



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Instrukcja współfinansowana przez Unię Europejską
w ramach Europejskiego Funduszu Społecznego
w projekcie

*„Innowacyjna dydaktyka bez ograniczeń
– zintegrowany rozwój Politechniki Łódzkiej – zarządzanie Uczelnią,
nowoczesna oferta edukacyjna i wzmacniania zdolności
do zatrudniania osób niepełnosprawnych”*

Instrukcja jest dystrybuowana bezpłatnie.

Instrukcja do laboratorium, część 3

Krzysztof Ślot

Sztuczna inteligencja i jej zastosowania w biomedycznej diagnostyce obrazowej

Studia podyplomowe „Przetwarzanie i analiza obrazów biomedycznych”



Politechnika Łódzka
Instytut Elektroniki

90-924 Łódź, ul. Żeromskiego 116,
tel. 042 631 28 83
www.kapitalludzki.p.lodz.pl



Ćwiczenie 3.

Wykorzystanie metod optymalizacji deterministycznej i stochastycznej do detekcji obiektów w obrazach.

Spis treści

Ćwiczenie 3.....	2
Wykorzystanie metod optymalizacji deterministycznej i stochastycznej do detekcji obiektów w obrazach.....	2
Spis treści	2
1 Wprowadzenie.....	3
1.1 Detekcja z wykorzystaniem optymalizacji deterministycznej	3
1.1.1 Przebieg ćwiczenia	5
1.2 Detekcja z wykorzystaniem optymalizacji stochastycznej	6
1.2.1 Przebieg ćwiczenia	7



1 Wprowadzenie

Przedmiotem ćwiczenia jest zapoznanie się z grupą metod wykrywania obiektów obrazów, bazującą na detekcji ich konturu i dopasowaniu tego konturu do posiadanych wzorców. Założeniem rozważanej strategii rozpoznawania jest znajomość kształtu poszukiwanego obiektu. W celu uzyskania dobrej skuteczności rozpoznawania, konieczne jest zapewnienie odporności metody rozpoznawania na szereg czynników, które nieuchronnie utrudniają proces analizy. Obiekty prawie na pewno będą wykazywać rozmaite odstępstwa od stworzonych wcześniej wzorców – będą różnić się kształtem, rozmiarem, orientacją itp. Celem ćwiczenia jest prezentacja metodologii postępowania, zmierzających do zapewnienia niewrażliwości na występowanie wymienionych problemów. Podstawą wielu metodologii postępowania jest optymalizacja, definiująca następujące podejście do rozpoznawania: zdefiniuj model konturu danego obiektu, zawierający zbiór parametrów, a następnie, manipulując wartościami parametrów, spróbuj najlepiej dopasować model do badanego obiektu. Jakość dopasowania musi być określona w sposób ilościowy – jednym z fundamentalnych elementów optymalizacji jest sformułowanie odpowiedniej funkcji kryterialnej.

Ćwiczenie ilustruje dwie podstawowe strategie optymalizacji, wraz z określeniem ich wad i zalet. Pierwsza z nich to optymalizacja deterministyczna, gdzie korekty wartości parametrów są ściśle określone przez właściwości funkcji kryterialnej. Druga, to optymalizacja stochastyczna, gdzie korekty parametrów mają charakter losowy. Skutkuje to mniej konsekwentną drogą do rozwiązania, jednak pozwala na ominięcie istotnych wad metod deterministycznych.


Ćwiczenie umożliwia zaznajomienie się z przebiegiem całego procesu rozpoznawania obiektów, począwszy od budowy parametrycznego modelu konturu, poprzez formułowanie funkcji kryterialnej, aż do określania metod korekt wartości parametrów, zapewniających poprawę dopasowania. Dla ilustracji wspomnianych strategii procesu rozpoznawania opracowane zostały trzy różne programy, napisane w języku Matlab®.

1.1 Detekcja z wykorzystaniem optymalizacji deterministycznej

Pierwszy z programów używanych w ćwiczeniu ('Optim1') ilustruje prostą strategię optymalizacji deterministycznej. Interfejs programu, pokazany na rys. 1, zawiera obraz (o ustalonej treści – koło, o zmiennej jasności, malejącej wzdłuż promienia) oraz zestaw elementów kontrolnych. Interakcja z programem jest dokonywana przy użyciu suwaków (za pomocą których ustawiane są początkowe wartości parametrów modelu – „x0”, „y0”, „r”), selektorów (uzależniających proces optymalizacji od odpowiednich parametrów – „Obliczaj x0” i „Obliczaj y0”) i przycisków (uruchamiających proces dopasowania – „Szukaj” – oraz rysujących wykres funkcji kryterialnej – „Funkcja celu”).

Celem procedury jest detekcja zawartego w obrazie koła (określenie jego położenia oraz promienia). Punktem wyjścia rozpoznawania jest założenie, że znany jest kształt konturu obiektu. Określony dla obiektów rozważanej kategorii model może być opisany przy użyciu

trzech parametrów: współrzędnych środka i promienia. Rozpoznawanie polega na próbie dopasowania modelu do obszaru obrazu i ocenie, czy wynik spełnia określone kryterium podobieństwa. Dopasowanie jest inicjowane umieszczeniem modelu w przestrzeni obrazu. Następnie, przeprowadzany jest ciąg operacji korekt parametrów modelu, które mają za zadanie zmienić kształt wzorca tak, by jak najbliżej odpowiadał konturowi obiektu.



Rysunek 1. Okno programu 'Optim1'


Jednym z kandydatów na funkcję kryterialną, pozwalającą na ocenę bieżącej zgodności wzorca i analizowanego obiektu jest średnia wartość modułu gradientu, występującego wzdłuż konturu. Wartość ta jest maksymalna, gdy punkty okręgu będącego modelem klasy są położone wzdłuż brzegu analizowanej figury (zbiór punktów brzegowych figury charakteryzuje się występowaniem silnych gradientów). Przedstawiona funkcja kryterialna została zastosowana w programie Optim1.

Sposób dopasowania konturu do obiektu to ciąg operacji:

1. Określenie wartości funkcji kryterialnej dla bieżącego konturu $f(x_0, y_0, r)$, gdzie x_0 i y_0 to współrzędne środka konturu a r to jego promień,
2. Określenie gradientu funkcji kryterialnej w przestrzeni parametrów x_0, y_0, r
3. Wyznaczenie nowych wartości parametrów metodą Gaussa-Newtona


1.1.1 Przebieg ćwiczenia

Ćwiczenie zaczyna się od zbadania możliwości uzyskania dobrego dopasowania konturu przy założeniu znajomości położenia środka okręgu. Jedynym parametrem o nieznannej wartości jest promień. Zadawanie wartości początkowej promienia dokonywane jest przy użyciu suwaka z etykietą „r”. Dla ustalonego konturu początkowego (wyświetlanego w kolorze zielonym), uruchomienie procedury optymalizacji jest dokonywane naciśnięciem przycisku „Szukaj”. Efektem procesu optymalizacji jest obliczenie i wyświetlenie (w kolorze czerwonym) wyniku dopasowania (rys. 2).




Rysunek 2. Wynik dopasowania konturu początkowego do obrazu. W dolnej części okna wyświetlane są informacje określające znalezione parametry.

W dalszej części przedmiotem badań jest określenie możliwości dopasowania bazującego na doborze większej liczby parametrów. Wybór selektorów „Obliczaj x0” i „Obliczaj y0” pozwala na zróżnicowanie położenia środka okręgu. Przykładowy wynik działania programu dla dowolnego położenia punktu startowego, przedstawia rys. 3.



Rysunek 3. Wynik dopasowania dla przypadkowej lokalizacji początkowej konturu: poprawny (a) i błędny (b).

Przedstawiona strategia dopasowywania konturu do krawędzi obiektu okazuje się być nieskuteczna, dla wielu możliwych początkowych zestawów parametrów (rys. 3b). Przyczyną jest charakter funkcji celu, stosowanej w optymalizacji – jedynie w prostych przypadkach jest ona monotoniczna (rys.4a), a zwykle, ma ona szereg maksimów lokalnych (rys. 4.b).



Rysunek 4. Przebieg funkcji celu: funkcja monotoniczna, gwarantująca znalezienie rozwiązania (a) i wielomodalna, z dużym prawdopodobieństwem niepowodzenia poszukiwań (b)

1.2 Detekcja z wykorzystaniem optymalizacji stochastycznej

Cechą optymalizacji stochastycznej jest uzależnienie korekt parametrów modeli od czynnika losowego. Uzyskiwane nowe zbiory („kandydaci”) są następnie oceniani pod względem ich przydatności dla realizacji danego zadania, a najlepsi z nich stanowią punkt odniesienia dla procesów dalszych korekt. Jedną z najczęściej stosowanych strategii optymalizacji stochastycznej, zapożyczoną z biologii są tzw. Algorytmy Genetyczne. Algorytmy Genetyczne stanowią metodę rozwiązywania problemów, których celem jest znalezienie zbioru parametrów zapewniających najlepsze spełnienie danego kryterium przy obecności ograniczeń.



Punktem wyjścia dla przeprowadzenia algorytmu genetycznego jest określenie zbioru wektorów parametrów, będących początkowymi przymiarkami rozwiązania problemu, funkcji kryterialnej, oceniającej jakość bieżącego rozwiązania oraz ograniczeń, określających dozwolone zakresy wartości parametrów. Korzystając z terminologii zaczerpniętej z biologii, wektor parametrów nazywany jest chromosomem, a zbiór chromosomów (wektorów) – populacją. Metoda rozwiązywania problemu za pomocą algorytmu genetycznego polega na cyklicznym powtarzaniu dwóch operacji: selekcji bieżących chromosomów (hipotez) i budowaniu nowej populacji, bazującej na wynikach selekcji. Celem selekcji jest określenie podzbioru chromosomów najlepiej spełniających kryterium poszukiwań. Typowy sposób tworzenia nowej populacji jest następujący. Pierwszą grupę jej elementów stanowi zbiór chromosomów początkowych, które najlepiej spełniały przyjęte kryterium oceny. Druga grupa chromosomów powstaje z elementów grupy pierwszej, poddanych operacjom mutacji. Mutacja to przypadkowa zmiana wartości elementów chromosomu, zachodząca z zadaniem prawdopodobieństwem. Trzecia grupa nowej populacji to chromosomy powstałe w wyniku wzajemnego krzyżowania elementów pierwszej grupy. Krzyżowanie polega na zamianie przypadkowych fragmentów dwóch chromosomów bazowych i skutkuje powstaniem dwóch elementów potomnych. Wreszcie, pozostała część nowej populacji to zbiór nowych, losowo wybranych chromosomów.


1.2.1 Przebieg ćwiczenia

Przykładem wykorzystania algorytmu genetycznego do rozwiązywania problemów przetwarzania obrazów jest zadanie wydzielania obiektów o nieregularnych konturach. Interfejs programu, przedstawiony na rys. 5, zawiera przetwarzany obraz oraz zbiór narzędzi do tworzenia i przeprowadzania procesu detekcji. Celem przetwarzania jest wydzielanie obiektów o kształcie, przedstawionym na rys. 5. Detekcja, polega na osiągnięciu najlepszego możliwego dopasowania konturu, określonego przez zbiór parametrów (tzw. krzywej sklepanej) do linii brzegowej obiektu. Parametrami, które podlegają modyfikacji w trakcie procesu przetwarzania są: położenie środka konturu, jego orientacja i rozmiar oraz lokalizacje sześciu punktów kontrolnych, wyznaczających przebieg konturu. Wszystkie te parametry tworzą piętnastoelementowe chromosomy, podlegające procesom losowych korekt (mutacji i krzyżowań).

Narzędzia, które znajdują się w interfejsie graficznym programu, pozwalają na modyfikację różnych aspektów algorytmu. Interfejs daje też możliwość obrazowego zapoznania się z efektami zmian parametrów chromosomu, odpowiadającego konturowi. Przyciśnięcie przycisku „Modyfikuj” skutkuje wyświetleniem konturu początkowego (używanego jako przybliżony model rozważanej figury) oraz konturu, będącego efektem przeprowadzenia mutacji parametrów konturu początkowego.


Pierwszym krokiem optymalizacji z wykorzystaniem algorytmu genetycznego jest utworzenie początkowej populacji chromosomów. Użytkownik ma możliwość określenia liczności tej populacji, poprzez wpisanie odpowiedniej wartości do pola edycyjnego „Liczba chromosomów”. Procedurę tworzenia populacji uruchamia wciśnięcie przycisku „Inicjuj”, a uzyskany zbiór chromosomów staje się punktem wyjścia dla dalszej części przetwarzania. Użytkownik ma możliwość określenia proporcji między różnymi grupami chromosomów,

tworzącymi kolejne populacje, poprzez wstawianie odpowiednich wartości liczbowych w pola edycyjne z etykietami: „Nowe” (przypadkowo generowane chromosomy, niepowiązane ze zbiorem początkowym), „Mutacje” (liczność zbioru chromosomów zmutowanych) oraz „Krzyżowania” (liczność zbioru chromosomów, uzyskiwanych z krzyżowania najlepszych chromosomów).



Rysunek 5. Kontur początkowy (zielony) i kontur odpowiadający losowo zmodyfikowanym wartościom parametrów początkowych (niebieski)

Procedura optymalizacji jest uruchamiana przyciśnięciem przycisku „Wykonaj”. Liczba iteracji procesu optymalizacji to liczba wykonywanych cykli, obejmujących selekcję i tworzenie na podstawie jej wyników nowych populacji. Liczba ta może być ustalona przez użytkownika poprzez modyfikację zawartości pola edycyjnego „Liczba iteracji”. Użytkownik ma dodatkowo możliwość ustalania trzech innych parametrów algorytmu genetycznego: prawdopodobieństwa mutacji (pole „P-stwo mutacji”), skali mutacji („Skala mutacji”) i prawdopodobieństwa krzyżowania („P-stwo krzyżowania”). Skala mutacji określa procentową wartość maksymalnej dozwolonej zmiany korygowanego parametru. Licznik iteracji, znajdujący się nad przyciskiem „Wykonaj” informuje użytkownika o postępie obliczeń. Wynikiem obliczeń jest zbiór parametrów, uznany jako najlepiej spełniający zadaną funkcję kryterialną. Funkcja kryterialna, zastosowana w programie jest bardzo prosta – jest nią średnia wartość modułu gradientu obrazu, występująca wzdłuż całego konturu. Po zakończeniu obliczeń, na obrazie (rys. 6) wyświetlana jest krzywa (w kolorze czerwonym), odpowiadająca zwiędkiemu chromosomowi.



Rysunek 6. Wynik optymalizacji – krzywa najlepiej pasująca do brzegu nieznanej figury (wyznaczona po 10 iteracjach algorytmu genetycznego)

Wynik procesu optymalizacji, może stać się punktem startowym dla kolejnych obliczeń, poprzez wciśnięcie przycisku „Inicjuj”. W przeciwnym przypadku, punktem startowym nowej procedury optymalizacyjnej, będzie domyślny zestaw parametrów, odpowiadający zielonej krzywej, przedstawionej na rys. 5.