

## MIKROPROCESSZOROS EEG JELFELDOLGOZÁS LINEÁRIS MODELLILLESZTÉSSEL

Kollár István

Budapesti Műszaki Egyetem Műszer és Méréstechnikai Tanszék

Tanszékünkön jelenleg egy mikroprocesszor-vezérelt intelligens EEG jelanalizátor fejlesztése folyik. Ezzel kapcsolatban megvizsgáltuk a parametrikus /lineáris modellillesztésen alapuló/ EEG analízis mikroszámítógépes megvalósítási kérdéseit. A cikk a vizsgálat eredményeit ismerteti.

### Az EEG jel automatikus feldolgozása

Az EEG jel a legösszetettebb biológiai jelek egyike. A jelet létrehozó mechanizmusról máig nem létezik kielégítő modell, és így az EEG jel automatikus analízise gyakorlatilag megoldatlan kérdés. A jelből az információ nagy részét csak sokéves praxissal rendelkező szakorvosok képesek kiszűrni, méghozzá nem elméleti alapon, hanem gyakorlati tapasztalataik, intuíciójuk alapján.

Az EEG jelre világszerte megpróbálják a szokásos jelfeldolgozó módszereket alkalmazni. Ezek: sávszűrős frekvenciaanalízis, Fourier-analízis, intervallum-analízis /hullámszámlálás/, differenciálás, illesztett szűrők alkalmazása stb. A felsorolt jelfeldolgozási algoritmusok lényeges tulajdonsága az, hogy nem, vagy alig adaptívak. Ez azt jelenti, hogy egy adott jelnek képesek ugyan bizonyos tulajdonságait kiemelni, de ha a jel egyéb jellemzői esetleg megváltoznak, ez a jelfeldolgozás eredményére is lényeges befolyással lehet.

Az EEG jelnek sajnos sok, a jelfeldolgozás szempontjából kellemtelen tulajdonsága van. Ezek a következők:

1. Az EEG jel erősen függ
  - a vizsgált személy életkorától;
  - öröklött tényezőktől;
  - a vizsgálat közben előforduló /esetleg akaratlan/ mozgásoktól /szemmozgás, pislogás stb./;
2. Az EEG jel egyszerre sok olyan tényezőtől függ, melyeket külön-külön szeretnénk vizsgálni:
  - gyógyszerek hatása;
  - agyi elváltozások, sérülések;
  - betegségek;
  - külső ingerek;
  - éberség;stb.
3. Az EEG jel nem stacionárius, azaz statisztikai jellemzői a fenti tényezőktől függetlenül is időben változnak.
4. Az EEG jel információtartalmát részben lassu, kvázistacioner jelek, részben gyors, többé-kevésbé véletlenszerűnek tekinthető pulzusok hordozzák.

A fentiek alaposan elbátortalanítják a jelanalízissel foglalkozókat. Szerencsére azonban az EEG jel modellezését lehetővé teszik a következő megfigyelések [2, 4, 5, 7]:

1. Az EEG jel gyakran modellezhető egy sztochasztikus folyamattal, melyre véletlenszerű időpillanatokban tranziens csúcsok szuperponálódnak.
2. A sztochasztikus folyamat szétvágható 2...10 sec-os szakaszokra, melyek stacionernek tekinthetők.
3. A stacionernek tekinthető szakaszok kis fokszámu lineáris modellel aránylag jól leírhatók.

A lineáris modell több célra is felhasználható:

- a./ Az EEG jel kevés paraméterrel leírható /az információ nagy része megmarad/.
- b./ Kiszámítható egy nagy felbontású spektrum.
- c./ Mivel a modellillesztéssel egyuttal a minimális négyzetes hibájú jósló algoritmust is megalkottuk, a jóslás és az aktuális mintavételezett érték különbsége felhasználható
  - a stacionaritási hipotézis ellenőrzésére illetve adaptív (szegmentáció végrehajtására /a kvázistacioner szakaszok szétválasztására/.
  - spike /csúcs/ detektálásra, ill. a szemmozgásból stb. származó zavarok kiszűrésére.

A fentiek alapján feltétlenül szükségesnek látszik a lineáris modellillesztés beépítése az EEG analízátorba.

#### A lineáris modellillesztés

A lineáris modellillesztés azt jelenti, hogy olyan lineáris szűrőt hozunk létre, amelynek kimenő jele statisztikai jellemzői fehér zaj gerjesztés esetén megegyeznek az adott folyamat /esetünkben az EEG jel/ statisztikai jellemzőivel. Mivel diszkrét jeltérben dolgozunk, a szűrőt z-átviteli függvényével írhatjuk le:

$$H(z) = \frac{B(z)}{A(z)}$$

Ez az időfüggvényé visszairva azt jelenti, hogy a jel modellje /ARMA modell/:

$$x_n = \sum_{i=0}^q b_i x_{n-i} - \sum_{k=1}^p a_k x_{n-k} \quad (1)$$

A kérdés tehát az, hogy hogyan is lehet az adott EEG jelhez a megfelelő  $\{a_k\}$ ,  $\{b_i\}$  együtthatókat kiszámítani.

A  $\{b_i\}$  együtthatók kiszámítása sajnos másodfoku, tehát nemlineáris egyenletrendszer megoldását jelenti, ami pl. Newton-Raphson iterációval történhet. Egy ilyen iteráció mikroszámítógéppel még off-line üzemmódban is elég reménytelennek látszik, de szerencsére a tapasztalatok [3, 4, 5, 6, 7] alapján az EEG jel kis fokszámu / $p \leq 10$ / AR modellel /autoregresszív modell/ is kielégíthető pontossággal modellezhető:

$$x_n = n_n - \sum_{k=1}^p a_k x_{n-k} \quad (2)$$

azaz

$$H(z) = \frac{1}{A(z)},$$

csak pólusokat tartalmaz.

Ha most (1)-et sorra beszorozzuk az  $x_{n-1}, x_{n-2}, \dots$  változókkal, és várható értékeket képzünk, akkor

$$R(m) = E\{x_n x_{n+m}\}$$

jelöléssel a következő egyenletrendszerre jutunk /Yule-Walker egyenletrendszer/:

$$\begin{bmatrix} R(0) & R(-1) & R(-2) & \dots & R(-(p-1)) \\ R(1) & R(0) & R(-1) & & R(-(p-2)) \\ \vdots & & & & \vdots \\ R(p-1) & R(p-2) & \dots & & R(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} R(1) \\ R(2) \\ \vdots \\ R(p) \end{bmatrix} \quad (3)$$

vagy mátrix-formában:

$$\underline{R}_p \underline{a} = \underline{R}.$$

Mivel nekünk az  $\underline{a}$  vektorra van szükségünk, a (3) lineáris egyenletrendszert kell megoldanunk, ami lényegében az  $\underline{R}_p$  mátrix invertálását jelenti.

Az AR paraméterbecslés tehát két műveletre bontható:

- a./ az  $R(m)$  korrelációk becslése a mintából;
- b./ a (3) egyenletrendszer megoldása.

Ezután, ha szükséges, az identifikált AR paraméterekkel meg kell határozni a jóslási hiba időfüggvényét /a stacionaritás ellenőrzése, spike detektálás stb. céljából/. A mikroszámítógépes realizációhoz tehát a fenti feladatok megoldását kell elemeznünk.

Megemlítjük, hogy a fenti eljárás nem feltétlenül optimális: a rövid regisztrátumból kapható  $\hat{R}(m)$  becslőkkel megoldva a (3) egyenletrendszert az AR becslő bizonyos esetekben kellemetlenül eltérhet a valódi  $R(m)$  értékekből kapható paraméterértékektől [7, 9]. Mivel azonban a korrekció sok matematikai műveletet igényel, és célunk ugyanis csak a számítási igény becslése, egyelőre a fenti modellnél maradunk.

Az AR becslés realizálása

Tegyük fel, hogy N mintavételi értékünk van, ebből akarjuk meghatározni a p+1 db korrelációbecslőt, majd ezekkel megoldjuk a (3) egyenletrendszerét. Számértékek: p=10, N=256, ami  $f_m=100$  Hz mintavételi frekvencia mellett 2,56 sec hosszúságú mintaregisztrátumot jelent, ami realizztikusnak látszó feltételezés.

a./ A korreláció becslését az


$$\hat{R}(m) = \frac{1}{N} \sum_{i=1}^{N-m} x_i x_{i+m} \quad (4)$$

képlet alapján végezzük /ez a becslés kissé torzított, de az  $R_p$  becslő mátrix pozitív szemidefinit lesz, ami a számításoknál előnyös [9]/. A közvetlen becslés kb. pN szorzást és összeadást jelent. FFT-vel is dolgozhatunk, de a cirkuláris korreláció miatt N db 0-val kiegészítve az adatsort ez 2N adat transzformációját, négyzetreemelését és visszatranszformálását jelenti, ami tiszta software megvalósítás esetén a nagy műveletszám miatt lényegesen hosszabb.

b./ A (3) egyenlet mátrixa Toeplitz-típusú /az átlók mentén az elemek azonosak/, és  $R(m) = R(-m)$  miatt szimmetrikus. Ezt kihasználva a Gauss-elimináció  $p^3$  nagyságrendű szorzása helyett  $p^2$  nagyságrendű  $/p^2+p-1$ , [7]/ szorzással meg lehet oldani a (3) egyenletrendszerét /Levinson-Robinson-Durbin, LRD algoritmus/.

c./ A p-edfoku szűrő alkalmazása ismét pN műveletet igényel /az a. ponthoz hasonlóan itt is lehetne FFT-t alkalmazni/.

Összefoglalva, a szorzások számával becsülve az analízisidőt, a következőt kapjuk:



Látható, hogy tekintélyes számítási igényről van szó. Irodalmi adatok szerint a szokásos megoldás miniszámítógép /PDP11/ illetve az ennek megfelelő mikroprocesszor /LS11/, vagy pedig más gyors, 16 bites mikroprocesszor /TMS9900/ alkalmazása. Elképzelhető azonban szerényebb megoldás is, pl. a nálunk aránylag elterjedt Z80 mikroprocesszorral is. A továbbiakban ennek lehetőségeit vizsgáljuk meg röviden. 16 bites fixpontos algoritmust veszünk alapul, mivel az irodalmi adatok szerint ez elegendő pontosságú [3].

- 1./ Tiszta software megvalósítás esetén a szorzórutin futási ideje dominál /0,5 msec/. Ezzel az össz-szorzási idő 2,5 sec, ami néhány másodperces teljes modellillesztési időt jelent. Ez általában megengedhetetlenül sok. Összehasonlításképpen TMS9900-zal [3] a végrehajtási idő 1,5 sec.
- 2./ Az időigényes matematikai műveleteket elvégezhetjük aritmetikai processzorral, pl. az Intel 8231A APU-val. Ennél a szorzási idő

50  $\mu$ sec körül van, ami 10-szeres gyorsítást jelent. Az adminisztrációt is beleszámítva becslésünk szerint a végrehajtási idő 1 sec alá szorítható, ami - tekintve, hogy a processzorra számos egyéb feladat is hárul - legfeljebb 1 csatorna real-time feldolgozását jelentheti.

- 3./ Megfigyelhetjük, hogy a fő időt a korrelációképzés és a szűrés vászi el. Ha hardware rásegítéses FFT-vel számolunk /lepke-áritmetika, címkidolgozás/, akkor az FFT idő 200 msec-re szorítható, ami 1 sec alatti összidőt jelent.
- 4./ Speciális korrelációképző és szűrő hardware segítségével a végrehajtási idő némileg tovább csökkenthető, de feltehetőleg az adminisztráció végrehajtási ideje hamarosan korlátoz: nagyobb igények esetén gyorsabb processzort kell használni.

*Összefoglalva:* Z80 mikroprocesszorral ésszerű hardware rásegítéssel 1 csatornán elképzelhető real-time lineáris modell-illesztés. p csökkentésével /p=5/ feltehetően ez realizálható is, de esetleges további feldolgozó műveletek az RT időbe már valószínűleg nem férnek bele.

#### Irodalom

- [1] Kay, S.M. - Marple, S.L.: Spectrum Analysis - A Modern Perspective. Proc. IEEE, 69,11, /Nov. 1981/, p. 1380-1419.
- [2] Cohen, B.A.: Stationarity of the human electroencephalogram. Medical & Biological Engineering & Computing, 15. /Sept. 1977/ p. 513-518.
- [3] Ahlborn, L.G. - Larsson, B.-O. - Zetterberg, L.H.: A Microprocessor System for Real Time Analysis of EEG. From Electronics to Microelectronics, ed. W.A. Kaiser, W.E.Proebster, North-Holland Publishing Company, 1980.
- [4] Jindra, R.H.: All-pole model in electroencephalogram analysis. Medical & Biological Engineering & Computing, 17. /Nov.1979/, p. 715-718.
- [5] Isaksson, A. - Wennberg, A. - Zetterberg, L.H.: Computer Analysis of EEG Signals with Parametric Models. Proc. IEEE 69, 4 /April, 1981/, p. 451-463.
- [6] Jansen, B.H. - Bourne, J.R. - Ward, J.W.: Autoregressive Estimation of Short Segment Spectra for Computerized EEG Analysis. IEEE Transactions on Biomedical Engineering, BME-28, 9 /Sept. 1981/, p. 630-638.
- [7] Jansen, B.H. - Hasman, A. - Lenten, R. - Visser, S.L.: Usefulness of autoregressive models to classify EEG-segments. Biomedizinische Technik, 24, 9 /1979/, p. 216-223.
- [8] Carayannis, G. - Kalouptsidis, N. - Manolakis, D.G.: Fast Recursive Algorithms for a Class of Linear Equations. IEEE Transactions on Acoustics ... ASSP-30,2 /April 1982/, p. 227-239.
- [9] Haykin, S. /editor/: Nonlinear Methods of Spectral Analysis. Springer-Verlag, Berlin, 1979.