

ANALIZA PRZESTRZENNA CECH JAKOŚCIOWYCH. APLIKACJE GEOLOGICZNE

Alfred Stach

Instytut Paleogeografii i Geoekologii, Uniwersytet im. A. Mickiewicza
ul. Dziegielowa 27, 61-680 Poznań
e-mail: frdstach@amu.edu.pl

(referat wygłoszony w dniu 12.05.2005)

Wstęp

Częścią rutynowych procedur geologicznych, zwłaszcza w terenie, jest rejestracja szeregu cech jakościowych, takich jak typ genetyczny skały, kolor, tekstura, struktura itp. Znaczenie tego typu danych, początkowo duże, wraz z wkraczaniem metod ilościowych do geologii i sedymentologii stopniowo malało. Tradycyjne analizy statystyczne nie są bowiem przeznaczone do przetwarzania danych jakościowych. Sytuacja zaczęła się zmieniać w ostatnim dziesięcioleciu, kiedy coraz powszechniej zaczęto w klasyfikacjach i modelowaniu stosować bardziej wyrafinowane metody (por. Agresti 2002). Umożliwiają one nie tylko wykorzystywanie danych jakościowych, ale „traktowanie” ich na równi z ilościowymi. Należą do nich: regresja logistyczna, uogólnione modele regresji (GLM, GAM), drzewa klasyfikacyjno-regresyjne (CART), a zwłaszcza sztuczne sieci neuronowe (ANN). Wiele subtelnych, złożonych problemów, na przykład wyróżnianie subfacji osadów, może być często rozwiązane tylko przy wykorzystaniu wyżej wymienionych metod, i uwzględnieniu cech jakościowych.

Oprócz metod należących do głównego nurtu statystyki, w ostatnim czasie bardzo rozwinęła się numeryczna analiza przestrzenna danych jakościowych – jako dziedzina GIS. Jeden z najważniejszych jej nurtów jest rozwijany w ramach geostatystyki, gdzie wynik pomiaru/obserwacji traktowany jest jako realizacja przestrzennej (lub czaso-przestrzennej) funkcji losowej (Chilès, Delfiner 1999, Deutsch, Journel 1998, Goovaerts 1997, Lantuéjoul 2002). Celem geostatystyki jest: charakterystyka struktury przestrzennej/czasowej zjawiska, jego estymacja, symulacja oraz optymalizacja próbkowania. Fundamentem wszystkich wymienionych wyżej zastosowań jest identyfikacja, na drodze empirycznej, funkcji spadku podobieństwa zjawiska (a w praktyce mierzonych parametrów, które je charakteryzują) w przestrzeni i/lub czasie – funkcji autokorelacji. Najczęściej wykorzystywane do tego celu są autokowariancja, autokorelacja i semiwariogram. Należy zauważyć, że metody geostatystyczne są stosowane dla danych 1, 2, 3 i 4 wymiarowych (czaso-przestrzennych).

W polskiej geologii metody geostatystyczne były stosowane od wielu lat i wielokrotnie (Badyda i in. 2003, Cyrul 1992, Dębowska, Zawadzki 2005, Goldsztejn, Skrzypek 2004a, 2004b, Kokosz, Nieć 1992, Namysłowska-Wilczyńska 1993). Analizy te jednak ograniczały się zazwyczaj do estymacji (interpolacji) zmiennej (zmiennych) ciągłej metodą krigingu. Wykorzystanie technik wielozmiennych, symulacji, a zwłaszcza uwzględnianie w obliczeniach danych jakościowych (kategorii) jest praktycznie nieznane. W niniejszym opracowaniu przedstawiony zostanie krótki, i ze względu na ograniczenia objętości, pobieżny przegląd zastosowań geostatystyki do analizy danych jakościowych.

Estymacje

Zestawienie metod estymacji geostatystycznych, w których wykorzystywane są dane jakościowe, zostało zaprezentowane na **Ryc. 1**. Jako podstawę klasyfikacji przyjęto typ i „ilość” danych.

Jedną z najczęściej spotykanych sytuacji należy taka, kiedy dysponujemy nielicznymi wynikami precyzyjnych, kosztownych, laboratoryjnych analiz osadów, oraz znacznie gęstszą siatką wykonywanych w terenie, za pomocą prostych, tanich przyrządów (lub na oko), mało dokładnych pomiarów ilościowych lub jakościowych. Przykładem mogą być laboratoryjne oznaczenia zawartości CaCO_3 i test w terenie za pomocą rozcieńzonego HCl, albo też potencjometryczne – laboratoryjne, i kolorymetryczne – terenowe oznaczenia odczynu. W nomenklaturze geostatystycznej mamy wtedy do dyspozycji nieliczne dane „twarde”, i wielokrotnie liczniejsze dane „miękkie” (*hard and soft data*). Dane miękkie mogą mieć charakter skategoryzowany (czasami binarny) na przykład „brak”, „śląd”, „mało”, „dużo”, lub przedziałowy, na przykład „pH od 6,5 do 7,5”. Mając takie dane możemy do estymacji przestrzennych wykorzystywać różne warianty kokrigingu z kodowaniem binarnym uzupełniającej zmiennej „miękkiej”. Dane „miękkie” nie muszą mieć charakter zmiennej ściśle związanej z szacowaną, jak w podanych wyżej przykładach. Samo określenie typu osadu lub facji może już w dużym stopniu podwyższać jakość estymacji. Jako alternatywę, przy tego sytuacjach można zastosować stratyfikowany kriging (*kriging within strata*), lub prosty kriging z zmiennymi średnimi lokalnymi (*simple kriging with varying local means*).

Do zilustrowania tego zagadnienia wykorzystano dane pochodzące z obrazowania satelitarne powierzchni Ziemi (**Ryc. 2**). Obejmują one prostokątny wycinek doliny Ebby (Ebbadallen) na wyspie Spitsbergen Zachodni, o powierzchni $2,92 \text{ km}^2$ ($1500 \times 1950 \text{ m}$). Zdjęcie o rozdzielczości 15 m wykonano czujnikiem ASTER z satelity TERRA, 5 sierpnia 2001 roku. W północno-zachodniej części analizowanego wycinka znajduje się stok (stożek) usypiskowy, a w południowo-wschodniej – stok napływowy. Rozdziela je łożysko glacialnej

rzeki roztokowej. Z populacji jaką stanowiło 13000 wartości refleksyjności w bliskiej podczerwieni losowo pobrano próbkę 250 danych (1,9% całości). Oryginalną powierzchnię (populację) zrekonstruowano (Ryc. 2) trzema metodami geostatystycznymi. Do interpolacji za pomocą zwykłego krigingu (OK) wykorzystano jedynie dane z 250 wylosowanych punktów. W dwóch pozostałych algorytmach – krigingu stratyfikowanym (KWS) i prostym krigingu ze zmiennymi średnimi lokalnymi (SKlm) – uwzględniono również informacje o podziale analizowanego obszaru na „regiony”. Uzyskane wyniki estymacji zostały następnie porównane z rzeczywistym obrazem. Jako miary jakości estymacji użyto współczynnika korelacji (r), średniego błędu (ME) i średniego błędu kwadratowego (MSE, Tab. 1). Uwzględnienie w obliczeniach danych jakościowych (kategorii) spowodowało co prawda niewielkie obniżenie współczynnika korelacji, ale radykalnie zmniejszył się (szczególnie w wynikach KWS) błąd estymacji.

Metoda	r	ME	MSE
OK	0,735	7,39	65,7
KWS	0,721	-2,43	18,7
SKlm	0,702	-0,61	61,3

Tab. 1. Porównanie jakości estymacji wykonanych bez uwzględnienia danych o podziale obszaru na „regiony” (OK), i uwzględniających te dane (KWS i SKlm)

Objaśnienia: r – współczynnik korelacji liniowej (Pearsona), ME – średni błąd estymacji (optymalnie powinien wynosić 0), MSE – średni błąd kwadratowy (powinien być jak najniższy). Grubszą linią obwiedziono metodę dającą najlepszy wynik ze względu na wszystkie trzy kryteria.

Z inną sytuacją mamy do czynienia, kiedy dysponujemy wyłącznie danymi jakościowymi. Stosuje się wówczas kriging i kokriging wskaźnikowy (*indicator kriging*, *indicator cokriging*). Efektem jest estymacja punktowa, lub obszarowa (mapa) dająca wartość prawdopodobieństwa przynależności do danej kategorii (Ryc. 3).

Na tym samym co w poprzednim przykładzie obszarze wydzielono, w oparciu o 5 obrazów satelitarnych wykonanych w latach 2001-2004, sześć klas pokrycia terenu. Każdy z wykorzystanych obrazów obejmował 3 kanały spektralne z zakresu światła widzialnego i bliskiej podczerwieni, zatem klasyfikacja była dokonana na podstawie 15 zmiennych. Ze względu na znikomy udział roślinności wyróżnione 6 klas należy wiązać z występowaniem na tym obszarze zróżnicowanych skał/zwierzelin/osadów – klasa 2 na przykład to osady fluwiogłacialne stożka sandrowego. Tak jak poprzednio dysponowano 250 próbkami z populacji liczącej 13000 obiektów. Pierwszym krokiem było wykonanie mapy zasięgu

wyróżnionych kategorii metodą najbliższego sąsiada – *nearest neighbour*. Przypisuje się wówczas poszczególnym węzłom siatki interpolacyjnej wartość najbliższej leżącego punktu pomiarowego. Metoda ta dała wyniki zgodne z rzeczywistością w 66,5% (czyli w 8644 węzłach siatki). Zastosowanie metody krigingu wartości kodowanych (IK) umożliwiło stworzenie map prawdopodobieństwa przynależności do poszczególnych kategorii (Ryc. 3). Dla każdego węzła siatki i każdej kategorii uzyskuje się liczbę będącą ułamkiem dziesiętnym w zakresie od 0 (kategoria na pewno nie występuje w danej lokalizacji) do 1 (prawdopodobieństwo wystąpienia danej kategorii jest 100%). Suma prawdopodobieństw wszystkich kategorii dla jednego węzła wynosi 1. Ocenę jakości metody IK dla przedstawionego przykładu dokonano dwuetapowo. Najpierw zanalizowano wyniki tylko dla tych węzłów, w których prawdopodobieństwo przynależności do jednej klasy przekraczało 0,5 (50%). Takich lokalizacji było 11394 czyli 87,6% całości. Odsetek poprawnych ocen wynosił tutaj 74,7%. Dla pozostałych punktów przyjęto tę kategorię, która wykazywała najwyższe prawdopodobieństwo. Odsetek poprawnych „przypisań” wynosił tutaj 46,1%. Globalnie zatem metodą IK zgodnie z rzeczywistością zidentyfikowano wyróżnione kategorie w 71,2% przypadków. W praktycznych sytuacjach kiedy próbkowane są milionowe, czy nawet miliardowe części populacji – a nie 1,9% jak w tym przypadku (250/13000) – przewaga metod geostatystycznych zaznacza się bardziej wyraźnie.

Symulacje

Wadą wszystkich metod estymacji opartych na algorytmach regresji liniowej za pomocą najmniejszych kwadratów jest generalizacja rzeczywistego obrazu przestrzennego. Coś, co czasami jest zaletą – wygładzanie obrazu, redukcja szczegółów, „obcinanie” ekstremów – w innych sytuacjach stanowi wadę. Maskuje bowiem rzeczywistą skalę zróżnicowania środowiska. W kategoriach ilościowych wada metod interpolacyjnych polega na tym, że wygenerowany za ich pomocą model (powierzchnia opisana izopolami) ma inną charakterystykę statystyczną (rozkład zmiennej/histogram) i przestrzenną (semiwariogram), niż oryginalna próbka, na podstawie której powstał. W wszystkich zastosowaniach, gdzie ocena wartości ekstremalnych oraz zachowanie rzeczywistego zróżnicowania, ma znaczenie kluczowe, stosuje się warunkowe symulacje, które honorując dane pomiarowe, dają serię równie prawdopodobnych obrazów zmienności przestrzennej zjawiska. Dotyczy to również danych skategoryzowanych – jakościowych.

Zaprezentowana na Ryc. 4 klasyfikacja metod warunkowych symulacji przestrzennych danych jakościowych została oparta o inne kryteria, niż w przypadku estymacji. Pierwsze z nich dotyczy typu reprezentacji przestrzeni, a drugi – podstaw numerycznych (teoretycznych)

stosowanego algorytmu. W symulacjach bowiem możliwe jest zarówno przedstawienie przestrzeni w postaci ciągłej, tzw. pikselowej, jak nieciągłej – obiektowej. Zwłaszcza ten drugi sposób jest szczególnie ważny w zastosowaniach geologicznych, gdzie często potrzebna jest ocena występowania różnego rodzaju obiektów liniowych, płaszczyznowych, czy też „objętościowych” (spękań, uskoków, „ciał” skalnych itp., por. Escudem Viruete i in. 2003, Li, White 2003, Mao, Journel 1999, Roth 2000, Strebelle 2003, Weissmann, Fogg 1999, White i in. 2003, Yao 2002, Yao, Chopra 2000). Wszystkie geostatystyczne metody symulacji są rozwinięciem dla zagadnień przestrzennych koncepcji metody Monte Carlo. Poza odwzorowaniem histogramu symulowanej zmiennej reprodukowany jest model jej zmienności przestrzennej, zazwyczaj charakteryzowany przez semiwariogram.. Jeśli symulacja uwzględnia również wartości pomiarowe w ich lokalizacjach – mówi się że jest „warunkowa” (*conditional simulation*). Kolejny podział metod symulacji geostatystycznych dotyczy przyjętego modelu procesu losowego: gaussowskiego, nieparametrycznego lub fraktalnego. Bardziej szczegółowe omówienie teorii tych metod przekracza ramy niniejszego opracowania. Znaleźć je może czytelnik w cytowanych poprzednio podręcznikach (Chilès, Delfiner 1999, Deutsch, Journel 1998, Goovaerts 1997, Journel i in. 1998, Lantuéjoul 2002). Zwięzły i przystępny przegląd można również znaleźć w Internecie (Vann i in. 2002).

Na **Ryc. 5** przedstawiono przykład symulacji wykonanych Sekwencyjną Symulacją Wartości Kodowanych (SIS) należącej do grupy metod nieparametrycznych. Na podstawie tych samych co poprzednio 250 próbek 6 klas pokrycia terenu, wykonano 5 powtórzeń obliczeń dających za każdym razem inny – ale równie prawdopodobny – obraz zróżnicowania przestrzennego analizowanej cechy. Zgodność kategorii symulowanych z rzeczywistymi w konkretnych lokalizacjach jest mniejsza niż w metodach estymacji, bo wynosi od 29 do 33%, ale celem symulacji nie jest osiągnięcie maksymalnej dokładności punktowej, tylko obszarowej – globalnej.

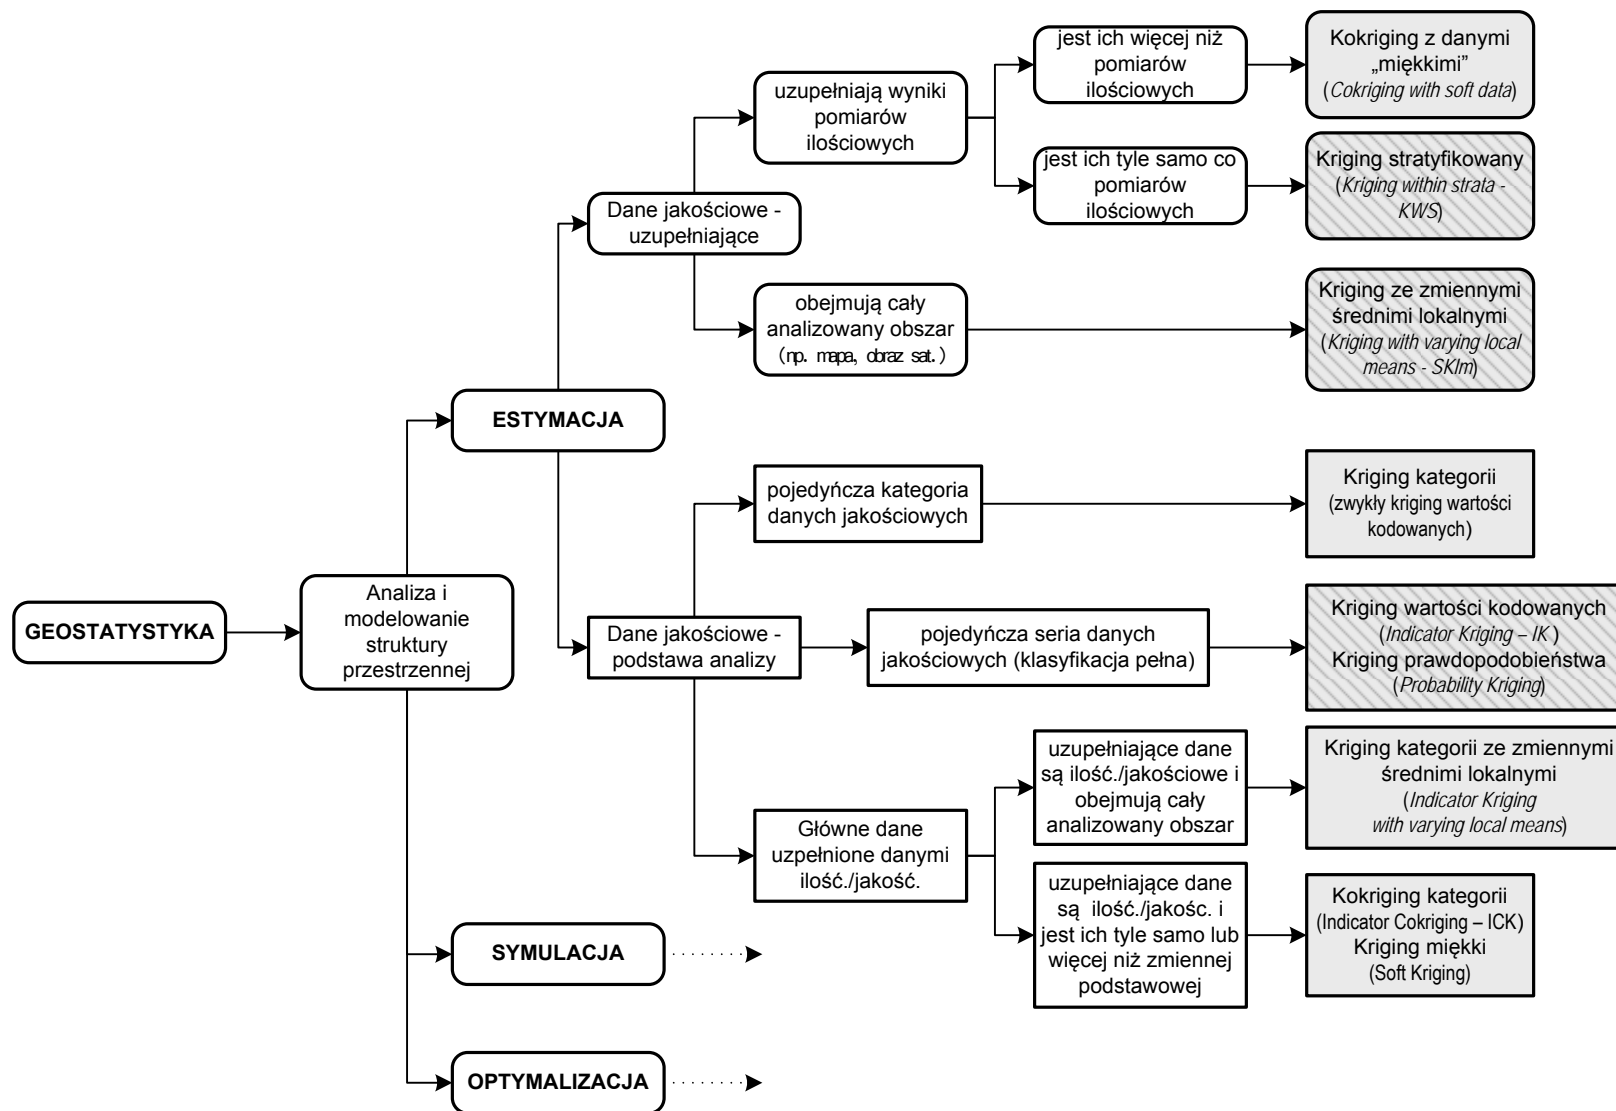
Podsumowanie

W niniejszym opracowaniu przedstawiono aktualny wachlarz najczęściej stosowanych metod estymacji i symulacji przestrzennych danych jakościowych. Należy jednakże zaznaczyć, że w przypadku symulacji i optymalizacji stosowane są uzupełniająco metody kombinatoryjne, z których największą popularność zyskało symulowane wyrażanie (*simulated annealing*, Goovaerts 1994). Instrumentarium to stanowi ważne narzędzie dla geologów, szczególnie w zakresie szacowania złóż (**Ryc. 6**, Caers 2001, Gorell 1995, Hirsche i in. 1998, Journel i in. 1998, Seifert, Jansen 1999, 2000,).


LITERATURA:

- Agresti, A., 2002: *Categorical data analysis*. Second edition. Wiley Interscience, 1-710.
- Badyda, A., Wawrzonek, R., Zawadzki, J., 2003: Wykorzystanie właściwości wskaźnika dopasowania IGF w celu ograniczania liczby punktów opróbowania w cyklicznych kampaniach pomiarowych. *Technika poszukiwań geologicznych i geotermia*, 3, (221):41-52.
- Caers, J., 2001: Geostatistical reservoir modelling using statistical pattern recognition. *Journal of Petroleum Science and Engineering*, 29: 177–188.
- Chilès, J-P., Delfiner, P., 1999: *Geostatistics. Modeling spatial uncertainty*. J. Wiley & Sons, 1-695.
- Cyrul, T., 1992: Elementy prognozowania wyrzutów skalno-gazowych i gazonośności w ujęciu geostatystycznym. *Zeszyty Naukowe AGH nr 1486, Górnictwo z. 160*, 1-158.
- Dębowska, U., Zawadzki, J., 2005: Analiza statystyczna i geostatystyczna zróżnicowania przestrzennego parametrów położenia warstw w NW części Gór Świętokrzyskich. *Przegląd Geologiczny*, 53: 306-310.
- Deutsch, C.V., Journel, A.G., 1998: *GSLIB. Geostatistical software library and user's guide*. Second edition. Oxford University Press, 1-369.
- Escuder Viruete, J., Carbonell, R., Martí, D., Jurado, M.J., Pérez-Estaún, A., 2003: Architecture of fault zones determined from outcrop, cores, 3-D seismic tomography and geostatistical modeling: example from the Albalá Granitic Pluton, SW Iberian Variscan Massif. *Tectonophysics* 361: 97–120.
- Goldsztejn, P., Skrzypek, G., 2004a: Morfologia powierzchni stropowej glin zwałowych zlodowacenia sanu 2 w centrum Wrocławia. *Przegląd Geologiczny*, 52 (2): 160–162.
- Goldsztejn, P., Skrzypek, G., 2004b: Wykorzystanie metod interpolacji do numerycznego kreślenia map powierzchni geologicznych na podstawie nieregularnie rozmieszczonych danych. *Przegląd Geologiczny*, 53, (3): 233-236.
- Goovaerts, P. 1994. Prediction and stochastic modelling of facies types using classification algorithms and simulated annealing. Stanford Center for Reservoir Forecasting, Stanford University, Unpublished annual report No 7 (<http://home.comcast.net/~goovaerts/scr94.html>).
- Goovaerts, P., 1997: *Geostatistics for natural resources evaluation*. Oxford University Press, 1-483.
- Gorell, S.B., 1995: Using geostatistics to aid in reservoir characterization. *The Leading Edge*, September 1995, 967-974.
- Hirsche, K., Boerner, S., Kalkomey, C., Gastaldi, G., 1998: Avoiding pitfalls in geostatistical reservoir characterization: A survival guide. *The Leading Edge*, April 1998, 493-504.
- Journel A.G., Gunderso R., Gringarten E., Yao T., 1998: Stochastic modelling of a fluvial reservoir: a comparative review of algorithms. *Journal of Petroleum Science and Engineering*, 21: 95-121.
- Kokesz, Z, Nieć, M., 1992: Metody geostatystyczne w rozpoznawaniu i dokumentowaniu złóż oraz w ochronie środowiska. *Studia i Rozprawy CPPGSMiE PAN nr 19, Kraków*, 1-51.
- Lantuéjoul, C., 2002: *Geostatistical simulation. Models and algorithms*. Springer-Verlag, 1-254.
- Li, H., White, C., 2003: Geostatistical models for shales in distributary channel point bars (Ferron Sandstone, Utah): From ground-penetrating radar data to three-dimensional flow modeling. *AAPG Bulletin*, 87, (12): 1851-1868.
- Mao, S., Journel, A.G., 1999: Conditional 3D simulation of lithofacies with 2D seismic data. *Computers and Geosciences*, 25: 845-862.
- Marinoni, O., 2003: Improving geological models using a combined ordinary–indicator kriging approach. *Engineering Geology* 69: 37–45.
- Namysłowska-Wilczyńska, B., 1993: Zmienność złóż rud miedzi na monoklinie przedsudeckiej w świetle badań geostatystycznych. *Prace Naukowe Instytutu Geotechniki i Hydrotechniki Politechniki Wrocławskiej nr 64, Seria Monografie nr 21, Wrocław*, 1-205.
- Oilfield Review, 1992: Reservoir characterization using expert knowledge, data and statistics. *Oilfield Review*, January 1992, 25-39 (www.slb.com/media/services/resources/oilfieldreview/ors92/0192/p25_39.pdf).
- Roth, C., 2000: Incorporating information about edge effects when simulating lithofacies. *Mathematical Geology*, 32 (3): 277-300.
- Seifert, D., Jensen, J.L., 1999: Using sequential indicator simulation as a tool in reservoir description: issues and uncertainties. *Mathematical Geology*, 31 (5): 527-550.

- Seifert, D., Jensen, J.L., 2000: Object and pixel-based reservoir modeling of a braided fluvial reservoir. *Mathematical Geology*, 32 (5): 581-603.
- Strebelle, S., 2003: Integration of sequence stratigraphy concepts into multiple point geostatistical models. Proceedings of IAMG 2003, International Association for Mathematical Geology, Portsmouth, UK, September 7-12, 2003 (www.iamg.org/meetings/Proceedings_2003/papers/Strebelle1.pdf).
- Vann, J., Bertoli, O., Jackson, S., 2002: An overview of geostatistical simulation for quantifying risk. [w:] Geostatistical Association of Australasia Symposium, "Quantifying Risk and Error", March 2002 (www.quantitativegeoscience.com/images/pdf/vann_bertoli_jackson_simulation_for_risk_distribution.pdf).
- Weissmann G.S., Fogg G.E., 1999: Multi-scale alluvial fan heterogeneity modeled with transition probability geostatistics in a sequence stratigraphic framework. *Journal of Hydrology*, 226: 48–65.
- White, C.D., Novakovic, D., Dutton, S.P., Willis, B.J., 2003: A geostatistical model for calcite concretions in sandstone. *Mathematical Geology*, 35 (5): 549-575.
- Yao, T., 2002: Integrating seismic data for lithofacies modeling: A comparison of sequential indicator simulation algorithms. *Mathematical Geology*, 34 (4): 387-403.
- Yao, T., Chopra, A., 2000: Integration of seismic attribute map into 3D facies modeling. *Journal of Petroleum Science and Engineering*, 27: 69–84.

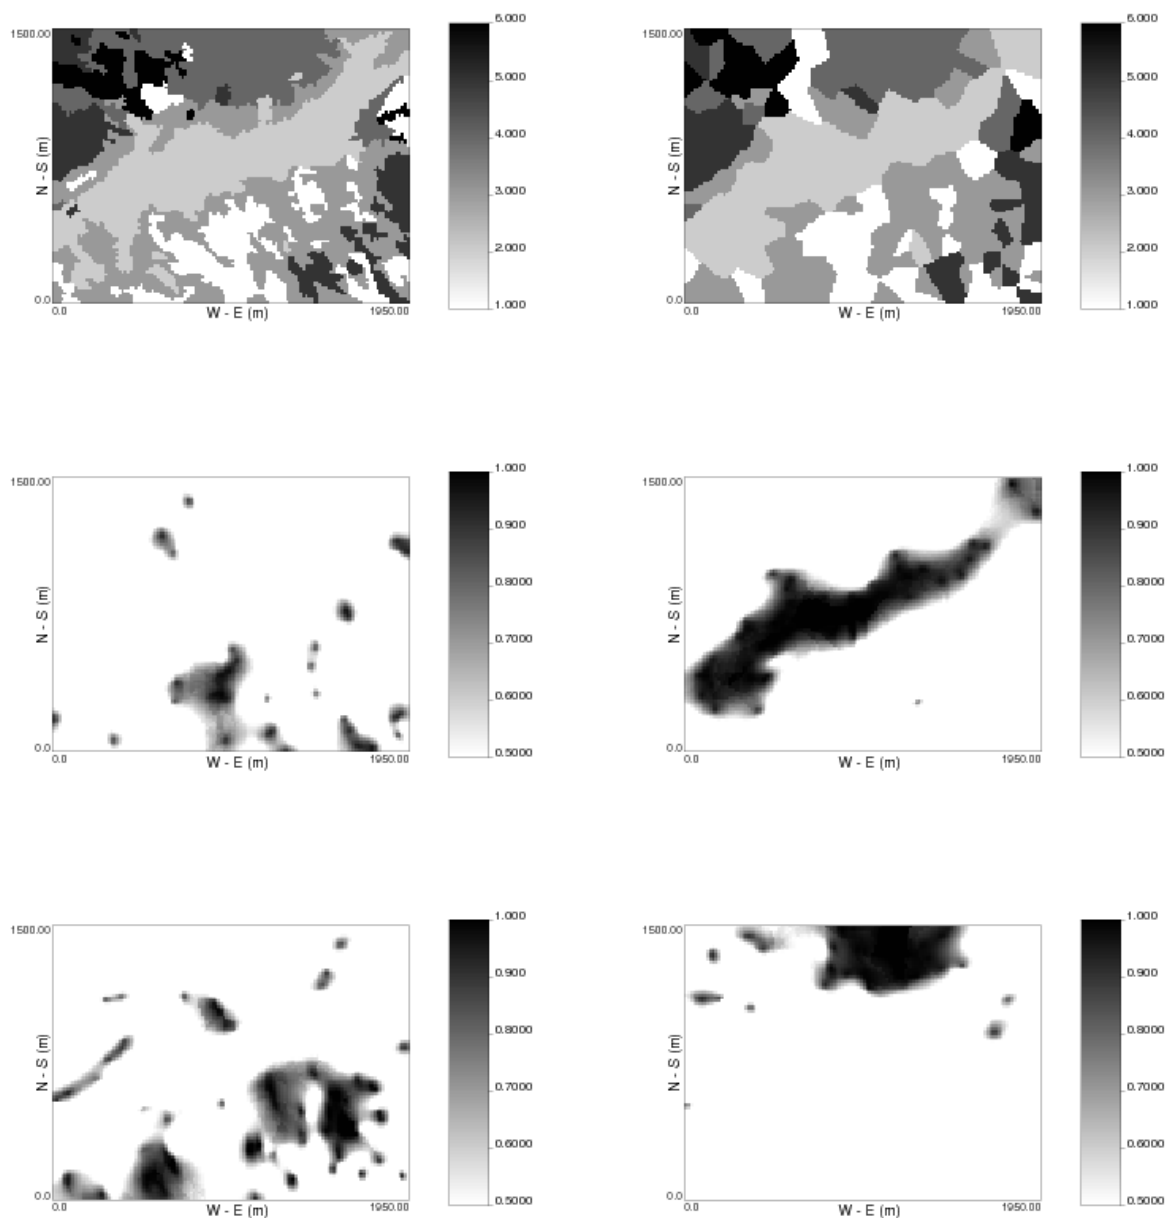


Ryc. 1. Zestawienie metod estymacji geostatystycznych uwzględniających dane jakościowe – zarówno jako uzupełniające, jak i podstawowe
 Zastosowanie metod oznaczonych na schemacie szrafowanym tłem zostało zaprezentowane na rycinach 2 i 3



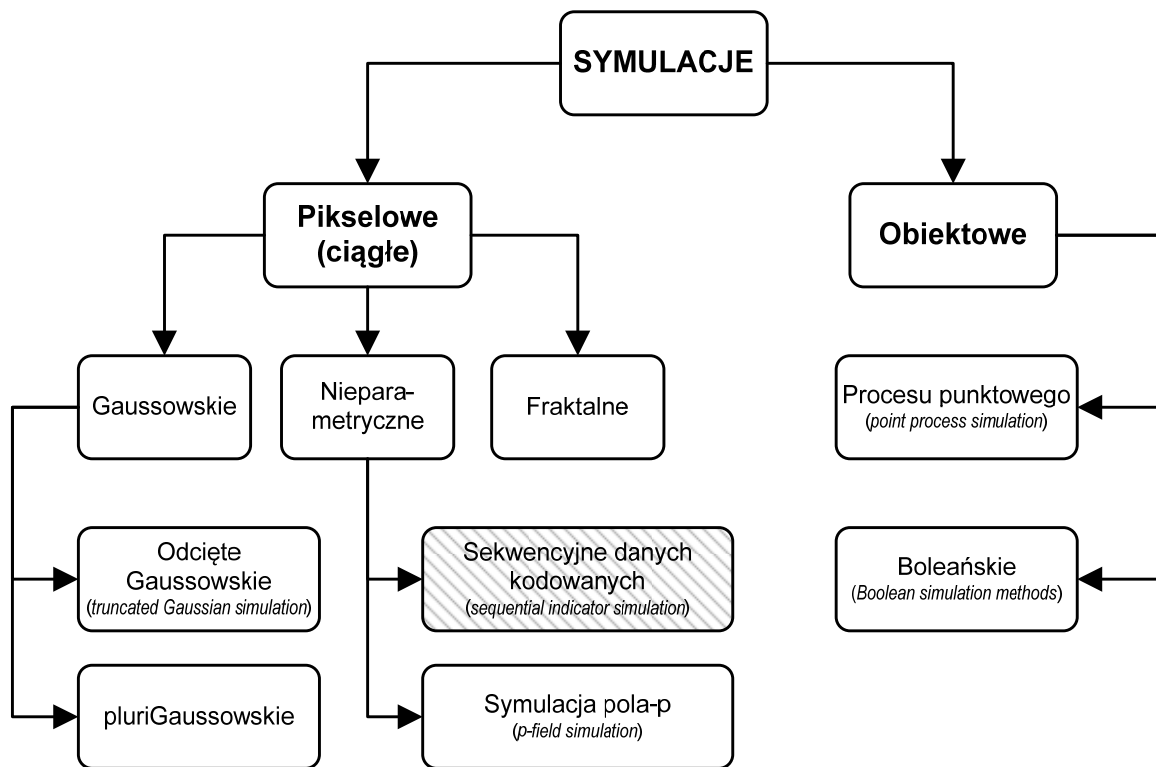
Ryc. 2. Przykład zastosowania uzupełniających danych jakościowych do polepszenia efektów estymacji – interpolacji

Lewy górny róg: fragment obrazu satelitarnego doliny Ebby na Spitsbergenie Zachodnim z wyróżnionymi trzema regionami (1 – stok usypiskowy NW, 2 – dno doliny, 3 – stok napływowy SE). Prawy górny róg: rzeczywisty obraz natężenia refleksyjności w podczerwonym przedziale widma (13000 pikseli). Środkowy lewy: 250 losowych próbek (1,9% populacji). Środkowy prawy: interpolowany metodą zwykłego kriginu (OK) z 250 próbek obraz zmienności natężenia refleksyjności w podczerwieni. Lewy dolny róg: interpolacja przy wykorzystaniu informacji jakościowych (regionów) metodą kriginu stratyfikowanego (KWS). Prawy dolny róg: interpolacja przy wykorzystaniu informacji jakościowych (regionów) metodą prostego kriginu ze zmiennymi średnimi lokalnymi (SKlm). Dokładne objaśnienia w tekście.




Ryc. 3. Przykład estymacji rozkładu przestrzennego danych jakościowych (kategorii)

Lewy górny róg: klasyfikacja pokrycia terenu fragmentu doliny Ebby na Spitsbergenie Zachodnim oparta o dane satelitarne z zakresu światła widzialnego i bliskiej podczerwieni z lat 2001 – 2004. Prawy górny róg to mapa zasięgu wyróżnionych kategorii wykonana na podstawie 250 próbek (patrz Ryc. 2) metodą najbliższego sąsiada (*nearest neighbour*). Pozostałe cztery mapy pokazują zasięg prawdopodobieństwa większego od 0,5 przynależności do kategorii 1 – 4 oszacowany na podstawie tych samych 250 próbek za pomocą krigingu wartości kodowanych (*Indicator Kriging*).



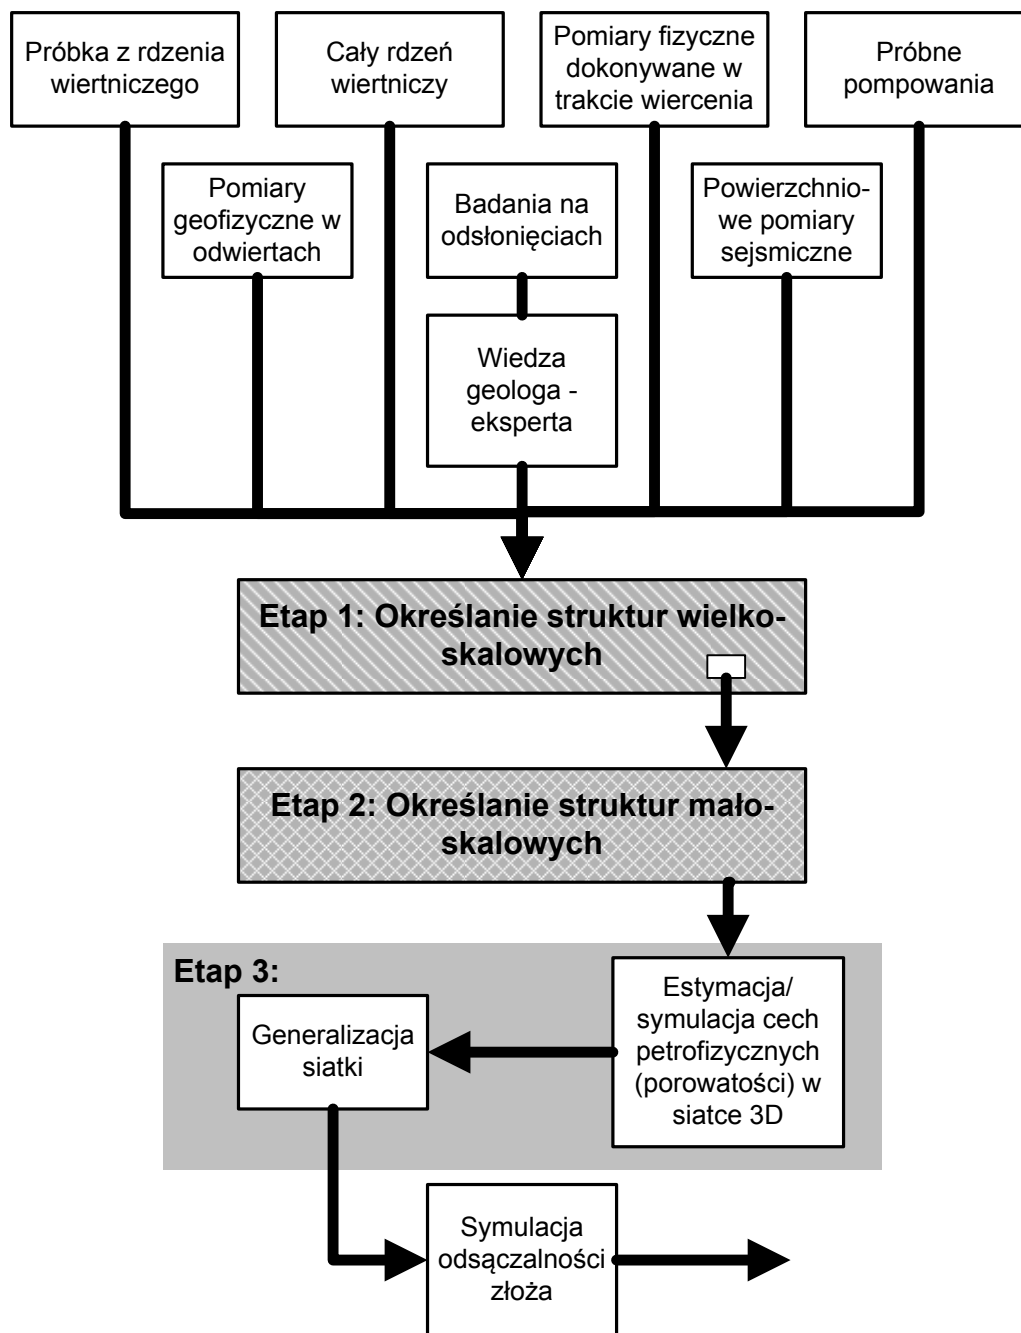
Ryc. 4. Klasyfikacja geostatystycznych metod symulacji przestrzennych danych jakościowych (kategoryzowanych)

Zastosowanie metody oznaczonej na schemacie szrafowanym tłem zostało zaprezentowane na Ryc. 5.



Ryc. 5. Przykład symulacji rozkładu przestrzennego danych jakościowych (kategorii)

Lewy górny róg jak na Ryc. 3. Pozostałe 5 mapek pokazuje przykładowe realizacje stochastyczne metodą sekwencyjnej symulacji wartości kodowanych (*Sequential Indicator Simulation*). Każdy uzyskany obraz honoruje dane pomiarowe (250 prób) w ich lokalizacjach (*conditional simulation*), globalną proporcję i strukturę przestrzenną poszczególnych kategorii. Obrazy estymowane (interpolowane) nie zachowują cech rozkładu statystycznego próby ani jej struktury przestrzennej.



Ryc. 6. Etapy tworzenie modelu zbiornika bituminów na podstawie danych pomiarowych i wiedzy eksperta przy zastosowaniu metod geostatystycznych (Oilfield Review 1992, zmienione)

Etapy 1 i 2 związane są z estymacją/symulacją cech jakościowych złoża – facji/subfacji osadów