

Kraków, 11.01.2019

Prof. dr hab. inż. Bogusław Cyganek
Wydział Informatyki, Elektroniki i Telekomunikacji
Katedra Elektroniki
Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
cyganek@agh.edu.pl

Recenzja rozprawy doktorskiej
mgra inż. Michała Romaszewskiego
New methods for hyperspectral image classification

Wstęp

Recenzja dotyczy rozprawy doktorskiej Pana mgra inżyniera **Michała Romaszewskiego** pt. „*New methods for hyperspectral image classification*”, opracowanej w roku 2018 w Instytucie Informatyki Teoretycznej i Stosowanej Polskiej Akademii Nauk w Gliwicach. Promotorem pracy jest p. dr hab. inż. Piotr Gawron. Promotorem pomocniczym jest p. dr inż. Przemysław Głąb. Praca została napisana w języku angielskim. Przygotowanie recenzji zostało zlecone przez p. prof. dr hab. inż. Jerzego Klamkę, zastępcę Dyrektora Instytutu.

1. Charakterystyka zagadnienia naukowego podjętego w pracy, tezy pracy oraz umiejscowienie podjętego zagadnienia w nauce światowej

Rozprawa doktorska Pana magistra Michała Romaszewskiego dotyczy opracowania nowych metod klasyfikacji obrazów hiperspektralnych. Obrazy te należą do specyficznej grupy obrazów uzyskanych z wykorzystaniem sensorów wielo-spektralnych dzięki czemu uzyskuje się znacznie większe pokrycie pasma promieniowania niż to ma miejsce np. w przypadku dobrze znanych obrazów kolorowych RGB. Dzięki ilości przenoszonych w ten sposób informacji, w wielu dziedzinach nauki oraz techniki, takich jak np. geografia, kartografia, ekologia, rolnictwo, kryminalistyka, poszukiwania i ratownictwo, obrazy hiperspektralne znajdują liczne zastosowania. Umożliwiają one bardziej dogłębną analizę właściwości obserwowanych obiektów niż ma to miejsce w przypadku zastosowania np. wspomnianych obrazów kolorowych. Tym niemniej, ze względu na konieczność zastosowania specjalnych sensorów, proces akwizycji jest kosztowny. Z kolei ze względu na charakter oraz ilość danych, klasyfikacja obrazów hiperspektralnych pociąga za sobą konieczność opracowania innych podejść niż popularne i dobrze znane metody klasyfikacji innych typów sygnałów. Praca p. mgra inż. Michała Romaszewskiego wpisuje się w ten nurt badań związanych z opracowaniem skutecznych metod klasyfikacji obrazów hiperspektralnych.

Podjęty przez p. mgra inż. M. Romaszewskiego problem badawczy uważam za istotny. W pracy została przedstawiona następująca teza „*Application of multi-view and semi-supervised learning improves the accuracy of hyperspectral image classification algorithms*”. Teza ta została następnie wykazana.

Doktorant potrafił opracować dwie zaawansowane i przede wszystkim skuteczne metody klasyfikacji obrazów hiperspektralnych. Metody te uważam za główne osiągnięcie naukowe p. mgra inż. Michała Romaszewskiego.

Rozprawa jest obszerna, liczy ponad 140 stron i składa się z 6 rozdziałów, jak również bogatego spisu literatury dotyczącej przedmiotu badań. Przedstawiona praca ma charakter teoretyczno-eksperymentalny i bez wątpienia plasuje się w dyscyplinie informatyka.

2. Najważniejsze osiągnięcia naukowe przedstawione w rozprawie, ich oryginalność oraz pozycja w stosunku do stanu wiedzy

Do najważniejszych osiągnięć naukowych Doktoranta, p. mgra inż. Michała Romaszewskiego, opisanych w recenzowanej pracy i stanowiących oryginalny dorobek zaliczyć można zaproponowanie, a następnie opracowanie teoretyczne, wykonanie oraz przetestowanie dwóch różnych metod klasyfikacji obrazów hiperspektralnych. Poniżej przedstawiona została krótka charakterystyka obydwu rozwiązań.

1. Zastosowanie paradygmatu uczenia pół-nadzorowanego (ang. *semi-supervised*) w schemacie do-uczenia (ang. *co-training*), jak również zastosowanie zarówno cech przestrzennych, jak i spektralnych punktów obrazowych do opracowania oryginalnej metody klasyfikacji obrazów hiperspektralnych. Metody klasyfikacji dzieli się często na podstawowe dwie grupy: metody nadzorowane, które umożliwiają otrzymanie działania zbliżonego do eksperckiego, co uzyskiwane jest dzięki danym wcześniej sklasyfikowanym (poetykietowanym, oznaczonym) przez eksperta, oraz druga grupa tzw. metod nienadzorowanych, w których dzięki znalezieniu pewnych wspólnych właściwości danych możliwa jest ich klasteryzacja, bądź też klasyfikacja. Oczywiście, metody nadzorowane wymagają dużego nakładu związanego z przygotowaniem danych. Istnieją też tzw. metody pół-nadzorowane, łączące obydwie te podejścia. Co więcej, wykazano że zastosowanie tzw. do-uczenia pozwala na znaczne zwiększenie dokładności wynikowego klasyfikatora, dzięki użyciu zarówno dostępnych danych oznaczonych, jak i tych nieoznaczonych, które w kolejnych procesach iteracyjnych zostają wykorzystane do poprawy klasyfikatorów już istniejących. Podejście tego typu zastosował również Doktorant w opracowanej metodzie. W pierwszym kroku dane nieoznaczone klasyfikowane są przez dwa klasyfikatory, wytrenowane wcześniej na dostępnej puli danych oznaczonych. Wyniki ich klasyfikacji są następnie szeregowane pod kątem pewności odpowiedzi, np. na podstawie zwracanego prawdopodobieństwa przynależności do danej klasy, a następnie tak wyselekcjonowane odpowiedzi z powrotem zasilają zbiór danych uczących, ponownie wykorzystany do kolejnego trenowania klasyfikatorów. Można wykazać, że taki proces postępowania prowadzi do otrzymania wysoce skutecznych klasyfikatorów, o jakości znacznie przekraczającej klasyfikatory trenowane wyłącznie na danych oznaczonych. Metoda ta, ze względu na użycie dwóch klasyfikatorów typu P oraz N, została nazwana przez Autora *PNGrow*. Na porównawczych zbiorach obrazów hiperspektralnych, takich jak Indian Pines, Modified Indian Pines oraz Pavia University i La Selva, wykazuje ona znaczną skuteczność klasyfikacji, porównywalną lub przewyższającą wiele innych metod klasyfikacji obrazów hiperspektralnych.
2. Opracowanie podstaw teoretycznych, jak również implementacji pół-nadzorowanej metody klasyfikacji obrazów hiperspektralnych z wykorzystaniem wielo-zależności danych (ang. *multi-view*). W podejściu tym p. mgr inż. Michał Romaszewski zastosował wielo-zależność (wieloaspektowość) cech danych w postaci kolekcji jednokierunkowych ważonych grafów do klasyfikacji z wykorzystaniem błędzenia losowego (ang. *random walk*). Metoda ta została opisana

w postaci algorytmu (Algorithm 1, str. 50), który następnie został przeanalizowany teoretycznie, jak również zbadany eksperymentalnie. Bardzo ważne jest tutaj opracowanie przez Autora warunków koniecznych oraz wystarczających istnienia rozwiązania w postaci prawidłowego poetykietowania każdego z węzłów grafu, czyli w rezultacie możliwości przeprowadzenia pełnej klasyfikacji danych. Jest to bardzo cenne osiągnięcie przede wszystkim teoretyczne, ale również umożliwiające w praktyce określenie możliwości działania metody w danych warunkach eksperymentalnych. Metoda ta umożliwia również określenie występowania klastrów danych, czyli miejsc grupowania danych. Oprócz przedstawienia podstaw teoretycznych tej metody, Autor eksperymentalnie przeanalizował działanie tej metody, wykazując dużą przydatność tego podejścia do klasyfikacji obrazów hiperspektralnych (Tabela 4.1). Metoda ta charakteryzuje się nieco mniejszą dokładnością niż pierwsza z opracowanych metod, jednakże działa lepiej niż metody oparte o klasyfikatory SVM.

Wyżej wymienione osiągnięcia świadczą o dużej dojrzałości naukowej Pana magistra inżyniera Michała Romaszewskiego, który swobodnie porusza się zarówno w dziedzinie widzenia komputerowego, uczenia maszynowego, metod obliczeniowych, jak również w dziedzinie programowania systemów komputerowych.

3. Słabe strony rozprawy, jej główne wady oraz zagadnienia dyskusyjne

Niewątpliwie praca napisana jest na wysokim poziomie, zarówno pod kątem naukowym, jak również edycyjnym. Tak jak już wspomniano, Autor prezentuje kilka oryginalnych i pod kątem formalnym dobrze rozwiniętych metod badawczych. Metody te zostały również gruntownie przebadane w procesie klasyfikacji obrazów hiperspektralnych, wykazując dobre działanie. Jednakże pozostaje kilka istotnych kwestii i pytań, które podzieliłem na zasadnicze i dotyczące wyboru głównych kierunków i metod badawczych, jak również umiejscowienia zaprezentowanych rozwiązań w kontekście osiągnięć współczesnej nauki i tzw. state-of-the-art. W drugiej części przedstawiam pozostałe pytania, czy też wątpliwości, które już bliżej dotyczą szczegółów prezentowanych rozwiązań.

Bardzo ważnym aspektem w działalności naukowej, a szczególnie w naukach technicznych, jest ciągłe monitorowanie i odnoszenie się do najnowszych i najskuteczniejszych rozwiązań. W dziedzinie klasyfikacji obrazów, jak również uczenia maszynowego, do których należy również recenzowana rozprawa, w ciągu ostatnich kilku lat nastąpił prawdziwy przełom za sprawą opracowania głębokich sieci neuronowych. Sieci neuronowe znane są od kilkudziesięciu lat. Dla przykładu, tzw. sieci spłotowe zostały opracowane pod koniec lat dziewięćdziesiątych ubiegłego stulecia. Tym niemniej, dzięki badaniom naukowym, zarówno teoretycznym (np. rozwiązanie problemu zanikającego gradientu), jak również związanym z rozwojem technologii obliczeniowych (dostępność kart graficznych), opracowane zostały głębokie sieci neuronowe w swojej skuteczności znacznie przewyższające większość znanych rozwiązań w dziedzinie klasyfikacji obrazów, w tym hiperspektralnych. Co więcej, powszechna dostępność platform programistycznych (np. TensorFlow, Teano, itd.) spowodowała prawdziwą ekspansję rozwiązań bazujących na głębokich strukturach neuronowych, jak również przyczyniła się do wyłonienia się wręcz dziedziny gospodarki w postaci sztucznej inteligencji (AI). Niestety, Autor rozprawy w ogóle tego zjawiska nie zauważa, przytaczając jedynie dwie publikacje z tego zakresu ([2] z roku 2016, autorstwa Aptoula *et al.*, oraz [19] z roku 2015, autorstwa zespołu Chen *et al.*). Jest to duże niedopatrzenie, czy też wręcz niedostrzeżenie nowych i bardzo ważnych, wręcz przełomowych,

kierunków w uprawianej dziedzinie. A opublikowanych i łatwo dostępnych prac dotyczących klasyfikacji obrazów hiperspektralnych za pomocą struktur głębokich jest wiele i są na bardzo dobrym poziomie. Dla przykładu przytaczam niektóre z nich, łatwo dostępne już od roku 2016:

1. Yunsong Lia, Weiyang Xiea, Huaqing Li: *Hyperspectral image reconstruction by deep convolutional neural network for classification*. Pattern Recognition 63 (2017), pp. 371–383 (online 2016)
2. Shi Cheng, PunChi-Man: *3D multi-resolution wavelet convolutional neural networks for hyperspectral image classification*, Information Sciences, Information Sciences, Vol. 420, 2017, pp 49-65.
(Pavia Univ. overall acc. OA=96.60, average acc. AA=95.91, Salinas: OA=94.67, AA=97.17)
3. Shiqi Yua, Sen Jiaa, ChunyanXub: *Convolutional neural networks for hyperspectral image classification*, Neurocomputing, Vol. 219, 2017, pp. 88-98.
(Pavia Univ. overall acc. AA=67.85, Salinas AA=85.24)
4. M. He, B. Li and H. Chen, *Multi-scale 3D deep convolutional neural network for hyperspectral image classification*, 2017 IEEE International Conference on Image Processing (ICIP), 2017, pp. 3904-3908.
(Pavia Univ. 98.49, Salinas 97.24)
5. Subir Paul a, D. Nagesh Kumar: *Spectral-spatial classification of hyperspectral data with mutual information based segmented stacked autoencoder approach*, ISPRS Journal of Photogrammetry and Remote Sensing 138, 2018, pp. 265–280 (online od 2017).
6. M.E. Paoletti, J.M. Haut, J. Plaza, A. Plaza: *A new deep convolutional neural network for fast hyperspectral image classification*, ISPRS Journal of Photogrammetry and Remote Sensing 145, 2018, pp. 120–147 (online od 2017).
7. Congcong Chen et al.: *Hyperspectral classification based on spectral-spatial convolutional neural networks*. Engineering Applications of Artificial Intelligence 68, 2018, pp.165–171 (online od 2017).
(Pavia Univ. 0.9844, Indian Pines 0.9839).
8. Qishuo Gao, Samsung Lim: *Hyperspectral Image Classification Based on a Convolutional Neural Network and Discontinuity Preserving Relaxation*. IGARSS 2018 - IEEE International Geoscience and Remote Sensing Symposium, 2018.
9. Mengxin Ha et al.: *Joint spatial-spectral hyperspectral image classification based on convolutional neural network*. Pattern Recognition Letters, 2018.
(Pavia Univ. 99+)

Są to tylko niektóre prace, a uwzględniając rok 2019 ich ilość uległa znacznemu zwiększeniu. Znajdują się tam też prace, które wręcz wpisują się w metodologię przyjętą przez Doktoranta, tj. klasyfikacji z wykorzystaniem zarówno informacji przestrzennej, jak i spektralnej sygnałów hiperspektralnych. Stąd też pisanie (rozdział 2.5, wnioski) i porównywanie się do metod tzw. *state-of-the-art* w tej dziedzinie (np. tabele 2.1-2.4), bez uwzględnienia już dobrze zakorzenionych i znanych w środowisku architektur sieci głębokich wymaga gruntownego uzupełnienia.

Oczywiście, nastanie epoki głębokich struktur neuronowych nie musi i nie oznacza zaprzestania badań nad innymi rozwiązaniami (gdyby tak było, to nigdy nie powstałyby sieci głębokie), w tym wykorzystujących np. struktury grafowe do klasyfikacji obrazów, itd. Każda z tych metod ma swoją

specyfikę, zalety i wady, np. czas i ilość niezbędnych danych do uczenia, złożoność obliczeniową, możliwość interpretacji wyników, itd. Co jednak jest istotne i wymagane od każdego badacza to śledzenie i zauważanie bieżącego postępu nauki i techniki, jak również porównanie swoich rozwiązań do rozwiązań już istniejących. Tak więc, Doktorant powinien znacznie bardziej odnieść się, jak również porównać swoje wyniki, do tych rozwiązań.

Pewną zagadką jest dla mnie sposób przedstawienia właściwości oraz możliwości aplikacyjnych drugiej z głównych metod, przedstawionej w postaci algorytmu nr 1. Na str. 94 Autor pisze „*Results indicate that the Algorithm 1 has a potential to be an effective method for hyperspectral image classification. However, since clarity of its theoretical properties was the main focus of its design, its assumptions may be oversimplified when applied to real data*”. Znajdujemy tu dwie istotne, aczkolwiek zaskakujące informacje. Jedną to że algorytm ten „posiada potencjał żeby być efektywnym w klasyfikacji obrazów”. Tylko nie bardzo wiadomo na czym ten potencjał miałby polegać, jak również nie wiadomo czy Autor już go zna, czy tylko się domyśla. Być może jest to bardziej życzenie niż stwierdzenie. Po drugie, i niemniej zaskakujące, że główną przesłanką w jego opracowaniu było osiągnięcie przejrzystości teoretycznej rozwiązania, cokolwiek to znaczy. Niestety, nie mogę się zgodzić z żadnym z tych stwierdzeń i być może należy zaliczyć je raczej do sformułowań nietrafionych.

Następna istotna sprawa, to ograniczenie ewaluacji algorytmów wyłącznie do baz hiperspektralnych. Algorytmy te wydają się być na tyle uniwersalne, że aż prosi się o ich przetestowanie na jednej z wielu dobrze dostępnych baz testowych z obrazami RGB, takimi jak np. PASCAL, German Road Signs, CIFAR10, CIFAR100, itd. Obrazy te to również jakiś rodzaj „wielo-spektralności”, a są one znacznie bardziej urozmaicone o ile chodzi o zawartość, format, itd. niż dostępne bazy hiperspektralne. Ale oczywiście, to tylko pomysł na przyszłe badania.

Praca nie należy jednak do lektur łatwych, głównie przez wprowadzenie wielu równoważnych definicji, jak również przez samą objętość pracy, która moim zdaniem bez utraty wartości naukowych mogłaby zostać skrócona do wielkości trzech, czterech publikacji naukowych (czyli mniej więcej o połowę). Główne pytania i niejasności związane z tym aspektem pracy są następujące.

Autor używa wielu różnych pojęć dotyczących tego samego zjawiska. Wyśledzenie tego faktu zajmuje czas i jest frustrujące podczas analizy prezentowanych metod. Dla przykładu używane jest słowo „example”, które dopiero w przypisie na str. 41 wytłumaczone jest, że jest to „zwykły” piksel obrazowy „*each example corresponds to a single hyperspectral pixel that can be described by a vector of reflectance values*”. Niestety, mimo iż jest to wektor, Autor nie zawsze zaznacza ten fakt poprzez użycie odpowiedniej czcionki (do tego celu przyjęło się używać czcionek typu *bold*), czy też symbolu wektora nad zmienną. Podobnie niejasne jest pojęcie „view”, które w dziedzinie przetwarzania obrazów może mieć też kilka innych znaczeń niż użyte przez Autora. Co prawda Autor podejmuje próby usystematyzowania pojęć, np. w tabeli 3.1, ale w rezultacie wprowadza kolejne zamieszanie pojęciowe – np. pierwszy wiersz, P, „*The set of examples (nodes)*”, czyli „example” to „node”, ale tuż na poprzedniej stronie znajdowało się to już przytoczone wyjaśnienie, że być może jest to też „pixel”...

Przedstawienie algorytmu 1 – Niejasne pojęcie "arguments" – raczej powinno być przyjęte w algorytmie Input / Output. Od razu nasuwa się też pytanie w jaki sposób otrzymywać "na wejściu" np. stochastyczne macierze przejść S_v , itd.

Przyjęte założenie dotyczące eksperta typu P zakłada równomierne jądro gaussowskie (wzór 2.2). Jednakże już na początku lat dziewięćdziesiątych Perona i Malik pokazali, że użycie funkcji anizotropowych, gdzie struktura sygnału wpływa na strukturę jądra, prowadzi do znacznie lepszych wyników. Dlaczego więc zwykle jądro gaussowskie?

Autor wielokrotnie stwierdza inspirację zastosowania dwóch klasyfikatorów P oraz N pracą Z. Kalal, *et al.*: *Tracking-learning-detection*. IEEE Transactions on Pattern Analysis and Machine Intelligence, z roku 2012. Jednakże użyte tam klasyfikatory P oraz N mają nieco odmienną rolę i są użyte w inny sposób niż ten zaprezentowany w rozprawie. Czy można te dwa podejścia jakoś porównać?

Doktorant powinien też jasno opisać na ile jego metoda, w postaci algorytmu 1, różni się od innych podejść, np. zaprezentowanych w pracy [95]?

Rozdział 4.2.1 – warto by się zastanowić jaki wpływ ma podział danych na rozdzielne "widoki"; Wiele metod właśnie wykorzystuje ich korelację i traktuje razem.

Str. 84 – Autor zakłada zdobycie dodatkowej informacji na temat przetwarzanych danych, dobrze, tylko jak to zrobić automatycznie? Inny klasyfikator? Ekspert?

Rozdział 4.3.4, str. 90 – dyskusja warunków wystarczających, ale jak odporne/nieodporne jest obliczanie tych warunków "wystarczalności" rozwiązania; Na ile ich obliczenie jest dokładne, zakładając konkretny zbiór danych. Temat ten powinien zostać rozwinięty przez Doktoranta.

Podobnie dobieranie parametrów, np. współczynnika lambda, kontrolującego działanie algorytmu, Zakładając jakieś praktyczne użycie tych metod to dobieranie tych parametrów wydaje się być bardzo uciążliwe. Jak to zrobić? W porównaniu np. z zespołem SVM'ów, gdzie znalezienie parametrów w tzw. trybie *grid-search* jest stosunkowo proste.

Problem do-uczania opisany na str. 91 – na ile różnorodność (diversity) pomiędzy klasyfikatorami uczestniczącymi w procesie współ-do-uczania (ang. *co-training*) wspomaga działanie metody?

Opisana została następująca procedura „*In an actual classification scenario these examples could be removed by preprocessing or heuristics such as for example the detector of mixed spectra in pixels.*” – Czy to oznacza, że musimy mieć jeszcze inny klasyfikator, lepszy? Na ile poważna jest taka wada dla działania całej metody? A może trzeba więcej „*co-learner'ów*”?

Rozdział 5.4.1 – Stwierdzenie „*assumes that due to the presence of searched small target materials in the image, statistical properties of bands where the pattern is visible become non-Gaussian*” wymaga głębszego uzasadnienia.

Rozdział 5 – wspomniane są tensory, wielowymiarowe momenty statystyczne (*multi-cumulants*), itd. ale brak jest wyjaśnienia tych pojęć, a nawet odniesień literaturowych.

W podsumowaniu „*Summary of research goals*” Autor wymienia obliczenia warunków wystarczalności SCM oraz ESCM. Ale w ogóle jaka jest złożoność obliczeniowa samego algorytmu, jak również obliczania warunków wystarczalności SCM oraz ESCM? W pracy nie ma zdania na ten temat.

Tabela 4.1 prezentująca wyniki działania różnych metod, z *PNGrow* wymienionym jako niekwestionowany zwycięzca. Tylko jak to się ma do innych jeszcze rozwiązań (*random trees*, np.) nie wspominając o sieciach głębokich? No i to trochę porównanie to jest być może nie-fair w stosunku do SVM, bo w ich przypadku nie było procesu do-uczania (*co-training*)?

Referencja [112] – nieprawidłowy spis autorów tej pracy.

Powyższe pytania mają charakter polemiczny i dotyczą dalszego wyjaśnienia, bądź też zawierają sugestie rozszerzenia pewnych zagadnień natury naukowej poruszonych w rozprawie.

4. Przydatność rozprawy dla nauk technicznych

Opisane powyżej metody opracowane oraz opisane w rozprawie doktorskiej p. mgra inż. Michała Romaszewskiego są oryginalne i zaawansowane naukowo. Metody te mają istotne znaczenie dla nauk technicznych, zarówno w aspekcie osiągnięć teoretycznych, jak i możliwości aplikacyjnych. Przydatność ta jest pochodną głównych i samodzielnych osiągnięć Autora, o których była mowa w poprzednich rozdziałach recenzji. W szczególności, podkreślić należy główne osiągnięcia, czyli opracowanie dwóch metod klasyfikacji obrazów hiperspektralnych. Metody te zostały gruntownie przetestowane, wykazując ich dużą skuteczność. Obydwie metody mogą być przedmiotem dalszych badań i mogą zostać znacznie rozszerzone.

5. Charakterystyka działalności naukowej, w tym publikacyjnej, Doktoranta

Oprócz przedstawionych w poprzednich punktach analiz dotyczących głównych metod zaprezentowanych w rozprawie, istotnym aspektem jest działalność naukowa oraz publikacyjna Doktoranta. Z nadesłanych informacji, jak również z analizy materiałów dostępnych w Internecie, można podsumować, że p. Michał Romaszewski jest współautorem 6 publikacji. Wg bazy Web of Science jego indeks $H=2$, co w przypadku Doktoranta jest wynikiem dobrym. W tym zestawie na szczególne wyróżnienie zasługuje publikacja w czasopiśmie ISPRS Journal of Photogrammetry and Remote Sensing, w którym p. Michał Romaszewski jest pierwszym autorem, a którego tzw. współczynnik Impact Factor wynosi $IF=5,994$, jak również IEEE Transactions on Geoscience and Remote Sensing $IF=4,662$, jak również Geoscience and Remote Sensing Letters o $IF=2,892$, Forensic Science International 1,974 oraz.

Wszystkie powyższe osiągnięcia świadczą o bardzo wysokim poziomie naukowym p. mgra inż. Michała Romaszewskiego, jak również o całym zespole z którym współpracuje. Świadczy to też o dużej aktywności oraz dojrzałości naukowej Doktoranta. Należy dodać, że tak wysokie współczynniki bibliometryczne nie należą do częstych nawet w przypadku habilitacji.

6. Podsumowanie

Podsumowując stwierdzam, że **postawione w rozprawie zagadnienia badawcze zostały prawidłowo rozwiązane**. Uzyskane rezultaty stanowią oryginalny własny wkład Autora rozprawy Pana mgra inżyniera Michała Romaszewskiego w rozwój dyscypliny naukowej Informatyka, a w szczególności dziedzin widzenia komputerowego oraz uczenia maszynowego. Pan M. Romaszewski wykazał się przy tym dogłębną znajomością metod i algorytmów przetwarzania obrazów, klasyfikacji danych, pokazał również doskonałe opanowanie warsztatu badawczego, zarówno od strony teoretycznej, jak i praktycznej. Wszystko to świadczy o dojrzałości naukowej Pana mgra inż. Michała Romaszewskiego.

Recenzowaną pracę oceniam jako **spełniającą z nadmiarem** wymagania stawiane rozprawom doktorskim i **zasługującą na wyróżnienie**. Wniosuję o jej przyjęcie oraz o dopuszczenie Pana magistra inżyniera Michała Romaszewskiego do publicznej obrony.