

ZASTOSOWANIE KWANTOWYCH ALGORYTMÓW GENETYCZNYCH DO SELEKCJI CECH



Łukasz Jopek, Robert Nowotniak, Michał Postolski,
Laurent Babout, Marcin Janaszewski

Katedra Informatyki Stosowanej, Politechnika Łódzka, Łódź, Polska
ljopek, rnowotniak, mpostol, lbabout, janasz@kis.p.lodz.pl

Streszczenie

Selekcję cech, używanych przez klasyfikator minimalno odległościowy k-NN w procesie segmentacji obrazów, można potraktować jako problem dwukryterialnej optymalizacji kombinatorycznej, której celem jest znalezienie takiego podzbioru cech punktów obrazu, który pozwala na zadowalającą segmentację w możliwie krótkim czasie.

W pracy porównano trzy populacyjne metody heurystyczne:

Klasyczny Algorytm Genetyczny SGA

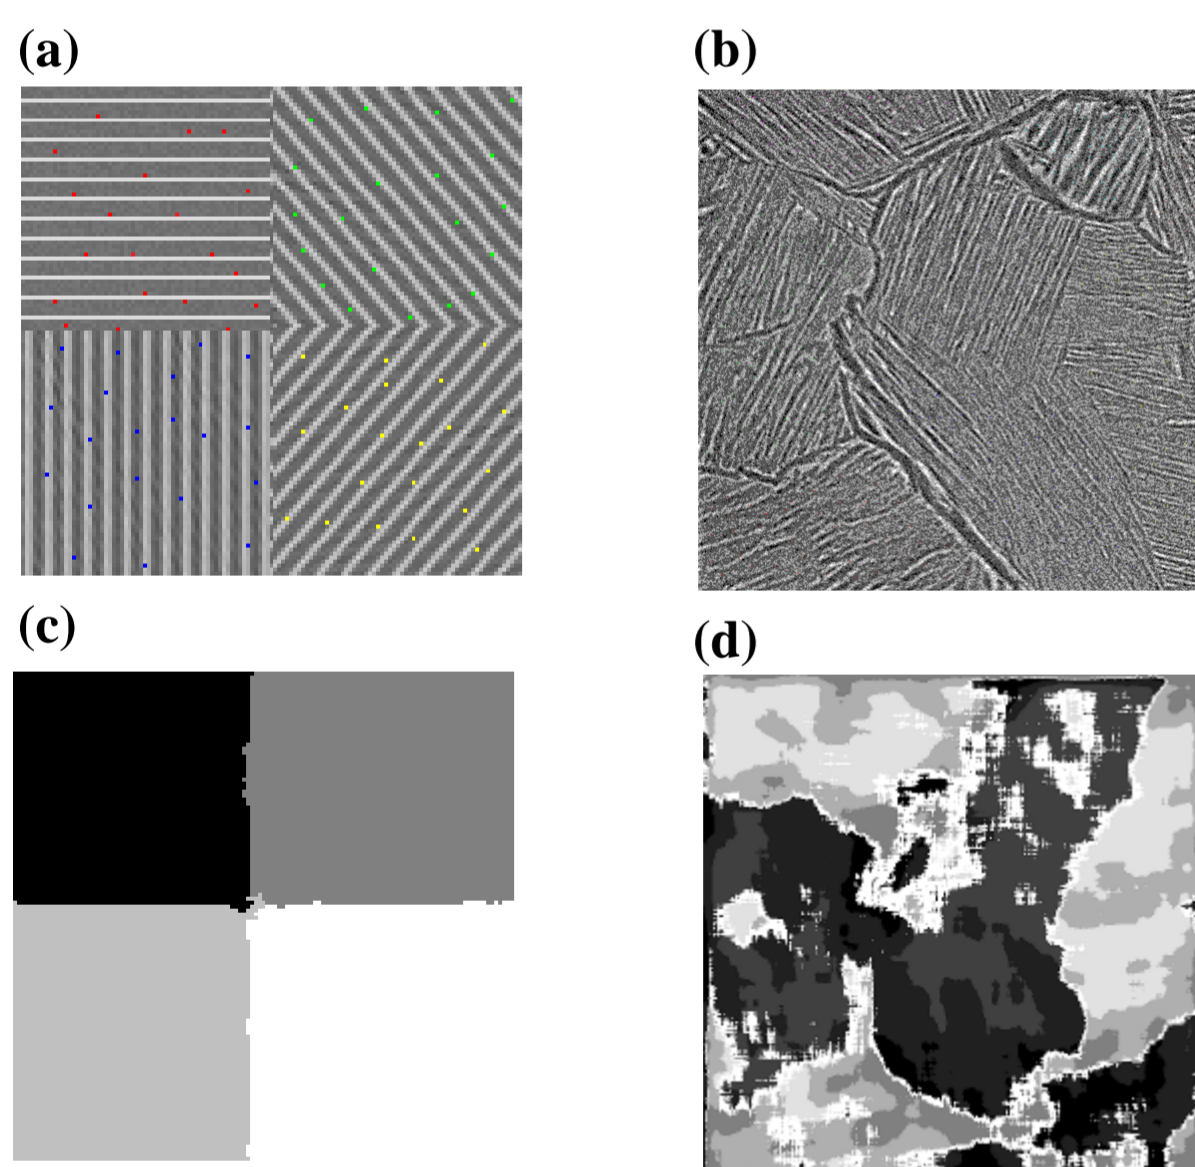
oraz jego dwie modyfikacje, czerpiące inspirację z systemów informatyki kwantowej:

- QiGA (ang. *Quantum-Inspired Genetic Algorithm*)
- GAQPR (ang. *Genetic Algorithm with Quantum Probability Representation*)

1. Segmentacja obrazów

Segmentacja obrazu to podział obrazu na obszary, jednorodne pod względem wybranych kryteriów.

Dokładna segmentacja jest istotnym krokiem w wielu praktycznych zastosowaniach polegających na analizowaniu obrazów np. analiza ilościowa i jakościowa obrazów pochodzących z tomografii komputerowej lub rezonansu magnetycznego w materiałoznawstwie [1] lub medycynie [2].



Rysunek 1: Obraz tekstury sztucznej (a) oraz tomograficznej [1] (b), na których zostały przeprowadzone badania. Obrazy (c) i (d) przedstawiają uzyskany wynik segmentacji dla obrazów kolejno (a) i (b). Wyróżnione punkty na obrazie (a) są losowo wybranymi reprezentantami każdej z klas i stanowią zbiór uczący w procesie klasyfikacji.

2. Selekcja cech

W procesie segmentacji korzysta się zazwyczaj z różnorodnych cech punktów obrazu, które można wyznaczyć np. za pomocą oprogramowania MaZda [3].

Na potrzeby niniejszego artykułu zostały wybrane następujące grupy cech (łącznie 144 różne cechy):

- Cechy statystyczne histogramu (6 cech)
- Cechy wyznaczone na podstawie macierzy zdarzeń (120 cech)
- Cechy wyznaczone na podstawie pasm (16 cech)
- Cechy wyznaczone na podstawie macierzy gradientu (2 cechy)

Do przeprowadzenia poprawnej segmentacji ważne jest, by wybrać tylko te cechy lub grupy cech, które są dobrymi dyskryminatorami, czyli cechami, które pozwalają jak najlepiej rozróżnić dane klasy obrazów.

Warto zauważyć, że wykorzystywanie niektórych cech, wiąże się ze znacznym kosztem obliczeniowym, a ich wpływ na poprawność klasyfikacji punktów (a zatem na jakość segmentacji) jest niewielki.

3. Wykorzystanie metod ewolucyjnych

Wybór podzbioru cech, które będą wykorzystywane przez klasyfikator, można traktować jako zadanie optymalizacji kombinatorycznej, uwzględniającej dwa kryteria: czas potrzebny na obliczenie wartości wybranych cech oraz uzyskiwaną jakość segmentacji.

Przy założeniu, że pojedynczy proces klasyfikacji za pomocą algorytmu k-NN trwa 10ms, ocena wszystkich podzbiorów 32-elementowego zbioru cech, wymagałaby ponad roku obliczeń. Z tego powodu rozsądną alternatywą jest podejście heurystyczne, pozwalające na efektywne znalezienie satysfakcjonującego, suboptymalnego rozwiązania w znacznie krótszym czasie.

4. Funkcja Oceny

Na potrzeby niniejszej pracy funkcja oceny dla problemu selekcji cech została dobrana w następujący sposób:

$$f(x) = K - S(t, w) \quad (1)$$

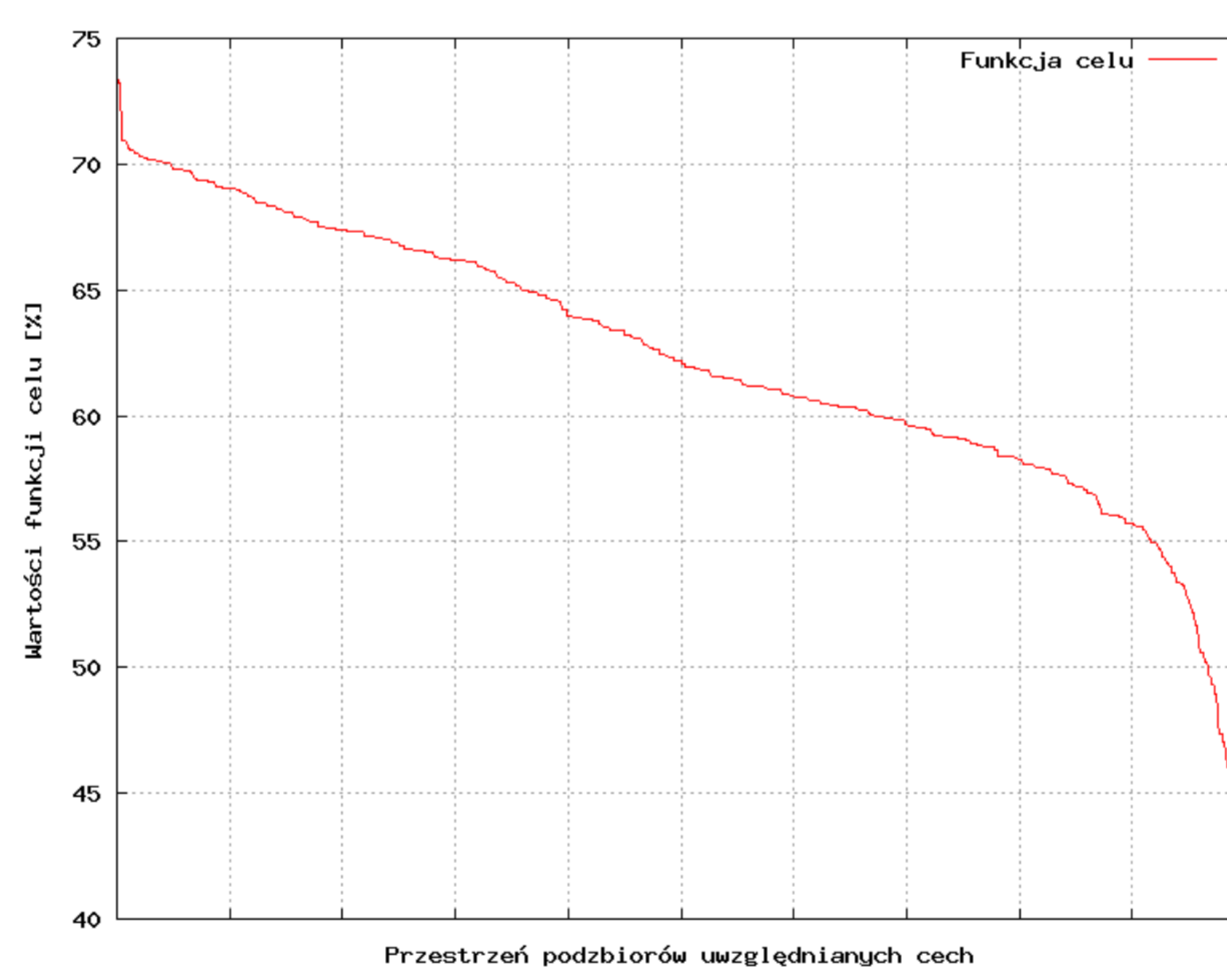
gdzie:

x - wybrany podzbiór wszystkich uwzględnianych cech

K - jakość uzyskiwanej klasyfikacji

T - czas potrzebny na obliczenie cech, należących do x

$S(t, w)$ - liniowa funkcja kary, skalująca czas t do przedziału $< 0; w >$



Rysunek 2: Rozkład statystyczny wartości zaproponowanej przez autorów funkcji celu w przestrzeni podzbiorów uwzględnianych cech – wygenerowany dla tekstury tomograficznej (Rys. 1 (b))

5. Kwantowe algorytmy genetyczne

Informatyka kwantowa [4] zajmuje się wykorzystaniem możliwości obliczeniowych miniaturowych układów, podlegających prawom mechaniki kwantowej. Dzięki unikalnym własnościom takich układów niektóre problemy obliczeniowe mogłyby być rozwiązywane w sposób znacznie bardziej efektywny, niż jest to możliwe za pomocą jakichkolwiek klasycznych maszyn obliczeniowych (np. [5]).

Mimo iż budowa użytecznego komputera kwantowego pozostaje ciągle wyzwaniem równoległe od późnych lat 90. XX wieku trwają badania nad metodami sztucznej inteligencji, posiadającymi elementy inspirowane systemami informatyki kwantowej.

W ciągu ostatniego dziesięciolecia wykazano, że modyfikacja istniejących metod sztucznej inteligencji, poprzez dodanie elementów o naturze kwantowej, pozwala w wielu przypadkach na znaczną poprawę efektywności tych metod.

Jedną z prób wprowadzenia tego typu modyfikacji do algorytmów genetycznych są algorytmy QiGA [6, 7] (ang. *Quantum-Inspired Genetic Algorithm*) oraz GAQPR [8] (ang. *Genetic Algorithm with Quantum Probability Representation*).

procedure GAQPR

```

begin
  t := 0
  zainicjalizuj Q(t)
  utwórz P(t) poprzez obserwację stanów Q(t)
  oceń rozwiązanie P(t)
  zapamiętaj najlepsze rozwiązanie z P(t)
  while (warunek stopu nie spełniony) do
  begin
    t := t + 1
    utwórz P(t) poprzez obserwację stanów Q(t-1)
    oceń rozwiązanie P(t)
    zapamiętaj najlepsze rozwiązanie z P(t)
    zaktualizuj Q(t) za pomocą bramek kwantowych U(t)
    zastosuj dodatkowe operatory genetyczne na Q(t)
  end
end
end

```

gdzie:

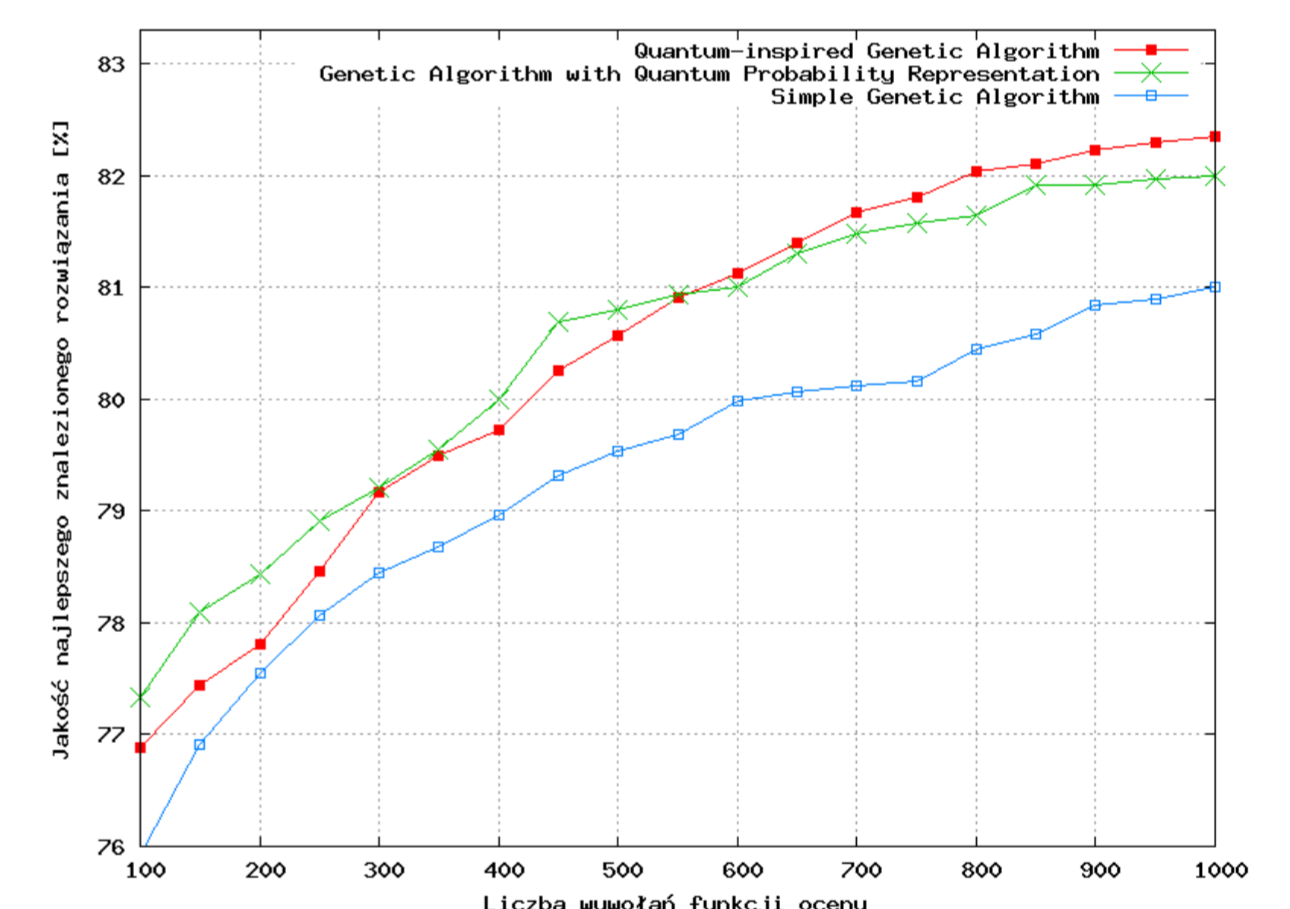
t - numer generacji

$Q(t)$ - populacja chromosomów kwantowych w generacji t

$P(t)$ - zbiór ciągów binarnych

$U(t)$ - zbiór bramek kwantowych używanych w generacji t do modyfikacji populacji Q

6. Uzyskane wyniki



Rysunek 3: Wykres przedstawiający jakość znalezionych podzbiorów cech przez trzy porównywane algorytmy w funkcji liczby wywołań funkcji oceny, dla tekstury tomograficznej.

7. Wnioski

W przeprowadzonych testach wyniki uzyskiwane przez algorytmy genetyczne, posiadające elementy inspirowane systemami informatyki kwantowej, były za każdym razem lepsze od wyników klasycznego algorytmu genetycznego.

Interesującym przedmiotem dalszych badań będzie analiza wpływu parametrów przedstawionych zmodyfikowanych algorytmów genetycznych na szybkość i jakość otrzymywanych rezultatów, a także porównanie tych algorytmów dla inaczej zdefiniowanej funkcji oceny.

Bibliografia

- [1] Babout L., Marrow T.J., Preuss M.: Sequential X-ray Tomography Studies of Damage Assessment in Materials Science, 4th International Symposium on Process Tomography in Poland. Proceedings. s.159-162, 2006.
- [2] Tschirren J., Hoffman E.A., McLennan G., Sonka M.: Intrathoracic Airway Trees: Segmentation and Airway Morphology Analysis from Low-Dose CT Scans. IEEE Transactions on Medical Imaging 24(12), pp. 1529-1539, 2005
- [3] Program MaZda, http://www.elel.p.lodz.pl/programy/cost/progr_mazda.html
- [4] Nielsen M.A., Chuang I.L.: Quantum Computation and Quantum Information, Cambridge University Press, 2000
- [5] Nowotniak R.: Informatyka kwantowa. XV Konferencja Sieci i Systemy Informatyczne, Łódź, 2007.
- [6] Han K. H., Kim J.H.: Genetic quantum algorithm and its application to combinatorial optimization problem. in Proceedings of the 2000 Congress on Evolutionary Computation, pp. 1354-1360, 2000.
- [7] Han K. H., Kim J. H.: Analysis of quantum-inspired evolutionary algorithm. Proceedings of the 2001 International Conference on Artificial Intelligence, pp. 727-730, 2001.
- [8] Bin L., Junan Y., Zhenquan Z.: GAQPR and its application in discovering frequent structures in time series. Proceedings of the 2003 International Conference on Neural Networks and Signal Processing, 2003.