

**WYBRANE PROBLEMY TRANSFORMACJI WSPÓLRZĘDNYCH
Z UKŁADU LOKALNEGO MIASTA SZCZECIN DO UKŁADU 2000
Z WYKORZYSTANIEM NIEKTÓRYCH SIECI NEURONOWYCH**

**SELECTED PROBLEMS OF COORDINATES TRANSFORMATION
FROM LOCAL COORDINATE SYSTEM OF CITY OF SZCZECIN
TO COORDINATE SYSTEM “2000”**

Witold Kazimierski, Krzysztof Beczkowski

Katedra Geoinformatyki, Wydział Nawigacyjny, Akademia Morska w Szczecinie

SŁOWA KLUCZOWE: transformacja współrzędnych, układy lokalne, układ 2000, sztuczne sieci neuronowe, Szczecin

STRESZCZENIE: Artykuł przedstawia zagadnienia związane z wykorzystaniem sztucznych sieci neuronowych do transformacji współrzędnych z układu lokalnego Szczecina do układu „2000”. W kolejnych częściach ujęto syntetyczny opis układu lokalnego miasta Szczecin, podstawy teorii sztucznych sieci neuronowych, a następnie koncepcję i wyniki badań. Przyjęto założenie, że zastosowanie tego narzędzia pozwoli na bezpośrednie znalezienie zależności dla układu empirycznego, jakim jest układ lokalny. Transformacji dokonano na podstawie punktów dopasowania, które stały się przypadkami uczącymi dla sieci neuronowych. Punktami dopasowania były punkty osnowy geodezyjnej I i II klasy z obszaru miasta Szczecin. Analizie poddano trzy struktury sieci, a mianowicie sieci liniowe, perceptron wielowarstwowy oraz sieci radialne. Zadowalające wyniki uzyskano zwłaszcza dla sieci liniowej, dla której następnie zbadano znaczenie długości ciągu uczącego I wielkości obszaru transformacji. Wyniki badań pokazują, że istotny wpływ na jakość dopasowania ma liczebność zbioru uczącego, a właściwie zagęszczenie punktów uczących. Wyniki porównano do rezultatów uzyskanych za pomocą transformacji Helmerta.

1. WPROWADZENIE

Transformacja współrzędnych pomiędzy układami lokalnymi, a układem „2000” jest problemem często spotykanym podczas realizacji prac geodezyjnych i kartograficznych. Duża część zasobu geodezyjno-kartograficznego i dostępnych opracowań, z których czerpane są dane w różnego rodzaju opracowaniach kartograficznych i geoinformatycznych została opracowana w „starych” układach („1965”, lokalne). Powstaje zatem konieczność ich transformacji do „nowych” („2000”, „1992”) obecnie używanych. Tradycyjnie stosowaną do tego celu metodą, uwzględnioną również przez Wytyczne Techniczne G-1.10, jest konforemna transformacja Helmerta uzupełniona o korektę post-transformacyjną Hausbrandta, która pozwala na zachowanie istniejących współrzędnych katalogowych układów empirycznych. Opracowane szczegółowo algorytmy tych obliczeń pozwalają na osiągnięcie dokładności wymaganych dla prac geodezyjno-kartograficznych. Należy tu zwrócić uwagę na konieczność wprowadzania poprawek wynikających z różnic pomiędzy teoretycznymi

układami współrzędnych, wyznaczonymi na podstawie obliczeń oraz ich empirycznymi odpowiednikami, określonymi na podstawie pomiarów (Kadaj, 2005). Numeryczne algorytmy transformacji mogą być rozwijane w różnych kierunkach. Jednym z przykładów może być zastosowanie metod tzw. m-estymacji, które mają wyeliminować problem błędów grubych, nieuwzględnianych w transformacji Helmerta (Janicka, 2008).

Alternatywnym podejściem do problemu transformacji może być wykorzystanie metod sztucznej inteligencji, które stosowane są coraz powszechniej np. do rozpoznawania obrazów, analizy danych, czy modelowania powierzchni. Jedną z gałęzi sztucznej inteligencji są sztuczne sieci neuronowe. Są to algorytmy matematyczne, które z założenia mają naśladować sposób rozumowania ludzkiego umysłu. Zaletą takiego podejścia jest bezpośrednio znajdowanie zależności pomiędzy układami empirycznymi. Idea pracy sieci zakłada złożenie wielu prostych operacji wykonywanych równolegle. Ta koncepcja stanowi o potencjale sztucznych sieci neuronowych, jako narzędzia do rozwiązywania wielu problemów, np. regresyjnych. Takim problemem, w zastosowanym podejściu, staje się zagadnienie transformacji współrzędnych. Sieć ma za zadanie wyznaczyć parę nieznaną współrzędnych (układu wtórnego) na podstawie współrzędnych zadanych (układu pierwotnego). Koncepcja taka była już prezentowana w literaturze krajowej i międzynarodowej, np. w pracy (Mrówczyńska, 2009), w której uzyskano interesujące wyniki przy zastosowaniu perceptronu wielowarstwowego i sieci neuro-rozmytych TSK. Innymi przykładami może być wykorzystanie sieci o radialnych i sigmoidalnych funkcjach aktywacji do transformacji współrzędnych w państwowych układach współrzędnych innych krajów, przedstawione w (Zaletnyik, 2004) lub w (Gullu, 2010).

W badaniach prezentowanych w niniejszym artykule, oprócz percepcora oraz sieci RBF, zaproponowano również wykorzystanie liniowej sieci neuronowej, przy uwzględnieniu stosunkowo niedużego zbioru uczącego. Terytorialnie ograniczono się bowiem do obszaru miasta Szczecin, a jako wzorce wykorzystano tylko punkty osnowy I i II klasy. Eksperyment miał charakter badań wstępnych, a ich celem było określenie, czy istnieje potencjał do dokładniejszej analizy proponowanego podejścia w dalszych etapach. Docelowo w dalszych pracach ma powstać skryptowe narzędzie zaimplementowane w oprogramowaniu GIS pozwalające na transformację współrzędnych na podstawie punktów dopasowania wskazanych przez użytkownika lub na podstawie wartości domyślnych. Wskazuje się przy tym na szerokie zastosowanie geoinformatyczne, niekoniecznie do prac geodezyjnych. Badania przeprowadzono z wykorzystaniem programu Statistica Neural Network, a także autorskich aplikacji w VB.Net. Analizy statystycznej dokonano w oprogramowaniu MS Excel.

W pierwszej części artykułu scharakteryzowano zwięźle układ lokalny miasta Szczecin. W dalszej kolejności, po wstępnym sformułowaniu problemu przedstawiono krótko koncepcję funkcjonowania sieci neuronowych, założenia oraz wyniki badań. Całość zakończono wnioskami i uwagami końcowymi.

2. UKŁAD LOKALNY MIASTA SZCZECIN

W latach pięćdziesiątych XX wieku dla większych polskich miast założono tzw. układy lokalne, które były podstawą do prowadzenia wielkoskalowych map gospodarczych. Podobnie było również w Szczecinie.

Układ lokalny miasta Szczecin powstał na skutek rozwoju miasta w latach 1956–1957 i został zrealizowany przez Państwowe Przedsiębiorstwo Geodezyjne – praca zarejestrowa-

wyrównaniem założono bazę pomiarową, stanowiącą bok sieci głównej – Ostoja-Warzymice. Istniejąca sieć główna i szczegółowa została wyrównana ściśle, na podstawie nowych obserwacji. Natomiast w celu ujednoczenia układu współrzędnych, duży szereg punktów pomiarowych, które nie brały udziału w wyrównaniu zostały przetransformowane.

Wyrównanie całej sieci opracowano w nawiązaniu do 6 punktów triangulacji niemieckiej z 1899 roku, przyjmując różne błędy położenia tych punktów (od 10 cm do 30 cm), w zależności od usytuowania. Były to punkty Bezzecze, Warszewo, Gołęcino, Dąbie, Klucz, Siadło Górne (Rys. 1). Dla dwóch punktów – wieże kościelne (Gołęcino i Dąbie) – przyjęto większe błędy położenia (30 cm) ze względu na to, iż punkty te, jako budowle stałe (wieże) mogły ulec w czasie zmiany położenia, na skutek działań wojennych i ewentualnych remontów. Poparte to zostało również wcześniejszą transformacją współrzędnych przybliżonych do punktów pomiarowych.

W celu dowiązania nowopowstałej sieci do układu niemieckiego wyrównanego w odniesieniu do południka Bania I w odwzorowaniu Soldnera, przeliczono współrzędne na płaszczyznę Gaussa-Krugera, w tym samym południku odwzorowawczym. Ponadto, dla sieci głównej zredukowano wszystkie kąty na płaszczyznę odwzorowania, oraz pomierzoną linię bazową (Ostoja-Warzymice). Obserwacji sieci szczegółowej nie zredukowano na płaszczyznę Gaussa-Krugera, ze względu na zmniejszenie pracochłonności oraz zaniechywalną różnicę wyników.

Na powstałym terenie znajdował się szereg punktów osnowy pomiarowej, dlatego też wykonano transformację współrzędnych ponad 450 różnych punktów osnowy, w oparciu o współczynniki transformacji:

- współczynnik skrętu: - 0.000 020 1878
- współczynnik zmiany skali z: - 0.000 010 8919
- przesunięcie X0: + 0.698
- przesunięcie Y0: + 0.545

oraz dodatkowo wykonano interpolację graficzną w celu wyeliminowania odchyłek na punktach łącznych. Średni błąd transformacji wyniósł 10 cm.

Współrzędne wyrównane przedstawiono w lokalnym układzie odniesienia Banie I na płaszczyźnie Gaussa-Krugera. Zaś w celu uniknięcia ujemnych wartości do współrzędnych Y dodana została wartość + 100 000.00 m (MODGiK Szczecin, 1956). W 1966 sieć osnowy została zagęszczona i ponownie wyrównana.

Układ miasta Szczecin, podobnie jak inne lokalne układy współrzędnych był stosowany do opracowań wielkoskalowych równoległe z obowiązującym układem państwowym, jako układ podstawowy dla prac kartograficzno-geodezyjnych.

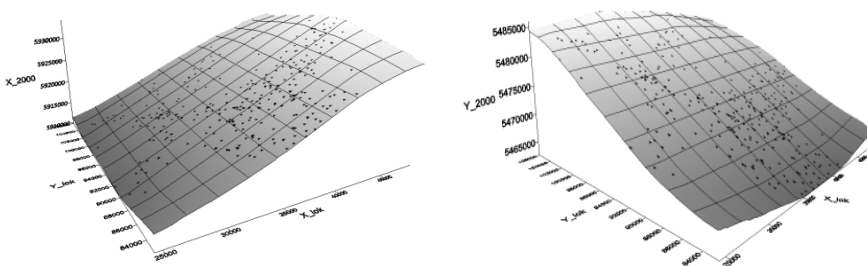
3. SFORMUŁOWANIE PROBLEMU BADAWCZEGO

Wprowadzenie układu 2000 wymusiło potrzebę opracowania jednoznacznych związków transformacyjnych do konwersji zasobów geodezyjno-kartograficznych z układów lokalnych. Zwykle przyjmowaną metodyką jest znalezienie związków transformacyjnych pomiędzy układem lokalnym, a układem 1965. Związki pomiędzy układem 1965, a układem 2000 są bowiem znane i opublikowane (Kadaj, 2002). W powszechnie stosowanej metodyce (zalecanej przez GUGiK) związki transformacyjne wyznaczane są na podstawie tzw. punktów dostosowania metodami numerycznymi.

Punkty dostosowania to punkty posiadające współrzędne wyznaczone niezależnie w obu układach – w analizowanym przypadku w układzie lokalnym miasta Szczecin (x_{lok} , y_{lok}) oraz układzie 2000 (x_{2000} , y_{2000}). Istotą transformacji jest więc znalezienie funkcji wektorowej f , takiej, że

$$[x_{2000}, y_{2000}] = f([x_{lok}, y_{lok}]) \quad (1)$$

Transformację taką można także zrealizować za pomocą sztucznych sieci neuronowych. Pary punktów o znanych współrzędnych będą w tym przypadku wzorcami, na podstawie których zostanie przeprowadzone uczenie sieci. Nacisk w tym podejściu położony jest nie na znalezienie funkcji, ale na efektywne wyznaczanie transformowanych współrzędnych przy pomocy narzędzia, jakim jest sztuczna sieć neuronowa. Dla każdej współrzędnej sieć będzie starała się znaleźć możliwie dobrą powierzchnię odpowiedzi. Na rysunku 2 przedstawiono zależności pomiędzy współrzędnymi w różnych układach w postaci powierzchni trójwymiarowej. Na powierzchniach zaznaczono także położenie punktów I i II klasy osnowy geodezyjnej. Należy zauważyć, że transformacja z wykorzystaniem sieci neuronowych nie jest przekształceniem konforemnym.



Rys. 2. Zależność współrzędnych w układzie 2000 od współrzędnych w układzie lokalnym

Bardzo istotną kwestią przy bezpośredniej transformacji współrzędnych prostokątnych płaskich jest dobór punktów dostosowania. Dla transformacji zasobów geodezyjno-kartograficznych wymagania odnośnie ich doboru, jak również zalecenia związane z samą transformacją można znaleźć w Wytycznych Technicznych G-1.10 (GUGiK, 2000). Opisane są tam szczegółowo zwłaszcza zagadnienia związane z transformacją współrzędnych z empirycznego układu 1965 do układu 1992. W myśl wytycznych lokalne transformacje korekcyjne powinny być liniowymi transformacjami konforemnymi Helmerta, uzupełnionymi w większości wypadków o korektę posttransformacyjną Hausbrandta. Wytyczne podają szczegółowo rozkład i ilość punktów dostosowania w zależności od żądanej dokładności transformacji. Koncepcja przyjęta w artykule zakłada, że punkty dostosowania mogą być wskazane przez użytkownika GIS, który może nie znać lub nie stosować się do wytycznych.

4. SZTUCZNE SIECI NEURONOWE

Sztuczne sieci neuronowe to obok logiki rozmytej, systemów eksperckich i algorytmów genetycznych jeden z filarów inteligencji obliczeniowej. Metody tej grupy rozwinęły się w drugiej połowie XX wieku. Podstawy powstały już w latach czterdziestych, ale prawdziwy rozkwit nastąpił począwszy od lat osiemdziesiątych, kiedy to możliwości

obliczeniowe komputerów pozwoliły na znaczący rozwój. Od tamtego czasu pojawiła się znaczna liczba różnego rodzaju struktur neuronowych, algorytmów uczących, a także sposobów ich wykorzystania.


Koncepcja pracy sztucznych sieci neuronowych ma w swych założeniach naśladować pracę ludzkiego mózgu. Proste elementy przetwarzające (neurony) grupowane są w tzw. warstwy, a następnie łączone ze sobą w odpowiedni sposób. Każde połączenie ma przypisaną wagę, a każdy neuron dokonuje sumowania ważonych sygnałów neuronów z warstwy poprzedniej oraz realizuje założone przekształcenie funkcyjne (tzw. funkcja aktywacji). W efekcie na wyjściu sieci uzyskiwany jest sygnał będący złożeniem wielu prostych operacji wykonywanych równoległe (Rutkowski, 2006). Sieć, podobnie jak człowiek, żeby znajdować prawidłowe odpowiedzi musi się najpierw nauczyć. Sama struktura sieci, nie poddana procesowi uczenia jest bezużyteczna. Dla poszczególnych sieci opracowano szereg algorytmów realizujących proces uczenia.

Istotnym atutem sieci jest stosunkowa łatwość użycia. W praktyce same one konstruują potrzebne użytkownikowi modele poprzez automatyczne uczenie się na podanych przez niego przykładach (Duch i in., 2000). Niemniej jednak przestrzec należy przed traktowaniem sztucznych sieci neuronowych jako metody dobrej do rozwiązania wszystkich problemów. W praktyce osiągnięcie żądanej dokładności nie zawsze jest możliwe i nie każdy problem da się rozwiązać z wykorzystaniem sztucznych sieci neuronowych z zadowalającą jakością. Sieci mimo swoich zalet są modelami stosunkowo złożonymi. Należy pamiętać, że jeżeli istnieje możliwość rozwiązania problemu prostszym modelem w zadowalający sposób, warto właśnie ten model zastosować.

W badaniach przedstawianych w artykule wykorzystane zostały trzy struktury sieciowe – sieć liniowa, perceptron wielowarstwowy oraz sieć radialna.

4.1. Sieci liniowe

Sieci liniowe są przykładem zastosowania struktury sieciowej do zaimplementowania algorytmu matematycznego, który można rozwiązać również poprzez bezpośrednie obliczenia numeryczne. W tym przypadku chodzi o aproksymację funkcji za pomocą modelu liniowego. Jest on zwykle przedstawiany w postaci macierzowej, a efektem działania tego algorytmu ma być znalezienie właściwego położenia i właściwego nachylenia hiperpłaszczyzny odwzorowującej dane. Neuronowa implementacja modelu liniowego to sieć nie posiadająca warstw ukrytych, zaś wszystkie neurony w warstwie wyjściowej są w pełni liniowe (Lula i Tadeusiewicz, 2001). Schemat takiej sieci, wykorzystanej w badaniach przedstawiono na rysunku 3.




Rys. 3. Schemat liniowej sieci neuronowej

Sieci liniowe stanowią dobry punkt odniesienia, z którym porównuje się jakość innych sieci neuronowych. Jest bowiem możliwe, że problem, który uważany był za bardzo złożony, może zostać w rzeczywistości rozwiązany równie dobrze przez sieć liniową, zamiast przez którąś z bardziej skomplikowanych struktur (Lula i Tadeusiewicz, 2001).

4.2. Perceptron wielowarstwowy

Perceptron wielowarstwowy to najpopularniejsza i najczęściej wykorzystywana struktura sztucznej sieci neuronowej. Jest klasyczną siecią jednokierunkową, w której sygnał jest przesyłany od wejścia do wyjścia przez wszystkie warstwy po kolei. Neurony w warstwie nie mają połączeń między sobą, są za to połączone z wszystkimi neuronami warstwy poprzedniej i następnej. Każdy z neuronów oblicza ważoną sumę swoich wejść, która staje się argumentem funkcji aktywacji (zwykle jest to funkcja sigmoidalna), dając wartość wyjściową neuronu. Sieć można interpretować jako model typu wejście – wyjście, którego parametrami są wagi oraz wartości progowe. Sieć taka może modelować – przy odpowiedniej liczbie warstw i neuronów – funkcję o prawie dowolnej złożoności (Duch i in., 2000). Schemat perceptronu wielowarstwowego przedstawiono na rysunku 4.



Rys. 4. Schemat perceptronu wielowarstwowego

Kluczowymi etapami w pracy z perceptronem wielowarstwowym są określenie prawidłowej liczby warstw i neuronów, a następnie uczenie sieci. Opracowano w tym celu szereg algorytmów, które powszechnie stosowane są w wielu aplikacjach.

W badaniach wykorzystano perceptron składający się z trzech warstw, przy czym w warstwie ukrytej umieszczono 13 neuronów z sigmoidalną funkcją aktywacji. Sama struktura sieci została zaproponowana w wyniku analizy pracy automatycznego projektanta sieci w programie Statistica Neural Network (SNN). Etap uczenia sieci był realizowany ręcznie z wykorzystaniem algorytmów zaimplementowanych w SNN. Zastosowano najpopularniejszy algorytm wstecznej propagacji błędów. Do zatrzymania sieci przedstawiono warunek dopuszczalnego błędu RMSE (0,01 m), który nie został osiągnięty oraz wymaganego polepszenia (0,01 m) w 100 epokach, który spowodował zatrzymanie algorytmu uczącego.

4.3. Sieci radialne


Struktura sieci radialnych nie różni się w zasadzie od perceptronu wielowarstwowego. Zasadniczą różnicą są tutaj zastosowane funkcje aktywacji neuronów. Zamiast powszechnych w perceptronach funkcji sigmoidalnych wykorzystywane są funkcje radialne. Zmienia to istotę rozwiązywania problemu. Przestrzeń odpowiedzi zamiast na hiperpłaszczyźnie dzielona jest na hipersfery. W wielu przypadkach może to się okazać korzystniejsze. Sieci RBF mogą modelować dowolną funkcję nieliniową za pomocą pojedynczej warstwy ukrytej, a uczą się dużo szybciej od perceptronów (Lula i Tadeusiewicz, 2001).

Sieć zastosowana w badaniach zawierała 12 neuronów radialnych w warstwie ukrytej. Strukturę zaproponowaną przez automatycznego projektanta uczono ręcznie dobierając parametry. Centra dobrano za pomocą metody próbkowania radialnego, zaś współczynnik wygładzania dobrano ręcznie minimalizując błąd RMSE. Również zastosowanie algorytmu pseudoinwersji w warstwie wyjściowej spowodowało poprawę jakości pracy sieci.

5. KONCEPCJA BADAŃ

W proponowanym podejściu sieć ma za zadanie wyznaczyć parę współrzędnych (układu wtórnego) na podstawie współrzędnych zadanych (układu pierwotnego). W tym celu konieczne jest przeprowadzenie uczenia sieci, które jest niezbędnym elementem filozofii pracy z sieciami neuronowymi. Etap ten następuje już po określeniu struktury sieci. Na wejście i wyjście sieci podawane są wartości wzorcowe, zwane przykładami uczącymi. W omawianym przypadku będą to współrzędne punktów dopasowania w układzie pierwotnym (na wejściu) i wtórnym (na wyjściu). Proces uczenia polega na takim dobraniu (zgodnie z przyjętym algorytmem uczenia) wag połączeń i wartości progowych neuronów, aby uzyskana przez sieć wartość wyjściowa była możliwie bliska wartości wzorcowej. Po wyczerpaniu całego zbioru uczącego następuje etap testowania sieci poprzez podanie jej znanych przykładów spoza zbioru uczącego. Jeśli wyniki są zadowalające sieć jest gotowa do pracy.

Badania przeprowadzono z wykorzystaniem 336 punktów osnowy geodezyjnej I i II klasy określonych niezależnie w układzie lokalnym miasta Szczecin oraz w układzie 2000. Dane pozyskano z MODGiK w Szczecinie. Punkty osnowy podstawowej zostały wyrównane w oparciu o punkty osnowy POLREF, założone w nawiązaniu do europejskiej sieci geodezyjnej ETRF oraz EUREF-POL. W oparciu o współrzędne sieci podstawowej I klasy zostały obliczone, metodą ścisłego wyrównania, współrzędne osnowy II klasy. Wyrównanie przeprowadzono w układzie 1992 a następnie współrzędne przeliczono matematycznie do układu 2000.



Rys. 5. Rozkład punktów zbioru uczącego (osnowa I i II klasy)

Podczas wyrównania osnowy I i II klasy wykorzystano wszelkie dotychczas istniejące materiały (obserwacje) z układu 1942 i układu 1965. Ze względu na czasochłonność nie przeprowadzono nowych pomiarów terenowych.

W zależności od wariantu badań, zbiór uczący składał się z różnej ilości przykładów – od 50 do 300. Warto zwrócić uwagę, że jest to stosunkowo niewielki zbiór danych uczących. Przy powierzchni analizowanego obszaru ponad 300 km², nawet dla największego zbioru uczącego jeden punkt reprezentował sobą obszar ponad 1 km². Rozkład punktów zbioru uczącego na obszarze miasta Szczecin przedstawiono na rysunku 5. Badania przeprowadzono dla różnych wielkości ciągów uczących i różnych obszarów miasta.

6. WYNIKI BADAŃ

W pierwszym etapie badań porównano wyniki transformacji wykonanej za pomocą trzech różnych struktur sieciowych w ich domyślnej postaci. W tym przypadku wykorzystano wszystkie punkty dostosowania. Zbiór uczący miał 300 elementów, 16 przeznaczono na walidację, zaś 20 punktów zawierał zbiór testowy. Obszar obejmował całe terytorium Szczecina. W tabeli 1 przedstawiono pierwiastek kwadratowy błędu średniokwadratowego (RMSE) dla poszczególnych zbiorów danych i struktur sieciowych oraz dla porównania wyniki uzyskane za pomocą transformacji Helmerta.

Tab. 1. RMSE dopasowania punktów [m] dla różnych struktur sztucznych sieci neuronowych

Zbiór Sieć	Uczący	Walidacyjny	Testowy
Liniowa	0,0128	0,009	0,0123
Radialna (RBF)	0,118	0,122	0,137
Perceptron	0,579	0,528	0,582
Transformacja Helmerta	0,022		0,02

Komentując wyniki zawarte w tabeli należy stwierdzić, że początkowe wyniki dla sieci RBF oraz MLP były dużo gorsze i błąd średniokwadratowy kształtował się na poziomie kilkunastu metrów. Istotne znaczenie dla poprawy wyników miało wprowadzenie normalizacji danych wejściowych, zamiast proponowanych przez SNN metod pre-processingu oraz wydłużenie procesu uczenia. Pozwoliło to na osiągnięcie błędu średniokwadratowego w okolicach 1–1,5 m.

Kolejną poprawę uzyskano usuwając ze zbioru uczącego punkty, których współrzędne po normalizacji znacznie różniły się od siebie w obu układach. Uznano je za błędy grube, znacznie odstające od przyjętego modelu. W przyszłości należy rozważyć wykrywanie błędów grubych za pomocą metod proponowanych np. w (Prószyński i Kwaśniak, 2002). Analiza rozkładu przestrzennego tych punktów wykazała, że znajdują się one przede wszystkim w okolicach jeziora Dąbie, jak również na tzw. Międzyodrzu. Tereny podmokłe oraz obszary wodne spowodowały mniejszą dokładność wyrównania sieci osnowy. Podobne problemy napotkano przy wyrównaniu osnowy przeprowadzonej w latach 1951–1953. Selekcji tych punktów dokonano na podstawie analizy statystycznej rozkładu różnic pozycji z obu układów po normalizacji. Odrzucono wszystkie wartości większe od kwantyla rzędu 0,95, którym okazała się wartość 0,01. Poprawa dokładności transformacji pozwala postawić tezę, że wprowadzenie błędów grubych do zbioru uczącego powoduje, że cała sieć zostanie obciążona pewnym błędem, w wyniku którego całość danych zostanie

błędnie transformowana. Należy dodać, że wyeliminowanie punktów odstających przy realizacji prac pomiarowych, wymaga zwykle pomiaru kontrolnego na punktach odstających lub zagęszczenia istniejącej sieci w miejscach najbardziej odstających lub „wrażliwych” ze względu na konstrukcję sieci. Takie czynności nie były przedmiotem opisywanych badań.

Wyniki pokazane w tabeli 1 są słabsze dla bardziej skomplikowanych struktur sieciowych. Najbardziej zadowolające wyniki, na poziomie centymetrowym, uzyskała sieć liniowa. Sieć radialna i perceptron wielowarstwowy dokonały transformacji z błędem kilkunastu lub kilkudziesięciu centymetrów. Uzyskane z ich wykorzystaniem rezultaty byłyby zadowolające być może dla niektórych zastosowań geoinformatycznych, jednak z pewnością nie do prac geodezyjnych. Należy wszakże zauważyć potencjał tych sieci i możliwość dalszej optymalizacji, zwłaszcza w przypadku perceptronu. Wyniki uzyskane dla sieci RBF są zbliżone do przedstawianych w literaturze.

W tej sytuacji w dalszej części przedstawiono jedynie wyniki dla sieci liniowej. W tabeli 2 ujęto badania nad doбором długości ciągu uczącego, przedstawiając pierwiastek kwadratowy błędu średniokwadratowego dla kilku wielkości ciągu. Dla porównania przedstawiono również wyniki uzyskane w przypadku zastosowania transformacji Helmerta. Dodatkowo zawarto także wyniki po zmniejszeniu terytorialnym obszaru opracowania w rubrykach *port* oraz *lewobrzeże*. Pociągnęło to za sobą automatycznie zmniejszenie zbiorów uczących, jednak pomimo znacznej redukcji ilości przypadków, manewr ten miał pozytywny wpływ na wyniki transformacji. Potwierdza to, że zagęszczenie punktów dopasowania ma zasadniczy wpływ na jakość transformacji. Na mniejszym obszarze, nawet niewielka ilość punktów wystarcza do osiągnięcia zadowolających rezultatów.

Tab. 2. RMSE dopasowania punktów [m] dla różnych zbiorów uczących

Zbiór Ciąg uczący	Uczący	Walidacyjny	Testowy	Transformacja Helmerta	
				Uczący	Testowy
50	2,672	2,249	2,844	0,063	0,073
150	0,0133	0,0135	0,011	0,023	0,02
250	0,0125	0,0129	0,0137	0,022	0,024
300	0,0128	0,009	0,0123	0,023	0,02
Port (20)	0,004	0,0047	0,0053	0,01	0,017
Lewobrzeże (160)	0,0053	0,006	0,0056	0,02	0,019

Wyniki przedstawione w tabeli 2 potwierdzają ogólną tendencję, że im więcej punktów uczących, tym lepsze dopasowanie. Zasadniczy skok jakościowy ma miejsce pomiędzy 50, a 150 przypadkami uczącymi. W tym przedziale błąd spada z ponad 2 metrów do nieco ponad centymetra. Bardzo dobre rezultaty uzyskano po zmniejszeniu obszaru. Dla 160 punktów lewobrzeża błąd jest połowę mniejszy niż dla 150, a nawet 250 punktów rozmieszczonych na całym obszarze. Porównując wyniki uzyskane za pomocą sieci liniowej do algorytmu Helmerta, należy stwierdzić, że kształtują się one na podobnym poziomie (poza przypadkiem „50”). Nie jest to dużym zaskoczeniem, biorąc pod uwagę, że oba algorytmy to w istocie przekształcenia liniowe. Dla większości przypadków sieć liniowa transformowała z błędami nieznacznie mniejszymi, niż algorytm Helmerta.

Najlepsze wyniki uzyskano dla niewielkiego obszaru portu, gdzie już 20 punktów dopasowania wystarczyło na przeprowadzenie transformacji z błędem mniejszym niż 1 cm. Podobne wartości uzyskane dla wszystkich zbiorów świadczą o prawidłowym procesie uczenia.

7. PODSUMOWANIE

W artykule przedstawiono wyniki badań związanych z wykorzystaniem niektórych sztucznych sieci neuronowych do transformacji współrzędnych z układu lokalnego miasta Szczecin do układu „2000”. Eksperyment przeprowadzono z wykorzystaniem różnych struktur sieciowych i różnej wielkości zbiorów danych spośród punktów osnowy geodezyjnej I i II klasy.

Analiza wyników przeprowadzonych badań pozwala na postawienie istotnych wniosków związanych zarówno z samym eksperymentem, jak i z proponowaną koncepcją wykorzystania sztucznych sieci neuronowych do transformacji współrzędnych.

Wśród analizowanych sieci najlepsze rezultaty uzyskano przy zastosowaniu sieci liniowej – były to średnie błędy na poziomie około 0,5–1,5 cm (w zależności od zbioru uczącego). Bardziej skomplikowane struktury sieciowe (RBF i perceptron) popełniły większe błędy – uzyskany błąd zwłaszcza dla perceptronu wielowarstwowego jest większy niż oczekiwano w aspekcie dostępnej literatury, np. (Mrówczyńska, 2009). Warto w tym miejscu jednak zauważyć, że w przytaczanej publikacji autorka wykorzystala zbiór uczący ponad dziesięciokrotnie większy. Zatem to właśnie niewielki zbiór uczący może być wskazywany jako przyczyna słabszych rezultatów. Dalsze badania przeprowadzone dla sieci liniowej pokazały, że zbyt mała ilość przypadków uczących powoduje znaczny spadek jakości transformacji, a zagęszczenie punktów dostosowania i zmniejszenie obszaru analizy poprawia jakość transformacji.

Wyniki badań, szczególnie dla sieci liniowej wydają się być na tyle interesujące, żeby kontynuować tematykę badań w przyszłości. Wskazane są dalsze badania nad optymalizacją struktur sieciowych, w tym programowa implementacja algorytmów uczących. Ciekawe rezultaty może także przynieść implementacja w strukturę sieci rozróżnienia dokładności danych uczących (I i II klasa). Inną alternatywą jest opracowanie kaskadowej sieci, w której pierwszy stopień wybierałby ze zbioru punktów uczących najbliższe dla szukanego przypadku, a drugi stopień realizowałby transformację. Takie podejście kaskadowe pozwoliłoby na zagęszczenie punktów uczących poprzez terytorialne ograniczenie zbioru uczącego. Punkty bliskie powinny bowiem mieć największy wpływ na estymację współrzędnych w danym punkcie.

Wydaje się wskazane opracowanie testowego zbioru punktów pozwalającego na szczegółowe badanie różnych algorytmów transformacji neuronowej. Taki zbiór symulacyjny, w przeciwieństwie do danych rzeczywistych, może być dowolnie modelowany w zależności od przyjętej koncepcji badań.

8. LITERATURA

Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R., *Sieci neuronowe*. Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.

GUGiK, *Wytyczne Techniczne G-1.10. Formuły odwzorowawcze i parametry układów współrzędnych*. GUGiK, 2000.

Gullu M., *Coordinate transformation by radial basis function neural network*, Scientific Research and Essays Vol. 5(20), Academic Journal, 2010.

Janicka J., *Transformacja współrzędnych z zastosowaniem wybranych metod m-estymacji*, Czasopismo techniczne, z. 2-Ś, Wydawnictwo PK, 2008.

Kadaj R.J., *Polskie układy współrzędnych. Formuły transformacyjne, algorytmy i programy*, <http://www.geonet.net.pl/>, Rzeszów 2002.

Kadaj R. J.: „*Problematyka przekształceń zasobów geodezyjnych i kartograficznych do układu „2000”*”. I Ogólnopolska Konferencja Naukowo-Techniczna „Kartografia numeryczna i informatyka geodezyjna”, Rzeszów 2005.

Lula P., Tadeusiewicz R., *Wprowadzenie do sieci neuronowych*. Statsoft Polska, Kraków, 2001.

MODGiK Szczecin, *Triangulacja miasta Szczecina. Operat techniczny KERG 63/56*, w Miejskim Ośrodku Dokumentacji Geodezyjnej i Kartograficznej w Szczecinie, 1956.

Mrówczyńska M., *Eksperyment numeryczny przekształcenia układu współrzędnych za pomocą sieci neuronowych i systemów neuronowo rozmytych*, Przegląd Geodezyjny nr 12, 2009.

Prószyński W., Kwaśniak M., *Niezawodność sieci geodezyjnych*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2002.

Rutkowski L., *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2006.

Zaletnyk P., *Coordinate Transformation with Neural Networks and with Polynomials in Hungary*, Proceedings of International Symposium on Modern Technologies, Education and Professional Practice in Geodesy and Related Fields, Sofia, Bulgaria, 2004.

SELECTED PROBLEMS OF COORDINATES TRANSFORMATION FROM LOCAL COORDINATE SYSTEM OF CITY OF SZCZECIN TO COORDINATE SYSTEM “2000”

KEY WORDS: coordinates transformation, local coordinate systems, artificial neural networks, polish coordinate system “2000”, Szczecin

SUMMARY: The paper presents selected issues about using of artificial neural networks for coordinates transformation from local coordinate system of city of Szczecin to system „2000”. The description of local system of Szczecin itself and the basics of artificial neural networks are given in the first parts of paper. Then the concept and the results of the research are included. The assumption has been made, that using of neural networks would allow finding of direct relationships for the empirical system like local system. The transformation has been made based on points of adjustment, which has been introduced as a teaching sequence to neural network. These points have been chosen from gravimetric frame of I and II class in the area of Szczecin. The analysis has been made for three structures of neural networks – linear networks, multilayer perception and radial basis network. Especially satisfactory results have been achieved for the linear network and for this network further research on the influence of teaching sequence length and the area has been made. The results shows that the number of teaching points and the density of them has an important influence on such a transformation. The results are compared to the values achieved with Helmert transformation.

dr inż. Witold Kazimierski
w.kazimierski@am.szczecin.pl

mgr inż. Krzysztof Beczkowski
k.beczowski@am.szczecin.pl