

# OPTIMALIZACE ALGORITMŮ PRO AUTOMATICKOU DETEKCI PATOLOGICKÉ VYSOKOFREKVENČNÍ AKTIVITY V INTRAKRANIÁLNÍCH EEG ZÁZNAMECH

J. Balach, T. Havel, P. Ježdík, R. Čmejla

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

## Abstrakt

Hodnocení intrakraniálních EEG záznamů je velice komplexní a složitá záležitost. Při dlouhodobé monitoraci je nahráno velké množství dat a pro lékaře je téměř nemožné detailně prohlédnout a vyhodnotit celý záznam. Nalezení vysokofrekvenční aktivity, která má velmi malý odstup signál/šum je pak téměř nemožné. Proto se nabízí možnost vytvořit metody pro automatickou detekci této aktivity. Za tímto účelem již vzniklo několik algoritmů pro automatickou detekci tohoto fenoménu. V naší skupině jsme se také pokusili o pár vlastních návrhů. V tomto článku se pokusíme optimalizovat jednotlivé algoritmy a porovnat jejich zlepšení či citlivost vzhledem ke změnám jejich parametrů.

## 1 Problematika vysokofrekvenčních oscilací a její detekce


Vysokofrekvenční oscilace (HFO) v intrakraniálním EEG záznamu představují nový biomarker epileptogenní tkáně [1,2,3]. HFO se obecně dělí na dva typy podle jejich frekvence. *Ripples* v pásmu od 80 – 200 Hz a *Fast ripples* v pásmu 200 – 500 Hz. Dle dosavadních výzkumů se předpokládá, že mají spojitost s oblastí počátku záchvatu (SOZ) [4]. Sledování jejich výskytu vizuální kontrolou je velice náročné. Ohodnotit deseti minutový záznam z deseti kanálů trvá přibližně 10 h [5]. Nabízí se tedy možnost využít automatických algoritmů, jenž usnadní jejich lokalizaci.

Takových algoritmů již bylo navrženo několik. Jejich rozdíly již od počátku návrhu spočívají v předpokládaném použití na konkrétních datech, hledaném grafoelementu či použitých elektrodách. Ve skutečnosti, ale tak rozdílné nejsou. Co se signálového zpracování týče, liší se pouze přístupem k datům a sledovaným parametrům. Signál lze analyzovat pomocí časových, spektrálních nebo statistických parametrů, či jejich kombinací.

V tomto článku jsme se rozhodli využít tří publikovaných detektorů a to RMS detektoru [6], Line Length detektoru [7] a Hilbert detektoru [8]. K těmto třem vytvořeným algoritmům jsme přidali ještě dva vlastní založené odlišných principech. Pomocí vytvořené testovací množiny HFO jsme se pokusili o optimalizaci těchto algoritmů a nalézt tak optimální přístup k této problematice na našich datech. Optimalizace proběhla nalezením vhodné hladiny prahování sledovaného parametru zkoumaného signálu a vyzkoušením různého typu filtrace.

## 2 Metody detekce

Základní princip detekce lze obecně popsat ve třech krocích viz **Obr.**. Na začátku dochází k předzpracování signálů. Nejčastěji jako filtrace či segmentace. V druhém kroku se napočítají parametry již předzpracovaného signálu, které jsou následně (ve třetím kroku) prahovány. Samotný práh může být statické hodnoty, či dynamicky proměnná veličina v závislosti na parametrech signálu.



Obr 1: Diagram základního procesu detekce grafoelementů

K optimalizaci jsme si vybrali tři publikované a dva vlastní algoritmy. Detailnější popis vybraných metod je v publikaci porovnávací kvalitu jejich výstupů s nastavením tak, jak byly publikovány [9], či původních článcích [6,7,8]. Stručný přehled metod a jejich principu je v **TAB 1**.


Tabulka 1: PŘEHLED A PŮVODNÍ NASTAVENÍ DETEKČNÍCH ALGORITMŮ

	<i>Filtrační pásma</i>	<i>Přístup</i>	<i>Prahování</i>
RMS Detector	100 - 500 Hz (FIR)	RMS hodnota	$\mu+5\sigma$
LineLength Detector	80 - 100 Hz (IIR)	Krátkodobá délka čáry	97.5 percentil / 3min epocha
Hilbert Detector	180 - 400 Hz (FIR)	Hilbertova obálka (energie)	Lokální maxima > $5\sigma$
ISARG H. Detector	80 - 500 Hz (IIR)	Hilbertova obálka (amplitudy)	Dynamické prahování
ISARG B. Detector	60 - 250 Hz (IIR)	Krátkodobá energie	95 percentil / 1.5 min epocha
ISARG Bayes Detector	75 - 350 Hz (IIR)	Bayesovská evidence	Okamžitá frekvence

### 3 Metodika optimalizace a testování

Držíme-li se postupu znázorněném na diagramu **OBR**, tak lze provést optimalizaci pouze v kroku 1., „Předzpracování“ a kroku 3., „Prahování“. Samotný výpočet parametrů signálu nemá na optimalizaci výsledků algoritmů žádný vliv. Jediná optimalizace, jenž lze v tomto kroku udělat je zlepšení časové a paměťové náročnosti výpočtu. O to nám ale v tomto případě nejde, a proto se zaměříme pouze na kroky 1. a 3.

U předzpracování byly rámci optimalizace vyzkoušeny tři typy filtrů a to IIR filtr s Butterworthovým oknem, IIR typu Chebyshev 2 a FIR filtr. Řády filtrů a jejich frekvenční charakteristiky jsou uvedeny v **OBR**. Frekvenční rozsah pro všechny typy algoritmů byl upraven na pásmo ripples (80 - 200Hz). Za prvé pro objektivní hodnocení všech algoritmů a za druhé z důvodu, že se v testovací množině nachází pouze HFO typu ripples. V třetím kroku nastavování prahu, jsme volili rozsah vždy v závislosti na daném typu prahování a tak aby byla pokud možno proměřena celá charakteristika zkoumaného algoritmu.



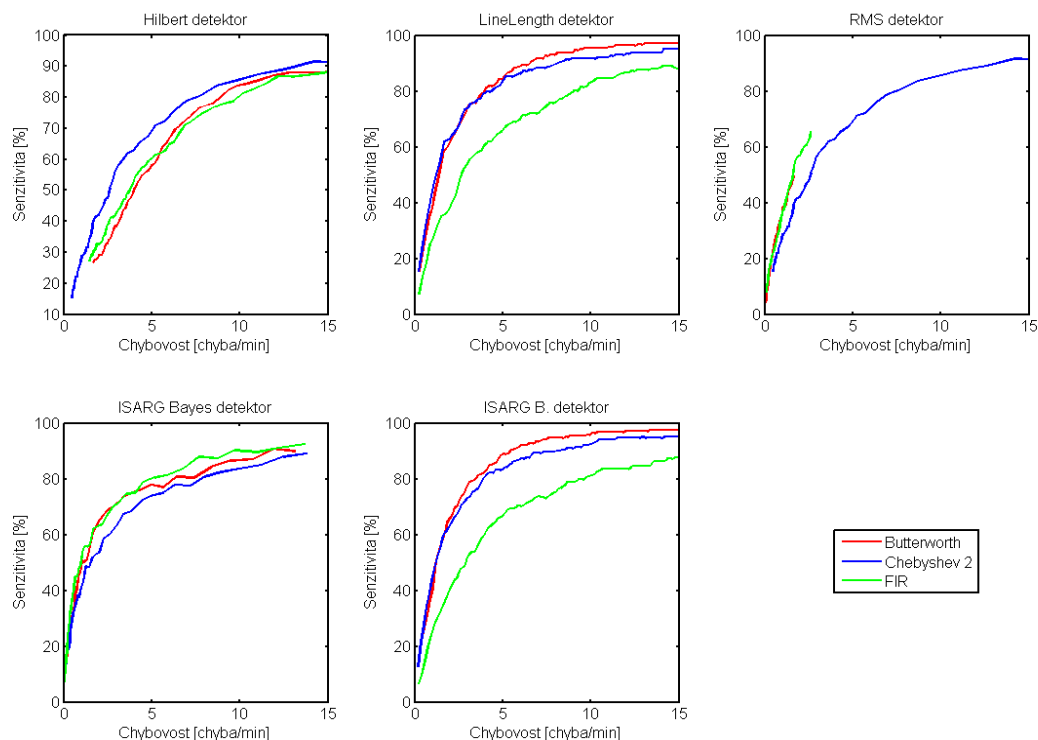
Obr 2: Frekvenční charakteristiky použitých filtrů

K ověření parametrů jednotlivých algoritmů jsme měli k dispozici signály dvou pacientů s označenými úseky HFO aktivity celkem 4mi hodnotiteli (lékaři a experti). Jako HFO byly uznány jen ty úseky, na kterých se shodla alespoň polovina hodnotitelů. Celkem se jedná o 15 minut záznamu z 8mi elektrod, kde bylo označeno celkem 252 HFO. Vzorkovací frekvence obou záznamů je 1kHz. Na těchto

datech byla měřena citlivost (senzitivita) a chybovost jednotlivých detektorů při změně základních parametrů.

## 4 Výsledky

V následujícím obrázku jsou zobrazeny naměřené ROC křivky pro jednotlivé algoritmy a zvolenou filtraci.



Obr 3: Výsledné ROC křivky detektorů

Z ROC křivek byly odečteny hodnoty citlivosti a chybovosti při ideálním nastavení parametrů a filtraci.

Tabulka 1: PARAMETRY DETEKTORŮ V OPTIMÁLNÍM BODĚ

<i>Detektory</i>	<i>Senzitivita</i>	<i>Chybovost</i>
Hilbert Detector	72,31%	5,695
Line Length Detector	78,93%	3,873
RMS Detector	65,70%	2,585
ISARG B.	78,93%	3,089
ISARG Bayes	71,49%	3,094

## 5 Závěr

Byla proměřena celá charakteristika všech algoritmů až na RMS detektor, kde u použitého filtru FIR a Butterworth docházelo k chybám zpracování detekcí. Z výsledků optimalizace je patrné, že na testovací množině dosahuje nejlepších výsledků ISARG B. detektor. Taktéž, že není žádný obecně nejlepší typ filtru, ale pro každou metodu je vhodnější jiný typ. Pro energetické parametry je vhodnější Butterworth s menším útlumem nebo chebyshev 2, s kterým algoritmy dosahují velmi podobných

výsledků. Statistické parametry, jako je bayesovská evidence má lepší výsledky s filtrem typu FIR. U Hilbertovi transformace je jasně lepší IIR filtrace typu Chebyshev 2.

## Poděkování

Práce výzkumného týmu je podporována granty Ministerstva Zdravotnictví ČR IGA NT14489 Pochopení funkční organizace neuronálních okruhů epilepsie temporálního laloku za účelem zkvalitnění předoperační diagnostiky a predikce výsledku chirurgické léčby, IGA NT13357 Detekce markerů epileptogenicity u tuberkulózní sklerózy a optimalizace epileptochirurgie, Grantovou agenturou ČR GA14-02634S Dynamika a kritické chování neuronálních populací a jejich význam v přechodu do epileptického záchvatu, Studentskou grantovou soutěží ČVUT v Praze SGS13/138/OHK3/2T/13 Analýza a zpracování biologických signálů a Nadačním fondem Neuron NFKJ 001/2012.

## References

- [1] Schevon, C. A., Trevelyan, A. J., Schroeder, C. E., Goodman, R. R., McKhann, G., & Emerson, R. G. (2009). Spatial characterization of interictal high frequency oscillations in epileptic neocortex. *Brain*, 132(11), 3047-3059.
- [2] Zijlmans, M., Jiruska, P., Zelmann, R., Leijten, F. S., Jefferys, J. G., & Gotman, J. (2012). High-frequency oscillations as a new biomarker in epilepsy. *Annals of neurology*, 71(2), 169-178.
- [3] Jiruska, P., Finnerty, G. T., Powell, A. D., Lofti, N., Cmejla, R., & Jefferys, J. G. (2010). Epileptic high-frequency network activity in a model of non-lesional temporal lobe epilepsy. *Brain*, 133(5), 1380-1390.
- [4] 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.
- [5] Zelmann, R., Mari, F., Jacobs, J., Zijlmans, M., Dubeau, F., & Gotman, J. (2012). A comparison between detectors of high frequency oscillations. *Clinical Neurophysiology*, 123(1), 106-116.
- [6] Staba, Richard J., et al. "Quantitative analysis of high-frequency oscillations (80–500 Hz) recorded in human epileptic hippocampus and entorhinal cortex." *Journal of neurophysiology* 88.4 (2002): 1743-1752.
- [7] Gardner, Andrew B., et al. "Human and automated detection of high-frequency oscillations in clinical intracranial EEG recordings." *Clinical neurophysiology* 118.5 (2007): 1134-1143.
- [8] Crépon, Benoît, et al. "Mapping interictal oscillations greater than 200 Hz recorded with intracranial macroelectrodes in human epilepsy." *Brain* 133.1 (2010): 33-45.
- [9] Balach, J., Jezdik, P., Cmejla, R., Krsek, P., Marusic, P., & Jiruska, P. (2014, June). Comparison of algorithms for detection of high frequency oscillations in intracranial EEG. In *Medical Measurements and Applications (MeMeA), 2014 IEEE International Symposium on* (pp. 1-4). IEEE.

---

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

Tomáš Havel  
email: tomas.havel@fel.cvut.cz

Petr Jezdik  
email: petr.jezdik@fel.cvut.cz

Roman Čmejla  
email: cmejla@fel.cvut.cz