

Anna PIĘTA, Justyna BAŁA

Akademia Górniczo - Hutnicza, Kraków

## Metody dekompozycji zadania odwrotnego na przykładzie wybranych zagadnień geofizyki

### Słowa kluczowe

inwersja danych geofizycznych, obliczenia równoległe, inwersja połączona, lokalizacja wstrząsów

### Streszczenie

W artykule zaprezentowano i porównano dwie metody dekompozycji zadania odwrotnego. Obliczenia przeprowadzono na przykładzie wybranych zagadnień z dziedziny geofizyki: lokalizacji współrzędnych hipocentrum wstrząsu górniczego oraz inwersji połączonej danych geoelektrycznych. Do rozwiązania zadania odwrotnego zastosowano algorytmy optymalizacji globalnej z grupy metod przeszukiwania siatki. W przedstawionych przykładach w przypadku obliczeń równoległych zastosowano dwie strategie podziału zadania sekwencyjnego: podział grubo i drobnoziarnisty. Analizowano czas obliczeń, przyspieszenie i efektywność zaproponowanych schematów dekompozycji.

### 1. Wstęp

Geofizyka jest jedną z dyscyplin nauk o Ziemi, w której zachodzi potrzeba rozwiązywania skomplikowanych i czasochłonnych problemów obliczeniowych. Jednym ze sposobów na uzyskanie dobrej jakości rozwiązania (np. rozwiązania o zadawalającej dokładności) tego typu zagadnień w akceptowalnym czasie jest wykorzystanie obliczeń równoległych. Współbieżne algorytmy obliczeniowe mogą być stosowane zarówno na etapie przetwarzania jak i modelowania i interpretacji danych geofizycznych. Równoległa realizacja zadań obliczeniowych zwiększa prędkość obliczeń, wpływa na ich dokładność i stwarza możliwość realizacji zadań zbyt dużych dla maszyn sekwencyjnych. Wśród prac wykorzystujących równoległe algorytmy w zagadnieniach geofizycznych można wymienić między innymi prace związane z modelowaniami i inwersją danych geoelektrycznych [10], [9], [4], modelowaniami zjawisk konwekcyjnych zachodzących w płaszczu Ziemi [3], modelowaniami i inwersją sejsmicznego pola falowego [5], [11], [15].

Efektywne wykorzystanie równoległego środowiska obliczeniowego uwarunkowane jest: doбором odpowiedniego modelu programowania równoległego, dostosowaniem architektury do konkretnego problemu obliczeniowego, wyborem właściwych narzędzi programowych oraz efektywną implementacją algorytmu. Szczególnie istotna jest odpowiednia dekompozycja zadania obliczeniowego. Polega ona na wydzieleniu tych części algorytmu, które mogą być wykonywane współbieżnie i na podziale dziedziny danych na niezależne od siebie podzbiory.

Podział zadania obliczeniowego może odbywać się poprzez dekompozycję trywialną, funkcjonalną i dekompozycję danych.

Dekompozycję trywialną stosuje się w przypadku, gdy wynik obliczeń żadnego z pomniejszych elementów zadania w żaden sposób nie zależy od innego elementu. Ze względu na brak zależności pomiędzy poszczególnymi porcjami danych, nie istnieje konieczność komunikacji między procesorami. Dekompozycję trywialną można zastosować do wszystkich problemów obliczeniowych wykorzystujących metody Monte Carlo.

Sposób funkcjonalnego podziału zadania polega na zaprojektowaniu lub znalezieniu takich części algorytmu, które mogą być wykonywane oddzielnie. Dekompozycja funkcjonalna jest stosowana przede wszystkim w równoległych implementacjach obliczeń związanych z prognozowaniem pogody lub zmian klimatycznych [2], ze względu na konieczność uwzględnienia wpływu wielu zjawisk i ich wzajemnego oddziaływania.

Dekompozycję danych wykorzystuje się w zadaniach operujących na dużych zestawach danych, gdy o czasie obliczeń w znacznym stopniu decyduje częste odwoływanie się do tego zbioru. Idea tego podejścia polega na takim podziale bazy danych, aby poszczególne procesory mogły niezależnie operować na przypisanych im podzbiorach danych. W odróżnieniu od dekompozycji trywialnej, istnieje tu potrzeba wymiany informacji o aktualnym stanie zbioru danych pomiędzy jednostkami obliczeniowymi. Dekompozycja danych jest naturalnym podejściem przy rozwiązywaniu problemów obliczeniowych opartych na rozwiązywaniu równań różniczkowych zdyskretyzowanych na regularnych bądź nieregularnych siatkach.

W artykule zaprezentowano i porównano dwie metody dekompozycji zadania odwrotnego: dekompozycję grubo- i drobnoziarnistą. Obie metody należą do grupy trywialnego podziału zadania obliczeniowego. Analizę wybranych metod dekompozycji zadania odwrotnego przedstawiono na przykładzie dwóch zagadnień z dziedziny geofizyki: lokalizacji współrzędnych hipocentrum wstrząsu górniczego [12] oraz inwersji połączonej danych geoelektrycznych [1].

## 2. Zagadnienia odwrotne w geofizyce

Zadanie odwrotne w geofizyce sprowadza się do obliczenia parametrów modelu na podstawie danych pomiarowych. Model matematyczny opisujący związek pomiędzy parametrami modelu  $\vec{m}$  oraz danymi pomiarowymi  $\vec{d}$  można przedstawić za pomocą wzoru.

$$\vec{d} = G(\vec{m})^T \quad (2.1)$$

gdzie:

$\vec{d} = (d_1 \dots d_l)^T$  jest wektorem danych pomiarowych o wymiarze  $l$ ,

$\vec{m} = (m_1 \dots m_n)^T$  jest wektorem parametrów modelu o wymiarze  $n$ ,

$G$  jest operatorem opisującym relację pomiędzy parametrami modelu a danymi pomiarowymi.

Rozwiązanie zagadnienia odwrotnego (obliczenie parametrów modelu) uzyskuje się najczęściej na drodze analitycznej oraz przez zastosowanie procedury optymalizacyjnej [6]. Rozwiązanie zadania odwrotnego na drodze analitycznej możliwe jest tylko dla wąskiej grupy zagadnień [17], dlatego często do ich rozwiązania wykorzystane są procedury optymalizacyjne. Większość problemów inwersyjnych można sprowadzić do odpowiadającego im problemu

optymalizacyjnego, który polega na poszukiwaniu takiej konfiguracji parametrów  $\vec{m}^*$  modelu, dla której obliczone dane pomiarowe będą najbardziej zbliżone do danych uzyskanych w wyniku pomiaru:

$$\|\vec{d} - G(\vec{m}^*)\| = \min \quad (2.2)$$

gdzie:

$\min$  oznacza wartość minimalną,


$\|\cdot\|$  oznacza normę wektora np. normę euklidesową,

$\vec{d}, G(\vec{m}^*)$  są odpowiednio rzeczywistymi oraz wymodelowanymi danymi pomiarowymi.

Poszukiwanie najlepszej wartości parametrów modelu  $\vec{m}^*$  sprowadza się do znalezienia minimum funkcji celu  $F(\vec{m})$  danej wzorem (2.3)

$$\|\vec{d} - G(\vec{m}^*)\| \leq F(\vec{m}) \quad (2.3)$$

Do wyznaczenia minimum funkcji  $F(\vec{m})$  (2.3) stosuje się tzw. metod minimalizacji lokalnej ([14], [19]). Funkcja celu  $F(\vec{m})$  może posiadać wiele minimów – tzw. minimów lokalnych, odpowiadających różnym konkurencyjnym rozwiązaniom, których położenie jest zależne od punktu startowego procedury minimalizacyjnej. (Rys. 1).



**Rys.1.** Minima funkcji jednej zmiennej  
**Fig. 1.** Minima of functions of one variable

Zastosowanie klasycznych metod optymalizacji, np. metod gradientowych może prowadzić do błędnego rezultatu optymalizacji, polegającego na odnalezieniu przez algorytm optymalizacyjny minimum lokalnego zamiast minimum globalnego. Rozwiązaniem tego problemu może być zastosowanie algorytmów optymalizacji globalnej, które co prawda nie gwarantują uzyskania rozwiązania optymalnego, ale w z znacznym stopniu zmniejszają prawdopodobieństwo popełnienia błędu ([7], [18]). W metodach optymalizacji globalnej wartości funkcji celu liczone są dla pewnego zestawu stochastycznie wybranych punktów. Sposób doboru zestawu punktów startowych jest podstawową cechą różniącą algorytmy optymalizacji globalnej. Pośród najczęściej stosowanych algorytmów optymalizacji globalnej, wyróżnić można metody kombinacyjne, siatki, ortogonalnego spadku, metody Monte Carlo,

czy też metody stosujące modele rozmyte, sieci neutronowe, metody sztucznej inteligencji, algorytmy ewolucyjne [8].

W odniesieniu do przedstawionych w niniejszym artykule zagadnień odwrotnych zastosowano dwa warianty metody przeszukiwania siatki (ang. *Grid Search*): metodę kombinacyjną – dla problemu lokalizacji hipocentrum wstrząsu oraz metodę siatki [8] przy inwersji połączonej danych geoelektrycznych.

W metodzie kombinacyjnej obliczenia prowadzone były w ten sposób, że wartość funkcji celu obliczana była dla wszystkich możliwych kombinacji parametrów stanowiących przestrzeń rozwiązań. Zastosowanie tej metody jest ograniczone tylko do specyficznych rozwiązań, ze względu na niezmierną czasochłonność obliczeń, niemniej jednak gwarantuje odnalezienia minimum globalnego funkcji celu.

Metoda siatki, zastosowana w inwersji połączonej, zakłada systematyczne przeszukiwanie rzadszej siatki obliczeniowej polegające na obliczeniach metody lokalnej „startującej” we wszystkich punktach rzadszej siatki obliczeniowej. Algorytm ten, również kosztowny obliczeniowo jest często wykorzystany w analizie efektywności stosowanych procedur optymalizacji lokalnej oraz jako narzędzie do analizy zagadnienia niejednoznaczności uzyskanych rezultatów.

### 2.1. Zagadnienie lokalizacji współrzędnych hipocentrum wstrząsu

Lokalizację współrzędnych hipocentrum wstrząsu przeprowadzono za pomocą metody czasów pierwszych wstąpień fali P (bardziej szczegółowego opis algorytmu znajduje się w [12]). Funkcję celu  $F(x,y,z;t)$ , stanowiącą miarę dopasowania między obliczanymi współrzędnymi hipocentrum a rzeczywistymi współrzędnymi źródła emisji fali sejsmicznej skonstruowano zakładając, że emisja sejsmiczna nastąpiła w chwili  $t$ , a jej źródło znajduje się w punkcie o współrzędnych  $(x,y,z)$ . Dla ośrodka jednorodnego i izotropowego ma ona postać: (2.4).

$$F(x, y, z; t) = \sum_{i=1}^n \left[ t_i - t - \frac{\sqrt{(x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2}}{v} \right]^2 \quad (2.4)$$

gdzie:

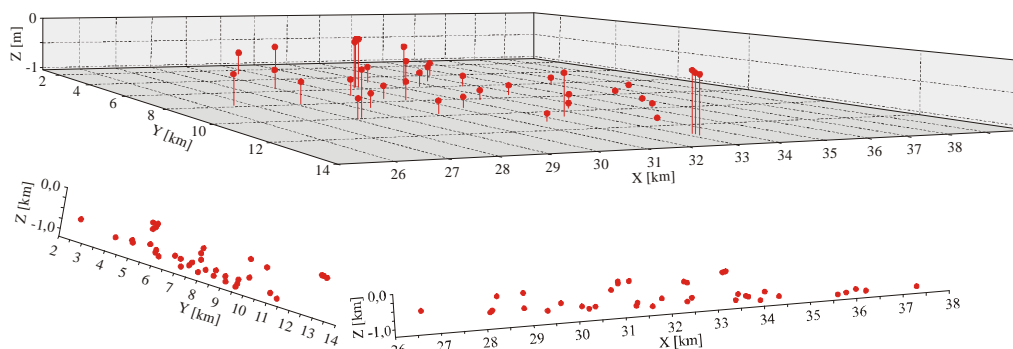
$t_i$  - jest zarejestrowanym przez  $i$ -ty geofon czasem wejścia fali P.

$(x,y,z)$  - są współrzędnymi hipocentrum (źródła wstrząsu);

$(x_i,y_i,z_i)$  - współrzędnymi  $i$ -tego geofonu;

$v$  – jest prędkością fali P w górotworze.

Obliczenia przeprowadzono dla sieci geofonów znajdującej się w Kopalni Miedzi „Rudna”. Rozmieszczenie sieci seismologicznej przedstawia rys. 2.



**Rys. 2.** Położenie 43 geofonów kopalni Rudna. Przedstawiono rozmieszczenie przestrzenne czujników oraz ich rzuty na płaszczyzny XZ i YZ [13]

**Fig. 2.** Location of 43 geophones of Rudna mine. The spatial distribution of sensors and their projections onto the plane XZ and YZ are presented [13]

Przyjęty w tym przypadku kombinacyjny algorytm optymalizacji globalnej zakładał, że obliczenia będą wykonane dla wszystkich możliwych kombinacji parametrów stanowiących przestrzeń rozwiązań. Współrzędne hipocentrum losowano w obszarze kostkowym zadanym w górniczym obszarze współrzędnych:

$$29\,000\text{ m} < x < 35\,000\text{ m},$$

$$500\text{ m} < y < 10\,000\text{ m},$$

$$-1\,000\text{ m} < z < -600\text{ m},$$

Zastosowanie metody kombinacyjnej, chociaż niezmiernie czasochłonne obliczeniowo, gwarantowało jednoznaczne wyznaczenie położenia hipocentrum wstrząsu. Analiza wszystkich możliwych wartości, jakie przyjmuje funkcja celu (2.4) pozwalała na wskazanie zestawu parametrów  $(x, y, z, t)$ , dla których ta funkcja przyjmowała wartość najmniejszą. Ten punkt z całą pewnością wskazywał na położenie źródła wstrząsu.

## 2.2. Zagadnienie inwersji połączonej danych geoelektrycznych

W odniesieniu do zagadnienia inwersji połączonej danych geoelektrycznych przy optymalizacji globalnej zastosowano tzw. metodę siatki. Metoda ta zakłada systematyczne „startowanie” metody lokalnej we wszystkich punktach rzadkiej siatki obliczeniowej.

Do inwersji połączonej sondowań elektrooporowych i dipolowych sondowań indukcyjnych zastosowano funkcję celu opisaną wzorem:

$$F = \frac{1}{2N} \left[ \sum_{i=1}^N \left( \ln(\rho_i^o) - \ln(\rho_i^c) \right)_{PSE}^2 + \sum_{i=1}^N \left( \ln(\rho_i^o) - \ln(\rho_i^c) \right)_{EMHD}^2 \right] \quad (2.5)$$

gdzie:

$\rho_i^o$  i  $\rho_i^c$  – obserwowane i obliczone wartości oporności pozornej dla sondowania elektrooporowego (PSE) i dipolowych sondowań indukcyjnych układem HD (EMHD),  
 $N$  – jest ilością pomiarów.


Optymalizacja globalna metodą siatki, zastosowana w tym przypadku w celu analizy zagadnienia niejednoznaczności uzyskanych rezultatów wymagała uruchomienia procedury

minimalizacyjnej dla każdego punktu startowego z określonej przestrzeni parametrów. Współrzędne węzłów siatki, z których „startowała” metoda lokalna zostały zestawione w poniższej tabeli.

**Tabela 1.** Przedziały i krok wyboru poszczególnych parametrów warstw dla kolejnych modeli startowych  
**Table 1.** Intervals and the step of choice of the parameters for starting models

Warstwy	$\rho_{\min}$ ( $\Omega\text{m}$ )	$\rho_{\max}$ ( $\Omega\text{m}$ )	$\Delta\rho$ ( $\Omega\text{m}$ )	$h_{\min}$ (m)	$h_{\max}$ (m)	$\Delta h$ (m)
1	300	450	10	10	40	10
2	25	75	10	5	15	5
3	500	1000	100	-	-	-

Wyniki procedury optymalizacyjnej inwersji połączonej (rys. 3c) zestawione z modelami otrzymanymi w wyniku oddzielnych inwersji krzywych oporności dla sondowania elektrooporowego (rys. 3a) i dipolowego sondowania indukcyjnego (rys. 3b) wskazują, że zastosowanie inwersji połączonej, chociaż czasochłonne obliczeniowo, może znacznie ograniczyć niejednoznaczność interpretacji.



**Rys. 3.** Modele osiągnięte w wyniku oddzielnych inwersji PSE (a) i EMHD (b) oraz inwersji połączonej (c)

**Fig. 3.** The obtained final models for individual inversions of PSE (a) and EMHD (b) and joint inversion (c)

### 3. Wpływ dekompozycji zagadnienia odwrotnego na efektywność ich realizacji.

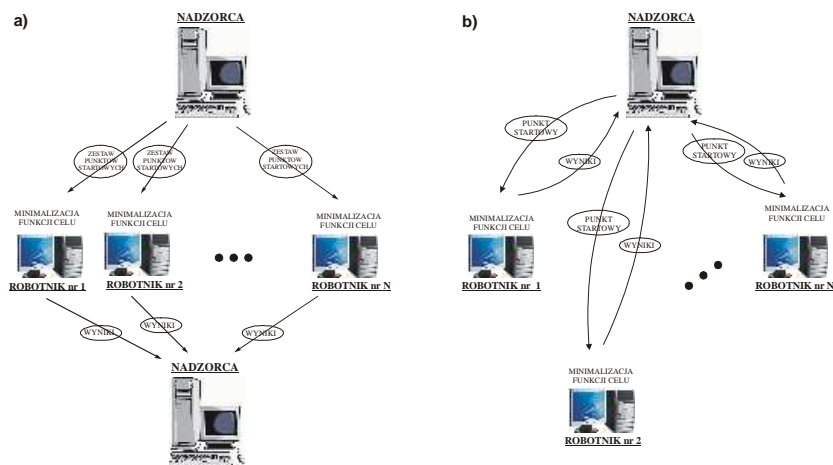
W odniesieniu do omawianych problemów inwersji danych geofizycznych zaproponowano obliczenia równoległe wysokiego poziomu polegające na zrównolegleniu strategii poszukiwania minimum globalnego. Przeanalizowano dwa różne sposoby dekompozycji zadania sekwencyjnego: podział gruboziarnisty (ang. *coarse grain*), charakteryzując się tym, że operacje przesyłania lub odbierania komunikatów przedzielone są wieloma instrukcjami

wykonywanymi przez każdy z procesorów [16] oraz stanowiący jego przeciwieństwo podział drobnoziarnisty (ang. *fine grain*).

Metody zrównoleglenia, należące do grupy metod gruboziarnistych są najczęściej stosowanymi sposobami dekompozycji używanymi przy konstruowaniu algorytmów zrównoleglających proces optymalizacyjny [16]. Środowiskiem obliczeniowym, w którym najczęściej implementowane są algorytmy gruboziarniste są komputery wieloprocessorowe z pamięcią dzieloną i pamięcią lokalną oraz klastry komputerowe – w tym sieci komputerów osobistych. Nie wszystkie gruboziarniste algorytmy optymalizacji globalnej, implementowane w klastrach komputerów osobistych w efektywny sposób wykorzystują zasoby środowiska obliczeniowego. Istnieje grupa zagadnień optymalizacyjnych, ich przykładem jest przedstawiona w poprzednich rozdziałach inwersja połączona danych geoelektrycznych, dla których istnieje konieczność zastosowania innych niż gruboziarniste algorytmów równoległych. Opisane w niniejszym artykule algorytmy równoległe zostały zaimplementowane przy użyciu biblioteki MPI (ang. Message Passing Interface). Zaprezentowane w kolejnym rozdziale metryki wydajnościowe programów równoległych, zostały obliczone przy realizacji programów obliczeniowych w klastrze komputerów PC zbudowanego z 20 komputerów z procesorami Intel Pentium 4, 2.8 GHz i 1024 MB RAM, połączonych siecią 100 Mbit/s.

Przy równoległej realizacji omawianych algorytmów równoległych wykorzystano hierarchiczną architekturę nadzorca – robotnicy. Wyróżniony procesor (nadzorca) odpowiadał za podział obliczeń pomiędzy poszczególne procesory, koordynację obliczeń oraz spójność i gromadzenie wyników. Procesory obliczeniowe (procesory – robotnicy) przeprowadzały obliczenia (minimalizację funkcji celu) dla wskazanych przez nadzorcę punktów startowych.

Schematyczny opis architektury nadzorca – robotnicy i dekompozycji grubo i drobnoziarnistej przedstawiono na rysunku 4.



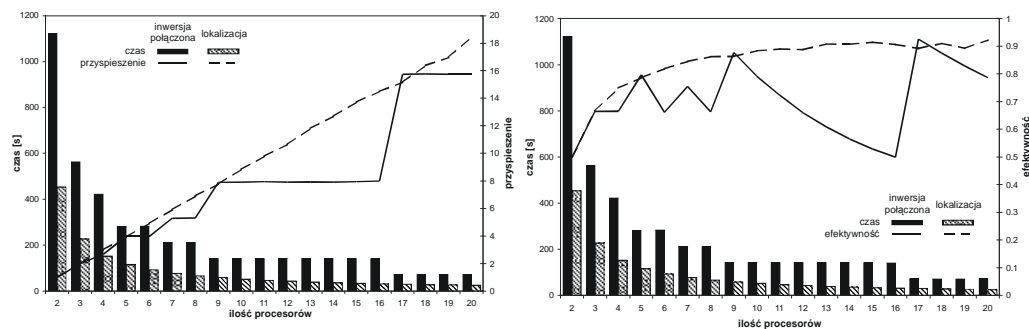
**Rys. 4.** Dekompozycja grubo (a) i drobnoziarnista (b) sekwencyjnego algorytmu inwersji połączonej oraz lokalizacji wstrząsu górniczego (a)

**Fig. 4.** The coarse (a) and the fine grain (b) decomposition of sequential algorithm of the joint inversions and the location of mining tremor (a)

#### 4. Wyniki

Analizę efektywności dekompozycji zadania odwrotnego przeprowadzono w oparciu o podstawowe parametry określające wydajność programu równoległego. Założenie stałego rozmiaru zadania obliczeniowego (stałą ilość punktów startowych metody lokalnej) oraz zmiennej ilości jednostek obliczeniowych (komputerów budujących klaster obliczeniowy) pozwoliły na wyznaczenie podstawowych parametrów określających wydajność programu równoległego: krzywych zmiany czasu trwania obliczeń, przyspieszenia, liczonego jako stosunek czasu obliczeń programu na jednym procesorze do czasu obliczeń na  $p$  procesorach i efektywności, będącej stosunkiem prędkości do ilości procesorów, na których prowadzone były obliczenia (rys. 5 i rys. 6).

Na rysunku 5 przedstawiono wykresy podstawowych parametrów określających wydajność obliczeń równoległych dla podziału gruboziarnistego zastosowanego zarówno dla zagadnienia lokalizacji hipocentrum, jak i zagadnienia inwersji połączonej danych geoelektrycznych.



**Rys. 5.** Zależność czasu obliczeń, przyspieszenia i efektywności od ilości procesorów wchodzących w skład klastra dla dekompozycji gruboziarnistej równoległego algorytmu lokalizacji hipocentrum i inwersji połączonej danych geoelektrycznych

**Fig. 5.** Relation between time, speedup, efficiency and number of computers for the the coarse grain parallel decomposition of the hypocenter location algorithm and the inversion of geoelectrical data


Wykresy parametrów wydajnościowych aplikacji równoległej dekompozycji gruboziarnistej zastosowanej dla algorytmu lokalizacji i inwersji połączonej danych geoelektrycznych (rys. 5) w znacznym stopniu różnią się między sobą. Analiza wykresów przyspieszenia i efektywności wskazuje, że dekompozycja gruboziarnista w efektywny sposób wykorzystuje zasoby środowiska równoległego w odniesieniu do algorytmu lokalizacji hipocentrum wstrząsu. Przy inwersji połączonej danych geoelektrycznych jest efektywna tylko dla specjalnych konfiguracji środowiska obliczeniowego. Znaczne różnice w czasach realizacji obu algorytmów inwersji danych geofizycznych, dochodzące do 200%, nie mają wpływu na charakter krzywych przyspieszenia i efektywności (oba te parametry wydajnościowe, z definicji są znormalizowane).

Schodkowy charakter wzrostu krzywej przyspieszenia czasu obliczeń (rys 5a) i spadająca w nawet do 50% efektywność (rys 5b) wykorzystania środowiska równoległego obserwowana dla dekompozycji gruboziarnistej inwersji połączonej wskazują, że zastosowany podział nie jest optymalnym sposobem zrównoleglenia tego zagadnienia optymalizacji globalnej. W odniesieniu do zagadnienia inwersji połączonej zaproponowano podział drobnoziarnisty (rys. 4b). W dekompozycji drobnoziarnistej minimalizacja funkcji przeprowadzana jest dla



konkretnych wartości wszystkich pięciu parametrów obliczanych w inwersji połączonej danych geoelektrycznych. Po ustaleniu wartości punktów startowych metody lokalnej procesor - nadzorca przesyłał informację do procesora prowadzącego przeszukiwanie przestrzeni parametrów modelu począwszy od wskazanej przez nadzorcę kombinacji parametrów startowych. Po zakończeniu lokalnej procedury minimalizacyjnej nadzorca odbierał wyniki od procesora, który prowadził obliczenia metodą lokalną oraz wysyłał do niego kolejny zestaw parametrów startowych. Podział ten charakteryzuje się dużą ilością komunikatów wysyłanych w trakcie obliczeń, co wskazywane jest jako cecha dyskryminująca jego implementację w środowiskach złożonych z komputerów osobistych [16].

Na rysunku 6 przedstawiono parametry porównujące równoległą realizację podziału drobno i gruboziarnistego zastosowanego dla równoległego algorytmu inwersji danych geoelektrycznych.



**Rys. 6.** Zależność czasu obliczeń, przyspieszenia i efektywności od ilości procesorów wchodzących w skład klastra dla dekompozycji drobno i gruboziarnistej równoległego algorytmu inwersji danych geoelektrycznych

**Fig. 6** Relation between time, speedup, efficiency and number of computers for the fine and the coarse grain parallel decomposition of the inversion of geoelectrical data

Analiza parametrów określających efektywność obliczeń równoległych wskazuje, że dla omawianego przypadku większe korzyści wynikające ze zrównoleglenia aplikacji i lepsze wykorzystanie procesorów klastra obliczeniowego uzyskano dla dekompozycji drobnoziarnistej inwersji połączonej danych geoelektrycznych.

## 5. Podsumowanie

W artykule przedstawiono analizę efektywności równoległych algorytmów zagadnienia optymalizacji globalnej danych geofizycznych. Analiza podstawowych parametrów wydajnościowych aplikacji równoległej wskazała, że nie istnieje uniwersalny schemat dekompozycji zagadnienia minimalizacji globalnej, w optymalny sposób wykorzystujący zasoby środowiska obliczeniowego. Przedstawione wyniki pozwalają wysnuć wniosek, że istnieją zagadnienia, dla których równoległe algorytmy oparte o dekompozycję gruboziarnistą nie są najbardziej efektywnym sposobem zrównoleglenia. Dla specyficznych zagadnień inwersji danych geofizycznych, których przykładem jest inwersja łączona danych geoelektrycznych, bardziej efektywnym rozwiązaniem jest podział drobnoziarnisty. Wynika to ze sposobu realizacji optymalizacji globalnej metodą przeszukiwania siatki. Dla tego typu

zagadnień podział drobnoziarnisty jest efektywniejszy, nawet jeżeli jest on implementowany w środowiskach obliczeniowych w których komunikacja pomiędzy poszczególnymi jednostkami obliczeniowymi może w znaczny sposób wpływać na wydłużenie czasu realizacji obliczeń.

*Praca finansowana z badań statutowych Katedry Geoinformatyki i Informatyki Stosowanej WGGiOŚ, AGH.*

## Literatura

- [1] Bała J., 2010: Zadanie proste i odwrotne w wybranych metodach geoelektrycznych z uwzględnieniem inwersji połączonej - rozprawa doktorska, Akademia Górniczo-Hutnicza im. Stanisława Staszica, Kraków.
- [2] Barros, S. R. M., Dent D., Isaksen, I., Robinson, G., Mozdzyński, G., Wollen-weyer, F., 1995: The IFS model: a parallel production weather code. *Parallel Computing*, 21 No. 10, 1621–1638.
- [3] Bunge H. P., Baumgardner J. R., 1995: Mantle convection modeling on parallel virtual machines, *Computers in Physics*, Vol 9, 207-215.
- [4] Commer M., Newman G., 2004: A parallel finite difference approach for 3D transient electromagnetic modeling with galvanic sources, *Geophysics*, , Vol 69, No 5, 1192-1202.
- [5] Danek T., Franczyk A., 2004: Parallel and distributed seismic wave-field modelling, *TASK Quarterly : scientific bulletin of Academic Computer Centre in Gdansk*, vol. 8, s. 573-581.
- [6] Dębiski W., 2010, Seismic Tomography by Monte Carlo sampling *Pure Appl. Geophys.* Vol. 167, pp. 131-152
- [7] Dębiski, W. 2004. Application of Monte Carlo techniques for solving selected seismological inverse problems, *Publs. Inst. Geophys. Pol. Acad. Sc. B-34 (367)*, 1–207.
- [8] Findeisen W., Szymanowski, J., Wierzbicki A., 1980: Teoria i metody obliczeniowe optymalizacji, Wydawnictwo Naukowe PWN, Warszawa
- [9] Forenc J., Skorek A., Analysis of High Frequency Electromagnetic Wave Propagation Using Parallel MIMD Computer and Cluster System, 2000, International Conference on Parallel Computing in Electrical Engineering (PARELEC'00), 176.
- [10] Newman G. A., Alumbaugh D. L., 1997: Three-dimensional massively parallel electromagnetic inversion-I. Theory, *Geophys. J. Int.* 128, 345-354.
- [11] Phadke S., Bhardway D., Yerneni S., 2000: 3D Seismic Modeling in a Message Passing Environment, SPG (Society of Petroleum Geophysycist) third conference, 168-172.
- [12] Pięta A., Pszczoła G., Leśniak A., 2005: Symulacja komputerowa błędów lokalizacji wstrząsów górniczych przy użyciu rozproszonego środowiska obliczeniowego, *Prace Naukowe Instytutu Górnictwa Politechniki Wrocławskiej*, nr 110. Konferencje, nr 42
- [13] Pięta, A., 2007: Zastosowanie obliczeń w środowisku rozproszonym w wybranych zagadnieniach nauk o Ziemi - rozprawa doktorska, Akademia Górniczo-Hutnicza im. Stanisława Staszica, Kraków
- [14] Press W. H., Flannery B. P., Teukolsky S. A. , Vetterling W. T., 1986: Numerical recipes in C. The art of scientific computing, Cambridge University Press, Cambridge
- [15] Roy I.G., Sen M.K., Torres-Verdin C., 2005: Full waveform seismic inversion using a distributed system of computers, *Concurrency and Computation: Practice and Experience*, v. 17, no. 11, 1365-1385.
- [16] Schnabel R. B., 1995: A View of the Limitations, Opportunities and Challenges in Parallel Nonlinear Optimization, *Parallel Computing*, vol. 21, 875-90
- [17] Snieder and Trampert, 1999 R. Snieder and J. Trampert, Inverse problems in geophysics. In: A. Wirgin, Editor, *Wavefield Inversion*, Springer-Verlag, New York (1999), pp. 119–190.
- [18] Tarantola, A. 2005, *Inverse Problem Theory and Model Parameter Estimation*. Philadelphia: SIAM.
- [19] Zhdanov M.S., Keller G.V., 1994: *The geoelectrical methods in geophysical exploration*. Elsevier, Amsterdam

## **Parallelization methods of the inverse problem for the chosen geophysical issues**

### **Key words**

inversion of geophysical data, parallel computation, joint inversion, location of mining tremors

### **Abstract**

The article presents two different kinds of parallel decomposition of the inverse problem. The computations were performed on the example of selected issues in the fields of geophysics: the location of mining tremors and the joint inversion of geoelectrical data. Global optimization algorithms from the group of the grid search method were used to solve the inverse problem. For a parallel realization of this algorithm the fine and the coarse grid decomposition were proposed. Execution time, speed-up and efficiency of both kinds of parallel algorithms were presented and analyzed.