



## Použití Hilbert-Huangovy transformace k detekci ERP komponent

Tomáš Prokop<sup>1</sup>

### 1 Úvod

K detekci ERP komponent a analýze EEG signálu se nejčastěji používají časově-frekvenční metody např. waveletová transformace nebo matching pursuit. Novou metodou patřící do této kategorie je Hilbert-Huangova transformace (HHT), která byla navržena pro zpracování nestacionárních signálů. V nedávné době byly navrženy cílené modifikace HHT pro zpracování EEG signálu, které výrazně vylepšili rozklad signálu na tzv. intrinsic mode funkce (IMF). V mé práci jsem se snažil dále vylepšit algoritmus modifikované HHT. Navrhl jsem dodatečné podmínky pro výběr IMF, nové klasifikátory vhodné pro detekci ERP komponent a vše otestovat na reálných datech.

### 2 Hilbert-Huangova transformace

HHT se skládá ze dvou částí – Empirical mode decomposition (EMD) a Hilbertovy spektrální analýzy (HAS). Při EMD je původní signál rozkládán na množinu Intrinsic Mode funkcí (IMF) a zbytek signálu. Proces hledání IMF se nazývá sifting. Většina dat nejsou IMF. Aby funkce byla IMF, musí její střední hodnota obálky definované lokálními maximy a minimy být nulová v každém bodě viz práce Huang et al. (1998).

Výsledkem Hilbertovy transformace je analytický signál získaný ze sekvence reálných dat. Analytický signál je signál skládající se z reálné části reprezentující původní data a imaginární části, která představuje Hilbertovu transformaci. Imaginární část analytického signálu je původní signál s fází posunutou o  $90^\circ$ . Hilbertova transformace se využívá k získání okamžitých vlastností signálu, hlavně okamžité amplitudy a frekvence. Základní i modifikovaná HHT je podrobně popsána v Ciniburk (2011).

### 3 Dodatečné podmínky

Podmínku IMF je složité striktně dodržet, a proto je nahrazena hodnotou normálního rozdělení nebo Cauchyho testu konvergence. IMF splňující tuto novou podmínku nemusí být ideální. Je možné, že by se v některé z dalších iterací dala najít lepší IMF, která by lépe vystihovala trend signálu a zlepšila tak pozdější klasifikaci. Proto jsem navrhl dvě dodatečné podmínky, které pomáhají algoritmu nalézt kvalitnější IMF.

První dodatečná podmínka je založena na normálním rozdělení. Normální rozdělení křivky lze jednoduše popsat jako průměrnou vzdálenost funkčních hodnot křivky od průměru. Nás ale nezajímá vzdálenost od průměru, ale od nuly. Tato vzdálenost by měla být u průměrné křivky obálek co nejmenší. Druhá podmínka testuje průměrnou hodnotu průměrné křivky, která by měla být co nejbližší nule.

---

<sup>1</sup> student magisterského (navazujícího) studijního programu Inženýrská informatika, obor Inteligentní počítačové systémy, e-mail: prokop@students.zcu.cz

## 4 Klasifikátory

Navrhl jsem dva klasifikátory uzpůsobené k detekci P3 komponenty. Oba využívají dva příznaky – průměrnou amplitudu a frekvenci. První klasifikátor přiděluje každému příznaku váhu na základě hodnoty příznaku a zvolené funkce. Druhý klasifikátor vypočítává příznaky v menším okně, kterým se postupně prochází signál, dokud není komponenta detekována nebo se nedosáhlo konce prohledávané části signálu.

## 5 Výsledky

K dispozici jsem měl implementaci autora modifikované HHT i s několika původními klasifikátory a jeho testovací data naměřená v naší laboratoři viz. Ciniburk (2011). V tabulce 1 jsou výsledky klasifikace nových klasifikátorů a nejlepšího původního klasifikátoru za použití dodatečných podmínek i bez nich. Zkratka SD označuje první podmínku a MV druhou. Z tabulky vyplývá, že použití nových klasifikátorů a zároveň dodatečné podmínky je nejlepší volbou, protože se dá dosáhnout vyšší maximální, minimální i průměrné úspěšnosti klasifikace než s původními klasifikátory bez použití dodatečné podmínky.

Klasifikátor	Dodatečná podmínka	Hodnota podmínky	Maximální úspěšnost [%]	Minimální úspěšnost [%]	Průměrná úspěšnost [%]
Váhový	SD	0,01	95	77,5	88,0556
Okénkový	SD	0,01	95	80	86,9444
Okénkový	MV	0,01	95	80	85,6944
Váhový	MV	0,01	92,5	80	87,0833
Původní	MV	0,01	92,5	72,5	84,0278
Původní	SD	0,025	92,5	72,5	84,0278
Váhový	Bez podm.		90	80	86,6667
Okénkový	Bez podm.		90	80	85
Původní	Bez podm.		87,5	72,5	83,3333

Tabulka 1: Úspěšnost klasifikace P3 komponenty

## 6 Závěr

Tento projekt jsem zpracovával v rámci diplomové práce. Seznámil jsem se s metodami zpracování EEG signálu a detekce ERP komponent. Zaměřil jsem se na Hilbert-Huangovou transformaci a vylepšil jsem proces hledání IMF. Dále jsem navrhl a otestoval dva nové klasifikátory. Kombinací dodatečné podmínky a nových klasifikátorů jsem dosáhl o 7,5% vyšší úspěšnosti klasifikace než u původní implementace modifikované HHT.

## Literatura

- Ciniburk J., 2011. Hilbert-Huang transform for ERP detection, disertační práce, Západočeská universita v Plzni.
- Huang N. E. and et al., 1998. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*[454].