

Tomasz Praczyk

SIEĆ GRNN W KOMPRESJI OBRAZÓW RADAROWYCH

STRESZCZENIE

Obraz morskiego radaru nawigacyjnego może być podstawą perspektywicznego systemu wyznaczenia pozycji okrętu. Obrazy uzyskane z radarów nawigacyjnych zawierają zwykle ogromne ilości informacji. Wykorzystanie jej w całości w systemach pozycjonowania jest praktycznie niemożliwe. Wiąże się to z ograniczonymi możliwościami obliczeniowymi współczesnych komputerów. Konieczne staje się zatem skondensowanie występującej w każdym obrazie informacji do wielkości akceptowalnej z punktu widzenia praktycznych zastosowań. Efekt taki możemy uzyskać poprzez zastosowanie metod ekstrakcji cech z zarejestrowanych obrazów radarowych. Artykuł prezentuje jedną z metod ekstrakcji cech bazującą na możliwościach samoorganizującej sieci Kohonena oraz sieci GRNN.

WSTĘP

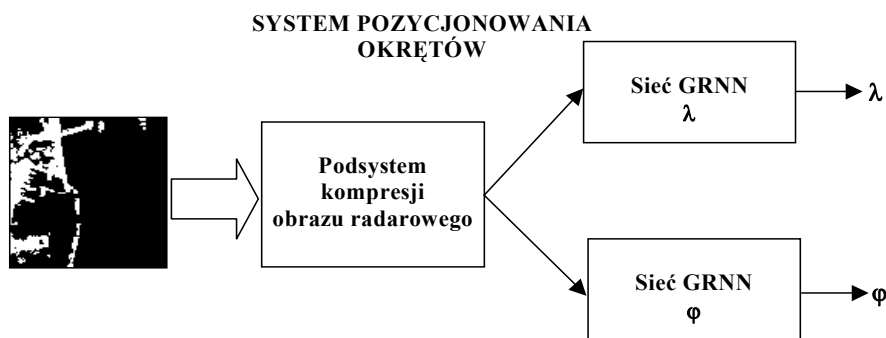
Sieci neuronowe wykazały wielokrotnie swoją przydatność w rozwiązywaniu wielu, nawet najbardziej złożonych, problemów. Z reguły dotyczy to zadań, którym tradycyjnie stosowane metody nie były w stanie sprostać lub dawały wielce niezadowolające rezultaty. Możemy znaleźć również dziedziny, w których sieci neuronowe konkurują z algorytmami konwencjonalnymi. Jedną z nich jest kompresja obrazów. Sieciami z powodzeniem mogącymi dokonywać kompresji są perceptron wielowarstwowy, sieć samoorganizująca na podstawie reguły Hebba, sieć Kohonena, a także sieć GRNN. W artykule zaprezentowane zostaną możliwości tej ostatniej w zakresie kompresji obrazów radarowych.

Sieć GRNN jest typową siecią aproksymacyjną, zazwyczaj z jednym wyjściem, uczoną z pomocą „nauczyciela”. Oznacza to, że do poprawnego działania potrzebuje ona ciągu uczącego zawierającego pary (x, y) , gdzie x jest wektorem wejściowym (obrazem radarowym), natomiast y wartością skojarzoną z x . Problem kompresji obrazu jest jednak zgoła zupełnie innej natury. Nie mamy tutaj, niestety,

żadnych wartości, które moglibyśmy zwi azać z ka dym z obraz w poddawanych kompresji. Jak w takim razie wygl ada u ycie sieci GRNN w kompresji obraz w? My l u ycia ich w tym zakresie jest rozwini ciem pomys u wykorzystania sieci Kohonena do kompresji obraz w.

W tym wypadku poszczególne neurony sieci Kohonena stanowi  zbi r wektor w ucza cych x , natomiast indeksy ka dego z nich odpowiadaj  warto ciom y . Oznacza to,  e do konstrukcji kompresora opartego na sieci GRNN konieczna jest nauczona sie  Kohonena.

Istnieje wiele kryteri w oceny algorytmu kompresji, poczynaj c od stopnia kompresji, czyli stosunku wielko ci obrazu przed kompresj  do jego wielko ci po kompresji, szybko ci kompresji, miary jej bezstratno ci, czyli r ownicy pomi dzy obrazem oryginalnym a obrazem odtworzonym z jego postaci skompresowanej, ko cz c na zdolno ci algorytmu kompresji do zachowania relacji pomi dzy obrazami oryginalnymi, r ownie  po stronie ich skompresowanych odpowiednik w. W naszych rozwa aniach u yjemy jednak innego kryterium oceny przedstawionych w artykule algorytm w kompresji. B dzie nim zdolno   systemu wyznaczenia pozycji okr tu do okre lenia dok adnego po o enia jednostki na podstawie obraz w radarowych skompresowanych sieci  GRNN.




Rys. 1. Schemat systemu pozycjonowania okr t w

SIE  GRNN

Sie  Kohonena ma ograniczony zbi r warto ci, kt re jest nam w stanie zwr ci . Jest nim zbi r indeks w lub warto ci liczbowych skojarzonych z ka dym z neuron w. W przypadku kiedy na wej ciu sieci pojawi si  obraz, sie  zwr ci nam wielko   zwi zan  z neuronem najbardziej podobnym temu obrazowi. Im wi cej

neuronów będzie w sieci, tym stopień dokonywanego przez nią uogólnienia będzie mniejszy, a skompresowany obraz po dekompresji bardziej podobny do oryginału. Sieć GRNN natomiast zamiast wartości skojarzonej z neuronem najbardziej podobnym zwróci nam wartość adekwatną do stopnia podobieństwa obrazu wejściowego do poszczególnych neuronów sieci.



Rys. 2. Zasada działania sieci GRNN w kompresji obrazów [5]

Kompresująca sieć GRNN może zostać zbudowana w oparciu o informację zawartą w sieci Kohonena. Pary (x, y) ciągu uczącego sieci GRNN będą zawierały w tym wypadku neurony sieci Kohonena jako obrazy x oraz wartości skojarzone z każdym z neuronów tej sieci (indeks neuronu lub wartość wyznaczoną za pomocą odwzorowania Sammona) jako parametry.


Budując sieć GRNN, możemy się również oprzeć bezpośrednio na obrazach (segmentach obrazu) umieszczonych w ciągu uczącym, zupełnie pomijając etap budowy sieci Kohonena. W tym celu należy, posługując się odwzorowaniem Sammona, przyporządkować każdemu z obrazów uczących wartość liczbową lub wektor 2-, 3-wymiarowy, a następnie skonstruować na podstawie uzyskanych w ten sposób par uczących (x, y) sieć GRNN.

EKSPERYMENTY NUMERYCZNE

Sieć GRNN została przebadana pod względem możliwości jej zastosowania jako podsystemu kompresji obrazów radarowych w systemie pozycjonowania okrętów na morzu. Sieć GRNN odgrywała również rolę podsystemu aproksymacji.

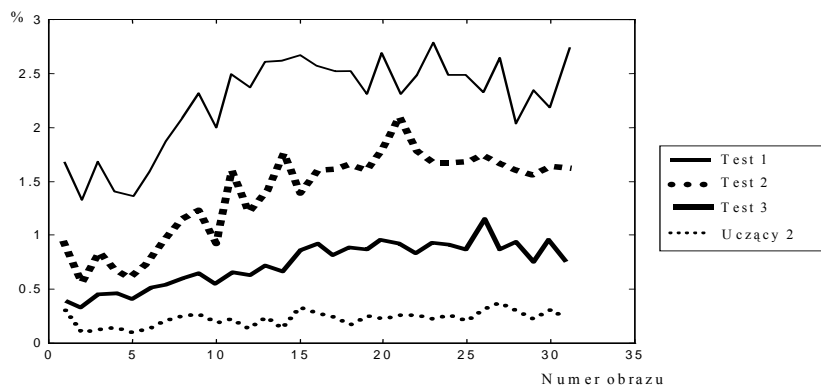
Do badań wykorzystano oryginalne obrazy radarowe sprowadzone do wielkości 100*100 pikseli. Wszystkie poddane zostały procesowi segmentacji. Każdy z nich podzielono na 100 równej wielkości segmentów o rozmiarach 10*10 pikseli.

Eksperymenty przeprowadzono z wykorzystaniem dwóch ciągów uczących oraz trzech ciągów testujących. Ciągi testujące oraz jeden z ciągów uczących zostały skonstruowane poprzez stopniowe zniekształcenia pierwotnie zarejestrowanego ciągu uczącego nr 1.



Rys. 3. Przykładowe obrazy radarowe wykorzystywane podczas badań

Każdy z ciągów miał jednakową liczbę obrazów radarowych – 31 obrazów (100*31 segmentów – dokładnie 3100 obrazów uczących wielkości 10*10 pikseli). Obrazy o tych samych indeksach w każdym z ciągów odpowiadały tej samej pozycji okrętu. Odległość pomiędzy kolejnymi rejestracjami poszczególnych obrazów radarowych wynosi ok. 600 m. Dalej przedstawiono różnice w procentach pomiędzy obrazami ciągu uczącego nr 1 („obrazu matki”) a obrazami ciągu uczącego nr 2 oraz obrazami z ciągów testujących.



Rys. 4. Różnice pomiędzy obrazami podstawowego ciągu uczącego (ciągu uczącego nr 1) a obrazami z ciągów testujących oraz z ciągu uczącego nr 2

Najmniejsze różnice występują pomiędzy pierwszym ciągiem uczącym a ciągiem uczącym nr 2. Najbardziej zniekształcony w stosunku do pierwszego ciągu uczącego jest ciąg testujący nr 3.

Ciąg uczący nr 1 jest podstawowym ciągiem występującym podczas procesu uczenia sieci Kohonena (potrzebnej przy konstrukcji kompresującej sieci GRNN), a także sieci GRNN (kompresującej podsystem kompresji oraz aproksymującej podsystem aproksymacji położenia). W przypadku obu sieci GRNN konieczne było zastosowanie jeszcze jednego ciągu uczącego, z pomocą którego przeprowadzono ostateczną optymalizację ich struktury. W przypadku sieci GRNN kompresującej wybrano taką jej konfigurację, która zapewniała najmniejsze różnice pomiędzy generowanymi przez nią wektorami skompresowanymi odpowiadającymi obrazom z ciągu uczącego nr 2 a wektorami skompresowanymi uzyskanymi z odpowiedniej sieci Kohonena podczas prezentowania jej tych samych obrazów co jej poprzedniczce – obrazów z ciągu uczącego nr 2. Dokładne poszukiwania optymalnej struktury kompresującej sieci GRNN polegały na wykonaniu następującej sekwencji czynności:

1. Nauczanie sieci Kohonena za pomocą ciągu uczącego nr 1.
2. Organizacja neuronów nauczonej sieci Kohonena zgodnie z odwzorowaniem Sammona – przyporządkowanie poszczególnym neuronom odpowiadających im wektorów 2- i 3-liczbowych.
3. Budowa sieci GRNN w oparciu o neurony sieci Kohonena.
4. Optymalizacja struktury każdej sieci GRNN z użyciem ciągu uczącego nr 2.

Strukturę sieci GRNN aproksymującej wybrano tak, aby generowany przez nią błąd maksymalny podczas pracy z ciągiem uczącym nr 2 był jak najmniejszy. Budowa optymalnej struktury sieci GRNN aproksymującej wymagała wykonania następujących kroków:

1. Budowa sieci GRNN na podstawie skompresowanego ciągu uczącego nr 1 (dwie sieci – pierwsza sieć dla parametru długości geograficznej φ , druga do wyznaczenia szerokości geograficznej λ).
2. Optymalizacja obydwu sieci z wykorzystaniem ciągu uczącego nr 2.

Podczas badań poddano testom następujące sieci kompresujące:


- sieć GRNN 2- i 3-wyjściowa dla 5, 10, 20 i 50 neuronów.

W przypadku sieci Kohonena z uporządkowanymi neuronami nie udało się uzyskać struktury zawierającej więcej niż 50 neuronów dla 2 i 3 wyjść. Jest to spowodowane brakiem sukcesów w poszukiwaniu odpowiedników 2- i 3-rozmiarowych dla 75 i więcej egzemplarzy neuronów sieci Kohonena o 100 składowych (segment obrazu 10*10 pikseli). Jako że sieć GRNN była budowana z neuronów sieci Kohonena o uporządkowanej strukturze, również w tym przypadku ograniczono się do badań z siecią 5-, 10-, 20- i 50-neuronową.


Sieć GRNN aproksymująca zbudowana była z 31 neuronów odpowiadających skompresowanym obrazom z ciągu uczącego nr 1. W przypadku sieci kompresującej 2-wyjściowej (1 neuron – 2 wyjścia) były to neurony o 200 składowych (1 segment – 2 wartości, 100 segmentów – 200 wartości), a dla sieci kompresującej o 3 wyjściach neurony o 300 składowych.

WYNIKI EKSPERYMENTÓW NUMERYCZNYCH

W trakcie badań sprawdzono wpływ wielkości sieci, liczby wyjść każdej z nich oraz zakłóceń na dokładność generowanej pozycji. Pierwsze dwa wykresy prezentują wpływ liczby neuronów oraz wielkości wyjścia sieci na błąd średni oraz maksymalny wyznaczonej pozycji otrzymany dla wybranego ciągu testującego. W dalszej części przedstawiono zdolności uogólniające sieci GRNN, a więc odporność systemu na dane z różnym poziomem odchylenia od obrazów uczących.



Rys. 5. Błąd średni wyznaczonej pozycji w zależności od liczby neuronów i wielkości wyjścia (badania przeprowadzone z ciągiem testującym nr 1)




Rys. 6. Błąd maksymalny wyznaczonej pozycji w stosunku do liczby neuronów i wielkości wyjścia (badania przeprowadzone z ciągiem testującym nr 1)


Badania pokazują, że zwiększanie liczby neuronów powoduje coraz większą łatwość systemu aproksymacji w wyznaczeniu właściwej pozycji okrętu. Przy małej liczbie neuronów (5 neuronów) system charakteryzuje się bardzo dużym błędem średnim oraz maksymalnym. Błąd pozycji dla sieci 10-neuronowej jest już nieporównywalnie mniejszy.

Wykresy prezentują również wpływ ilości informacji wyjściowej uzyskiwanej z podsystemu kompresji na dokładność wyznaczonej pozycji. Większa liczba danych płynących do podsystemu aproksymacji wpływa z jednej strony na mniejszy

błąd generowanej przez niego pozycji, z drugiej zaś powoduje dłuższy czas działania tej części systemu pozycjonowania. Należy jednak zaznaczyć, że idealną dokładność wyznaczonej pozycji otrzymaliśmy dla sieci kompresującej 3-wyjściowej przy 10-neuronowej strukturze, a dla sieci 2-wyjściowej dopiero przy 50 neuronach. Można z tego wnioskować, że do uzyskania takiej samej dokładności pozycji potrzebujemy większej sieci 2-wyjściowej niż 3-wyjściowej, a to z kolei oznacza mniejszy czas przetwarzania na etapie kompresji dla sieci 3-wyjściowej mogący zrekompensować dłuższy czas przeprowadzanych obliczeń w fazie aproksymacji dla takiej struktury sieci kompresującej.



Rys. 7. Błąd średni wyznaczonej pozycji w stosunku do liczby neuronów dla trzech ciągów testujących dla sieci 2-wyjściowych



Rys. 8. Błąd maksymalny wyznaczonej pozycji w stosunku do liczby neuronów dla trzech ciągów testujących dla sieci 2-wyjściowych

Badania pokazują negatywny wpływ wielkości zakłóceń wprowadzonych do obrazów wejściowych. Im większe różnice pomiędzy obrazem testującym a jego reprezentantem w ciągu uczącym, tym gorsze wyniki i większa liczba neuronów potrzebna do uzyskania określonej dokładności pozycji okrętu. Dla ciągu testującego nr 3 charakteryzującego się największymi odchyleniami od swojego pierwowzoru (ciągu uczącego nr 1) żadna struktura sieci nie była w stanie zniwelować różnic pomiędzy poszczególnymi obrazami i umożliwić systemowi aproksymacji precyzyjne wyznaczenie pozycji okrętu.

PODSUMOWANIE

Niniejszy artykuł przedstawia problem kompresji obrazu radarowego i proponuje rozwiązanie go za pomocą sztucznych sieci neuronowych. Zaprezentowano kompresującą sieć GRNN. Sieć ta jest w stanie sprostać zadaniu ekstrakcji cech z zarejestrowanych obrazów radarowych dużej rozdzielczości. W trakcie przeprowadzonych badań wielokrotnie uzyskano kompresor umożliwiający dokładne wyznaczenie pozycji okrętu na podstawie obrazu uzyskanego z jego radaru nawigacyjnego.

Przeprowadzone eksperymenty oprócz niezaprzeczalnych zalet kompresującej sieci GRNN pokazały również duże trudności w budowie takiej sieci. Wynikają one przede wszystkim z kłopotów podczas tworzenia sieci Kohonena z uporządkowaną strukturą, która jest podstawą konstrukcji sieci GRNN kompresującej.

BIBLIOGRAFIA

- [1] Masters T., *Sieci neuronowe w praktyce. Programowanie w języku C++*, WNT, Warszawa 1996.
- [2] Praczyk T., *Metoda neuronowej identyfikacji źródeł fal radiowych dla potrzeb nawigacji morskiej*, rozprawa doktorska, WSM, Szczecin 2001.
- [3] Specht D. F., *A General Regression Neural Network*, „IDEE Transactions on Neural Networks”, 1996, t. 2, nr 6.
- [4] Stateczny A., *Nawigacja porównawcza*, Gdańskie Towarzystwo Naukowe, Gdańsk 2001.

- [5] Stateczny A., Praczyk T., *Sztuczne sieci neuronowe w kompresji obrazów radarowych*, „Zeszyty Naukowe WSM”, 2002, Szczecin.
- [6] Stateczny A., *Problemy komputerowego wyznaczania pozycji okrętu metodami porównawczymi*, „Zeszyty Naukowe AMW”, 1990, 107A, Gdynia 1990.

ABSTRACT

A picture from a navigation radar can be used to develop a future system for fixing ship position. Pictures obtained from navigation radars usually contain a large amount of information. It is impossible to use all of it in a position fixing system. This is mainly due to limited computation capacities of present day computers. Therefore it becomes necessary to condense information contained in each picture to the size acceptable from the point of view of practical application. Such a result can be obtained by employing methods of extraction of properties from radar pictures recorded. The paper presents one of the extraction methods based on Kohonen self-organizing net and GRNN net.

Recenzent kmdr prof. dr hab. inż. Andrzej Felski