

Poszukiwanie „śladowych” obiektów geologicznych przy cząstkowej informacji geologicznej i sieci zaszumionych pomiarów geofizycznych

Jan Dzwinel*, Witold Dzwinel**, Krzysztof Dzwinel***

Problemem geologa jest możliwość bezpośredniej integracji swojej wiedzy i intuicji geologicznej z licznymi zbiorami informacji geofizycznych nie obciążonymi subiektywizmem interpretacji geofizycznej.

Całość dostępnych geologowi informacji składa się: z ilości N cząstkowych informacji geologicznych (ograniczonych do nielicznych wierceń) i sieci K punktów pomiarów M atrybutów geofizycznych lub geochemicznych.

Atrybuty te są zwykle bardzo silnie zaszumione informacjami nie dotyczącymi tematu badawczego geologa lub geofizyka.

Problem sprowadza się, zatem, do rozpoznania i wydzielenia informacji „utopionych” w geologicznym i geofizycznym szumie informacyjnym (do tego stopnia, że mają one charakter śladowy).

Każdy element materii (np. skały) ma swój odpowiednik w abstrakcyjnym „elementie informacji”. Dzisiaj wiemy, że prawu zachowania masy, w abstrakcji informatycznej jest równoważne prawo zachowania ilości informacji kodowania/dekodowania Shannona-Kołmogorowa.

Potrafiemy, drogą ciągów procesów technologicznych wydzielać z olbrzymich mas mikroskopijnie małe — „śladowe” pierwiastki. Współczesna teoria informacji i informatyka umożliwia to samo czynić i z informacją.

Podajemy algorytm oraz geologiczne przykłady rozwiązania tego problemu.

Proponowany algorytm ma uniwersalną konstrukcję i zastosowanie do poszukiwania lub badania samodzielnego, przez geologa lub geofizyka, dowolnych obiektów geologicznych. Wymaga on jedynie:

— posiadania cząstkowej informacji geologicznej oraz sieci pomierzonych wielu (M) atrybutów geofizycznych lub geochemicznych predestynowanych do tego typu badań geologicznych;

— podstawowych elementów umiejętności pracy geologa na komputerze z bazą danych geologicznych.

Sposób rozwiązania problemu

Z prawa zachowania ilości informacji kodowania (N)/dekodowania (M) Shannona-Kołmogorowa:

$$N \cdot \log n = M \cdot \log m \quad [1]$$

gdzie: N — ilość atrybutów geologicznych z gradacjami (n), M — ilość atrybutów geofizycznych z gradacjami (m) wynika, że:

Jeżeli obiekt geologiczny jest, w całości, definiowany przez N atrybutów o n gradacjach — to potrzebna jest równoważna ilość atrybutów geofizycznych M o gradacjach m — aby ten obiekt rozpoznać.

*GEOPROS S.&T. CONSULTING Ltd, os. Kolorowe 19/72, 31-940 Kraków

**Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Akademia Górniczo-Hutnicza, al. Mickiewicza 30, 30-059 Kraków; e-mail dzwinel@uci.agh.edu.pl

***Geofizyka Kraków Sp. z o.o., ul. Łukasiewicza 3, 31-429 Kraków; e-mail dzwinel@pgnig.com.pl

Rycina 1 ilustruje schematycznie transformację N_{1-n} atrybutów geologicznych w atrybuty geofizyczne M , na drodze promienia fali sejsmicznej (S) lub elektromagnetycznej (EM): powierzchnia–złoże/facja–powierzchnia. Bardzo ciekawa jest komplementarność informacji obu tych fal na trasie promienia sejsmicznego lub linii prądowej.

Transformacja (kodowanie) promienia sejsmicznego zachodzi, wzdłuż całej jego drogi, głównie na szkieletie krystalicznym skał.

Transformacja (kodowanie) linii prądowej zachodzi, wzdłuż całej drogi linii prądowej, głównie po powierzchni porowej pokrytej elektrolitami i po elektrolitach (1 m^3 skały ma od $0,25 \text{ km}^2$ do 25 km^2 i więcej, tej powierzchni!) „skażonej” geochemicznymi atrybutami ciekłych lub gazowych „emanacji złożowych” i wtórną ich zmianą lub mineralizacją, pod wpływem reakcji tych czynników z otoczeniem.

Kod „złożowy” jest zawarty nie tylko w złożu lecz i w całym specyficznym geologicznym i geochemicznym jego otoczeniu (tzw. „aureole” nad złożami kruszców, „kominy dyfuzyjne” nad złożami węglowodorów, pola termalne, polaryzacji elektrycznej, itp.), które zostało ukształtowane w całym geologicznym procesie jego kształtowania i trwania.

Często geolog, nawet z wierceń, nie ma kompletu informacji (atrybutów) geologicznych N w obszarze wierceń. Zawsze jednak, posiada informację, że w przewierconym otworze „jest” (N^A) lub „brak” (N^B) genotypu (zbioru atrybutów) poszukiwanego/badanego złoża (węglowodorów, kruszców, innych kopalin) lub facji (litologicznej, okruszczowanej, nasyconej węglowodorami, wodami mineralnymi itp.).

W ten sposób, jest on w stanie stwierdzić, że pomierzone w tych miejscach atrybuty geofizyczne, geochemiczne itp. mogą zawierać M^A lub nie zawierać M^B geofizyczne genotypy poszukiwanych/badanych obiektów. Zadaniem geofizyka jest, tak dobrać metodologię pomiarów atrybutów geofizycznych M — aby najwięcej z nich obejmowało kod genetyczny poszukiwanych obiektów, zgodnie z kryterium [1].

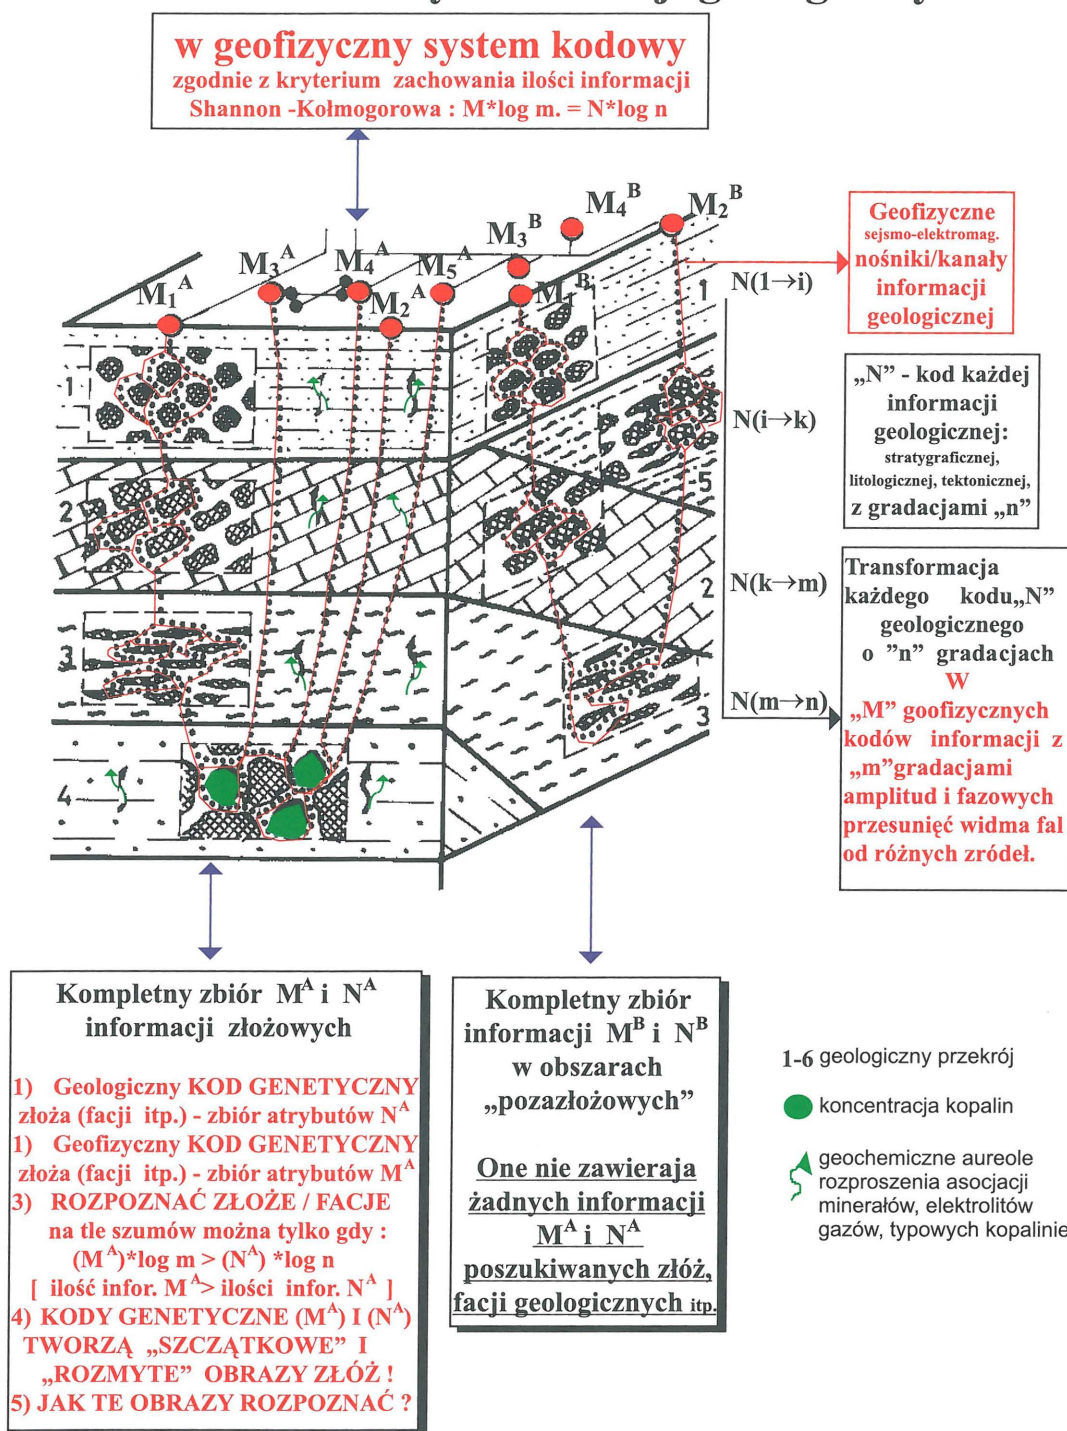
Podstawowym testem zgodności z kryterium [1] jest faktyczne uzyskanie rozdzielenia (w danym rejonie) pomiarów M^A i M^B na dwie różne klasy „jest”(+) i „brak”(-), według genotypów geologicznych: N^A , N^B .

Zarówno geolog, jak i geofizyk wiedzą, że przyjęte wzorce „startowe” mogą, lecz nie muszą być głównymi („uczącymi”) reprezentantami swoich klas (+) lub (-). Każda z tych klas może mieć rozległe „rozmyte” wzajemne granice swoich atrybutów: gradacji „ m ” i „ n ” w relacji [1]. Ponadto poszukiwana klasa (+) może być „utopiona” w lawinie informacji nie obejmujących celów poszukiwań lub badań, a klasa (-) może być bardzo zróżnicowana.

Do rozwiązania tych zadań zastosowaliśmy najnowocześniejsze narzędzia z teorii informacji i informatyki, (Czołga & Pedrycz, 1985; Goldberg, 1998; Osowski, 1996), które pragniemy w dostępny sposób przedstawić i zachęcić do ich wykorzystywania.

Narzędzia te absolutnie nie dążą do aproksymacji zjawisk geologicznych ścisłymi formułami matematycznymi

Schemat zamiany informacji geologicznych



Ryc. 1. Schemat zamiany informacji geologicznych w geofizyczny system kodowy

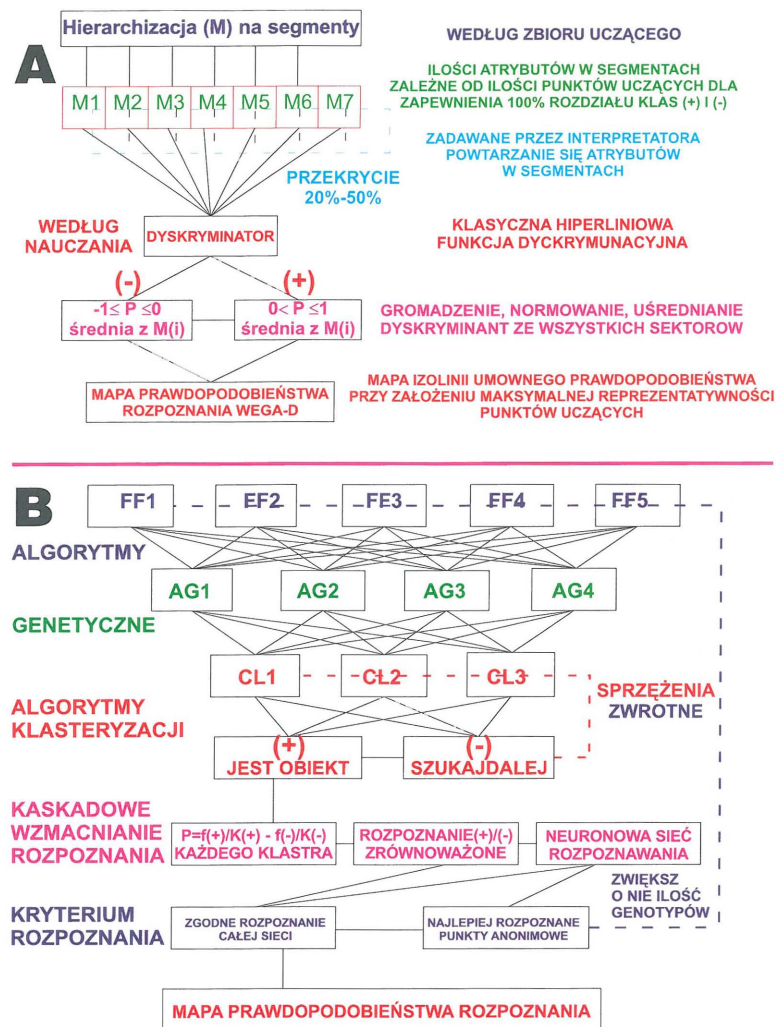
wzorów, które zawsze wśród specjalności przyrodniczych wywołują pewien sceptycyzm.

Tu cyfrowe operacje matematyczne spełniają tylko funkcje ogólne i logiczne. Schematycznie można je porównać do: „kruszarni” i „młynów” rozdrabniających sploty informacji, „sit” przesiewających te rozdrobnione informacje, „wanien flotacyjnych” lub „elektrolitycznych”, które z dużego bloku informacji (skały) wydobywają śladowe informacje (minerały), bez zniekształceń i zgodnie z prawem zachowania ilości informacji [1].

Rozwiązanie zadania na podstawie algorytmów dyskryminacji

Rycina 2A przedstawia schemat algorytmu dyskryminacyjnego rozpoznania (implementowany przez K. Dzwiniela), do poszukiwań naftowych w okresie 1988–1996 w Systemie WEGA-D (Dzwiniel & Dzwiniel, 1996).

• W oparciu o cząstkowe informacje geologiczne, tworzy się zbiór punktów „uczących”: K^+ — „jest” obiekt i K^- — „brak” obiektu, na których mierzy się (te same i w dużej ilości) atrybuty M (patrz też ryc. 1, 3).



Ryc. 2A Schemat algorytmu „dyskryminacyjnego” rozpoznawania
 Ryc. 2B Schemat algorytmu sieci neuronowej rozpoznawania MEGA-D

• Dokonuje się hierarchizacji wszystkich atrybutów M według wielkości ich różnicy pomiędzy zbiorem punktów K⁺ i zbiorem punktów K⁻; (uporządkowanie zbioru informacji).

• Kolejno od czoła hierarchicznego ciągu atrybutów, tak wybiera się segmenty atrybutów: M1, M2, ..., Mi, aby dla punktów „uczących” K⁺ i K⁻ następował zawsze 100%-owy ich podział na klasę (+) i klasę (-). Poza 1. segmentem, następne segmenty mogą „sąsiadować” lub zawierać 20%–50% atrybutów z poprzedniego segmentu; (segmentowanie „proste” lub „z przekryciem”).

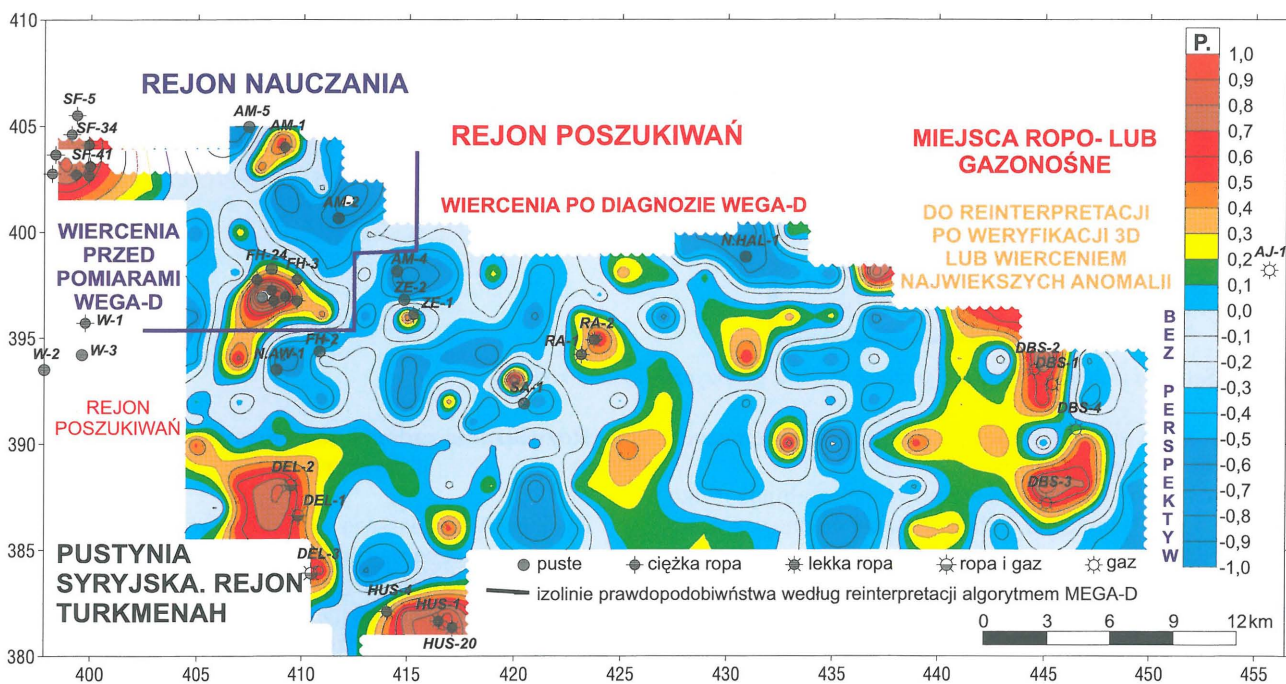
• Segmenty dobiera i rozpoznaje liniowa funkcja dyskryminacyjna „nastrojona” na 100% warunek rozpoznania wyłącznie znanych punktów uczących; („dobór sita” do wzorców).

• Tak „nastrojony” dyskryminator dzieli na klasy (+) i (-) wszystkie K punktów anonimowych; („przesiew”).

• Nadaje im oceny rozpoznania (oddzielnie dla każdego segmentu) dla klasy (+) w granicach $0 < p \leq 1$ i dla klasy (-) w granicach $1 \leq p \leq 0$; („odwirowywanie” = „flotacja” = „wyflukiwanie”).

• Następnie gromadzi je ze wszystkich segmentów, „odwirowuje” łącznie przez „wyważone sita” i przedstawia w postaci mapy izolinii wartości $-1 \leq P \leq 1$, dla wszystkich K — jako finalną mapę umownych prawdopodobieństw należenia do klasy (+) lub (-); (przykłady rozpatrzmy dalej na ryc. 4).

Algorytm ten zakłada, że: podobnie do punktów uczących K⁺ i K⁻ dzielą się wszystkie punkty anonimowe K, a stopień „ukrycia” (zaszumienia) całej klasy nierozpoznanych K⁺ i K⁻ jest również podobny.



Ryc. 3. Mapa MEGA-D prawdopodobieństwa obecności węglowodorów; reinterpretacja pomiarów WEGA-A algorytmem MEGA-D; Pustynia Syryjska, rejon Turkmenah

Algorytm ten ma, więc, kłopotliwe ograniczenia warunków zastosowania. Ma on też ograniczoną stosowność w przypadkach „zaszumienia” i „rozmycia” informacji M — szczególnie, gdy mają one tylko śladowy charakter.

Algorytm ten działa jak „młyn” zaopatrzonego w selektywne „sita” i „wirówki”. Rozdrobi, przesieje sitami według wzorca, odwiruje na frakcje: $-1 < P < 0$ i $0 < P < 1$ i przedstawi w postaci mapy: $-1 < P < 1$ (ryc. 4). Pomimo tych ograniczeń algorytm ten (ze względu na dużą statystykę „segmentów”, możliwości różnorodnych kombinacji „przekryć” wektorów M .) daje w różnych regionach geologicznych dobre wyniki (Dzwinel & Dzwinel, 1995; Dzwinel & Dzwinel, 1996).

Problem powstaje, gdy „wzorce uczące” reprezentują, nie ogólne, a tylko rzadkie i szczególne przypadki, gdy śladowe informacje są sprzężone z niepożądanymi informacjami tak, że nie poddają się prostym i wielokrotnym „odwirowaniom”.

Ograniczenia te eliminuje algorytm oparty na najnowszych osiągnięciach informatyki w zakresie: algorytmów genetycznych, analizy klastrowej i sieci neuronowych Czołga & Pedrycz, 1985; Goldberg, 1995; Osowski, 1996).

Rozpoznanie algorytmem MEGA-D w oparciu o algorytmy genetyczne, klasteryzacji i sieci neuronowe

Rycina 2B ilustruje, w ogólnie czytelny sposób, istotę konstrukcji tego algorytmu, opracowanego przez W. Dzwinelę dla celów poszukiwania „śladowych” obrazów „rozmytych” w szumie informacyjnym.

• Z cząstkowych informacji geologicznych N^A w punktach K^A — „jest obiekt” i N^B — w punktach K^B — „brak obiektu” oraz z dokonanych w obrębie ich pomiarów tych samych M atrybutów geofizycznych M^A i M^B , (ryc. 1) definiuje się tzw. kryteria testu: $FF1, FF2, \dots, FFi, \dots, FFm$. Różnorodność tych funkcji umożliwia uwzględnienie hipotetycznego założenia o „rozmytej” reprezentatywności punktów K^A i K^B dla całości zbiorów anonimowych punktów klasy K^A i K^B .

• Kryteria testu-to funkcje FFi , tak rozdzielające „startowe” zbiory punktów pomiarowych K^A i K^B względem K^B z genotypami odpowiednio M^A i M^B aby:

1. Granice dzielące punkty K^+ = „jest” i K^- = „brak” obejmowały wszystkie i prawdopodobne, w danym regionie geologicznym, warianty występowania złóż (obiektów) i różnej roli w nich punktów K^A i K^B .

2. „Startowe” punkty K^A i K^B stanowiły tylko losowe przypadki geologiczne możliwych (i) warunków występowania wobec innych, anonimowych punktów K^+ , otaczających je punktów K^- i ich sytuacji geologicznych (nie zakłada się, że są one „typowe” = „uczące” dla tego rejonu poszukiwań).

• Algorytm genetyczny AG „krzyżuje” ze sobą, na wzór biologiczny, dwa genotypy (łańcuchy genetyczne atrybutów M) każdego pomierzonego punktu K z każdym punktem K i według zasady Darwina, zachowuje tylko genotyp złożony z najsilniejszych atrybutów $M(i)$ w „rodzinie” (zbiorze) $FF(i)$. W ten sposób dobiera do każdej sytuacji (i) najlepszy zbiór atrybutów (genotyp) złożony $M(i)$; (spełnia rolę selektywnego „sita” do odsiania dobrych atrybutów M).

• Stosuje się celowo kilka różnych algorytmów genetycznych: AG1, AG2, ..., AGn, a każdy z nich ze wszystkimi funkcjami $FF1, FF2, \dots, FFi, \dots, FFm$. Taka operacja

powiększa ilość („sit”) odgałęzień „neuronowych” do ilości $m \cdot n$ i jednocześnie w każdym odgałęzieniu, niezależnie, eliminuje te atrybuty M , które nie biorą istotnego udziału w kodzie genetycznym złoża, facji itp...

• Z każdego AGn, każdy genotyp $M(i)$, przekazuje się do kilku różnych algorytmów klasteryzacji CL1, CL2, ..., CLk. Każdy CLk dzieli cały zbiór punktów K (całkowicie niezależnie od K^+ i K^-) na kilka (naście) klas (grup) C , według kryterium „najlepszego sąsiedztwa”. W ten sposób sieć uzyskuje $b = m \cdot n \cdot k$ rozgałęzień z których każde wydziela C klastrów. (Realizuje się „sito” do przesiewania punktów K po przesianiu atrybutów M).

• Ilość C klastrów w każdym CLk powiększa się aż do „przebicia się poprzez zakłócenia” i uzyskania 20%–30% klastrów C z przewagą stosunku częstości (f^+) pojawiania się K^+ ($f^+/K^+ = p^+$) nad stosunkiem ($f^-/K^- = p^-$). To jest, do uzyskania stwierdzenia „jest obiekt”. W przeciwnym przypadku podaje się polecenie „szukaj dalej” i powtarza się klasteryzację na innym parametrze sterowania CLk. W ten sposób „wydobywa się” coraz głębiej ukryte (zaszumione = „utopione”) genotypy złożowe w każdej z $b = m \cdot n \cdot k$ odgałęzień sieci (jest to „flotacyjne” = „elektrolityczne” wydzielenie wzbogaconych agregatów informacji).

• W każdej gałęzi sieci dokonuje się indywidualnej, dla każdego klastra C , oceny rozpoznania według relacji:

$$p_c = f^+/K^+ - f^-/K^- = p_c^+ - p_c^- \quad [2]$$

• Ta gałąź jest zakwalifikowana $b_{ijk} = (m_i \cdot n_j \cdot k_k)$, dla której da się obustronnie (operacją tłumienia ekstremalnych wartości) zrównoważyć rozpoznanie:

$$\text{suma } p_c \text{ dla wszystkich } K^+ = -(\text{suma } p_c \text{ dla wszystkich } K^-) \quad [3]$$

Operacja ta, zrealizowana dla każdego klastra C na wszystkich punktach K doprowadza do:

1. Wydobywania poszukiwanego obiektu „jest” z pozycji „śladowej” na równorzędną pozycję „brak”.

2. Zamiany (transformacji) ich przynależności klastrowej C ($C = 0, 1, 2, 3, \dots, 9, \dots$) na miarę umownego prawdopodobieństwa, należenia do klasy „jest złożo” ($1 > p_c^+ > 0$) lub klasy „brak złożo” ($-1 < p_c^- < 0$); („odwirowanie” informacji).

3. Dalszego „kaskadowego” wprowadzenia przetransformowanych, dla każdego anonimowego punktu, wektorów-synaps do klasycznej sieci neuronowej — jako ostatniego stopnia weryfikującego rozpoznanie.

• Ostatecznie zostaje zakwalifikowana taka struktura ($b_{opt} = m_{opt} \cdot n_{opt} \cdot k_{opt}$) — gałęzi grafu sieci, która w sumie [3], zwielokrotnionej b_{opt} razy, będzie bezbłędnie zaliczać, swoją średnią wielkością P każdy punkt K^+ ($P > 0$) i K^- ($P < 0$) do swojej klasy (+) lub (-).

• najlepiej rozpoznany punktami anonimowymi, na zasadzie sprzężenia zwrotnego, uzupełnia się funkcje $FF(m_{opt})$ i proces powtarza się już tylko w strukturze sieci $b_{opt} = m_{opt} \cdot n_{opt} \cdot k_{opt}$, aż do uzyskania stabilnej mapy $-1 < P < 1$ umownego prawdopodobieństwa rozpoznania poszukiwanego obiektu ($0 < P < 1$) i jego otoczenia ($-1 < P < 0$) (ponowne „odwirowanie-elektroliza” frakcji(+) od (-)).

Przykłady zastosowania

Oba algorytmy mogą być stosowane do dowolnych zadań geologicznych jeżeli:

• istnieją cząstkowe rzeczywiste lub hipotetyczne informacje geologiczne (N) i sieć wielu atrybutów geofi-

zycznych (M) lub geochemicznych (M_G) lub cyfrowych zdjęć (lotniczych, mikroskopowych) na różnych częstotliwościach świetlnych (M_L) itp.;

- bardzo dobre zbiory atrybutów M_S zapewnia sejsmika 3D, a szczególnie jej „okna” amplitud rzeczywistych dla badanych kompleksów stratygraficznych (w postaci atrybutów: transformat Korhunena-Leove’go, częstości przejścia „0”, atrybutów amplitud, pochłaniania, selekcji klastrowych itd.);

- bardzo dobre zbiory atrybutów M zapewnia geoelektromagnetyka, dla której (w Systemie MEGA-D) przy: (f) częstotliwościach, (t) charakterystykach czasowych, (T) różnych źródłach zasilania, (R) różnych odbiornikach składowej elektrycznej i magnetycznej, (d) różnych odległościach nadajnik-odbiornik, uzyskuje się ilość $M = f \cdot t \cdot T \cdot R \cdot d$ atrybutów, dla pomierzonego sygnału amplitudy i tyle samo dla przesunięć fazowych (w systemie WEGA-D atrybutów jest o $(t \cdot d) = 20 \cdot 3 = 60$ razy mniej).

- sieć pomiarów geochemicznych, rozłożonych na atrybuty: minerałów, związków chemicznych, składów jonowych itp.;

- również kompleks innych godnych informacji: gravimetrycznych, magnetycznych, radiometrycznych, termicznych i innych jeżeli są one współzależne z kodem genetycznym poszukiwanego obiektu.

Tylko ze względu na dostępność, obszerny zakres pomiarów w różnych warunkach geologicznych (od Kanady, Polskę, Węgry do Syrii — na 15 000 km² powierzchni) oraz oczywistość faktu „śladowości” obiektów złożowych węglowodorów wraz z ich „kominem dyfuzyjnym” — zostaną przedstawione przykłady analizy atrybutów elektromagnetycznych WEGA-D.

System *Wielowymiarowe Elektromagnetyczne Geofizyczne Atrybuty* — WEGA-D daje zbiory atrybutów w przedziale: $250 < M < 700$. Atrybuty te uzyskuje się (ryc.1) z: 6–10 częstotliwości (f), 6–10 różnych źródeł zasilania (T) i odbioru ($R=7$) dla 4-ech składowych elektrycznych + 3 składowe magnetyczne ($M = f \cdot T \cdot R$).

Przykład 1. Pustynia Syryjska, rejon Turkmenah. Złoża węglowodorów występują w dolomitach Kurachina, 1250–1500 m (trias) i w skałach węglanowych Markada, 2100–2500 m (karbon).

Cząstkowej informacji geologicznej (N) dostarczał mały fragment obszaru (ryc. 3 „rejon nauczania”). W tym „rejonie nauczania” tzw. struktury sejsmiczne 2D nie zawsze korelowały się ze zbiornikowymi atrybutami dolomitów i szereg wierceń było nietrafnych. Stąd pomiary WEGA-D (1988) zrealizowane na otworach „jest” i „brak” dały punkty uczące K^+ i K^- ze zbiorami atrybutów (genotypami) M^+ i M^- .

Cały rejon, w tym i „rejon poszukiwań” pokryto siecią 2 km x 2 km pomiarów WEGA-D z ilością punktów $K=216$ i ilością atrybutów $M=252$ — amplitudy i $M=252$ — fazy, na każdy punkt K.

Pomiary WEGA-D opracowano według algorytmu dyskryminacyjnego (algorytm „neuronowy” MEGA-D opracowano w 1998 r.) w postaci mapy prawdopodobieństwa występowania złóż węglowodorów WEGA-D.

Na podstawie gęstej sieci sejsmicznej 2D i mapy WEGA-D, zaczęto rozwierać „rejon poszukiwań” w oparciu o strategiczną zasadę: „Wiercić w miejscach najlepszej zgodności 2D i WEGA-D”.

Wszystkie wiercenia według tego kryterium w 100% odkryły złoża ropy i gazu (ryc. 3).

W przypadku wiercenia ZE-1, duża i dobra „struktura” 2D, wbrew negatywnej diagnozie WEGA-D zachęciła do następnego wiercenia ZE-2. Okazało się ono puste z powodu braku korelacji jakości „struktury” z jakością dolomitowego kolektora (złoża i jego „komin dyfuzyjny” nie rozwinęły się na całej strukturze sejsmicznej).

Podobnie było z wierceniami na dobrych strukturach 2D: SA-1 i N.HAL-1 lecz nie akceptowanych przez WEGA-D. Wiercenia DEL akceptowały strukturę 2D lecz z niewielkim wskaźnikiem +P.

Ryc. 3 przedstawia mapę zreinterpretowaną (w 1999 r.) algorytmem MEGA-D.

W jednoznaczny sposób MEGA-D rozpoznaje złoża węglowodorów różnych klas i w różnych warunkach geologicznych. Sugeruje ona ponadto optymalny i oszczędny wybór powierzchni pomiarów dla 3D oraz nieperspektywność ekonomiczną, w warunkach Syrii, wielu małych obiektów. Porównanie jakości map WEGA-D i MEGA-D, w tym przypadku opuszczamy, ponieważ podobne ono jest do porównania podanego dalej dla warunków polskich (ryc. 4, 5).

Przykład 2. Przedgórze Karpat, rejon Nosówka.

Ryc. 4 przedstawia mapę geologiczną Moryca (1992) na którą, za zgodą autora, naniesiono izolinie prawdopodobieństwa istnienia złóż WEGA-D z lat: 1980 i 1992. Izoliny z 1980 r. opracowano dla gęstości pomiarów 1 punkt WEGA-D na 5,3 km² powierzchni poszukiwań. Punkty uczące wykonano na znanych złożach: Sędziszów, Czarna Sędziszowska, Kielanówka.

Po rozpoznaniu sejsmicznym 2D, na zgodnym z WEGA-D (9 lat wcześniej wskazanym obiekcie!) wierceniem Nosówka-1 odkryto złoża ropy w karbonie. W 1992 r. wykonano solidną sieć pomiarową WEGA-D z: gęstością średnią 1 punkt na 0,6 km², ilością punktów $K=286$, ilością atrybutów $M=490$ — dla pomiarów amplitud oraz $M=490$ — dla pomiarów przesunięć fazowych fal elektromagnetycznych.

Atrybuty $M=490+490=980$ zostały opracowane algorytmem dyskryminacyjnym (ryc. 2A).

Przedstawione w postaci mapy ryc. 4 wyniki (Dzwinel & Dzwinel, 1996) wydobywają z „szumu geologicznego” nowe obiekty złożowe. Weryfikacja ich wierceniami okazała się następująca:

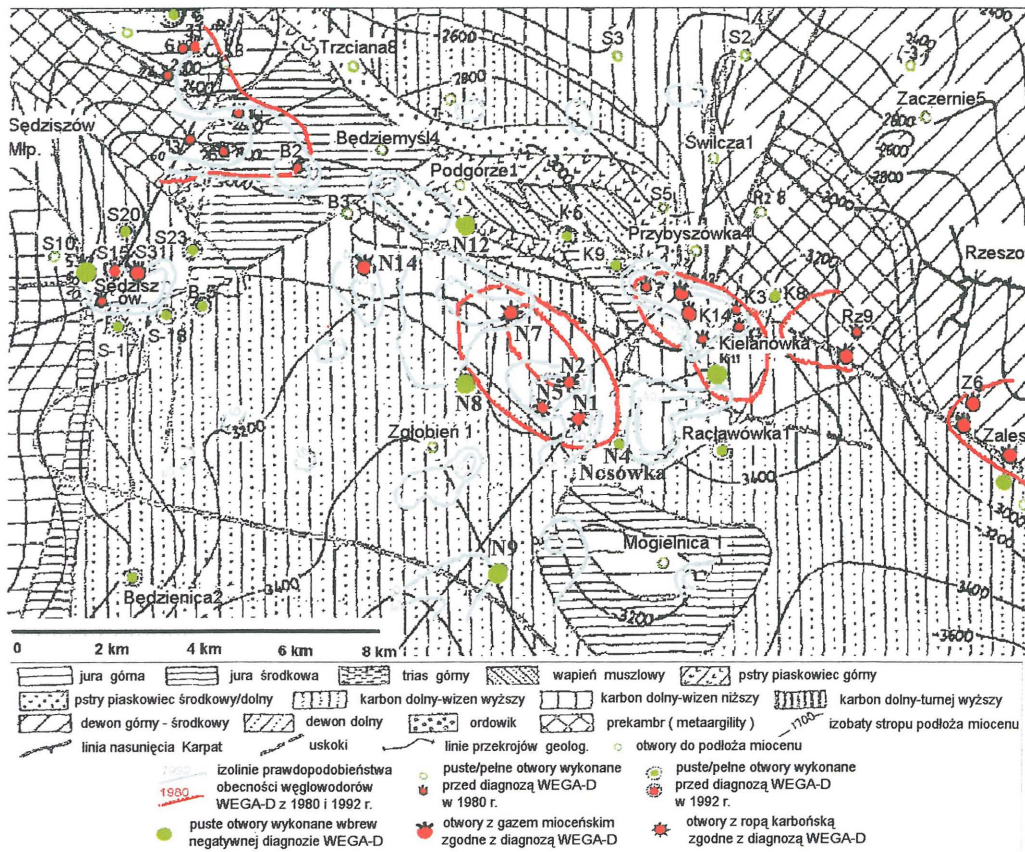
- wiercenia dla zgodnych diagnoz 2D i WEGA-D : N-2, N-5, N-7, N-14 - odkryły ropę i gaz,

- wiercenia zgodne ze „strukturami” 2D i niezgodne z WEGA-D (1992): N4, N-8, N9, N-12 -były puste,

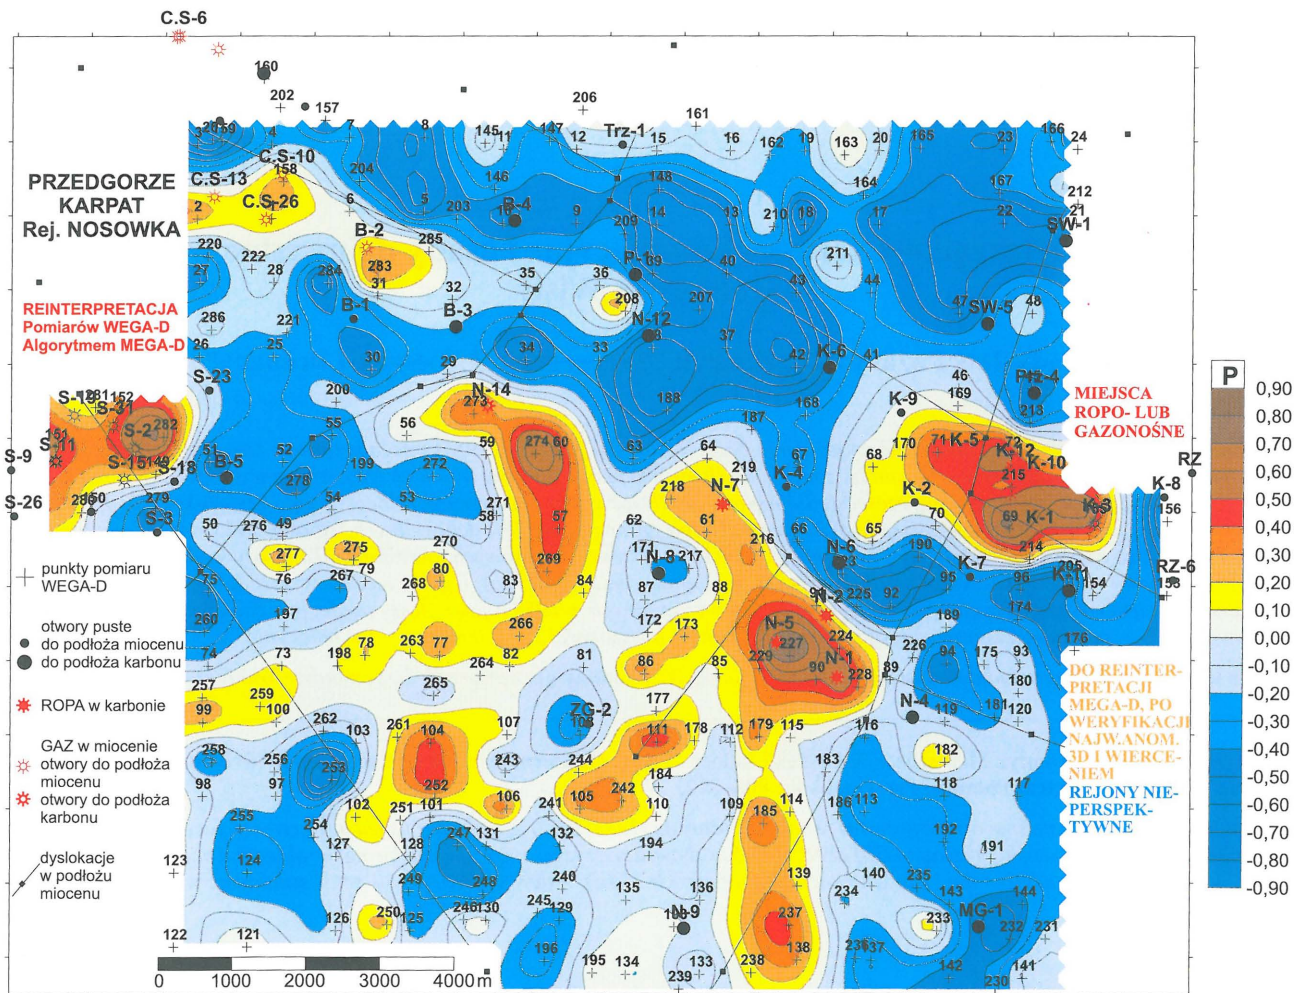
Rycina 5 przedstawia te same pomiary opracowane w 1999r według algorytmu MEGA-D (jest to autorska prezentacja). Algorytm ten, poza zdecydowanie wzmocnionym wydzieleniem już rozpoznanych złóż (porównaj ryc. 4 -5). wydobywa z „szumu geologicznego” nowe — mniejsze obiekty klasy złożowej. Wskazuje, w ten sposób, dla sejsmiki 3D i geologów, nowe obszary „szczególnego zainteresowania” w tym rejonie.

Wykonane 2 lata wcześniej pomiary 3D (na całym obszarze ryc. 5) i zinterpretowane tradycyjnie, nie dostarczyły dostatecznej jakości atrybutów informacji „strukturalnych” dla podjęcia decyzji wykonania wierceń w tych „szczególnych” miejscach.

Bardziej szczegółowa, reinterpretacja „klasyczna” 3D, pii prędkości (w obszarach anomalii MEGA-D) — może skorygować obraz „strukturalny”. Wymaga ona analizy maksymalnej ilości atrybutów, a szczególnie z „okien” miocenu gazonośnego i karbonu roponośnego — dla głębokości ok. 1200–1500 m i ok. 3100–3800 m. Możliwe



Ryc. 4. Mapa geologiczno-strukturalna podłoża miocenu (wg Moryca, 1992) z mapami prawdopodobieństwa WEGA-D; przedgórze Karpat, rejon Nosówka



Ryc. 5. Mapa MEGA-D prawdopodobieństwa obecności węglowodorów; przedgórze Karpat, rejon Nosówka

jest też „sformatowanie” tych atrybutów dla zastosowania algorytmu MEGA-D w podobny sposób, jak to przedstawi- liśmy. Oczekiwać należy od reinterpretacji 3D, wydzielenia i rozpoznania sytuacji geologicznych występowania facji z „rodziny” tych, które obecnie zawierają złoża węglowodorów, oraz ocenić przy pomocy MEGA-D, wielkość prawdopodobieństwa ich występowania (w postaci mapy podobnej do ryc. 5).

Zakończenie

Niedostępność sieci wieloatrybutowych pomiarów, nie tylko sejsmicznych 3D lecz geochemicznych, oraz kompozycji atrybutów: grawimetrycznych, magnetycznych, termicznych, radiometrycznych itp., cyfrowych zdjęć spolaryzowanej/nie spolaryzowanej fali świetlnej o różnej długości (np. fragmentów zdjęć księżyca) — nie pozwoliła autorom podać przykłady poszukiwania lub badania innych i w innych miejscach (nie naftowych) „śladowych” obiektów „utopionych” w szumach informacyjnych.

Podane „naftowe” przykłady zastosowania software MEGA-D (przy hardware MEGA-D zapewniającym miesięczne rozpoznanie ok. 300 km² powierzchni za cenę 3–15 razy mniejszą od 1 km bieżącego profilu sejsmicznego 2D) są pouczające dla wyboru strategii „czas-koszt-efekt” w kompleksie z sejsmiką 2D i 3D. Rozwój MEGA-D, jest poddawany publicznej profesjonalnej ocenie Komisji Kwalifikacyjnych i uczestników najbardziej prestiżowych międzynarodowych konferencji geofizycznych i informatycznych (Dzwinel & Dzwinel, 1996; Dzwinel & Dzwinel, 1997). Aktualny etap jego rozwoju przedstawia ta publikacja.

Podany algorytm ma ogólne zastosowanie. Nie wymaga

on aby niepewnie rozpoznane środowisko i formy geologiczne *a priori* opisywać bardzo pewnymi (zdeteterminowanymi) funkcjami matematycznymi i bardzo kosztownymi pomiarami.

Na wzór pracy neuronowych struktur biologicznych, ich zasad ewolucyjnego dostosowania się „najtańszym kosztem” do stawianych celów — współczesna informatyka daje dodatkowe — nowe narzędzie badawcze. Ono nie zastępuje zdeteterminowanego aparatu matematycznego geofizyki (odwzorowującego geometrię przestrzenną), metodologii i techniki geologicznej (wypełniającej tę przestrzeń treścią geologiczną) lecz umożliwia jedynie stosować je w obszarach istotnych dla geologa, to jest stosować w sposób najbardziej racjonalny technicznie, ekonomicznie i intelektualnie.

Literatura

- CZOGAŁA E. & PEDRYCZ W. 1985 — Elementy i metody teorii zbiorów rozmytych. PWN.
- DZWINEL J. & DZWINEL K. 1996 — Strategia i taktyka zastosowania Systemu WEGA-D na Przedgórzu Karpat. Polski. Gaz i Nafta, 6: 7–12.
- DZWINEL J. & DZWINEL K. 1995 — Mnogomiernyje elektromagnitnyje poiski uglewododorodow sistiemoj MEGA-D. International Geophysical Conference & Exposition (SEG, EAEG, EAGO), Juli, St. Petersburg, Russia, 1: 35–36.
- DZWINEL W., DZWINEL J. & DZWINEL K. 1997 — Development of Parallel Application for MEGA-D System for Oil and Gas Prospecting. International Conference on High Performance Computing and Networking HPCN'97, April, Vienna, Austria: 223–231.
- GOLDBERG D. E. 1995 — Algorytmy genetyczne i ich zastosowanie. Wyd. Naukowo-Techniczne.
- OSOWSKI S. 1996 — Sieci neuronowe w ujęciu algorytmicznym. Wyd. Naukowo-Techniczne.
- MORYC W. 1992 — Budowa geologiczna utworów podłoża miocenu w rejonie Sędziszów Młp.-Rzeszów i ich perspektywność. Nafta-Gaz, 9–10: 205–223.