



Marcin Woźniak

Prognoza stopy bezrobocia

na terenie małych jednostek przestrzennych
z wykorzystaniem skrajnie różnych metod

RAPORT Z BADAŃ

CENTRUM DORADZTWA ZAWODOWEGO DLA MŁODZIEŻY
OBSERWATORIUM GOSPODARKI I RYNKU PRACY AGLOMERACJI POZNAŃSKIEJ

POZNAŃ, LIPIEC 2016

Marcin Woźniak¹

Prognoza stopy bezrobocia na terenie małych jednostek przestrzennych z wykorzystaniem skrajnie różnych metod

ABSTRAKT

Celem badania było opracowanie 13 miesięcznej prognozy stopy bezrobocia dla poszczególnych powiatów z terenu województwa Wielkopolskiego i zbadanie jej trafności w porównaniu do danych historycznych. Zakres czasowy prognozy to kwiecień 2015 – kwiecień 2016. W celu osiągnięcia celu badawczego posłużono się dwoma skrajnie różnymi modelami prognostycznymi, które zasilono miesięcznymi danymi za okres styczeń 2005 – marzec 2016 gromadzonymi przez powiatowe urzędy pracy z terenu Wielkopolski.

Badania realizowano od marca 2015 poprzez następujące po sobie zadania badawcze:

- Opracowanie przeglądu literatury przedmiotu oraz zestawienia najważniejszych badań.
- Zebranie danych empirycznych niezbędnych do opracowania prognozy.
- Opracowanie i estymacja dwóch modeli prognostycznych.
- Opracowanie prognozy z wykorzystaniem estymowanych modeli.

Raport niniejszy podsumowuje wyszczególnione powyżej zadania badawcze. Podpunkty *wprowadzenie*, *teoria prognozowania* oraz *przegląd badań* zestawiają kluczowe informacje ze zgromadzonych materiałów źródłowych; podpunkt *dane empiryczne* prezentuje statystyki opisowe i metodykę wstępnej obróbki zgromadzonych danych. W podpunkcie *metodologia badań* znalazło się szczegółowe objaśnienie dotyczące dwóch opracowanych modeli prognostycznych i metod ich estymacji. W podpunkcie tym zaprezentowano również wyniki badań i porównano osiągi modeli w zakresie precyzji prognozy. Całość raportu kończy *podsumowanie*.

Raport jest skierowany przede wszystkim do osób zainteresowanych sytuacją gospodarczą na terenie aglomeracji poznańskiej, a także decydentów chcących kreować opartą na dowodach politykę rynku pracy. Adresatami badań są również ekonomiści, dla których zaprezentowane podejście badawcze może okazać się interesujące.

JEL Classification: R1, J22, C33, C53

¹ Obserwatorium Gospodarki i Rynku Pracy Aglomeracji Poznańskiej oraz Uniwersytet Ekonomiczny w Poznaniu; kontakt: m.wozniak@cdzdm.pl.

Spis treści

Wprowadzenie	4
Teoria prognozowania	7
Przegląd badań.....	8
Dane empiryczne	10
Metodologia badań.....	14
Przestrzenny model wektorowej autoregresji.....	14
Przestrzenny model oparty na sztucznych sieciach neuronowych.....	19
Podsumowanie.....	24
Bibliografia	26

Wprowadzenie

Prognozowanie to jedno z podstawowych zadań ekonomii, które w związku z dużą krytyką, związaną przede wszystkim z błędami oszacowań i małą zdolnością przewidywania szoków gospodarczych zostało odłożone na boczny tor. Jednak tendencja ta ulega powolnemu odwrotowi. Obecnie coraz więcej analiz skupia się zarówno na teoretycznym jak i praktycznym rozwoju oraz implementacji metod i technik prognozowania zmian gospodarczych.

W głównym nurcie ekonomii królują obecnie duże modele gospodarcze, konstruowane zazwyczaj dla poziomu kraju. Tego typu rozwiązania łączą kilka wybranych elementów gospodarki w agregatowy system równań, który w zależności od potrzeb może prognozować przyszłe wartości zmiennych makroekonomicznych (np. PKB, poziom płac, itp.), bądź posłużyć do eksperymentów związanych z testowaniem nowych rozwiązań politycznych. Duże modele makroekonomiczne służą obecnie jako narzędzie doradcze w kreowaniu polityki gospodarczej w takich krajach jak Anglia, Niemcy, USA czy Australia.

Drugie ogniwo analizy ekonomicznej to modele gospodarek lokalnych, które dzięki rozwojowi statystyki publicznej i nowoczesnych technik przetwarzania informacji spełniają podobną rolę, jednak dla mniejszych obszarów (np. regiony, powiaty, miasta). Niestety w odróżnieniu od dużych modeli makroekonomicznych, które bazują często na cykliczności, sezonowości i powtarzalności agregatów zmiennych, modele gospodarek lokalnych muszą uwzględniać skomplikowane procesy i zależności lokalne, które w skali kraju pozostają niezauważalne. Hendry (2001) wskazuje, że jednostki przestrzenne na niskich poziomach agregacji dotyczą następujące zjawiska:

- Fluktuacje sezonowe i zróżnicowanie zmiennych jest znacznie wyższe na poziomie lokalnym niż krajowym.
- Istnieje zjawisko tzw. korelacji przestrzennej pomiędzy sąsiednimi lokalnymi rynkami, które ma wpływ na ich kształtowanie się.
- Procesy ekonomiczne różnią się, często znacznie pomiędzy sąsiadującymi jednostkami przestrzennymi.
- Szoki ekonomiczne, które dotyczą rynków lokalnych są zupełnie inne, niż te które mają wpływ na gospodarkę narodową.

Powyższe procesy w sposób bezpośredni wiążą się z problemami w modelowaniu procesów ekonomicznych na małych obszarach. Ponadto Hong, Lee, Lim, Kim (2013) wskazują, że wyszczególnione, zachodzące w skali lokalnej zjawiska, rodzą dodatkowe trudności metodologiczne, które skutkują tym, że

standardowe rozwiązania stosowane w klasycznej ekonometrii stają się nieskuteczne i prowadzą do błędnych szacunków.

Z kolei Lehmann i Wolhrabe (2015) w dogłębnej metaanalizie badań dotyczących prognozowania rynków pracy podkreślają, że:

- Istnieje niewiele badań, które łączą różne metody prognozowania.
- Istnieje duża potrzeba prognozowania rynków pracy na niskich poziomach agregacji.
- Zazwyczaj do obliczeń wykorzystuje się dane kwartalne lub roczne, nieliczne opracowania posługują się danymi o wyższej częstotliwości.
- Większość prognoz skupia się na gospodarce Stanów Zjednoczonych bądź Niemiec.

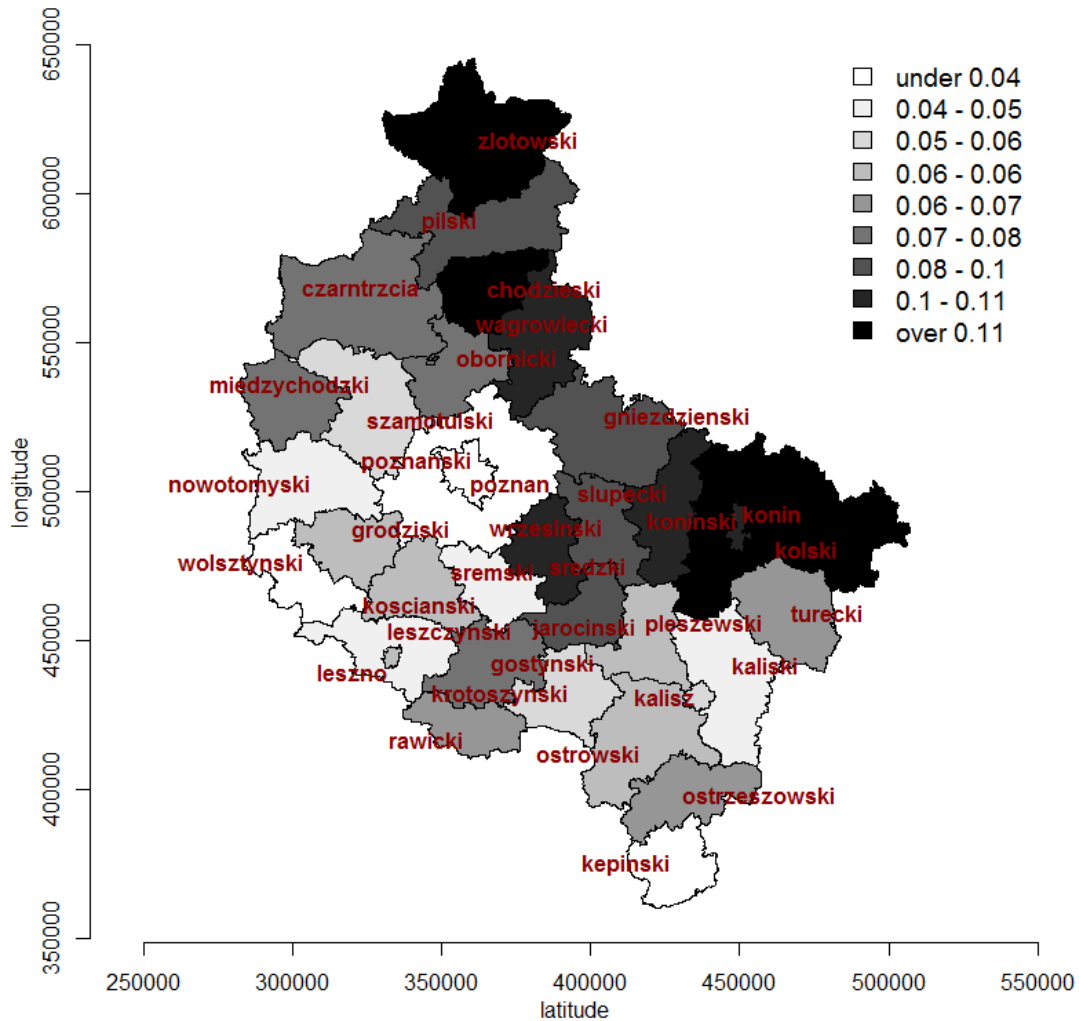
Zarysowane powyżej kwestie, na które zwrócono uwagę w literaturze przedmiotu, zaowocowały podjęciem problemu badawczego, który:

- 1) Skupia się na opracowaniu prognozy stopy bezrobocia na niskim poziomie agregacji przestrzennej (35 powiatów województwa wielkopolskiego).
- 2) Rozwija i łączy dwie skrajnie różne metody prognozowania na małych obszarach.
- 3) Włącza tzw. zależności przestrzenne pomiędzy jednostkami analizy (powiatami) do zaproponowanych modeli prognostycznych.

Reasumując, celem raportu jest opracowanie prognozy stopy bezrobocia dla 35 powiatów województwa Wielkopolskiego w średniookresowej perspektywie czasowej: kwiecień 2015 – kwiecień 2016 roku (13 miesięcy). W miarę pojawiania się nowych danych empirycznych prognoza będzie mogła być aktualizowana (np. raz na kwartał). Prognozę opracowano z wykorzystaniem dwóch skrajnie różnych metod badawczych: 1) przestrzennego modelu wektorowej autoregresji (SpVAR) oraz 2) przestrzennego modelu opartego na sztucznych sieciach neuronowych (SpANN). Wyboru metod dokonano w oparciu o wskazówki znajdujące się w opracowaniu Lehmana i Wolhrabe (2015). Kierowano się również możliwościami modeli w zakresie zasilenia ich dostępnymi w statystyce publicznej danymi. W celu estymacji modeli przestrzennych wykorzystano miesięczne dane za okres styczeń 2005 – marzec 2016 i w przypadku modelu wektorowego wykorzystano metodę regresji pozornie niezależnej, a w przypadku modelu opartego na sieciach neuronowych metodę propagacji wstecznej. Estymowane modele wykorzystano następnie do obliczenia prognozy kwiecień 2015 – kwiecień 2016 (13 miesięcy). Szersze omówienie metod i danych wykorzystanych do estymacji modeli znajduje się w kolejnych podpunktach niniejszego raportu.

Wykres 1 przedstawia wysokość stopy bezrobocia w Wielkopolsce w kwietniu 2016.

Wykres 1. Stopa bezrobocia w 35 powiatach Wielkopolski w kwietniu 2016 (ETRS89)



Wielkopolska to województwo mające powierzchnię 30 tys. km kwadratowych, usytuowane w północno zachodniej Polsce. Zamieszkuje je 3,5 miliona osób. 31 powiatów to powiaty grodzkie, a 4 to miasta na prawach powiatu (Poznań, Konin, Kalisz, Leszno). Średnia wielkość powiatu wynosi 860 kilometrów kwadratowych. Region jest znany ze stosunkowo dobrej sytuacji gospodarczej i należy do najbogatszych w Polsce. Rozpiętość wskaźników ekonomicznych jest tu jednak bardzo duża: np. stopa bezrobocia waha się od 2,5% w Poznaniu do 13,7% w powiecie złotowskim. Nawet w sąsiadujących powiatach różnice mogą być znaczne (np. powiat poznański (2,8%) sąsiaduje z wrzesińskim (9,5%)).

Teoria prognozowania

Analiza literatury przedmiotu pozwala wyodrębnić cztery różne podejścia do prognozowania danych gospodarczych. Pierwszym elementem tego zestawienia są tzw. modele wektorowej autoregresji, w których prognoza oparta jest na przeszłych wartościach danych empirycznych (Wenzel and Wolf (2013); Rapach and Strauss (2012); Schanne i in. (2010)). Modele tego typu są bardzo elastyczne, ponieważ nie wiążą ich ściśle założenia teoretyczne. Ogólnym zamysłem jest uchwycenie powiązań pomiędzy wieloma zmiennymi, tak aby jak najlepiej wpisać się w dane empiryczne. Ewolucja zmiennej zależnej w tym przypadku jest wypadkową jej przeszłych wartości jak i przeszłych wartości innych zmiennych, które mogą mieć wpływ na stabilność całego systemu.

Innym popularnym podejściem są modele czynnikowe, które do obliczeń prognostycznych wykorzystują liczny zestaw, nierzadko bardzo różnorodnych zmiennych. Zmienne te mogą być liczne, np. Lemann i Wohlrabe (2006) znaleźli 386 zmiennych, które mają wpływ na prognozowaną wartość PKB w niemieckich regionach. W tym przypadku zebranie danych empirycznych może być wyzwaniem, zwłaszcza gdyby chcieć włączyć dłuższy szereg czasowy do obliczeń. Modele tej klasy wykorzystuje się zazwyczaj do szacunków z wykorzystaniem danych panelowych, w których liczba jednostek panelu przewyższa długość czasową obserwacji.

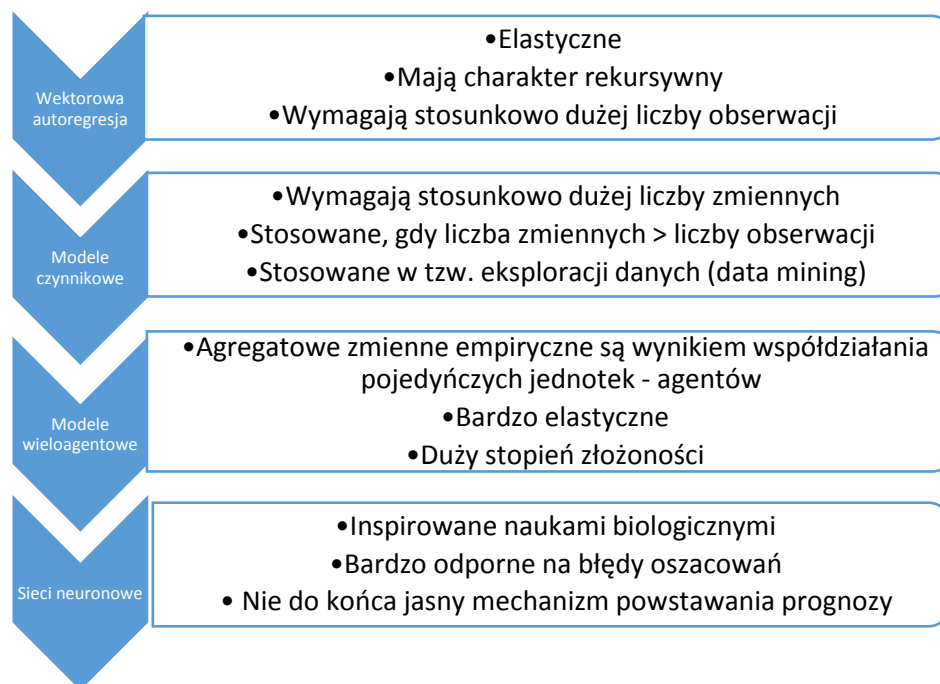
Kolejną, trzecią metodą, która zdobywa coraz większe uznanie na gruncie nauk ekonomicznych, a która z powodzeniem może zostać wykorzystana do prognozowania i to na małych obszarach są tzw. modele (systemy) wieloagentowe. Odwracają one założenia klasycznych modeli ekonomicznych, gdyż w tym przypadku ewolucja danego wskaźnika nie jest wypadkową agregatowego równania, bądź układu równań, lecz efektem autonomicznych decyzji poszczególnych jednostek (agentów), którzy kooperują w sztucznie wykreowanym świecie (Tesfatsion, Judd 2006). Podejście to wywodzi się z tzw. automatów komórkowych i zyskuje obecnie na znaczeniu, głównie z powodu realizmu i elastyczności. Z kolei wśród największych wad systemów wieloagentowych wskazuje się ogromny poziom skomplikowania i zbyt dużą dowolność w modelowaniu (Parker, Epstein 2011; Lustick, Miodownik 2009; Lengnick 2011; Marks, Vriend 2012).

Ostatnią, czwartą metodą, są sztuczne sieci neuronowe, które wywodzą się z tzw. maszynowego uczenia się. Podejście to, podobnie jak systemy wieloagentowe, odbiega od klasycznego, ekonometrycznego modelowania szeregów czasowych. Sztuczna sieć neuronowa to system zbudowany ze sztucznych neuronów, pomiędzy którymi zachodzi interakcja. Neurony to samouczące się algorytmy,

które przechwytyją zależności występujące w danych empirycznych (Gurney 2004, Kriesel 2005). W oparciu o wykryte wzorce obliczana jest prognoza (Zhang, Patuvo, Hu 1998).

W ramach zaprezentowanych metod prognostycznych istnieją ich liczne hybrydy, które umożliwiają włączenie zależności przestrzennych do obliczeń. Szczegółowe omówienie modeli przestrzennych można znaleźć m.in. w Debarsy i in. (2012). Ogólne zestawienie metod prognozowania zjawisk gospodarczych znalazło się na wykresie 2.

Wykres 2. Metody prognozowania wraz z najważniejszymi charakterystykami



Przegląd badań

Warto na wstępie zaznaczyć, że zarówno przestrzenne modele wektorowej autoregresji jak i modele oparte na sieciach neuronowych są stosunkowo nowym rozwiązaniem badawczym, obecnym w nurcie empirycznym od około dwóch dekad. Samo zwrócenie uwagi na procesy przestrzenne i ich rolę w kształtowaniu gospodarki i rynku pracy miało miejsce znacznie wcześniej. Problem ten był dyskutowany wielokrotnie począwszy od początku lat 70. Prawdopodobnie pierwszym opracowaniem, które porusza tą tematykę jest publikacja Cliffa i in. (1975). Autorzy wskazują na istnienie zależności przestrzenności jak i autokorelacji w danych przestrzennych. Dostarczają oni również metodologii do pomiaru korelacji w danych przestrzennych, a ich opracowanie rzuca nowe światło na analizę przestrzenną w ekonomii. Osobą, która kontynuowała te rozważania jest Anselin (1988), który jest autorem rozbudowanego studium prezentującego założenia ekonometrii przestrzennej, procedur estymacji i walidacji

ekonometrycznych modeli przestrzennych. Jak przyznaje w posłowie sam autor opracowanie to jest efektem 10 lat pracy badawczej i rzuca szeroką perspektywę na problem zależności przestrzennych.

Z uwagi na rozwój sprzętu informatycznego jak i oprogramowania, w końcu lat 90. i na początku XXI wieku powstaje coraz więcej opracowań podejmujących próbę szacowania modeli z komponentem przestrzennym (np. Le Sage 1999), pojawiają się również publikacje, które tego typu modele wykorzystują do prognozowania zjawisk gospodarczych np. Giacomini i Granger (2001).

Propozycję modelu wektorowej autoregresji z komponentem przestrzennym po raz pierwszy przedstawili izraelscy naukowcy Beenstock i Felsenstein (2007). Zastosowali oni opracowaną metodologię do regionalnych danych dla Izraela za lata 1987-2004, a ich celem było opracowanie prognozy cen nieruchomości w tym państwie. Artykuł rozpoczyna debatę na temat łączenia danych przestrzennych i szeregów czasowych w modelach ekonometrycznych.

Baltagi, Fingleton, Pirotte (2011) to kontynuatorzy metody zaproponowanej przez Beenstock i Felsenstein (2007). Zaproponowali oni osiem różnych strategii estymacji dla tego typu modeli i przetestowali każdą z nich wskazując najefektywniejszą. Autorzy bazowali na danych empirycznych dla 255 europejskich regionów NUTS2 z lat 1995-2002. Ostatnie dwa lata (2001-2002) posłużyły jako zbiór testowy dla opracowanej prognozy.

W opracowaniu Vega i Elhorst (2014) porównano z kolei 10 różnych sposobów na wprowadzenie zależności przestrzennych do modelu. W tym celu autorzy testowali różne rodzaje macierzy wag przestrzennych. W opracowaniu połączono również czasowy i przestrzenny wymiar danych dla 112 regionów znajdujących się w 8 krajach Unii Europejskiej. Autorzy dowodzą, że uwzględnienie jakiegokolwiek macierzy przestrzennej w modelu, podnosi jakość oszacowań.

Wśród badań wykorzystujących sztuczne sieci neuronowe należy z pewnością przywołać opracowanie Kaastra i Boyd (1996). Autorzy prawdopodobnie jako pierwsi przedstawili szczegółową metodologię prognozowania z użyciem tej metody. Prognozowanie z wykorzystaniem sieci neuronowych zostało podzielone na 8 etapów, z których każdy opisano, tak aby dać jasne wytyczne kontynuatorom rozważań. Z kolei Patuelli, Longhi, Reggiani, Nijkamp (2005) budują model sztucznej sieci neuronowej, który wykorzystują następnie do prognozy zatrudnienia dla 439 regionów wschodnich i zachodnich Niemiec w latach 1999-2000. Prognoza dotyczyła 9 sektorów ekonomii i została przeprowadzona z wykorzystaniem 18 różnych modeli z różną liczbą warstw i neuronów w warstwach.

Według autora, obecnie nie istnieją opracowania porównujące przestrzenny model wektorowej autoregresji z przestrzennym modelem opartym na sieciach neuronowych. Ponadto studia dotyczące

prognozowania na małych obszarach należą do rzadkości, a żadne z nich nie dotyczy gospodarki Polskiej. Niniejszy raport wypełnia tę lukę.

Dane empiryczne

W celu estymacji modeli i ewaluacji prognozy zgromadzono miesięczne dane za okres styczeń 2005 – kwiecień 2016 dla 35 powiatów województwa wielkopolskiego. Dane pobrano ze stron internetowych 31 powiatowych urzędów pracy w Wielkopolsce oraz ze strony Wojewódzkiego Urzędu Pracy w Poznaniu. Pozyskane dane, wraz z ich oznaczeniem zaprezentowano w tabeli 1.

Tabela 1. Zebrane dane wraz z ich oznaczeniem

Nazwa	Oznaczenie zmiennej
Stopa bezrobocia	<i>urate</i>
Liczba osób bezrobotnych	<i>u</i>
Liczba wolnych miejsc pracy	<i>v</i>
Napływ do bezrobocia	<i>inf</i>
Odptyw na rynek pracy	<i>out</i>
Restrykcyjność rynku pracy	<i>v/u</i>

Kompletna baza liczyła w sumie 27930 obserwacji, tzn. 135 obserwacji dla każdej z 6 zmiennych i 35 jednostek panelu. W toku procedury badawczej, dane podzielono na dwa zbiory:

- Zbiór treningowy obejmujący lata styczeń 2005 – marzec 2015 (123 miesiące).
- Zbiór testowy (ewaluacyjny) obejmujący lata kwiecień 2015 – kwiecień 2016 (13 miesięcy).

Zgodnie z przyjętą metodologią zestaw treningowy posłużył do estymacji modeli, a zestaw testowy do porównania wartości stopy bezrobocia generowanej przez modele z wartościami empirycznymi - ewaluacja.

Oprócz szeregu podstawowych danych, które można pobrać za stron urzędów pracy, do rozważań włączono tzw. wskaźnik restrykcyjności rynku pracy. Jest to relacja wolnych miejsc pracy do liczby bezrobotnych i stanowi silne odniesienie do fazy cyklu koniunkturalnego, w której znajduje się gospodarka. Negatywna korelacja pomiędzy tymi dwoma zmiennymi jest potwierdzonym empirycznie faktem i nosi nazwę tzw. krzywej Beveridga (np. Blanchard, Diamond 1990). Ogólnie rzecz ujmując wysoka wartość wskaźnika jest związana z czasem rozkwitu gospodarczego, a niska z czasem recesji.

Kolejną istotną kwestią związaną z danymi tego typu stanowi tzw. stacjonarność szeregów czasowych, która jest wymogiem uzyskania nieobciążonych szacunków w większości stosowanych obecnie modeli ekonometrycznych. Upraszczając, dane są stacjonarne, gdy daje się zaobserwować względnie stałą

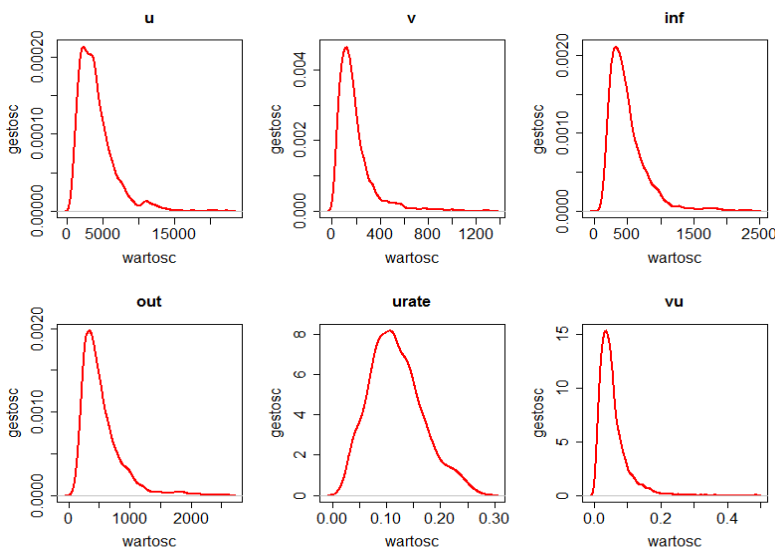
wariancję i średnią tych danych na przestrzeni czasu. W celu weryfikacji hipotezy o stacjonarności zgromadzonych danych posłużono się testami pierwszej i drugiej generacji. Wyniki obu testów uprawniają nas do odrzucenia hipotezy o istnieniu pierwiastka jednostkowego, co oznacza, że dane są stacjonarne (Tabela 2).

Tabela 2. Wyniki testu Levin-Lin-Chu oraz testu Peserana na obecność pierwiastka jednostkowego

Test Series	Levin-Lin-Chiu		Peseran's CADF ²	
	Test value	p-value	Test value	p-value
Unemployment rate	-7.7815	0.00	-2.98	0.01
Number of unemployed	-8.5788	0.00	-3.004	0.01
Vacancies	-4.8952	0.00	-5.021	0.01
Labor market tightness	-5.7079	0.00	-4.968	0.01
Inflow	-6.5351	0.00	-5.755	0.01
Outflow	-5.898	0.00	-4.95	0.01

Na kolejnych wykresach zobrazowano zgromadzone zmienne empiryczne. Wykres 3 przedstawia funkcję gęstości prawdopodobieństwa dla poszczególnych szeregów czasowych.

Wykres 3. Funkcja gęstości prawdopodobieństwa dla zmiennych empirycznych




Funkcja gęstości prawdopodobieństwa wskazuje najbardziej prawdopodobne wartości poszczególnych zmiennej dla danych obserwacji. I tak jeśli chodzi o liczbę bezrobotnych to znalazła się ona

² Szeregi czasowe przetestowano do drugiego opóźnienia, ponieważ opracowane modele nie zawierają wyższych rzędów opóźnień.


w przedziale 3000-5000; wolne miejsca pracy w przedziale 100-200. Napływ do bezrobocia zamyka się w przedziale 400-500. Odptyw na rynek pracy 450-550. Stopa bezrobocia 0.05-0.10; wartość wskaźnika restrykcyjności rynku pracy znalazła się w przedziale 0.04-0.08.

Kolejne wykresy wizualizują zgromadzone szeregi czasowe w zakresie zbioru treningowego (styczeń 2005 – marzec 2015) w odniesieniu do poszczególnych powiatów województwa wielkopolskiego. I tak wykres 4 ilustruje wysokość stopy bezrobocia; wykres 5 przedstawia napływy i odpływy z bezrobocia, wykres 6 wolne miejsca pracy, a wykres 7 liczbę bezrobotnych na terenie poszczególnych jednostek przestrzennych.

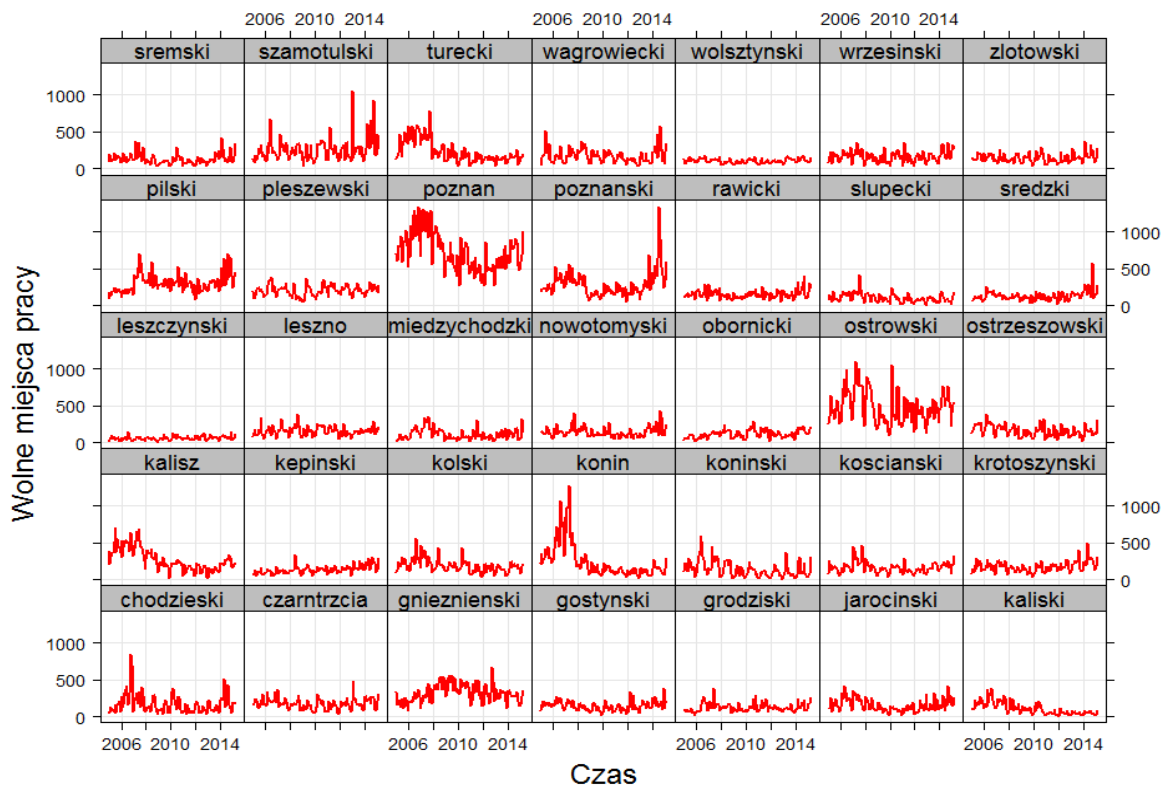
Wykres 4. Stopa bezrobocia w powiatach Wielkopolski styczeń 2005 – marzec 2015



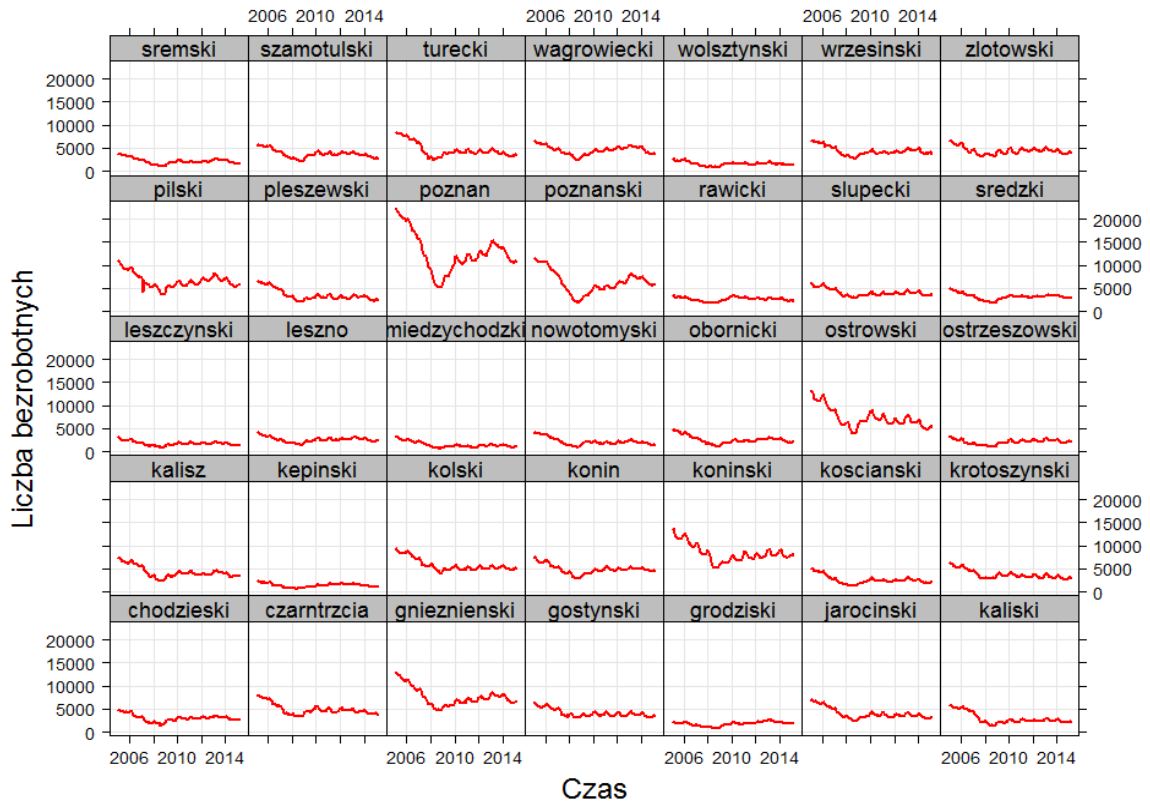
Wykres 5. Odprawy i naprawy do bezrobocia (czerwona linia) w powiatach Wielkopolski styczeń 2005 – marzec 2015



Wykres 6. Wolne miejsca pracy w powiatach Wielkopolski styczeń 2005 – marzec 2015



Wykres 7. Liczba bezrobotnych w powiatach Wielkopolski styczeń 2005 – marzec 2015



Na wszystkich wykresach charakterystyczne są spore rozbieżności pomiędzy jednostkami przestrzennymi. Np. stopa bezrobocia waha się od 1.4% w Poznaniu w 2008 roku do 28.1% w 2005 roku w Koninie; liczba bezrobotnych mieści się w zakresie od 659 w 2008 roku w powiecie międzychodzkiem do 22385 w 2005 w Poznaniu. Oczywistym jest, że aglomeracja poznańska odstaje znacząco od pozostałego obszaru województwa. Taki stan rzeczy jest charakterystyczny dla dużych obszarów miejskich pełniących rolę centrum regionu. Należy zauważyć, że obszary z gorszą sytuacją na rynku pracy znalazły się głównie na obrzeżach województwa.


Metodologia badań

Przestrzenny model wektorowej autoregresji

Przestrzenny model wektorowej autoregresji jest rozwinięciem klasycznych modeli wektorowej autoregresji. Najważniejszą zmianą w stosunku do swojego pierwowzoru jest tzw. macierz wag przestrzennych, która jest odpowiedzialna za transmisję zależności pomiędzy sąsiadującymi w przestrzeni jednostkami. W celu konstrukcji macierzy posłużono się danymi grafiki wektorowej dla województwa

Wielkopolskiego, które można pobrać ze strony firmy GIS support (www.gis-support.pl). Macierz naniesiona na mapkę województwa prezentuje się następująco (wykres 8).

Wykres 8. Wielkopolska z macierzą wag przestrzennych



Kolejnym etapem było wybranie takich predyktorów wśród zgromadzonych zmiennych, które w najbardziej precyzyjny sposób pozwolą prognozować przyszłe wartości stopy bezrobocia. W tym celu posłużono się tzw. testem przyczynowości Grangera, który pozwolił na wyodrębnienie trzech z spośród zgromadzonych zmiennych, które charakteryzowały się największą siłą prognostyczną. Oprócz opóźnionych wartości stopy bezrobocia ur były to odpięty na rynek pracy out oraz liczba wolnych miejsc pracy v . Model analityczny zbudowany w oparciu o wskazane zmienne był układem 105 równań (po 3 równania na powiat). Przykładowy blok równań z s opóźnieniami przestrzennymi i p opóźnieniami czasowymi dla N powiatu może być zapisany w sposób następujący:

$$\left\{ \begin{array}{l} ur_{t,N} = c_{1,N} + \alpha_{1,N,p}ur_{t-p} + \beta_{1,N,s}\Phi ur_{t-s} + \delta_{1,N,p}out_{t-p} + \mu_{1,N,s}\Phi out_{t-s} + \tau_{1,N,p}v_{t-p} \\ \quad + \rho_{1,N,s}\Phi v_{t-s} + \epsilon_{1,t,N} \\ \\ out_{t,N} = c_{2,N} + \alpha_{2,N,p}out_{t-p} + \beta_{2,N,s}\Phi out_{t-s} + \delta_{2,N,p}ur_{t-p} + \mu_{2,N,s}\Phi ur_{t-s} + \tau_{2,N,p}v_{t-p} \\ \quad + \rho_{2,N,s}\Phi v_{t-s} + \epsilon_{2,t,N} \\ \\ v_{t,N} = c_{3,N} + \alpha_{3,N,p}v_{t-p} + \beta_{3,N,s}\Phi v_{t-s} + \delta_{3,N,p}ur_{t-p} + \mu_{3,N,s}\Phi ur_{t-s} + \tau_{3,N,p}out_{t-p} \\ \quad + \rho_{3,N,s}\Phi out_{t-s} + \epsilon_{3,t,N} \end{array} \right.$$

Gdzie Φ jest macrycą wag przestrzennych, a symbole pozostałych zmiennych pozostają w zgodzie z tabelą 1. Układ równań estymowano z wykorzystaniem metody regresji pozornie niezależnej oraz iteracyjnej metody regresji pozornie niezależnej. Wyniki przedstawiono w tabeli 3.

Tabela 3. Najważniejsze charakterystyki wyjściowe dla obu metod estymacji

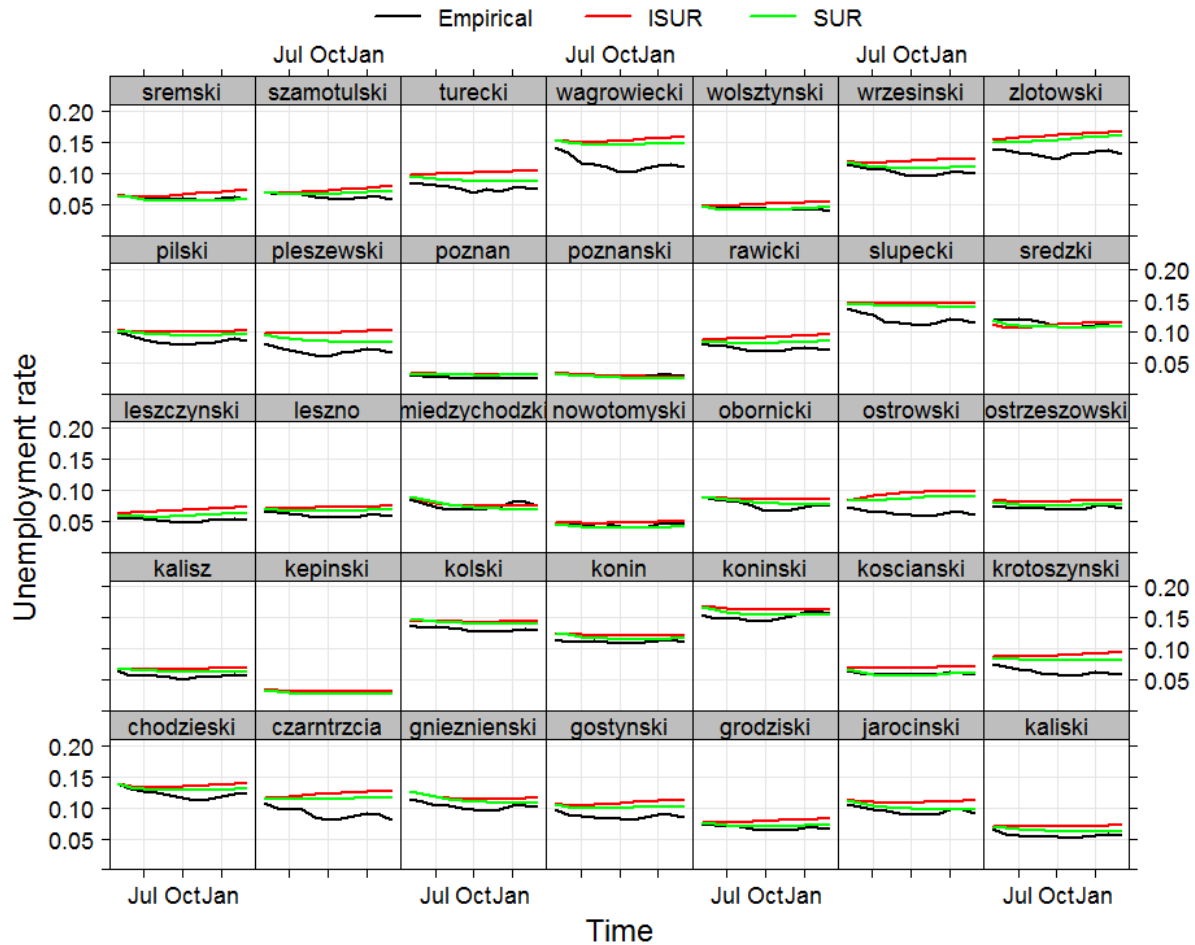
Metoda	SUR*	Iteracyjna SUR*
Wyznacznik macierzy kowariancji składnika resztowego	5.76E+26	0.014
współczynnik min	-28776.1	-28059.08
współczynnik max	19533.16	22254.87
R2	0.5	0.42
Błąd średniokwadratowy	71781716	82697141
Stopnie swobody	12075	12075

**SUR – estymacja z wykorzystaniem metody regresji pozornie niezależnej; iteracyjna SUR – estymacja z wykorzystaniem iteracyjnej metody regresji pozornie niezależnej.*

Po estymacji modelu, zrealizowano cel główny badania, tzn. obliczono 13 miesięczną prognozę stopy bezrobocia dla 35 powiatów województwa wielkopolskiego i zestawiono ją z danymi historycznymi za okres kwiecień 2015 – kwiecień 2016.

Przestrzenny model wektorowej autoregresji jest ze swej natury rekursywny i składa się z 735 parametrów (7 parametrów na równanie, 21 parametrów na powiat). Opracowanie prognozy polegało na wyodrębnieniu parametrów z układu równań i zastosowaniu autoregresji. W pierwszym kroku obliczono wartości wektora zmiennych zależnych. W drugim kroku, na podstawie obliczonych wartości wektora zmiennych, obliczono przestrzennie opóźnione ich wartości. Wartości te zostały podstawione do modelu SpVAR aby obliczyć wartość stopy bezrobocia dla kolejnego okresu. Kroki te zostały powtórzone 13 razy, tak aby otrzymać prognozowaną wartość stopy bezrobocia na 13 miesięcy w przód. W celu sprawdzenia błędu prognozy obliczono wartości błędów: średniokwadratowego, absolutnego oraz pierwiastek z kwadratu średniej błędu. Prognoza została zilustrowana na wykresie 9; tabela 4 prezentuje z kolei zmierzone błędy prognozy.

Wykres 9. Prognozowana i empiryczna wartość stopy bezrobocia dla powiatów Wielkopolski w okresie kwiecień 2015 – kwiecień 2016



Linia czarna oznacza wartość empiryczną; linia czerwona to wartości wygenerowane przez model iteracyjny; linia zielona to wartości wygenerowane przez model nieiteracyjny.

Tabela 4. Błędy prognozy dla przestrzennego modelu wektorowej autoregresji

Model	SUR	ISUR
MAE ³	0.011	0.016
MSE ⁴	0.0002	0.0004
RMSE ⁵	0.010	0.016

$$^3 MAE = \frac{1}{n} \sum_{i=1}^n |P_i - A_i|.$$

$$^4 MSE = \frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2.$$

$$^5 RMSE = \sqrt{\sum_{i=1}^n \frac{(P_i - A_i)^2}{n}}, \text{ where } n \text{ is the prediction sample size; } P \text{ are the predicted values; } A \text{ are the actual values.}$$

Analiza wykresu 9 wskazuje na pewne spójności, ale i rozbieżności w prognozie stopy bezrobocia wygenerowanej przez model iteracyjny i nieiteracyjny. Ogólnie rzecz biorąc błędy prognozy są niewielkie, tzn. prognozowane wartości w większości przypadków znajdują się blisko danych empirycznych. Oba modele mają jednak tendencję, aby przeszacowywać dane historyczne. Zjawisko to jest szczególnie widoczne w przypadku powiatów: węgrowskiego, czarnkowsko-trzcianeckiego i złotowskiego. Nieco bardziej precyzyjny okazał się model nieiteracyjny. Można zauważyć, że największe błędy prognozy dotyczą powiatów usytuowanych na obwodzie województwa, z wysoką wartością stopy bezrobocia. Zjawisko to można wytłumaczyć poprzez tzw. 'efekt wycięcia': macierz wag przestrzennych była niekompletna w przypadku skrajnych powiatów, gdyż dzielą one również granicę z innymi powiatami z innych województw, które nie były uwzględnione w macierzy. W efekcie model mógł mieć więcej kłopotów z trafnym przewidywaniem wartości wskaźnika na tych obszarach.

Przestrzenny model oparty na sztucznych sieciach neuronowych

Sztuczne sieci neuronowe to algorytmy, które naśladują działanie biologicznych systemów nerwowych. Są one atrakcyjnym narzędziem badawczym, gdyż zdolne są do uchwycenia często niejasnych powiązań w danych empirycznych (Patuelli, Longhi, Reggiani, Nijkamp 2005). Jako model prognostyczny generują przyszłe wartości zmiennej zależnej na podstawie wzorców sezonowych pojawiających się wśród zmiennych niezależnych (Adhikari, Agraval 2012). W literaturze wymienia się cechy charakterystyczne modeli opartych na sieciach neuronowych, które zachęcają do stosowania ich w badaniach empirycznych (Kaastra, Boyd (1996):

- Modele oparte na sieciach neuronowych są nieparametryczne stąd brak konieczności stosowania skomplikowanych procedur ich estymacji.
- Modele są nieliniarne, co zbliża je do zjawisk rzeczywistych.
- Potrzebują do działania tylko zbioru danych.
- Mogą się same adaptować do wzorców w danych.
- Cechuje je duża tolerancja na błędy i biały szum⁶.
- Charakteryzują się wysoką ogólną odpornością.

W związku z powyższymi faktami, modele oparte na sieciach neuronowych są stosunkowo popularne w naukach ekonomicznych, zwłaszcza jeśli chodzi o analizę związaną z obszarem finansów czy giełdy. Aplikacje na gruncie ekonomii pracy w ostatnich latach są jednak stosunkowo rzadkie.

W praktyce modele oparte na sztucznych sieciach neuronowych są przybliżeniem funkcji i są zdolne do symulowania każdej zależności empirycznej (Zhang i in. 2012). Najważniejszym dylematem podczas konstrukcji modelu opartego na sieciach neuronowych jest odpowiedni wybór liczby warstw i neuronów w tych warstwach oraz algorytmu uczenia się sieci (Sheela, Deepa 2013).

Ogólnie rzecz biorąc, model oparty na sztucznych sieciach neuronowych składa się z trzech głównych elementów: wejściowych szeregów czasowych, warstw i neuronów w tychże warstwach oraz danych wyjściowych, będących rezultatem pracy modelu. Neurony w poszczególnych warstwach są ze sobą połączone z różną siłą, która wskazuje na istotność wejściowych danych. Dodatkowo w każdej warstwie znajduje się również tzw. neuron błędu, który odgrywa podobną rolę do stałej w klasycznych modelach regresji (Hyndman 2015).

⁶ Biały szum to ciąg niezależnych zmiennych losowych o jednakowych rozkładach prawdopodobieństwa ze skończonymi wartościami przeciętnymi i wariancjami.

Tak jak w klasycznej ekonometrii, jednym z kluczowych etapów jest wybór predyktorów. May i in. (2011) dokonuje przeglądu metod, które są pomocne w określeniu zmiennych wejściowych, jednak wiele z nich jest bardzo wyszukanych i bazuje na dodatkowych modelach regresyjnych lub procedurach optymalizacji. W oparciu o opracowanie May i in. (2011) wykorzystane zostały dwie proste metody, które pomogły w wyborze zmiennych objaśniających: współczynnik korelacji rang Pearsona oraz informacja wzajemna. Informacja wzajemna jest miarą tego jak wiedza dotycząca jednej zmiennej pozwala zmniejszyć niewiedzę o innej zmiennej. Im wyższy rezultat, tym dwie zmienne mają więcej wspólnego. Rezultaty obliczeń dla poszczególnych metod i zmiennych przedstawiono w tabeli 5.

Tabela 5. Predyktory stopy bezrobocia dla przestrzennego modelu opartego na sieciach neuronowych

var	Korelacja rang Pearsona	Informacja wzajemna
v	-0.136	0.99
inf	0.342	0.34
out	0.05	0.37
v/u	-0.45	0.93
u	0.34	0.23

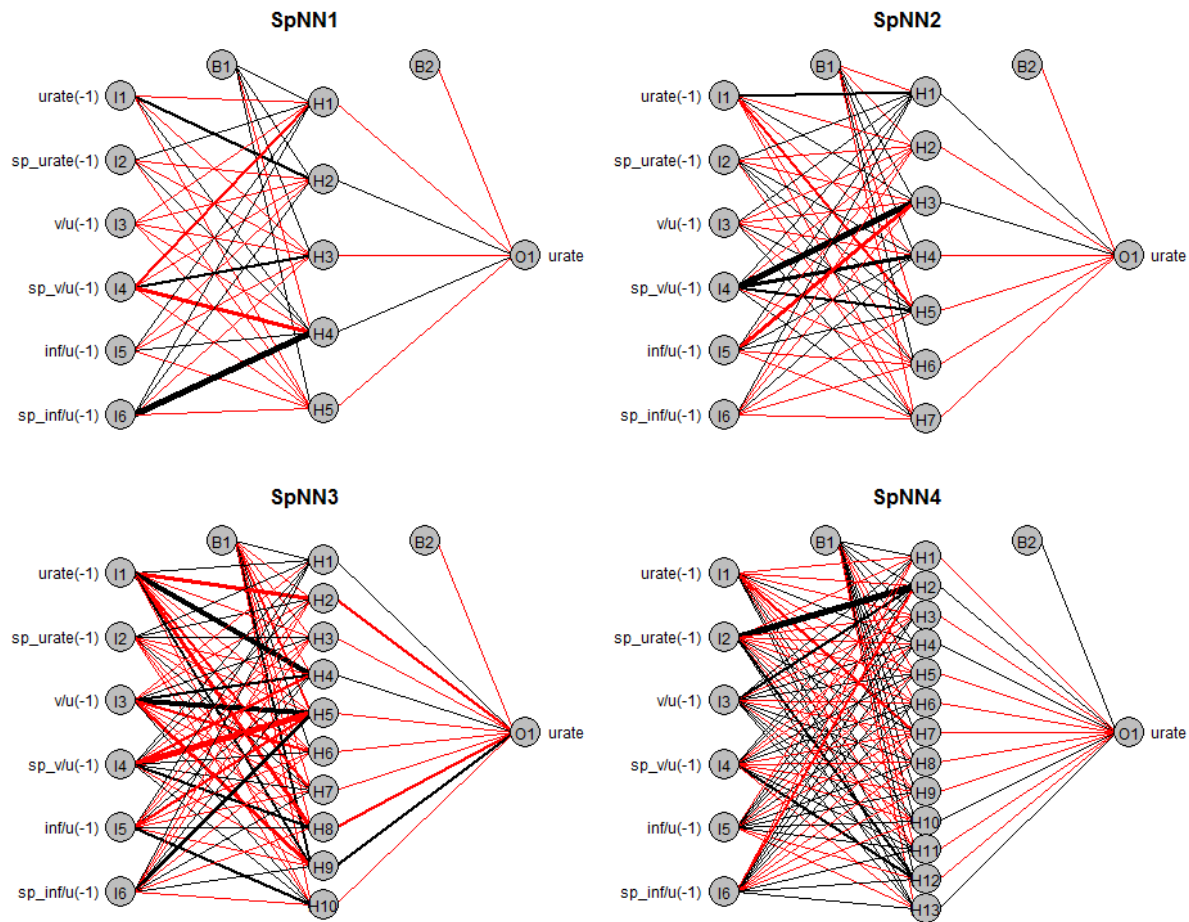
Na podstawie wyników obliczeń, z modelu wykluczono zmienną odpływy z bezrobocia z uwagi na słaby wynik testu korelacji rang Pearsona. Dwie zmienne uzyskały podobny, dość wysoki rezultat: napływ do bezrobocia oraz liczba bezrobotnych, w związku z tym zdecydowano się na włączenie do modelu ich relacji tzn. *inf/u*, tak aby liczba predyktorów była zgodna z przestrzennym modelem wektorowej autoregresji. W modelu uwzględniono pierwsze opóźnienia zmiennych objaśniających oraz tą samą macierz wag przestrzennych co w przestrzennym modelu wektorowej autoregresji. Formalnie przestrzenny model oparty na sieciach neuronowych możemy zapisać jako:

$$ur_{t,N} = c_{1,N} + \alpha_{1,N,p}ur_{t-p} + \beta_{1,N,s}\Phi ur_{t-s} + \delta_{1,N,p}v/u_{t-p} + \mu_{1,N,s}\Phi v/u_{t-s} + \tau_{1,N,p}inf/u_{t-p} + \rho_{1,N,s}\Phi inf/u_{t-s} + \epsilon_{1,t,N}$$

Liczba neuronów w modelu zależy jest od liczby danych wejściowych – im więcej danych, tym więcej neuronów i warstw, aczkolwiek trudno wskazać z ilu neuronów model powinien być zbudowany (Hyndman 2015). Podjęto wiele prób, podczas których testowano różne konfiguracje modeli, a ostatecznie zdecydowano się na wybór 4 najlepiej rokujących z pojedynczą warstwą i różną liczbą ukrytych neuronów. Bengio i LeCun (2007) wskazują, że skomplikowane sieci neuronowe mają zwykle gorsze osiągi, niż systemy składające się z jednej lub dwóch warstw. W tym przypadku nasze doświadczenie było podobne

– bardziej skomplikowane sieci cechowały się większymi błędami. Najbardziej obiecujące modele przedstawiono na wykresie 10.

Wykres 10. Przestrzenne modele oparte na sztucznych sieciach neuronowych




SpNN1 to model z 5 neuronami; SpNN2 to model z 7 neuronami; SpNN3 to model z 10 neuronami i SpNN4, to model z 13 neuronami. Koła z I w środku oznaczają neurony wejściowe, z H to neurony ukryte w warstwie, a B to neurony błędu, O to neuron wyjściowy; czerwone linie to połączenia (wagi) dodatnie, a czarne to połączenia (wagi) ujemne.

Tak jak w modelu przestrzennej wektorowej autoregresji, dane podzielono na dwa zbiory, z których pierwszy pełnił rolę zbioru treningowego (styczeń 2005-marzec 2015) a drugi testowego (kwiecień 2015 – kwiecień 2016). Główna różnica dotyczyła w tym przypadku metody „estymacji”, czy też uczenia się sieci neuronów.

W tym celu zastosowano algorytm propagacji wstecznej ze śledzeniem wag, którą po raz pierwszy zaprezentowali Riedmiller i Brown (1993). Algorytm ten ma wiele zalet m.in. szybki czas obliczeń, odporność, jest łatwy w implementacji, a parametry wybiera się w sposób intuicyjny (Igel, Husken 2003).

Na kolejnym wykresie (11) przedstawiono względną istotność czynników wejściowych, która została obliczona na podstawie wag przyporządkowanych w procesie uczenia się sieci.

Wykres 11. Relatywna istotność zmiennych wejściowych w zależności od modelu




1-opóźniona wartość stopy bezrobocia; 2-opóźniona wartość wskaźnika niedopasowania rynku pracy; 3-opóźniona wartość relacji napływ/u; 4-przestrzennie opóźniona wartość stopy bezrobocia; 5-przestrzennie opóźniona wartość wskaźnika niedopasowania rynku pracy; 6-przestrzennie opóźniona wartość relacji napływ/u.

Ostatecznym celem było opracowanie 13 miesięcznej prognozy stopy bezrobocia i porównanie jej z wartościami empirycznymi (kwiecień 2015 – kwiecień 2016). W przypadku przestrzennego modelu opartego na sieciach neuronowych prognoza nie mogła być obliczona w sposób rekursywny, gdyż system nie wspiera wektora wszystkich zmiennych wejściowych, tylko pojedynczy szereg czasowy. W tym przypadku zastosowana została trzystopniowa procedura, tzn. 1) obliczono wartości zmiennych wejściowych z ich własnych opóźnień, tak jak w zwykłym modelu AR(1); 2) z otrzymanych danych wyliczono przestrzennie opóźnione ich wartości; 3) dane otrzymane w krokach 1 i 2 posłużyły do zasilenia opracowanych przestrzennych modeli opartych na sieciach neuronowych. Procedura została powtórzona 13 razy, tak aby otrzymać prognozę w żądanym horyzoncie czasowym (13 miesięcy).

Prognoza za okres kwiecień 2015 – kwiecień 2016 została przedstawiona na wykresie 12. Tabela 6 zestawia błędy prognozy: średniokwadratowy, absolutny oraz pierwiastek z kwadratu średniej.

Wykres 12. Prognozowana i empiryczna wartość stopy bezrobocia dla powiatów Wielkopolski w okresie kwiecień 2015 – kwiecień 2016



Linia czarna oznacza wartości empiryczne stopy bezrobocia; linia czerwona to wartości wygenerowane przez model z 10 neuronami; linia zielona to wartości wygenerowane przez model z 13 neuronami.

Tabela 6. Błędy prognozy dla przestrzennych modeli opartych na sieciach neuronowych

Model	SpNN3	SpNN4
MAE	0.016	0.015
MSE	0.0003	0.0003
RMSE	0.016	0.015

Prognoza obliczona przez przestrzenny model oparty na sieciach neuronowych cechuje się nieco mniejszą dokładnością niż wyniki modelu SpVAR. Odchylenia od wartości empirycznych są szczególnie widoczne w

powiatach pleszewskim, złotowskim, krotoszyńskim i czarnkowsko-trzcianeckim. Tak więc również i w tym przypadku można było zaobserwować 'efekt wycięcia' charakterystyczny dla obszarów skrajnych, na których modele miały tendencję to przeszacowywania danych historycznych. Prognozy opracowane z wykorzystaniem obu modeli są bardzo zbliżone z niewielką przewagą na korzyść modelu SpNN4.

Podsumowanie

Porównanie obu odmiennych modeli w kontekście trafności prognozowania można rozstrzygnąć na korzyść przestrzennego modelu wektorowej autoregresji (SpVAR), jednak przewaga ta jest zaskakująco niewielka. Oczekiwaliśmy, że mocno osadzony w literaturze przedmiotu model wektorowy będzie bardziej precyzyjny, niż eksperymentalne podejście z wykorzystaniem sieci neuronowych. Warto jednak w tym kontekście przytoczyć kluczowe elementy metodologii, które mogły przyczynić się do otrzymania takich, a nie innych rezultatów:

- 1) Skupiono się na opracowaniu modelu, który umożliwił jednoczesne prognozowania dla wszystkich 35 powiatów województwa wielkopolskiego, co zmusiło nas do estymacji modelu z wykorzystaniem metody regresji pozornie niezależnej.
- 2) Do zasilenia modeli wykorzystane zostały surowe dane, w opozycji do większości opracowań posługujących się danymi zlogarytmowanymi.
- 3) Zdecydowano się na prognozę na terenie bardzo małych jednostek przestrzennych (powiaty).
- 4) Wykorzystano macierz wag przestrzennych typu królowej, bazującej na sąsiedztwie geograficznym.

Być może, jeśli prognoza byłaby opracowana dla całego województwa, a model SpVAR estymowanych z pomocą uogólnionej metody momentów i danych zlogarytmowanych, rezultaty byłyby inne. Cel tego opracowania był jednak inny: chodziło o przetestowanie dwóch skrajnie różnych podejść z wykorzystaniem prawdziwych danych na małych jednostkach przestrzennych.

Obie metody prognozowania wykazały się bardzo dużą precyzją, jeśli chodzi o obszar miasta Poznania i powiatu poznańskiego. Z kolei prognoza dla powiatów usytuowanych na obwodzie województwa, zwłaszcza tych cechujących się wysoką stopą bezrobocia, była często przeszacowana. Zjawisko to dotyczyło obydwu metod i może być związane z tzw. 'efektem wycięcia' i niekompletnością macierzy wag przestrzennych dla skrajnych powiatów graniczących z powiatami z innego województwa.

Podsumowując, jeśli najważniejszą rzeczą jest precyzja prognozy, zalecamy skupienie się na przestrzennym modelu wektorowej autoregresji. Jeśli jednak istotna jest prostota i szybkie rezultaty zalecamy zastosowanie modelu opartego na sztucznych sieciach neuronowych.

Bibliografia:

- Alsultanny, Y. (2013). Labor market forecasting by using data mining. *Procedia Computer Science*, 18, 1700–1709. <http://doi.org/10.1016/j.procs.2013.05.338>
- Anselin, L. (1988), *Spatial Econometrics: Methods and Models*, Springer Science & Business Media.
- Arandarenko, M., & Bartlett, W. (2012) ed. *Labour Market and Skills in the Western Balkans*. Foundation for the Advancement of Economics.
- Baltagi, B. H., Fingleton, B., & Pirotte, A. (2014). Estimating and forecasting with a dynamic spatial panel data model. *Oxford Bulletin of Economics and Statistics*, 76(1), 112–138. <http://doi.org/10.1111/obes.12011>
- Barnichon, R., & Nekarda, C. (2012). The Ins and Outs of Forecasting Unemployment: Using Labor Force Flows to Forecast the Labor Market. *Brookings Papers on Economic Activity*, (Fall), pp.83–132. <http://doi.org/10.1353/eca.2012.0018>
- Baruffini, M. (2013). An agent-based simulation of the Swiss labour market : an alternative for policy evaluation.
- Beck, N., Gleditsch, K., & Beardsly, K. (2006). Space is more than geography: Using spatial econometrics in the study of political economy. *International Studies ...*, 50, 27–44. <http://doi.org/10.1111/j.1468-2478.2006.00391.x>
- Beenstock, M., & Felsenstein, D. (2007). Spatial Vector Autoregressions. *Spatial Economic Analysis*, 2(2), 167–196. <http://doi.org/10.1080/17421770701346689>
- Bijak, J. (2007). Population and Labour Force Forecast for Nine European Countries: Assumptions and Results. Retrieved from http://www.cefmr.pan.pl/docs/cefmr_wp_2007-04.pdf
- Canova, F., & Ciccarelli, M. (2013). Panel Vector Autoregressive Models A Survey. *ECB Working Paper Series*, (15), 1–53. [http://doi.org/10.1108/S0731-9053\(2013\)0000031006](http://doi.org/10.1108/S0731-9053(2013)0000031006)
- Chen, Y. (2012). On the four types of weight functions for spatial contiguity matrix, *Letters in Spatial and Resource Sciences*, Volume 5, Issue 2, pp 65-72.
- Cliff, A., and J.K. Ord (1973). *Spatial Autocorrelation*. London: Pion.
- Cochrane, W. B. (2011). A Spatial Econometric Analysis of Selected Local Labour Market Outcomes in New Zealand, 1994. Retrieved from <http://researchcommons.waikato.ac.nz/handle/10289/5943\nhttp://researchcommons.waikato.ac.nz/bitstream/handle/10289/5943/thesis.pdf?sequence=3>
- Corrado, L. and Fingleton, B. (2012): “Where is the economics in spatial econometrics”, *Journal of Regional Science*, 52(2), 210-239.
- Cörvers, F., & Heijke, H. (2004). Forecasting the labour market by occupation and education : Some key issues. *Economic Policy*, (december).
- Danckwerts, R., & Danckwerts, M. (1999). The HWWA Econometric Model for Economic Forecasts, *Intereconomics*, Vol. 34, Issue 4, pp 201-208.

- Dewachter, H., Houssa, R., & Toffano, P. (2012). Spatial propagation of macroeconomic shocks in Europe. *Review of World Economics*, 148(2), 377–402. <http://doi.org/10.1007/s10290-012-0118-1>
- Félix, R. M. (2003). Forecasting Euro-Area aggregates with Bayesian VAR and VECM Models. Banco de Portugal, Research Department.
- Fotheringham, S. Rogerson, P. (2009). *The SAGE Handbook of Spatial Analysis*, SAGE Publications Ltd.
- Girardin, E. (2011). How helpful are spatial effects in forecasting the growth of Chinese provinces? *Journal of Forecasting*, Volume 30, Issue 7, pages 622–643.
- Giacomini, R. Granger, C., (2004), Aggregation of space-time processes, *Journal of Econometrics*, Vol. 118, Issues 1–2, Pages 7–26
- Gurney K.N. (2006), Neural networks for perceptual processing: from simulation tools to theories. *Philos. Trans R Soc. Lond. B Biol. Sci.*, vol. 362, pp. 339-353.
- Hewings, G., & Kim, J. (2011). An Application of the Disequilibrium Adjustment Framework to Small Area Forecasting and Impact Analysis. *ERSA Conference Papers*, (June 2010), 1–41. Retrieved from <http://www-sre.wu.ac.at/ersa/ersaconfs/ersa11/e110830aFinal01839.pdf> http://www.ekf.vsb.cz/projekty/cs/okruhy/weby/esf-0116/databaze-prispevku/clanky_ERSA_2011/ERSA2011_paper_01839.pdf
- Hong, J., Lee, S., Lim, J., & Kim, J. (2013). Application of Spatial Econometrics Analysis for Traffic Accident Prediction Models in Urban Areas, 9(1991).
- Joutz, F. L. (2006). *Econometric Forecasting Models*. Annual Meeting of the Middle Atlantic Actuarial Club, Inc., 20052(202).
- Juodis, A. (2014), Cointegration Testing in Panel VAR Models Under Partial Identification and Spatial Dependence, No 14-08, UvA-Econometrics Working Papers, Universiteit van Amsterdam, Dept. of Econometrics, <http://EconPapers.repec.org/RePEc:ame:wpaper:1408>.
- Kaastra, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*. [http://doi.org/10.1016/0925-2312\(95\)00039-9](http://doi.org/10.1016/0925-2312(95)00039-9)
- Karlsson, S. (2013). Forecasting with Bayesian Vector autoregression. *Handbook of Economic Forecasting*, 2, 791–897. <http://doi.org/10.1016/B978-0-444-62731-5.00015-4>
- Kholodin, K. Siliverstos, B. Kooths, S. (2007). A dynamic panel data approach to the forecasting of the GDP of German Lander, German Institute for Economic Research.
- Kukenova, M. Monteiro, J. (2009). Spatial Dynamic Panel Model and SGMM. (<http://www.ub.edu/sea2009.com/Papers/93.pdf>)
- Knobel, Claudia; Kriechel, Ben; Schmid, Alfons (ed.) (2008). *Regional forecasting on labour markets*. Rainer Hampp Verlag
- Kopoin, A., Moran, K. and Paré, J.P. (2013). Forecasting regional GDP with factor models: How useful are national and international data? *Economics Letters*, 121(2), 267-270.
- Kriesel, D. (2007). A Brief Introduction to Neural Networks, available at <http://www.dkriesel.com>

- Kueth, T. H., & Pede, V. (2009). Regional Housing Price Cycles: A Spatio-Temporal Analysis Using Us State Level, (09-04). Retrieved from <http://ideas.repec.org/p/pae/wpaper/09-04.html>
- Lehmann, R., & Wohlrabe, K. (2015). Regional economic forecasting : state-of-the-art methodology and future challenges, 3(4), 218–231.
- LeSage, J. P. (1999). The Theory and Practice of Spatial Econometrics. *International Journal of Forecasting*, 2(2), 245–246. [http://doi.org/10.1016/0169-2070\(86\)90119-6](http://doi.org/10.1016/0169-2070(86)90119-6)
- Lewandowski, C. M. (2015). The Effects of Brief Mindfulness Intervention on Acute Pain Experience: An Examination of Individual Difference. Dissertation <http://opensiuc.lib.siu.edu/dissertations/1089/>
- Lewkowicz, Z., & Kant, J.-D. (2007). A Multi-Agent System to model the Labor Market: simulating a new job contract introduction. *Essa* 2007.
- Longhi, Simonetta and Nijkamp, Peter, (2005), Forecasting Regional Labour Market Developments Under Spatial Heterogeneity and Spatial Autocorrelation, No 05-041/3, Tinbergen Institute Discussion Papers.
- Love, I., & Zicchino, L. (2006). Financial development and dynamic investment behavior: Evidence from panel VAR. *The Quarterly Review of Economics and Finance*, 46(2), pp. 190–210. <http://doi.org/10.1016/j.qref.2005.11.007>
- Lütkepohl, H. (2011). Vector autoregressive models, 1–25.
- Lütkepohl, H., & Xu, F. (2012). The role of the log transformation in forecasting economic variables. *Empirical Economics*, 42(3), 619–638. <http://doi.org/10.1007/s00181-010-0440-1>
- Matthes, B., Burkert, C., & Biersack, W. (2008). Regional unemployment forecasts with spatial Interdependencies. IAB Discussion Paper no 35.
- Monteiro, J. (2009). Pollution Havens: a Spatial Panel VAR Approach. *Zugriff Am*, (July), 1–26.
- Morrison, P. S., Papps, K. L., & Poot, J. (2006). Wages, employment, labour turnover and the accessibility of local labour markets. *Labour Economics*, 13(5), 639–663. <http://doi.org/10.1016/j.labeco.2004.10.007>
- Moser, C. (2009). Spillover effects of minimum wages in a two-sector search model Nikolai Stähler Discussion Paper Series 1 : Economic Studies, (01).
- Mutl, J. (2009). Panel VAR Models with Spatial Dependence. Institute for Advanced Studies, Economics Series, 237, 1–38.
- Nakajima, M. (2012). Business cycles in the equilibrium model of labor market search and self-insurance. *International Economic Review*, 53(10), 399–432. <http://doi.org/10.1111/j.1468-2354.2012.00686.x>
- Narciso, C., Herrera, B., Barbeito, J. M., & Mitra, P. G. (2006). LABOR MARKET SIGNALING ANALYSIS USING THE PROBABILITY OF MISCLASSIFICATION AND NEURAL NETWORKS, 61–76.
- Navarro, L. (2007). Labor market policies in a sector specific search model with heterogeneous firms and workers. *REViSta DE aNaLiSiS ECoNoMiCo*, 22(2), 29 – 45. Retrieved from http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1217582
- Neugart, M., & Richiardi, M. (2012). Agent-based models of the labor market, (125). Retrieved from http://www.laboratoriorevelli.it/_pdf/wp125.pdf

- OANCEA, B. Ciucu, S. (2013). Time series forecasting using neural networks, Proceedings of the CKS 2013 International Conference.
- Pablo-Martí, F. (2012). Forecasting and simulation of the impact of public policies on industrial districts using an Agent-Based model. ERSA Conference ..., 21, 1–23. Retrieved from <http://www-sre.wu.ac.at/ersa/ersaconfs/ersa12/e120821aFinal00555.pdf>
- Patuelli, Roberto and Mayor, Matías. (2012). Short-Run Regional Forecasts: Spatial Models Through Varying Cross-Sectional and Temporal Dimensions. Quaderni DSE Working Paper No. 835. Available at SSRN: <http://ssrn.com/abstract=2084219> or <http://dx.doi.org/10.2139/ssrn.2084219>
- Patuelli, R., Longhi, S., Reggiani, A., & Nijkamp, P. (2002). Multicriteria Analysis of Neural Network Forecasting Models: An Application to German Regional Labour Markets. *Studies in Regional Science*, 33(3), 205–229. http://doi.org/10.2457/srs.33.3_205
- Patuelli, R., Longhi, S., Reggiani, A., & Nijkamp, P. (2005). Forecasting Regional Employment in Germany by Means of Neural Networks and Genetic Algorithms, (0511002), 1–23. Retrieved from <http://ideas.repec.org/p/wpa/wuwpc0/0511002.html>
- Patuelli, R., Longhi, S., Reggiani, A., Nijkamp, P., & Blien, U. (2007). A Rank-Order Test on the Statistical Performance of Neural Network Models for Regional Labor Market Forecasts. *Review of Regional Studies*, 37(1), 64–81. Retrieved from <https://libproxy.library.unt.edu:9443/login?url=http://search.ebscohost.com/login.aspx?direct=true&db=a9h&AN=32797783&site=ehost-live&scope=site>
- Pavlyuk, D. (2011). Spatial Analysis of Regional Employment Rates, *Scientific Journal of Riga Technical University*, vol. 2, pp. 56-62.
- Pfaff, B. (2008). VAR, SVAR and SVEC models: Implementation within R package vars. *Journal of Statistical Software*, 27(4), 1–32.
- Pietrzykowski, R. (2011). Wykorzystanie metod statystycznej analizy przestrzennej w badaniach ekonomicznych. *Roczniki Ekonomiczne*, 4. Retrieved from http://www.kpsw.edu.pl/menu/pobierz/RE4/97_pietrzykowski.pdf
- Ramajo, J., Marquez, M., & Hewings, G. (2013). Spatio-temporal analysis of regional systems: A multiregional spatial vector autoregressive model for Spain. ERSA Conference Papers, (2008). Retrieved from <http://ideas.repec.org/p/wiw/wiwr/ersa13p159.html>
- Rapach, D. Jack K. Strauss, Forecasting US employment growth using forecast combining methods, *Journal of Forecasting*, Volume 27, Issue 1, pages 75–93.
- Schade, H. (2009). TOPIC Labour market prognoses – trends , opportunities and limits. *Labour*, 18–22.
- Schanne, N. (2010). Forecasting Regional Labour Markets with GVAR Models and Indicators, 49(April).
- Schanne, N., Wappler, R. and Weyh, A. (2010) Regional unemployment forecasts with spatial interdependencies, *International Journal of Forecasting*, 26(4), 908-926.
- Seymen, A. (2008). A Critical Note on the Forecast Error Variance Decomposition. *SSRN Electronic Journal*, 1–17. <http://doi.org/10.2139/ssrn.1266093>

- Sims, Christopher A. (ed.), 1994. "Advances in Econometrics," Cambridge Books, Cambridge University Press
- Stock, J., & Watson, M. (2006). Dynamic factor models. *Oxford Handbook of Economic Forecasting*, (January), 1–43. Retrieved from <http://link.springer.com/article/10.1007/s10182-006-0219-z>
- Sutherland, J., & Álmos, E. (2011). Long-Term Industrial Labor Demand Forecast for Hungary, (August).
- Tesfatsion, L., & Judd, K. L. (2006). *Handbook of Computational Economics*. *Handbook of Computational Economics* (Vol. 2). [http://doi.org/10.1016/S1574-0021\(05\)02016-2](http://doi.org/10.1016/S1574-0021(05)02016-2)
- Vega, S., Elhorst, J. P. (2014), Modelling regional labour market dynamics in space and time, *Papers in Regional Science*, vol. 93(4), pp. 819-842.
- Vidangos, I. (2009). Fluctuations in Individual Labor Income : A Panel VAR Analysis. *Finance and Economics*.
- Viton, P. a. (2010). Notes on Spatial Econometric Models. *City and Regional Planning*, 870(03), 9–10. Retrieved from <http://facweb.knowlton.ohio-state.edu/pviton/courses2/crp8703/spatial.pdf>
- Wenzel, L. and Wolf, A. (2013) Short-term forecasting with business surveys: evidence for German IHK data at federal state level, *HWWI Research Paper 140*, Hamburg, DE.
- Wozniak, 2012, Search and matching models as a labor market study tool, *JOURNAL of LAW, ECONOMICS and SOCIOLOGY*, vol. 4, UAM PRESS: Poznan.
- Wozniak, 2015, Can stochastic equilibrium search model fit transition economies? The tale of the three post-soviet countries, *Acta Oeconomica* vol 4.
- Wozniak, M. (2016). Job Placement Agencies in an Agent-based Model of the Local Labor Market with the Long-term Unemployed and on-the-job Flows. *Economics Discussion Papers*, No 2016-24, Kiel Institute for the World Economy. <http://www.economics-ejournal.org/economics/discussionpapers/2016-24>
- Xu, W., Li, Z., Chen, Q. (2012). Forecasting the Unemployment Rate by Neural Networks Using Search Engine Query Data, *Hawaii International Conference on System Sciences*
- Yu, J., de Jong, R., & Lee, L. (2012). Estimation for spatial dynamic panel data with fixed effects: The case of spatial cointegration. *Journal of Econometrics*, 167(1), 16–37. <http://doi.org/10.1016/j.jeconom.2011.05.014>
- Zivot, E., & Wang, J. (2006). Vector autoregressive models for multivariate time series. *Modeling Financial Time Series with SPLUS*, 383–427. http://doi.org/10.1007/978-0-387-32348-0_11