

Metoda rekonstrukcji obrazów z rzadkich pomiarów tomograficznych

Olga Walenciuk

Kierunek: Inżynieria biomedyczna

Opiekun pracy dyplomowej:
prof. dr hab. inż. Artur Przelaskowski



- 1. Cel i motywacja pracy**
- 2. Podstawy teoretyczne – rzadkość i niekoherencja**
- 3. Wyniki rekonstrukcji obrazu MRI**
- 4. Podsumowanie**



Motywacja pracy

- Problem czasochłonnej akwizycji danych w obrazowaniu metodą rezonansu magnetycznego
- Pobrane dane są często nadmiarowe
- Ograniczenie liczby próbek do minimum potrzebnego przy rekonstrukcji sygnału, znacząco wpłynęłoby na czas pomiaru, pociągając za sobą dalsze korzyści



Cel pracy

Celem pracy było skonstruowanie metody rekonstrukcji obrazów, która pozwoliłaby na uzyskanie jakości porównywalnej z metodami tradycyjnymi, jednak przy znacznym zmniejszeniu liczby potrzebnych danych.

Opracowanie metody obejmowało dwa kluczowe zagadnienia:

- zaprojektowanie odpowiedniego schematu próbkującego przestrzeń k
- dobór algorytmu rozwiązującego problem rekonstrukcji obrazu z niepełnych danych.



Podstawowymi założeniami oszczędnego próbkowania jest rzadkość sygnału oraz niekoherentny pomiar.

Sygnał jest **rzadki**, jeżeli duża część jego składowych jest równa zero lub jeżeli istnieje baza, w której może być reprezentowany przez niewielką liczbę niezerowych współczynników.

Koherencja pomiarowa jest miarą korelacji między bazą pomiarową a bazą sygnału. Mniejsza koherencja, oznacza mniej pomiarów potrzebnych do odtworzenia sygnału.







Przykład obrazu
rzadkiego w
oryginalnej bazie –
angiografia MR



źródło: <https://www.siemens-healthineers.com/magnetic-resonance-imaging/clinical-specialities/compressed-sensing>



źródło: Schmainda KM, Prah M (2018) Data from Brain-Tumor-Progression. The Cancer Imaging Archive.



Problem rekonstrukcji obrazów sprowadza się do szukania rozwiązań zagadnienia odwrotnego, postawionego w następujący sposób.

Niech $\mathbf{x} \in \mathbb{R}^n$ będzie badanym sygnałem, a $\mathbf{y} \in \mathbb{R}^m$ wektorem zaobserwowanych danych, zaś $\mathbf{A} \in \mathbb{R}^{m \times n}$ macierzą modelującą proces pomiaru. Proces pomiarowy można zatem przedstawić wzorem:

$$\mathbf{y} = \mathbf{A}\mathbf{x}$$




Przy założeniu, że wektor x może być reprezentowany jako rzadki wektor z w pewnej bazie, oraz macierz A spełnia określone warunki, możliwe staje się uzyskanie jednoznacznego rozwiązania przez rozwiązanie poniższego problemu optymalizacyjnego, jakim jest minimalizacja normy ℓ_1 .

$$\operatorname{argmin}_{z \in \mathbb{R}^n} \|z\|_1, \text{ pod warunkiem } y = Az$$


W celu rozwiązania powyższego problemu zaimplementowano iteracyjny algorytm oparty na miękkim progowaniu, będący przykładem algorytmu zachłannego.




Maski próbujące przestrzeń k




a)




b)




c)




d)




e)



f)



g)




h)


źródło: opracowanie własne




Liniowa rekonstrukcja obrazów




a)




b)




c)




d)




e)



f)



g)




h)


źródło: opracowanie własne




Wyniki zastosowania iteracyjnego algorytmu rekonstrukcji




a)




b)




c)




d)




e)



f)



g)




h)

źródło: opracowanie własne




Wykres zależności wskaźnika podobieństwa strukturalnego SSIM od liczby iteracji rekonstrukcji – wyniki dla różnych masek



źródło: opracowanie własne




Wykres zależności wskaźnika podobieństwa strukturalnego SSIM od procentu pozostawionych danych – wyniki dla różnych masek



źródło: opracowanie własne




Wykres zależności wskaźnika podobieństwa strukturalnego SSIM od liczby iteracji rekonstrukcji – wyniki dla różnej wartości progu



źródło: opracowanie własne



Przykład rekonstrukcji z 10% danych przy użyciu maski adaptacyjnej i zmodyfikowanego algorytmu.



Środkowy wynik uzyskano po 5 iteracjach



źródło: opracowanie własne



Podsumowanie

- Zastosowanie iteracyjnego algorytmu opartego na miękkim progowaniu wraz z maską adaptacyjną pozwoliło na niemal dokładną rekonstrukcję obrazu tylko z 25% pozostawionych danych - wskaźnik SSIM wyniósł 0.98
- Przy pozostawieniu 10% składowych, zastosowanie maski adaptacyjnej oraz dynamicznej zmiany progu, pozwoliło na uzyskanie wartości wskaźnika SSIM powyżej 0.9 już po pięciu iteracjach.
- Przy dalszym rozwoju metody warto rozważyć wykorzystanie innych algorytmów zachłannych



Dziękuję za uwagę

