

# Klasyfikacja podpisu offline z wykorzystaniem metody DTW\*

**Khalid Saeed, Marcin Adamski**

Wydział Informatyki Politechniki Białostockiej  
ul Wiejska 45A, 15-351 Białystok

<aida>, <adams>@ii.pb.bialystok.pl  
<http://aragorn.pb.bialystok.pl/~zspinfo/>

**Streszczenie:** Podpis odręczny jest często stosowaną metodą potwierdzania tożsamości i autoryzacji wszelkiego rodzaju dokumentów. W większości przypadków otrzymany podpis jest jedynie statycznym obrazem bez dodatkowych informacji takich jak: dynamika wykonania, siła nacisku, itp. Niniejsza praca przedstawia wybrane algorytmy służące klasyfikacji offline podpisu odręcznego. Punkty charakterystyczne są pozyskiwane z mapy bitowej zawierającej linię podpisu z użyciem 3 różnych metod. Klasyfikacja wektorów cech charakterystycznych jest wykonana z wykorzystaniem nieliniowej transformaty czasowej DTW. W pracy przedstawiono wyniki badań z użyciem podstawowej metody DTW oraz uwzględniono modyfikacje takie jak: ograniczenie ścieżki dopasowania, wykorzystanie pochodnej badanego sygnału – DDTW. Uzyskane rezultaty zachęcają do dalszej pracy, poprawność klasyfikacji w niektórych przypadkach przekroczyła 90%.

**Summary:** Handwritten signature is a very common way of personal identification and variety documents verification. In most cases, the acquired signature is a static image without additional features like dynamics of writing process, pen pressure, etc. This paper presents an approach for offline classification of signatures. The characteristic points are extracted from the bitmap image of the signature following three different methods. The classification of feature vectors is conducted by means of Dynamic Time Warping (DTW) algorithm. Experiments were carried out with the standard DTW algorithm and its modifications like global path constraint and Derivative Dynamic Time Warping (DDTW). The results are encouraging for further applications as the success rate reached 90% in some cases.

## 1. Wstęp

Weryfikacja tożsamości danej osoby jest bardzo ważną kwestią w dziedzinach takich, jak: kontrola dostępu, potwierdzanie autentyczności informacji, kryminalistyka i wielu innych. Istnieje szeroki wachlarz metod począwszy od podstawowych, jak podpis odręczny i odcisk palca, do nowoczesnych metod biometrycznych wykorzystujących zaawansowane techniki pomiaru i weryfikacji danych. Dodatkowo algorytmy kryptograficzne pozwalają na cyfrowe podpisywanie informacji czyniąc ich źródło wysoce wiarygodnym.

Podpis odręczny, a zwłaszcza jego statyczna forma mimo swoich oczywistych niedoskonałości (stosunkowa łatwość podrobienia, brak dokładnej powtarzalności podpisów wykonanych przez tę samą osobę) jest wciąż bardzo powszechnie stosowany. Niniejsza praca skupia się właśnie na analizie statycznego obrazu podpisu i klasyfikacji zebranych informacji.

## 2. Pozyskiwanie danych

Dane wejściowe systemu stanowią mapy bitowe z obrazami podpisów. Mapy bitowe pochodzą ze skanowanych dokumentów, przy czym proces segmentacji obrazu podpisu od reszty informacji jest przeprowadzony przed wprowadzeniem danych do systemu. Przykłady map bitowych z linią podpisu przedstawia rys. 1.

---

\* Praca została sfinansowana przez Rektora Politechniki Białostockiej, grant nr W/WI/3/04

Rys. 1. Przykłady map bitowych podpisów.

### 3. Ekstrakcja cech

Dane w postaci mapy bitowej mają bardzo wysoką wymiarowość, co stanowiłoby problem na etapie klasyfikacji. Aby zmniejszyć wymiarowość zastosowano technikę wyboru cech reprezentujących ogólny kształt podpisu opartą o pojęcie widoku. Prezentowane podejście zostało z sukcesem wykorzystane w innych pracach badawczych przy rozpoznawaniu liter, słów i podpisu [3,5,6,7,8]. Dodatkowo celem zebrania informacji o wewnętrznej strukturze podpisu (rozpoczęcia, zakończenia linii, pętle, przecięcia) wykorzystano technikę użytą w [3]. Opis powyższych metod został przedstawiony w sekcji 3.1 oraz 3.2.

#### 3.1. Wydobywanie zewnętrznych widoków

W niniejszej pracy wyróżniamy dwa rodzaje widoków: górny oraz dolny [5,8]. Widok górny składa się z maksymalnych wartości pikseli stanowiących linię podpisu, natomiast dolny są to wartości minimalne. Wartości są obliczane jako odległości odpowiednich pikseli od dolnej krawędzi otaczającego podpis prostokąta.




Rys. 2. Podpis (b) oraz jego górny (a) i dolny (c) widok.

Jeśli w linii widoku występowały przerwy to były one ignorowane. W wyniku działania metody otrzymywano jeden wektor cech (1) na każdy widok z osobna.

$$Y = \langle y_1, y_2, \dots, y_{N-1}, y_N \rangle \quad (1)$$

#### 3.2. Wydobywanie wewnętrznej struktury podpisu

W celu zebrania informacji o wewnętrznych cechach zastosowano zliczanie liczby przejść: tło - linia dla każdej kolumny obrazu podpisu. Rys. 3 ilustruje tę koncepcję dla wybranych kolumn w obrazie przykładowego podpisu.



Rys.3. Wyznaczanie wewnętrznej struktury podpisu z wykorzystaniem liczby przejść tło-linia. Dla kolumny k1 2 przejścia, k2 – 4, k3 – 2, k4 – 4, k5 – 2.

#### 4. Redukcja cech i normalizacja

Dane otrzymane za pomocą metody widoków nadal stanowią złożony problem z punktu widzenia zadania klasyfikacji. Aby dalej zmniejszyć wymiarowość otrzymanego zbioru cech zastosowano dwa różne podejścia. Pierwsze polegało na próbkowaniu wartości widoku z określonym krokiem tzn.: wybieramy, co  $n$ -tą wartość z danego widoku. Krok  $n$  określano przy założeniu, że chcemy wybrać przynajmniej  $m$  punktów na wysokość  $H$  widoku reprezentowanego przez wektor cech (1).

$$\max = \max(y_1, y_2, \dots, y_{N-1}, y_N), \min = \min(y_1, y_2, \dots, y_{N-1}, y_N) \quad (2)$$

$$H = \max - \min \quad (3)$$

$$n = H / m \quad (4)$$

W drugim podejściu skorzystano z wyznaczania wartości ekstremalnych dla każdego z widoków [6]. Przy wyborze wartości ekstremalnych wykorzystano dodatkowo progowanie, aby zmniejszyć wpływ nieznacznych zmian wartości będących często rodzajem „szumu” powstałego w wyniku nieciągłości pióra, drgań ręki osoby piszącej lub jako efekt uboczny procesu skanowania.

W wyniku redukcji cech otrzymywano ostatecznie wektor (5) reprezentujący dany widok.

$$Y^R = \langle y_1^R, y_2^R, \dots, y_{M-1}^R, y_M^R \rangle \quad (5)$$

Normalizacja danych jest ważnym etapem w przypadku podpisów wykonanych w różnej skali. Zależnie od założeń dotyczących samego podpisu, krok ten czasem może być wymagany (podpisy w różnej skali, skanowanie z różną rozdzielczością), a czasem zbędny lub wręcz szkodliwy dla późniejszej klasyfikacji (podpis składany w polu formularza o określonych rozmiarach) [4]. W niniejszej pracy wartości wektorów opisujących zewnętrzną część podpisu były skalowane do długości jednostkowej w skali wysokości widoku, na bazie którego zostały uzyskane (6).

$$Y^R = \frac{Y^R - \min}{H} \quad (6)$$

#### 5. Klasyfikacja

Do klasyfikacji wykorzystano miarę odległości obliczaną z pomocą nieliniowej transformaty czasowej (ang. Dynamic Time Warping). Wybór niniejszej metody został uwarunkowany charakterem danych podlegających klasyfikacji. W przypadku rozpoznawania podpisów mamy do czynienia z następującymi cechami:

- różna długość wektorów cech wynikająca z różnic w rozmiarze (złożoności) podpisów,
- zmienność rozmiaru lokalnych elementów tworzących podpis takich, jak: szerokość znaków i szerokość odcinków łączących znaki,
- braki lub nadmiar elementów tworzących podpis.

Metoda DTW pozwala na znalezienie optymalnej (najmniejszej) odległości między dwoma ciągami czasowymi w sensie najlepszego dopasowania poszczególnych lokalnych wartości z tych dwóch ciągów. Wektor charakterystyczny uzyskany z pomocą opisanego wcześniej

algorytmu może zostać potraktowany jako ciąg czasowy, gdzie czas jest interpretowany jako zmiana pionowego profilu podpisu z lewego do prawego końca.

Podstawowy algorytm DTW definiuje odległość między dwoma ciągami czasowymi

$x_1, x_2, \dots, x_{k-1}, x_k$  oraz  $y_1, y_2, \dots, y_{l-1}, y_l$  jako rekurencyjną zależność (7):

$$D(i, j) = \min \left\{ \begin{array}{l} D(i, j-1) \\ D(i-1, j) \\ D(i-1, j-1) \end{array} \right\} + d(x_i, y_j) \quad (7)$$

Odległość  $d(x_i, y_j)$  może być obliczana na różne sposoby zależnie od zastosowania. W przypadku niniejszej pracy użyty został kwadrat odległości Euklidesa.

Do celów rozpoznawania wykorzystano również dwie modyfikacje podstawowej wersji algorytmu. Pierwsza wykorzystuje globalne ograniczenie możliwego dopasowania w postaci okna o rozmiarze  $r$ , poza które nie może wykraczać ścieżka dopasowania [1,3]. Druga modyfikacja polega na wyznaczaniu odległości między pochodnymi sygnałów zamiast odległości między ich poszczególnymi wartościami [2].

## 6. Wyniki badań

Celem badań było porównanie wpływu zastosowania opisanych metod budowy wektora cech oraz metody DTW na poprawność klasyfikacji podpisu. Klasyfikację przeprowadzono stosując nieliniową transformatę czasową w wersji podstawowej oraz dwie rozszerzone implementacje. Dane do eksperymentu stanowiły mapy bitowe podpisów skanowane z rozdzielczością 150dpi. Wykorzystany zbiór wejściowy składał się z podpisów złożonych przez 5 różnych osób, każdy powtórzony 5-krotnie, łącznie 25 podpisów. Wszystkie testy korzystały ze schematu, w którym każda z 5 wersji danego podpisu była wykorzystana jako podpis wzorcowy do klasyfikacji 4 pozostałych. Zgodnie z powyższym, każdy test składał się ze 100 klasyfikacji (5 rodzajów podpisów x 5 wzorców na każdy rodzaj podpisu x 4 podpisy danego rodzaju poddawane klasyfikacji).

Tab. 1 przedstawia wyniki klasyfikacji z wykorzystaniem podstawowej implementacji DTW dla widoków z różną wartością  $m$ . Klasyfikacja dla każdego widoku z osobna.

	widok górny	widok dolny
$m=5$	71%	68%
$m=10$	83%	77%
$m=20$	87%	77%
$m=40$	89%	81%

Tab. 1. Procent poprawnie sklasyfikowanych podpisów, DTW podstawowe, widoki z próbkowaniem.

Wyniki pozwalają na zgodną z intuicją konkluzję, że wraz ze wzrostem liczby cech charakterystycznych zwiększa się procent poprawnie sklasyfikowanych danych. Jednak minusem jest koszt obliczeń, gdyż algorytm klasyfikujący pracuje na danych o większej wymiarowości. Widać również, że górny widok pozwala na lepszą klasyfikację niż dolny. Jest to wynikiem tego, że jest on bardziej zróżnicowany i zawiera więcej informacji.

	widok górny	widok dolny
$m=5, r=4$	72%	68%
$m=10, r=9$	84%	77%
$m=20, r=18$	88%	76%
$m=40, r=35$	90%	81%

Tab. 2. Procent poprawnie sklasyfikowanych podpisów, DTW z oknem, widoki z próbkowaniem.

Tab. 2 przedstawia wyniki zastosowania implementacji DTW rozszerzonej o globalne ograniczenie ścieżki dopasowania do okna o rozmiarze  $r$ . Wartości  $r$  zostały wybrane tak, aby ograniczyć nadmiarowe dopasowania i jednocześnie pozwolić na wystarczającą elastyczność. Widać, że zastosowanie odpowiedniego okna pozwala poprawić wyniki klasyfikacji.

	widok górny	widok dolny
$m=5$	63%	42%
$m=10$	86%	52%
$m=20$	92%	62%
$m=40$	86%	60%

Tab. 3. Procent poprawnie sklasyfikowanych podpisów, DDTW, widoki z próbkowaniem.

Tab. 3 zawiera rezultaty algorytmu DDTW [2]. Jakość klasyfikacji w niektórych przypadkach uległa poprawie, natomiast w innych pogorszeniu. Zdaje się, że metoda dobrze sobie radzi z danymi o znacznie zróżnicowanej charakterystyce (widoki górne), gorzej natomiast klasyfikuje sygnały o mniejszej zmienności (widoki dolne). Jednakże widać, że przez wybór odpowiedniego kroku i zastosowania do danych o odpowiednim charakterze jakość klasyfikacji wyraźnie wzrosła (92% poprawnie sklasyfikowanych podpisów z użyciem widoku górnego i  $m=20$ ).

	widok górny	widok dolny
DTW	87%	73%
DDTW	91%	63%

Tab. 4. Procent poprawnie sklasyfikowanych podpisów, DDTW, wartości ekstremalne widoków.

Tab. 4 przedstawia wyniki klasyfikacji wektorów cech zbudowanych z wartości ekstremalnych poszczególnych widoków [6]. Dodatkowo, jeśli różnica między kolejnym a poprzednim ekstremum nie przekraczała określonego progu (próg  $T=0.05$  dla danych w skali  $\langle 0,1 \rangle$ ) kolejne ekstremum było ignorowane. Jak wydać rezultaty dla górnego widoku okazały się bardzo dobre, natomiast widok dolny pozwalał na nieco mniejszą poprawność klasyfikacji.

Ostatnim eksperymentem było sprawdzenie, jak dobrze można rozróżnić podpisy biorąc pod uwagę jedynie ich wewnętrzną strukturę reprezentowaną w postaci wektora cech opisanego w sekcji 3.2.

$m=5$	$m=10$	$m=20$	$m=40$
26%	37%	57%	65%

Tab. 4. Procent poprawnie sklasyfikowanych podpisów, DTW podstawowe, struktura wewnętrzna podpisu.

Rezultaty (Tab. 4) są znacznie słabsze niż w pozostałych przypadkach. Rozszerzone wersje metody DTW także nie dały lepszych wyników. Interpretacja tych danych może być dwójaka: sama struktura wewnętrzna nie pozwala na dobre rozróżnienie między różnymi klasami podpisów, a także metoda uzyskiwania wektora cech reprezentujących tę strukturę może nie być odpowiednia.

## 7. Podsumowanie i planowane kierunki badań

W pracy przedstawiono podejście do klasyfikacji podpisu offline z wykorzystaniem różnych technik ekstrakcji cech. Zastosowano trzy różne implementacje algorytmu dyskretnej transformaty czasowej do wyznaczania odległości między wzorcowym i badanym podpisem. Najwyższe z uzyskanych poprawności klasyfikacji przekraczały 90%, ale również istniały pewne kombinacje wyboru cech i wersji DTW gdzie wyniki były poniżej akceptowalnego poziomu. Wynika z tego wniosek, że uzyskanie wysokiej jakości klasyfikacji z pomocą DTW jest możliwe, jednakże wymaga to odpowiedniego dobrania cech oraz implementacji samego algorytmu. Przeprowadzone badania traktowały poszczególne elementy podpisu z osobna (widok górny, dolny, struktura wewnętrzna) celem sprawdzenia jak każdy z nich wpływa na klasyfikację. Należy jednak zaznaczyć, że zupełny system powinien uwzględniać wszystkie z tych elementów jednocześnie. Ważnym jest natomiast ocenienie na ile każdy z nich powinien wpływać na końcowy rezultat.

Wyniki eksperymentów zachęcają do dalszych badań w tym kierunku. Jako następny etap prac przewidziane jest powiększenie bazy podpisów oraz badania nad połączeniem wszystkich rodzajów informacji (zewnętrzny kształt i wewnętrzna struktura podpisu) w jeden wektor cech do procesu klasyfikacji. Dalsze badania będą się skupiać na zwiększeniu odporności systemu na próby fałszerstwa i zastosowaniu innych metod klasyfikacji np.: Ukryte Łańcuchy Markowa.

## Bibliografia

- [1] Sakoe H., Chiba S.: „Dynamic Programming Algorithm Optimization for Spoken Word Recognition”, IEEE Transactions on Acoustics, Speech, and Signal Processing, vol. ASSP-26, no. 1, luty 1978, pp. 43-49.
- [2] Keogh E. J., Pazzani M. J.: „Derivative Dynamic Time Warping”, First SIAM International Conference on Data Mining Proceedings, Chicago, IL, USA, 2001, pp. 187-194.
- [3] Rath T. M., Manmatha R.: „Word Image Matching using Dynamic Time Warping”, IEEE Conference on Computer Vision and Pattern Recognition, vol. 2, Madison, Wisconsin, czerwiec 2003, p. 521.
- [4] L. Lee, T. Berger, and E. Aviczer, „Reliable on-line Human Signature Verifiacion Systems”, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 18, no. 6, czerwiec 1996, pp. 643-647.
- [5] Saeed K., Tabędzki M., Adamski M.: „A New Approach for Object-Feature Extract and Recognition”, 9th International Conference on Advanced Computer Systems – ACS'02, Miedzyzdroje, 23-25 październik 2002, pp. 389-397.
- [6] Saeed K., Adamski M.: „Extraction of Global Features for Offline Signature Recognition”. Zaakceptowane do publikacji w ACS-CISIM, Ełk, 30.06-3.07, 2005.
- [7] Parisse C.: „Global Word Shape Processing in Off-Line Recognition of Handwriting”, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 18, no. 5, kwiecień 1996, pp. 460-464.
- [8] Saeed K., Tabędzki M.: „A New Hybrid System for Recognition of Handwritten-Script“, International Scientific Journal of Computing, Institute of Computer Information Technologies, vol. 3, issue 1, Ternopil, Ukraina 2004, pp. 50-57.