hullámokat, valamint az időfüggő mérési és elektromiografikus zajokat [1]. Ezért első lépésben egy három rétegű neurális hálózatra alapozott adaptív fehérítő szűrőt alkalmazunk. A bemeneti és a kimeneti réteg lineáris, míg a rejtett szint az $f(x) = (1 + \exp(-x/T))^{-1}$ szigmoid függvény segítségével hoz be nemlinearitást a rendszerbe. A bemeneti értékek minden egyes pillanatban az előző m darab mintavétel: $x_{i-1}, x_{i-2}, \dots, x_{i-m}$. Ezeket a lineáris bemeneti szint w_{kj} súlyokkal továbbítja a rejtett szint nemlineáris egységeinek bemeneteire. A kimeneti szint egyetlen lineáris egységből áll. A kimenet tulajdonképpen az adott pillanatban a korrelált

zaj becslült értéke: $n_i^w = \sum_{k=1}^M u_k z_i^k = \sum_{k=1}^M u_k f\left(\sum_{j=1}^m w_{kj} x_{i-j} + b_k\right)$. A rejtett szint súlyait az általánosított

delta szabály szerint változtatjuk. Az adaptív nem lineáris fehérítő szűrő és az erre alapozott QRS komplexus felismerő algoritmus tömbvázlata az 1. ábrán látható. Az adaptív szűrés a következő képpen működik: a bemenetekre vitt előző mintavételek értékeiből a neurális háló felbecsüli a következő mintában jelenlevő korrelált zajok amplitúdóját, melyet a mért jelből levonva megkapjuk a szűrt EKG jelet [3].

1. ábra – az adaptív szűrés és a QRS detekció tömbvázlata

A QRS komplexusokat felismerő algoritmus lényege a következő: kezdetben létrehozunk egy néhány R hullámalakból álló adatbankot. A bemeneti EKG jel az adatbank által szolgáltatott átlagolt R hullámmal egyszerre megy át a zajt eltávolító adaptív szűrőn. A kapott két jelből a hullámszűrő egy korrelációt számol, melyből az R hullám detektáló felismeri, ha a bemeneti jel R hullám volt. Amikor egy normális R hullámot talál, jelzést ad az adatbanknak az átlagolt R hullám megváltoztatására [3].

Aritmiák lokalizálása Kalman szűrő segítségével

A nem stacionárius biológiai jelek spektrumszámítási feladata kitűnően megoldható a Kalman szűrő alkalmazásával [2]. Az egymást követő R csúcsok között eltelt időintervallum hosszát egy autoregresszív (AR) folyamatként modellezhetjük, melynek AR paraméterei időben változnak. Ezen paraméterek értékeit határozzuk meg a Kalman szűrő alkalmazásával. Minden R csúcsnak megfelelő időpontban egy "pillanatnyi" vagy "lokális" spektrumot lehet felállítani az AR paraméterek segítségével. Különböző aritmiák jelenléte mutatható ki a lokális spektrumból, mindegyiknek megvan a specifikus felismerési kritériuma.

Jelöljük $t(n)$ -el az n -dik, illetve az utóbbi M darab R-R intervallum hosszának különbségét. A $\{t(n)\}$ sorozat elemei egy p rendű autoregresszív sorozattal modellezhető:

$t(n) = H(n)X(n) + v(n)$, ahol $H(n) = (-t(n-1), -t(n-2), \dots, -t(n-p))$, $X(n) = (a_1(n), a_2(n), \dots, a_p(n))^T$ az AR modell együtthatóit tartalmazza, $v(n)$ pedig egy fehér zaj számsorozat. A feladat itt az $\{a_m(n)\}$ értékeinek kiszámítása adott $\{t(n)\}$ értékek esetén. Ha ezen paraméterek értékei meg vannak határozva, a lokális $G(n, f)$ teljesítményspektrum az alábbi képlet alapján számítható ki:

$$G(n, f) = \frac{\sigma_R^2}{\left| 1 + \sum_{k=1}^p a_k(n) \exp(-j2\pi kf) \right|^2}.$$

A Kalman szűrő módszerét alkalmazzuk az $X(n)$ paramétervektor becslésére. Ehhez előre meg kell fogalmaznunk az $X(n)$ változásának modelljét az $n-1$ -dik és n -dik R csúcsnak megfelelő időpillanat között: $X(n) = X(n-1) + q(n)$, ahol $q(n)$ egy fehér zaj vektor. A $q(n)$ jelenléte modellezi az AR paraméterek az adatok nem stacionárius jellegének következtében történő változásait. A diszkrét Kalman szűrő egy rekurzív egyenlethalmaz, mely az autoregresszív együtthatókból alkotott $X(n)$ vektor értékeit becsüli az n -dik R csúcsnak megfelelő pillanatban. A Kalman szűrő egyenletei a következők:

$$P(n, n-1) = P(n-1, n-1) + Q(n) \quad \{s^2(n)\} = \sigma_R^2 + H(n)P(n, n-1)H^T(n)$$

$$K(n) = P(n, n-1)H^T(n) / \{s(n)\}^2 \quad P(n, n) = [I - K(n)H(n)]P(n, n-1)$$

$$X(n, n) = X(n-1, n-1) + K(n)[t(n) - H(n)X(n-1, n-1)],$$

ahol $X(n, n)$ a becsült értéke az $X(n)$ vektornak, $P(n, n)$ a becsült hiba kovariancia mátrix, $P(n, n-1)$ az előre becsült hiba kovariancia mátrix, σ_R^2 a $v(n)$ becslési hiba szórása, $Q(n)$ a mérési zaj kovariancia mátrixa, $K(n)$ pedig a Kalman nyereség vektor. Rekurzív voltak miatt ezek az egyenletek kitűnően alkalmazhatóak on-line rendszerek megvalósításában.

Eredmények

Az eddigiekben ismertetett eljárások hatékonyságát a MIT-BIH adatbázis segítségével vizsgáltuk. Az R hullám detektáló algoritmus eredményét az alábbi táblázat ismerteti.

MIT-BIH páciens	R csúcsok száma	Hibás detekció
104	2230	6
105	2572	12
108	1763	20
201	1963	10
203	2982	17
222	2484	6
228	2053	8
Összesen	16047	79

Bigenimiának nevezik azt a jelenséget, amikor egy egyébként stacionárius R-R intervallumokból álló sorozatba beékelődnek olyan szakaszok, melyekben minden második normális (szinuszcsofóból induló) szívverés hiányzik, és helyette időben eltolva megjelenik egy extra ütés, melynek alakja eltér a normális ütésétől. Ilyen esemény jelenlétében a lokális spektrumban egy csúcs található a 0.5 ciklus/ütés frekvenciánál [3]. Ennek a csúcsnak a jelenléte figyelhető meg a 2a ábrán. A bigeminia kimutatásának aránya 92-99 % között mozog a bigeminiás szakaszban található extra ütések számának függvényében. A trigeminia a bigeminiával hasonló körülmények között jön létre, és annyiban különbözik ettől, hogy az illető szakaszban minden két egymás utáni extra ütés között két normális ütés van. Ez a lokális spektrumban az egyharmad ciklus/ütés frekvenciánál okozza egy csúcs megjelenését. Egy ilyen jelenség kimutatását figyelhetjük meg a 2b ábrán.

2. ábra – a bigeminia (a) és a trigeminia (b) kimutatása a lokális teljesítményspektrumok segítségével

Kutatásaink során megvizsgáltuk további aritmiás jelenségek kimutatásának lehetőségeit, mint például a másodrendű AV blokkot és a kamrai lebegést, de mivel az MIT-BIH adatbázis mindkettőre csak egyetlen példát ad, nem volt lehetséges egyértelmű kritériumot meghatározni ezek jellemzésére.

Irodalom

- [1] Qiuzhen Xue, Yu Hen Hu, W. J. Tompkins - *Neural-Network-Based Adaptive Matched Filtering for QRS Detection*, IEEE Trans. Biomed. Eng., **39**, pp 317-329, Apr 1992.
- [2] M.S. Woolfson - *Study of cardiac arrhythmia using the Kalman filter*, Med. & Biol. Eng. & Comput., 1991, **29**, 398-405.
- [3] S. M. Szilágyi, L. Szilágyi, L. Dávid - *Comparison Between Neural-Network-Based Adaptive Filtering and Wavelet Transform for ECG Characteristic Points Detection*, Proceedings of 19th International Conference - IEEE/EMBS, November 1997, Chicago, IL. USA, p. 272-274.

Szilágyi László, egyetemi hallgató, Petru Maior Egyetem, Marosvásárhely

4300 Tg. Mureş, Str. Liszt Ferenc, Nr. 8, Tel. 40-(0)65-164490, E-mail: mszilagyi @ uttgm.ro

Szilágyi Sándor Miklós, doktorandusz, BME, Irányítástechnika és Informatika Tanszék