

# VYUŽITÍ HILBERT-HUANGOVY TRANSFORMACE PŘI DETEKCI PATOLOGICKÉ VYSOKOFREKVENČNÍ AKTIVITY V INTRAKRANIÁLNÍM EEG PACIENTŮ S EPILEPSIÍ

*J. Balach, P. Ježdík, R. Čmejla*

Katedra teorie obvodů, Fakulta Elektrotechnická, České vysoké učení technické v Praze

## Abstrakt

Vysokofrekvenční oscilace jsou jedním z příznaků epileptického EEG a lze je využít k přesnější diagnóze a lokalizaci epileptogenní tkáně. Pro zpracování epileptického EEG je v dnešní době již několik metod. Většina z nich je však pracuje na základě Fourierovy transformace. Ta předpokládá, že je signál stacionární a lineární, popřípadě pouze lineární pokud je využito krátkodobé fourierovy transformace. V tomto článku se zaměříme na využití ne tolik známé Hilbert-Huangovy transformace, která je navržena právě pro analýzu nestacionárních a nelineárních signálů. Navrhne algoritmus pro detekci vysokofrekvenční aktivity a ověříme zda je tato metoda pro tyto účely vhodná.

## 1 Úvod

Epilepsie se běžně diagnostikuje podle typických projevů, jakými jsou záchvaty a jejich příznaky. Při lokalizaci epileptogenní tkáně, jenž je zodpovědná za toto onemocnění, se využívá zpravidla funkčně zobrazovacích metod (CT, MRI, SPECT) a neinvazivního (skalповého) EEG. Pomocí zmíněných metod se dá diagnostikovat typ i příčina většiny typů epilepsie. Existují však i nelezionární typy epilepsie, kde není z výsledků vyšetření zcela zřejmé, kde se podezřelá oblast přesně nachází. Tito pacienti jsou podrobni dlouhodobé (cca týdeni) intrakraniální EEG monitoraci.

Získaná data jsou pak analyzována lékaři, kteří pozorují typické epileptické vzorce v záznamu a jejich výskyt. Jedná se o komplexy hrot-vlna, interiktální epileptické výboje [1] a patologickou vysokofrekvenční aktivitu [2] (HFO – High Frequency Oscillations). První dva typy jsou známé již delší dobu a při vyšetřeních je jich běžně využíváno. V tomto článku se zaměříme na HFO, které jsou intenzivně zkoumány v posledních dekáдах [2,3,4,5,8].

Obecně se vysokofrekvenční aktivita dělí na dva typy, a to na Ripples v pásmu od 80 – 200 Hz a Fast ripples v pásmu 200 – 500 Hz. Bylo dokázáno, že aktivita do 200Hz může být v určitých částech mozku přirozený jev [5], např. při učení či kognitivních funkcích. Avšak z výzkumů kolem epilepsie vyplývá, že jejich výskyt koresponduje s epileptogenní tkání [2,3]. Z tohoto důvodu je zapotřebí tyto grafoelementy detekovat a vhodně zpracovat. Při dnešní monitoraci pacientů 24h v kuse po několik dní je nashromážděno obrovské množství dat, které musí lékaři prohlížet. Proto se nabízí možnost vytvořit spolehlivý algoritmus pro automatickou detekci podezřelých událostí jenž by pomohl lékařům při hodnocení.

Při analýze signálů se z pravidla využívá Fourierova transformace, ta ovšem předpokládá že se jedná o stacionární signál. Pro zpracování nestacionárních dat lze ovšem využít krátkodobou fourierovu transformaci či Wigner-Villeho distribuci, jenž si s tímto problémem již poradí. Zde ovšem narážíme na problém při předpokladu, že jsou systémy lineární a platí zde princip superpozice. To v praxi příliš neplatí, proto jsme se rozhodli využít Hilbert-Huangovy transformace [6, 7], která dokáže zpracovat jak nelineární tak nestacionární signály. Implementovali jsme algoritmus v prostředí MATLAB a otestovali jeho využitelnost pro naše účely základní aplikací na soubor připravených dat.

## 2 Metody a algoritmy

### ..2.1 Hilbert-Huangova transformace

odečítat okamžité hodnoty amplitudy a frekvence v jednotlivých časech. Pro tyto účely využívá Hilbertovu transformaci, resp. analytický signál.

$$x_a(t) = x(t) + jx_h(t) \quad (1)$$

kde imaginární složka  $x_h(t)$  je Hilbertův obraz reálné složky  $x(t)$

Dále pak  $a(t) = \sqrt{(x(t))^2 + x_h(t)^2}$  a  $\theta(t) = \tan^{-1} \frac{x_h(t)}{x(t)}$  reprezentují okamžitou amplitudu a okamžitou fázi analytického signálu  $x_a(t)$ . Okamžitou frekvenci získáme derivací okamžité fáze:

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (2)$$

Tento postup vyžaduje, aby okamžitá fáze byla počítána ze signálu obsahujícího v daném čas pouze jednu frekvenční složku. U reálných signálů tohoto požadavku dosáhnout nelze, proto byla panem Huangem [6] navržena metoda Empirické modální dekompozice (EMD), která rozkládá signál na komponenty obsahující v jednom okamžiku vždy jen jednu frekvenční složku.

## ..2.2 Empirická modální dekompozice

Jak již bylo zmíněno, jedná se o metodu rozkladu původního signálu na několik frekvenčních komponent, postupně od těch obsahujících nejvyšší frekvence. Toho je dosaženo následujícím postupem:

1. Nalezení maxim a minim v  $x(t)$
2. Vytvoření vrchní a spodní obálky  $X_{up}(t)$ ,  $X_{low}(t)$  pomocí spline interpolace a spočítat

$$m(t) = \frac{X_{up} - X_{low}}{2}$$

střední obálku

3. Odečíst obálku od signálu  $d(t) = x(t) - m(t)$  a porovnat s podmínkami:

$\frac{35}{17}$  Počet lokálních extrémů je stejný nebo se liší maximálně o 1 s počtem průchodů nulou

$\frac{35}{17}$  Porovnat odchylku se zadanou hodnotou (typicky  $SD = 0.1$ )

$$SD_k = \frac{\sum_{i=0}^T |d_{k-1} - d_k(t)|^2}{\sum_{i=0}^T d_{k-1}^2(t)}$$

4. Pokud jsou obě podmínky splněny, tak se získaný signál  $c_i(t)$  odečte od původního signálu  $r_i(t) = x(t) - c_i(t)$  a vznikne residuum, s kterým je celý postup opakován dokud není monotónní, neobsahuje pouze jedno maximum/minimum a nebo již byl separován požadovaný počet komponent.

Původní signál lze znovu získat sečtením všech komponent a zbylého residua.

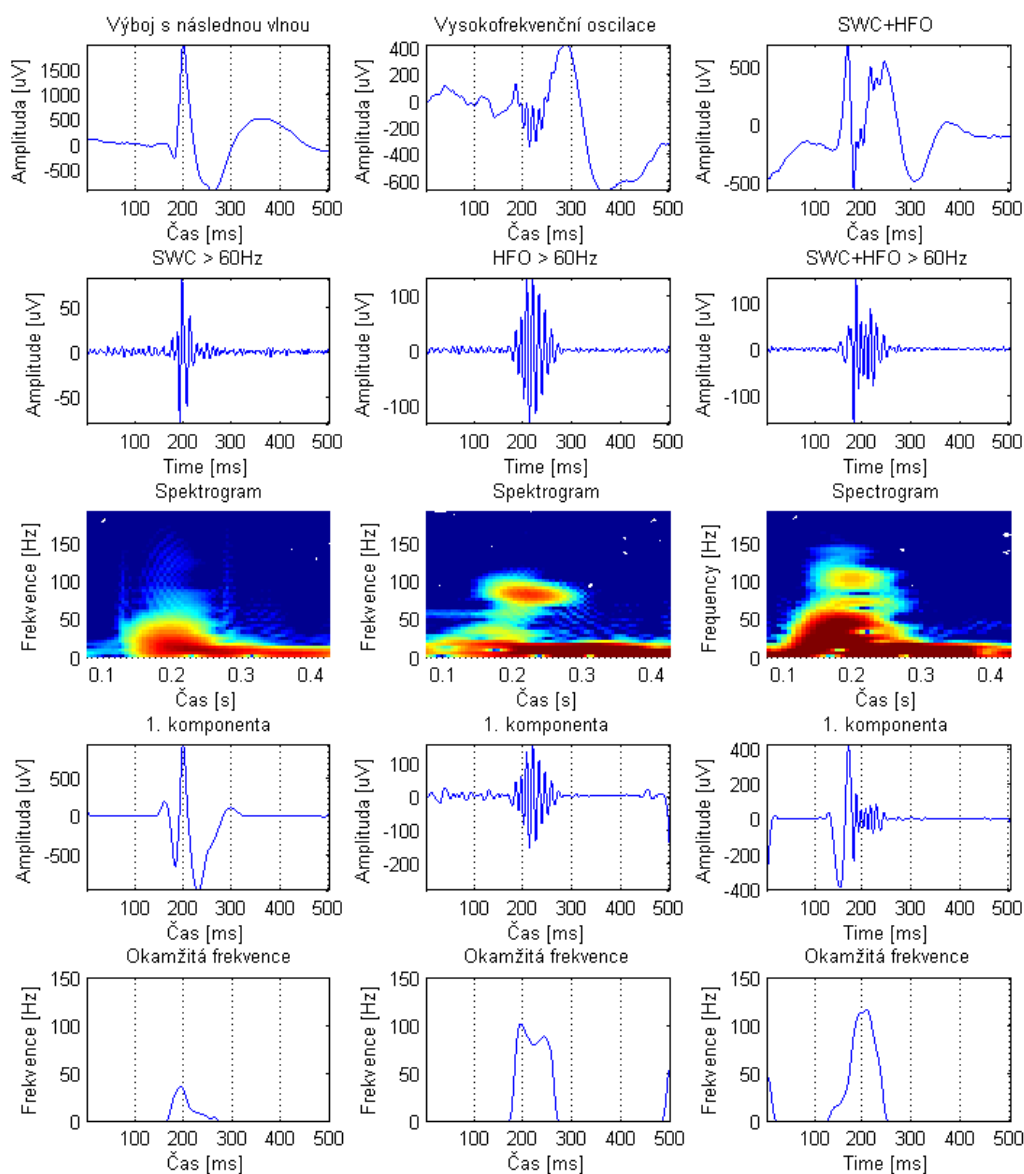
$$x(t) = \sum_{i=1}^N c_i(t) + r_N(t) \quad (3)$$

kde  $c_i(t)$  je  $i$ -tá komponenta a  $r_N(t)$  je zbylé residuum.

## ..2.3 Algoritmus pro detekci HFO

Hledané úseky v iEEG (intrakraniální EEG) záznamu by měli mít podle současných výzkumů frekvenční rozsah přibližně 80-500 Hz a měli by výrazně vystupovat nad pozadí [4,8]. Vzhledem k tomu, že hledané události mají vyšší frekvence než většina EEG signálů a iEEG není zatíženo svalovými artefakty, je použití pouze první komponenty nabíledni. Díky rozkladu na komponenty a výpočtu okamžité frekvence, také opadl problém s komplexy hrot-vlna jenž ve Fourierově spektru obsahuje i vyšší frekvence a způsobuje falešné detekce. Na Obr. 1 jsou znázorněny průběhy epileptických grafoelementů jak při zpracování přes Fourierovu transformaci a IIR filtraci (HP Butterworth na 60Hz) ale také první komponenta EMD a okamžitá frekvence grafoelementu.

Základní princip algoritmu je pouze v napočítání vhodné komponenty a její následným prahováním. Ovšem již samotný výpočet první komponenty je komplikovanější. Postup pro její získání je se zvětšujícím se objemem dat časově náročnější. Výpočet první komponenty pro jeden kanál 10-ti minutového záznamu může trvat i několik desítek minut. Proto byla potřeba najít způsob jak tento čas zkrátit. Toho jsme dosáhli postupným výpočtem po 10-ti sekundových úsecích a jejich následném složení do původní velikosti záznamu. U spline interpolace včas kolikrát vznikala u krajních bodů velká odchylka. Tu se podařilo odstranit tím, že jsme přidali při výpočtu složek jednotlivým oknům překryv a první a poslední vteřinu ze získané komponenty odstranili. Tím byla zachována kontinuita záznamu a odstraněna interpolační chyba.



Obr 1: Ukázka typických epileptických grafoelementů z pohledu Fourierovy a Hilbert-Huangovy transformace

Oddělení zajímavých segmentů od pozadí je řešeno prahováním. Za pozadí byl v komponentě považován celý signál. Jednotlivé HFO úseky představují jen zlomek z jeho celkové délky a tak výslednou hodnotu ztlačně neovlivní. Práh je pak určen jako 120% střední hodnoty napočítané z lokálních maxim v dané komponentě. Takto nastavený práh by měl být vždy nad pozadím a zasahovat jen

do úseků s výraznější energií. Protože detekované segmenty nejsou konzistentní, ty které jsou od sebe vzdáleny méně jak 30ms se spojí a poté se vyřadí všechny kratší než 40ms. Nakonec se pro všechny úseky vypočítá okamžitá frekvence a za HFO jsou považovány ty jenž mají průměrnou frekvenci vyšší než 70 Hz.

### 3 Testování a statistika

Pro účely testování jsme měli k dispozici záznam od dvou různých pacientů z dlouhodobé monitorace před epileptochirurgickým zákrokem. Z dat prvního pacienta Na těchto záznamech bylo manuálně předvybráno celkem 593 událostí, které byly ohodnoceny lékaři. Hodnotící stupnice byla “je HFO” (1), “není HFO” (0), “asi HFO” (0.5). Z výsledků byly vytvořeny 2 soubory pro hodnocení, přísnější set “Ground trust” se skládá jen ze segmentů, na kterých se shodli všichni lékaři a set “Gold standart”, kde jsou vybrány jen ty události jejichž průměr je vyšší než 0.5. Na těchto datech probíhalo testování a hodnocení algoritmu.

Výsledky detektoru byly porovnány s oběmi hodnotícími soubory a napočítáno statistické hodnocení a to senzitivita, jenž vyjadřuje míru správnosti detekcí ve smyslu rozeznávání správných událostí, a chybovost v počtu chybných detekcí na minutu. Specificita, jenž vyjadřuje schopnost algoritmu vyřadit špatné segmenty, použít nelze, protože neexistuje způsob jak získat počet TN (True Negative) úseků.

$$Senzitivita = \frac{TP}{TP + FN} \cdot 100 [\%] \quad (4)$$

#### ..3.1 Výsledky testování

Výsledky z testování algoritmu jsou shrnuty v následující tabulce.

Tabulka 1: Výsledky detektoru

	<i>Pacient 1</i>		<i>Pacient 2</i>		<i>Celkem</i>	
	<i>Senzitivita [%]</i>	<i>Chybovost [chyb / min]</i>	<i>Senzitivita [%]</i>	<i>Chybovost [chyb / min]</i>	<i>Senzitivita [%]</i>	<i>Chybovost [chyb / min]</i>
Ground trust	63,90%	6,07	33,30%	2,27	38,78%	3,04
Gold standart	64,38%	5,95	30,36%	2,3	43,50%	3,03

### 4 Závěr

Implementovali jsme algoritmus Hilbert-Huangovy transformace v prostředí MATLAB a otestovali jej na připravených datech. K dispozici byli data dvou pacientů trpících epilepsií s označenými HFO segmenty. Při nastavování parametrů detektoru jsme se zaměřili na rozumný poměr senzitivity k počtu chyb. V případě prvního pacienta je chybovost přibližně 6 chyb/min na 13 kanálech záznamu a v případě druhého pacienta 2,3 chyb/minutu na 7 kanálovém záznamu, což není tak moc. Co se týče senzitivity, výsledky druhého pacienta ukazují, že algoritmus není příliš robustní. Nicméně HHT lze využít do budoucna i mnoha dalšími způsoby. Díky okamžitým hodnotám parametrů signálu lze například pozorovat přesné změny frekvence HFO v čase. Z celkových výsledků analýzy je tedy patrné, že metoda HHT je využitelná při zpracování EEG záznamů za účelem detekování HFO a i jeho dalšího zpracování.

#### Poděkování

Práce výzkumného týmu je podporována granty Ministerstva Zdravotnictví ČR IGA NT 13357-4/2012, IGA NT 11460-4/2010 a studentským grantem SGS13/138/OKH3/2T/13.

#### Reference

- [1] Stead, M., Bower, M., Brinkmann, B. H., Lee, K., Marsh, W. R., Meyer, F. B., ... & Worrell, G. A. (2010). Microseizures and the spatiotemporal scales of human partial epilepsy. *Brain*, 133(9), 2789-2797.
- [2] McCall, P., Cabrerizo, M., & Adjouadi, M. (2012, December). Spatial and temporal analysis of interictal activity in the epileptic brain. In *Signal Processing in Medicine and Biology Symposium (SPMB), 2012 IEEE* (pp. 1-6). IEEE.

- [3] Brázdil, M., Halánek, J., Jurák, P., Daniel, P., Kuba, R., Chrastina, J., ... & Rektor, I. (2010). Interictal high-frequency oscillations indicate seizure onset zone in patients with focal cortical dysplasia. *Epilepsy research*, 90(1), 28-32.
- [4] Staba, R. J., Wilson, C. L., Bragin, A., Fried, I., & Engel, J. (2002). Quantitative analysis of high-frequency oscillations (80–500 Hz) recorded in human epileptic hippocampus and entorhinal cortex. *Journal of neurophysiology*, 88(4), 1743-1752.
- [5] Engel Jr, J., Bragin, A., Staba, R., & Mody, I. (2009). High-frequency oscillations: What is normal and what is not?. *Epilepsia*, 50(4), 598-604.
- [6] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903-995. .
- [7] Yan, R., & Gao, R. X. (2007). A tour of the tour of the Hilbert-Huang transform: an empirical tool for signal analysis. *Instrumentation & Measurement Magazine, IEEE*, 10(5), 40-45.
- [8] Gardner, A. B., Worrell, G. A., Marsh, E., Dlugos, D., & Litt, B. (2007). Human and automated detection of high-frequency oscillations in clinical intracranial EEG recordings. *Clinical neurophysiology*, 118(5), 1134-1143.

---

Jiří Balach  
email: balacjir@fel.cvut.cz  
tel: 605 962 373

Roman Čmejla  
email: cmejla@fel.cvut.cz

Petr Ježdík  
email: jezdipl@fel.cvut.cz