

Kiedy metody biometryczne stają się niebezpieczne

Khalid Saeed

khalids@wi.pb.edu.pl

<http://aragorn.pb.bialystok.pl/~zspinfo/>

Wydział Informatyki Politechniki Białostockiej
Wydział Fizyki i Informatyki Stosowanej AGH

Plan seminarium:

- Zainteresowania i osiągnięcia w dziedzinie *komputerowej analizy obrazów*.
- Zastosowania *macierzy Toeplitza* w redukcji danych oraz przy skutecznym opisie obrazów, a w szczególności obrazów biometrycznych.
- Program komputerowy o zastosowaniach MT

Co to Biometria?

Biometria oznacza **POMIARY BIOLOGICZE**
(ang. BIOMETRICS – **Biological Measurements**)

Nazwa ta pochodzi z greki **BIOS** - życie
i **METRON** - pomiar.

*Rozpoznawanie człowieka na podstawie jego cech
biologicznych*

-

Od kiedy istnieje biometria?

1885-1913 B.C. (Mezopotamia)

Odciski kciuków znaleziono na tablicach glinianych i ceramicznych naczyniach już w starożytnym Babilonie. Ludzie pozostawiali swoje odciski, aby zalegalizować swoje transakcje handlowe.



(seen in Museum of London)

*A więc od zawsze wykorzystywano biometrię
do identyfikacji człowieka !*

Systemy biometryczne składają się głównie z następujących elementów:

- 1. Skaner (kamera, mikrofon, fotokopiarka, ...)** - do skanowania anatomii człowieka
- 2. Przetwornik analogowo-cyfrowy oraz odpowiednie oprogramowania** - do zmiany danych analogowych na cyfrowe, zbierania i przetwarzania informacji
- 3. Baza danych** - do porównania bieżących danych z bazą w celu uwierzytelniania i identyfikacji człowieka

W biometrii wyróżniamy dwie kategorie:

1. Fizjologiczna (*Cognitive Biometrics*)

- mierzenie różnych cech indywidualnych człowieka, które zazwyczaj posiada od urodzenia.

Przykłady

Odciski palców - *Fingerprints*

Tęczówka - *Iris image* (coloured part of the eye)

Twarz - *Face*

Geometria dłoni - *Hand geometry*

Zapach - *Odor*

Wzorzec naczyniowy - *Vascular pattern*

DNA

2. Behawioralna (*Behaviometrics*)

- rejestrowanie zachowania człowieka przy pewnych czynnościach

Przykłady:

Mowa i mówca - *Speech and Speaker Recognition*



Podpis - *Signature*

Stukanie na klawiaturze - *Keystroke*

Ruch myszy - *Mouse dynamics*

Chód - *Gait (way of walking)*


Examples of Biometrics




Zdjęcie rentgenowskie kolana



Naczynia krwionośne



Rozstaw zębów



Signature

Źródło:[1] oraz opracowanie własne

Dlaczego stosujemy biometrię przy
uwierzytelnianiu i identyfikacji człowieka?

- W odróżnieniu od liczbowych haseł czy PIN kodów, biometria prezentuje niepowtarzalne i niezawodne hasła, po prostu każdy człowiek ma swoje cechy/rysy.

Poza tym:

- nietrudno zapomnieć czy zgubić klasyczne hasło,

- łatwa jest również kradzież tradycyjnych haseł.

Ale czy to oznacza, że systemy biometryczne są niezawodne?

A z drugiej strony, co zdecyduje o tym, którą cechę biometryczną należy zastosować? Dlaczego?

Poniższa tabela odpowiada na te pytania:

Errors Biometric	Error Rate	Error Sources	False Positive Successful theft	False Negative Fails to match
Fingerprint	1 in 500+	wycedrzs, dirt, age	Extremely Difficult	Extremely Difficult
Face	no data	lighting, age, glasses, hair	Difficult	Easy
Hand	1 in 500	hand injury, age	Very Diff.	Medium
Speech	1 in 50	noise, weather, colds	Medium	Easy
Iris tęczówka	1 in 131,000	poor lighting	Very Diff.	Very Diff.
Retina siatkówka	1 in 10,000,000	glasses	Ext. Diff.	Ext. Diff.
Signature	1 in 50	changing signatures	Medium	Easy

Źródła: [1], [2] oraz modyfikacja własna

Więc nie ma optymalnej, idealnej metody biometrycznej.

Z tej tabeli wynika, że biometria nie jest niezawodna!

Z drugiej strony, co może zagwarantować, że cech człowieka nie można ‘ukraść’?

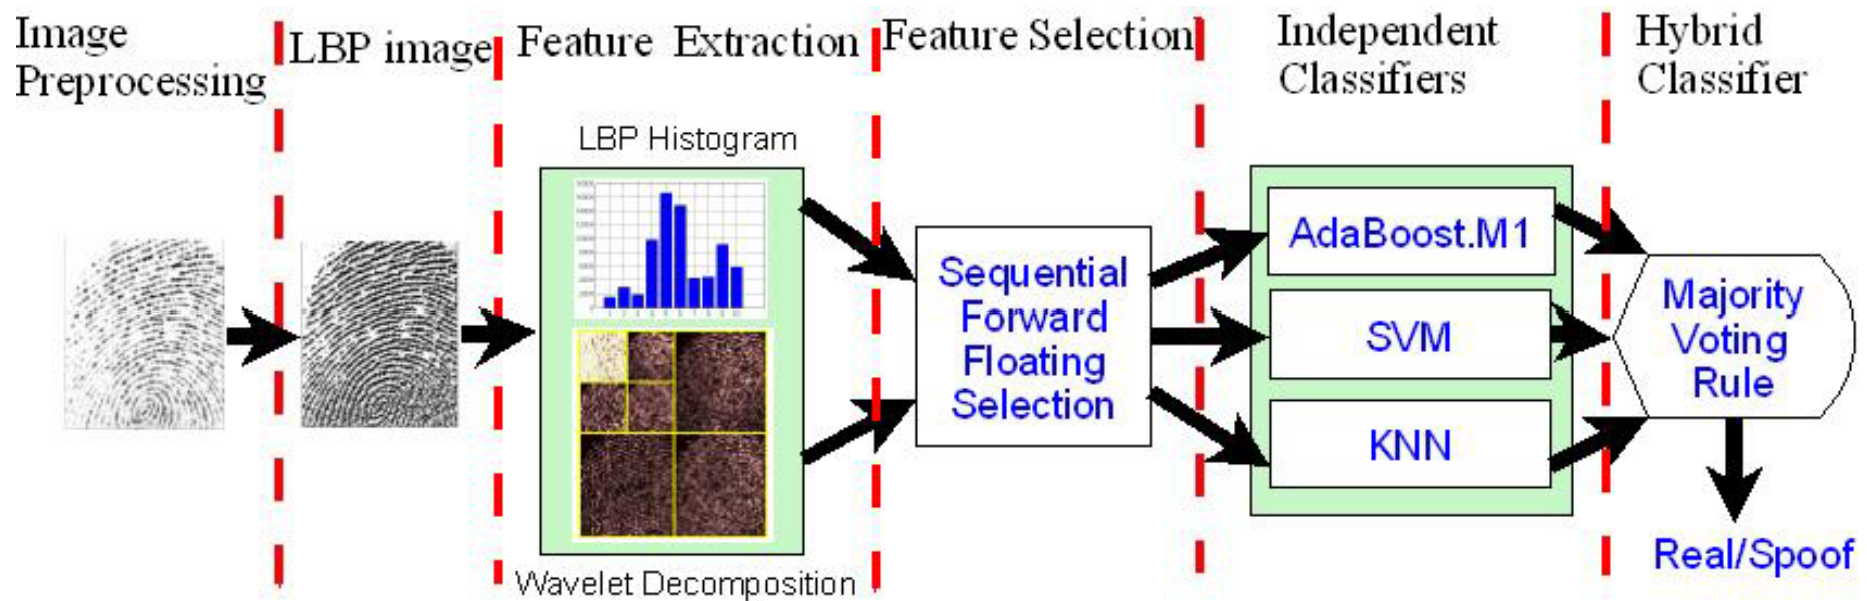
Spoofting - *Falszowania biometrii***

** [3] *Spoofting and Anti-Spoofting in Biometrics*, IJBM, vol. 1, no. 2, Inderscience Publishers, UK, 2008.

Anti-Spoofing

Badacze naukowci oczywiście od razu odpowiedzieli na spoofing stosując nowe metody ‘anti-spoofing’. Wynaleźli więc sposoby zatrzymania fałszerzy.

Zaczęli badać nie tylko obrazu danej cechy biometrycznej, lecz jej żywotność. Badali, na przykład, wzorzec odcisków palca, a równocześnie stosowali czujniki do testowania, czy ten palec jest żywy.



Liveness detection approach


Podejście do wykrycia żywotności tkanek palca

Źródło: [3]

Anti-Spoofing

Dalej jednak fałszowania nie zniknęły, gdyż złodzieje biometrii zastosowali różne sztuczne materiały do stworzenia figur symulujących żywe tkanki – temperatura ciała, krążenie krwi, itp.

Casts



Silicone rubber



Fun-Doh



Zelgan powder



M-seal



Pyrax-RR



Plastic

Moulds



Gummy, Fun-Doh




Gummy



Fun-Doh



Silicone



Live finger, Gummy

Podrobione palce

Źródło: [3]



(a)



(b)



(c)

Portions of fingerprint images:

- (a) Real finger,
- (b) Fun-Doh finger,
- (c) Gummy finger.

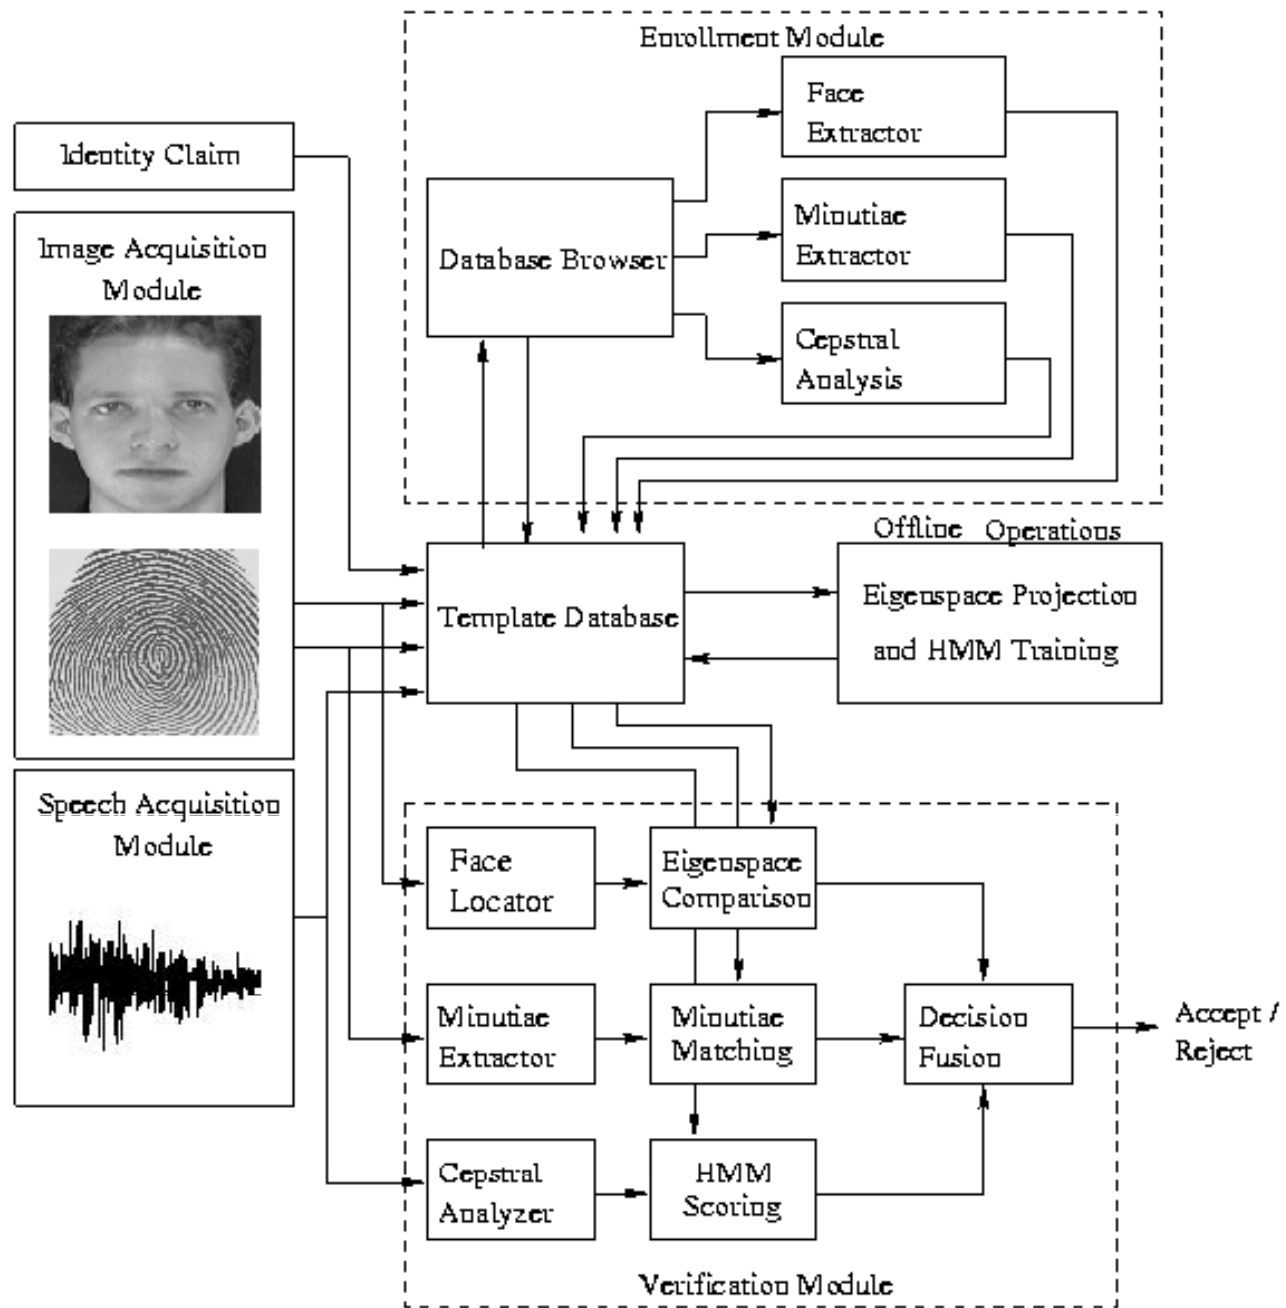
Badania i wyniki różnych eksperymentów okazały, że nie ma żadnego systemu biometrycznego, który może być zastosowany sam i zdałby egzamin!

**Jakie więc widzimy rozwiązanie?
Co zrobić, aby nie dopuścić do
sfalszowania naszych cech
biometrycznych?**

Multi-modelowe systemy wyglądają na najlepszy sposób ochrony danych człowieka i są chyba najlepszym rozwiązaniem.

Jain's Model of MULTIBIOMETRICS

Jain opracował model składający się z 3-ch metod jako 'Fusion Biometric System' [2], [4].



Kiedy zintegrujemy dwie lub więcej metod w jeden system, to stworzymy nowy problem – złożone systemy obliczeniowo !!

Jednak, na to znajdują się różne rozwiązania – algorytmy do REDUKCJI DANYCH.

Najważniejszym zadaniem takich algorytmów jest stworzenie modelu matematycznego, który zapewnia:


- zmniejszenie obliczeń
- otrzymanie wersji danych bez strat informacji o danym obiekcie.

W tym celu opracowałem model matematyczny na podstawie macierzy TOEPLITZ'a i ich minimalnych wartości własnych.


Dane liczby rzeczywiste

$$a_i \quad i = 1, 2, \dots, n$$

rozmieszczone na płaszczyźnie x - y według jakiegoś kryterium mogą na przykład reprezentować współrzędne danego obrazu.





Te punkty mogą być uporządkowane tak,
aby tworzyły poniższy wykres.



Zostaje to wykonane
według następującej
transformaty:

$$(x_i, y_i) \Rightarrow \lambda_i$$



Wykonuje się to korzystając z macierzy
Toeplitza.

Historia

Brune Function → Determinants →
→ D and λ of TM with complex numbers →
→ TM with real elements

Rational function → Taylor series → TM and
submatrices → λ for each submatrix


$$\lambda_0 \geq \dots \geq \lambda_i \geq \dots \geq \lambda_n$$

Macierze Töeplitza*

W swojej prostej formie, macierz Töeplitza jest taką macierzą hermitowską, która ma *stałe i równe wartości na diagonalu o ujemnym nachyleniu*.

$$C = \begin{bmatrix} c_0 & c_{-1} & c_{-2} & \cdots & c_{-n+1} \\ c_1 & c_0 & c_{-1} & \ddots & \vdots \\ c_2 & c_1 & c_0 & \ddots & c_{-2} \\ \vdots & \ddots & \ddots & \ddots & c_{-1} \\ c_{n-1} & \cdots & c_2 & c_1 & c_0 \end{bmatrix}$$

* Von Otto Töeplitz (Gottengen), "Über Die Fourier'sche Entwicklung Positiver Funktionen," Aus einem an Herrn Caratheodory gerichteten Briefe, Rendiconti del Circolo Matematico di Palermo, vol. 32 (1911), pp. 191-192.




Zachowanie minimalnych wartości własnych macierzy Töeplitza.


$$\lambda_0 \geq \dots \geq \lambda_i \geq \dots \geq \lambda_n$$

Spowoduje to zmniejszenie wymaganych danych wejściowych oraz zminimalizowanie elementów wektora cech dla danego obrazu w danej klasie.



Redukcja ta wynika z istotnego faktu, iż wektor cech zawiera *relację między cechami, a nie same cechy, jak w metodach klasycznych.* *Każdy kawałek wykresu przekazuje taką samą informację.*



... więc informacja jest podobna na wykresie jednego obrazu, ale różni się od informacji innych obrazów w danej klasie. Zatem wykresy te mogą stać się idealnym ANOTATOREM (deskryptorem).



Jak budować (konstruować) macierze Töeplitza
z punktów charakterystycznych obrazu?





Punkty charakterystyczne na płaszczyźnie biegunowej (a) oraz kartezjańskiej (b).


Źródło: [5]


Pozycje n punktów charakterystycznych leżących na każdej linii obrazu są wykryte, gdzie n zależy od klasy badanego obrazu.

Jako przykład
rozpatrzemy obraz litery „*dzim*” z alfabetu arabskiego
z trzema liniami

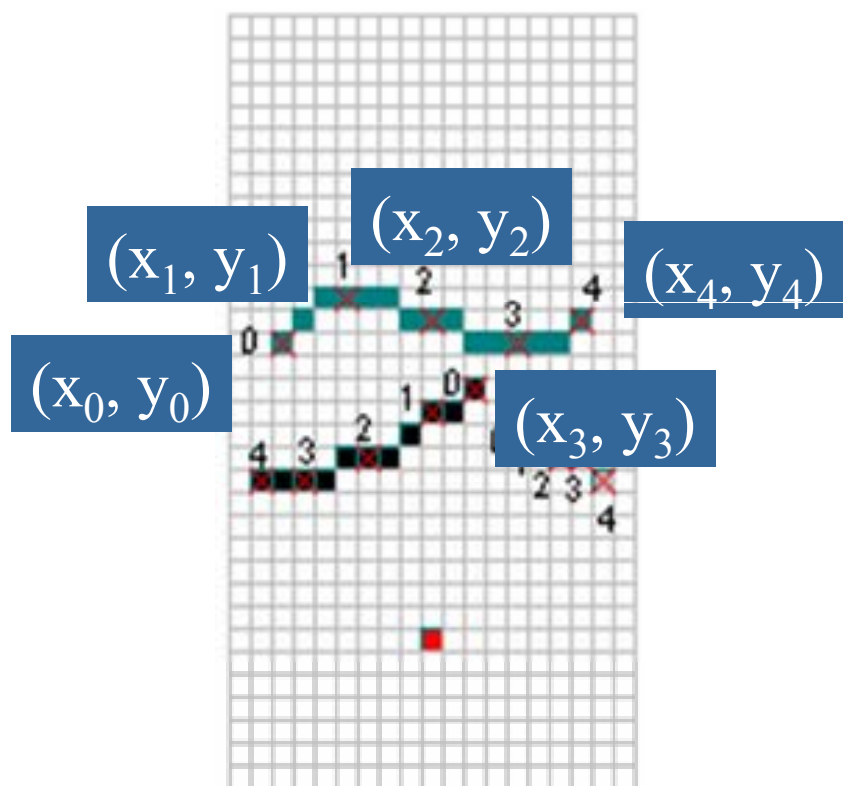


a po ścienianiu i fragmentacji






Wybranie punktów charakterystycznych




Wczytanie współrzędnych punktów
... w tym przykładzie, dla jednej linii



Tworzenie funkcji wymiernej

x_0	x_1	x_2	x_3	x_4
y_0	y_1	y_2	y_3	y_4


$$f(s) = \frac{P(s)}{Q(s)} = \frac{x_0 + x_1s + x_2s^2 + x_3s^3 + x_4s^4 + \dots}{y_0 + y_1s + y_2s^2 + y_3s^3 + y_4s^4 + \dots}$$

Rozwijanie w szereg Taylora

$$f(s) = \frac{P(s)}{Q(s)} = \frac{x_0 + x_1s + x_2s^2 + x_3s^3 + x_4s^4 + \dots}{y_0 + y_1s + y_2s^2 + y_3s^3 + y_4s^4 + \dots}$$



$$T(s) = c_0 + c_1s + c_2s^2 + \dots + c_is^i + \dots$$

Stworzenie macierzy Töeplitza i obliczanie minimalnych wartości własnych dla jej **podmacierzy**

$$C_0 = c_0 = \frac{x_0}{y_0} \quad \text{daje} \quad \lambda_0 \quad \quad C_1 = \begin{bmatrix} c_0 & c_1 \\ c_1 & c_0 \end{bmatrix} \quad \text{daje} \quad \lambda_1$$

$$C_2 = \begin{bmatrix} c_0 & c_1 & c_2 \\ c_1 & c_0 & c_1 \\ c_2 & c_1 & c_0 \end{bmatrix} \quad \text{daje} \quad \lambda_2$$


Natomiast,

$$C_k = \begin{bmatrix} c_0 & c_1 & c_2 & \cdots & c_k \\ c_1 & c_0 & c_1 & \ddots & \vdots \\ c_2 & c_1 & c_0 & \ddots & c_2 \\ \vdots & \ddots & \ddots & \ddots & c_1 \\ c_k & \cdots & c_2 & c_1 & c_0 \end{bmatrix} \quad \text{daje} \quad \lambda_k =, \dots \text{ itd.}$$

Otrzymane minimalne wartości własne stworzą szereg:

$$C = \begin{bmatrix} c_0 & c_1 & c_2 & \cdots & c_{n-1} \\ c_1 & c_0 & c_1 & \ddots & \vdots \\ c_2 & c_1 & c_0 & \ddots & c_2 \\ \vdots & \ddots & \ddots & \ddots & c_1 \\ c_{n-1} & \cdots & c_2 & c_1 & c_0 \end{bmatrix} \longrightarrow \begin{matrix} \lambda_0 \\ \lambda_1 \\ \vdots \\ \lambda_i \end{matrix}$$

$$T(s) = c_0 + c_1s + c_2s^2 + \dots + c_i s^i + \dots$$



λ_0
 λ_1
 \vdots
 λ_n

←

$$FV = [\lambda_0, \lambda_1, \dots, \lambda_n]$$

Szereg tych minimalnych wartości własnych **maleje**
monotonicznie do określonej granicy.

$$\lambda_0 \geq \dots \geq \lambda_i \geq \dots \geq \lambda_n$$

$$\lim_{n \rightarrow \infty} \lambda^n = \min \Re f(s)$$

Ten fakt jest udowodniony zarówno teoretycznie
jak i eksperymentalnie.

Granica tutaj nie ma żadnego znaczenia chociaż w specyficznych
zagadnieniach teorii obwodów elektronicznych oraz w filtrach
cyfrowych odgrywa ważną rolę.


Są jeszcze inne sposoby wprowadzania danych do macierzy Töeplitza, czyli obliczania współczynników szeregu Taylora, bez konieczności dzielenia wielomianów:

$$1) \quad c_i = \sqrt{x_i^2 + y_i^2}$$

$$2) \quad c_0 = |r_0| - |r_i|, \quad c_1 = |r_1| - |r_2|, \dots, c_n = |r_n|$$

$$3) \quad c_i = |r_i| e^{j\varphi_i} \quad \text{gdzie} \quad \begin{cases} |r_i| = \sqrt{x_i^2 + y_i^2} \\ \varphi_i = \tan^{-1} \frac{y_i}{x_i} \end{cases}$$

Różnica długości kolejnych wektorów

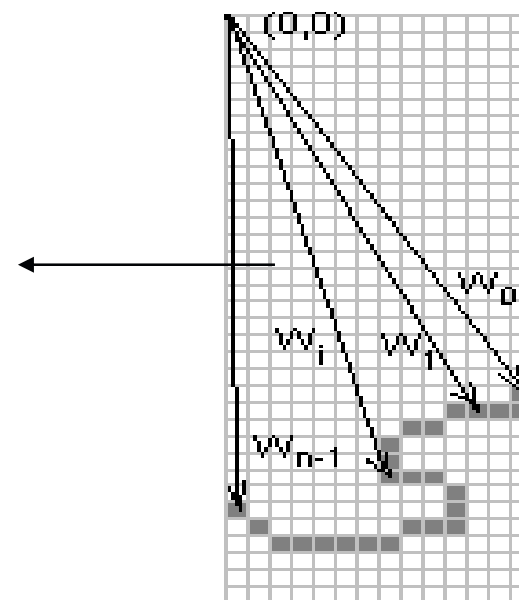


$$T(s) = c_0 + c_1s + c_2s^2 + \dots + c_is^i + \dots$$

Różnica długości kolejnych wektorów

$$c_i = |W_{i-1}| - |W_i|$$

$$i = 1, 2, \dots, n-1$$



$$T(s) = c_0 + c_1s + c_2s^2 + \dots + c_is^i + \dots$$

... Żeby opis i analiza były skuteczne, prawidłowe ścienianie jest bardzo ważne.

Opracowałem algorytm do szkieletyzacji liter alfabetów, który został rozszerzony, żeby ścieniać dowolny obraz.

Literatura

[1] Strike Force:

<http://www.strikeforcetech.com/solutions/biometrics/asp>.

September 2008.

[2] A. K. Jain and A. Ross, "Multibiometric Systems", *Comm. ACM*, vol. 47, no. 1, pp. 34-40, January 2004.

[3] K. Saeed (EiC), "Spoofing and Anti-Spoofing in Biometrics", *IJBM-International Journal of Biometrics*, vol. 1, no. 2, Inderscience Publishers, UK, 2008.

[4] A. K. Jain and S. Pankanti, "A Touch of Money," *IEEE Spectrum*, vol. 43, no. 7, pp. 22-27, July 2006.

[5] K. Saeed, "Image Analysis for Object Recognition," Bialystok Technical University Press, Bialystok, Poland, 2004.

D Z I Ę K U J Ę