

Kraków, 18.04.2022

Prof. dr hab. inż. Bogusław Cyganek
Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
Wydział Informatyki, Elektroniki i Telekomunikacji
Instytut Elektroniki

Recenzja rozprawy doktorskiej
„Algorytmy dekompozycji tensorów
w przetwarzaniu danych masywnych”

Pana magistra inżyniera Krzysztofa Fonała

Wstęp

Recenzja dotyczy rozprawy doktorskiej Pana mgra inżyniera Krzysztofa Fonała zatytułowanej „*Algorytmy dekompozycji tensorów w przetwarzaniu danych masywnych*”. Praca powstała w roku 2022 na Wydziale Elektroniki, Fotoniki i Mikrosystemów Politechniki Wrocławskiej. Promotorem pracy jest Pan dr hab. inż. Rafał Zdunek, prof. uczelni PWr. Przygotowanie recenzji zostało wykonane na zlecenie Przewodniczącego Rady Dyscypliny Naukowej Informatyka Techniczna i Telekomunikacja, Pana prof. dr hab. inż. Michała Woźniaka. Praca została napisana w języku polskim. Recenzja została zorganizowana w postaci odpowiedzi na pytania dotyczące rozprawy doktorskiej Pana Krzysztofa Fonała.

1. Jakie zagadnienie naukowe jest rozpatrzone w pracy i czy zostało ono dostatecznie jasno sformułowane przez autora? Jaki charakter ma rozprawa?

Główne zagadnienie naukowe podjęte w pracy doktorskiej Pana magistra inżyniera Krzysztofa Fonała dotyczy *opracowania oraz weryfikacji naukowej nowych algorytmów dekompozycji tensorów w przetwarzaniu danych masywnych*.

Współczesna cywilizacja w coraz większym stopniu bazuje na tworzeniu, przesyłaniu, zapisywaniu oraz przetwarzaniu olbrzymich strumieni danych cyfrowych. Powstają one praktycznie w każdej dziedzinie nie tylko nauki i techniki, czy też przemysłu, ale i życia codziennego – olbrzymie repozytoria danych wizualnych są tego jednym z licznych przykładów, a rewolucja technologiczna związana ze sztuczną inteligencją i uczeniem maszynowym (ML/AI) zawdzięcza swój sukces właśnie łatwej dostępności danych masywnych, znanych również jako „*big data*”. Rewolucja ta wymaga jednak ciągłego opracowywania nowych metod przetwarzania olbrzymich strumieni wielomodalnych danych cyfrowych. W nurt ten wpisuje się praca Pana magistra inżyniera Krzysztofa Fonała dotycząca właśnie

WPLYNĘŁO

02-05-2022

1

RDN-IT/MI/2022

opracowaniu efektywnych metod przetwarzania danych masowych z wykorzystaniem różnorodnych algorytmów dekompozycji tensorowych.

Należy tutaj pokrótce wspomnieć, że dekompozycje macierzowe, jak również stosunkowo młodsze od nich dekompozycje tensorowe, umożliwiają przede wszystkim (i) analizę zawartości macierzy, czy też tensorów, jak również (ii) przeważnie stratną kompresję danych. Są to cechy od dawna używane w analizie, czy też statystyce matematycznej, ale również chętnie używane w analizie i do kompresji danych cyfrowych. Te ostatnie stanowią z kolei podstawowe metody współczesnej dziedziny ML/AI.

Uwzględniając powyższe, uważam że problem badawczy podjęty przez Doktoranta Pana magistra inżyniera Krzysztofa Fonała ma znaczenie zarówno w obszarze badań teoretycznych, jak i aplikacyjnych. Praca ma charakter teoretyczno-doświadczalny.

2. Czy w rozprawie przeprowadzono w sposób właściwy analizę źródeł, w tym literatury światowej, stanu wiedzy i zastosowań w przemyśle, świadczą o dostatecznej wiedzy autora? Czy wnioski z przeglądu źródeł sformułowano w sposób jasny i przekonujący?

Metody przetwarzania danych masowych z wykorzystaniem algorytmów dekompozycji tensorowych należą do jednych z najintensywniej rozwijanych kierunków badawczych, a zajmują się nimi naukowcy z wielu dziedzin, takich jak matematyka oraz fizyka, ale również chemia, informatyka czy też elektronika. Stąd też dorobek publikacyjny w tej dziedzinie jest olbrzymi, co wymaga od badaczy dogłębnej i ciągłej analizy powstających opracowań. Doktorant, p. Krzysztof Fonał, bardzo dobrze radzi sobie z tym zadaniem – w swojej bardzo obszernej rozprawie odwołuje się on aż do 173 pozycji literaturowych, z których w kilku przypadkach jest jednym z autorów. Świadczy to o bardzo głębokim zrozumieniu przez Doktoranta podjętych tematów, gdyż w wielu przypadkach proponuje on własne rozwiązania rozszerzające te znane z literatury.

3. Czy autor rozwiązał postawione zagadnienia, czy użył właściwej do tego metody i czy przyjęte założenia są uzasadnione?

Główne zagadnienie naukowe polegające na opracowaniu efektywnych algorytmów dekompozycji tensorowych do przetwarzania danych masowych zostały prawidłowo określone i rozwiązane. Autor zaproponował wiele własnych oryginalnych metod i pomysłów oraz usprawnień w stosunku do metod i algorytmów już istniejących. Podsumowując, są to metody dekompozycji tensorowych obejmujących ogólnie pojęte dane cyfrowe, jak i dane o wartościach nieujemnych. Ta ostatnia szczególna grupa znajduje zainteresowanie m.in. ze względu na nieujemność i addytywny charakter danych powstających w niektórych obszarach nauki i techniki, takich jak np. biologia, psychologia, czy też przetwarzanie obrazów, itd., jak również ze względu na interpretowalność danych tego typu.

Opracowane przez Doktoranta metody zostały następnie zweryfikowane eksperymentalnie z wykorzystaniem dostępnych źródeł danych testowych, a wyniki tych eksperymentów zostały dokładnie opisane oraz omówione w rozprawie. Co więcej, opracowane metody zostały opublikowane w znanych materiałach konferencyjnych oraz periodykach naukowych, o czym będzie jeszcze mowa w kolejnym punkcie tej recenzji.

Autor, Pan inżynier magister Krzysztof Fonał, posiada dogłębną wiedzę, dotyczącą przede wszystkim metod tensorowych, ale również programowania systemów rozproszonych, algorytmów równoległych, jak również przetwarzania danych masywnych. Użyte przez niego metody i przyjęte założenia, które zostały przedstawione w rozprawie uważam za jak najbardziej poprawne i uzasadnione.

Przedstawione w rozprawie Pana magistra inżyniera Krzysztofa Fonała zaawansowane metody i algorytmy dekompozycji tensorowych do przetwarzania danych masywnych świadczą o jego głębokiej wiedzy w dyscyplinie Informatyka Techniczna i Telekomunikacja. Tematyka ta jest interdyscyplinarna i obejmuje takie dziedziny jak m.in. matematyka, fizyka oraz informatyka. Opracowane przez niego metody są na wysokim światowym poziomie, a uzyskane wyniki eksperymentalne plasują je wśród ścisłej czołówki rozwiązań światowych, tzw. *state-of-the-art*.

4. Na czym polega oryginalność rozprawy, co stanowi samodzielny i oryginalny dorobek autora, jaka jest pozycja rozprawy w stosunku do stanu wiedzy czy poziomu techniki reprezentowanych przez literaturę światową?

Jak już wspomniano, badania naukowe oraz osiągnięcia Pana magistra inżyniera Krzysztofa Fonała dotyczą opracowania oraz weryfikacji naukowej nowych metod dekompozycji tensorów w przetwarzaniu danych masywnych. Rozprawa doktorska Pana magistra inżyniera Krzysztofa Fonała jest niezwykle obszerna – liczy 170 stron – ale przede wszystkim zawiera precyzyjny opis nowych i istotnych metod i algorytmów opracowanych przez Autora od przetwarzania zbiorów i strumieni danych wielomodalnych. Główne osiągnięcia Doktoranta Pana Krzysztofa Fonała w tej dziedzinie i zaprezentowane w rozprawie doktorskiej można podsumować następująco.

1. Opracowanie oryginalnych rozwiązań do rozpraszania obliczeń w modelach dekompozycji danych z ograniczeniami nieujemności. Autor zaproponował tu dwie strategie obliczeniowe:

- algebraiczną oraz
- geometryczną,

służące rozszerzeniu możliwości podstawowych modeli dekompozycji tensorów. Zaproponowane przez Doktoranta algorytmy nadają się do obliczeń na dużych danych, ponieważ dają możliwość rozpraszania danych na wiele węzłów obliczeniowych i są przy tym skalowalne, a ich efektywność przewyższa niektóre rozwiązania konkurencyjne. Co więcej, zostało wykazane że algorytmy oparte na podejściu geometrycznym są najszybsze.

2. Opracowanie metod zmniejszania skali problemu dekompozycji tensorów w postaci
 - algorytmu rekurencyjnej aktualizacji estymowanych czynników dekompozycji oraz
 - algorytmu randomizującego dane.

W podejściu pierwszym dekompozycja kolejnych tensorów rdzeniowych przebiega w sposób rekurencyjny, tzn. każdy kolejny tensor rdzeniowy, poza pierwszym, obliczany jest na podstawie tensora będącego wynikiem poprzedniego kroku, itd. Doktorant wykazał przy tym, że podejście to znacząco przyspieszając dekompozycję i jednocześnie nie powodując utraty jakości estymowanych czynników i tensorów rdzeniowych.

W podejściu drugim tensor wejściowy mnożony jest w odpowiednim modzie przez losową macierz, co prowadzi do rzutowania jego wartości na losową podprzestrzeń o znacznie zmniejszonej wymiarowości w stosunku do przestrzeni oryginalnej. Jest to znane podejście,

jednakże rozszerzone przez Doktoranta m.in. dzięki pomysłowi zastosowania tego podejścia do modelu sieci tensorowej typu *tensor train* (TT) oraz zaproponowanemu rozproszeniu żmudnych obliczeń mnożenia macierzy i tensora wejściowego.

3. Opracowanie metod dekompozycji danych strumieniowych lub takich, które można przetwarzać sekwencyjnie wzdłuż jednego z modów. Oryginalne podejście Doktoranta polega tu m.in. zaproponowaniu nieujemnej dekompozycji Tuckera przeznaczonej do przetwarzania danych strumieniowych oraz estymacji czynników zmieniających się w czasie. Metoda ta może znaleźć liczne zastosowania, m.in. w problemach wymagających interpretowalności wpływu czynników, jak również do kompresji danych strumieniowych.

Należy tutaj podkreślić, że w każdym przypadku wyżej wymienionej metody dekompozycji tensorowej szczególną uwagę poświęcono przetwarzaniu tensorów o wartościach nieujemnych oraz dekompozycjom tego typu tensorów do czynników o wartościach nieujemnych, ze szczególnym uwzględnieniem przetwarzania w tzw. czasie rzeczywistym.

Powyższe zagadnienia badawcze są bardzo obszerne. Tym niemniej, Autor dodatkowo przedstawił

- algorytmy łączenia danych tensorowych poprzez wyszczególnienie wspólnego modu danych oraz
- algorytm uzupełniania danych brakujących w tensorach, ze szczególnym uwzględnieniem tzw. problemu *inpaintingu*, czyli uzupełniania wartości brakujących pikseli w obrazach cyfrowych.

Praca ta jest jednak niezwykle precyzyjna i dobrze napisana. Wyniki badań zostały częściowo opublikowane w materiałach znanych naukowych konferencji międzynarodowych, jak również w czasopismach naukowych z listy JCR.

Wszystkie wyżej wymienione osiągnięcia świadczą o dużej dojrzałości naukowej Pana magistra inżyniera Krzysztofa Fonała, który swobodnie porusza się zarówno w dziedzinie przetwarzania danych masywnych z wykorzystaniem metod dekompozycji tensorów, jak również w dziedzinie programowania równoległych i rozproszonych systemów komputerowych.

4. Jaka jest umiejętność poprawnego i przekonywującego przedstawienia uzyskanych wyników oraz jaki jest dorobek publikacyjny Doktoranta

Rozprawa doktorska Pana magistra inżyniera Krzysztofa Fonała liczy 170 stron. Napisana jest w języku polskim. Praca podzielona jest na 6 rozdziałów głównych i dodatki. Bibliografia liczy 173 pozycje literaturowe.

W bibliografii znajduje się 15 prac, w których współautorem jest Doktorant, a w 5 z nich jest on pierwszym z autorów – co więcej są to kluczowe publikacje dotyczące metod dekompozycji tensorów zaprezentowane w rozprawie doktorskiej p. Krzysztofa Fonała. Zbiór tych prac jest następujący:

1. K. Fonał, R. Zdunek, *Fast recursive nonnegative standard and hierarchical Tucker decomposition*, IEEE Signal Processing Letters 26, No. 9, 2019 (IF= 3.109).
2. K. Fonał and R. Zdunek, *Fast hierarchical Tucker decomposition with single-mode preservation and tensor subspace analysis for feature extraction from augmented multimodal data*, Neurocomputing 445, 2021 (IF= 5.719).

Kolejne publikacje z tej serii zostały opublikowane na istotnych konferencjach, są to:

3. K. Fonał, R. Zdunek, and A. Wolczowski, *Feature-fusion HALS-based algorithm for linked CP decomposition model in application to joint EMG/MMG signal classification*, Proc. International Conference on Pattern Recognition (ICPR 2018), Beijing, China, August 20-24, 2018.
4. K. Fonał and R. Zdunek, *Distributed nonnegative matrix factorization with HALS algorithm on Apache Spark*, Proc. 17th International Conference on Artificial Intelligence and Soft Computing, ICAISC 2018, Zakopane, Poland, June 3-7, 2018, Part II, 2018.
5. K. Fonał and R. Zdunek, *Distributed and randomized tensor train decomposition for feature extraction*, International Joint Conference on Neural Networks, IJCNN 2019 Budapest, Hungary, July 14-19, 2019, 2019.

W końcu na podkreślenie zasługuje też poniższa praca:

6. R. Zdunek and K. Fonał, *Incremental nonnegative Tucker decomposition with block-coordinate descent and recursive approaches*, Symmetry 14, no. 1, 2022. (IF=2.713)

napisana wraz z Promotorem, w której p. Krzysztof Fonał jest drugim z autorów.

Wszystkie te publikacje świadczą o dużej dojrzałości naukowej Doktoranta oraz o jego rozpoznawalności w środowisku naukowym.

5. Jakie są słabe strony rozprawy i jej główne wady?

Rozprawa doktorska Pana Krzysztofa Fonała zawiera opis głównych metod opracowanych przez Doktoranta, o których była już mowa w poprzednich punktach. Mimo znacznej liczby opisanych metod i wynikającej z tego objętości pracy, nie znalazłem żadnych poważniejszych błędów, czy też uchybień merytorycznych. Poniżej przedstawiam jednak uwagi, które mają charakter bądź to dotyczący pewnych kwestii do dalszej dyskusji naukowej, bądź też natury edycyjnej.

1. Pewnym niedociągnięciem jest zupełny brak porównania zaproponowanych metod klasyfikacji obrazów cyfrowych z metodami opartymi na głębokich sieciach neuronowych będących *de facto* standardem współczesnych metod klasyfikacji obrazów. Co prawda Autor wspomina o tym fakcie już na samym końcu rozprawy w podsumowaniach, jako przyszłe kierunki badań (rozdz. 6.6). Tymczasem jest to błąd – to nie jest przyszły kierunek badań, tylko już dawno zrobiony i zweryfikowany kierunek dotyczący rozpoznawania np. twarzy za pomocą różnorodnych głębokich sieci spłotowych (CNN), w zasadzie jeden z najbardziej „klasycznych” kierunków w ogóle w dziedzinie widzenia komputerowego. Dla przykładu, dla dobrze znanego zbioru testowego ORL, również używanego przez Doktoranta do weryfikacji metod tensorowych, wystarczy proste zapytanie internetowe i od razu znajdujemy prace, które opisują wyniki działania CNN właśnie na tym zbiorze. Dla przykładu, są to poniższe pozycje literaturowe:

L. Patil, V.D. Mytri: *Face Recognition with CNN and Inception Deep Learning Models*, International Journal of Recent Technology and Engineering (IJRTE) ISSN: 2277-3878, Vol. 8 Issue 3, 2019.

S. Almabdy, L. Elrefaei: *Deep Convolutional Neural Network-Based Approaches for Face Recognition*, Applied Sciences, 2019.

Zarówno te prace, jak również referencje w tych publikacjach, dokładnie opisują wyniki wspomnianych badań. Brak uwzględnienia najnowszych i bardzo skutecznych metod neuronowych oraz zamykanie się wyłącznie w domenę badań Autora nie jest podejściem prawidłowym, gdyż

nie przedstawia całego stanu rzeczy w szerzej rozumianej dziedzinie naukowej. To, że wyniki klasyfikacji z użyciem metod tensorowych nie przewyższają skutecznością odpowiedzi metod używających głębokie sieci neuronowe jest rzeczą znaną i dobrze opisaną w literaturze. Nie zmniejsza to wieloletniego wkładu Autora w rozwój tego typu metod, ani też samych metod, tylko wymaga określenia warunków ich stosowalności, np. przy innych warunkach badawczych (np. zbyt małe zbiory danych), czy też w innych zastosowaniach (np. do kompresji sygnałów wielowymiarowych, czy też wyjaśniania zjawisk za pomocą addytywnych właściwości nieujemnych czynników). Tym niemniej, właściwe podkreślenie użyteczności opracowanych metod z uwzględnieniem stanu *całej dziedziny*, tu klasyfikacji obrazów z użyciem nowoczesnych metod ML/AI, jest wręcz obowiązkiem badacza i na pewno spodziewałbym się takiej pogłębionej analizy i dyskusji w tak rozbudowanej rozprawie doktorskiej (nawet kosztem skrócenia opisu samych metod, który to opis znajduje się w innych publikacjach Doktoranta).

2. Również zaproponowany kierunek badań dotyczący kompresji wag głębokich sieci neuronowych jest już tematem bardzo dobrze zbadanym i opisanym – tu też spodziewałbym się głębszej analizy Autora, plasującej jego rozwiązania w tej dziedzinie (np. Capra M. et al.: *Hardware and Software Optimizations for Accelerating Deep Neural Networks: Survey of Current Trends, Challenges, and the Road Ahead*, IEEE Access, 2020).
3. Wiele opracowanych metod zakłada podanie rzędu dekompozycji jako parametru wejściowego. W większości przypadków Autor dokonuje tego wyboru, jak pisze, w sposób eksperymentalny. Temat ten jest jednak zagadnieniem poważniejszym, gdyż nie zawsze takie założenie jest możliwe, czy też optymalne. W tak rozbudowanej pracy nt. dekompozycji tensorowych warto by się pokusić po pierwsze o krótki chociaż opis z jakiego rodzajami (definicji) rzędu/ów tensorów mamy do czynienia (w przypadku tensorów sytuacja jest bardziej skomplikowana niż w przypadku macierzy). W wielu zagadnieniach praktycznych użytkownik nie ma wiedzy na temat potencjalnego rzędu/ów tensora, który chce dekomponować. W przypadku niewielkich tensorów można pokusić się o metodę prób i błędów, jednakże w wielu zastosowaniach lepszym i bardziej miarodajnym podejściem jest określenie maksymalnego dopuszczalnego średniego błędu dopasowania dekompozycji tensorowej. Istnieją metody dekompozycji tensorowych, które umożliwiają tego typu podejście, np. ST-HOSVD (N. Vannieuwenhoven et al.: *A New Truncation Strategy for the Higher-Order Singular Value Decomposition*, SIAM Journal on Scientific Computing, Vol. 34, Iss. 2, 2012). Można więc wyobrazić sobie zrandomizowany system, który za pomocą tej metody określa wstępne rzędy tensora, które potem są używane w jednym z algorytmów zaproponowanych przez Doktoranta. Tematyka ta wymaga pogłębionej analizy.
4. W większości omawianych metod dekompozycji tensorów brakuje mi pogłębionej dyskusji na temat problemu zbieżności tych metod. Dla przykładu, w przypadku metod wywodzących się z metody optymalizacji typu ALS – np. HALS – byłoby dobrze zawrzeć jakieś podstawy samej metody ALS, czy np. osiągnięte jest to optimum globalne, czy tylko lokalne, jak szybko, itd.
5. Autor opisał hierarchiczną metodę dekompozycji tensorów, polegającą na rekursywnym obliczaniu tensora rdzeniowego. Tym niemniej, w literaturze istnieją inne podejścia do hierarchicznej dekompozycji tensorów, w których dekomponowany jest tensor błędu, tj. różnicy między tensorem oryginalnym oraz tensorem odzyskanym z rozkładu, po czym procedura może być zastosowana ponownie, itd. Czy Doktorant zna te metody i jaka jest ich relacja w stosunku do rozwiązań zaproponowanych w rozprawie? Przykładowe prace w tej dziedzinie:
Q. Wu et al.: *Hierarchical Tensor Approximation of Multi-Dimensional Visual Data*, IEEE Transactions on Visualization and Computer Graphics, Vol.14, No.1, 2008.
A. Ozdemir et al.: *Multiscale analysis for higher-order tensors*. SPIE Optical Engineering + Applications, USA, 2019.

6. W tematyce łączenia cech, opisanych za pomocą metod tensorowych też istnieje wiele ciekawych opracowań i brakuje mi odwołania Autora do tych, jak również innych metod znanych z literatury. Przykładowa publikacja:

L. Kuang, *et al.*: *A Tensor-Based Approach for Big Data Representation and Dimensionality Reduction*. IEEE Transactions on Emerging Topics in Computing, 2014.

Drobniejsze pytania i uwagi są następujące:

7. Wzór (2.13) posiada niewyjaśnione indeksy.
8. W przypadku większości algorytmów nie jest jasno określony oryginalny i osobisty wkład Doktoranta w wymyślenie/opracowanie tego algorytmu jako całości, bądź też jego istotnych kroków (np. Algorytm 3 itd.).
9. Proces *MapReduce* (opis na str. 32 i kolejnych) – obliczenia prowadzimy na/w blokach pamięciowych, ale może warto by je wcześniej transponować żeby usprawnić operację pamięci podręcznej procesora (ang. *cache memory*)?
10. Problem implementacji, szczególnie w kontekście podejścia algebraicznego (rozdz. 2.2), ale i kolejnych zaprezentowanych w rozprawie – czy nie jesteśmy zbyt ograniczeni już samą platformą programową *Matlab*? A czemu do zrównoleglenia obliczeń i obliczeń rozproszonych nie użyć innych pakietów, takich jak *MPI* i/lub *OpenMP/OpenACC*?
11. Niejasne stwierdzenie na str. 38 – „warto zauważyć fakt, że superpozycja niepustych otoczek wypukłych tworzy również otoczkę wypukłą”. Czy istnieje dowód tej właściwości?
12. Algorytm 6 DG-NTF (str. 44) – skąd znamy wartość parametru wejściowego „ n ”?
13. Rys 27 – niejasny opis osi poziomej wykresu (co to za litery „B”, napis „Benchmark B”?). Czemu tak wygląda wykres iteracji? Czy jest to wykres funkcji?
14. Niejasne stwierdzenie (str. 66) „Jednak uproszczenie to jest zasadne dla specyfiki badań niniejszej pracy, gdzie najważniejszym czynnikiem jest pożądana kompresja, a precyzja jest wynikiem kompromisu” – oprócz kompresji Autor zajmuje się też klasyfikacją, to wymaga wyjaśnienia o jaki kompromis tu chodzi?
15. Algorytm 9 – co to jest „zbiór poświadanych rzędów macierzy oraz tensorów rdzeniowych” i jak te parametry dobierać? Jak kosztowna obliczeniowo jest funkcja *Reshape* w tym algorytmie?
16. Algorytm 12 – złożoność zależy od parametru wejściowego L określającego głębokość drzewa binarnego, ale jak wybierać L ?
17. Wyniki w tabeli 3.3 – nie wiadomo dla jakiego parametru L i w stosunku do jakiej wartości została obliczona kompresja.
18. Istnieje wiele prac dotyczących badań nad strumieniami danych tensorowych, w których zastosowano metody randomizacji, czy też zmiany skali wraz z oszacowaniem tzw. dryftu strumienia – w tej tematyce do porównania mogę polecić pracę:

B. Cyganek: *Thumbnail Tensor – A Method for Multidimensional Data Streams Clustering with an Efficient Tensor Subspace Model in the Scale-Space*, Sensors 2019.

Tematyka reprezentacji strumieni danych tensorowych jako ciągu tensorów vs. tensor z dodatkowym modem/modami (wzór 4.1 i kolejne) warto by rozwinąć i głębiej przedyskutować.

19. Badania zaprezentowane w rozdz. 4.4 dotyczą wyłącznie danych syntetycznych – szkoda że tylko, bo jest kilka źródeł danych strumieniowych, takich jak ruch internetowy, albo choćby sekwencje video, które są bardziej miarodajne w kontekście rzeczywistych aplikacji.
20. Str. 112 porównanie testów A i B – warto by się zastanowić dlaczego algorytmy BK-NTD i RI-NTD mają znacząco wyższy współczynnik SIR niż HALS-NTD oraz znacząco niższy poziom błędu rezydualnego; czy jest to tylko przypadek dla tych danych, czy też możemy się dopatrzeć jakiś cech charakterystycznych różniących te algorytmy, a prowadzących do mniejszego błędu dekompozycji; być może stabilność obliczeniowa, etc.?

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

6. Jaka jest przydatność rozprawy dla nauk technicznych?

Metody oraz algorytmy przetwarzaniu danych masywnych za pomocą dekompozycji tensorów, opracowane oraz opisane w rozprawie doktorskiej Pana magistra inżyniera Krzysztofa Fonała, mają istotne znaczenie dla nauk technicznych, zarówno w aspekcie osiągnięć teoretycznych, jak i możliwości aplikacyjnych. Wartość ta jest pochodną głównych i samodzielnych osiągnięć Autora, o których była mowa w poprzednich rozdziałach tej recenzji. Metody te z powodzeniem mogą być porównywane, a często przewyższają światowe rozwiązania *state-of-the-art*. Co więcej, opracowane metody mogą znaleźć liczne zastosowania przede wszystkim do kompresji, jak również analizy, danych wielowymiarowych.

Wnioski końcowe

Podsumowując stwierdzam, że postawione w rozprawie zadania badawcze zostały rozwiązane. Uzyskane rezultaty stanowią oryginalny własny wkład Autora rozprawy Pana mgra inżyniera Krzysztofa Fonała w rozwój dyscypliny naukowej Informatyka Techniczna i Telekomunikacja. Uzyskane wyniki świadczą, że Pan Krzysztof Fonał wykazał się dogłębną znajomością najnowszych metod i algorytmów przetwarzania danych masywnych za pomocą dekompozycji tensorów, jak również dobrym opanowaniem warsztatu badawczego, a w rezultacie również wysoką dojrzałością naukową.

Recenzowaną pracę oceniam jako **spełniającą ze znacznym nadmiarem** wymagania stawiane rozprawom doktorskim. **Wnioskuje o jej przyjęcie oraz o dopuszczenie Pana magistra inżyniera Krzysztofa Fonała do publicznej obrony.**

Ponadto, uwzględniając liczbę opracowanych metod, a przede wszystkim ich wartość naukową oraz oryginalność, jak również dorobek publikacyjny Doktoranta Pana magistra inżyniera Krzysztofa Fonała, **stawiam wniosek o wyróżnienie rozprawy.**

Dr. G. G. G.