

MĚŘENÍ ČASOVÉHO ZPOŽDĚNÍ MEZI SIGNÁLY MOZKU: APLIKACE V EPILEPTOLOGII

Jan Prokš¹, Přemysl Jiruška^{2,3}

¹Katedra teorie obvodů, Fakulta elektrotechnická ČVUT, ²Ústav fyziologie, Univerzita Karlova – 2. lékařská fakulta, ³Fyziologický ústav AVČR

1. Abstrakt


V předkládané práci jsme se zabývali analýzou mozkových signálů laboratorních krys během epileptického záchvatu. Cílem této práce bylo připravit takové metody měření časových rozdílů mezi signály, které by byly vhodné pro použití v experimentální epileptologii. K analýze umělých i reálných signálů byla použita metoda vzájemné fáze, a to ve třech rozdílných variantách. Výsledkem této práce je porovnání vlastností těchto metod s ohledem na velikost aditivního šumu a především v závislosti na délce analyzovaného segmentu. To je důležité pro sledování časového vývoje zpoždění mezi jednotlivými kanály. Sledování této závislosti zprostředkovává informace o šíření epileptické aktivity strukturami mozku.

2. Metody

K analýzám signálů byly použity tři varianty metody vzájemné fáze. První varianta je založena na odhadu vzájemného fázového spektra pomocí FFT a druhá využívá autoregresního modelování pomocí korelačních koeficientů. Třetí metoda je také založena na autoregresním modelování, k odhadu vzájemného spektra však využívá kovariance. Pro účely testování těchto metod byly generovány tři druhy umělých signálů.

2.1. Testovací signály


Všechny metody byly testovány na třech typech signálů. Prvním typem byl polynomiální model signálu, který kombinoval lineární a parabolické úseky tak, aby výsledný signál byl tvarově podobný reálnému signálu. Byla provedena i filtrace tohoto signálu, a to tak, aby výsledný umělý signál odpovídal reálnému i ve spektrální oblasti. Ukázka takto generovaného signálu je na obrázku 1.



Protože je pro testování algoritmů zapotřebí mít signály dva a se známým časovým posunem mezi nimi, byl druhý signál generován stejným způsobem, ale s jiným počátečním posuvem. Ke každé realizaci pak byla připočtena různá realizace aditivního šumu. Tím jsme získali dva signály, které se (až na šum) lišily pouze časovým posunem.

Obr. 1 – průběh umělého ikálního signálu s přidáním aditivním šumem (SNR=20dB)

Druhý typ testovacího signálu vznikl podobným způsobem, ale základem nebyl polynomiální model, ale reálný signál. Z jednoho reálného signálu byly „vyříznuty“ dva segmenty, které se lišily opět pouze posunem. Ke každému segmentu byl znovu přičten bílý aditivní šum pro získání dvou rozdílných průběhů. Tím se oproti polynomiálnímu modelu více přibližujeme reálnému signálu. Třetím typem modelových signálů je opět dvojice vzniklá z jednoho reálného průběhu, ale před tím, než je k segmentům připočten bílý aditivní šum, je jeden z nich zkreslen konvolučním šumem. Tento konvoluční šum charakterizuje přenosovou cestu mozku mezi elektrodami. Přenosová cesta byla získána jako průměr dílčích přenosových cest získaných pro každou dvojici reálných signálů. Podrobný postup získání této přenosové funkce není předmětem této práce. Za použití tohoto postupu získáme dvojici signálů, které se liší nejen časovým posunem a aditivním šumem, ale i tvarem jednotlivých signálů.



Výsledkem jsou signály se *známým* zpožděním, které však vznikly za analogických podmínek jako reálné signály. Pokud budou algoritmy správně pracovat na takovýchto testovacích signálech, lze předpokládat, že bude možné je použít i pro analýzu reálných průběhů s neznámým zpožděním.

Obr. 2 – příklad reálného interiktálního signálu s aditivním šumem (SNR=20dB) použitého pro testování.

2.2. Metoda DFT

Metoda výpočtu vzájemného spektra vychází ze vzájemné spektrální hustoty

$$\bar{G}_{xy}[k] = \frac{1}{N} \sum_{k=1}^q |X_m^*[k] \cdot Y_m[k]| \quad (1)$$

X^* je komplexně sdružené spektrum signálu $x[n]$, Y spektrum signálu $y[n]$, N délka signálů a q počet segmentů.

Po vypočtení vzájemného spektra a vyjádření fázové složky

$$\varphi_{xy}[k] = \arctan \left[\frac{\operatorname{Re}\{\bar{G}_{xy}[k]\}}{\operatorname{Im}\{\bar{G}_{xy}[k]\}} \right] = \arctan \left[\frac{\bar{Q}_{xy}[k]}{\bar{C}_{xy}[k]} \right]. \quad (2)$$

je třeba určit hledané zpoždění. To je dané směrnicí úsečky, kterou lze proložit lineární částí spektra. Sklon této směrnice určuje posun mezi signály (rovnice 3) na těch frekvencích, skrz které je proložena.

$$\Delta T = \frac{\varphi_2 - \varphi_1}{2\pi \cdot (f_2 - f_1)} \quad (3)$$

f_1, φ_1 jsou souřadnice počátku prokládané úsečky [Hz, rad], f_2, φ_2 souřadnice konce úsečky [Hz, rad].

Souřadnice je možné určit manuálně, ale pro automatické zpracování dat to je nevýhodné. Je možné postup automatizovat a pomocí koherenční funkce (rovnice 4) určit pásmo, kterým bude úsečka proložena.

$$\bar{\gamma}_{xy}^2[k] = \frac{|\bar{G}_{xy}[k]|^2}{\bar{G}_{xx}[k]\bar{G}_{yy}[k]} \quad (4)$$

Hodnoty koherence leží vždy v intervalu $\langle 0;1 \rangle$ a udávají míru korelace mezi dvěma signály na dané frekvenci. Pokud jsou signály na dané frekvenci zcela korelované, je hodnota koherenční funkce rovna jedné. Pokud signály nejsou vůbec korelované, je koherenční funkce na dané frekvenci nulová. Řečeno jinými slovy, koherence určuje, jak jsou si porovnávané signály na příslušné frekvenci podobné. Na frekvencích, kde je koherence významně odlišná od nuly, můžeme prokládat regresní úsečku.

2.3. Metoda AR

Jak je patrné z názvu této metody, je založena na autoregresním modelu, který popisuje také vzájemné spektrum jako metoda DFT. Rozdílem je jiný způsob získání tohoto vzájemného spektra.

Základem jsou tzv. normální rovnice,

$$\begin{bmatrix} R_{xx}[0] & R_{xx}[1] & \cdots & R_{xx}[M-1] \\ R_{xx}[1] & R_{xx}[0] & \cdots & R_{xx}[M-2] \\ \vdots & \vdots & \ddots & \vdots \\ R_{xx}[M-1] & R_{xx}[M-2] & \cdots & R_{xx}[0] \end{bmatrix} \cdot \begin{bmatrix} g[0] \\ g[1] \\ \vdots \\ g[M] \end{bmatrix} = - \begin{bmatrix} R_{xy}[0] \\ R_{xy}[1] \\ \vdots \\ R_{xy}[M] \end{bmatrix} \quad (5)$$

kteřé po úpravě přecházejí do tvaru

$$\mathbf{G} = -\mathbf{R}_{xx}^{-1}\mathbf{R}_{xy}, \quad (6)$$

kde

\mathbf{R}_{xx} je matice odhadů autokorelačních koeficientů signálu $x[n]$, \mathbf{R}_{xy} je sloupcovým vektorem vzájemných korelačních koeficientů signálů $x[n]$ a $y[n]$ a \mathbf{G} jsou hledané parametry modelu.

Vektor parametrů \mathbf{G} obsahuje kompletní informaci o vzájemném spektru signálů. Tyto parametry nepřisuzují konkrétním frekvencím určitou velikost složky, ale charakterizují celé vzájemné spektrum přenosovou funkcí. Vzájemné amplitudové a fázové spektrum se pak vyjádří standardním způsobem pomocí reálné a imaginární části komplexního vzájemného spektra.

Tento způsob výpočtu vychází z autokorelačních a vzájemných korelačních koeficientů. Jiná možnost se nabízí při náhradě korelace kovariancí. Výsledná matice (rovnice 5) zůstává beze změny, ale její koeficienty jsou vypočítány odlišným způsobem. Korelace je počítána dle vztahu

$$R[k] = \frac{1}{N} \sum_{n=1}^{N-k-1} s[n] \cdot s[n+k] \quad (7)$$

kovariance pak nepoužívá přesahy signálu a je jí možné vyjádřit


$$R[k] = \frac{1}{N-p} \sum_{n=p}^{N-1} s[n-1] \cdot s[n-k] \quad (8)$$

\bar{R}_{xy} odhad vzájemné korelace mezi vstupními signály $x[n]$ a $y[n]$, N délka vstupních signálů, k vybraný násobek maximálního předpokládaného zpoždění signálů, $k \ll N$.

Tento odlišný základ pak vede k odlišným výsledkům odhadu vzájemného spektra a tedy i přesnosti celé metody.

Důležitým parametrem autoregresního modelování je zvolený řád modelu. Při malém řádu modelu není vzájemné spektrum popsáno dostatečně a některé jeho části tak zůstanou neodhaleny, naopak při příliš vysokém řádu budou ve spektru generovány falešné špičky bez vztahu k realitě. Pro volbu optimálního řádu existuje mnoho kritérií. K návrhu optimálního řádu byla použita tato kritéria: Akaikovo informační kritérium, Akaikovo kritérium predikční chyby, Hannan-Quinovo kritérium, Pukillovo modifikované kritérium a kritérium MDL (Minimum Description Length). Poslední zmiňované kritérium vedlo na nejnižší řád modelu, a proto bylo používáno k jeho odhadu.

Během testování se podařilo určit, že lepších výsledků než s řádem voleným optimálně dle kritéria je dosahováno s pevně zvoleným řádem $M=16$. To je dáno tím, že při testování jsme použili signály se *známým* zpožděním. To je informace, kterou informační kritéria nemají k dispozici (na rozdíl od nás při vyhodnocování přesnosti metod). Z obrázku 3 je mimo jiné vidět, že minimum funkce je velice ploché, a tak může snadno dojít k nalezení falešného minima, podstatně vzdáleného od ideálního.



Obr. 3 – průběh kritériální funkce kritéria MDL v závislosti na řádu modelu.

3. Výsledky

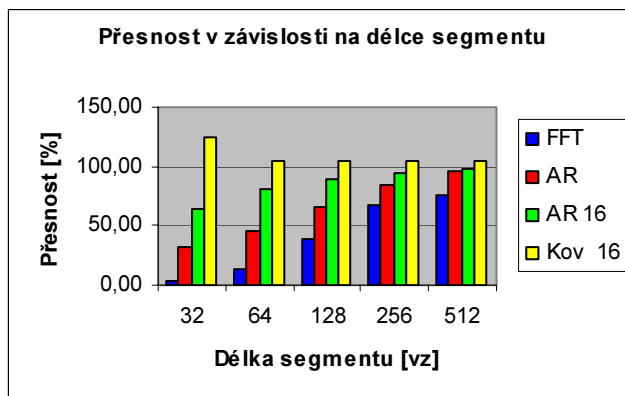
V této kapitole jsou porovnány výsledky, dosažené jednotlivými metodami na různých typech signálů.

Přesnost metod A byla vyhodnocována tak, aby vyjadřovala nejen velikost odchylky od skutečného zpoždění, ale i její polaritu. Tak je možné odlišit od sebe metody, které se od skutečné hodnoty odchylojí každá opačným směrem. Přesnost je tedy definována

$$A = 100 \cdot \frac{T}{T_p} [\%], \quad (9)$$



T je změřené zpoždění, T_p je zpoždění skutečné, uměle nastavené.

Příklad čtení grafu: druhý sloupec grafu ukazuje přesnost metod (v pořadí FFT-AR-AR 16-Kov 16) pro délku segmentu 64 vzorků.




Z grafu vyplývá, že pro tuto délku segmentu je nejpřesnější metodou metoda autoregresní kovarianční s pevným řádem modelu $M=16$ (Kov 16, poslední, žlutý podsloupec), metoda autoregresní korelační s pevným řádem $M=16$ vykazuje odchylku téměř 20%. Zbylé dvě metody, FFT a autoregresní korelační s optimálním řádem již vykazují přesnost velice malou (AR pod 50% a FFT dokonce pouze 15 %!).

Graf 1 – Závislost přesnosti na délce segmentu, reálný posunutý signál, SNR = 20 dB, bez zkraslení přenosovou funkcí.



Grafy 2 a 3 – Závislost přesnosti na délce segmentu, reálný posunutý signál zkreslený přenosovou funkcí (graf 2, vlevo), SNR = 20dB a polynomiální signál (graf 3, vpravo), SNR = 20dB.

Z uvedených grafů vyplývá, že z představených metod je nejpresnější a nejuniverzálnější autoregresní kovarianční metoda. Vykazuje vysokou imunitu proti aditivnímu i konvolučnímu šumu, a tím se nejlépe hodí pro analýzu reálných signálů. Všechny metody byly též testovány s nižším aditivní šumem (SNR = 50dB). Výsledky byly analogické, u všech metod došlo ke zvýšení přesnosti (hlavně pro krátké segmenty), ale nejpresnější opět byla autoregresní kovarianční metoda.



Byly prováděny i testy závislosti přesnosti na velikosti zpoždění. Z těchto výsledků vyplývá, že v rozmezí testovaných zpoždění <-20ms;20ms> přesnost algoritmu na tomto zpoždění nezávisí.

Uvedené výsledky a závěry nám dovolují používat k analýze signálů velice krátké segmenty. Tím získáme podrobnou informaci o vývoji časového zpoždění v čase. Ukázkou takového zpřesnění pozorování časového vývoje zobrazuje obr. 4.

Obr. 4 – časový vývoj hemisferálního zpoždění během iktálního epileptického záchvatu. Modrá křivka (délka segmentu 128 vzorků) zobrazuje detaily, které při delším segmentu (červená křivka, 1024 vzorků) zůstávají skryté.

4. Závěr

V této práci jsme porovnávali různé varianty odhadu vzájemného fázového spektra za účelem připravit takovou metodu, která by svojí stabilitou a přesností byla použitelná pro analýzu velice krátkých segmentů EEG. Z výsledků vyplývá, že z představených metod se pro tuto úlohu nejlépe hodí metoda vzájemné fáze, založená na autoregresním kovariančním modelování. Tato metoda vykazuje vysokou přesnost a nízký rozptyl výsledků pro segmenty o délce 128 vzorků (a delší), což při vzorkovací frekvenci 500 Hz odpovídá délce 256 ms.

Těchto výsledků bylo dosaženo při aditivním šumu $SNR=20dB$. Při stejné úrovni šumu je již rozptýl výsledků natolik podstatný, že není možné metodu použít, ale pro větší SNR (40 dB a více) je tuto metodu možné použít i na segmenty o poloviční délce, tedy 64 vzorků.

Dále se podařilo zjistit, že není optimální odhadovat řád použitého modelu ke každému ze segmentů zvlášť, ale že je správnější použít pro celou analýzu jediný řád modelu $M=16$. To vyplývá z toho, že při testování metod na signálech se známým zpožděním můžeme využít (na rozdíl od minimalizačního kritéria) k dispozici i informaci o tomto zpoždění a určit tak řád modelu přesněji.

5. Poděkování

Tato práce byla podpořena grantem Modelování biologických a řečových signálů, č. GAČR 102/03/H085 a výzkumným záměrem Transdisciplinární výzkum v oblasti biomedicínského inženýrství č. MSM 210000012.

6. Literatura

- [EN.REFLIST[9] Prokš, J., *Different methods of time delay estimation between EEG signals*. Proceedings of the Polish-Hungarian-Czech workshop on circuit theory, signal processing and applications, CTU Publishing House, 9/2003, p. 93 – 96.
- [10] Prokš, J. and P. Jiruška, *Diagnosis of patients diseased by epilepsy*, Poster 2003, Book of extended abstracts, CTU Publishing House, 2003.

7. Kontaktní informace

Jan Prokš
Katedra teorie obvodů, FEL-ČVUT, Technická 2, 166 27 Praha 6 – Dejvice
Tel.: 224 352 158
E-mail: jan.proks@seznam.cz