Analiza algoritma za automatsko određivanje perioda mišićne aktivnosti temeljenog na statističkoj evaluaciji hipoteza

Autor: Armin Rist Mentor: prof.dr.sc. Stanko Tonković
Zavod za elektroničke sustave i obradbu informacija
Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu

1 Uvod

Elektromiografija (EMG) proučava mišićne električne impulse, koristeći instrument – elektromiograf, koji bilježi signal – elektromiogram. Analiza elektromiograma može otkriti nepravilnosti u radu mišića, također korisna je kod kliničkih dijagnoza neuroloških i neuromuskularnih problema. Kod mnogih analiza elektromiograma potrebno je precizno odrediti točan početak perioda mišićne aktivnosti.
Zadatak ovog diplomskog rada je analiza algoritma za automatsko određivanje perioda mišićne aktivnosti koji se temelji na statističkoj evaluaciji hipoteza.

2 Opis problema

Problem detekcija perioda mišićne aktivnosti se najčešće rješava manualnom analizom signala od strane stručnjaka za EMG signale. Kod ovakvog načina detekcije dolazi do velikih odstupanja nalaza u ovisnosti o ispitivačima, njihovoj stručnosti i koncentraciji. Iz tog razloga su napravljeni razni algoritmi za automatsku detekciju perioda mišićne aktivnosti.

3 Metoda

Implementirane su dvije vrste algoritama za automatsku detekciju perioda mišićne aktivnosti. Prvi algoritam se bazira na *Micera, Sabatini & Dario* algoritmu, koji se temelji na statističkoj metodi *„Maximum Likelihood method“*.
Kod ove metode postavljene su dvije hipoteze. Prva hipoteza predstavlja mišić u relaksiranom stanju i označava se sa H_0. Druga hipoteza H_1 predstavlja kontrakciju mišića.
Likelihood funkcija koja opisuje da hipoteza H_0 vrijedi od trenutka 0 do trenutka *r-1*, a hipoteza H_1 od trenutka *r* do *n* :

$$L(0,1,r,y_0^n) = p_0(y_0^{r-1})p_1(y_r^n)$$

Za početak se pretpostavi da je cijeli EMG signal u relaksiranom stanju:

$$L(0,y_0^n) = p_0(y_0^n)$$

Zatim se napravi omjer tih dviju *Likelihood* funkcija:

$$\frac{L(0,1,r,y_0^n)}{L(0,y_0^n)} = \prod_{t=r}^{n} \frac{p_1(y[t])}{p_0(y[t])}$$

Iz dobivene funkcije, koja se sastoji od omjera gustoća vjerojatnost potrebno je odrediti r za koji funkcija ima maksimalnu vrijednost.
Budući da se EMG signal smatra stohastičkim signalom normalne distribucije na kraju se može pisati :

$$DF(0,1,y_0^n) = \max_{r\in[0,n]}\left\{\sum_{t=r}^{n}\log\left[\frac{\frac{1}{\sigma_1\sqrt{2\pi}}e^{-\frac{(y[t]-\mu_1)^2}{2\sigma_1^2}}}{\frac{1}{\sigma_0\sqrt{2\pi}}e^{-\frac{(y[t]-\mu_0)^2}{2\sigma_0^2}}}\right]\right\}$$

Rad drugog algoritma se temelji na zadavanju amplitudnog praga, nakon kojeg se smatra da je došlo do detekcije. Prvi korak je korištenje pomičnog prozora veličine 25 ms i računanje srednje vrijednosti, zatim se traže vrijednosti iz funkcije f_2 koje su veće od μ_0 (srednje vrijednosti) + $3\sigma_0$ (standardne devijacije).

$$f_2(i) = \frac{\sum_{i}^{i+24} f(i)}{25} \qquad f_2(i) > \mu_0 + 3\sigma_0$$

Drugi algoritam je primjer kako se klasično rješava problem detekcije perioda mišićne aktivnosti.

4 Rezultati

Analiza uspješnosti algoritma se odvijala na način da su uspoređena dva implementirana algoritma. Drugi algoritam (klasični) se uzeo kao referentni.

Evaluacija rezultata	
Početci mišićne aktivnosti (ms)	-63.59
Krajevi mišićne aktivnosti (ms)	481.26
Broj detekcija	0.32
Ukupno trajanje mišićne aktivnosti	9.23%

Analiza se vršila na 66 EMG signala za svaku vrstu mišića koji su prikupljeni od 22 ispitanika. Početak mišićne aktivnosti označava razliku između trenutaka prve detekcije početka razvijenog algoritma i klasičnog algoritma, a krajevi mišićne aktivnosti označavaju razliku između trenutaka zadnjih krajeva razvijenog i klasičnog algoritma. Broj detekcija predstavlja razliku broja detektiranih perioda mišićne aktivnosti između razvijenog i klasičnog algoritma. Ukupno trajanje mišićne aktivnosti predstavlja razliku između ukupnog trajanja perioda mišićne aktivnosti razvijenog i klasičnog algoritma, obje vrijednosti su izražene kao dio signala koji su algoritmi označili kao mišićnu aktivnost, izraženo u postocima.
Iz rezultata se može zaključiti da razvijeni algoritam detektira početak mišićne aktivnosti nešto ranije od klasičnog algoritma, da se kraj mišićne aktivnosti detektira znatno kasnije od klasičnog algoritma, da razvijeni algoritam detektira nešto veći broj perioda aktivnosti, te da razvijeni algoritam detektira mišićnu aktivnost u većem dijelu EMG signala.
Primjer rada dvaju algoritama:

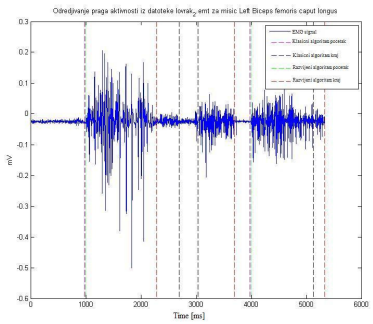

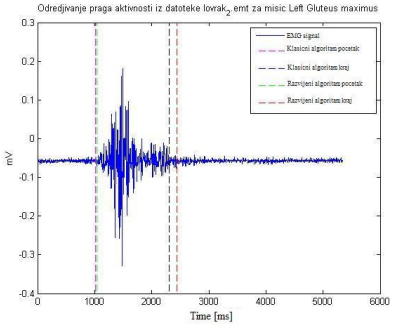

5 Zaključak

Rješavanjem ovog zadatka došlo se do zaključka da korištenjem “*Maximul likelihood*” metode dobivamo nešto veći broj detekcija perioda mišićne aktivnosti, prvi period u signalu je nešto ranije detektiran, a zadnji znatno kasnije nego korištenjem klasične metode koja se temelji na detekciji prelaska signala preko amplitudnog praga (definiranog u odnosu na standardnu devijaciju EMG signala mišića u mirovanju). Također subjektivnom, vizualnom procjenom smo zaključili da metoda temeljena na statističkoj evaluaciji hipoteza ima nešto veći broj točnih detekcija. Iako je testirana metoda nešto bolja od klasične broj pogrešnih detekcija je još uvijek dosta velik.

1. ZESOI diplomska radionica, FER, Zagreb, 1. srpnja 2010.