

OCENA JAKOŚCIOWA PUNKTÓW CHARAKTERYSTYCZNYCH TWARZY W PROCESIE ROZPOZNAWANIA

Sebastian PABIASZ¹

¹ Politechnika Śląska, Gliwice; sebastian.pabiasz@polsl.pl; identyfikator ORCID: 0000-0002-1239-5789

Streszczenie: Celem artykułu jest analiza dwóch zbiorów punktów charakterystycznych twarzy oraz zbadanie ich skuteczności na dużym zbiorze danych. Przedstawiono dwie metody ekstrakcji punktów charakterystycznych twarzy. Pierwsza bazuje na zmiennej liczbie punktów dobieranych automatycznie, druga bazuje na predefiniowanej siatce, wzorowanej na punktach antropometrycznych. Obydwie metody wykorzystują sieci neuronowe typu SOM.

Słowa kluczowe: biometria twarzy 3d, punkty charakterystyczne, rozpoznawanie twarzy

QUALITATIVE ASSESSMENT OF FACIAL LANDMARKS IN THE RECOGNITION PROCESS

Abstract: The purpose of this article is to analyze two sets of facial landmarks and to test their effectiveness on a large set of data. Two methods of extracting characteristic points of the face are presented. The first one is based on a variable number of automatically selected points, the second one is based on a predefined grid modeled on anthropometric points. Both methods use SOM-type neural networks.


Keywords: 3d face biometrics, landmarks, face recognition

1. Wprowadzenie

Rozpoznawania twarzy bazujące na obrazie 3D, jest coraz popularniejsze w dzisiejszych czasach. Dzieje się tak dlatego, ponieważ coraz większa liczba rozwiązań wymaga pewnej identyfikacji użytkownika (banki, giełdy) (A. Locher, M. Perdoch, H. Riemenschneider and L. Van Gool, 2016). Nie bez znaczenie pozostaje też rozwój telefonów komórkowych, których kamery pozwalają budować obraz 3D „w locie” (O. Muratov, Y. Slynko, V. Chernov, M. Lyubimtseva, A. Shamsuarov and V. Bucha, 2016), (X. Yang *et al.*, 2020). Oczywiście nie jest to model idealny, ale pozwala przynajmniej w minimalnym zakresie określić czy wizerunek użytkownika jest rzeczywisty czy zostało podstawione zdjęcie. Istnieje wiele podejść do samego procesu rozpoznawania (Lei, Y., Bennamoun, M., Hayat, M., Guo, Y., 2014, Li, H., Huang, D., Morvan, J.M., Wang, Y., Chen, L., 2015). W niniejszych badaniach skupiono się na koncepcji punktów charakterystycznych. Są to unikatowe punkty występujące na twarzy. Analizując ich usytuowanie możemy identyfikować bądź autoryzować użytkownika. W poprzednich badaniach zaproponowano dwa podejścia. Pierwsze to punkty wyznaczone w sposób automatyczny, niezależne od typowych punktów antropologicznych. Drugie punkty bazujące na punktach antropologicznych. Obydwa rozwiązania bazują na samoorganizujących się sieci neuronowych SOM, które zachowują topologię powierzchni przestrzeni trójwymiarowej. Zachowując topologię sieci, automatycznie zachowujemy związek między punktami orientacyjnymi twarzy reprezentowanymi przez węzły sieciowe. Takie podejście zapewnia natychmiastową i jednoczesną identyfikację charakterystycznych punktów na twarzach do rozpoznania. Niniejszy artykuł przedstawia porównanie obydwu zbiorów punktów i stara się odpowiedzieć na pytanie który zestaw punktów jest jakościowo lepszy w procesie rozpoznawania. Metoda rozpoznawania jest ta sama w obydwu przypadkach, zbiór danych wejściowych też, zmieniają się tylko dane referencyjne.

2. Punkty charakterystyczne twarzy

Koncepcja punktów charakterystycznych (ang. *landmarks*), wywodzi z antropologii. Są to z góry określone punkty na ciele człowieka wykorzystywane w pomiarach. Twarz a w zasadzie głowa ma pokaźny zbiór tych punktów. Rysunek 1 prezentuje, zbiór charakterystyczny dla twarzy.




Rysunek 1. Podstawowy zbiór punktów antropometrycznych. Opracowanie własne.

Punkty charakterystyczne twarzy wyznaczone w sposób automatyczny

Zbiór automatycznych punktów charakterystycznych jest wynikiem działania autorskiego algorytmu (Pabiasz, S., Starczewski, J.T., Marvuglia, A., 2014). Wyróżnia on 4 rodzaje wartości:

- lokalne minimum — najmniejsza wartość w obrębie okna przetwarzania,
- lokalne maksimum — największa wartość w obrębie okna przetwarzania,
- globalne minimum — najmniejsza wartość w obrębie wiersza lub kolumny,
- globalne maksimum — największa wartość w obrębie wiersza lub kolumny



Rysunek 2. Przykład automatycznych punktów charakterystycznych z zaznaczonym obszarem nosa. Opracowanie własne.


Rysunek 2 przedstawia przykłady automatycznych punktów charakterystycznych. Jak można zauważyć jest ich znacznie więcej w porównaniu do punktów antropometrycznych. Niektóre z nich się pokrywają. Zaznaczony obszar to (czarna ramka), to wyniki wyszukiwania obszarów których ułożenie jest charakterystyczne dla nosa. Obszary te zostały wyznaczone w sposób automatyczny. Wykonano klasyczne uczenie maszynowe.

Okno przetwarzania to mały wycinek obrazu. Rozmiar okna jest z góry zdefiniowany. Omawiane punkty zebrano w następujące podzbiory:

- **all** — zbiór wszystkich punktów,
- **col-l** — zbiór wartości lokalnych z analizy kolumnowej,
- **col-g** — zbiór wartości globalnych z analizy kolumnowej,
- **glob** — zbiór wartości globalnych z obydwóch analiz,
- **row-l** — zbiór wartości lokalnych z analizy wierszowej,
- **row-g** — zbiór wartości globalnych z analizy wierszowej.

Predefiniowane punkty charakterystyczne

W tym wypadku liczba punktów charakterystycznych jest stała a ich rozmieszczenie bazuje na punktach antropometrycznych (Rysunek 3)(Starczewski, J.T., Nieszporek, K., Wróbel, M., Grzanek, K., 2018). Podczas przetwarzania obrazu 3D twarzy siatka ta jest dostosowywana do każdej twarzy.



Rysunek 3. Predefiniowane punkty charakterystyczne. Na podstawie (Starczewski, J.T., Nieszporek, K., Wróbel, M., Grzaneck, K., 2018).

3. Porównanie zbiorów punktów charakterystycznych

W celu oceny jakościowej przedstawionych zbiorów, wykonano rozpoznawanie twarzy przy użyciu 50 twarzy z bazy NDOff-2007 (Faltemier, T., Bowyer, K., Flynn, P., 2008). Twarz referencyjna ustawiona była w pozycji frontальной. Dla każdej z twarzy przygotowano 5 ujęć z różnych pozach (np. frontally, z boku). Rozpoznawanie twarzy przeprowadzono w dwóch grupach:

- Twarzy ustawionych frontally
- Twarzy nie ustawionych frontally

W badaniu brano pod uwagę tylko poprawnie rozpoznane twarze oraz twarz rozpoznane fałszywie. W obydwóch przypadkach użyty był algorytm oparty o sieć SOM. W przypadku punktów automatycznych wynik końcowy to najlepszy wynik ze wszystkich po równych grupach (all, col-l, col-g, glob, row-l, row-g). Tabela 1 przedstawia wyniki eksperymentu.

Tabela 1.

Wyniki rozpoznawania twarzy.

	Zbiory	
	Zbiór punktów automatycznych	Zbiór punktów predefiniowanych
Twarz umieszczona	79,1 % / 8,3%	77,9 % / 8,9%

frontalnie		
Twarz nie umieszczona frontalnie	74,4 % / 11%	62,8 % / 13,7 %

Pierwsza wartość oznacza procent twarzy rozpoznany prawidłowo, druga – nieprawidłowo (wynik fałszywie dodatnio).

Metoda pierwsza lepiej radzi sobie w przypadkach zarówno umieszczenia twarzy frontalnie jak i w przypadkach w których twarz fotografowana jest pod kątem. W przypadku twarzy fotografowanej frontalnie wyniki są zbliżone. Przewagę metody pierwszej można tłumaczyć tym, iż zbiór punktów jest znacznie większy niż w przypadku metody drugiej stąd przy braku pewnej ich części wynik rozpoznawania może nie być precyzyjny. Należy zwrócić uwagę iż współczynnik wyników fałszywie dodatnich we wszystkich przypadkach jest porównywalny.

4. Podsumowanie

W artykule przedstawiono i porównano dwie podobne metody reprezentacji i rozpoznawania twarzy oraz przetestowano ich skuteczność rozpoznawania na dziesięciokrotnie większym zbiorze danych niż były testowane pierwotnie. Metody sprawdzono pod względem poprawnie rozpoznanych twarzy jak również pod wynikiem fałszywie dodatnich (FAR/FRR). Obydwie metody wykazały podobne rezultaty pod względem rozpoznawania twarzy ustawionej frontalnie jak również pod względem wyników fałszywie dodatnich. Metoda wyznaczająca punkty charakterystyczne w sposób automatyczny lepiej radziła sobie w przypadku twarzy ustawionych nie frontalnie. Jest to związane z tym iż reprezentacja twarzy w przypadku tej metody składa się ze znacznie większej liczby punktów, dlatego też nawet przy braku pewnej części z nich charakterystyka twarzy jest na tyle zróżnicowana, że pozwala lepiej radzić sobie z niedoborem danych i dawać skuteczniejsze wyniki rozpoznawania. Metoda druga ma mniejszy zbiór danych oraz jest on zunifikowany. Jeżeli chodzi o zastosowania lepiej nadaje się do oceny wizerunku twarzy „w locie”, gdzie warunki akwizycji mogą być wymuszane np. autoryzacja wizerunku klienta w aplikacjach bankowych, które porównują dane z danymi z dowodu osobistego. W dalszych pracach należałoby się skupić nad hybrydą obydwóch metod.

Bibliografia

1. Lei, Y., Bennamoun, M., Hayat, M., Guo, Y. (2014), An efficient 3D face recognition approach using local geometrical signatures. *Pattern Recogn.* 47(2), 509–524 (2014)
2. Li, H., Huang, D., Morvan, J.M., Wang, Y., Chen, L., (2015) Towards 3d face recognition in the real: a registration-free approach using fine-grained matching of 3d keypoint descriptors. *Int. J. Comput. Vis.* 113(2), 128–142
3. Pabiasz, S., Starczewski, J.T., Marvuglia, A.,(2014), A new three-dimensional facial landmarks in recognition. In: Rutkowski, L., Korytkowski, M., Scherer, R., Tadeusiewicz, R., Zadeh, L.A., Zurada, J.M. (eds.) *ICAISC, Part II. LNCS*, vol. 8468, pp. 179–186. Springer, Heidelberg
4. Faltemier, T., Bowyer, K., Flynn, P., 2008, Rotated profile signatures for robust 3d feature detection. In: 8th IEEE International Conference on Automatic Face Gesture Recognition, FG 2008, pp. 1–7
5. Starczewski, J.T., Nieszporek, K., Wróbel, M., Grzanek, K. (2018). A Fuzzy SOM for Understanding Incomplete 3D Faces. In: Rutkowski, L., Scherer, R., Korytkowski, M., Pedrycz, W., Tadeusiewicz, R., Zurada, J. (eds) *Artificial Intelligence and Soft Computing. ICAISC 2018. Lecture Notes in Computer Science()*, vol 10842. Springer, Cham.
6. A. Locher, M. Perdoch, H. Riemenschneider and L. Van Gool, 2016, "Mobile phone and cloud — A dream team for 3D reconstruction," *IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2016, pp. 1-8, doi: 10.1109/WACV.2016.7477629.
7. O. Muratov, Y. Slynko, V. Chernov, M. Lyubimtseva, A. Shamsuarov and V. Bucha, 2016, "3D Reconstruction for a Smartphone," *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2016, pp. 893-900, doi: 10.1109/CVPRW.2016.116.
8. X. Yang *et al.*, 2020, "Mobile3DRecon: Real-time Monocular 3D Reconstruction on a Mobile Phone," in *IEEE Transactions on Visualization and Computer Graphics*, vol. 26, no. 12, pp. 3446-3456, doi: 10.1109/TVCG.2020.3023634.