

Ocena ilościowa drgań w diagnostyce motoryki dłoni przy użyciu tabletu

Jarosław Marek Gliwiński
grupa I5, #74839

13 grudnia 2009

1 Wstęp

1.1 Postać problemu

Jednym z kryteriów diagnostycznych choroby Parkinsona jest występowanie drgań spoczynkowych rąk, o częstotliwości $4 - 6\text{Hz}$ i amplitudzie zmniejszającej się przy wykonywaniu ruchów dowolnych[1]. W praktyce diagnostycznej do oceny tego objawu można wykorzystać szablony przedstawiające proste geometryczne kształty, które pacjent powinien narysować ponownie na karcie szablonu, nie odbiegając od zadanych ścieżek kreślenia. Oczywistym kryterium występowania drgań jest trudność w prawidłowym skopiowaniu zadanych ruchów, świadczące zarazem o stopniu doświadczanych przez pacjenta w życiu codziennym utrudnień. Jednak kryteria oparte na subiektywnej ocenie, nawet w wykonaniu lekarza specjalisty często nie posiadają istotnej cechy — mianowicie nie jest możliwe obiektywne przyporządkowanie wynikowych wartości o wadze „wyniku pomiaru”.

W związku z powyższym tym kryteria zwyczajowo stosowane możemy nazwać *jakościowymi*, brak natomiast kryterium *ilościowego*, jakie jest dostępne w przypadku wielu parametrów badanych w praktyce medycznej (np. optometryczne badanie wzroku bądź pomiar temperatury termometrem). Dla kryterium jakościowego utrudniona jest także wymiana wyników pomiędzy lekarzami, ocena postępów leczenia objawowego a w szczególności automatyzacja pomiaru (który w przypadku tego rodzaju „pomiaru” należałoby raczej nazwać klasyfikacją).

Dość oczywistym rozwiązaniem jest akwizycja danych „rysowanych” przez pacjenta i automatyczne „komputerowe” ustalenie wyniku badania na podstawie próbkowania ścieżki przezeń kreślonej, co pozwoliłoby na ominięcie wskazanych powyżej ograniczeń. Techniczne rozwiązanie akwizycji danych jest proste — od dawna na rynku dostępne są urządzenia typu *tablet* pozwalające tego dokonać. Jakkolwiek pomimo tego optymalne rozwiązanie problemu nie jest trywialne i pozostaje kwestią otwartą.

1.2 Założenia i warunki pracy

Głównym założeniem było zachowanie niezależności metody mierzącej drgania od kształtu wzorca. Opracowana metoda musiała zatem nosić cechy niezależności od przebiegu kreślenia prawidłowego, jednocześnie wrażliwa musiała być na określony charakter zmian w stosunku do niego. Do celów badawczych dostępny był zbiór 12 zestawów danych[3] składających się z próbek opisywanych strukturą:

```
int pkTime;  
int pkX;  
int pkY;  
int pkPressure;  
int pkAzimuth;  
int pkAltitude;
```

Parametry te są oczywiste, za wyjątkiem dwóch ostatnich. Są to odpowiednio kierunku odchylenia rysika tabletu od pionu oraz kąt tego odchylenia. Ponadto znane było pochodzenie każdego zbioru danych (dla każdego pacjenta po jednym zbiorze przed- i pooperacyjnym). Kształt wzorca kreślonego przez pacjentów był znany, jednak w praktyce nie miał on większego znaczenia.

W tych warunkach opracowano model opierający się na podejściu teoriosygnalowym abstrahując od parametrów bardziej skomplikowanych niż wywodzące się bezpośrednio z opisu w pliku wejściowym. Poniżej przedstawiona została opracowana metoda *obiektywna* wraz z określeniem jej skuteczności na podstawie opracowanej miary porównującej wyniki z wynikami oceny *subiektywnej* danych ze zbioru testowego.

2 Analiza problemu

2.1 Rozważania ogólne

Proponowana metoda powinna była charakteryzować się następującymi cechami:

1. Niezależnością od wzorca
2. Zgodnością wyników z oceną subiektywną
3. Rozsądnym czasem obliczeń

Przy czym najistotniejsze są dwa pierwsze z tych kryteriów, jako że *de facto* odpowiadają za poprawność działania metody. Natychmiastowo eliminuje to metody dopasowujące do wzorca. Możemy jednak dopuścić metody zależne od wzorca w tym sensie, że nieporównywalne będą wyniki wygenerowane przy pomocy różnych wzorców. To znaczy, jeżeli charakterystyka wzorca wprowadza pewną składową stałą do wartości wyniku, możemy zaniedbać ten fakt, a wyniki nadal będą porządkowalne w ramach klasy wyników wygenerowanych przy użyciu tego samego kształtu wzorca.

To spostrzeżenie prowadzi do wniosku, iż możliwa jest *generacja* wzorca dla każdego badanego przypadku przez ekstrakcję danych nieobciążonych mierzonymi cechami¹. Możliwe to będzie oczywiście jedynie w przypadku, gdy wzorzec nie będzie zawierał cech charakterystycznych dla drgań — co wydaje się być rozsądnym założeniem. Takie podejście musi zostać jedynie uzupełnione miarą różnicy pomiędzy wygenerowanym wzorcem a danymi wejściowymi, która to miara będzie żądanym kryterium ilościowym.

2.2 Propozycja rozwiązania

Dane wejściowe możemy przedstawić jako zależności funkcyjne. Użycie słów takich jak *ekstrakcja* czy *usunięcie* w kontekście przebiegu dowolnej funkcji nasuwa użycie po-

¹Będzie to możliwe oczywiście tylko w idealnym przypadku, jednak tak czy inaczej ze względu na złożony charakter problemu metoda ma charakter przybliżony

dejsia znanego z przetwarzania sygnałów, tj. filtracji. Filtr dolnoprzepustowy o odpowiednich parametrach jest w stanie dokonać wspomnianej operacji — tj. pozostawić niskoczęstotliwościowe składowe odpowiadające parametrom wynikającym z kreślenia wzorca, zaś usunąć składowe o wyższych częstotliwościach, pochodzące od drgań dłoni pacjenta. Do przedstawionych poniżej badań użyto prostego filtra o stałych współczynnikach, tożsamego więc ze zwykłą średnią arytmetyczną n sąsiednich punktów (filtracja z oknem o długości n , jest to jednocześnie parametr odpowiadający za częstotliwość graniczną filtra). Rzecz jasna można zastosować szereg szczegółowych podejść, włącznie z teoretycznym zaprojektowaniem filtra przy uwzględnieniu charakterystyki częstotliwościowej drgań typowych w chorobie Parkinsona. Jednakże podejście to byłoby dużo bardziej złożone i wymagałoby dodatkowych informacji do istotnej poprawy wyników, zaś skalę tej poprawy trudno przewidzieć.

Po tych rozważaniach należy dla jasności przedstawić ogólny algorytm działania miary. Oto operacje wykonywane dla każdego (k -tego) punktu:

1. Jeżeli punkt został zarejestrowany z ryzykiem „w powietrzu”, pomiń k -ty punkt
2. Wylicz średnią odległość \overline{d}_k między punktami w oknie wokół k -tego punktu
3. Jeśli występuje w ramach okna odległość między dwoma kolejnymi punktami d_{ki} taka, że $d \gg \overline{d}_k$, pomiń k -ty punkt
4. Dokonaj filtracji dla tego okna
5. Wylicz różnicę r_k między wynikiem filtracji a oryginalną wartością punktu
6. Dodaj do ostatecznego wyniku $\frac{r_k}{\overline{d}_k}$

Łatwiej teraz będzie wyjaśnić pewne zastosowane operacje. Punkt 1. jest raczej oczywisty. Punkt 3. ma na celu zapobieganie sytuacji, która została zilustrowana na rys. 1. Pozostawienie takich okien powoduje zależność wyniku od poprawnego wzajemnego umiejscowienia odcinków linii — co nie jest przedmiotem pomiaru. Z kolei ostatni punkt nie jest, jak można zauważyć, jedynie prostą agregacją wyników dla kolejnych punktów — dodatkowo k -ta wartość jest skalowana przez średnią odległość \overline{d}_k . Ta modyfikacja ma za zadanie niwelować wpływ na wynik różnic w prędkości rysowania i/lub częstotliwości próbkowania tabletu. Jego wprowadzenie okazało się wskazane po analizie wyników uzyskiwanych na podstawie dodatkowo zarejestrowanych w laboratorium danych[2]. Pomimo wyraźnego braku składowych o wysokich częstotliwościach wersja algorytmu pozbawiona tego skalowania przydzielała tym dodatkowym zbiorom danych zdecydowanie wyższe wartości niż w przypadku zbioru referencyjnego².

²Jak wspomniano, prawdopodobnie te dodatkowe zbiory danych różniły się znacznie prędkością kreślenia (większe odległości między próbkami, a więc większe r_k) bądź inną częstotliwością próbkowania (mało prawdopodobne, jako że różnica parametru `pkTime` dla kolejnych próbek była dla obydwu zbiorów danych taka sama)

2.3 Optymalizacja rozwiązania

2.3.1 Przygotowania

Tak sformułowane rozwiązanie problemu nie jest jednak wystarczające do uzyskania zadowalających wyników. Po pierwsze, filtracji możemy poddawać różne parametry. Po drugie, kwestią otwartą przy zaniedbaniu analizy częstotliwościowej pozostaje dobór rozmiaru okna n . Dokonano optymalizacji tych parametrów stopniowo, w kolejnych krokach.

Pierwszym koniecznym krokiem było wyznaczenie wzorcowego uporządkowania zbiorów danych według subiektywnych kryteriów³. Dostępne było jedno uporządkowanie osiągnięte na drodze konsensusu przez grupę laboratoryjną. Dodatkowo przeprowadzono akwizycję 5 dodatkowych uporządkowań pochodzących od 3 różnych osób przy pomocy dedykowanej aplikacji. Implementacja opierała się na przeprowadzeniu dla zbioru referencyjnego turnieju[4] a następnie reprezentacji jako listy posortowanej według liczby subiektywnie przyznanych przez użytkownika „zwycięstw”. W ten sposób uzyskano 6 wzorcowych uporządkowań. Kolejnym niezbędnym elementem była miara pozwalająca określić podobieństwo dwóch uporządkowań. W tym celu zdefiniowano miarę następującej postaci wyrażającą „odległość” między pewnymi n -elementowymi uporządkowaniami u_1, u_2 :

$$(1) \quad \mu(u_1, u_2) = \sum_{i=1}^n |i - \text{pos}(u_1(i), u_2)|$$

Przy czym funkcja $\text{pos}(\text{what}, \text{where})$ określa pozycję elementu what w uporządkowaniu where . Zatem miarę μ można interpretować jako sumaryczne przesunięcie elementów na liście względem wzorcowych pozycji. Dla zbioru referencyjnego zbioru uporządkowań zdefiniowane pewne wartości charakterystyczne, przedstawione w tabeli 1. Osobno wyliczano je w grupie wszystkich uporządkowań jak i w podgrupach według osoby generującej ranking. Pobieźna analiza tych wartości pozwala na przybliżoną kategoryzację wyników na klasy:

- pary uporządkowań o $\mu \leq 10$ można uznać za nieodróżnialne (klasa I)
- pary uporządkowań o $10 < \mu \leq 16$ można uznać za bardzo podobne (klasa II)
- pary uporządkowań o $16 < \mu \leq 28$ można uznać za podobne (klasa III)
- pary uporządkowań o $28 < \mu$ można uznać za różne (klasa IV)

³Uporządkowania według niemalejącej

	generowane przez	
	różne osoby	tę samą osobę
minimalna μ	8	8
maksymalna μ	28	10
średnia μ	15.46	9

Tabela 1: Charakterystyka uporządkowań referencyjnych

2.3.2 Wyniki

Przeprowadzono uporządkowanie zbiorów danych dla każdej kombinacji następujących parametrów:

- rozmiar okna $n \in \{5, 10, 15, 20, 25, 30, 35, 40, 45\}$
- badany parametr $p \in \{X, Y, X+Y, \text{Pressure}, \text{Speed}, \text{Azimuth}, \text{Altitude}, \text{Time}\}$ ⁴

Następnie porównano każde z powstałych w ten sposób 72 uporządkowań z każdym uporządkowaniem referencyjnym, co dało w sumie 432 wyniki porównań. Wśród tych porównań 140 należało do co najmniej klasy III, 25 do co najmniej klasy II, zaś jedynie 4 do klasy I. Statystyczne wyniki dla tych danych przedstawiają wykresy na rysunkach 2–6. Wyniki dla samej klasy I są w zasadzie statystycznie nieistotne ze względu na niewielką próbę⁵. Na podstawie wyników dla klas I–III, a w szczególności I–II można łatwo określić pożądane parametry filtracji.

3 Wnioski

Na podstawie statystyk uzyskanych w punkcie 2.3.2 można wyciągnąć ogólne wnioski dotyczące optymalnych parametrów filtra. Rzmiar okna powinien wynosić około 20, zaś parametry, które należy brać pod uwagę, to współrzędne kolejnych punktów i ich odległości — a więc, co jest istotnym spostrzeżeniem, parametry przestrzenne. Wobec tego dobrym wyborem jest kombinacja parametrów zależnych od układu współrzędnych, z udziałem (z mniejszą wagą) parametru związanego z odległością kolejnych punktów (Speed). Nie ma przesłanek, by wyznaczać parametry dokładniej, ze względu na ograniczony i potencjalnie niereprezentatywny zbiór danych.


⁴X przekłada się na badanie odchylenia wzdłuż osi odciętych. Y — osi rzędnych. X+Y — odchylenie sumy. Speed — prędkość obliczona na podstawie odległości kolejnych punktów (częstotliwość próbkowania jest stała). Pressure — siła nacisku rysika. Azimuth i Altitude wyjaśniono w p. 1.2. Time to sygnatura czasowa próbki. Dodano ją w celu weryfikacji metody — uporządkowania oparte na tym parametrze powinny mieć — i zgodnie z przewidywaniami mają — najwyższe μ .

⁵Niemniej wyniki te zdają się potwierdzać wykreślone histogramy: jednokrotnie występuje każdy z parametrów ze zbioru $\{X, Y, X+Y, \text{Speed}\}$, zaś długości okna to 15 lub 20 (każda z nich dwukrotnie)


Dobrane w toku optymalizacji parametry filtra mogą nie być optymalne w ogólności — zbiór danych testowych był ograniczony ilościowo i pod względem różnorodności kreślonych szablonów, ponadto uporządkowania referencyjne dokonane zostały przez osoby bez jakiegokolwiek doświadczenia klinicznego. Jednakże zaproponowana procedura optymalizacji pozwala na ponowną kalibrację i dobór parametrów w sytuacji dostępności „lepszyc” danych wejściowych. Przy rozsądnym założeniu, że uporządkowania generowane przez amatorów nie odbiegają w sposób skrajny od profesjonalnych można stwierdzić, iż ilościowa ocena drgań oparta na filtracji dolnoprzepustowej jest skuteczna.

Literatura


- [1] Kozubski W., Liberski P. P., *Neurologia. Podręcznik dla studentów medycyny*.
- [2] Grupa I5, *Paczka z danymi od (w miarę) zdrowych ludzi*.
- [3] Jelonek J., *Komunikacja człowiek-komputer. Materiały do laboratorium*. http://www.cs.put.poznan.pl/jjelonek/kck_cw.html
- [4] Weisstein, E. W., "Tournament." *From MathWorld—A Wolfram Web Resource*. <http://mathworld.wolfram.com/Tournament.html>




Rysunek 1: Odległość „przefiltrowanego” punktu od oryginalnego jest dość duża, pomimo, że ewidentnie nie występują drgania w żadnej ze składowych. Wynik miary dla takiego okna nie jest wiarygodny.




Rysunek 2: Rozkład występowania uporządkowań wzorcowych w klasach I–III jest równomierny




Rysunek 3: Rozkład występowania parametrów w klasach I–III



Rysunek 4: Rozkład występowania długości okna w klasach I-III



Rysunek 5: Rozkład występowania parametrów w klasach I-II



Rysunek 6: Rozkład długości okna w klasach I-II