

RAFAŁ PUDEŁKO

Zakład Agrometeorologii i Zastosowania Informatyki  
Instytut Uprawy Nawożenia i Gleboznawstwa – Państwowy Instytut Badawczy w Puławach

## INTERPOLACJE MAP PLONÓW

Interpolation of yield maps

**ABSTRAKT:** Mapy plonów zazwyczaj wykreślane są na podstawie zbioru danych, który jest uzyskiwany automatycznie podczas prac kombajnu zbożowego. Sposób rejestracji zapewnia dużą liczebność prób, nie gwarantuje jednak wystarczającej stacjonarności danych dla wykonania jednoznacznego oszacowania ich zmienności przestrzennej, a tym samym nie pozwala na interpolację mapy plonów bez wstępnego opracowania zgromadzonych danych.

W pracy scharakteryzowano wpływ różnych metod interpolacji na generalizację obrazu map plonów. Opisane zostały charakterystyczne cechy wybranych deterministycznych i stochastycznych sposobów interpolacji map plonów oraz przeanalizowano wpływ doboru parametrów interpolującego algorytmu na przestrzenny obraz zmienności plonu. Uzyskiwane wyniki porównano z mapami konstruowanymi metodą alternatywną do interpolacji, polegającą na wyznaczeniu średnich statystycznych wartości plonu dla prób z najbliższego sąsiedztwa (*neighbourhood statistics*). Wynikiem prowadzonych badań było wyłonienie najlepszej metody interpolacji mapy plonu na polu produkcyjnym. Zastosowanie w praktyce opisanych w pracy metod pozwala na wykreślanie map plonów z dokładnością, która wynika z jakości danych.

**słowa kluczowe – key words:**

mapy plonów – *yield maps*, metody interpolacji – *methods of interpolation*, zmienność przestrzenna – *spatial variability*, rolnictwo precyzyjne – *precision agriculture*, geostatystyka – *geostatistic*

## WSTĘP

Badania nad zmiennością plonu w obrębie pola produkcyjnego są uważane przez wielu autorów za najważniejsze zadanie rolnictwa precyzyjnego (13, 19). Najczęściej używaną metodą określania zróżnicowania plonów w obrębie pola jest ich rejestracja w trybie pomiarów ciągłych przeprowadzonych podczas pracy kombajnu. Bezpośredni pomiar dokonywany jest za pomocą różnego typu mierników: optycznych, ultradźwiękowych, elektroniczno-optycznych i wagowych (18). Równoległe z pomiarem plonu rejestrowana jest pozycja kombajnu za pomocą odbiornika GPS (Global Positioning System). Informacje te zapisywane są w pamięci komputera pokładowego. Po wczytaniu danych z komputera kombajnu do środowiska GIS (Geographical Information System) następuje ich opracowanie metodami geostatystycznymi (interpolacje). Efektem końcowym jest wizualizacja w postaci mapy plonu. Na

jej jakość wpływają błędy, które mogą wystąpić przy rejestracji danych podczas prac polowych. Zależą one od wielu, często kumulujących się, czynników. Najważniejsze z nich to błędy pomiarowe i błędy kalibracji czujników plonu oraz zakłócenia odczytu pozycjonowania GPS, brak kontroli nad szerokością koszenia, lokalne przeszkody i nawroty kombajnu (5, 15). Większość błędów może zostać skorygowana za pomocą filtrów, które wstępnie analizują „surowe” dane w środowisku GIS (1, 2).

Na dokładność interpolacji map plonów duży wpływ ma występowanie zmienności przestrzennej właściwości fizycznych i chemicznych gleby w obrębie pola produkcyjnego. Zmienność ta wpływa bezpośrednio na zróżnicowanie ładu, co często jest przyczyną braku statystycznej stacjonarności w rozkładzie przestrzennym plonu. Utrudnia to zastosowanie stochastycznych metod interpolacji oraz zmusza do zastosowania generalizacji mapy, pomimo statystycznie wystarczającej liczby prób dla scharakteryzowania właściwości całej populacji.

W polskim piśmiennictwie analiza i interpretacja map plonów została szczegółowo przedstawiona przez Fabera (6-8). W Polsce pierwsze badania nad automatyczną rejestracją zmienności plonu rozpoczęto w 1994 roku w Stacji Doświadczalnej IUNG w Baborówku (9).

Głównym celem przedstawionych w niniejszej pracy analiz jest scharakteryzowanie przydatności wybranych metod interpolacji dla wykreślenia map plonów na podstawie próbek charakteryzujących się dużą wariancją oraz słabą stacjonarnością.

## MATERIAŁ I METODY

W pracy wykorzystano materiały pochodzące z badań zmienności przestrzennej właściwości gleb i plonów, które są prowadzone w Stacji Doświadczalnej Instytutu Uprawy Nawożenia i Gleboznawstwa PIB w Baborówku (województwo wielkopolskie). Stacja ta prowadzi wielkoobszarowe doświadczenia łąkowe z zastosowaniem metodyki i techniki rolnictwa precyzyjnego. Na polach doświadczalnych Stacji na 53,6 ha uprawia się w systemie płodozmiennym pszenicę ozimą, jęczmień jary oraz rzepak. Stosowana jest optymalna agrotechnika z uwzględnieniem zaleceń IUNG dla technologii przyjętych w rolnictwie integrowanym.

Dla rozwijania nowej technologii, jaką jest rolnictwo precyzyjne, Stacja została wyposażona w maszyny nowej generacji. Zbiór roślin wykonywany jest z użyciem kombajnu Massey-Ferguson 32, który dzięki zainstalowanym urządzeniom (system nawigacji GPS, izotopowy miernik plonów) przystosowany jest do ciągłej rejestracji wielkości plonów. Dane zbierane przez kombajn dostępne są od 1996 roku. Pomiar wykonywany jest ze stałym interwałem 1,2 sekundy. Podstawowymi informacjami gromadzonymi w czasie pracy kombajnu są wielkość plonu i współrzędne geograficzne każdego miejsca automatycznego próbobrania. Danymi pomocniczymi są data, czas oraz indeks HDOP (Horizontal Dilution Of Precision) pozwalający na szacowanie dokładności odczytu pozycji przez odbiornik GPS.

Wpływ doboru metody interpolacji i jej parametrów został przedstawiony przy użyciu algorytmów deterministycznych: IDW (Inverse Distance Weighted), NS (Neighbourhood Statistics) i splajn oraz stochastycznych (kriging zwykły, kriging zwykły dla semiwariogramu lokalnego). Algorytmy te są powszechnie wykorzystywane w środowisku GIS do interpolowania ciągłych obrazów przebiegu zmienności zjawisk. Danymi wejściowymi są zbiory punktów, a efektem analizy mapa zmienności w formacie modelu rastrowego, którego charakterystyczną cechą jest rozdzielczość wyrażająca się rozmiarem podstawowej komórki (piksela). Zastosowano programy: ArcView (interpolacje IDW i splajn), ERDAS (NS) i specjalistyczną aplikację, wykorzystującą metodę krigingu do analizy zmienności plonu – Vesper (20).

Analiza wpływu metody interpolacji na jakość modelu rastrowego (mapy w formacie GIS) została przeprowadzona na przykładzie zróżnicowania plonów pszenicy rejestrowanych przez kombajn w 2002 r. na polu o powierzchni 16 ha. O wyborze danych z tego roku zdecydowała duża wariancja i słaba stacjonarność prób stwierdzona na przestrzeni całego pola produkcyjnego.

### WYNIKI

Podczas pracy kombajnu zbożowego czujnik plonu zarejestrował 8138 rekordów. Po analizie „surowego” zbioru danych odrzucono ok. 5% rekordów. Za kryteria filtrowania przyjęto dokładność pozycjonowania i rozrzut wartości w rozkładzie statystycznym zbioru danych, co pozwoliło na eliminację większości błędów, które mogą wystąpić przy rejestracji danych podczas prac polowych (5, 6, 15). Odrzucono punkty o odległości mniejszej niż 3m od siebie (zbyt wolna jazda kombajnu) i większej niż 8m (potencjalne błędy pozycjonowania). Wartości te przyjęto na podstawie analizy rozkładu przestrzennego (histogramu i wektorów przemieszczania się kombajnu) oraz parametrów technicznych kombajnu. Wizualizacja na mapie tak określonych prób wykazała ich koncentrację na obrzeżach pola (nawroty) oraz możliwość występowania ewidentnych błędów w lokalizacji metodą GPS. Nie zaobserwowano natomiast znaczącej korelacji między błędami pozycjonowania a indeksem HDOP, co należałoby tłumaczyć zużyciem eksploatacyjnym odbiornika, a nie błędami systemu GPS. Dodatkowo odrzucono dane charakteryzujące się wartościami plonu mniejszymi lub większymi od dwóch odchyłeń standardowych od mediany (6). Po filtrowaniu pozostało 7716 próbek.

Efektywna interpolacja tak licznego zbioru danych może być realizowana przez metodę wybraną z jednej z trzech grup: wagowych deterministycznych, stochastycznych lub metodach bazujących na wartościach statystycznych podzbioru próbek z najbliższego sąsiedztwa (NS).

Najpopularniejszą deterministyczną metodą interpolacji jest IDW. Rysunek 1 przedstawia jej zastosowanie na czterech przykładach różniących się parametrami metody i rozdzielczością modelu. Parametrami możliwymi do modyfikacji w tej metodzie są współczynnik potęgowy ( $p$ ), który decyduje o wpływie wartości i odległo-

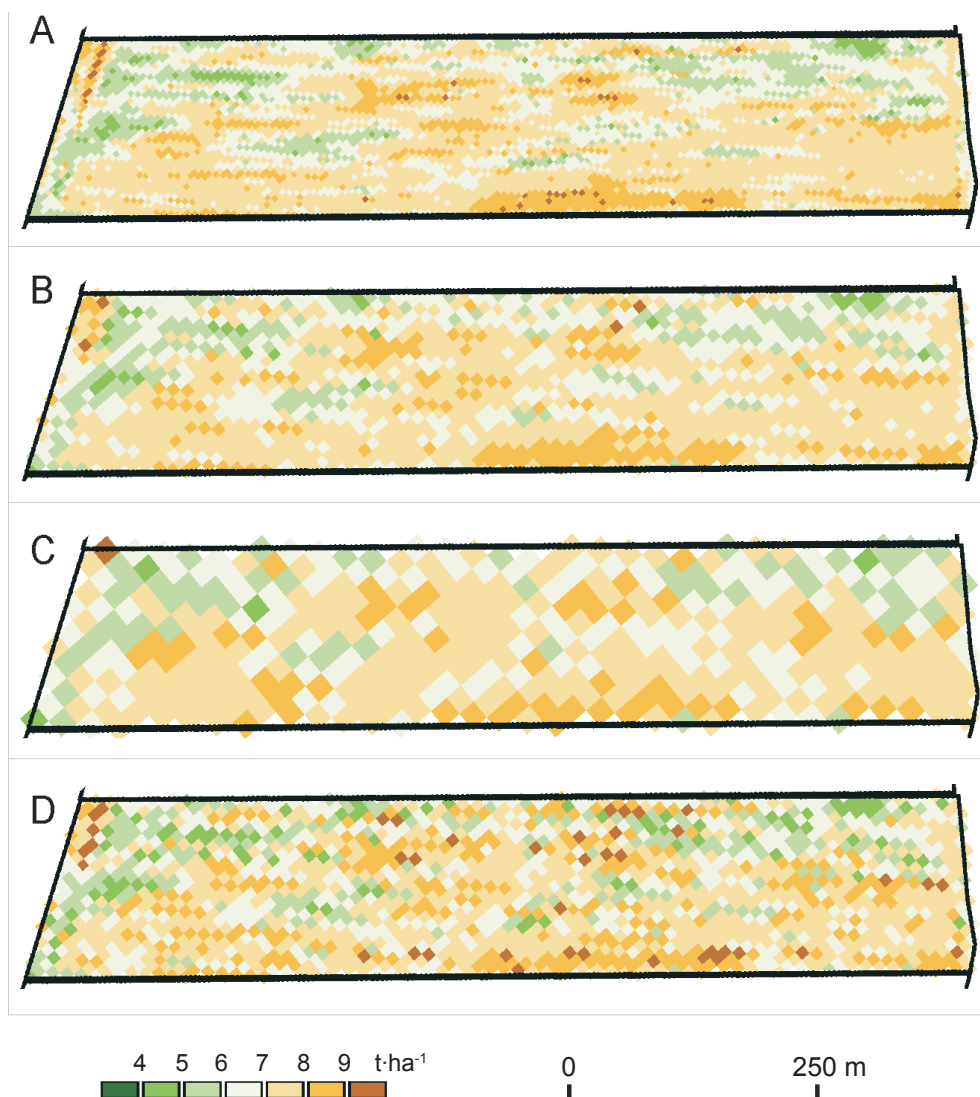
ści punktów z sąsiedztwa na wynik interpolacji, oraz liczba punktów najbliższych do środka komórki modelu rastrowego, dla której interpolowana jest wartość. Na rysunku 1A przedstawiono mapę otrzymaną przez zastosowanie współczynnika potęgowego równego 2. Rozdzielczość modelu (5 m) dostosowano do szerokości roboczej kombajnu. Dzięki takiemu doborowi parametrów otrzymano model najbardziej zbliżony do rzeczywistej sytuacji rejestrowanej przez kombajn.

Na mapie widoczny jest charakterystyczny „pasowy” układ wartości wzdłuż drogi kombajnu. Efekt ten jest niepożądany dlatego, że jego przyczyną są błędy pomiaru i/lub wpływ sposobu wykonywania zabiegów agrotechnicznych. Wskutek tego rzeczywiste możliwości plonotwórcze pola nie są właściwie przedstawiane. W efekcie nie stwierdza się dostatecznie ścisłych korelacji między interpolowanymi plonami a właściwościami gleby i wskaźnikami wegetacji określonymi na podstawie zdjęć satelitarnych czy lotniczych (na podstawie materiałów własnych opracowywanych w projekcie badawczym 2 P06R 041 27). Metodą eliminacji układu „pasowego” jest zastosowanie generalizacji przez przyjęcie mniej rygorystycznych parametrów interpolacji.

Mapa B na rysunku 1 obrazuje model uzyskany tą samą metodą jak poprzedni, lecz przy rozdzielczości zmniejszonej do 10 m. Porównanie obu modeli potwierdza, że nie wystąpiły między nimi znaczące różnice w zasięgach klas. Zmniejszeniu uległ jedynie efekt „pasowości”. Zmniejszenie rozdzielczości wskazane jest ze względu na możliwości wspólnej analizy map plonów i właściwości gleby przez nałożenie warstw piksel na piksel. Wybór tej rozdzielczości ułatwia konstrukcję map dawek nawozów i różnicowanie zabiegów agrotechnicznych (opartych na mapach plonu) w systemie rolnictwa precyzyjnego (12). Celowość ponownego dwukrotnego zmniejszenia rozdzielczości modelu (mapa C na rys. 1) może być już dyskusyjna. Model stał się jeszcze bardziej zgeneralizowany, lecz stracił wiele cech widocznych na modelach poprzednich. Z tego powodu dalsze analizy zostały przeprowadzone dla modeli o rozdzielczości 10 m.

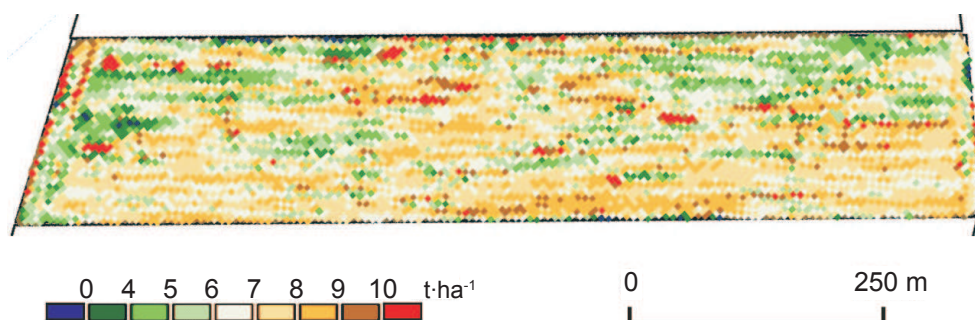
Zwiększanie wartości współczynnika potęgowego prowadzi do dążenia interpolowanej wartości komórki do wartości najbliższego punktu. Ze względu na dużą ilość punktów, które mogą się znaleźć na obszarze komórki, jest to efekt bardzo niekorzystny (mapa D na rys. 1). Wartości zostały chaotycznie rozproszone, zwiększyła się wariancja przestrzenna wizualizowanej cechy. Jak wynika z powyższych przykładów rekomendowaną wartością dla współczynnika potęgowego jest wartość standardowa (2,0) lub, jeżeli wymagana jest dalsza generalizacja, wartość mniejsza.

Drugą najczęściej używaną deterministyczną metodą interpolacji jest metoda splajnow. Rysunek 2 obrazuje model rastrowy o rozdzielczości 5 m interpolowany za pomocą tej metody. W porównaniu z analogicznym modelem interpolowanym metodą IDW stają się wyraźnie widoczne niekorzystne cechy splajnow. Duża gęstość próbkowania oraz duża wariancja lokalna powodują, że uzyskana mapa plonu charakteryzuje się dużą zmiennością. Detekcja „pasowości” układania się zmien-



Rys. 1. Wpływ doboru parametrów w metodzie IDW oraz rozdzielczości modelu na mapę plonów, A)  $p = 2$ ,  $r$  (rozdzielczość) = 5 m, B)  $p = 2$ ,  $r = 10$  m, C)  $p = 2$ ,  $r = 20$  m, D)  $p = 3$ ,  $r = 10$  m  
 IDW – influence of parameters and model resolution on yield map, A)  $p = 2$ ,  $r$  (resolution) = 5 m, B)  $p = 2$ ,  $r = 10$  m, C)  $p = 2$ ,  $r = 20$  m, D)  $p = 3$ ,  $r = 10$  m

ności plonu może być pomocna w procesie modelowania zjawiska, lecz na mapie plonów efekt ten powinien zostać zgeneralizowany. Ujawniają się też niekorzystne cechy metody polegające na dużych lokalnych zawyżaniach lub zaniżaniach wartości. Na mapie obszary te zostały zaznaczone kolorem czerwonym (plon większy niż  $10 t \cdot ha^{-1}$ ) i kolorem ciemnoniebieskim (plon mniejszy niż  $0 t \cdot ha^{-1}$ ). Opisane cechy

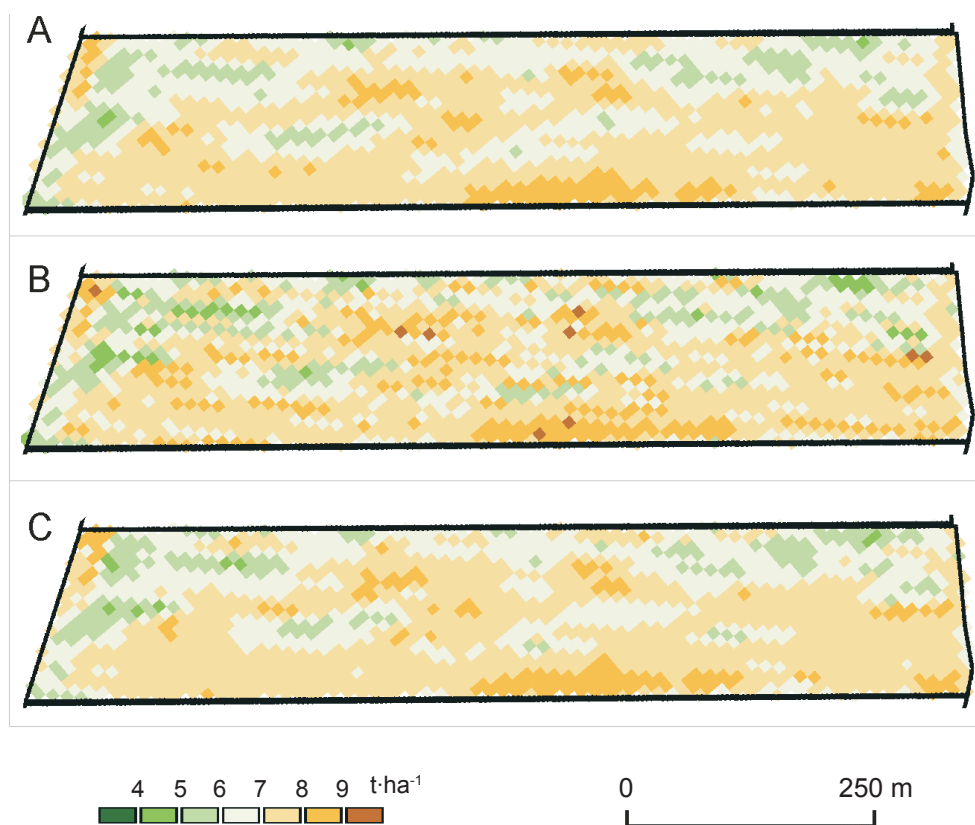


Rys. 2. Model interpolowany metodą splajnów  
Model interpolated using spline method

metody splajnów nie pozwalają na efektywne jej wykorzystanie przy konstruowaniu map pól i dlatego metody tej dalej nie analizowano i nie porównywano z innymi.

Zastosowanie metod stochastycznych wymaga spełnienia kryteriów statystycznych przez interpolowany zbiór danych. Wstępne analizy geostatystyczne potwierdziły, przewidywane na podstawie występowania dużej zmienności właściwości gleby (17), istnienie słabej stacjonarności danych wyrażającej się dużą lokalną wariancją i brakiem rozkładu normalnego. Z tego względu zastosowanie interpolacji metodą kriginu może być dyskusyjne. Dlatego też z wielu odmian tej metody wybrano kriginę zwykłą (OK), który jest najmniej wrażliwy na ograniczenia statystyczne. Mapa A na rysunku 3 udowadnia, że w przypadku tego rodzaju danych kriginę może być przyjęty za metodę interpolacji map zgeneralizowanych. Widoczne jest to zwłaszcza przy porównaniu tej mapy z mapą otrzymaną metodą IDW (rys. 1 B). Kriginę redukuje nieistotne lokalne (najczęściej wielkości piksela) skoki wartości, które są charakterystyczne dla map interpolowanych metodą IDW (tzw. bawole oczy).

Koniecznym warunkiem interpolacji metodą kriginu jest zbadanie zależności przestrzennych przetwarzanych danych metodą semiwariogramu. Przebieg funkcji semiwariogramu jest wykorzystywany w algorytmie kriginu do obliczania wag oddziaływań punktów mających wpływ na wynik interpolacji (3, 10, 11), dlatego dobór parametrów semiwariogramu bezpośrednio decyduje o jakości interpolacji oraz stopniu generalizacji obrazu mapy. Generalizacja powinna być celowym procesem, gdy gęstość próbkowania danych nie odpowiada rzeczywistej zmienności przestrzennej badanego zjawiska, dane obciążone są błędami pomiarowymi lub trendem. W przypadku rejestracji plonu analiza danych wskazuje najczęściej na istnienie najlepszej autokorelacji przestrzennej dla semiwariogramu kierunkowego, którego kąt odpowiada osi głównej pola, która jest kierunkiem ruchu kombajnu. Z założenia celem analizy metodą semiwariogramu jest znalezienie właśnie takiej zależności i zastosowanie jej postaci funkcyjnej do doboru wag w algorytmie interpolującym



Rys. 3. Modele interpolowane metodą kriginu zwykłego; A) semiwariogram izotropowy, B) semiwariogram anizotropowy o osi zgodnej z osią pola, C) semiwariogram lokalny  
 Models interpolated using ordinary kriging method; A) isotropic semivariogram, B) anisotropic semivariogram with axis parallel to field axis, C) local semivariogram

metodą kriginu. Jeżeli jednak informacje uzyskane za pomocą semiwariogramu zostaną zastosowane w tym przypadku, to uzyskany model nabierze niekorzystnych cech rozkładu „pasowego” wartości (rys. 3 B). Mapa będzie zbliżona do mapy uzyskanej metodą IDW (rys. 1 B). Z analizy wynika, że istnieje wpływ kierunku jazdy kombajnu na rejestrację danych.

Metodą pozwalającą na zbliżenie kriginu do metod deterministycznych jest zastosowanie semiwariogramu lokalnego (rys. 3 C). Dzięki temu można zmniejszyć niekorzystny wpływ braku stacjonarności danych. Porównanie modeli A i C (rys. 3) wykazało tylko niewielkie różnicowanie między nimi. Wynik porównania jest zgodny z przeświadczeniem wielu praktyków, którzy stosują kriginę nawet w przypadku braku spełnienia postulatów statystycznych i geostatystycznych przez dane, jako metodę dającą mimo wszystko lepsze rezultaty niż metody determini-

styczne. Za przykład może służyć porównanie mapy interpolowanej metodą IDW (rys. 1B) z mapami interpolowanymi krigingiem (rys. 3A lub 3C).

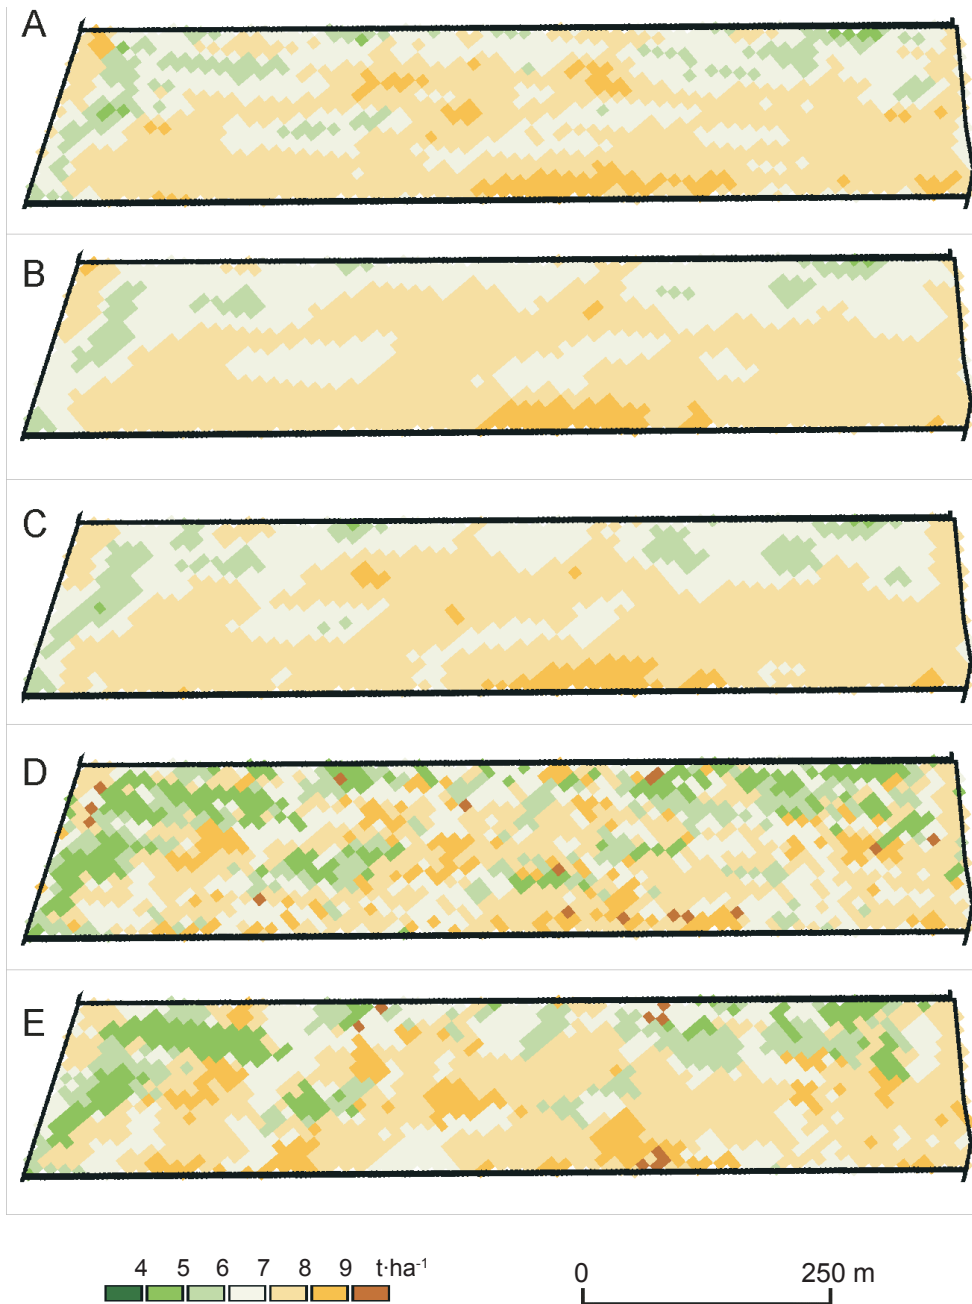
Duża liczba próbek, które mogą znajdować się na obszarze interpolowanej komórki lub w bezpośrednim jej sąsiedztwie, pozwala na zastosowanie metod statystycznego uśrednienia ich wartości dla oszacowania (interpolacji) wartości każdej komórki modelu rastrowego. Podobnie jak w przypadku klasycznych metod interpolacji należy wybrać sposób znajdowania najbliższych punktów. Za optymalne wydaje się przyjęcie promienia dostosowanego do rozdzielczości modelu. Programy GIS (np. ArcView, Erdas) pozwalają na automatyczne tworzenie modelu rastrowego dla średniej, mediany, wartości maksymalnej, minimalnej oraz najbardziej i najmniej charakterystycznej (znaczącej) dla wydzielonego w najbliższym sąsiedztwie podzbioru danych (NS). Na różnice w modelach interpolowanych tymi metodami największy wpływ ma lokalna wariancja, czyli stacjonarność zbioru danych. Duża wariancja lokalna powoduje lokalne różnice w rozkładach statystycznych podzbiorów. Z tego powodu szacowane wartości w modelach typu NS dla takich obszarów mogą różnić się znacząco. Decydującym parametrem jest zasięg (najczęściej promień) wyboru podzbioru. Im promień analizy jest większy, tym interpolowane wartości dążą do większej generalizacji. W sytuacji odwrotnej, w której promień dąży do zera, interpolowane wartości w coraz większym stopniu oddają zróżnicowanie lokalne interpolowanej cechy. Przed przystąpieniem do interpolacji metodą statystycznego uśredniania wskazane jest przeprowadzenie analizy rozkładu geograficznego próbek oraz analizy wariancji lokalnej. Analizy te są wystarczającym kryterium dla wyboru sposobu określania lokalnych podzbiorów.

Analizy przydatności zastosowań średnich lokalnych do wykreślenia map pól zostały przeprowadzone pod kątem takiego doboru parametrów, aby otrzymany model został zgeneralizowany w stopniu pozwalającym na redukcję efektu „pasowości” i „bawolich oczu” przy jednoczesnym zachowaniu poprawnego zróżnicowania plonu.

Modele lokalnej średniej A i B przedstawione na rysunku 4 różnią się długością promienia (A – 10 m, B – 20 m). Model A odpowiada stopniem generalizacji modelowi otrzymanemu za pomocą krigingu z semiwariogramem izotropowym (rys. 3A). Model B dzięki zastosowaniu dłuższego promienia jest modelem bardziej zgeneralizowanym. Dalsza generalizacja prowadzi do utraty charakterystycznych cech rozkładu zmienności. Porównanie modelu B z modelem lokalnej mediany (C) interpolowanym z zastosowaniem tych samych parametrów co model B ( $r = 20$  m) świadczy o niewielkiej różnicy między lokalną średnią a medianą. W tym przypadku lokalna mediana lepiej oddaje charakter zjawiska. Ze względu na dużą wariancję lokalną przyjęcie mediany za miarę tendencji centralnej jest bardziej uzasadnione statystycznie.

Modele D i E przedstawiają mapy wartości najbardziej charakterystycznych (najczęściej występujących) dla lokalnych podzbiorów. W pierwszym przypadku model został interpolowany przy użyciu promienia 10 m, w drugim – 20 m. Modele te w porównaniu z modelami poprzednio omawianymi: IDW (rys. 1), kriging





Rys. 4. Modele interpolowane metodą uśrednienia wartości próbek z najbliższego sąsiedztwa (NS);  
 A) średnia w promieniu 10 m, B) średnia w promieniu 20 m, C) mediana w promieniu 20 m,  
 D) wartość najbardziej znacząca w promieniu 10 m, E) wartość najbardziej znacząca w promieniu 20 m  
 Models interpolated using neighbourhood statistics; A) mean,  $r = 10$  m, B) mean,  $r = 20$  m,  
 C) median,  $r = 20$  m, D) majority value,  $r = 10$  m, E) majority value,  $r = 20$  m

(rys. 3) oraz lokalnej średniej i mediany (rys. 4 A, B i C) wykazują lokalnie wartości znacząco niższe (częściej) i wyższe. Charakterystyczną dla tych modeli cechą jest wyeliminowanie efektu „pasowości” w rozkładzie plonów.

#### DYSKUSJA

Wyniki przedstawione w pracy jednoznacznie udowadniają, że obraz mapy plonu zależy od doboru metody interpolacji i jej parametrów. W przypadku danych nie spełniających wszystkich warunków pozwalających na jednoznaczne wyznaczenie przebiegu zmienności przestrzennej analizowanego zbioru jedynie właściwy wybór metody kreślenia mapy może zapewnić poprawność jej obrazu przez generalizację wartości przypadkowych lub błędnych.

Na podstawie przeprowadzonych analiz można stwierdzić, że metoda kriginu zwykłego (OK) pomimo metodycznych ograniczeń jest możliwa do zastosowania nawet w przypadku danych charakteryzujących się słabą stacjonarnością. Użycie kriginu zwykłego w porównaniu z metodami deterministycznymi pozwala na uzyskanie mapy zjawiska pozbawionej artefaktów w postaci „bawolich oczu” oraz lokalnych przeszacowań i niedoszacowań wartości. W porównaniu z metodami deterministycznymi krigin daje więcej możliwości przy indywidualnym doborze parametrów interpolacji dla każdego z przypadków (14). Wykazano, że na podstawie doboru parametrów semiwariogramu można interpolować model zjawiska o wymaganym stopniu generalizacji, na który bezpośredni wpływ ma stosunek wariancji strukturalnej do wariancji ogólnej. Wskaźnik ten określa wpływ autokorelacji przestrzennej na ogólną zmienność zbioru (10, 11). Im będzie on mniejszy (mała zmienność strukturalna) tym stopień generalizacji interpolacji metodą kriginu będzie większy.

Zastosowanie kriginu jako metody interpolacji zbioru próbek pozwala na generalizację badanego zjawiska wynikającą z analizy geostatystycznej. Dzięki temu generalizacja zostaje dostosowana do jakości danych. Spełnione zostają wówczas wymagania kartograficzne dotyczące dostosowania dokładności mapy do dokładności danych. W przypadku zastosowania interpolacji deterministycznych wybór metody i jej parametrów oparty może być tylko na doświadczeniu i intuicji operatora.

Zastosowanie semiwariogramu lokalnego rekomendowanego przez Whelana i in. (20) dla interpolowania licznych zbiorów, szczególnie plonów, może pomóc w lepszym dopasowaniu modelu do zmienności lokalnej. Jednak różnice między otrzymanymi modelami są niewielkie, a modele interpolowane z zastosowaniem semiwariogramu globalnego i lokalnego niemal identyczne. Największe różnice między modelami uzyskano, zgodnie z przewidywaniami, w miejscach o największej wariancji lokalnej.

W pracy wykazano, że alternatywną metodą do kriginu w przypadku interpolacji modeli plonów może być metoda wyznaczania lokalnej tendencji centralnej (15).

Zasięg wyboru najbliższych próbek (promień) dla oszacowania średniej wartości powinien zostać określony na podstawie mapy gęstości próbek wykonanej dla całego badanego obszaru. Otrzymane tą metodą mapy plonów zbliżone są stopniem generalizacji do map uzyskanych metodą krigingu. W obu przypadkach ograniczany jest wpływ efektu systematycznego zaniżenia wartości plonów przez koszenie niepełną szerokością headera (15). Efekt ten może być ograniczony kosztem generalizacji modelu. Jego eliminacja możliwa jest dopiero w procesie zaawansowanego modelowania, w którym wartości plonów w błędnych ścieżkach będą korygowane w zależności od detekcji stopnia zaniżenia plonu (16).

Dzięki cyklicznej rejestracji wielu cech przez pracujący kombajn możliwe jest zastosowanie modelowania wielu zmiennych dla poprawienia jakości mapy plonów. Dzięki kombajnom nowszej generacji, które wyposażone są w więcej czujników (rejestracja szerokości pokosu, wilgotności ziarna) analizy tego typu mogą być rozbudowywane, co powinno przełożyć się na lepszą jakość modeli (map) plonów (4).

### WNIOSKI

Ocena przydatności wybranych metod interpolacji dla wykreślania map plonów na podstawie próbek charakteryzujących się dużą wariancją oraz słabą stacjonarnością, przeprowadzona na polach SD IUNG-PIB w Baborówku wykazała, że:

1. Metoda krigingu zwykłego daje najlepsze rezultaty interpolacji. Pozwala na dostosowanie cech modelu do jakości użytego do interpolacji zbioru danych.

2. W przypadku występowania dużego zróżnicowania lokalnej wariancji na badanym obszarze, kriging zwykły pozwala na interpolowanie zgeneralizowanych modeli, dzięki dopasowaniu funkcji semiwariogramu do wariancji strukturalnej zbioru danych. Model wynikowy nie jest obciążony artefaktami (nieuzasadnioną lokalną zmiennością) generowanymi przez metody deterministyczne.

3. Dokładność danych rejestrowanych podczas pracy kombajnu w systemie rolnictwa precyzyjnego musi być weryfikowana przez analizy przestrzenne, a zarejestrowane dane poddane procesowi filtracji.

4. Duża liczebność pomiarów pozwala na efektywną interpretację modeli plonów przez wyznaczenie lokalnej tendencji centralnej.

5. Badania potwierdziły, że optymalną rozdzielczością interpolowanych modeli jest przyjęta w rolnictwie precyzyjnym rozdzielczość równa (lub zbliżona) do 10 m.

### LITERATURA

1. Blackmore B.S., Marshall C.J.: Yield mapping; errors and algorithms. Precision Agriculture, ASA, CSSA, SSSA, Madison, Wisconsin, 1996, 403-415.
2. Blackmore B.S., Moore M.: Remedial correction of yield map data. Precision Agriculture 1, 1999, 53-66.

3. Błaszczyk L.: Geostatystyczna analiza zmienności przestrzennej plonu ziarna pszenicy ozimej. *Fragm. Agron.*, 2001, **2**: 28-35.
4. Dobermann A., Ping J.L., Simbahan G.C., Adamchuk V.I.: Processing of yield map data for delineating yield zones. J. Stafford and A. Werner (Ed.), *Precision Agriculture*, 4<sup>th</sup> ECPA-ECPLF, Berlin, 2003, 177-186.
5. Faber A.: System Rolnictwa Precyzyjnego. I. Mapy plonów. *Fragm. Agron.*, 1998, **1(57)**: 4-16.
6. Faber A.: System Rolnictwa Precyzyjnego. II. Analiza i interpretacja map plonów. *Fragm. Agron.*, 1998, **1(57)**: 16-28.
7. Faber A.: Doskonalenie jakości map plonów w technologii precyzyjnego rolnictwa. *Inż. Rol.*, 1999, **1(7)**: 7-16.
8. Faber A., Jadczyzyn T.: Ocena zmienności przestrzennej plonów pszenicy ozimej w zależności od sposobu zbioru. *Fragm. Agron.*, 2001, **1**: 23-30.
9. Fotyma M., Faber A., Czajkowski M., Kubsik K.: Preliminary experience concerning precision agriculture, J.V. Stafford (Ed.). *Precision Agriculture' 97 Bios Sci. Publ.*, Oxford, 1997, 111-118.
10. Gołaszewski J.: Zastosowanie metod geostatystyki w doświadczeniach polowych. *Listy Biomet.*, 1997, **34**: 63-85.
11. Gołaszewski J.: Analiza zmienności przestrzennej w doświadczeniach polowych. *Fragm. Agron.*, 2000, **4**: 4-14.
12. Jadczyzyn T.: System Rolnictwa Precyzyjnego. III. Nawożenie w rolnictwie precyzyjnym. *Fragm. Agron.*, 1998, **1(57)**: 28-40.
13. Makepeace R.J.: Benefits and limitations of precision farming. *Proc. Brighton Conf. on Pests and Diseases*, 18-21 November, 1996, **3**: 1235-1242.
14. McBratney A.B., Webster R.: Choosing functions for semivariograms of soil properties and fitting them to sampling estimates. *J. Soil Sci.*, 1986, **37**: 617-639.
15. Moore M., Kremmer P.R.: An investigation into the factors influencing the accuracy of yield maps. *The International Fertiliser Society*, Cambridge, UK, 1998, 60.
16. Noack P.O., Muhr T., Demmel M.: An algorithm for automatic detection and elimination of defective yield data. J. Stafford and A. Werner (Ed.), *Precision Agriculture*, 4<sup>th</sup> ECPA-ECPLF, Berlin, 2003, 445-450.
17. Oczko Z.: SD IUNG Baborówko, mapa glebowa 1:1000. IUNG, 1994.
18. Pierce F.J., Anderson N.W., Colvin T.S., Schueller J.K., Humburg D.S., McLaughlin N.B.: Yield mapping. W: F.J. Pierce and E.J. Sadler, eds. *The State of Site-Specific Management for Agricultural*. ASA-CSSA-SSSA, Madison, Wisconsin, 1997, 211-243.
19. Plumb R.T.: Issues and opportunities for precision approaches to crop management. *Proc. Brighton Conf. on Pests and Diseases*, 18-21 November, 1996, **3**: 1097-1104.
20. Whelan B.M., McBratney A.B., Minasny B.: Vesper – spatial prediction software for precision agriculture. *Proceedings of 3rd European Conference on Precision Agriculture*, Montpellier, France, 2001, 139-144.

## INTERPOLATION OF YIELD MAPS

### Summary

Yield maps are usually based on data automatically gathered during harvest. This method of field survey provides a large amount of data, but does not guarantee adequate statistical stationarity for making geostatistical analysis. Therefore, pre-processing of the data is a necessity before any evaluation of spatial variability and maps interpolation are made.

The aim of this survey was to estimate the influence of some of most useful interpolation algorithms on yield maps generalisation. Characteristic (positive and negative) features of deterministic and sto-

---

chastic methods were described and their influence on the image of yield variation was analysed. The results were compared with the maps of a local average yield, which were made using a neighbourhood statistical method. The result of the work is a set of recommendations, which enables a selection for an optimal factor of generalisation to interpolate yield maps based on collecting harvester's data.

*Praca wpłynęła do Redakcji 28 XI 2006 r.*