

MIKOVINY SÁMUEL FÖLDTUDOMÁNYI DOKTORI ISKOLA
Iskolavezető: DR. KOVÁCS FERENC AKADÉMIKUS

MÉLYFŰRÁSI GEOFIZIKAI ADATOK
ÉRTELMEZÉSÉNEK MODERN INVERZIÓS
MÓDSZEREI

DOKTORI (PHD) ÉRTEKEZÉS

Írta:
SZABÓ NORBERT PÉTER

Tudományos vezető:
DR. DOBRÓKA MIHÁLY
egyetemi tanár
a műszaki tudomány doktora

Miskolci Egyetem
Geofizikai Tanszék
Miskolc
2004.

TÉMAVEZETŐI AJÁNLÁS

Szabó Norbert Péter

”Mélyfúrási geofizikai adatok értelmezésének modern inverziós módszerei”

című doktori (PhD) értekezéséhez

A doktori (PhD) értekezés témájául választott együttes geofizikai inverziós problémakör a nemzetközi szakmai érdeklődés előterében áll. A dolgozatban bemutatott eredményeivel a Jelölt a mélyfúrási geofizikai adatok értelmezésének inverziós tématerületét gazdagítja azáltal, hogy globális optimalizáció módszereinek alkalmazásával intervallum inverziót végez a pontonkénti inverziós módszerekhez képest jelentős pontossági és megbízhatósági javulást érve el.

A globális optimalizációs eljárások közül Jelölt a Simulated Annealing és a Genetikus Algoritmus módszerét választja és a mélyfúrási geofizikai adatok feldolgozására ezek javított változatait vezeti be: általánosított objektív függvényt definiál, és ennek minimalizálásával adja meg az inverz probléma megoldását. Vizsgálatai során új módszereket fejleszt ki részben a mélységpontonkénti, részben pedig az intervallum inverzió terén. Az új inverziós módszereket algoritmizálja, majd MATLAB 6. rendszerben szoftvereket fejleszt ki. Ennek alapján numerikus összehasonlító vizsgálatokat végez a hagyományos pontonkénti és intervallum inverziós, illetve a linearizált és globális optimalizációs eljárások között. Az inverziós algoritmusokat szintetikus és terepi szelvényadatokon teszteli és vizsgálja az inverziós módszerek pontosságát, megbízhatóságát és stabilitását. Az intervallum inverziós módszert kiterjeszti intervallumon vertikális változást mutató modellparaméterek meghatározására is. Ehhez hatványfüggvény szerinti sorfejtést alkalmaz egy rétegben, melynek sorfejtési együtthatóit az intervallum inverzió modellvektorába foglalja. Kidolgoz egy a globális és linearizált optimalizáción alapuló kombinált intervallum inverziós módszert is. Ennek lényege, hogy startmodell-független globális optimalizációval kezdve a keresést az iteráció során eljut a globális optimum közelébe, ahonnan linearizált módszerrel folytatva az eljárást a futási idő lényeges csökkentésével jut megoldásra. E módszer lehetővé teszi a becsült paraméterek hibájának és megbízhatóságának meghatározására ismert módszerek alkalmazását.

Az inverziós kutatásaihoz szükséges mértékben Jelölt foglalkozik a mélyfúrési geofizikai előremodellezés kérdéseivel is. Elemzi a mélyfúrési geofizikai direkt feladatban szereplő válaszfüggvények paraméter-érzékenységeit a paraméterek inverziós meghatározhatóságának szempontjából és a gyakorlat számára fontos következtetésekre jut.

Elméleti vizsgálatainak tapasztalatait terepi mérési adatok inverziós kiértékelése terén hasznosítja az inverziót egy hazai szénhidrogén-kutató fúrás szelvényadatain (először mélységpontonkénti, majd intervallum) inverziós kiértékelést végezve el. Ez utóbbi módszerrel automatikus rétegvastagság-meghatározást is bemutat. Az egyik tároló rétegben hatványfüggvény szerinti sorfejtéssel, vertikálisan változó petrofizikai paramétereket feltételezve inverziós becslést végez a tárolók porozitására, agyagtartalmára és víztelítettségére és megadja a mozgásképes és maradék gáztelítettséget.

A fentiek alapján megállapítható, hogy doktori értekezésében a Jelölt a kitűzött tudományos feladat igényes, az inverziós eljárások bevezetése tekintetében pedig kifejezetten elegáns megoldását adja meg és aktuális területen új tudományos eredményekre jut. Eredményeit a szakmai hazai és nemzetközi fórumai előtt bemutatta, publikációs teljesítménye kielégíti a Miskolci Egyetem Doktori (PhD) Szabályzatában megfogalmazott feltételeket. A dolgozat a formai követelményeknek megfelel.

Az értekezés nyilvános vitára bocsátását és Jelölt részére a doktori (PhD) cím odaítélését meggyőződéssel javaslom.

Miskolc, 2004. november 29.

Dobróka Mihály
egyetemi tanár,
a műszaki tudomány doktora

MODERN INVERSION METHODS FOR THE INTERPRETATION OF WELL-LOGGING DATA

- Ph.D. Thesis -

Author: Péter Norbert Szabó
Scientific adviser: Prof. Dr. Dobróka Mihály

In the thesis new inversion methods for the interpretation of geophysical well logging data are presented. The object of the interpretation procedure is to detect various rocks in the sequence of strata and determine their layer-thicknesses and some petrophysical parameters so as to characterize the geometrical and physical properties of the layers for the exploration of mineral stocks. Extracting this information from the data set the most sophisticated way is to use advanced inversion methods.

In the industrial practice the inverse problem is usually solved by local gradient-based linearized point by point inversion methods. Having enough a priori information about the formations investigated they work as very quick and effective algorithms. However, in case of extensive inversion problems they can assign the solution to a local optimum of the objective function with high probability. This problem is reformed by the global optimization methods that search for the absolute extremum of the objective function. I used Simulated Annealing method (Metropolis algorithm named MSA) and float-encoded Genetic Algorithm (FGA) solving the nonlinear geophysical well-logging inverse problem.

Besides the conventional point by point well log interpretation methods there is another inversion technique, which can improve the accuracy and the reliability of the estimated petrophysical model. Furthermore, it is able to give an estimate for the layer-thicknesses that could not have been treated as unknowns in the geophysical well-logging inversion so far. The so-called interval inversion method processes all the data of a greater depth-interval in a joint inversion procedure. Testing and applying the conventional point by point and the interval inversion interpretation methods synthetic and field well log data were inverted. After I compared interval inversion results to the ones resulted from point by point inversion.

I introduced 10 new inversion algorithms for the interpretation of well log data. Altogether 297 Matlab script and function files were written to form a system of computer programs. By means of it 9 synthetic and measured data sets and 5 inversion models were subjected to numerical experiments. As conclusions the following theses were composed:

1. New point by point inversion methods were developed based on global optimization named as MSA-P and FGA-P. The Metropolis algorithm was modified applying new energy function to form a new point by point inversion procedure called MMSA-P. The new inversion methods were subjected to numerical experiments on noisy synthetic well log data. It was demonstrated that more accurate and reliable petrophysical parameter estimation can be attained by the new inversion methods than by linearized point by point inversion. In case of initial models characterized by large model (and data) distance and high correlation between model parameters, MMSA-P assures faster convergence to the solution compared to Metropolis algorithm.
2. Interval inversion algorithms based on linearized (DLSQ-I, LAD-I) and global optimization (MMSA-I and FGA-I) were developed. Beside fixed layer-boundary coordinates numerical tests were carried out on synthetic well log data. It was demonstrated that the accuracy of parameter estimation can be increased at least by one order of magnitude compared to point by point inversion in case of layer-wise homogeneous geophysical model.
3. A new interval inversion algorithm was developed that supports the determination of petrophysical parameters varying vertically in an arbitrary depth interval. Power functions were used for the discretization of model parameters in a series expansion. A combined interval inversion algorithm was applied based on both linearized and global optimization as FGA+DLSQ-I. By this the convergence velocity of FGA algorithm was accelerated by one order of magnitude. Furthermore, the parameter estimation errors were computed by means of the combined inversion algorithm (global optimization methods have not been provided with it in case of a single inversion program run).
4. A new interval inversion algorithm was developed that gives an estimate for the layer-thicknesses and petrophysical parameters in one inversion procedure. Global optimiza-

tion methods were implemented to form MMSA-H and FGA-H algorithms. It was shown that the inversion for the layer-thicknesses can be solved in stable numerical procedure, which means a new approach in geophysical well logging inversion. Moreover an appropriate selection of energy function was made for MMSA-H algorithm that resists the outliers of the well log data set and gives a quick convergent solution.

5. As a field case, the inversion of a well log data set measured in a domestic well bore for hydrocarbon exploration was interpreted. Global point by point inversion method was applied, and then I performed interval inversion for characteristic petrophysical parameters and layer-thicknesses presuming layer-wise homogeneous geophysical model. At last, a combined interval inversion algorithm was applied to estimate petrophysical parameters varying vertically in a hydrocarbon reservoir to improve the efficiency of interval inversion method.

The efficiency of the new inversion methods were shown in the thesis. It is especially true for the interval inversion procedure. It is independent from the initial model and stable. It results in very accurate and reliable estimation as well. Moreover, it is able to give information about the position of the layer-boundaries in the well bore. In my view in the future this method can be used for several geophysical well logging interpretation problems. It can be further developed to utilize more inversion unknowns as textural and zone parameters, which can not be extracted from the well log data set by the traditional point by point inversion methods. Solving multidimensional inverse problems based on automatic layer-thickness determination, interval inversion method can be effectively applied in the advanced geophysical well logging interpretation especially in hydrocarbon exploration.

TARTALOMJEGYZÉK

1. BEVEZETÉS	1
2. A GEOFIZIKAI INVERZIÓ ALAPJAI	6
2.1 A NEMLINEÁRIS INVERZ FELADAT MEGFOGALMAZÁSA	6
2.2 LINEARIZÁLT INVERZIÓS MÓDSZEREK.....	7
2.2.1 A nemlineáris inverz feladat linearizálása.....	7
2.2.2 A legkisebb négyzetek elve szerinti megoldás (LSQ)	8
2.2.3 A csillapított legkisebb négyzetek elve szerinti megoldás (DLSQ)	9
2.2.4 A legkisebb abszolút értékek elve szerinti megoldás (LAD)	10
2.2.5 A paraméterbecslés pontosságának és megbízhatóságának mérőszámai.....	11
2.3 GLOBÁLIS INVERZIÓS MÓDSZEREK	13
2.3.1 A Simulated Annealing eljárás.....	13
2.3.1.1 A Metropolis algoritmus (MSA)	14
2.3.2 A Genetikus Algoritmus	16
2.3.2.1 A Klasszikus Genetikus Algoritmus (CGA)	18
2.3.2.2 A Valós Kódolású Genetikus Algoritmus (FGA).....	20
3. A MÉLYFŰRÁSI GEOFIZIKA DIREKT FELADATA	24
4. INVERZIÓS MÓDSZERFEJLESZTÉS MÉLYFŰRÁSI GEOFIZIKAI ADATOK FELDOLGOZÁSÁRA	30
4.1 A MÉLYSÉGPONTONKÉNTI INVERZIÓS ALGORITMUS.....	31
4.2 AZ INTERVALLUM INVERZIÓS ALGORITMUS	34
4.3 A RÉTEGHATÁR-MEGHATÁROZÁS INVERZIÓS ALGORITMUSA	39
4.4 AZ INVERZIÓS MÓDSZERFEJLESZTÉS ÖSSZEFOGLALÁSA	41
5. SZINTETIKUS ADATOK MÉLYSÉGPONTONKÉNTI INVERZIÓJA	43
5.1 SZINTETIKUS ADATOK LINEARIZÁLT MÉLYSÉGPONTONKÉNTI INVERZIÓJA	43
5.1.1 Szintetikus adatok generálása.....	43
5.1.2 Gauss-zajjal terhelt adatok inverziója DLSQ-P módszerrel	44
5.1.3 Kiugró adatok inverziója DLSQ-P módszerrel	45
5.2 SZINTETIKUS ADATOK GLOBÁLIS MÉLYSÉGPONTONKÉNTI INVERZIÓJA	47
5.2.1 Inverziós vizsgálatok a Simulated Annealing módszerrel	47
5.2.1.1 Startmodell-függetlenségi vizsgálatok.....	47
5.2.1.2 Gauss-zajjal terhelt adatok inverziója MMSA-P módszerrel.....	48
5.2.1.3 Kiugró adatok inverziója MMSA-P módszerrel	49
5.2.1.4 Inverziós vizsgálatok távoli startmodell alkalmazása esetén.....	50
5.2.2 Inverziós vizsgálatok Genetikus Algoritmus felhasználásával	52
5.2.2.1 Gauss-zajjal terhelt adatok inverziója FGA-P módszerrel	53
6. SZINTETIKUS ADATOK INTERVALLUM INVERZIÓJA	56
6.1 SZINTETIKUS ADATOK LINEARIZÁLT INTERVALLUM INVERZIÓJA	56
6.1.1 Gauss-zajjal terhelt adatok inverziója DLSQ-I módszerrel	56
6.1.2 Kiugró adatok inverziója a DLSQ-I és LAD-I módszerekkel	58
6.2 SZINTETIKUS ADATOK GLOBÁLIS INTERVALLUM INVERZIÓJA.....	60
6.2.1 Numerikus vizsgálatok ismert réteghatár-koordináták esetén	61

6.2.1.1	<i>Inverziós vizsgálatok Simulated Annealing módszerrel</i>	61
6.2.1.1.1	<i>Gauss-zajjal terhelt adatok inverziója MMSA-I módszerrel</i>	61
6.2.1.1.2	<i>Kiugró adatok inverziója MMSA-I módszerrel</i>	62
6.2.1.2	<i>Inverziós vizsgálatok FGA-I algoritmussal</i>	64
6.2.2	Numerikus vizsgálatok ismeretlen réteghatár-koordináták esetén	67
6.2.2.1	<i>Inverziós vizsgálatok Simulated Annealing módszerrel</i>	67
6.2.2.1.1	<i>Gauss-zajjal terhelt adatok inverziója MMSA-H módszerrel</i>	67
6.2.2.1.2	<i>Kiugró adatok inverziója MMSA-H módszerrel</i>	69
6.2.2.2	<i>Inverziós vizsgálatok FGA-H algoritmussal</i>	71
6.2.3	Rétegben vertikálisan változó petrofizikai paraméterek meghatározása	73
6.2.3.1	<i>Szintetikus adatrendszer generálása hatványfüggvények segítségével</i>	73
6.2.3.2	<i>Az FGA+DLSQ-I kombinált inverziós módszer alkalmazása</i>	74
7.	ÉRZÉKENYSÉGI FÜGGVÉNYEK VIZSGÁLATA ÉS INVERZIÓS ALKALMAZÁSA	78
8.	TEREPI ADATOK INVERZIÓJA	84
8.1	AZ INVERZ FELADAT BEMUTATÁSA	84
8.2	MÉLYSÉGPONTONKÉNTI INVERZIÓS VIZSGÁLATOK	85
8.3	INTERVALLUM INVERZIÓS VIZSGÁLATOK	87
8.3.1	Intervallum inverzió automatikus réteghatár meghatározással	88
8.3.2	Rétegben vertikálisan változó petrofizikai paraméterek meghatározása FGA+DLSQ-I kombinált inverziós módszerrel	90
9.	MÉLYFŰRÁSI GEOFIZIKAI ADATOK PONTONKÉNTI ÉS INTERVALLUM INVERZIÓJÁNAK ÖSSZEHASONLÍTÁSA SZINTETIKUS ÉS TEREPI ADATRENDSZEREK ESETÉN	94
10.	ÖSSZEFOGLALÁS	99
	<i>Köszönetnyilvánítás</i>	102
	IRODALOMJEGYZÉK	103
	FÜGGELÉK	106

1. BEVEZETÉS

A nyitott lyukbeli mélyfúrási geofizikai mérések az ásványi nyersanyagkutatásban kulcsfontosságú szerepet játszanak. A földkéreg felső néhány kilométeres részében nagy vertikális felbontóképességű szondákkal közel in-situ adatokat nyerhetünk a fúrás közvetlen környezetében elhelyezkedő kőzetek fizikai tulajdonságairól. A mélyfúrási geofizikai adatok értelmezésével meghatározhatóak a földtani egységek egyes geometriai (rétegvastagság, rétegdőlés) és petrofizikai paraméterei (porozitás, víztelítettség, agyagtartalom, kőzetösszetétel, permeabilitás), mellyel a kőzetek térbeli elhelyezkedéséről és kőzetfizikai tulajdonságaikról, valamint az ásványi nyersanyagok mennyiségéről, minőségéről kapunk nélkülözhetetlen információt. A mért szelvényadatok értelmezésének minőségével szemben, mind a nemzetközi, mind pedig a hazai gyakorlat egyre nagyobb követelményeket támaszt. Ez különösen igaz az olajipar területén, ahol egyre bonyolultabb földtani viszonyok között kell ezen értelmezési paramétereiből megbecsülni a kitermelhető olaj és gáz készleteket.

Az első fúrólyukbeli mérés, 1927 (Magyarországon 1935) óta a mélyfúrási geofizika gyors fejlődésen ment keresztül. Tekintsük át röviden e fejlődési fázisokat, elsősorban a kiértékelés oldaláról. 1942-ig, az Archie-formulák megszületéséig a csekély szelvényválaszték (SP, ellenállás) miatt a karotázs szelvényeket kizárólag kvalitatív (áttekintő) kiértékelésre használták. Ez az információ hasznosnak bizonyult a litológiai tagolásban, a nyersanyagok felismerésében, és az egyes fúrások közötti réteggörreláció végrehajtásánál, azonban kvantitatív kiértékelést G. E. Archie és kortársai munkássága nyomán csupán az 1950-es évektől kezdve alkalmaztak. Ekkor jelentős szerepe lett a karotázs méréseknek, elsősorban a szénhidrogénipar területén, ahol elsőként terjedtek el a rádióaktív szondák, majd később az akusztikus (CBL) és termelési geofizikai (PWL) mérések. E gyors fejlődést elsősorban a drága és hosszadalmas magfúrások felváltására irányuló igény hívta életre, és a fúrólyukból (később kútból) kapott folytonos információszerzés lehetősége.

A kvantitatív értelmezés időszakát kb. 1965-től számítjuk. Ekkor a terepen rutinszerűen használt konvencionális ellenállásmérések mellett megjelentek az irányított áramterű (laterolog) szondák, és az 1970-es évektől kezdve a sűrűség-, majd a neutronmérés eszközei. Ekkor alkalmaztak először szondavonatokot. Ezek együttes alkalmazása már lehetővé tette a petrofizikai paraméterek mennyiségi meghatározását is. A kvantitatív értelmezés a litológia-meghatározás, a porozitás-követés, és a szaturációs viszonyok megállapításán túl, rétegdőlés és kezdetleges image feldolgozásokkal bővült. Ebben az időszakban nőtt meg nagymértékben a számítástechnika szerepe. A Schlumberger vállalat elsőként létesített számítóközpontot, és

ettől kezdve rohamos hardver- és szoftverfejlesztés kezdődött. Nemsokára megindult a korszerű mélyfúrású geofizikai értelmezési rendszerek használata. Ezek közül a legelterjedtebbek a Western Atlas vállalat WDS (Well Data System) programrendszerében használt SAND (Shaly Sand Analyses), CLASS (Clay Classification Analyses), CRA (Complex Reservoir Analyses), valamint a Schlumberger CYBERLOOK interpretációs rendszerei lettek. Ennek mintájára Magyarországon is létrehozták a KISS (Karotage Interpreter Subsystem) számítógépes mélyfúrású geofizikai értelmező programcsomagot.

Az 1980-as években alkalmazott mélyfúrású geofizikai értelmező rendszerek még a klasszikus manuális kiértékelési lépések sorozatát hajtották végre. A petrofizikai paraméterek számítására alkalmazott egyenletek determinisztikusak voltak, és a crossplot technika elsősorban a neutron és a sűrűség mérés kombinációján alapult. Később e rendszerek mellett azonban egy egészen új irányvonal jelent meg a mélyfúrású geofizikai értelmezés területén. Az új elven alapuló ún. statisztikus értelmezési rendszereket korszerű, többnyire geofizikai inverziós kiértékelő programokból építették fel. Széles körben alkalmazzák napjainkban is ezeket, főleg a világ vezető olajtársaságai. Itt elsősorban a Schlumberger GLOBAL (MAYER ET AL., 1980), a Gearhart ULTRA (ALBERTY ET AL., 1984), és a Western Atlas OPTIMA (FERTL ET AL., 1987) értelmező rendszereket kell kiemelni, melyek a hagyományos kőzetösszetétel és porozitás típusokon túl hibasávokat is számítanak a becsült petrofizikai jellemzők konfidenciájának jellemzésére.

A szénhidrogén iparban magas a követelmény az értelmezési eredményekkel szemben. E területen az integrált értelmezés során az információ maximalizálása, továbbá az eredmények magas szintű felhasználása a cél. Napjainkban számítógépeink gyorsasága és kapacitása rohamosan nő, ezzel arányos a mért adatmennyiség is. Ezzel általánossá vált a különböző természetű adatrendszerek együttes kezelése az egyre komplexebb felépítésű tárolók kutatásában. A vizualizáció is magas szintre fejlődött, a hagyományos crossplot-okon túl 3-D crossplot-ok, és az összes földtani és fúrású információt egységesen magában foglaló kompozit szelvények előállítását történik, melyen akár több fúrás anyaga is helyet kaphat. A mérés területén újabb eszközök jelennek meg, pl. a Nukleáris Mágneses Szelvényezés (NMR) az utóbbi évtized egyik legkorszerűbb eszköze, mely a porozitás-víztelítettség-permeabilitás hármásra egyszerre tud kvantitatív információt szolgáltatni (SCHLUMBERGER, 1987). Ennek ellenére az eszközfejlesztés és a mérési tapasztalatok szerint a hagyományos litológiai, porozitás-követő, és szaturációs szelvények együttes alkalmazását még nem mindenhol tudták az új mérési módszerek forradalmasítani, és a becsült petrofizikai paraméterekre vonatkozó szigorú minőségi kritériumoknak nem minden esetben tudtak ezen új mérési eljárások megfelel-

ni. Ezért szükséges az értelmezés minőségének és információtartalmának növeléséhez új kiértékelési módszerek keresése, melyek a régebbi eljárások mellett hatékonyan alkalmazhatók a mélyfúrású geofizikai szelvények kiértékelésére.

Nemzetközi viszonylatban jelenleg széles körben folyik a geofizikai inverziós módszerek kutatása. A geofizikai inverziós eljárások korszerű és automatizált információ feldolgozást valósítanak meg a mélyfúrású geofizikai adatok értelmezése területén, melyre mostanra már adott a megfelelő hardver feltétel is. A determinisztikus és inverziós módszerek együttes alkalmazása igen hatékony eszköznek bizonyul a szelvényértelmezésben, erre láthatunk példát a hazai olajiparban alkalmazott Baker Atlas EXPRESS SYSTEMS rendszerénél, mely a szolnoki MOL Rt. Petrofizikán működik. E korszerű, komplex mélyfúrású geofizikai értelmezést végző rendszer hatékonyságát tovább növeli, hogy saját fejlesztésű alkalmazások beépíthetők a rendszerbe. Ebben a modern környezetben újabb elvű inverziós módszerek is hasznosan működtethetők és gyorsan tovább fejleszthetők, valamint a determinisztikus és egyéb hagyományos statisztikus elvű kiértékelési módszerekkel integráltan alkalmazhatók.

Az inverziós szelvénykiértékelő eljárások matematikai optimalizációs módszereken alapulnak, melyek a petrofizikai paraméterek becslését iteratív eljárásban hajtják végre. Az optimális közetfizikai paramétereket az aktuális kiértékelési modellen számított szintetikus adatok valamint a fúrásban mért szelvényadatok eltérésének minimalizálásával becsüljük, melyet a kezdeti modell fokozatos finomításával érhetünk el. Az iparban alkalmazott inverziós módszerek, lévén lokális gradiens-alapú linearizált eljárások, a mért adatok hibájának ismeretében a becsült paraméterek minőségére és megbízhatóságára is szolgáltatnak információt. E módszerek elvi alapjait a diszkrét linearizált inverzió elméletében találjuk meg, melyet MENKE (1984) és TARANTOLA (1987) foglalt össze, illetve azok mélyfúrású geofizikai alkalmazásával többek között ETNYRE (1984), MAYER et al. (1980), KORMOS (1987), valamint FERENCZY és STEINER (1987) foglalkozott.

Az utóbbi években a számítógépek és az optimalizációs módszerek is tovább fejlődtek. A matematikusok rájöttek, hogy a természetben lezajló fizikai vagy egyéb folyamatok analógiája alapján megalkothatók olyan algoritmusok, melyek képesek hatékonyan kezelni számos mérnöki és természettudományos feladatot. Ezek közé tartoznak a véletlen keresési szabályokat alkalmazó ún. globális optimalizációs módszerek, melyek az optimális modell megtalálása érdekében az optimalizálandó függvény (célfüggvény) abszolút szélsőérték helyét keresik. Ezen eljárások alkalmazásával a petrofizikában elterjedt súlyozott legkisebb négyzetek módszerén alapuló linearizált inverziós kiértékelési módszereknél jobb eredmény érhető el. Kimutatható, hogy ha a feltételezett geofizikai modell meglehetősen távol áll a földtani-petrofizikai

valóságtól (pl. ha nincs elegendő információ a kezdeti modell megfelelő megállapítására), akkor a linearizált módszerek nem minden esetben képesek megtalálni az optimális megoldást. A probléma háttérében az áll, hogy a legkisebb négyzetek módszerén alapuló linearizált inverziós eljárások a nagyszámú lokális szélsőértékkel rendelkező célfüggvény egy helyi minimumában stabilizálódnak, nem pedig az abszolút minimumhelyen. E probléma kiküszöbölésére a globális optimalizációs módszerei hatékonyan alkalmazhatóak.

A globális optimalizációs módszerek geofizikai alkalmazásaira láthatunk példát ROTHMAN (1985), SEN és STOFFA (1991) munkáiban statikus korrekciók számításánál, BHATTACHARYA et al. (1993) 1-D szerkezeteken mért látszólagos fajlagos ellenállás adatok inverziójánál, DITTMER és SZYMANSKY (1995) mágneses és látszólagos fajlagos ellenállás adatok, és KIS (1998) felszínközeli szerkezetek geofizikai vizsgálatában. A mélyfúrési geofizikai értelmezés területén még nem terjedtek el széles körben a globális optimalizációs módszerek. Kevés szakirodalmi alkalmazás ismeretes, pl. FANG et al. (1996) minerológiai összetélt számított karotázs szelvényekből, illetve SZÜCS és STEINER (1997) P-normát minimalizáló globális inverziós eljárást publikáltak. A kevés számú alkalmazás ellenére azonban kimutatható, hogy a mélyfúrési geofizikai értelmezésbe a globális optimalizációs módszerek hatékonyan beépíthetők, ráadásul a direkt feladat egyszerűsége és számítási gyorsasága kedvez e módszerek használatának. Ennek eredményeképpen a becsült kőzetjellemző paraméterek pontosabban meghatározhatók, így minőségi javulást várhatunk az ásványi nyersanyagokat rejtő kőzetek kvantitatív jellemzésében (pl. szénhidrogén mennyiségi becslése).

A nemlineáris mélyfúrési geofizikai inverz feladat megoldása hagyományosan mélységpontonkénti inverzióval történik. Ennek keretében a mérési intervallum egyes pontjaiba külön-külön határozzuk meg a kérdéses kőzetfizikai paramétereket. Az iparban alkalmazott inverziós módszerek is pontonként építik fel a petrofizikai paraméterek mélységi eloszlását. A pontbeli adatok viszonylag kis száma miatt azonban, az inverziós modellt leíró válaszgyenletekben szereplő texturális jellemzőket és a nagyszámú zónaparamétert konstansnak kell feltételeznünk, mellyel egy kismértékben túlhatározott inverz feladatot kapunk. Mivel az inverzió során a szomszédos mélységpontok adatait nem vonjuk be a pontbeli inverziós kiértékelésbe, ezért e módszer csak viszonylag kevés számú kőzetjellemző paraméter meghatározását teszi lehetővé. További zónaparaméterek és egyéb texturális állandók, valamint a réteghatárkoordináták inverziós meghatározására a pontonkénti inverzió nem nyújt lehetőséget, ezért azokat csak manuális vagy determinisztikus úton állíthatjuk elő. Mivel a mélyfúrési geofizikai értelmezés feladata az egyes földtani egységek (elsősorban a rétegek) kvantitatív kőzetfizikai és geometriai jellemzése, így ehhez jól kapcsolódik azon elgondolás, hogy a szelvényadatok

inverzióját ne csak pontonként hajtsuk végre, hanem egy nagyobb mélységintervallum adatszerkezetét egyetlen inverziós eljárás keretében szimultán értékeljük ki. E feladat végrehajtására alkalmas az ún. intervallum inverziós algoritmus, melynek kifejlesztése és kutatása a Miskolci Egyetem Geofizikai Tanszék Inverziós és Tomográfiai Kutatócsoportjának az eredménye. Az intervallum inverziós eljárással a bemenő szelvényadatok száma nagymértékben növelhető a pontonkénti inverzió adatainak számával szemben, és a petrofizikai paraméterekre nézve nagymértékben túlhatározott inverz feladat állítható elő. A nagyfokú túlhatározottság a paraméterbecslésben nagyobb pontosságot és megbízhatóságot garantál a pontonkénti eljárással szemben, illetve lehetővé teszi újabb ismeretlenek (pl. a rétegvastagságok) automatikus (inverziós eljárásán belüli) meghatározását. Az intervallum inverziós módszer során a lokális szonda-válaszfüggvényeket ki kell terjesztenünk a teljes invertálandó mélységintervallumra, ahol a petrofizikai paraméterek a mélység függvényeiként jelennek meg. A direkt feladat számára alkalmas intervallumon értelmezett (mélységfüggő) válaszgyenleteket DOBRÓKA (1995) vezette be, melyek a petrofizikai paraméterek mélységfüggvényeit tartalmazzák. E mélységtől függő válaszgyenletek petrofizikai paramétereinek diszkretizálása többféleképpen elvégezhető. Az általam alkalmazott módszer ismert bázisfüggvény-rendszer szerinti sorfejtésen alapul. Miután az intervallum inverziós módszer hatékonyságát szintetikus adatokon végzett inverziós vizsgálatok eredményei igazolták, reálisnak láttam a módszer kipróbálását terepi adatok kiértékelésénél is.

Az értekezés új tudományos eredményeket mutat be mélyfúrás geofizikai adatok inverziós értelmezése témakörében. Ennek keretében egyrészt a hagyományos mélységpontonkénti inverziós módszer továbbfejlesztett eljárásai, másrészt egy elvében új eljárás, az ún. intervallum inverzió kerül bemutatásra. Az inverziós algoritmusokat először zajjal terhelt szintetikus szelvényadatokon teszteltem, majd valódi terepi adatok kiértékelésére alkalmaztam. A numerikus vizsgálatokat és kiértékelést személyi számítógépen (CPU: Intel Celeron 1.7 GHz) saját fejlesztésű MATLAB-5 rendszerben írt szoftverrendszer segítségével végeztem. Az inverziós vizsgálati eredményeim alapján összehasonlítást végzek a hagyományos pontonkénti és intervallum inverziós eljárások, illetve a linearizált és globális optimalizáció között. Ismertetem az érzékenységi függvények szerepét az inverziós kiértékelésben, végül terepi adatok inverzióját mutatom be. A fenti eredmények alapján választ adok az inverziós eljárások pontossági, megbízhatósági és stabilitási kérdéseire, valamint bemutatom az új inverziós módszerekkel történő paraméter meghatározás előnyeit a hagyományos eljárásokkal szemben.

2. A GEOFIZIKAI INVERZIÓ ALAPJAI

A geofizikai mérésekkel a felszín alatti földtani szerkezetek fizikai és geometriai viszonyairól nyerhetünk információt. E jellemzőket általában közvetett módon, a mérési adatok feldolgozásával és értelmezésével határozzuk meg. A mért adatrendszer és az ismeretlen közetjellemző paraméterek kapcsolatát általános esetben

$$\vec{g}(\vec{d}, \vec{m}) = 0$$

implicit nemlineáris vektor-vektor függvény adja meg, ahol \vec{m} az általunk megalkotott geofizikai (majd később az inverziós eljárással becsült) modell, és \vec{d} a mérési adatokat tartalmazó vektor (MENKE, 1984). Tételezzük fel, hogy a \vec{g} függvényben az adatok explicite kifejezhetőek a modellparaméterekre nézve nemlineáris összefüggéssel. Ekkor általában \vec{g} linearizálásával az ismeretlenek meghatározása (mivel általában a mért adatok és az ismeretlenek száma eltérő) egy alulhatározott vagy túlhatározott inverz feladatra vezet, melyet a mérési adatok és a geofizikai modellre számított adatok eltérésének minimalizálásával (szükség esetén egyéb segédegyenletek bevonásával) oldhatjuk meg. A hagyományos linearizált inverziós módszerek lineáris algebrai egyenletek megoldásával szolgáltatnak eredményt, mely az eljárás során számos közelítést tartalmaz. Egy másik megközelítésen alapuló inverziós technika azonban mindezt nélkülözi. A globális optimalizációs módszerek linearizálás nélkül hatékony véletlen keresést hajtanak végre a paraméterterben az optimális modell meghatározásának érdekében. E fejezetben a fontosabb linearizált és globális optimalizációs eljárások elveit tekintjük át, melyek a későbbi inverziós vizsgálatok alapját képezik.

2.1 A NEMLINEÁRIS INVERZ FELADAT MEGFOGALMAZÁSA

A geofizikai modell alatt az inverz feladatban vizsgált földtani szerkezetet jellemző közetfizikai és geometriai paraméterek vektorát értjük, mely a valós földtani szituációt leegyszerűsített formában, kvantitatív módon írja le. Legyen az inverz feladat modellvektora

$$\vec{m} = [m_1, m_2, \dots, m_M]^T, \quad (2.1)$$

ahol M a modellparaméterek száma (T a transzponált jelölése). E modellparaméterek meghatározása érdekében geofizikai méréseket végzünk. Legyen a mérési adatok vektora

$$\vec{d} = [d_1, d_2, \dots, d_N]^T, \quad (2.2)$$

ahol N az adatszám. A mért adatvektor és a modellparaméterek vektora közötti

$$\vec{d} = \vec{g}(\vec{m}) \quad (2.3)$$

függvénykapcsolat általában nemlineáris, melyet gyakran modelltörvényként emlegetnek.

A (2.3) egyenletben szereplő \bar{g} függvény ismeretében a modelltől direkt úton elvi adatrendszer származtatható. E számított adatrendszer olyan adatokat feltételez, melyeket akkor mérnénk, ha a modellünk a valóságos földtani rétegsorral megegyezne, és a méréseinket hiba egyáltalán nem terhelné. Bizonyos felszíni geofizikai módszerek esetén a \bar{g} függvény nem-linearitása dominál, azonban a mélyfúrési geofizikai válasz egyenletek többnyire lineáris többváltozós függvényei az ismeretlen modellparamétereknek, melyeket (2.3) ismeretében geofizikai inverzióval határozunk meg.

2.2 LINEARIZÁLT INVERZIÓS MÓDSZEREK

A konvencionális inverziós eljárások a nemlineáris inverz feladatot iteratív úton lineáris problémák sorozatára vezetik vissza. Ennek keretében a paramétertér egy megoldáshoz közeli pontjából indítjuk az eljárást (melyet a priori földtani és geofizikai információk alapján határozunk meg), majd a modellt lépésenként korrigálva jutunk egyre közelebb a matematikailag optimális megoldáshoz. A modell javítása a következő formula szerint történik

$$\bar{m}^{(q)} = \bar{m}^{(q-1)} + \delta\bar{m}^{(q)}, \quad (2.4)$$

ahol $q = 1, 2, \dots, q_{\max}$ az iterációs lépések száma, $\bar{m}^{(q)}$ a q-adik lépésben javított modellvektor, és $\delta\bar{m}^{(q)}$ a q-adik lépésbeli paraméterkorrekció vektor. Az előzőekben vázolt iteratív inverziós eljárást egy adott stopkritérium teljesüléséig folytatjuk, mellyel a megoldást előírt pontossággal közelíthetjük.

2.2.1 A nemlineáris inverz feladat linearizálása

Fejtsük Taylor-sorba (2.3) függvényt, a megoldás közelében lévő $\bar{m}^{(0)}$ kiindulási modell (startmodell) körül, és hanyagoljuk el a magasabb rendű deriváltakat. Ekkor (2.4) felhasználásával a (2.3) vektoregyenlet k-adik tagjára az alábbi összefüggés adódik

$$d_k(\bar{m}) = g_k(\bar{m}^{(0)}) + \sum_{i=1}^M \left. \frac{\partial g_k}{\partial m_i} \right|_{\bar{m}_0} \delta m_i.$$

Az egyenlet jobb oldalának első tagja a startmodellre számított adatvektor k-adik eleme, melyet $d_k^{(0)} = g_k(\bar{m}^{(0)})$ -vel jelöljük $k=1, 2, \dots, N$ mellett. Vezessük be a $i=1, 2, \dots, M$ mellett

$$\delta d_k = d_k - d_k^{(0)}$$

$$G_{ki} = \left. \frac{\partial g_k}{\partial m_i} \right|_{\bar{m}_0}$$

N dimenziós eltérésvektort és az $N \times M$ elemű Jacobi-mátrixot.

Az előzőek felhasználásával a

$$\underline{\underline{\delta d}} = \underline{\underline{G}} \underline{\underline{\delta m}}$$

lineáris algebrai egyenletrendszer állítható elő, melynek ismételt megoldásával a (2.4) egyenlet szerint a korábbi modellt fokozatosan finomíthatjuk. Ezzel a nemlineáris inverz problémát linearizáltuk, mivel a $\underline{\underline{G}}$ mátrix független a paraméterek $\underline{\underline{\delta m}}$ vektorától.

Mivel mérési adataink mindig zajosak és modellhibák is jelen vannak az inverzió során, ezért az adatok és a modellparaméterek kapcsolatát leíró lineáris egyenletrendszerből képzett

$$\underline{\underline{e}} = \underline{\underline{\delta d}} - \underline{\underline{G}} \underline{\underline{\delta m}} \quad (2.5)$$

hibavektor a geofizikai gyakorlatban nem lehet zérus. Ugyanakkor, a mélyfúrési geofizikában általában túlhatározott inverz problémával találkozunk (a független mért szondaadatok száma meghaladja a meghatározandó paraméterek számát), így az egyenletnek nem létezik egyértelmű algebrai megoldása. Az inverz feladatot ekkor $\underline{\underline{e}}$ valamely normáján keresztül, a mért és a számított adatok eltéréseinek minimalizálásával oldjuk meg (MENKE, 1984).

2.2.2 A legkisebb négyzetek elve szerinti megoldás (LSQ)

Az LSQ (Least Squares) gyakran alkalmazott linearizált inverziós módszer, mely az (2.5) eltérésvektor Euklideszi-norma (L_2 -norma) négyzetét (a mért és a számított adatok eltéréseinek négyzetösszegét) minimalizálja. E módszer az adatokat terhelő zaj Gauss-eloszlása esetén ad optimális megoldást. A minimalizálandó célfüggvény (2.5) alapján

$$E(\underline{\underline{m}}) = \underline{\underline{e}}^T \underline{\underline{e}} = \sum_{k=1}^N e_k^2 = \sum_{k=1}^N \left(d_k^{(m)} - d_k^{(sz(0))} - \sum_{i=1}^M G_{ki} \delta m_i \right)^2 \rightarrow \min, \quad (2.6)$$

melyben $\underline{\underline{d}}^{(m)}$ a mért adatok és $\underline{\underline{d}}^{(sz(0))}$ a kezdeti geofizikai modellen számított adatok vektora.

A (2.6) célfüggvény minimumát szélsőérték-kereséssel, a $\partial E / \partial m_i = 0$ ($i=1,2,\dots,M$) egyenletrendszer teljesülése mellett keressük meg, mely MENKE (1984) alapján a

$$\underline{\underline{G}}^T \underline{\underline{G}} \underline{\underline{\delta m}} = \underline{\underline{G}}^T \underline{\underline{\delta d}} \quad (2.7)$$

inhomogén lineáris algebrai egyenletrendszerre vezet, ahol $\underline{\underline{\delta m}}$ korrekcióvektor (2.4), az adatvektor pedig $\underline{\underline{\delta d}} = \underline{\underline{d}}^{(m)} - \underline{\underline{d}}^{(sz(0))} = \underline{\underline{d}}^{(m)} - \underline{\underline{G}} \underline{\underline{m}}^{(0)}$ alapján számítható. A (2.7) normálegyenletből a becsült modellparaméter vektor $\underline{\underline{m}} = \underline{\underline{m}}^{(0)} + \left(\underline{\underline{G}}^T \underline{\underline{G}} \right)^{-1} \underline{\underline{G}}^T \underline{\underline{\delta d}}$ szerint számítható. Ez alapján az LSQ eljárás

$$\underline{\underline{m}}^{(q)} = \underline{\underline{m}}^{(q-1)} + \left(\underline{\underline{G}}^T \underline{\underline{G}} \right)^{-1} \underline{\underline{G}}^T \left(\underline{\underline{d}}^{(m)} - \underline{\underline{G}} \underline{\underline{m}}^{(q-1)} \right)$$

formula szerint állítja elő a q-adik iterációs lépésbeli becsült modellt.

Az LSQ módszer alkalmazása során abban az esetben, amikor különböző nagyságrendű adatokat kell együttesen invertálnunk (mint pl. karotázs adatok együttes inverziójánál), szükséges a (2.5) eltérésvektor helyett az alábbi relatív hibavektor bevezetése (DOBRÓKA, 2001)

$$\bar{\mathbf{e}}^{(rel)} = \bar{\mathbf{d}}^{(rel)} - \underline{\underline{\mathbf{G}}}\bar{\mathbf{m}}^{(rel)}, \quad (2.8)$$

ahol

$$\begin{aligned} d_k^{(rel)} &= \frac{d_k^{(m)} - d_k^{(sz(0))}}{d_k^{(sz(0))}} \\ m_i^{(rel)} &= \frac{\delta m_i}{m_i^{(0)}} \\ G_{ki} &= \frac{m_i^{(0)}}{d_k^{(sz(0))}} \left. \frac{\partial g_k}{\partial m_i} \right|_{\bar{\mathbf{m}}^{(0)}}. \end{aligned}$$

E normálással a mért és a számított adatok eltérései azonos nagyságrendűek lesznek, és az $\bar{\mathbf{e}}^{(rel)}$ relatív hibavektort (2.6) célfüggvénybe helyettesítve az inverz feladat a fentiekhez hasonlóan oldható meg. Az LSQ módszer megoldhatóságának feltétele, hogy $\det(\underline{\underline{\mathbf{G}}^T \underline{\underline{\mathbf{G}}})} \neq 0$ feltétel teljesüljön, ugyanis ellenkező esetben nem létezik a $(\underline{\underline{\mathbf{G}}^T \underline{\underline{\mathbf{G}}})}^{-1}$ inverz mátrix, és az eljárás önmagában alkalmatlanná válik a modellparaméterek meghatározására. Ekkor alkalmazzák a különböző regularizációs eljárásokat, melyek numerikusan kezelhetővé teszik az algoritmust.

2.2.3 A csillapított legkisebb négyzetek elve szerinti megoldás (DLSQ)

A geofizikai inverziós gyakorlatban (2.7) általában rosszul kondicionált lineáris egyenletrendszer. A kondíciószám definíciója RUGGE (1993) alapján a következő

$$\kappa = \left| \frac{\lambda_{\max}}{\lambda_{\min}} \right|,$$

ahol $\lambda_{\max}, \lambda_{\min}$ egy tetszőleges mátrix maximális és minimális sajátértéke. A geofizikai gyakorlatban $\underline{\underline{\mathbf{G}}^T \underline{\underline{\mathbf{G}}}}$ kondíciószáma kezelhető esetekben $\kappa \sim 10$, azonban rosszul kondicionált egyenleteknél κ értéke több nagyságrenddel is megnőhet. Ekkor a (2.7) egyenlet numerikusan instabil inverzióra vezet.

Vezessük be a DLSQ (Damped Least Squares) módszernél alkalmazható vektornormát, mely (2.6) célfüggvénytől csak egy járulékos tagban különbözik

$$E(\bar{\mathbf{m}}) = \sum_{k=1}^N \left(d_k^{(m)} - d_k^{(sz(0))} - \sum_{i=1}^M G_{ki} \delta m_i \right)^2 + \varepsilon^2 \sum_{j=1}^M m_j^2 \rightarrow \min.$$

A fenti kifejezés második tagja a modell paramétereire nézve ad előírást, mely egyszerre stabilizálja az LSQ algoritmust, és egyben érvényre juttatja az inverz feladat kevert határozottsá-

gának jellegét is (látható, hogy $\varepsilon^2 = 0$ esetben a feladat visszavezethető a hagyományos LSQ módszerre). A modellvektor iteratív javítása MARQUARDT (1959) algoritmusának felhasználásával a következő gyakorlat szerint történik

$$\vec{m}^{(q)} = \vec{m}^{(q-1)} + (\underline{\underline{G}}^T \underline{\underline{G}} + \varepsilon^2 \underline{\underline{I}})^{-1} \underline{\underline{G}}^T (\vec{d}^{(m)} - \underline{\underline{G}} \vec{m}^{(q-1)}),$$

ahol q az iterációs lépésszám és $\underline{\underline{I}}$ az $M \times M$ méretű egységmátrix.

2.2.4 A legkisebb abszolút értékek elve szerinti megoldás (LAD)

A legkisebb négyzetek módszerén alapuló linearizált inverziós módszerek nem adnak optimális megoldást, ha a mért adatokat nem Gauss-eloszlásból származó zaj terheli. Ebben az esetben használhatjuk az IRLS (Iteratively Reweighted Least Squares) eljárást (TARANTOLA, 1987), amely az eltérésvektor

$$E_p(\vec{m}) = \sum_{k=1}^N |e_k|^p = \sum_{k=1}^N \left| d_k - \sum_{i=1}^M G_{ki} m_i \right|^p \rightarrow \min \quad (2.9)$$

normájának (L_p -norma) minimalizálásán alapul, ahol általában $p \leq 2$ feltétel teljesül a geofizikai inverziós alkalmazások során.

Differenciáljuk az E_p -funkcionált $l=1 \dots M$ számú modellparaméter szerint. Ezt a műveletet felhasználva

$$\frac{\partial E_p}{\partial m_l} = -p \sum_{k=1}^N |e_k|^{p-1} \operatorname{sgn}(e_k) \sum_{i=1}^M G_{ki} \delta_{il} = 0,$$

egyenletrendszer eredményezi ($\delta_{il} = 1$, ha $i=l$, valamint $\delta_{il} = 0$, ha $i \neq l$), melyből a mért és számított adatok eltérésvektorának (2.9)-ben szereplő helyettesítésével az

$$\sum_{k=1}^N |e_k|^{p-2} d_k G_{kl} - \sum_{k=1}^N |e_k|^{p-2} \sum_{i=1}^M G_{ki} m_i G_{kl} = 0$$

egyenletrendszer adódik. Ezután vezessük be a $W_{ks} = |e_k|^{p-2} \delta_{ks}$ diagonális adattérbeli súlymátrixot, mely $k=s$ esetén $W_{kk} = |e_k|^{p-2}$ súlyokkal előállítja a probléma normálegyenletét

$$\underline{\underline{G}}^T \underline{\underline{W}} \underline{\underline{G}} \vec{m} = \underline{\underline{G}}^T \underline{\underline{W}} \vec{d}.$$

Láthatjuk, hogy $p=2$ esetben a súlymátrix egységmátrix, így a probléma normál egyenlete lineáris és megegyezik a legkisebb négyzetek (LSQ) elvének normálegyenletével. A $p \neq 2$ értékek mellett a fenti normálegyenlet nem lineáris. A geofizikai gyakorlatban leggyakrabban alkalmazott inverziós eljárás ezek közül az L_1 -norma minimalizálásán alapuló LAD (Least Absolute Deviations) módszer, mely a Gauss-eloszlásnál „szélesebb szárnyú” sűrűség-

függvénnyel jellemezhető zajok esetén (pl. Laplace eloszlás) ad megbízhatóbb eredményt az LSQ módszerrel szemben. A megoldás előállítás a LAD módszernél ugyancsak iteratív úton történik. Mivel $p=1$ mellett a \underline{W} súlymátrix főátlóbeli elemeit $k=1, \dots, N$ adat esetén

$$W_{kk} = |e_k|^{-1} = \left| d_k - \sum_{i=1}^M G_{ki} m_i \right|^{-1} \quad (2.10)$$

szerint számítjuk, így az elvi értéküktől nagymértékben elütő mért adatokat kicsiny, ellenkező esetben nagyobb súlyok képviselik a súlymátrixban. A súlymátrixot az iterációs eljárás során minden lépésben újra számoljuk, ezzel a q -adik lépésben a megoldás

$$W_{kk}^{(q)} = \left| d_k - \sum_{i=1}^M G_{ki} m_i^{(q-1)} \right|^{-1},$$

$$\vec{m}^{(q)} = (\underline{G}^T \underline{W}^{(q)} \underline{G})^{-1} \underline{G}^T \underline{W}^{(q)} \vec{d}.$$

Az IRLS eljárás konvergenciája során a súlymátrix egyre kevésbé változik. Ez a módszer előnyösen alkalmazható kiugró adatokkal terhelt adatrendszerek inverziójánál.

2.2.5 A paraméterbecslés pontosságának és megbízhatóságának mérőszámai

A linearizált inverziós eljárásokkal becsült paraméterek hibáját az okozza, hogy a mérési adatok mindig zajosak, és az adattérbeli hibák az inverzió során (mely lineáris egyenletrendszereken keresztül összekapcsolja a paraméterteret az adattérrel) átranzformálódnak a paraméterterbe. Másrészt a valódi földtani szerkezet finom részleteinek hiánya az alkalmazott modellben további diszperziót okoz inverziós eredményeinkben.

Az inverz probléma megoldásának pontosságát mind az adat-, mind pedig a paraméterterben is jellemezhetjük. Ennek első mérőszámaként tekintsük a relatív adattérbeli távolságot, mely azt mutatja meg, hogy a becsült modell alapján számított adatok hogyan illeszkednek a mérési adatokra. E dimenziótlan skalár LSQ eljárás esetén DOBRÓKA (2001) alapján

$$D_d^{(LSQ)} = \sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{d_k^{(m)} - d_k^{(sz)}}{d_k^{(m)}} \right)^2}, \quad (2.11)$$

ahol N az adatok száma, $d_k^{(m)}$ és $d_k^{(sz)}$ a k -adik mért és számított adat. Ez LAD módszer esetén

$$D_d^{(LAD)} = \frac{1}{N} \sum_{k=1}^N \left| \frac{d_k^{(m)} - d_k^{(sz)}}{d_k^{(m)}} \right|. \quad (2.12)$$

Ha az inverziós algoritmusok tesztelése céljából ismert (egzakt) modellen számított szintetikus adatokból zaj hozzáadásával kvázi mért adatokat generálunk, és azokat invertáljuk, akkor lehetőségünk nyílik az egzakt és az inverzióval becsült modell paraméterterbeli relatív

távolságának meghatározására. A jellemző dimenziótlan skaláris mennyiség ekkor a relatív modelltérbeli távolság, mely DOBRÓKA (2001) alapján

$$D_m^{(LSQ)} = \sqrt{\frac{1}{M} \sum_{i=1}^M \left(\frac{m_i^{(b)} - m_i^{(e)}}{m_i^{(e)}} \right)^2}, \quad (2.13)$$

ahol M a modellparaméterek száma, $m_i^{(b)}$ és $m_i^{(e)}$ pedig az i -edik becsült és az egzakt modellparaméter. LAD eljárás alkalmazása esetén a relatív modelltérbeli távolságot

$$D_m^{(LAD)} = \frac{1}{M} \sum_{i=1}^M \left| \frac{m_i^{(b)} - m_i^{(e)}}{m_i^{(e)}} \right| \quad (2.14)$$

formulával definiálhatjuk. E fenti két mennyiség ismert modellre számított hibátlan adatok esetén az inverziós eljárás matematikai pontosságát is jellemzi, ezért érdemes a terepi adatok invertálása előtt azokat szintetikus adatokon is tesztelni. A hibás adatokkal történő szintetikus vizsgálatokkal pedig az inverziós eljárás gyakorlati alkalmazhatósága tesztelhető különböző hibájú mérések tekintetében.

A linearizált inverzió elméletében lehetőség van a becsült modellparaméterek hibájának és megbízhatóságának kvantitatív jellemzésére is. Tételezzük fel, hogy az inverz feladatban a paramétertér és az adattér lineáris kapcsolatát az

$$\underline{\underline{m}} = \underline{\underline{A}} \underline{\underline{d}}$$

egyenlet írja le, melyben $\underline{\underline{A}}$ az aktuális inverziós módszer általánosított $M \times N$ dimenziós inverz mátrixa. Mivel $\underline{\underline{A}}$ az adatok ismételt mérése során nem változik, így levezethető a

$$\underline{\underline{\text{cov}}}(\underline{\underline{m}}) = \underline{\underline{A}} \underline{\underline{\text{cov}}}(\underline{\underline{d}}) \underline{\underline{A}}^T \quad (2.15)$$

egyenlet, mely bármilyen inverziós eljárás esetén összekapcsolja az adattérbeli és a paramétertérbeli kovariancia mátrixot (MENKE, 1984).

A legkisebb négyzetek módszere (LSQ) esetén a paramétertérbeli kovariancia mátrix egyszerűbbé válik, ha az adatok korrelálatlanok és varianciájuk megegyezik. Ekkor az adattérbeli kovariancia mátrix MENKE (1984) szerint felírható

$$\underline{\underline{\text{cov}}}(\underline{\underline{d}}) = \sigma_{(d)}^2 \underline{\underline{I}}$$

alakban, ahol $\underline{\underline{I}}$ az egységmátrix, és $\sigma_{(d)}^2$ az adatok varianciája. Mivel (2.7) alapján

$\underline{\underline{A}} = \left(\underline{\underline{G}}^T \underline{\underline{G}} \right)^{-1} \underline{\underline{G}}^T$, ezért $\underline{\underline{\text{cov}}}(\underline{\underline{m}}) = \sigma_d^2 \left(\underline{\underline{G}}^T \underline{\underline{G}} \right)^{-1}$ fődiagonálisának elemei a modellparaméterek varianciáit adják meg, melyből az i -edik becsült modellparaméter hibája

$$\sigma_{m_i} = \sqrt{\text{cov}(\underline{\underline{m}})_{ii}}. \quad (2.16)$$

A kovariancia mátrix elemeiből normálással származtatható a korrelációs mátrix, mely a modellparaméterek páronkénti (lineáris) függőségi viszonyairól ad felvilágosítást. A korrelációs mátrix i -edik sorának és j -edik oszlopának eleme a

$$\text{corr}(\vec{m})_{ij} = \frac{\text{cov}(\vec{m})_{ij}}{\sqrt{\text{cov}(\vec{m})_{ii} \text{cov}(\vec{m})_{jj}}} \quad (2.17)$$

korrelációs együttható, mely az i -edik és a j -edik modellparaméter korreláltságát jellemzi egy $[-1,1]$ intervallumbeli számmal. Ha ez a szám abszolút értékben 1-hez közel áll, akkor ez a becsült paraméterek szoros kapcsolatára utal. Ekkor az inverziós eredményt a fennálló erős csatolás miatt fenntartással kell fogadnunk. Sok esetben a nagy korrelációs együtthatóval jelentkező paraméterek kvalitatív információ szolgáltatására sem alkalmasak, ebből adódóan a geofizikai inverzió számára a megbízható paramétereket a 0.5 alatti abszolút értékű korrelációs együtthatók jelölik.

2.3 GLOBÁLIS INVERZIÓS MÓDSZEREK

A geofizikai gyakorlatban az inverz feladatot általában linearizált optimalizációs módszerekkel oldják meg, melyek megfelelő a priori információ ismeretében (az eljárást a megoldástól nem túl távol eső pontból indítva) kielégítő és gyors megoldást szolgáltatnak. Alkalmazásuk sok esetben célravezető, azonban a geofizikai inverzióban előforduló nagyszámú lokális szélsőértékkel rendelkező célfüggvények optimalizálásakor e módszerek nem abszolút szélsőérték kereső eljárásaként működnek, ugyanis hajlamosak arra, hogy a megoldást a célfüggvény egy lokális extrémumához rendeljék. E probléma kezelésére alkalmasak a globális szélsőérték kereső eljárások, melyek bizonyos feltételek mellett képesek a célfüggvény abszolút szélsőérték helyét meghatározni (ld. 1. melléklet). A globális optimalizációs módszerek közül kiemelném a Simulated Annealing eljárást és a Genetikus Algoritmust, melyeket széles körben alkalmaznak természettudományos és mérnöki területeken.

2.3.1 A Simulated Annealing eljárás

A Simulated Annealing (SA) eljárást METROPOLIS és társai (1953) dolgozták ki fémek termikus egyensúlyi állapotának modellezése céljából. A klasszikus Metropolis-algoritmust alkalmazó Simulated Annealing eljárás (MSA) egy, a fémek speciális hűtésének analógiája alapján tervezett hatékony globális optimalizációs módszer, melynek algoritmusát többen továbbfejlesztették elsősorban a futási idő csökkentése céljából (pl. Very Fast Simulated Annealing). E módosított SA algoritmusokat TREITEL és HELBIG (1997) foglalták össze.

A Simulated Annealing eljárás keresési mechanizmusa a véges Markov-láncok elméletével matematikailag egzaktul leírható. TREITEL és HELBIG (1997) bebizonyították, hogy az optimális modell konvergens eljárásban az ún. Gibbs-Boltzmann-féle eloszláshoz tart, a termikus egyensúly megvalósulása érdekében. Ehhez megfelelő hűtés szükséges. GEMAN (1984) kimutatta, hogy a Metropolis eljárás globális minimumhoz történő konvergenciájának szükséges és elégséges feltétele a következő hűtési mechanizmus alkalmazása

$$T(q) = \frac{T_0}{\ln q}, \quad q > 1, \quad (2.18)$$

ahol $T(q)$ az q -edik iterációs lépésbeli hőmérséklet (mely az optimalizációban egy lényeges dimenziótlan kontrollparaméter szerepét tölti be), és T_0 a kezdeti (kritikus) hőmérséklet. Ha tehát (2.18) szerint hűtünk, akkor garantált az abszolút minimum meghatározása. Ehhez elvileg végtelen idő szükséges, viszont a tapasztalat azt mutatja, hogy a gyakorlati alkalmazások számára ez elfogadható (véges) futási idők alatt is nagy valószínűséggel bekövetkezik és a hűtési ütem fenti megválasztásával megfelelő pontosság érhető el.

2.3.1.1 A Metropolis algoritmus (MSA)

Az MSA eljárás fémek hőkezelésének egy speciális technikáját algoritmizálja, mely felhasználható a geofizikai inverz feladat megoldására. Az analógia alapja a hűtés időtartamától és ütemétől függően kialakuló fémrács atomi összenergiája és az inverz feladat minimalizálható célfüggvényének kapcsolata.

A kohászatban a fémek lágyítását az olvadt állapothoz közeli hőmérsékletről történő lassú hűtéssel valósítják meg. Ennek hatására a nagy számú atom fokozatosan veszít mozgási energiájából, a fém kristályosodni kezd. A kialakuló fémrács atomi összenergiája a hűtés időtartamának a függvénye. Elvileg végtelen lassú hűtés eredményezi a minimális energiájú tökéletes rácsszerkezetet, mely analóg a geofizikai inverz probléma célfüggvényének globális minimumban való stabilizálódásával. A gyakorlatban ilyen lassú hűtés nem valósítható meg, ezért gyorsabb eljárás szükséges. Gyors hűtési ütem következtében viszont a kristályos szerkezetben rácshibák alakulnak ki, így a fém egy magasabb energiaszinten fagy „tökéletlen” rácdba. Ez megfelel az inverziós eljárás lokális minimumban való stabilizálódásának. Az atomok csak speciális hőkezelés hatására tudnak kiszabadulni e magasabb energiaszintű kristályszerkezetből, majd ezután megfelelően lassú hűtés mellett érik el az abszolút minimális energiájú rácsszerkezetet. Az MSA eljárás e folyamatot másolja a célfüggvény globális minimumának megtalálása érdekében. A módszer hazai együttes inverziós alkalmazását elsőként KIS (1996) publikálta.

A MSA terminológiájában a mért és a számított geofizikai adatok eltérését jellemző függvényt energiafüggvénynek nevezzük, melyet az inverz feladat megoldása érdekében minimalizálnunk kell. A leggyakrabban alkalmazott energiafüggvény ($k=1,2,\dots,N$ adat esetén) a mért és a számított geofizikai adatok eltérésének négyzetösszegét minimalizálja

$$E_2 = \frac{1}{N} \sum_{k=1}^N \left(d_k^{(m)} - d_k^{(sz)} \right)^2 \rightarrow \min, \quad (2.19)$$

mely akkor ad optimális megoldást, ha a mérési adatrendszert kiugró hiba nem terheli, ellenkező esetben pedig az

$$E_1 = \frac{1}{N} \sum_{k=1}^N \left| d_k^{(m)} - d_k^{(sz)} \right| \rightarrow \min \quad (2.20)$$

energiafüggvény minimalizálása vezet jobb eredményre. Az MSA eljárás az optimalizálás során véletlen keresést hajt végre a paramétertérben, miközben a paramétertér elemeit

$$m_i^{(q)} = m_i^{(q-1)} + b \quad (2.21)$$

formula szerint iterációról iterációra változtatja. A képlet szerint az i -edik modellparamétert a q -adik iterációs lépésben, az előző iterációs lépésbeli paraméterérték és a b paraméterkorrekció összegeként számítjuk. A b értékét minden iterációs lépésben $0 \leq b \leq b_{\max}$ között véletlenszerűen generáljuk, annak maximális értékét előírt iterációs lépésszám után csökkentjük a $b_{\max}^{(q)} = b_{\max}^{(q-1)} \cdot \varepsilon$, $0 \leq \varepsilon \leq 1$ összefüggés szerint. Ezzel az MSA eljárás adott hőmérsékleten különböző véletlen energiaállapotokat (modelleket) próbál ki, és az aktuális paramétertérbeli pontból számított energiafüggvény értéket összehasonlítja az előző lépésben elfogadott energiafüggvény értékkel. Az új modellparaméter elfogadását valószínűségi szabályhoz kötjük. A Metropolis algoritmus a Metropolis kritériumról kapta a nevét, mely az aktuális modell elfogadására a következő valószínűségi szabályt írja elő (METROPOLIS et al., 1953)

$$P(\Delta E = E^{(q)} - E^{(q-1)}) = \begin{cases} 1, & \Delta E \leq 0 \\ \exp(-\Delta E / T), & \Delta E > 0 \end{cases}.$$

A képlet szerint, ha az új állapotban az energia értéke (a mért és számított geofizikai adatok távolsága) csökken, akkor mindig elfogadjuk az új modellparamétereket. A képlet a lokális minimumból való kiszabadulás lehetőségét is megengedi, hiszen az energia növekedése (adat-térbeli távolság növekedése) esetén is definiál (egy az energianövekménytől függő) elfogadási valószínűséget. Ha erre teljesül a $P(\Delta E) \geq \alpha$ feltétel (ahol α egy egyenletes valószínűséggel generált $[0,1]$ intervallumba eső szám), akkor az új paramétereket elfogadjuk, ellenkező esetben elvetjük azokat. A képletben található T általánosított hőmérsékletet (próba-futtatások során nyert tapasztalatok alapján) az eljárás alatt alkalmasan megválasztott ütemben csökkenteni

kell. Az inverzió konvergenciája e hűtési ütemtől nagymértékben függ, így kerülni kell a túl gyors hűtést, mert ez az eljárást könnyen lokális minimumba tereli, viszont túl lassú hűtés sem célszerű, mert csak jóval hosszabb idő múlva kapjuk meg a megoldást. A (2.18) logaritmusos hűtési formula kicsit lassú, azonban garantálja a globális optimum megtalálását.

Végül röviden összefoglalva, az MSA algoritmus működéséről a következőket mondhatjuk. Kezdetben az input adatok (mért adatok, startmodell) és a folyamatjellemző paraméterek (kezdeti hőmérséklet, hűtés, paraméterváltoztatás mértéke) beállítása után véletlen számokkal perturbáljuk a modellvektor elemeit. Ha ezzel csökkent az adattávolság (az energiafüggvény értéke), akkor az új modellt elfogadjuk. Ellenkező esetben (az energia növekedése esetén) az új modell elfogadását $P(\Delta E) \geq \alpha$ feltételhez kötjük. Ha ez nem teljesül újra indítjuk a keresést. Ekkor még állandó hőmérsékleten folyik a keresés a paramétertér részletes vizsgálata céljából. Ezután a (2.18) hűtés szabálya szerint a folyamatot megadott lépésszám után kisebb hőmérsékleten és kisebb paraméterváltoztatást engedve folytatjuk. A kilépési feltételeket a stop-kritériumban határozzuk meg, mellyel a legutolsó lépésben elfogadott modellt tekintjük az inverz feladat megoldásának.

2.3.2 A Genetikus Algoritmus

A Genetikus Algoritmus (GA) elnevezés a globális szélsőérték kereső eljárások egy külön családjára utal, mely az optimalizációs eljárások körében a véletlen keresést használó módszerek csoportján belül az evolúciós algoritmusok között kap helyet. A GA működése biológiai analógián alapul, mely egyrészt az evolúciós fejlődést meghatározó természetes szelekciót, másrészt talán napjaink egyik legnagyobb ütemben fejlődő tudományágát, a genetikát használja fel. Köztudott, hogy a darwinisták szerint a természetben elsősorban azok az élőlények maradnak fenn és szaporodnak, melyek az adott körülmények között erre a legalkalmasabbnak bizonyulnak. Ezt az alap gondolatot felhasználva elsőként HOLLAND (1975) tett kísérletet az öröklődési mechanizmus leírására, először csak biológiai folyamatok kutatása céljából. Nemsokára ezt egyéb (nemcsak biológiai) mesterséges rendszerek vizsgálatára és optimalizációjára alkalmas matematikai algoritmusok követték.

A mesterséges populációk egyedeinek genetikai információit – a DNS-lánc analógiája alapján – kódolt számsorozatok hordozzák, melyek egyértelműen definiálják az optimalizációs probléma paramétereit. Mesterséges öröklődéskor a GA véletlen populációból választja ki a legalkalmasabb egyedet, azok között részleges információcserét és mutációt hajt végre egy alkalmasabb generáció létrehozása érdekében. A GA a populációt a kiválasztási, keresz-

tezési és mutációs operátorok ismételt alkalmazásával iteratív úton, determinisztikus és sztochasztikus lépések sorozatán keresztül fokozatosan javítja.

A geofizikai inverz probléma esetén egyed alatt a (2.1) szerint definiált modellvektort, azaz a geofizikai modellt értjük. A populáció minden egyes egyedéhez rendeljük hozzá egy alkalmassági, ún. fitness értéket, mely az egyed túlélési képességeit kvantitatív módon jellemzi. Minél nagyobb ez az érték, az egyed annál nagyobb valószínűséggel és nagyobb számban szaporodik. Lényegében a fitness függvény határozza meg, hogy az egyed bekerül-e a következő generációba, vagy elpusztul. Az új generáció összetételét a reprodukció művelete alakítja ki. Általában az átmeneti (genetikus műveleteken átesett) populáció egyedeiből építjük fel az új generációt, azonban léteznek olyan algoritmusok is, melyek megtartják a régi populáció legjobb (legnagyobb fitness értékű) egyedét és kicserélik azt az átmeneti populáció legrosszabb (legkisebb fitness értékű) egyedére (elitizmus). Lényegében, a GA olyan optimalizációs eljárás, mely a fitness függvény maximalizálására törekszik a legalkalmasabb modell(ek) megtartása érdekében. A geofizikai inverz feladat megoldása során tehát az alkalmassági függvényt úgy kell megválasztanunk, hogy azzal a mért és a számított geofizikai adatok eltérése mérhető legyen, és annak globális maximumához tartozzon az optimális megoldás.

A geofizikai inverzióban általánosan a következő skalár jellemzi a mérési és a (2.1)-ben definiált i -edik geofizikai modell alapján számított adatok illeszkedését

$$E^{(i)} = E(\vec{d}^{(m)} - \vec{g}(\vec{m}^{(i)})).$$

Mivel E vektornorma minimumát keressük, ezért pl. ennek reciproka képezheti a geofizikai inverz feladatban maximalizálandó fitness függvényt

$$F(\vec{m}^{(i)}) = \frac{1}{E^{(i)} + \varepsilon^2},$$

ahol ε^2 pozitív skalár (DOBRÓKA, 2001). A geofizikai inverziós alkalmazásban a fitness függvény az M -dimenziós modell térben gyakran nem folytonos (pl. ha a modellparaméterek egyes, a keresési térben lehetséges intervallumait geofizikai-földtani törvények alapján kizárjuk), és gyakran a parciális deriváltak létezése sem garantált. Ráadásul a fitness a direkt feladaton keresztül kapcsolatban van a (2.2) pontokból álló N -dimenziós adattérrel, mely a mintavételezés folytán diszkrét pontokból tevődik össze és mindig zajos. Az ilyen környezetben a hagyományos linerizált optimalizációs módszerek gyakran kudarcot vallanak, mivel a Jacobi-mátrixhoz megadásához elengedhetetlen differenciálhányadosok számítása, továbbá elegendő a priori információ szükséges a lokális szélsőérték helyek elkerülése szempontjából (ami gyakran ezzel együtt sem sikerül). Ezzel szemben a GA eljárások hatékonyak, robosztusabbak és

ugyan nincs matematikai garancia rá, de a gyakorlati tapasztalatok szerint képesek a globális maximumban stabilizálni a megoldást.

A keresési folyamat során a GA kezdetben nagyszámú véletlen modellt generál, nem egyetlen modellt tökéletesít, mint az SA eljárások. Az optimális modellszám optimalizálási problémák esetén általában 30-100 (ÁLMOS ET AL., 2002). Mivel a véletlen keresés nem pont-ról-pontra történik a paramétertérben, hanem több pontot szimultán megvizsgálunk, ezzel hatékonyan el tudjuk kerülni a lokális szélsőérték helyeket. Ráadásul a GA a keresés közben az egyes egyedek kódjainak hasonlóságait felismerve, a paramétertér egyes hipersíkpartícióit egyszerre átvizsgálja és szelektálja. Ennek hátránya csak a futási idők tekintetében jelenik meg, ugyanis a linearizált (gradiens-alapú) módszerekkel összehasonlítva a GA-ok lassú eljárások. Ez a technika ugyanakkor előnyös tulajdonságokat is mutat a linearizált módszerekkel szemben, mivel nem alkalmaz linearizálást, így a deriváltak számítása szükségtelen, csak a kódokkal és a célfüggvény értékészletével dolgozik. A GA eljárás tehát nem igényel segédinformációkat – derivált- és startmodell-független –, sőt a legmodernebb algoritmusok már a modellparaméterek lebegőpontos ábrázolásával a kódolást is elkerülik. A következőkben röviden áttekintem a klasszikus és az ún. valós kódolású genetikus algoritmusok elvi alapjait.

2.3.2.1 A Klasszikus Genetikus Algoritmus (CGA)

A CGA (Classical Genetic Algorithm) bizonyos tekintetben eltér más globális optimalizációs módszerektől. Egyik alapvető tulajdonsága, hogy a paramétereket kódolt formában kezeli, és a genetikus műveleteket a kódokon végzi el közvetlenül. Az optimum keresése során az alkalmassági függvény kiértékeléséhez tehát dekódolási művelet szükséges.

A kódolás legegyszerűbb módja a bináris átalakítás, mely a modellt egy véges hosszúságú számsorozattá konvertálja. Ennek szerkezete analóg a kromoszómával, mely a populáció minden egyedét genetikailag egyértelműen azonosítja. A geofizikai modellt a modellparaméterek kódjaiból összefűzött bitfüzér reprezentálja, melynek alapelemeit, a géneket 0 és 1 értékű bitekkel ábrázolhatjuk. Pl., ha az inverz feladatban a longitudinális hullám terjedési sebessége 1500 - 1810 m/sec között változik, akkor

$$00000 = 1500$$

$$00001 = 1510$$

$$00010 = 1520$$

$$00011 = 1530$$

$$\vdots$$

$$11111 = 1810$$

kódok a kereset modellparamétert 10 m/sec pontossággal bontják fel. Észrevehető, hogy pl. a sebességet 10 m/sec-al 1530-ról 1540-re növelve 3 bit megváltoztatása szükséges. A bináris kódolás lassítja a GA eljárást, mivel legtöbbször több bitet kell egyszerre átkapcsolnunk ahhoz, hogy a modellparaméter értékét „egységnyi” értékkel megnöveljük. A futási idők szempontjából alkalmasabb pl. a Gray kódrendszer (FORREST, 1993), vagy egyéb kódolási ABC alkalmazása.

A bináris CGA algoritmus esetén a keresési tér pontjainak kódolását a bináris genetikus operátorok alkalmazása követi. Az első a szelekció, mely véletlenszerűen kiválasztja és arányosan sokszorosítja az egyedeket a hozzájuk tartozó fitness értékeik alapján. Ez azt eredményezi, hogy a legalkalmasabb egyedek nagy számmal bekerülnek egy új populációba, melyben a legkisebb fitness értékkel rendelkező egyedek már nem vesznek részt. E fitness arányos kiválasztást először az ún. Rulett-szelekcióval hajtották végre (GOLDBERG, 1989), de további szelekciós metódusok is léteznek, melyeket később a 2.3.2.2 fejezetben ismertetek.

A keresztezés műveletével a kiválasztott modelleket sztochasztikusan párosítjuk és parciális információcserét hajtunk végre közöttük. Vegyünk a fenti szeizmikus példából két sebességadatot, majd egy véletlenszerűen generált bitpozíciótól jobbra elhelyezkedő biteket cseréljük fel a két egyed között. Ez az egyponos (egyszerű) keresztezés, mely pl. $k=4$ bitpozíció esetén az $m^{(1,régi)}$, $m^{(2,régi)}$ kiinduló modellekből $m^{(1,új)}$, $m^{(2,új)}$ új modellpárt hozza létre

$$\begin{array}{l}
 m^{(1,régi)} = 0110|1 \\
 \quad \quad \quad \downarrow \\
 m^{(2,régi)} = 1100|0 \\
 \quad \quad \quad \downarrow \\
 m^{(1,új)} = 01100 \\
 m^{(2,új)} = 11001
 \end{array}$$

A bitfüzér keresztezését modellparaméterenként külön-külön generált bitpozíciók mentén is elvégezhetjük többpontos keresztezéssel.

Az utolsó genetikus operátor a mutáció, mely a CGA eljárás esetén egy bit értékének véletlenszerű megváltoztatásával hajtható végre. A konvergencia erősen függ a mutációs aránytól (mutált egyedszám/összes egyedszám), melynek értékét tapasztalati úton adjuk meg. A hagyományos mutáció pl. a terjedési sebességet kódoló bitsorozat $k=5$ bitjét átkapcsolja, ahol

$$\begin{array}{l}
 m^{(1,régi)} = 01100 \\
 \quad \quad \quad \downarrow \quad \downarrow \\
 m^{(1,új)} = 01101
 \end{array}$$

szerint változik meg a kiinduló paraméter. Megemlítjük, hogy a mutáció egyik speciális művelete az inverzió (nem geofizikai inverzió!), mely véletlenszerűen kiválasztja a kódsorozat egy szakaszát, majd azt megfordítva helyezi a biteket vissza ugyanazon pozíciókba. A fenti genetikus operátorok ismételt alkalmazásával a CGA eljárás a régi generációkból újabbakat generál, ezért a generáció megegyezik az optimalizációs algoritmus iterációs lépésszámával. E folyamat végén az utolsó generáció egyedeit dekódolva az alkalmassági értékek maximumához tartozó modellt fogadjuk el megoldásként.

2.3.2.2 A Valós Kódolású Genetikus Algoritmus (FGA)

A klasszikus CGA eljárás hatékonyan működik az optimalizációs probléma megoldásánál, azonban meglehetősen időigényes. Elegendő, ha arra gondolunk, hogy geofizikai inverz probléma esetén iterációs lépésenként kódolás-dekódolás műveletet kell alkalmaznunk a szintetikus adatok számítása érdekében, mely a célfüggvény (becsült modell fitness értékének) számításához elengedhetetlen. MICHALEWICZ (1992) azonban kimutatta, hogy felépíthetők olyan korszerű GA-ok is, melynél a kódolási művelet elhagyható, továbbá a bináris kódolás helyett egy természetesebb számábrázolással a probléma reprezentáció is tökéletesíthető. Az FGA (Float-Encoded Genetic Algorithm) a gének lebegőpontos számábrázolásán alapul. Ez azt jelenti, hogy az FGA eljárás valós modell paraméterekkel számol közvetlenül, nem pedig kódokat választ ki, keresztez vagy mutál. Minden modellparaméter egy-egy kijelölt (csak alulról és felülről korlátozott) valós intervallumból kerül ki, így a modelltér sokkal finomabban felbontható, mint hagyományos bináris kódolással. Az FGA eljárás hatékonysága legfőképpen a futási idők tekintetében mutatkozik meg. Michalewicz vizsgálatai alapján arra a következtetésre jutott, hogy az FGA algoritmus nagyságrendekkel kisebb CPU időket produkál egyazon probléma megoldásánál, mint a CGA eljárás.

Az FGA eljárás alapelvei megegyeznek a CGA módszerekével, annyi különbséggel, hogy az FGA a genetikus operátorokat valós műveletekkel definiálja. A valós operátorok gazdag eszköztárából azokat a műveleteket szeretném áttekinteni, melyeket az értekezés gyakorlati részében magam is alkalmaztam. A kezdeti véletlen modellek Rulett-szelekciója esetén az i -edik modell kiválasztásának valószínűsége

$$P(\vec{m}^{(i)}) = \frac{F(\vec{m}^{(i)})}{\sum_{j=1}^S F(\vec{m}^{(j)})},$$

mely a modell fitness értékének és a populációban résztvevő összes modell fitness-összegének hányadosa (S a populáció mérete, azaz a benne részt vevő modellek száma). Ekkor

HOUCK et al. (1995) szerint az i -edik egyed akkor kerül kiválasztásra, ha egy $\zeta \in U(0,1)$ egyenletes valószínűséggel generált számnál nagyobb az i -edik kummulatív valószínűség (C_i)

$$C_i = \sum_{t=1}^i P_t$$

$$C_{i-1} < \zeta_i < C_i.$$

E szelekciós eljárásban egyenként válogatjuk ki az egyedeket, addig amíg a kiinduló modellek számának megfelelő új populációt nem generáltunk. Ez az eljárás egy átmeneti populációt hoz létre, mellyel a reprodukció után felépül egy új generáció. A kiválasztás következtében bizonyos egyedek elpusztulnak, mások pedig akár többször is kiválasztásra kerülnek a nekik megfelelő fitness értékük alapján. E művelet sémáját láthatjuk a 2. melléklet legfelső ábráján.

A fenti kiválasztási feltételek alkalmazásán alapulnak a rang szelekciós metódusok is. E módszernél kezdetben az egyedeket alkalmassági értékeik szerint sorba rendezzük, úgy hogy a legnagyobb fitness értékű egyed rangja 1, a legkisebbé pedig S (populáció mérete) legyen. Ezután kiszámítjuk az egyedek kiválasztási valószínűségeit. Az ún. normált geometriai rangszelekció esetén az i -edik egyed kiválasztási valószínűsége MICHALEWICZ (1992) alapján

$$P(\bar{m}^{(i)}) = \frac{q}{1 - (1 - q)^S} (1 - q)^{r_i - 1}$$

az egyed rangjától (r_i), a maximális fitness értékű egyed kiválasztásának valószínűségétől (q) és a populáció modellszámától függ.

E két kiválasztási mechanizmus mellett érdemes említést tenni a versenyszelekcióról, mely a legegyszerűbb, a kiválasztási valószínűség számítását nélkülöző kiválasztó eljárás. Alkalmazásakor kezdetben egy bizonyos számú egyed kiválasztunk (az ismétlés engedélyezése mellett) a populációból, majd ezek közül kiemeljük a legnagyobb fitness értékkel rendelkező egyedeket és áthelyezzük az új populációba. Ezt az eljárást egészen addig ismétljük, míg a kezdeti populációméretet jellemző S számú egyed ki nem választottuk.

A keresztezési eljárások legegyszerűbb esete az egy pontos (egyszerű) keresztezés, melyre korábban bináris példát is láttunk. Valós esetben e művelet MICHALEWICZ (1992) alapján

$$m_i^{(1,új)} = \begin{cases} m_i^{(1,régi)} & , i < k \\ m_i^{(2,régi)} & , i \geq k \end{cases}$$

$$m_i^{(2,új)} = \begin{cases} m_i^{(2,régi)} & , i < k \\ m_i^{(1,régi)} & , i \geq k \end{cases},$$

ahol $m_i^{(1,régi)}$, $m_i^{(2,régi)}$ a kiinduló, valamint $m_i^{(1,új)}$, $m_i^{(2,új)}$ a keresztezett két modell i -edik paramétere, és k véletlen egész szám. A k véletlen számot az \bar{m} modellt felépítő paraméterek számá-

nak megfelelő tartományból ($i=1,2, \dots, M$) kell sorsolnunk. E szám azt a k -adik paraméterpozíciót határozza meg, melynél a nagyobb indexhez tartozó komponenseket fel kell cserélnünk a két modell között (ld. 2. melléklet középső ábra). A keresztezés műveletével két kiinduló (régi) modelltől két újat származtatunk.

A következő gyakran alkalmazott művelet az aritmetikus keresztezés, mely a kiinduló modellek lineáris kombinációjával tér vissza. Ha $p \in [0,1]$ egyenletes valószínűséggel generált véletlen egész szám, akkor a keresztezés után az új modellpár MICHALEWICZ (1992) alapján

$$\left. \begin{aligned} m_i^{(1,új)} &= pm_i^{(1,régi)} + (1-p)m_i^{(2,régi)} \\ m_i^{(2,új)} &= (1-p)m_i^{(1,régi)} + pm_i^{(2,régi)} \end{aligned} \right\}$$

Az aritmetikus keresztezés továbbfejlesztett változatának tekinthető a heurisztikus keresztezés, mely $F(\bar{m}^{(1)}) > F(\bar{m}^{(2)})$ fitness értékre vonatkozó feltétel teljesülése mellett, a következő módon extrapolálja a két kiinduló modellt MICHALEWICZ (1992) alapján

$$\left. \begin{aligned} m_i^{(1,új)} &= m_i^{(1,régi)} + p(m_i^{(1,régi)} - m_i^{(2,régi)}) \\ m_i^{(2,új)} &= m_i^{(1,régi)} \end{aligned} \right\}$$

Az utolsó genetikus operátor a mutáció, melynek sémája a 2. melléklet legalsó ábráján látható. Az ún. egyenletes eloszlású mutáció az egyed valamely $j \in (1,M)$ -edik paraméterét felcseréli egy véletlen számmal. E szám a modellparaméter lehetséges értékeinek ($i=1,2,\dots,M$) tartományából egyenletes valószínűséggel kerül ki. A mutációt leíró formula MICHALEWICZ (1992) alapján a következő

$$m_i^{(1,új)} = \begin{cases} m_i^{(1,új)} \in U[\min(m_i), \max(m_i)] & , i = j \\ m_i^{(1,régi)} & , i \neq j \end{cases}$$

Mivel a modellparaméterek a genetikus műveletek alkalmazása után sem vehetnek fel a lehetséges intervallumukon kívüli értékeket, ezért az operátorok „alkalmazhatóságának” valószínűségére fennáll a

$$P_f = \begin{cases} 0 & , \forall i : m_i^{(új)} > \max(m_i) \parallel m_i^{(új)} < \min(m_i) \\ 1 & , \text{egyébként} \end{cases}$$

kifejezés ($i=1,2,\dots,M$). Ha a P_f valószínűség nagyszámú próbálkozás után is zérus, akkor a kiinduló modelleket kell az új modelleknek megfeleltetni.

Összegezve az FGA eljárást, tekintsük annak geofizikai inverziós alkalmazását. Első lépésben beolvassuk a mérési adatokat, és a problémához illeszkedő fitness függvényt definiálunk. Ezután meghatározzuk a keresési teret, majd ennek megfelelő nagyszámú véletlen modellt generálunk. A geofizikai válaszfüggvények megadásával, a direkt feladatot megoldva

elvi adatrendszert számítunk. Ezek után kiválasztjuk az alkalmazni kívánt genetikus operátorokat. Inputként még a maximális generációk (iterációs lépések) számát, majd a stopkritériumot adjuk meg. Ezután a populáció egyedeinek fitness értékeit kiszámítjuk, és ez alapján a jobb egyedekből egy átmeneti populációt hozunk létre. E populációból véletlenszerűen kiválasztunk két egyedet, melyeken genetikus információcserét hajtunk végre (keresztezés). Ezután egy újabb véletlen egyed egy génjét megváltoztatjuk. A mutáció végrehajtása után a reprodukció művelete során megalkotjuk az új generációt az előző és az átmeneti populáció egyedeiből, majd növeljük az iterációs lépésszámot. Az eddigi folyamatot addig ismétljük, míg a megadott stopkritérium nem teljesül. Az utolsó generáció maximális fitness értékkel rendelkező egyedét fogadjuk el az inverz feladat megoldásának.

3. A MÉLYFÚRÁSI GEOFIZIKA DIREKT FELADATA

Szénhidrogén-kutatás során a porózus, permeábilis rétegek (melyek hazai viszonylatban többnyire agyaggal szennyezett törmelékes-üledékes, karbonátos vagy metamorf kőzetek) petrofizikai paramétereinek meghatározása mélyfúrési geofizikai szelvények felhasználásával történik. A tárolójellemzők (rétegvastagság, kőzetösszetétel, porozitás illetve annak jellege és típusa, az agyagtartalom, valamint annak típusai - laminált, diszperz, strukturális-, a kitermelhető és redukálhatatlan víztelítettség, szénhidrogén-telítettség, permeabilitás) üledékes kőzetek esetén általában (a permeabilitást leszámítva) a szelvényekből nagy pontossággal meghatározhatók. A metamorf tárolók kiértékelése nehezebb feladat, mivel általában a komplex kőzetmátrix és a mérési körülmények miatt a szelvények információtartalma kisebb, és gyakran nem teljesülnek a jól bevált homok-agyag összetettségben alkalmazott empirikus összefüggések.

Az értekezésben az inverziós kiértékelési eljárások vizsgálatához üledékes kőzetekre vonatkozó értelmezési modelleket választottam, melyek ismeretlenjeit a tárolókutatás néhány alapparamétere képezte. E petrofizikai (fajlagos térfogatl jellemző) mennyiségek meghatározása alapján megadható a tárolókőzet összetétele, valamint megbecsülhető a kitermelhető szénhidrogén mennyisége. Legyen (2.1) modellvektor egy adott mélységpontban a következő

$$\vec{m} = [POR, SX0, SW, VSH, VSD]^T, \quad (3.1)$$

ahol

POR – effektív porozitás [%],

SX0 – kisépért zóna víztelítettsége [%],

SW – érintetlen zóna víztelítettsége [%],

VSH – agyagtartalom [%],

VSD – homok mátrixkomponens fajlagos térfogata [%].

A fenti kőzetfizikai paraméterek közvetlenül nem mérhető mennyiségek, meghatározásuk a mért szonda-adatok felhasználásával történik. A karotázs mérések során a fúrólukban és közvetlen környezetében fellépő természetes, illetve a szondán keresztül mesterségesen létrehozott fizikai terek jellemző paramétereit rögzítjük a mélység függvényében. Nyitott lyukban a mérést különböző behatolású és vertikális felbontóképességű lyukeszközökkel hajtjuk végre. Általában a szelvényeket a szénhidrogén-kutatásban betöltött szerepük alapján technikai, litológiai, porozitáskövető, és szaturációs szelvények szerint csoportosítjuk. A következő szelvénykombinációval – mely inverziós célkitűzésünk szempontjából alkalmas a (3.1) vek-

torban szereplő kőzetjellemező paraméterek meghatározására – minden mélységpontban képezhető (2.2) alapján a pontonkénti inverz feladat mért adatvektora

$$\vec{d}^{(m)} = [GR, SP, PORN, DEN, AT, RMLL, RLLD, K, U, TH]^T, \quad (3.2)$$

ahol

- GR – természetes gamma szelvény [API],
- SP – természetes potenciál szelvény [mV],
- PORN – neutron porozitás szelvény [p.u.],
- DEN – sűrűség szelvény [gcm^{-3}],
- AT – akusztikus terjedési idő szelvény [μsecm^{-1}],
- RMLL – mikrolaterologgal mért fajlagos ellenállás szelvény [ohmm],
- RLLD – mélybehatolású laterologgal mért fajlagos ellenállás szelvény [ohmm],
- K – kálium spektrális gamma szelvény [%],
- U – urán spektrális gamma szelvény [ppm],
- TH – tórium spektrális gamma szelvény [ppm].

A mélyfúrési geofizikai mérések rendszerint bonyolult mérési körülmények (szabálytalan lyukgeometria, iszappal történő elárasztás, szondák eltérő behatolási mélysége és vertikális felbontóképessége, nagy nyomás és magas hőmérséklet, vertikálisan és horizontálisan inhomogén közeg, anizotropia stb.) között történnek. Ehhez járul az a tény, hogy a mért adatok mindig zajjal terhelték. A mérési hibákat laza rétegekben általában a kavernásodás vagy az iszaplepeny kialakulása, továbbá az elektronika (statisztikus ingadozás, ciklusugrás stb.) okozza. Ezért először a mért szelvényeket a szonda környezetének különböző hatásaira korrigálnunk kell. E művelettel növelhető a mérések kőzetekre vonatkozó információtartalma, viszont a korrekciók is egyfajta hibaforrásnak foghatók fel. A korrigálás után a transzformált szelvényeket mélységre illesztjük, majd azokat crossplot-ok segítségével hitelesítés céljából ellenőrizzük. Az üledékes rétegsor réteghatárainak kijelölése hagyományosan manuális vagy interaktív történik. Ehhez nagy felbontóképességű szelvényeket alkalmazunk. Szükség esetén e kis behatolású és a „hosszú szondák” együttes kiértékelése előtt a nagy felbontóképességű szelvényeket átlagoljuk, mélységsimítást hajtunk rajtuk végre.

A kiértékelés keretében a mért adatrendszer és előzetes ismereteink alapján megbecsüljük a vizsgált rétegsor modellparamétereinek az értékét. E modell a vizsgált rétegek petrofizikai paramétereit kvantitatív módon rögzíti. A modellalkotás annál sikeresebb, minél több a priori információ van a birtokunkban az adott földtani szerkezetre vonatkozólag. A fűrőmagok labo-

ratórium vizsgálati eredményei (porozitás, permeabilitás, víztelítettség, redukálhatatlan víztelítettség stb.), a feldolgozásból nyert crossplot-ok (mátrix, fluidum-jellemzők stb.), a közeli fúrások mélyfúrési geofizikai szelvényei, a felszíni geofizikai mérések és egyéb geológiai ismeretek mind-mind felhasználhatók a modellalkotás során.

A kiértékelési modell birtokában elvi adatokat számítunk az általunk feltételezett földtani szerkezetre, mely ugyancsak hibával terhelt, hiszen a modell egyszerűségénél fogva nem egyezik meg a valódi földtani szerkezettel. Az elvi adatok számítása az ún. direkt feladat keretén belül történik. Ennek megoldásához ismernünk kell azokat a kőzetfizikai relációkat, melyek kapcsolatot teremtenek a (3.1) modellparaméterek és a (3.2) szelvényadatok elméleti (számított) értékei között. A szakirodalom számos empirikus szonda válaszegyenletet közöl (2.3) egyenletrendszer közelítő megoldására. Az egyenletek megfelelő kiválasztása függ az aktuális földtani szituációtól (a telep mélysége, kora, litológiája, rétegtartalma, kompakciója stb.). Az értekezésben (3.2) adatvektor elvi értékeinek meghatározásához a következő egyenletrendszert tekintetem alapul (HALLIBURTON COMPANY, 1993):

1. Természetes gamma válaszfüggvény:

$$GRTH = \frac{1}{DETH} \left\{ \begin{aligned} &POR(GRMF \cdot DEMF \cdot SX0 + GRCH \cdot DECH(1 - SX0)) + \\ &+ VSH \cdot GRSH \cdot DESH + \sum_{i=1}^n VMA_i \cdot GRMA_i \cdot DEMA_i \end{aligned} \right\} \quad (3.3)$$

2. Természetes potenciál válaszfüggvény:

$$SPTH = SPSD + POR \cdot SPCHC(1 - SX0) - VSH(SPSD - SPSH) \quad (3.4)$$

3. Neutron-porozitás válaszfüggvény:

$$\begin{aligned} PORNTH &= POR(PORNMF - BCOR(1 - SX0) - BC) + VSH \cdot PORNSH + \\ &+ \sum_{i=1}^n VMA_i \cdot PORNMA_i + PORNEX \\ PORNEX &= \left(\frac{DEMA}{2.65} \right)^2 (2 \cdot POR^2 \cdot JCH + 0.04 \cdot POR)(1 - JCH) \\ JCH &= PORNMF \cdot SX0 + PORNSH(1 - SX0) \\ BCOR &= SCHB \left\{ 1 - \frac{B}{DEMF(1 - PMF)} \right\} \\ BC &= 2 \cdot POR(1 - SX0)SCHB(1 - B) \{ 1 - (1 - SX0)(1 - B) \} \\ B &= \begin{cases} 2.2 \cdot DECH & , DECH < 0.25 \\ DECH + 0.3 & , DECH \geq 0.25 \end{cases} \end{aligned} \quad (3.5)$$

4. Sűrűség válaszfüggvény:

$$\begin{aligned}
DETH &= POR(DEMF - 1.07 \cdot SCHRB(1 - SX0)(ALFA \cdot DEMF - BETA)) + \\
&+ VSH \cdot DESH + \sum_{i=1}^n VMA_i \cdot DEMA_i \\
ALFA &= 1.11 - 0.15 \cdot PMF \\
BETA &= \begin{cases} 1.24 \cdot DECH & , DECH \leq 0.333 \\ 1.11 \cdot DECH + 0.03 & , DECH > 0.333 \end{cases}
\end{aligned} \tag{3.6}$$

5. Akusztikus terjedési idő válaszfüggvény (Wyllie egyenlet):

$$\begin{aligned}
ATTH &= POR(ATMF \cdot SX0 + ATCH(1 - SX0)) + VSH \cdot ATSH + \sum_{i=1}^n VMA_i \cdot ATMA_i \\
ATCH &= 1.11 \{ ATO(DECH - 0.05) + ATG(0.95 - DECH) \}
\end{aligned} \tag{3.7}$$

6. Mikrolaterolog válaszfüggvény (Indonéziai egyenlet):

$$\frac{1}{RMLLTH^{1/2}} = \left\{ \frac{VSH^{(1-VSH/2)}}{RSH^{1/2}} + \frac{POR^{BM/2}}{(BA \cdot RMF)^{1/2}} \right\} SX0^{BN/2} \tag{3.8}$$

7. Mélybehatolású laterolog válaszfüggvény (Indonéziai egyenlet):

$$\frac{1}{RLLDTH^{1/2}} = \left\{ \frac{VSH^{(1-VSH/2)}}{RSH^{1/2}} + \frac{POR^{BM/2}}{(BA \cdot RW)^{1/2}} \right\} SW^{BN/2} \tag{3.9}$$

8. Spektrális természetes gamma válaszfüggvények:

$$\begin{aligned}
KTH &= \frac{1}{DETH} \left(POR \cdot SX0 \cdot KMF \cdot DEMF + VSH \cdot KSH \cdot DESH + \right. \\
&\quad \left. + \sum_{i=1}^n VMA_i \cdot KMA_i \cdot DEMA_i \right) \\
UTH &= \frac{1}{DETH} \left(POR \cdot SX0 \cdot UMF \cdot DEMF + VSH \cdot USH \cdot DESH + \right. \\
&\quad \left. + \sum_{i=1}^n VMA_i \cdot UMA_i \cdot DEMA_i \right) \\
THTH &= \frac{1}{DETH} \left(POR \cdot SX0 \cdot THMF \cdot DEMF + VSH \cdot THSH \cdot DESH + \right. \\
&\quad \left. + \sum_{i=1}^n VMA_i \cdot THMA_i \cdot DEMA_i \right)
\end{aligned} \tag{3.10}$$

A (3.3)-(3.10) elméleti szonda-válasz egyenletek bal oldalán a (3.2) mélyfúrás geofizikai szelvény adatok teoretikus értékei, jobb oldalán pedig (3.1) modellparaméterek és nagyszámú függvénykonstans állnak (az egyenletekben szereplő jelölések részletes listáját a 3. melléklet tartalmazza). Ez utóbbiak a kőzetmátrixot, az agyagot és a pórufolyadékot jellemzik, és a kőzet texturális sajátosságait (a kőzetalkotók geometriai elrendeződése, mérete, alakja, eloszlá-

sa) hordozzák magukban. A függvénykonstansok részben zónaparaméterek, melyek egy nagyobb mélységintervallumon belül állandó mennyiségek (mátrix, agyag, fluidum jellemzők), másrészt ún. szelvényjellegű konstansok, melyek nem túl nagy mélységintervallumban állandók, vagy a mélységnek lassan változó függvényei (pl. hőmérséklet, iszapellenállás stb.). A válaszgyenlet-rendszer matematikai szempontból nemlineáris, azonban az egyenletek egyszerű szerkezetűek, többnyire a számított szelvényadatok a modellparaméterek többváltozós lineáris függvényei. Ez meglehetősen gyors direkt feladat megoldást tesz lehetővé, mely inverziós szempontból rendkívül előnyös tulajdonság, különösen a nagyobb számítási időt igénybe vevő globális optimalizációs módszereken alapuló inverziós algoritmusok alkalmazásánál. Emiatt a globális inverziós módszerek alkalmazása a geofizikán belül talán a mélyfúrési geofizikai inverzióban a legindokoltabb, mivel pl. más felszíni geofizikai modellezésekhez (végeselemes, véges különbséges több dimenziós stb.) képest nagyságrendileg rövidebb futási idő szükséges a direkt feladat megoldásához.

A direkt feladatban szereplő válaszgyenleteket további kiegészítő, ún. korlátozó egyenletekkel bővíthetjük, melyek a petrofizikai paraméterek értékeire és kapcsolatára írnak elő megszorítást. Ezen szabályozó egyenleteket MAYER et al. (1980) három típusba sorolták. Elsőként tekintünk az elméleti megszorításokat, melyek a petrofizikai paramétereket matematikai szabályok alapján korlátozzák, pl.

$$0 \leq POR \leq 1.0,$$

$$0 \leq VSH \leq 1.0,$$

$$0 \leq SX0 \leq 1.0,$$

$$0 \leq VMA_i \leq 1.0.$$

A fenti paraméterek tapasztalati értékeire további kikötések tehetők, pl. törmelékes-üledékes kőzetek esetén néhány petrofizikai paraméter a terepi gyakorlatban a következőképpen szabályozható

$$0 \leq POR \leq 0.47,$$

$$0.15 \leq SW \leq 1.0,$$

$$0.50 \leq SX0 \leq 1.0.$$

A lokális korlátozások a területre vonatkozó a priori információk alapján adódnak (pl. a maximális, és az áteresztőképes minimális porozitás-, vagy a minimális és maximális gyakorlati víztelítettségek). Végül a geológiai szabályozó egyenletek alkotják a korlátozó egyenletek harmadik csoportját, melyek az ismeretlenek közötti kapcsolatokat írják elő fizikai, földtani törvények alapján. Ilyen egyenlet, pl. a víztelítettségekre vonatkozó $SX0 \leq SW^{1/5}$ összefüggés (BAKER ATLAS, 1996).

A korlátozó egyenletek mellett az egyes kőzetkomponensek fajlagos térfogatösszegére vonatkozó alapvető törvénynek is kell teljesülnie. Ha kőzetet három fő alkotórészre bontjuk (pórustér, kőzetmátrix, agyag), akkor az egységnyi térfogatú kőzetre az anyagmérleg egyenlet a kőzetmátrixot alkotó n számú ásványi komponens esetén a következő

$$POR + VSH + \sum_{i=1}^n VMA_i = 1. \quad (3.11)$$

A direkt feladat megoldásával, az adott terepi problémához illeszkedő teoretikus adatrendszert tudunk generálni, mely alkalmas a fúrólukban mért adatokkal való összehasonlítással a kérdéses kőzetfizikai paraméterek meghatározására. Az adatok hibája mellett természetesen a válasz egyenletek változóinak empirikus megadásából származó modell hibája is kihat a becsült paraméterek pontosságára. A szelvényeket alapvetően befolyásoló három jellemző – a kőzet struktúrája, textúrája és a fluidum-tartalma – közül a modell hibáját leginkább a texturális jellemzők kis megbízhatósága okozza, ugyanis azokat általános összefüggések hiányában csak irodalmi vagy tapasztalati képletek alapján tudjuk csak megadni. A legkényesebb anyagi konstansok (az agyag jellemzői mellett) a nemlineáris ellenállás egyenletekben megjelenő cementációs kitevő (BM), tekervényességi (tortuozitási) tényező (BA), a szaturációs exponens (BN). Ilyen paraméter még az akusztikus terjedési idő egyenletét korrigáló kompaktációs koefficiens, mely laza (konszolidálatlan) üledékes kőzetek értelmezésénél jelenik meg. E jellemzőket egy-egy zónában konstansnak feltételezzük, azonban ismert, hogy értékük nem állandó gyakran még egy összletben sem. A pontatlanul megválasztott texturális jellemzők hatása igen kedvezőtlen lehet az inverz feladat megoldására.

4. INVERZIÓS MÓDSZERFEJLESZTÉS MÉLYFÚRÁSI GEOFIZIKAI ADATOK FELDOLGOZÁSÁRA

A mélyfúrési geofizikai adatokat a gyakorlatban együttesen invertáljuk. Ez azt jelenti, hogy a különböző fizikai elven, vagy ugyanazon elven, de eltérő szondahossz mellett mért (pl. fajlagos ellenállás) szelvényadatokat egyetlen inverziós eljárásban integráljuk. Ezután a direkt feladat keretében számított adatrendszerrel a mért adatokkal összehasonlítva valamely inverziós módszer segítségével megbecsüljük az ismeretlen modellparaméterek értékét. Az együttes inverzió alkalmazása a mélyfúrési geofizikában a legelterjedtebb, ezért karotázs adatok független inverziójáról ritkán beszélünk.

A mélyfúrési geofizikai inverz feladatban ismeretlennek tekintjük a szonda válaszegyenletekben jelenlévő térfogatjellemező petrofizikai-, texturális és zónaparamétereket, illetve az azokban meg nem jelenő, geometriai struktúrát jellemző rétegvastagságokat. Az ismeretlen paraméterek száma pontonként legegyszerűbb esetben 4 (porozitás, víztelítettség, agyagtartalom, egy ásványi komponensből álló közetmátrix), azonban a gyakorlatban ez a közetek összetételétől és a rétegtartalomtól függően akár 8-10 is lehet. A zónaparaméterek száma e szám sokszorososa, míg a mért adatok száma pontonként általában 7-11. Hagyományosan, a mélységpontonként végzett inverzió esetén e nagymértékű alulhatározottság kezelése csak úgy lehetséges, ha a zónaparamétereket a priori adottnak tekintjük. Erre általában megvan a lehetőség az előzetes geológiai, geofizikai és labormérések ismeretében. E keretek között azonban megoldhatatlan problémát jelent a réteghatár-koordináták inverziós meghatározása.

A nemlineáris mélyfúrési geofizikai inverz feladat hagyományos megoldása mélységpontonkénti inverzióval történik. Ennek keretében a mért mélységintervallum egyes pontjaiban külön-külön határozzuk meg az inverziós ismeretleneket, a pontbeli szelvényadatok felhasználásával. A pontbeli adatok aránylag kis száma miatt, a válaszegyenletekben szereplő zónaparamétereket konstansnak feltételezzük, így az ismeretlen petrofizikai paraméterekre nézve kismértékben túlhatározott inverz feladatot kapunk. Mivel a szelvényen egymás „mellett” elhelyezkedő mélységpontok adatait a szeparált (pontonkénti) inverzió során függetlennek tekintjük egymástól, ezért a rétegvastagságok inverziós meghatározása e keretek között nem lehetséges.

A mélységpontonkénti inverziós eljárással a közetek pontbeli petrofizikai tulajdonságait lokális szelvényadatok felhasználásával határozzuk meg. Mivel a mélységpontban a mért adatok száma alig több az ismeretlenek számánál, a csekély túlhatározottság miatt a paraméterbecslés pontossága és megbízhatósága relatíve korlátozott. Másrészt, mivel pontonkénti inverzió esetén a mélységpontokat általában függetlennek tekintjük a szomszédos vagy a távo-

labbi mélységpontoktól, így az inverzió nem veszi figyelembe azokat a földtani struktúrára vonatkozó információkat, amelyeket az adatrendszer tartalmaz. A mélyfúrási geofizikai értelmezés feladata az egyes földtani egységek (rétegek, zónák) kvantitatív kőzetfizikai jellemzése, továbbá mint alapvető földtani információ, a réteghatárok elhelyezkedésének a meghatározása. Ez a gyakorlatban inverziós eljárásen kívül történik, a litológiai és a nagy felbontású szelvények jellegzetes pontjainak vizsgálata alapján. A fenti problémák kezelése céljából célszerű egy olyan módszer kifejlesztése, mely meghatározott (akár a teljes mért) intervallumba eső mélységpontok adatrendszerét egyazon inverziós eljárás keretében invertálja. E módszert nevezzük intervallum inverziós eljárásnak.

Az intervallum inverzió számára a lokális válaszegyenleteket ki kell terjesztenünk a vizsgált mélységintervallumra. DOBRÓKA (1995) a petrofizikai paramétereket, mint a mélység függvényeit vezette be, ezzel intervallumon értelmezett válaszegyenleteket definiált a direkt feladat számára. A mélységfüggő válaszegyenletek paramétereinek diszkretizálása sokféleképpen történhet. Diplomamunkámban sorfejtési eljárást alkalmaztam, melynek keretében ismert bázisfüggvény-rendszer segítségével leírt rétegjellemző petrofizikai paraméterek inverziós meghatározásával foglalkoztam (SZABÓ, 1999). Ezt egységugrás függvényekből felépített, rétegenként homogén földtani modell esetén vizsgáltam. A sorfejtésben szereplő bázisfüggvények azonban szabadon megválaszthatók és az adott földtani szituációhoz illeszthetők. Érdeemes megjegyezni, hogy az inverzió stabilitása szempontjából előnyt jelent olyan bázisfüggvények alkalmazása, ahol a lehető legkevesebb ismeretlennel tudjuk megfelelően leírni az adott földtani szerkezetet, ugyanis az ismeretlenek számának növelése a túlhatározottságot csökkenti. Az értekezésben az egységugrás függvények mellett bemutatjuk a hatványfüggvényekkel történő intervallum inverzió algoritmusát is.

A dolgozatban háromféle inverziós módszerrel foglalkozom, a mélységpontonkénti, az intervallum inverziós (homogén rétegek, illetve rétegben vertikálisan változó petrofizikai paraméterek mellett), valamint a rétegvastagságok meghatározására alkalmas intervallum inverziós eljárással. A következő alfejezetek e módszerek alapjait, majd erre építve a saját módszerfejlesztés keretében létrehozott új algoritmusokat mutatják be.

4.1 A MÉLYSÉGPONTONKÉNTI INVERZIÓS ALGORITMUS

A mélységpontonkénti inverziós módszerrel általában (3.2) adatvektorból (3.1) modellvektor elemeit határozzuk meg a (3.3)-(3.10) lokális válaszegyenletek ismeretében. Ebben az eljárásban a (2.3) függvénykapcsolatot mélységpontonként külön-külön értelmezett (lokális) válaszegyenletekkel írjuk le.

Tételezzük fel, hogy mélységpontonként azonos $k=1,2,\dots,N$ számú szelvényadat áll rendelkezésünkre. Ekkor a k -adik lokális adat számított értéke

$$\varphi_k = g_k(m_1, m_2, \dots, m_M), \quad (4.1)$$

mely a (3.1) modellvektor $i=1,2,\dots,M$ számú petrofizikai paraméterének a függvénye. Mivel a gyakorlatban $N > M$ feltételnek kell teljesülnie, ezért az inverz probléma túlhatározott. Az inverz feladatot linearizált és globális optimalizációs módszerekkel oldhatjuk meg, melyek közül sorra veszem az általam alkalmazott, ill. bevezetett új pontonkénti inverziós eljárásokat.

Linearizált inverziós módszerek közül a DLSQ eljárást (2.2.3 fejezet) alkalmaztam a globális inverziós módszerekkel történő összehasonlítás céljából, melynek pontonkénti inverziós változatát DLSQ-P algoritmusnak neveztem el.

1) A DLSQ-P algoritmus:

A lineáris inverzió keretében ismert kiindulási állapotból indítjuk az eljárást. Ekkor a (4.1) egyenletet felhasználva $\vec{d}^{(sz)} = \vec{\varphi}$ helyettesítéssel a DLSQ eljárás közvetlenül alkalmazható. A geofizikai gyakorlatban a linearizált optimalizáció során a minimalizálandó célfüggvények általában tartalmazzák a mérési adatok hibáját (TARANTOLA, 1987), mely a súlyozott inverziós módszerek logikáját követi. A geofizikai inverziós algoritmusok felépítésénél azonban létezik egy másféle megközelítés is. Képezzük (2.5) eltérésvektor helyett (2.8) relatív hibavektorból az inverz feladat célfüggvényét

$$E^{(DLSQ-P)} = \sum_{k=1}^N \left(\frac{d_k^{(m)} - d_k^{(sz)}}{d_k^{(m)}} \right)^2 \rightarrow \min, \quad (4.2)$$

ahol $d_k^{(m)}$, $d_k^{(sz)}$ a pontbeli k -adik mért és számított adat. E módszerrel a különböző elven mért karotázs adatok eltérő nagyságrendje célfüggvényre gyakorolt hatását korigáljuk, és az eltérésvektor komponenseket ugyanabba az értéktartományba kényszerítjük, továbbá dimenzió nélkülivé tesszük. Az adatok hibáját (2.15) modelltérbeli kovariancia mátrix számításánál vettem figyelembe a becsült paraméterek hibájának meghatározásánál.

A pontonkénti inverzióval becsült paraméterek pontosságát a 2.2.5. fejezetben bevezetett mennyiségek számításával jellemezhetjük. A relatív adattérbeli távolságot

$$D_d^{(mp)} = \frac{1}{P} \sum_{p=1}^P \left(\sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{d_{pk}^{(m)} - d_{pk}^{(sz)}}{d_{pk}^{(m)}} \right)^2} \right) \cdot 100 [\%] \quad (4.3)$$

skalárral P számú mélységpontot tartalmazó mélységintervallumra jellemző átlagértékként de-

finiáltam, ahol $d_{pk}^{(m)}$, $d_{pk}^{(sz)}$ a p-edik mélységpontbeli k-adik mért és számított adat. A modell-
térbeli távolság számtani középértéke az azonos nagyságrendű modellparaméterek miatt

$$D_m^{(mp)} = \frac{1}{P} \sum_{p=1}^P \left(\sqrt{\frac{1}{M} \sum_{i=1}^M (m_{pi}^{(b)} - m_{pi}^{(e)})^2} \right) \cdot 100[\%], \quad (4.4)$$

ahol $m_{pi}^{(b)}$, $m_{pi}^{(e)}$ a p-edik mélységpontbeli i-edik becült- illetve egzakt modellparaméter, és M
a pontbeli modellparaméterek száma.

A mélységpontenkénti inverziós eljárás továbbfejlesztését globális optimalizációs eljárá-
sok alkalmazásával valósítottam meg. Az új algoritmusok a 2.3 fejezetben bemutatott MSA és
FGA módszeren alapulnak, melyeket új célfüggvények bevezetésével módosítottam a pon-
tonkénti inverziós algoritmus felépítése során.

2) Az MMSA-P algoritmus:

A Metropolis Simulated Annealing algoritmus (2.3.1 fejezet) energiafüggvényének egy
általánosítását KIS (1998) vezette be. Ezt az elvet és (2.8) eltérésvektort egyesítve MMSA-P
(Módosított Metropolis Simulated Annealing - Pontonkénti) néven új pontonkénti inverziós
módszert fejlesztettem, mely az alábbi energiafüggvényt minimalizálja

$$E^{(MMSA-P)} = \sum_{k=1}^N \left| \frac{d_k^{(m)} - d_k^{(sz)}}{d_k^{(m)}} \right|^{\mu} + \lambda^2 \sum_{i=1}^M |m_i|^{\nu} \rightarrow \min, \quad (4.5)$$

ahol μ és ν értékeinek megfelelő megválasztásával (4.5) célfüggvény visszavezethető (2.19)
és (2.20) energiafüggvényekre. A λ csillapítási tényező bevezetésével a kevert határozottságú
inverz problémák globális optimalizációval is hatékonyan kezelhetők, és biztosítható ehhez a
gyors konvergencia sebesség. A módszer néhány speciális esetével SZABÓ (1999), illetve
DOBRÓKA és SZABÓ (2001) foglalkozott.

3) Az FGA-P algoritmus:

A globális optimalizációs GA módszerek (2.3.2 fejezet) közül hatékonysága miatt a valós
kódolású FGA eljárást választottam. Az inverzió előtt a modellparaméterek lehetséges értéké-
nek tartományát rögzítettem. Ez a mélyfúrési geofizikai inverzió esetén nem jelent hátrányos
megszorítást, hiszen a petrofizikai változókat megadott intervallumokban értelmezzük (pl.
 $0 \leq \text{POR} \leq 1$). Ezt követően a paramétertér aktuális részéből nagyszámú véletlen modellt gene-
ráltam. A közetfizikai korlátozó egyenletek így automatikusan teljesültek, azonban az anyag-
mérleg egyenletet külön beépítettem az algoritmusba. Az FGA-P (Valós kódolású Genetikus

Algoritmus - Pontonkénti) inverzió során a mért és a számított szelvényadatok eltérését a következő fitness-függvénnyel definiáltam (SZABÓ, 2001)

$$F^{(FGA-P)} = -\sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{d_k^{(m)} - d_k^{(sz)}}{d_k^{(m)}} \right)^2} = -D_d \rightarrow \max. \quad (4.6)$$

E célfüggvény globális maximumhelyét – (2.11) adattérbeli távolság minimumhelyét – kerestem minden mélységpontban a modellparaméterek meghatározása céljából.

4.2 AZ INTERVALLUM INVERZIÓS ALGORITMUS

Az intervallum inverziós eljáráshoz intervallumon értelmezett válaszgyenleteket szükséges definiálnunk, mellyel a (4.1) lokális válaszfüggvényt kiterjeszthetjük a teljes invertálandó mélységintervallumra. Ennek keretében először a petrofizikai paramétereket, mint a mélység függvényeit írjuk fel. Az intervallumon értelmezett (mélységfüggő) válaszgyenletből származtatott elvi szelvényadatok DOBRÓKA (1995) alapján

$$\varphi_k(z) = g_k(m_1(z), m_2(z), \dots, m_M(z)), \quad (4.7)$$

ahol $\varphi_k(z)$ az k-adik számított szelvényadat, $m_i(z)$ az i-edik közetfizikai paraméter z mélység-koordinátához tartozó értéke. A fenti válaszgyenletben a modellparaméterek a mélység folytonos függvényeiként jelennek meg, melyek pontbeli értékét diszkrétizálással határozzuk meg. A mélységfüggő válaszgyenletek paramétereinek diszkrétizálására sorfejtési eljárást alkalmaztam.

A sorfejtéses intervallum inverziós eljárás keretében ismert bázisfüggvény-rendszerek segítségével diszkrétizáljuk a petrofizikai paramétereket. A bázisfüggvények típusa szabadon megválasztható, és az adott földtani szituációhoz illeszthető. Tekintsük az (4.7) mélységfüggő válaszgyenletben szereplő i-edik rétegjellemző paraméter általános sorfejtett alakját

$$m_i(z) = \sum_{q=1}^{Q_i} B_q^{(i)} \psi_q(z), \quad (4.8)$$

ahol $B_q^{(i)}$ jelenti az i-edik petrofizikai paraméter q-adik sorfejtési együtthatóját (Q_i a sorfejtéshez szükséges tagok száma), ψ_q pedig a q-adik ismert mélységfüggő bázisfüggvényt jelöli.

A legegyszerűbb esetben, a rétegenként homogén modell leírásában (a legkevesebb ismeretlennel) a bázisfüggvényeket egységugrás függvények kombinációjával állíthatjuk elő

$$\psi_q(z) = u(z - Z_{q-1}) - u(z - Z_q), \quad (4.9)$$

ahol Z_q, Z_{q-1} a q-adik és (q-1)-edik réteghatár mélységkoordinátája, Ψ_q a q-adik mélységfüggő bázisfüggvény. Mivel $\psi_q(z) = 1$, ha $Z_{q-1} < z < Z_q$, egyébként zérus, ezért a (4.8) sorfejtésben

szereplő $B_q^{(i)}$ sorfejtési együttható megegyezik az i -edik modellparaméter q -adik rétegbeli értékével. Ezzel a sorfejtés teljes mélységintervallumán egyszerre előállítható $i=1, \dots, M$ számú modellparaméter rétegenként konstans értéke. A petrofizikai paraméterek gyakran a rétegen belül is változnak a mélység függvényében. E tulajdonságot a lineáris változástól egészen a bonyolultabb függvénykapcsolatokig (hatványfüggvények, Chebishev-, Legendre-polinomok stb.) szükséges pontossággal meg tudjuk közelíteni. A q -adik bázisfüggvény hatványfüggvény szerinti közelítéssel

$$\psi_q(z) = z^{q-1}$$

szerint vehető fel. Végül, ha a rétegsor homogén és inhomogén rétegekből épül fel, akkor a fenti függvények szuperpozíciójával is élhetünk.

Az intervallum inverziós eljárás lényeges eleme, hogy a (4.8) sorfejtéssel a (4.7) mélységfüggő válaszgyenlet felírható

$$\varphi^{(k)}(z) = g^{(k)}(B_1^{(1)}, B_2^{(1)}, \dots, B_{Q_1}^{(1)}, B_1^{(2)}, B_2^{(2)}, \dots, B_{Q_2}^{(2)}, \dots, B_1^{(M)}, B_2^{(M)}, \dots, B_{Q_M}^{(M)}, z), \quad (4.10)$$

ahol a független változók a közetfizikai ismeretlenek helyett a B sorfejtési együtthatók. Ez azt jelenti, hogy az inverz feladat ismeretlenjeit a $B_q^{(i)}$ sorfejtési együtthatók képezik, melyek

száma a teljes intervallumon $M^* = \sum_{i=1}^M Q_i$, ezzel az inverziós ismeretleneket tartalmazó mo-

dellvektor elemei, $i=1, \dots, M$ számú petrofizikai paraméter esetén

$$\vec{m} = [B_1^{(1)}, B_2^{(1)}, \dots, B_{Q_1}^{(1)}, B_1^{(2)}, B_2^{(2)}, \dots, B_{Q_2}^{(2)}, \dots, B_1^{(M)}, B_2^{(M)}, \dots, B_{Q_M}^{(M)}]^T. \quad (4.11)$$

A mérési adatrendszerbe az intervallumon gyűjtött összes szelvényadat beletartozik. Ha $k=1, 2, \dots, K$ számú szelvényt mértünk, és n_k jelöli a k -ik szelvény mélységpontjainak számát,

akkor a rendelkezésre álló összes adatszám $N^* = \sum_{k=1}^K n_k$. A mintavételi köz általában 0.1 m, a

szelvényhossz ~50-5000 m, ezért az intervallum inverziós probléma $N^* > M^*$ esetén nagymértékben túlhatározott. Az inverz feladat megoldásához foglaljuk a mért adatokat egyetlen vektorba és képezzük (4.11)-hez hasonló módon a számított adatvektort

$$\vec{d}^{(m)} = [d_1^{(1)}, d_2^{(1)}, \dots, d_{n_1}^{(1)}, d_1^{(2)}, d_2^{(2)}, \dots, d_{n_2}^{(2)}, \dots, d_1^{(K)}, d_2^{(K)}, \dots, d_{n_K}^{(K)}]^T, \quad (4.12)$$

$$\vec{\varphi} = [\varphi_1^{(1)}, \varphi_2^{(1)}, \dots, \varphi_{n_1}^{(1)}, \varphi_1^{(2)}, \varphi_2^{(2)}, \dots, \varphi_{n_2}^{(2)}, \dots, \varphi_1^{(K)}, \varphi_2^{(K)}, \dots, \varphi_{n_K}^{(K)}]^T, \quad (4.13)$$

ahol $\vec{d}^{(m)}$ az egyesített mért adatvektor, és $\vec{\varphi}$ az elméleti adatok vektora az intervallum inverziós eljárásban.

Linearizált inverziós módszerek közül a DLSQ és LAD (ld 2.2.3 és 2.2.4 fejezet) eljárást alkalmaztam, melyekkel DLSQ-I és LAD-I néven mélyfúrési geofizikai intervallum inverziós eljárásokat fejlesztettem karotázs szelvényadatok kiértékelése céljából.

1) A DLSQ-I algoritmus:

A linearizált intervallum inverziós feladat célfüggvényét a pontonkénti inverzióhoz hasonlóan definiáltam, azzal a különbséggel, hogy ebben az esetben a teljes adatrendszeret integráltam a minimalizálandó függvényben. Ha P az intervallum mélységpontjainak a száma, és N a pontbeli adatszám, akkor a célfüggvény

$$E^{(DLSQ-I)} = \sum_{p=1}^P \sum_{k=1}^N \left(\frac{d_{pk}^{(m)} - d_{pk}^{(sz)}}{d_{pk}^{(m)}} \right)^2 \rightarrow \min \quad (4.14)$$

ahol $d_{pk}^{(m)}, d_{pk}^{(sz)}$ a p -edik pontbeli k -adik mért és számított adat. Felhasználva (2.3) és (4.13) kifejezéseket, $\vec{d}^{(sz)} = \vec{\varphi}$ helyettesítéssel a linearizált inverz feladat 2.2.3 fejezetben leírt gondolatmenet szerint megoldható az ismeretlen sorfejtési együtthatókra nézve. Ezután a becült sorfejtési együtthatókkal (4.8) alapján előállíthatjuk a kérdéses petrofizikai paramétereket.

A becült paraméterek pontosságát megadó (4.3) és (4.4) formulák az intervallum inverzió esetében módosításra szorulnak. Mivel az eljárás a teljes adatrendszerből szimultán számítja valamennyi rétegjellemzőt (minden mélységpontban $k=1,2,\dots,K$ számú szelvényadat esetén) a relatív adattérbeli távolság a következőképpen számítható

$$D_d^{(int)} = \sqrt{\frac{1}{P \cdot K} \sum_{p=1}^P \sum_{k=1}^K \left(\frac{d_{pk}^{(m)} - d_{pk}^{(sz)}}{d_{pk}^{(m)}} \right)^2} \cdot 100 [\%], \quad (4.15)$$

ahol $d_{pk}^{(m)}, d_{pk}^{(sz)}$ a p -edik mélységpontbeli k -adik mért és számított szelvényadat. A modelltérbeli távolság R számú réteg (fix rétegvastagság értékek mellett), valamint rétegenként homogén modell szerinti sorfejtés esetén az azonos nagyságrendű modellparaméterek miatt

$$D_m^{(int)} = \sqrt{\frac{1}{R \cdot M} \sum_{r=1}^R \sum_{i=1}^M (m_{ri}^{(b)} - m_{ri}^{(e)})^2} \cdot 100 [\%], \quad (4.16)$$

ahol $m_{ri}^{(b)}, m_{ri}^{(e)}$ az r -edik rétegbeli i -edik becült és egzakt modellparaméter, M a petrofizikai paraméterek száma a rétegben. A becült paraméterek hibáját (2.16), megbízhatóságukat

$$S = \sqrt{\frac{1}{M(M-1)} \sum_{i=1}^M \sum_{j=1}^M (corr(\vec{m})_{ij} - \delta_{ij})^2}. \quad (4.17)$$

korrelációs átlaggal (Dobróka et al., 1991) jellemeztem (2.17) együtthatókat felhasználva.

2) A LAD-I algoritmus:

A legkisebb abszolút értékek elvén alapuló intervallum inverziós algoritmust LAD-I eljárásnak neveztem el. Ekkor (4.14) célfüggvény a következőképpen módosul

$$E^{(LAD-I)} = \sum_{p=1}^P \sum_{k=1}^N \left| \frac{d_{pk}^{(m)} - d_{pk}^{(sz)}}{d_{pk}^{(m)}} \right| \rightarrow \min. \quad (4.18)$$

A LAD módszernél alkalmazott (2.10) súlymátrixot az adattérben normáltam

$$W_{kk} = \left(d_k^{(m)} - \sum_{i=1}^M G_{ki} m_i \right) / d_k^{(m)} \Big|^{-1}, \quad (4.19)$$

ahol W_{kk} a súlymátrix fődiagonálisának k-adik eleme.

A LAD-I módszer esetén a (4.18) képlet alapján a relatív adattérbeli, valamint modelltérbeli távolság R számú réteg esetén (4.15) és (4.16)-hoz hasonlóan

$$D_d^{(int)} = \frac{1}{P \cdot N} \sum_{p=1}^P \sum_{k=1}^K \left| \frac{d_{pk}^{(m)} - d_{pk}^{(sz)}}{d_{pk}^{(m)}} \right| \cdot 100 [\%], \quad (4.20)$$

$$D_m^{(int)} = \frac{1}{R \cdot M} \sum_{r=1}^R \sum_{i=1}^M |m_{ri}^{(b)} - m_{ri}^{(e)}| \cdot 100 [\%]. \quad (4.21)$$

A globális optimalizációs módszerek felhasználásával MMSA-I és FGA-I néven új mélyfúrési geofizikai intervallum inverziós eljárásokat fejlesztettem az ismeretlen petrofizikai paraméterek számítása céljából.

3) Az MMSA-I algoritmus:

Az 4.1 fejezetben bemutatott (4.5) általánosított energiafüggvényen alapuló pontonkénti inverziós eljárás kiterjeszhető a teljes adatrendszer intervallum inverziójára. Az MMSA-I (Módosított Metropolis Simulated Annealing - Intervallum) algoritmus számára az

$$E^{(MMSA-I)} = \sum_{p=1}^P \left(\sum_{k=1}^N \left| \frac{d_k^{(m)} - d_k^{(sz)}}{d_k^{(m)}} \right|^\mu + \lambda^2 \sum_{w=1}^M |m_w|^\nu \right) \rightarrow \min \quad (4.22)$$

energiafüggvényt vezettem be, ahol P az együttesen invertált adatok intervallumába eső mélységpontok számát jelöli. Ez az új eljárás μ és ν megfelelő megválasztásával visszavezethető a klasszikus Metropolis algoritmusra, továbbá outlier-ekre kevésbé érzékeny (rezisztens) intervallum inverzió hajtható vele végre. Az algoritmus feltételes szélsőérték keresést hajt végre, amely abból áll, hogy a (3.11) anyagmérleg egyenletet nem kielégítő modellekhez $P=0$ elfogadási valószínűséget rendel. A hűtést (2.18) szerint végeztem. A módszer speciális alkalmazásaival DOBRÓKA és SZABÓ (2002), illetve SZABÓ (2004) foglalkozott.

4) Az FGA-I algoritmus:

A valós kódolású Genetikus Algoritmust implementálva új globális intervallum inverziós eljárást fejlesztettem FGA-I néven (SZABÓ, 2003). A modellparaméterek keresési intervallumát az algoritmus inicializálása során rögzítettem, a közetfizikai korlátozó egyenletek teljesülését figyelembe véve. Emellett az anyagmérleg egyenletet is beépítettem az algoritmusba a kiindulási populáció egyedeinek generálása során.

Az FGA-I inverzió során a petrofizikai paraméterek meghatározása céljából (4.6)-hoz hasonló módon választottam meg az intervallum inverziós módszer célfüggvényét. A fitness függvényt ezúttal az aktuális populáció valamely egyede (modellje) alapján számított, a teljes, intervallum inverzióba bevont adatrendszert jellemző (4.15) adattérbeli távolság -1-szeres értékével definiáltam

$$F^{(FGA-I)} = -\sqrt{\frac{1}{P \cdot N} \sum_{p=1}^P \sum_{k=1}^N \left(\frac{d_{pk}^{(m)} - d_{pk}^{(sz)}}{d_{pk}^{(m)}} \right)^2} = -D_d^{(int)} \rightarrow \max, \quad (4.23)$$

ahol P az invertált intervallumon lévő mélységpontok száma, N a pontbeli adatszám. A módszerrel SZABÓ ÉS DOBRÓKA (2001) foglalkozott.

A globális optimalizáción alapuló intervallum inverziós módszerek konvergenciája igen lassú (ld. pl. 14. ábra, ahol a q=1000-10000 lépés között igen kevés változást fogad el az eljárás). E probléma kezelésére új intervallum inverziós algoritmust fejlesztettem ki, mely a globális optimalizációt kombinálja a linearizált módszerekkel SZABÓ (2003).

5) Az FGA+DLSQ-I algoritmus:

Az FGA+DLSQ-I kombinált intervallum inverziós módszer keretében először a startmodell megválasztásától nagymértékben független globális FGA-I algoritmussal megközelítjük az (4.23) fitness függvény abszolút maximumhelyét (adattérbeli távolság abszolút minimumát), ezután a linearizált DLSQ-I módszerrel folytatva az eljárást, meghatározzuk a modellvektor elemeit. E kombinált inverziós módszerrel javítható a globális optimalizáció két kevésbé előnyös tulajdonsága. Egyrészt megvalósítható a konvergencia nagymértékű gyorsítása, mivel a globális inverzió lassú keresését egy idő után (a megfelelő ponton) felváltja a gyors lokális gradiens-alapú linearizált optimalizáció. Másfelől a linearizált inverzió révén a módszer lehetővé teszi a petrofizikai paraméterek hibájának és megbízhatóságának számítását.

Az intervallum inverziós módszer lehetőséget nyújt a rétegenként homogén modellnél sokkal összetettebb modellek, pl. nagyobb mélységintervallumon, vagy akár a rétegben belül is

vertikális változást mutató közetfizikai paraméterek leírására is. Az új FGA+DLSQ-I algorit-mussal rétegben vertikálisan változó petrofizikai paraméterek meghatározását végeztem el. Ennek keretében a (4.8) sorfejtés számára hatványfüggvényeket választottam bázisfüggvény-ként. Azt az esetet vizsgáltam, amikor az r-edik réteg inhomogén, mely homogén rétegek kö-zé ágyazva jelenik meg. Ekkor az i-edik petrofizikai paraméter sorfejtett alakja

$$m_i(z) = \sum_{q=1}^{Q(i)} m_q^{(i)} [u(z - Z_{q-1}) - u(z - Z_q)] + \sum_{l=1}^{L(i)} B_l^{(i)} (z - Z_{l-1})^{l-1}, \quad (4.24)$$

ahol $m_i(z)$ i-edik petrofizikai jellemző z-mélységpontbeli értéke, Z_q a q-adik réteghatár mély-ség-koordinátája, és $B_q^{(i)}$ az i-edik modellparaméter q-adik sorfejtési együtthatója (Q illetve L a sorfejtési együtthatók szükséges száma). A sorfejtésben szereplő együtthatókat az intervallum inverzió modellvektorába vettem fel.

A gyakorlatban a mélységadatokból csak nagyságrendileg lehetséges (4.24) sorfejtésben szereplő $B_q^{(i)}$ együtthatókat megbecsülni. A rosszul megválasztott együtthatók a startmodel-eknek a megoldástól igen nagy relatív adattérbeli és modelltérbeli távolságát is eredményez-heti. Ekkor a megfelelő startmodell hiányában a linearizált módszerek nagy valószínűséggel a célfüggvény lokális minimumban stabilizálódnak. E probléma kezelését a globális és a linearizált optimalizációs módszerek együttes, hatékony alkalmazásával oldottam meg.

Az eredmények minőségi ellenőrzése során a becsült modell relatív adattérbeli távolságát (4.3) alapján, a relatív modelltérbeli távolságot pedig

$$D_m = \frac{1}{P} \sum_{p=1}^P \left(\sqrt{\frac{1}{M} \sum_{i=1}^M \left(\frac{m_{pi}^{(b)} - m_{pi}^{(e)}}{m_{pi}^{(e)}} \right)^2} \right) \cdot 100[\%] \quad (4.25)$$

szerint számítottam, a különböző nagyságrendű sorfejtési együtthatók miatt.

4.3 A RÉTEGHATÁR-MEGHATÁROZÁS INVERZIÓS ALGORITMUSA

Az intervallum inverziós probléma jelentősen túlhatározott, mivel az intervallumon mért adatok száma több nagyságrenddel is meghaladhatja a rétegjellemző petrofizikai paraméterek számát. E keretek között a pontonkénti inverzió problémakörében ismertnek tekintett réteg-vastagságok ismeretlen paraméterként kezelhetők, és a réteghatárok mélység-koordinátái meghatározhatók. Mivel a rétegvastagságokkal az ismeretlen modellvektor elemeinek a száma csak kismértékben növekszik, így az inverz feladat jelentősen túlhatározott marad. Az auto-matikus (inverzió belüli) réteghatár-meghatározás a hagyományos pontonként inverzióval nem hajtható végre, ezzel szemben az intervallum inverzió keretein belül megvalósítható.

Vegyük fel (4.8) sorfejtésben szereplő bázisfüggvények paraméterei közé R számú réteg Z_1, \dots, Z_R réteghatár-koordinátáit

$$m_i(z) = \sum_{q=1}^{K_i} B_q^{(i)} \psi_q(z, Z_1, Z_2, \dots, Z_R),$$

mellyel

$$\varphi^{(s)}(z) = g^{(s)}(z, B_1^{(1)}, \dots, B_{K_1}^{(1)}, B_1^{(2)}, \dots, B_{K_2}^{(2)}, \dots, B_1^{(M)}, \dots, B_{K_M}^{(M)}, Z_1, Z_2, \dots, Z_R) \quad (4.26)$$

mélységfüggő válaszgyenletet kapjuk, továbbá

$$\vec{m} = [B_1^{(1)}, \dots, B_{K_1}^{(1)}, B_1^{(2)}, \dots, B_{K_2}^{(2)}, \dots, B_1^{(M)}, \dots, B_{K_M}^{(M)}, H_1, H_2, \dots, H_R]^T$$

modellvektort, melynek ismeretlenjei között megjelennek a H_1, H_2, \dots, H_R rétegvastagságok. E mennyiségek az alsó és a felső réteghatár mélységkoordinátái ismeretében könnyen meghatározhatóak. Képezzük az s -edik szelvény elvi adatait (4.26) alapján, majd képezzük a mért és számított adatok vektorát (4.12)-(4.13)-hoz analóg módon. Ezután $\vec{d}^{(sz)} = \vec{\varphi}$ helyettesítéssel elméletileg bármely linearizált és globális optimalizációs módszer alkalmazható. Az automatikus rétegvastagság meghatározást megvalósító intervallum inverziós eljárás ismeretlenjeinek a száma ekkor M^* (ld. 4.2 fejezet)-ről $M^{**} = M^* + R$ ismeretlenre nő, viszont $N^* > M^{**}$ mellett a probléma továbbra is nagymértékben túlhatározott.

Az automatikus rétegvastagság meghatározást globális optimalizációs eljárások alkalmazásával valósítottam meg, mivel linearizált optimalizáció során a rétegvastagságok-szerinti deriváltak (relatív nagy szomszédos mélységpont távolság melletti) közelítő számítása miatt az inverziós eljárás numerikus stabilitási problémákkal küzd. Az új globális intervallum inverziós algoritmusok a 2.3 fejezetben bemutatott MSA és FGA módszeren alapulnak.

1) Az MMSA-H algoritmus:

A módosított SA módszerrel MMSA-H néven új intervallum inverziós algoritmust fejlesztettem, mely a (4.22) energiafüggvényt minimalizálja. Az MSA-H módszernél korlátozó egyenletek bevonásával érhetjük el, hogy a modellparaméterek ne lépjenek ki lehetséges értékeik intervallumából, az anyagmérleg egyenlet alkalmazásával pedig az elfogadott modellek felülbíráhatók.

Az inverziós eredmények relatív adattérbeli távolságát (4.15) és (4.20) szerint számítottam, a modell-távolságokat pedig R számú homogén rétegből álló modell esetén

$$D_m^{(int)} = \sqrt{\frac{1}{R \cdot M} \sum_{r=1}^R \sum_{i=1}^M \left(\frac{m_{ri}^{(b)} - m_{ri}^{(e)}}{m_{ri}^{(m)}} \right)^2} \cdot 100[\%], \quad (4.27)$$

mivel a rétegvastagságok a térfogatjellemező petrofizikai paraméterek értékeihez képest eltérő nagyságrendbe esnek. E formula $\mu=2$ energiafüggvény paraméterek mellett érvényes, az

$$D_m^{(int)} = \frac{1}{R \cdot M} \sum_{r=1}^R \sum_{i=1}^M \left| \frac{m_{ri}^{(b)} - m_{ri}^{(e)}}{m_{ri}^{(e)}} \right| \cdot 100[\%], \quad (4.28)$$

pedig $\mu=1$ esetre alkalmazható. A módszert SZABÓ (2004) publikálta.

2) Az FGA-H algoritmus:

A Valós Kódolású Genetikus Algoritmussal FGA-H néven új intervallum inverziós algoritmust fejlesztettem, mely a (4.23) fitness függvényt maximalizálja (SZABÓ, 2003). Az FGA-H algoritmus esetén a modellparaméterek (beleértve a rétegvastagságokat) keresési tartományát inverzióon kívül szabályozhatjuk. A becült paraméterek minőségellenőrzését (4.15) relatív adattérbeli-, valamint (4.27) relatív modelltérbeli távolsággal végeztem.

4.4 AZ INVERZIÓS MÓDSZERFEJLESZTÉS ÖSSZEFOGLALÁSA

Ebben a fejezetben bemutattam a hagyományos mélyfúrási geofizikai mélységpontonként végzett inverziós eljárást, majd újabb algoritmusokat vezettem be, melyek részben a pontonkénti, részben az ún. intervallum inverzió családjába tartoznak.

Elsőként az (iparban alkalmazott) linearizált optimalizáción alapuló mélyfúrási geofizikai inverziós kiértékelés pontosságának javítására globális optimalizációs inverziós algoritmusokat fejlesztettem. A Metropolis Simulated Annealing módszert módosítottam új energiafüggvény bevezetésével, amely az MSA módszernél gyorsabb konvergenciát biztosít. Az eljárás az MMSA-P nevet kapta. Emellett kifejlesztettem a Valós Kódolású Genetikus Algoritmuson alapuló pontonkénti inverziós eljárást, az FGA-P algoritmust, mely szintén globális szélsőérték keresést hajt végre.

Második lépésben új intervallum inverziós módszereket vezettem be. Először ismert rétegvastagságok mellett, mélyfúrási geofizikai adatok kiértékelése céljából új, linearizált és globális optimalizáción alapuló inverziós eljárásokat fejlesztettem. E módszerekkel különböző földtani modellek esetén növelhető a paraméterbecslés pontossága és megbízhatósága mélységpontonkénti inverzióhoz képest. Jelen fejlesztés négy módszert foglal magába (DLSQ-I, a LAD-I, az MMSA-I és az FGA-I), melyeket először rétegenként homogén földtani modell petrofizikai paramétereit határozhatjuk meg.

Ezután az intervallum inverzió keretein belül a rétegvastagságokat is inverziós ismeretlenek tekintettem. Mélyfúrási geofizikai adatokból petrofizikai paraméterek és réteghatár-

koordináták szimultán meghatározásra alkalmas új globális optimalizáción alapuló intervallum inverziós algoritmusokat (MMSA-H, FGA-H) fejlesztettem.

A globális optimalizációs módszerek futási idejének csökkentése és hatékonyságának növelése céljából, globális és linearizált optimalizáción alapuló kombinált intervallum inverziós módszert fejlesztettem ki. Az FGA-DLSQ-I kombinált inverziós algoritmussal a globális optimalizációs módszer konvergencia-sebességét növelhetjük, valamint a paramétertérbeli kovariancia és korrelációs mátrix ismeretében a becsült paraméterek hibájának és megbízhatóságának egyetlen futtatásból történő számítását is megvalósíthatjuk, melyre a hagyományos globális optimalizációs módszerek csak statisztikailag elegendő (nagy) számú futtatás után kínálnak csak lehetőséget.

Végül az intervallum inverzió keretein belül olyan eljárást fejlesztettem ki, mely homogén rétegek mellett tetszőleges mélységintervallumon vertikálisan változó petrofizikai paraméterek meghatározását teszi lehetővé egyetlen inverziós eljárásban. Erre hatványfüggvény szerinti sorfejtést alkalmaztam.

5. SZINETIKUS ADATOK MÉLYSÉGPONTONKÉNTI INVERZIÓJA

E fejezetben a mélységpontonkénti inverziós eljárást zajjal terhelt szintetikus szelvények kiértékelése során teszteltem. A pontonkénti inverziót ismert petrofizikai modellből számított kvázi mért adatrendszer mellett vizsgáltam, melyből kvantitatív információkat kaptam a linearizált, valamint globális optimalizáción alapuló inverziós algoritmusok pontosságára és stabilitására vonatkozólag. E mellett az optimalizáció gyakran vizsgált kérdéseivel, az algoritmusok lépésszámával, időigényével is foglalkoztam.

5.1 SZINETIKUS ADATOK LINEARIZÁLT MÉLYSÉGPONTONKÉNTI INVERZIÓJA

Ebben a részben a DLSQ módszerrel (ld. 2.2 fejezet) végeztem inverziós vizsgálatokat, ahol a becsült paraméterek jóságát a (4.3) relatív adattérbeli- és (4.4) modelltérbeli távolsággal, illetve (2.16) becslési hibával jellemeztem.

5.1.1 Szintetikus adatok generálása

Az alkalmazott elméleti inverziós modell egy négyréteges üledékes rétegösszlet, melyben a porózus homokrétegeket különböző mértékben shale-agyag szennyezi. A rétegtartalom víz, illetve az első és harmadik rétegben a pórusrésben szénhidrogén is található. A modell paramétereit az 1. táblázat tartalmazza, ahol H [m] a rétegvastagság, és a többi petrofizikai paramétert (3.1) modellvektor elemei képezik.

H	POR	SX0	SW	VSH	VSD
6.0	0.2	0.8	0.4	0.3	0.5
2.0	0.1	1.0	1.0	0.8	0.1
8.0	0.3	0.8	0.3	0.1	0.6
4.0	0.1	1.0	1.0	0.6	0.3

1. táblázat

MODELL-1 négyréteges inverziós célmodell

MODELL-1 paramétereit alapján (3.3)-(3.9) válaszegyenletek felhasználásával $dz=0.1m$ mintavételi közzel szintetikus szelvényadatokat generáltam (a szelvénykonstansok aktuális értékei a 4. mellékletben található). A szintetikus szelvényekhez további hibát adva az inverziós vizsgálatok számára kétféle bemenő adatrendszert képeztem:

- (I) Gauss-eloszlásból származó 5 %-os zajjal terhelt (ld 5. melléklet fekete görbék),
- (II) Gauss-eloszlásból származó 5 %-os zajjal, valamint az adatok 1/5-e további 25 %-os kiugró hibával terhelt (ld. 5. melléklet szürke görbék).

5.1.2 Gauss-zajjal terhelt adatok inverziója DLSQ-P módszerrel

Az (I) adatrendszer linearizált mélységpontenkénti inverzióját a legkisebb négyzetek módszerén alapuló DLSQ-P módszerrel végeztem. Mivel MODEL-1 (ld. 1. táblázat) esetén pontonként $M=5$ ismeretlennel szemben $N=7$ szelvényadat áll rendelkezésre, ezért az inverz feladat kismértékben túlhatározott volt. A startmodellt az ismert modellhez képest (4.4) alapján $D_{m,0}=21$ %-os modelltérbeli távolsággal vettem fel, amihez (4.3) szerint $D_{d,0}=120$ %-os relatív adattérbeli távolság tartozott.

A futtatások során a hagyományos LSQ eljárással végzett inverzió a modellparaméterek számítására alkalmatlannak bizonyult, mivel a mélységpontok túlnyomó részében (2.7) egyenletben lévő $\underline{G}^T \underline{G}$ mátrix kondíciószáma $\kappa \sim 10^{17}$ volt. Ezért a csillapított legkisebb négyzetek elvének (DLSQ) megfelelően, a mátrix főátlóbeli elemeihez $\varepsilon^2=15$ tapasztalati számot adtam, melyet az iterációs folyamat során lépésenként ezen érték 27 %-ára csökkentettem. A regularizációs tényező értéke az utolsó iterációs lépésben 10^{-11} nagyságrendű volt, ezért az általa okozott hiba a megoldásban elhanyagolható. A módszer numerikusan stabilizálta az algoritmust, és konvergens megoldást állított elő. Az inverzió során a (2.8)-ban szereplő \underline{G} mátrixot numerikus deriválással számítottam, ahol a differenciahányadosban szereplő modellparamétereket rendre $h=0.001$ értékkel növeltem meg. A DLSQ-P eljárás átlagosan már az 5-6. iterációs lépésben konvergensen bizonyult, majd a $q=10$ lépés felett beállt az optimumra. A maximális iterációs lépésszámot mélységpontonként $q_{\max}=20$ -nak választottam, mellyel a teljes szelvényhossznak megfelelően a futási idő $t \sim 5$ perc volt.

Az inverzió eredményeként, az 5 %-os Gauss-zajjal terhelt szintetikus adatok inverziója az ismert modelltől $D_d=5.79$ %-os átlagos relatív adattérbeli, ill. $D_m=2.28$ %-os átlagos modelltérbeli távolsággal jellemezhető paramétereket eredményezett (ld. 2. táblázat).


(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
120.02 %	21.10 %	5.79 %	2.28 %	00:04:53

2. táblázat

Az (I) 5 %-os Gauss-zajjal terhelt adatrendszer
DLSQ-P inverziós eredményei

Az inverziós eredmények szelvényeit az 1. ábra mutatja. A bal oldali ábrán a becsült porozitás, agyag és homoktartalom, jobb oldalon a víztelítettség szelvényeket láthatjuk. Ez utóbbiakból, további két szelvény is képezhető. Az SCHM= SX0-SW értékek a mozgásképes szénhidrogén-, és az SCHR=1-SX0 a redukálhatatlan szénhidrogén-telítettségre adnak infor-

mációt a porózus és permeábilis rétegekben (KISS és FERENCZY, 1993). A szelvényeket MODELL-1 paramétereivel összehasonlítva, szembetűnő, hogy meglehetősen erősen szórnak a rétegen belül a közetfizikai paraméterek értékei. Pl. tekintsük a porozitás hibaszelvényét (ld. 2. ábra), ahol a lila színnel kitöltött hibasávon belül helyezkedik el a valódi porozitás érték (a porozitásra jellemző minden mélységpontban (2.16) alapján számított szórását $SDEV_{POR}$ -al jelöltem). A DLSQ-P eljárás konvergensenek bizonyult, azonban további startmodellekkel végzett futtatások azt mutatták, hogy az egzakt modelltől körülbelül $D_m=30$ %-os modelltérbeli távolság felett az eljárás több mélységpontban is divergens volt.




1. ábra

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer DLSQ-P inverziójával nyert petrofizikai paraméterek szelvényei

5.1.3 Kiugró adatok inverziója DLSQ-P módszerrel

Az (I) adatrendszer egy átlagos karotázs mérést szimulál, azonban a gyakorlatban előfordul, hogy méréseinket lokálisan durva (mérési) hibák terhelik. A (II) adatrendszer kvázi mért kiugró adatokat tartalmaz, melynek pontonkénti inverzióját 5.1.2 fejezethez hasonló módon végeztem. Mivel pontonkénti inverzió esetén a legkisebb abszolút értékek (LAD) módszerének alkalmazása nem jelent előnyt a DLSQ módszerrel szemben, ezért a vizsgálatokat elegendőnek találtam az utóbbi módszerrel elvégezni.

Ebben az esetben a maximális iterációs lépésszámot pontonként $q_{max}=20$ -nak választottam, mellyel a futási idő 4 és fél perc volt. A DLSQ-P inverziós eljárással becsült petrofizikai paraméterek MODELL-1 paramétereit $D_d=14.56$ %-os átlagos relatív adattérbeli-, illetve $D_m=4.42$ %-os átlagos modelltérbeli távolsággal közelítették meg. A becsült petrofizikai paraméterek szelvényeit a 3. ábra szemlélteti.




2. ábra

Az 5 %-os Gauss-zajjal terhelt (I) és az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer DLSQ-P inverziójával nyert porozitás szelvény és hibája

(II) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
121.74 %	21.10 %	14.56 %	4.42 %	00:04:36

3. táblázat

Az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer DLSQ-P inverziós eredményei



3. ábra

Az 5 % Gauss + kiugró zajjal terhelt (II) adatrendszer DLSQ-P inverziójával nyert petrofizikai paraméterek szelvényei

A 2. és 3. ábrán látható, hogy nagy bizonytalanság terheli a becsült közetfizikai paramétereket, mely a szénhidrogén-telítettség értékeknél különösen szembetűnő. A fenti eljárás konvergens maradt a kiugró zaj ellenére is, azonban a 3. táblázatbeli $D_{m,0}$ -tól nagyobb kezdeti

modelltávolsággal jellemezhető startmodellekkel végzett futtatások esetén divergens megoldások jelentkeztek egyes mélységpontokban.

5.2 SZINTETIKUS ADATOK GLOBÁLIS MÉLYSÉGPONTONKÉNTI INVERZIÓJA

A linearizált inverziós módszerek után, a 2.3 fejezetben bemutatott globális optimalizációs eljárásokon alapuló mélységpontenkénti inverziós módszereket vizsgáltam. Az (I) és (II) adatrendszer pontenkénti inverzióját a Metropolis Simulated Annealing (MSA) módszernek egy általam továbbfejlesztett változatával (MMSA), továbbá a valós kódolású Genetikus Algoritmussal (FGA) végeztem.

5.2.1 Inverziós vizsgálatok a Simulated Annealing módszerrel

A mélységpontenkénti inverziós vizsgálatok során a Metropolis Simulated Annealing eljáráson alapuló, valamint a (4.5) energiafüggvényt minimalizáló MMSA-P algoritmust alkalmaztam. A globális optimalizáció hatékonyságának vizsgálatát, az inverziót megelőző startmodell-függetlenségi vizsgálatokkal mutatom meg. Erre a célra MODELL-1 paramétereit alapján három adatrendszert generáltam, majd azokkal végzett inverziós futtatások bizonyítják, hogy a globális inverzió a linearizált módszerekhez képest távolabbi startmodellek megválasztása esetén is konvergens megoldást ad.

5.2.1.1 Startmodell-függetlenségi vizsgálatok

A globális optimalizációs módszerek előnye abban nyilvánul meg, hogy az optimumkeresés közben hatékonyan elkerüli a célfüggvény lokális minimumhelyeit, és a megoldást annak abszolút minimumához rendeli. Ennek vizsgálatára MODELL-1 paramétereit alapján három adatrendszert generáltam, különböző mértékű hibával terhelve.

A startmodell-függetlenségi vizsgálatok számára (az eddig alkalmazott két adatrendszer sorszámát folytatva) a következő adatrendszereket generáltam:

- (III) Hibátlan (0 %-os hibával terhelt) adatrendszer ,
- (IV) Gauss-eloszlásból származó 2 %-os hibával terhelt adatrendszer,
- (V) Gauss-eloszlásból származó 6 %-os hibával terhelt adatrendszer.

A pontenkénti MMSA-P inverziós futtatásokat azonos iterációs lépésszám és hűtési ütem mellett végeztem (4.5) energiafüggvény $\mu=2$ és $\nu=0$ értékei mellett, amely a hagyományos Metropolis algoritmussal egyezik meg. A relatív adattérbeli távolságokat (4.3), a modelltérbe-

li távolságokat (4.27) alapján számítottam. A futtatások eredményeit a 4. táblázatban foglaltam össze.

A vizsgálatok során mindhárom adatrendszer inverzióját három különböző startmodell mellett vizsgáltam. Mindhárom esetben a 4. táblázatban látható, hogy az optimalizáció nagy pontossággal ugyanarra az eredményre vezetett. A maximális eltérés az eredménymodell paramétereinek között $D=0.01\%$, mind a paraméter-, mind az adattérben. Látható, hogy a paramétertérben az egzakt modelltől $D_{d,0}=182\%$ -os relatív adattávolságon belül az MSA-P eljárás ugyanahhoz a minimumhoz jutott el, a startmodell megválasztásától függetlenül. Ez azt bizonyítja, hogy a linearizált módszerekhez képest a modellterben 6-7-szer nagyobb startmodell távolságról is a globális optimalizáció konvergens és megfelelően pontos megoldást szolgáltat. Később látni fogjuk, hogy sokkal nagyobb hibájú modellek esetén is konvergens megoldást kapunk (ld. 5.2.1.4, 6.2.2.1.1 fejezet).

Adatrendszer	$D_{d,0}[\%]$	$D_{m,0}[\%]$	$D_d[\%]$	$D_m[\%]$
(III) 0 % Gauss zaj	24.47	20.00	0.001	0.002
	63.90	50.01	0.001	0.002
	182.53	150.00	0.001	0.002
(IV) 2 % Gauss zaj	24.47	20.00	2.37	3.44
	63.90	50.01	2.36	3.44
	182.53	150.00	2.37	3.44
(V) 6 % Gauss zaj	24.47	20.00	6.95	9.95
	63.90	50.01	6.96	9.96
	182.53	150.00	6.96	9.96

4. táblázat

Startmodell-függetlenségi vizsgálatok MMSA-P módszerrel

5.2.1.2 Gauss-zajjal terhelt adatok inverziója MMSA-P módszerrel

Az (I) adatrendszer inverzióját az MMSA-P módszerrel végeztem, ahol (4.5) energiafüggvényt $\mu=v=2$ értékei mellett alkalmaztam. Az inverz feladatban MODELL-1 (ld. 1. táblázat) pontonként $M=5$ ismeretlent tartalmaz, ezért az $N=7$ pontonkénti adatszám mellett kis mértékben túlhatározott inverz problémát kell megoldanunk.

A startmodellét az ismert modellhez képest (4.4) alapján $D_{m,0}=21\%$ -os modellterbeli illetve (4.3) szerint $D_{d,0}=120\%$ -os relatív adattérbeli távolsággal vettem fel. Az iterációs lépésszámot mélységpontonként $q_{\max}=2000$ -nek választottam, valamint a globális minimumot biztosító (2.18) logaritmusos hűtési mechanizmust alkalmaztam, $T_0=10^{-4}$ kezdeti hőmérséklettel. A paraméterek változtatását (2.21) alapján végeztem, ahol $q=80$ iterációs lépésenként a ma-


ximális paraméterváltoztatás változóját $\varepsilon=62$ %-kal csökkentettem. Az aktuális iterációs lépésbeli paraméterváltoztatás mértékét $b = -b_{\max} + 2b_{\max}\eta$ szerint számítottam, ahol η minden lépésben más $[0,1]$ intervallumban egyenletes valószínűséggel generált valós szám. Az algoritmust az inverz problémához inicializálva, beépítettem az anyagmérleg egyenleten alapuló további elfogadási kritériumot. Amikor e kritérium nem teljesült, akkor az eljárás az új modellt elvetette és visszatért az előző lépésben elfogadott modellhez. A (4.5) energiafüggvényben szereplő $\lambda=3$ csillapítási tényezőt próbafuttatások alapján választottam meg és az iterációs lépésszám növekedésével $q=100$ lépésenként értékét 60 %-kal csökkentettem.

Az inverziós eredmények $D_d=5.62$ %-os átlagos relatív adattérbeli-, illetve $D_m=2.25$ %-os átlagos modellterbeli távolsággal jellemezhetők (ld. 5. táblázat). A 4. ábra alapján megállapíthatjuk, hogy az adattérbeli zajnak megfelelően a petrofizikai paraméterek értékei továbbra is elég zajosak, melyet a pontenkénti inverziós feladat kismértékű túlhatározottsága okoz.

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
120.2 %	21.1 %	5.62 %	2.25 %	00:13:16

5. táblázat

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer
MMSA-P inverziós eredményei



4. ábra

Az 5 % Gauss zajjal terhelt (I) adatrendszer
MMSA-P inverziójával nyert petrofizikai paraméterek szelvényei

5.2.1.3 Kiugró adatok inverziója MMSA-P módszerrel


A (II) adatrendszer MMSA-P inverzióját a (4.5) energiafüggvény $\mu=2$ és $\nu=2$ értékei mellett minimalizálással végeztem. Az algoritmus szabályozó paraméterei megegyeznek 5.2.1.2-

ben leírtakkal. A választott startmodellt az ismert modelltől $D_{m,0}=21.1$ %-os átlagos modell-térbeli illetve $D_{d,0}=121.74$ %-os relatív adattérbeli távolság jellemezte. Az inverziós eredményeket a 6. táblázat, a becült paraméterek szelvényeit az 5. ábra mutatja, melyek szerint a kapott eredmények az adattérbeli zaj mértéke ismeretében elfogadhatóak.

(II) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
121.7 %	21.10 %	12.82 %	4.42 %	00:14:02

6. táblázat

Az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer MMSA-P inverziós eredményei



5. ábra

Az 5 % Gauss + kiugró zajjal terhelt (II) adatrendszer MMSA-P inverziójával nyert petrofizikai paraméterek szelvényei

5.2.1.4 Inverziós vizsgálatok távoli startmodell alkalmazása esetén

Az 5.1 fejezetben láttuk, hogy a startmodell megfelelő megválasztása nagymértékben befolyásolja a linearizált módszerek sikerességét. Ha a paramétereket a földtani szituáció hiányos ismerete miatt, vagy egyéb okból rosszul választjuk meg, az néhány esetben befolyásolhatja a globális optimalizációs módszerek hatékonyságát, amely elsősorban a konvergencia sebességét érinti.

Az abszolút minimumhoz rendelhető megoldástól távoli startmodellek alkalmazása önmagában még nem jelent akadályt a Simulated Annealing módszer számára, azonban, ha a startmodell egyes paraméterei erős korrelációban állnak egymással, akkor a Metropolis algoritmus konvergenciája nagymértékben lelassulhat. Vizsgáljuk meg, hogy mi történik, ha egy

távoli, erősen korrelált paraméterekkel megadott startmodellt veszünk fel és alkalmazzuk a hagyományos Metropolis algoritmust, majd az MMSA-P eljárást.

Tekintsük a 7. táblázatot, mely azt mutatja, hogy az inverzió számára felvett startmodell valóban erős belső csatolások, valamint az egzaktul ismert modelltől extrém relatív adattérbeli távolság ($D_{d,0}=5542\%$) jellemzi (a petrofizikai paraméterek utáni számok a réteg sorszámát jelentik). Először a linearizált DLSQ-P módszert alkalmaztam az (I) adatrendszer esetén, mely minden mélységpontban divergens megoldást adott. A DLSQ-P eljárás sok esetben a víztelítettségekre nulla értéket becsült, így a fajlagos ellenállások végtelenné váltak, ezért a relatív adattérbeli távolságban $\infty/\infty = NaN$ (Not a Number) értékkel tért vissza az inverziós program. A linearizált DLSQ-P optimalizáció alkalmatlannak bizonyult.

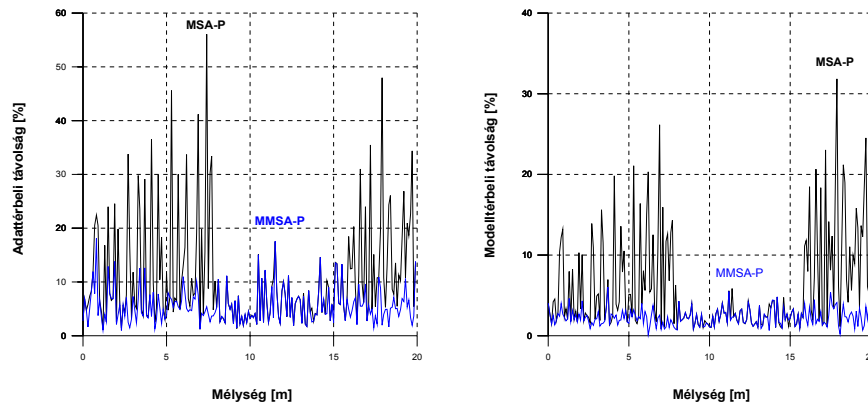
Modellparaméter		Korrelációs együttható
POR1	SX01	-0.81
VSH1	VSD1	-0.96
POR2	SX02	0.87
POR2	SW2	0.87
SX02	SW2	0.99
POR2	VSH2	-0.94
SX02	VSH2	-0.98
SW2	VSH2	-0.98
SX03	SW3	0.99
SW3	VSH3	-0.98
POR4	SW4	-0.77

7. táblázat

A startmodell néhány paraméterpárjára vonatkozó korrelációs együtthatók

A globális optimalizáció esetén (4.5) energiafüggvény alapján MMSA-P pontenkénti inverziós algoritmust használtam $\mu=v=2$ paraméterek mellett, illetve $\mu=2$ és $v=0$ esetén az eljárást visszavezettem a hagyományos Metropolis algoritmuson alapuló (MSA-P) pontenkénti inverzióra. Mindkét eljárásnál azonos kezdeti hőmérsékletet ($T_0=100$) választottam, hogy az eljárás nagy elfogadási valószínűség mellett sok modellparaméter kombinációt kipróbáljon, majd a globális minimum érdekében a (2.18) logaritmikus hűtési algoritmus szerint jártam el. Az eredményeket a 6. ábrán láthatjuk, mely a szelvény menti mélységpontokban ábrázolja a becsült paraméterekre számított relatív adat-, és modelltérbeli távolságokat. Látható, hogy amíg az MSA-P algoritmus a legtöbb mélységpontban még csak a megoldás közelében tartózkodik, addig az MMSA-P eljárás már elérte az optimumot.

A 8. táblázatban láthatjuk, hogy az MMSA-P inverzió esetén nagymértékű javulás következett be a paraméterek meghatározásában. Tekintve, hogy MODELL-1 paramétereit becslésekor a GEMAN (1984) által alkalmazott hűtési eljárást követtük, az 5. táblázattal összehasonlítva az eredményeket megállapíthatjuk, hogy az MMSA-P algoritmus konvergencia sebessége nagyobb a hagyományos Metropolis algoritmusénál, mivel ugyanahhoz az optimumhoz talált. Ez a példa bizonyítja az MMSA-P módszer hatékonyságát extrém startmodell esetén is.



6. ábra

Az 5 % Gauss zajjal terhelt (I) adatrendszer MSA-P és MMSA-P inverziójával kapott adattérbeli és modelltérbeli távolságok mélységfüggvényei

(I) adatrendszer					
Algoritmus	$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
DLSQ-P			divergens	divergens	00:04:05
MSA-P	5542 %	159.4 %	10.69 %	5.82 %	00:16:19
MMSA-P			5.62 %	2.26 %	00:16:11

8. táblázat

Az 5 %-os Gauss zajjal terhelt (I) adatrendszer pontonkénti inverziós eredményei a megoldástól távoli startmodell esetén

5.2.2 Inverziós vizsgálatok Genetikus Algoritmus felhasználásával

A globális optimalizációs GA módszerek közül a valós kódolású FGA eljárást választottam MODELL-1 paramétereinek meghatározására. Az inverzió előtt minden modellparaméter keresési intervallumát rögzítenünk kell, majd a paramétertér e részéből nagyszámú véletlen modellt generálunk, melyekre automatikusan teljesülnek a matematikai és földtani korlátozó egyenletek. Azonban a közetkomponensek összegére fennálló anyagmérleg egyenlet továbbra is szükséges, melyet már a kezdeti modellcsalád generálásánál is figyelembe vettem. Az FGA-P pontonkénti inverzióval modellegyüttesek generációit iteratív eljárásban javítjuk az optimális modell megtalálása érdekében.

5.2.2.1 Gauss-zajjal terhelt adatok inverziója FGA-P módszerrel

Az FGA-P inverzió során (4.6) célfüggvényt választottam fitness függvénynek, melynek globális maximumhelyét – (2.11) adattávolság minimumhelyét – kerestem minden mélységpontban MODELL-1 petrofizikai paramétereinek meghatározása céljából.

A startmodelleket alkotó kezdeti populációt $S=20$ egyeddel generáltam (az irodalomban is a legtöbb alkalmazás $S\sim 30$ modellel dolgozik). A 9. táblázatban, pl. az első mélységpont első populációjának relatív adattávolság értékei láthatók, melyek átlagos értéke $D_d=167.33$ % és szórása $\sigma=360.1$, mely a (4.6) alapján számított $D_m=30.26$ % átlagos modelltérbeli távolsághoz tartozik. A keresési intervallum minden modellparaméter esetén $[0,1]$, a maximális iterációs lépésszám (generációk maximális száma) mélységpontonként $q_{\max}=3500$ volt. Valós genetikus műveleteket alkalmaztam: normált geometriai rang szelekciót, heurisztikus keresztezést és egyenletes eloszlású mutációt. A reprodukció során (mely a genetikus műveleteken átment aktuális populáció egyedeit áthelyezi az új generációba) az elitizmus elvét követtem, azaz az előző iterációs lépésben számított generáció legalkalmasabb egyedével kicseréltem az átmeneti populáció legrosszabb egyedét.

modell	$D_d^{(1)}$ [%]	$D_d^{(150)}$ [%]	modell	$D_d^{(1)}$ [%]	$D_d^{(150)}$ [%]
1.	96.41	10.23	11.	112.35	46.09
2.	29.47	10.23	12.	1690.17	46.09
3.	30.27	110.98	13.	156.34	38.42
4.	96.13	17.65	14.	96.03	16.36
5.	30.26	5.96	15.	75.00	16.36
6.	98.86	13.60	16.	71.73	17.70
7.	83.82	7.60	17.	80.93	5.96
8.	89.72	64.53	18.	68.60	5.96
9.	156.75	7.85	19.	80.93	18.32
10.	122.77	7.85	20.	80.89	5.96

9. táblázat

Az 1. és a 150. generáció modelljeire számított relatív adattérbeli távolságok

Az FGA-P algoritmus futása során jellemző a populáció homogenizálódása, amint a rendszer tart az optimum felé. Ennek érzékeltetésére tekintsük a 9. táblázatot, ahol megfigyelhető, hogy a 150. populációban már számottevően lecsökken az átlagos relatív adattérbeli távolság és a szórás, melyek értéke $D_d=23.69$ % és $\sigma=26.35$. Továbbá az is látható, hogy a legalkalmasabb (minimális relatív adattérbeli távolságú) modellek nagyobb számban képviseltetik magukat a későbbi generációban, mint a korábbiakban. Pl. az első populációban $D_d=80.93$ %-kal két modell szerepel, a 150. populációban a legjobb modell pedig már $D_d=5.96$ %-kal négyszer


van jelen (amely már igen közel áll az optimumhoz). Nyilván a $[0,1]$ -intervallumból egyenletes valószínűséggel generált véletlen modellparaméterek együttese sok esetben nem teljesíti az anyagmérleg egyenletet, így e modellek azonnal kizselektálódnak, illetve elvetésre kerülnek. Ilyen modell, pl. a kezdeti populáció 12-es sorszámú egyede.

Az inverziós eredményeket a 10. táblázat és a 7. ábra mutatja. A táblázatban az egyedi mélységpontokban kapott maximális fitness értékhez tartozó modelleknek a szelvényezett intervallumra vett átlagos relatív adattérbeli és modelltérbeli távolságai szerepelnek. A becült modellek relatív adattérbeli távolságából megállapítható, hogy a zaj mértékének megfelelő adattérbeli hiba terheli a becült paramétereket. A futási idő globális optimalizációs módszerhez képest nem túl nagy. Mivel (II) adatrendszer FGA-P inverziója során az MSA-P inverzióval igen jól egyező eredményeket kaptam, ezért további FGA-P vizsgálatokat nem ismertetek.

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
163.37 %	30.26 %	5.64 %	2.26 %	00:12:56

10. táblázat

Az (I) 5 %-os Gauss-zajjal terhelt adatrendszer FGA-P inverziós eredményei



7. ábra

Az (I) 5% Gauss-zajjal terhelt adatrendszer FGA-P inverziójával nyert petrofizikai paraméterek szelvényei

Ebben a fejezetben szintetikus mélyfúrési geofizikai szelvényadatok mélységpontonkénti inverziós vizsgálatával foglalkoztam. A hagyományos (iparban alkalmazott) linearizált optimalizáción alapuló mélyfúrési geofizikai inverziós kiértékelés eredményének javítása céljából

mélységpontonkénti globális inverziós algoritmusokat fejlesztettem. A Metropolis Simulated Annealing eljárást új energiafüggvény bevezetésével módosítottam, mely az alapmódszernél gyorsabb konvergencia sebességet biztosít.

A módosított Simulated Annealing módszeren (MMSA-P) és a Valós Kódolású Genetikus Algoritmuson (FGA-P) alapuló pontonkénti inverziós eljárásokat zajjal terhelt szintetikus adatokon teszteltem. Az eredményekből kimutatható, hogy a fenti globális optimalizációs módszerekkel javítható a becsült petrofizikai paraméterek pontossága a hagyományos linearizált eljárásokhoz képest. Bemutattam, hogy a megoldástól igen nagy modell- és adat-térbeli távolsággal jellemezhető startmodell esetén (erősen korrelált paraméterek mellett is) az MMSA-P eljárás konvergenciája gyorsabb a Metropolis algoritmushoz képest, továbbá ahol a linearizált inverzió már numerikusan nem működik, ott a globális optimalizáció konvergens megoldást képes szolgáltatni.

6. SZINTETIKUS ADATOK INTERVALLUM INVERZIÓJA

Ebben a fejezetben MODELL-1 (ld. 1. táblázat) paramétereit (I) valamint (II) zajjal terhelt szintetikus adatrendszer intervallum inverziójával (ld. 4.2 fejezet) határozom meg. Először a rétegenként homogén modell rétegjellemző paramétereit ismert rétegvastagságok mellett vizsgáltam, majd ezután a rétegvastagságokat is inverziós ismeretlenek tekintetem. Ezután az intervallum inverziós módszert egy újabb modellre (MODELL-2) alkalmazom, melyet a homogén rétegek mellett egy rétegben a közetjellemző paraméterek inhomogén mélységeloszlása jellemez.

6.1 SZINTETIKUS ADATOK LINEARIZÁLT INTERVALLUM INVERZIÓJA

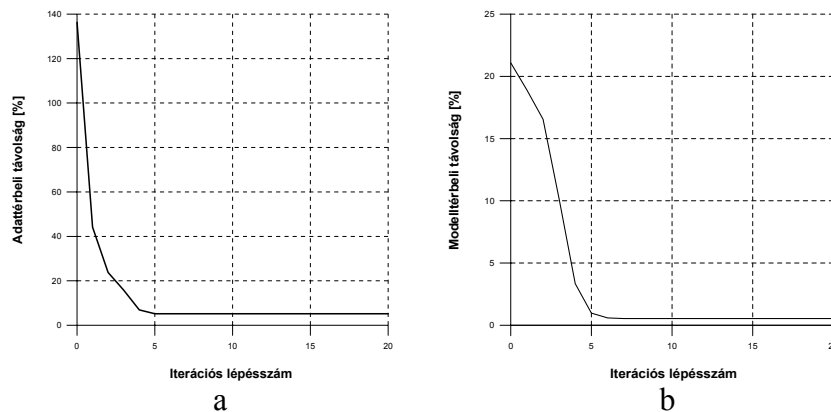
A nemlineáris intervallum inverziós problémát ebben a fejezetben linearizált optimalizációs DLSQ-I és LAD-I eljárásokkal oldom meg. Mindkét inverziós módszer a petrofizikai paraméterek (4.8) szerinti sorfejtésén alapul, mely MODELL-1 paramétereinek meghatározása céljából rétegenként homogén modellt leíró bázisfüggvény-rendszert alkalmaz. A rétegvastagságokat itt ismertnek tekintetem. A numerikus vizsgálatok során a becsült modellparaméterek adattérbeli és modelltérbeli távolságai mellett vizsgálom az algoritmusok futási idejét, a konvergencia alakulását az iterációs lépésszám függvényében, valamint a becsült paraméterek hibáját és a korrelációs mátrix elemeit is számítom.

6.1.1 Gauss-zajjal terhelt adatok inverziója DLSQ-I módszerrel

Rétegenként homogén modell szerinti sorfejtés esetén az intervallum inverziós probléma nagymértékben túlhatározott. Ekkor a teljes intervallumon invertált adatok száma a vizsgált mélységpontok száma szorozva a pontbeli adatszámmal. A mélységpontok száma a MODELL-1 esetén $P=200$, így pontonként $N=7$ szelvényadat lévén a teljes intervallumon $N^*=1400$ adat áll rendelkezésre. Mivel fix rétegvastagságok mellett az ismeretlenek száma $M=20$, ezért nagymértékű túlhatározottság ($M \ll N^*$) teljesül.

Az (I) adatrendszer linearizált inverzióját először a csillapított legkisebb négyzetek módszerével oldottam meg, melynél a numerikus differenciálást 5.1.2-ben leírtakhoz hasonlóan végeztem. A DLSQ-I eljárás konvergenciáját a 8. ábra mutatja. Látható, hogy az eljárás már az 5. iteráció után megtalálta az optimumot. A maximális iterációs lépésszámot $q_{\max}=20$ -nak választottam, mellyel az inverzió körülbelül 1 percet vett igénybe. Az intervallum inverzió eredménye 5 %-os Gauss-zajjal terhelt szintetikus adatok esetén (4.15) szerint $D_d=5.16$ % relatív adattérbeli és (4.16) alapján $D_m=0.54$ % modelltérbeli távolság (ld. 11. táblázat).

A becsült kőzetfizikai paraméterek szelvényeit a 9. ábrán tekinthetjük meg, melyeket MODELL-1 paramétereivel (ld. 1. táblázat) összevetve, már vizuálisan is szembetűnik az eredmény nagyfokú pontossága. Az intervallum inverziós eljárás igen stabil és pontos paraméterbecslést tesz lehetővé. A becsült kőzetjellemzők hibáját (2.16) alapján számítottam. A 12. táblázatban a négy réteg összes paraméterének hibáját feltüntettem, mely a valódi érték előfordulását adja meg a megadott intervallumban. Ebből látható, hogy a térfogatjellemző petrofizikai paraméterek hibája igen kicsi intervallum inverzió esetén.



8. ábra

Az a, adattérbeli távolság vs. iterációs lépésszám és b, modelltérbeli távolság vs. iterációs lépésszám DLSQ-I inverzió folyamán

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
120.2 %	21.10 %	5.16 %	0.54 %	00:00:43

11. táblázat


Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer DLSQ-I inverziós eredményei

Réteg	POR	SX0	SW	VSH	VSD
1	0.2003 (±0.0020)	0.7989 (±0.0046)	0.3999 (±0.0022)	0.3000 (±0.0029)	0.4907 (±0.0047)
2	0.0977 (±0.0038)	1.0000 (±0.0069)	1.0000 (±0.0095)	0.7996 (±0.0022)	0.1077 (±0.008)
3	0.2985 (±0.0015)	0.8034 (±0.0040)	0.3025 (±0.0014)	0.1010 (±0.0017)	0.5964 (±0.0042)
4	0.1010 (±0.0024)	0.9995 (±0.0052)	0.9990 (±0.0064)	0.6015 (±0.0029)	0.3005 (±0.0057)

12. táblázat

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer DLSQ-I inverziójával nyert paraméterek és hibáik

A DLSQ-I inverzióval becsült kőzetjellemzők megbízhatóságára a 6. melléklet szolgáltat információt. A mellékelt táblázatban szereplő korrelációs együtthatók nem túl nagyok, ill. a (4.17) alapján számított $S=0.17$ korrelációs átlag is alacsony, mely a becsült paraméterek elfogadhatóságára utal. A korrelációs mátrixból kiolvasható a modell szerkezete, mivel a ritka mátrix struktúrájában elszeparálódik a négy réteg. Látható, hogy a különböző rétegek közötti zérus értékű paraméter korreláció van, mely a fix réteghatárt használó intervallum inverziós módszer következménye. Ha a rétegvastagságok is ismeretlenek lennének, megjelenének az egyes rétegek közötti függőségi számok, melyek most a fix rétegvastagságok esetén zérus értékűek. Ekkor ugyanis a \underline{G} mátrixban megjelenének a rétegvastagság szerinti deriváltak, melyek a lineáris egyenlet megoldása során összekapcsolják a rétegvastagságokat a többi réteg modellparamétereivel. A korrelációs mátrixban elemeinek előjele a függőségi viszonyban lévő paraméterek együtváltozásának irányára utal.



9. ábra

Az 5 %-os Gauss zajjal terhelt (I) adatrendszer
DLSQ-I inverziójával nyert petrofizikai paraméterek szelvényei

6.1.2 Kiugró adatok inverziója a DLSQ-I és LAD-I módszerekkel

Az intervallum inverzió kiugró adatokat tartalmazó adatrendszerekre vonatkozó viselkedésének vizsgálata céljából a (II) adatrendszeren a DLSQ-I, majd a legkisebb abszolút értékek elvén alapuló LAD-I eljárással inverziós vizsgálatokat végeztem. Az alkalmazott startmodellek MODELL-1-től számított relatív adattérbeli és modelltérbeli távolsága megegyezett 11. táblázatban leírtakkal. A DLSQ-I algoritmus beállításain nem változtattam (ld. 6.1.1 fejezet). A LAD-I módszer súlymátrixát (4.19) szerint definiáltam, ahol az eltérésvektort a mért ada-

tokkal normáltam az adatok különböző nagyságrendje miatt. A LAD-I eljárás így az adatokat az elvi értéküktől való eltérésük alapján súlyozottan veszi figyelembe a megoldás kialakításánál. Ezzel az inverzió során a kiugró zaj hatását elnyomjuk, így javítható az outlier-ekre kifejezetten érzékeny DLSQ-I inverzió.

A futtatások során a maximális iterációs lépésszámot mindkét algoritmus esetén $q_{\max}=20$ -nak választottam. Mindkét eljárás a kiugró zaj ellenére konvergens és stabil maradt. A futási idő DLSQ-I esetén alig több mint fél perc, LAD-I esetén $t=1$ perc volt. A 13. táblázatban található (4.15 és 4.20) relatív adattérbeli- és (4.16 és 4.21) modelltérbeli távolságok igazolták annak tényét, hogy a DLSQ-I módszer által becsült paraméterek pontosságát nagymértékben javította a LAD-I módszer, illetve az utóbbi módszer kiugró adatokkal szembeni rezisztenciája mélyfúrás geofizikai inverzió esetén is fennáll. A DLSQ-I módszer mellett alkalmazott LAD-I eljárás esetén a relatív adattérbeli távolság $D_d=13.07\%$ -ról 7.42% -ra, a modelltérbeli távolság pedig $D_m=1.48\%$ -ról 0.86% -ra csökkent.

(II) adatrendszer					
Algoritmus	$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
DLSQ-I	120.2 %	21.10 %	13.07 %	1.48 %	00:00:36
LAD-I			7.42 %	0.86 %	00:01:03

13. táblázat

Az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer linearizált intervallum inverziós eredményei


A DLSQ-I módszerrel becsült paramétereket és hibáját a 14. táblázatban láthatjuk. Ebből kitűnik, hogy a maximális hiba a második rétegbeli víztelítettséget terhelte (SW2), továbbá relatíve nagy hiba adódott SX02, SX04, SW4, valamint VSD2 és VSD4 paraméterekre. Ez megmagyarázható a 7. fejezetben végzett paraméter-érzékenységi vizsgálatokkal. A tapasztalat azt mutatja, hogy a válaszgyenletekből számított adatok azokra a paraméterekre reagálnak a legérzékenyebben, melyek a legtöbb válaszfüggvényben jelen vannak, és melyekre a (7.1) paraméter-érzékenységi függvény értéke nagy. Ugyanezen paraméterek meghatározása inverziós szempontból is kedvezőbb. Jelen inverziónál megállapítható, hogy a víztelítettségek csak külön-külön a (3.8) és (3.9) fajlagos ellenállás válaszgyenletekben szerepelnek, valamint az is kimutatható, hogy a válaszgyenletek VSD paraméterre vonatkozó érzékenysége a kis homoktartalom tartományban általában kicsi. A 25. ábrán pl., a Wyllie-féle akusztikus válaszfüggvény homoktartalom érzékenységi függvénye is ezt támasztja alá. Ezért volt e fenti petrofizikai paraméterek meghatározása a legkedvezőtlenebb. A korrelációs átlag kiugró adatok esetén is $S=0.17$ volt.

A (II) adatrendszer DLSQ-I és LAD-I inverziós módszerekkel becsült paraméterszelvényei vizuálisan nem különíthetők el egymástól, ezért elegendőnek találtam a LAD-I inverziós eredmények bemutatását. A 10. ábrán látható szelvényeket összehasonlítva MODEL-1 paramétereivel, megállapítható, hogy kiugró zaj ellenére is az intervallum inverzió igen pontosan megközelítette a célmodellt.

Réteg	POR	SX0	SW	VSH	VSD
1	0.2021 (±0.0040)	0.8049 (±0.0093)	0.3994 (±0.0044)	0.2946 (±0.0059)	0.4938 (±0.0095)
2	0.0895 (±0.0075)	1.0000 (±0.0140)	1.0000 (±0.0196)	0.8009 (±0.0044)	0.0961 (±0.0159)
3	0.2985 (±0.0030)	0.8071 (±0.0081)	0.3028 (±0.0029)	0.0973 (±0.0034)	0.5712 (±0.0083)
4	0.0982 (±0.0049)	1.0009 (±0.0106)	1.0034 (±0.0135)	0.5962 (±0.0060)	0.3251 (±0.0118)

14. táblázat

Az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer DLSQ-I inverziójával nyert paraméterek és hibáik



10. ábra

Az 5% Gauss + kiugró zajjal terhelt (II) adatrendszer LAD-I inverziójával nyert petrofizikai paraméterek szelvényei

6.2 SZINTETIKUS ADATOK GLOBÁLIS INTERVALLUM INVERZIÓJA

Az intervallum inverziós probléma a linearizálás mellett globális optimalizációval is kezelhető. Ennek keretében a célfüggvény globális optimumához tartozó modellt véletlen kereséssel határozzuk meg. Ebben a részben az SA és a GA eljárások alkalmazásán keresztül megvizsgáltam, hogyan automatizálható a rétegvastagságok meghatározása, továbbá az inter-

vallum inverzió hogyan fejleszthető tovább inhomogén réteg paramétereinek meghatározására. Ezután megvizsgálom a globális és a linearizált algoritmusok kombinálásának előnyeit. A numerikus vizsgálatok során a becsült modellparaméterek adattérbeli és modelltérbeli távolságai mellett vizsgálom az algoritmusok futási idejét és a konvergencia alakulását az iterációs lépésszám függvényében. A becslési hiba jellemzésének két útja lehetséges. Az egyik a sokszori futtatás módszere, melynek eredményeiből statisztikai paraméterek állíthatók fel a becsült petrofizikai paraméterekre nézve. Azonban ez az igen hosszú futási idő mellett ma még nem gazdaságos módszer. A másik út a kombinált inverzió alkalmazása, melynél globális optimalizációval indítva az eljárást adott iterációs lépésszám után áttérünk linearizált optimalizációra, így az eljárás végén lehetséges a kovariancia mátrix felhasználása a hibajellemzésben.

6.2.1 Numerikus vizsgálatok ismert réteghatár-koordináták esetén

Ebben a vizsgálatcsoportban a rétegvastagságokat az intervallum inverzió során a priori adottnak tekintjük és a rétegjellemzőket rétegenként homogén modell szerinti sorfejtés alapján számítjuk. A teljes intervallumon invertált adatok száma MODELL-1 esetén $N^*=1400$, továbbá az ismeretlen modellparaméterek száma $M=20$. Mivel a rétegvastagságok ismertek, ezért az ismeretlen modell paraméterek azonos nagyságrendje miatt a modelltérbeli távolságot továbbra is (6.1) szerint számítom.

6.2.1.1 Inverziós vizsgálatok Simulated Annealing módszerrel

A 4.2 fejezetben (4.22) energiafüggvénnyel bevezetett MMSA-I intervallum inverziós módszert alkalmazom az (I) és (II) adatrendszer felhasználásával MODELL-1 paramétereinek meghatározására.

6.2.1.1.1 Gauss-zajjal terhelt adatok inverziója MMSA-I módszerrel

Az MMSA-I módszer (4.22) általánosított energiafüggvényét $\mu=2$ és $\nu=2$ paraméterek mellett képeztem. A startmodell (4.15) alapján $D_{d,0}=134.13$ % relatív adattérbeli távolsággal, valamint (4.16) szerinti $D_{m,0}=21.14$ % modelltérbeli távolsággal vettem fel.

A fémek hűtési mechanizmusát követő eljárást $q_{\max}=5000$ iterációs lépésszámmal valósítottam meg. A maximális paraméterváltoztatás 1-90 iterációs lépésben $b_{\max}=0.11$ volt, mely a tárolójellemzők értékét lépésenként maximálisan 11 %-al engedte megváltoztatni (a b paraméterváltoztatás mértékét jellemző véletlen számot az 5.2.1.2 fejezetben megadott képlet sze-

rint sorsolta az algoritmus), majd ezt követően minden 90. iterációs lépésben b_{\max} értékét 85 százalékkal csökkentettem. Ez azt jelenti, hogy az 5000. lépésben $b_{\max} \sim 10^{-5}$ nagyságrendű értéke garantálta, hogy a globális optimum környezetéből ne történjen véletlen ugrás vissza egy rosszabb energiájú állapot felé. További megszorítást a közetjellemzők fajlagos térfogatra vonatkozó (3.11) anyagmérleg egyenlet jelentett, melyet minden új modell elfogadása után megvizsgált az algoritmus. Abban az esetben, ha az egyenlet nem teljesült, akkor az új paramétervektort nem fogadtuk el, és a keresés visszatért az előző lépésben elfogadott modellvektorhoz. Az alkalmazott hűtési mechanizmus során a kezdeti hőmérsékletet alacsony értékre $T_0=10^{-5}$ -re állítottam, amit minden 90. iterációs lépésben a (2.18) hűtési szabálynak megfelelően csökkentettem. E hűtési ütemnek köszönhetően kezdetben a konvergencia gyors volt, azonban az optimum környékén lelassult a keresés. Erre utal a 15. táblázatban látható, kb. 15 perces futási idő.

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
134.1 %	21.14 %	5.16 %	0.38 %	00:14:36

15. táblázat

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer
MMSA-I inverziós eredményei


A 11. ábra a relatív adattérbeli- és a modelltérbeli távolság alakulását mutatja az iterációs lépésszám függvényében. A 11/b ábrán megfigyelhető a piros körön belüli függvényértékek-nél, hogy az eljárás a $q=960$. iterációs lépésszám környékén éppen egy lokális minimumból kiszabadulva konvergál tovább a $q=1070$. iterációs lépéstől kezdve egy alacsonyabb energiaszint felé. Az MMSA-I stabil és pontos eljárásnak bizonyult, ezt bizonyítja, hogy a becsült közetjellemzők (ld. 12. ábra) között több olyan paramétert is kaptunk, melyek a négy tizedesjegy pontossággal egzaktul megegyeztek MODEL-1 megfelelő paramétereivel.

6.2.1.1.2. Kiugró adatok inverziója MMSA-I módszerrel

Mivel a fúrólukbeli geofizikai méréseknél ritkán van lehetőség az ismétlésre, ezért az adatfeldolgozással (kiértékelés) kell a mérőeszköz által hibásan detektált, vagy a kedvezőtlen lyukállapot miatt mért gyenge minőségű adatokból eredő problémák hatását csökkentenünk.


A kiértékelés oldaláról tekintve, erre nyújt lehetőséget a legkisebb abszolút értékek elvének (LAD) megfelelő alkalmazása. A linearizált optimalizációt követve hasonló elvű globális optimalizációs módszert fejlesztettem ki. Látni fogjuk, hogy a (4.22) energiafüggvény μ és v értékeinek megfelelő megválasztásával, kiugró adatokkal szemben rezisztens SA eljárás fej-

leszhető. A vizsgálat kétfajta energiafüggvény mellett képzett MMSA-I módszerre terjed ki a kiugró adatokat tartalmazó (II) adatrendszer kiértékelése során.



11. ábra

Az a, relatív adattérbeli távolság vs. iterációs lépésszám és b, modelltérbeli távolság vs. iterációs lépésszám MMSA-I inverzió folyamán



12. ábra

Az 5% Gauss zajjal terhelt (I) adatrendszer MMSA-I inverziójával nyert petrofizikai paraméterek szelvényei


A futtatásokat először az (I) adatrendszer inverziójakor eddig is alkalmazott $\lambda=3$ és $\mu=v=2$ paraméterek melletti MMSA-I módszerrel végeztem. Az algoritmus folyamatjellemző paramétereit 6.2.1.1.1 fejezetben leírtaknak megfelelően állítottam be (a λ csillapítási tényező értékét 90 iterációs lépésenként 60 %-kal csökkentettem.). Az inverziós eredmények a 16. táblázatban találhatóak. A minimalizálás viszonylag nagy relatív adattérbeli és modelltérbeli távolságot eredményezett, a kiugró adatok eltérítették az algoritmust, és annak konvergenciája erőteljesen lelassult.

Ezután a LAD módszerrel analóg módon $\lambda=2$ és $\mu=v=1$ paraméterekkel megadott energiafüggvényt minimalizáltam. A várakozásnak megfelelően az új intervallum inverzió rezisztenciája bebizonyosodott, mely gyorsabb konvergencia mellett lényegesen pontosabb megoldást szolgáltatott. A 16. táblázatban látható, hogy a relatív adattérbeli távolság $D_d=13.30\%$ -ról 7.26% -ra, a modell térbeli távolság pedig $D_m=0.75\%$ -ról 0.38% -ra csökkent. Megjegyezzük, hogy a két módszer adattérbeli és modell térbeli távolságát két hasonló, de más képlet definiálja, ezért ezek az mérőszámok csak kvalitatív összehasonlításra használhatók. Viszont ebből annyi mindenképpen látható, hogy szignifikánsan jobb eredményt szolgáltatott az utóbbi MMSA-I inverzió. A 13. ábrán látható, hogy a becsült petrofizikai paraméterek a kiugró adatok ellenére is megfelelően közelítik MODELL-1 paramétereinek értékeit.

(II) adatrendszer					
Algoritmus	$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
MMSA-I ($\mu=v=2$)	134.1 %	21.14 %	13.30 %	0.75 %	00:46:01
MMSA-I ($\mu=v=1$)			7.26 %	0.38 %	00:48:31

16. táblázat

Az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer
MMSA-I inverziós eredményei



13. ábra

Az 5%-os Gauss + kiugró zajjal terhelt (II) adatrendszer
MMSA-I ($\mu=1$ és $v=1$) inverziójával nyert petrofizikai paraméterek szelvényei

6.2.1.2 Inverziós vizsgálatok FGA-I algoritmussal

Az (I) adatrendszer FGA-I inverziója során (4.23) fitness függvényt maximalizáltam. Az algoritmus inicializálása során a kezdeti populációt $S=20$ véletlen egyeddal generáltam, me-

lyek közül a minimális modelltérbeli távolságú $D_{m,0}=17.05\%$ modellhez $D_{d,0}=45.07\%$ relatív adattérbeli távolság tartozott. Ez a kezdeti populáció maximális fitness értékű modellje.

Az FGA-I algoritmus a keresési tér előzetes megadását igényli az inverzió előtt, mely a modellparaméterek értékére vonatkozó korlátozásokat foglalja magában. MODEL-1 paramétereinek meghatározásához a 17. táblázatban szereplő keresési intervallumokat adtam meg, melyek mind a négy rétegre egyszerre fennállnak. E mellett az anyagmérleg egyenletet is beépítettem, azonban végeztem olyan futtatásokat is, ahol ezt a kényszerfeltételt nem alkalmaztam, mégis ugyanazt az eredményt kaptam. Ez alapján megállapítható, hogy az FGA-I eljárás igen stabil inverziót hajt végre, mialatt optimális modellek sorozatát állítja elő. E modellek közül automatikusan kiszelektálódnak a kényszerfeltételeket nem teljesítő egyedek.

Paraméter	Minimum	Maximum
POR	0	0.4
SX0	0.2	1.0
SW	0.5	1.0
VSH	0	1.0
VSD	0	1.0

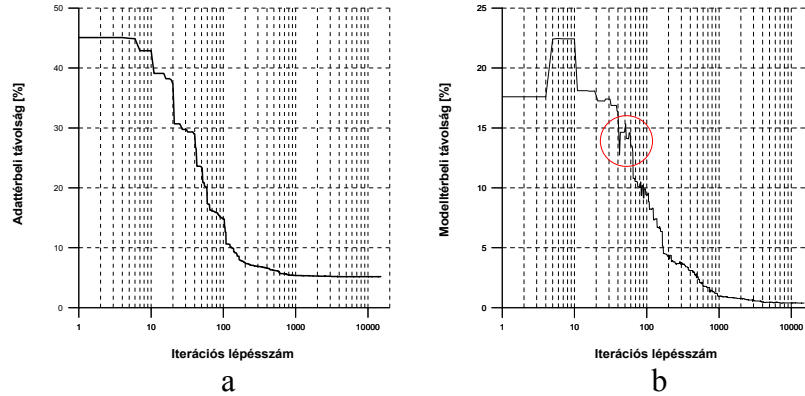
17. táblázat

A tárolójellemzők keresési intervalluma FGA-I inverzió során

Az optimális modell(ek) keresése céljából a generációk (iterációs lépések) számát próba-futtatások alapján $q_{\max}=15000$ -nek adtam meg. A numerikus kísérlet során normált geometriai rang szelekcióból, heurisztikus keresztezésből és egyenletes eloszlású mutációból álló genetikus operátor kombinációt alkalmaztam. A reprodukciónál, csak úgy, mint az FGA-P inverzió esetén megengedtem az elitizmus műveletét, mely az aktuális populációt megelőző generáció minimális adattérbeli távolsággal rendelkező modelljét minden esetben megtartotta az új generáció számára. A 14. ábrán az aktuális generáció maximális fitness értékű (az optimális) modelljéhez tartozó relatív adattérbeli és modelltérbeli távolságok láthatók az iterációs lépésszám (generációk száma) függvényében. A 14/b ábrán a piros körön belül a Simulated Annealing módszernél is tapasztalt jelenség látható. A véletlen keresés során a $q=42$. generáció után a rendszer kiszabadul a célfüggvény egy lokális maximumából (a relatív adattérbeli távolság függvény lokális minimumából), és a $q=65$. iterációs lépés után tovább konvergál az optimum felé.

Az FGA-I inverziós eredményeket a 18. táblázat és a 15. ábra tartalmazza. A táblázatban az utolsó generáció maximális fitness értékű modelljéhez tartozó relatív adat- és modelltérbeli távolságok szerepelnek. E modellt fogadta el az eljárás az utolsó generáció egyedei közül az

inverz feladat megoldásának. Az FGA-I igen stabil inverziós eljárásnak bizonyult, mely MODELL-1-et (ld. 1. táblázat) megfelelően rekonstruálta. A futási idő a Simulated Annealing módszerrel egy nagyságrendbe esett.




14. ábra

Az a, relatív adattérbeli távolság vs. iterációs lépésszám és b, modelltérbeli távolság vs. iterációs lépésszám alakulása FGA-I inverzió folyamán

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
45.07 %	17.05 %	5.16 %	0.38 %	00:54:07

18. táblázat

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer FGA-I inverziós eredményei



15. ábra

Az 5% Gauss zajjal terhelt (I) adatrendszer FGA-I inverziójával nyert petrofizikai paraméterek szelvényei

6.2.2 Numerikus vizsgálatok ismeretlen réteghatár-koordináták esetén

E vizsgálatcsoportban a rétegvastagság-meghatározást globális optimalizációval végrehajtó MMSA-H és FGA-H eljárásokat vizsgálom (ld. 4.3 fejezet). Mivel MODELL-1 (ld. 1. táblázat) esetén $N^*=1400$ adat mellett $M=20$ rétegjellemző meghatározása képezi az intervallum inverziós feladatot, a túlhatározottságot nem csökkenti nagymértékben további három rétegvastagság paraméter (H_1 - az első, H_2 - a második, H_3 - a harmadik réteg vastagsága) inverziós ismeretlenként való bevezetése. Az inverzió során az utolsó rétegvastagságot a szelvények véges hossza és az inverzió stabilitása miatt szintetikus vizsgálatoknál fixnek vettem, továbbá nem engedem meg a $H=0$ [m] rétegvastagságot.

6.2.2.1 Inverziós vizsgálatok Simulated Annealing módszerrel

Az ismeretlen réteghatár-koordináták melletti intervallum inverziót, az eddigi kiértékelésekre használt (I) Gauss, majd a (II) Gauss + kiugró zajjal terhelt szintetikus adatrendszeren az MMSA-H módszer alkalmazásával végeztem.

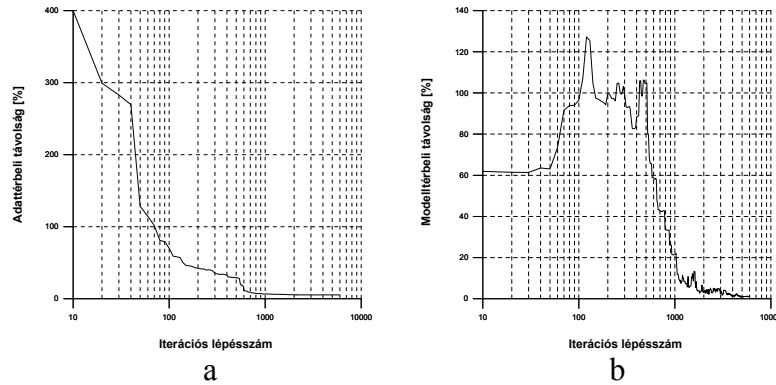
6.2.2.1.1 Gauss-zajjal terhelt adatok inverziója MMSA-H módszerrel

Az (I) adatrendszer MMSA-H inverzióját a (4.22) energiafüggvény minimalizálásával, $\mu=2$, $\nu=0$ paraméterek mellett végeztem. Az eljárást a kezdeti becsült rétegvastagság értékeknek köszönhetően a megoldástól egy igen távoli pontból ($D_{d,0}\sim 400\%$, $D_{m,0}\sim 62\%$) indítottam.

Az iterációs lépésszámot $q_{\max}=6000$ -ben maximalizáltam. A $b_{\max,1}=0.1$ kezdeti petrofizikai paraméterváltoztatás mellett bevezettem a $b_{\max,2}=3$ [m] paramétert. Ez a rétegvastagságok változtatásáért külön felelt a keresési folyamat során. A $b_{\max,1}$ -et $q=1000$ lépésenként az aktuális érték 85 %-ára, $b_{\max,2}$ -t annak 70 %-ára csökkentettem. A kezdeti hőmérséklet $T_0=10^{-1}$ volt, a hűtés (4.18) szerint történt. A korlátozó egyenleteket és az anyagmérleg egyenletet is beépítettem. A rétegvastagságokat ebben a vizsgálatban $dH=1$ m-enként engedtem változni.


Az iterációs eljárás folyamata a 16. ábrán, míg a rétegvastagságok értékének változása a 17. ábrán követhető. A két ábrát összevetve azt láthatjuk, hogy az MMSA-H eljárás először megkeresi a rétegvastagságok optimális értékét, majd a mért és számított szelvényadatok további illesztésével kezdi finomítani a rétegjellemzők értékeit egészen az optimum megtalálásáig. A 16/b ábra modellterbeli távolság – iterációs lépésszám görbéjén a $q\sim 100$ és a $q\sim 500$ iterációs lépésszámok között kapott három maximum egy-egy rétegvastagság érték megtalálásához kapcsolódó lokális minimumból való kiszabadulást szemléltet. A 17. ábrán látható, hogy $q\sim 500$ iterációs lépés után a rétegvastagságok értéke nem változik tovább, ezután már

csak a petrofizikai paraméterek konvergálnak az optimális értékeikhez. Az MMSA-H eljárás a távoli startmodell ellenére igen pontosan „visszatalált” a célmodell paramétereire (ld. 19. táblázat). A porozitás első rétegbeli értékét (POR1), az agyagtartalom első (VSH1), harmadik (VSH3) és negyedik rétegbeli értékét (VSH4) három tizedesjegy pontossággal egzaktul meghatározta. A válaszegyenletekre vonatkozó paraméter-érzékenységek e paraméterekre nézve nagyok (és valamennyi válaszegyenletben szerepelnek), így inverziós meghatározásuk kedvezőbb a többivel szemben és pontosságuk relatíve nagyobb (ld. 7. fejezet).



16. ábra

Az a, relatív adattérbeli távolság vs. iterációs lépésszám és a b, relatív modelltérbeli távolság vs. iterációs lépésszám alakulása MMSA-H inverzió folyamán



17. ábra

A rétegvastagságok változása az iterációs lépésszám függvényében MMSA-H inverzió folyamán

Réteg	H [m]	POR	SX0	SW	VSH	VSD
1	6.0	0.2003	0.7986	0.4014	0.3004	0.4898
2	2.0	0.1026	0.9985	0.997	0.7995	0.1021
3	8.0	0.2993	0.805	0.3019	0.1007	0.5982
4	4.0	0.0998	0.9951	0.9937	0.6000	0.3021

19. táblázat

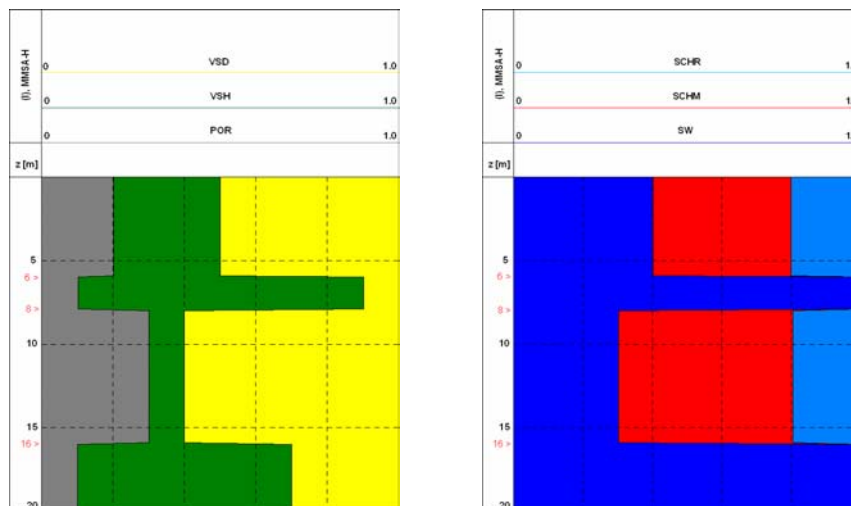
Az 5 %-os Gauss zajjal terhelt (I) adatrendszer MMSA-H inverziójával nyert paraméterek

A 18. ábrán a becsült rétegjellemzők szelvényei láthatók, melyek mélységskáláján piros számokkal az inverzióval meghatározott réteghatár-koordináták értékeit tüntettem fel. Megállapítható, hogy az MMSA-H eljárás a rétegvastagságokat egzaktul előállította ($H_1=6.0$ m, $H_2=2.0$ m, $H_3=8.0$ m). Ez a véletlen keresésnek köszönhető, mivel a linearizált módszerek esetén használt numerikus deriválás és a válaszegyenletek közelítéséből származó csonkítás globális inverzióval nem terheli hibával a becslést, így a rétegvastagságok igen pontosan előállíthatók. A becsült modellre (4.15) és (4.27) alapján $D_d=5.16$ % relatív adattérbeli- és $D_m=1.04$ % relatív modelltérbeli távolságok adódtak (ld. 20. táblázat).

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
399 %	61.50 %	5.16 %	1.04 %	00:39:40

20. táblázat

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer
MMSA-H inverziós eredményei



18. ábra

Az 5% Gauss zajjal terhelt (I) adatrendszer
MMSA-H inverziójával nyert petrofizikai paraméterek szelvényei
(A piros számok az inverzióval becsült réteghatár-koordinátákat jelölik)

6.2.2.1.2 Kiugró adatok inverziója MMSA-H módszerrel

A (II) adatrendszer ismeretlen rétegvastagságok melletti intervallum inverzióját két módszerrel végeztem: elsőként a (4.22) energiafüggvényből $\mu=2$, $\nu=0$ paraméterekkel, másodsor a $\mu=1$, $\nu=0$ paraméterek származtatott MMSA-H eljárással. E vizsgálatnak az volt a célja, hogy kimutassam, milyen mértékben javítható a rétegvastagságok és petrofizikai paraméterek együttes inverziója kiugró adatokat tartalmazó adatrendszerek esetén.


Az alkalmazott startmodell és a kontroll paraméterek értékei mindkét inverziónál megegyeztek. A (2.18) hűtést minden $q=200$. iterációban írtam elő. Az inverziók végrehajtása után hasonló viselkedést tapasztaltam, mint az (I) adatrendszer MMSA-H inverziója során. Amint az a 21. táblázatból kiderül a $\mu=1$, $v=0$ energiafüggvényt minimalizáló eljárás körülbelül kétszer jobb eredményre vezetett a másik módszerrel szemben. A kiugró adatok ugyanis a $\mu=2$, $v=0$ minimalizálást lelassították, míg a rezisztens $\mu=1$, $v=0$ módszernél a kiugró adatok nem befolyásolták a konvergenciát és jobb adat- és paramétertérbeli illeszkedést ért el ugyanannyi futási idő alatt.

(II) adatrendszer					
Algoritmus	$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
MMSA-H ($\mu=2, v=0$)	399 %	61.50 %	13.3 %	2.60 %	00:38:12
MMSA-H ($\mu=1, v=0$)			7.27 %	1.16 %	00:36:50

21. táblázat

Az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer MMSA-H inverziós eredményei

A kiugró adatok ellenére az inverziós eljárás stabil maradt, a modellparaméterek közül ebben az esetben is a rétegvastagságok értékeit határozta meg elsőként mindkét algoritmus (kb. $q=500$. iteráció környékén), továbbá azok egzakt értékét szolgáltatották. A 19. ábrán az MMSA-H ($\mu=1, v=0$) inverzióval becsült rétegpáraméterek szelvényei láthatók, melyen piros számokkal jelöltem az automatikusan meghatározott réteghatár-koordinátákat.



19. ábra

Az 5% Gauss + kiugró zajjal terhelt (II) adatrendszer MMSA-H ($\mu=1, v=0$) inverziójával nyert petrofizikai paraméterek szelvényei (A piros számok az inverzióval becsült réteghatár-koordinátákat jelölik)

6.2.2.2 Inverziós vizsgálatok FGA-H algoritmussal

A globális inverziós réteghatár-meghatározást a Valós Kódolású Genetikus Algoritmus alkalmazásával folytattam. Az FGA-H inverziós eljárás keretében a (4.23) fitness függvényt maximalizáltam MODELL-1 kőzetfizikai paramétereinek és rétegvastagságainak meghatározása érdekében.

Az FGA-H algoritmus maximális iterációs lépésszámát $q_{\max}=30000$ -nek választottam, ahol a kezdeti populációt $S=20$ véletlen modellel generáltam. Az alkalmazott valós genetikus operátorok kombinációját a normált geometriai rang szelekció, heurisztikus keresztezés és egyenletes eloszlású mutáció alkotta, valamint a reprodukciót elitizmussal kombináltam. A rétegvastagságokat valós számként értelmeztem, melyek zérustól különböző, valamint a szelvényezés mintavételi távolságától ($dz=0.1$ m) nagyobb értéket vehettek fel. Ez alapján a modellparaméterek (rétegvastagságok és kőzetjellemzők) keresési intervallumát a 22. táblázat szerint adtam meg. Az inverziós algoritmusba beépítettem az anyagmérleg egyenletet, mely tovább stabilizálta az eljárást.

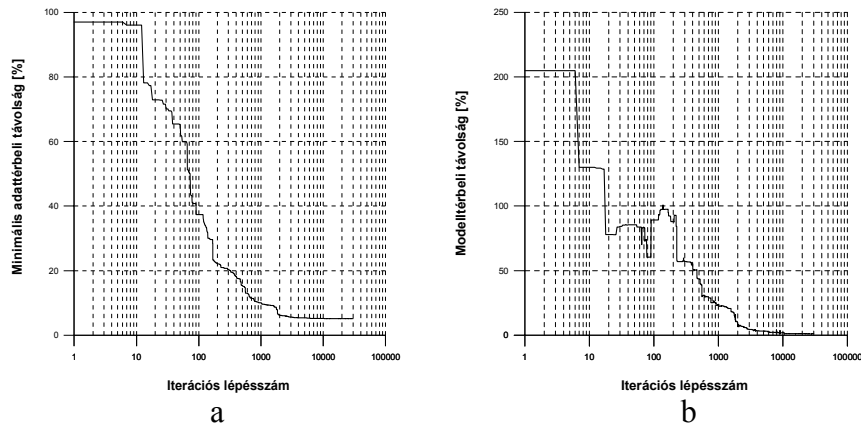
Paraméter	Minimum	Maximum
H_1	0.1	10.0
H_2	0.1	10.0
H_3	0.1	10.0
POR	0	0.5
SX0	0	1.0
SW	0	1.0
VSH	0	1.0
VSD	0	1.0

22. táblázat

A modellparaméterek keresési intervalluma
FGA-H inverzió során


Az FGA-H eljárás modellgenerációinak javulását a 20. ábrán kísérhetjük figyelemmel, ahol az aktuális iterációs lépésbeli maximális alkalmasságú egyedhez tartozó relatív adat- és modellterbéli távolság értékek olvashatók le. A 20/b ábrán a 0-200 generáció között a keresési eljárás több lokális minimumból való kiszabadulását láthatjuk, mely elsősorban a rétegvastagságok megtalálásához kapcsolódik. A módszer igen stabilnak bizonyult, mivel a rétegvastagságok a $q=119$. iterációs lépéssel bezárólag mind egzaktul felvették a célmodellben szereplő értékeiket (ld. 21. ábra). Az ezt követő iterációs lépésekben a petrofizikai paraméterek finomítása történt, melyet egyenletes konvergencia jellemzett a fitness függvény „globális” maximuma felé.

A 23. táblázat az FGA-H algoritmussal becsült eredménymodellre (4.15) és (4.27) alapján számított relatív adat-, és modellterbeli távolságokat mutatja. Az optimális modell szelvényeit külön nem mutatom be, ugyanis vizuálisan nem látható különbség azok és az MMSA-H eljárással becsült szelvények (ld. 18. ábra) között (mindkét eljárás globális optimumkeresést hajt végre). Megállapítható, hogy az FGA-H stabil és pontos becslést ad, azonban futási idő tekintetében kicsit hosszadalmas eljárás. Ennek oka a nagy iterációs lépésszám, illetve az, hogy az eljárás szimultán több modellt javít az optimumkeresés során.



20. ábra

Az a, relatív adattérbeli távolság vs. iterációs lépésszám és b, relatív modellterbeli távolság vs. iterációs lépésszám FGA-H inverzió folyamán



21. ábra

A rétegvastagság vs. iterációs lépésszám függvények

(I) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
96.94 %	204.7 %	5.16 %	1.09 %	01:48:02

23. táblázat

Az 5 %-os Gauss-zajjal terhelt (I) adatrendszer FGA-H inverziós eredményei

6.2.3 Rétegben vertikálisan változó petrofizikai paraméterek meghatározása

Az intervallum inverziós probléma nagymértékben túlhatározott. A 6.2.2 fejezetben láttuk, hogy a rétegvastagságokat inverziós ismeretlenek választva e jelentős túlhatározottság csak kismértékben csökkent, ezért az ismeretlenek száma elvileg még tovább növelhető. Az eddigi vizsgálatok a legegyszerűbb földtani modellen, a rétegenként homogén kőzetekből álló rétegsoron történtek. E modell paramétereit (4.8) sorfejtésben egységugrás bázisfüggvényekkel állítottam elő. Az intervallum inverziós módszer azonban lehetőséget nyújt sokkal összetettebb modellek, pl. nagyobb mélységintervallumon vagy akár egyetlen rétegben vertikális változást mutató kőzetfizikai paraméterek leírására is. Ehhez (4.8) sorfejtés számára alkalmas bázisfüggvény-rendszert kell választani. A vizsgálataim során a rétegjellemzők leírására hatványfüggvényeket alkalmaztam, és azok sorfejtésben szereplő együtthatóit az intervallum inverzió modellvektorába a többi ismeretlen mellé felvettem. Természetesen a bázisfüggvények fokszámának növelésével gyorsan nő az ismeretlenek száma, ezért az inverzió stabilitása és a paraméterbecslés pontossága érdekében törekedni kell azok redukálására.

Jelen vizsgálat keretében a globális optimalizáció startmodell-függetlenségét és stabilitását kihasználva, a homogén modell ismerete nélkül (a nulladfokú valamint az összes magasabb fokszámhoz tartozó tag sorfejtési együtthatója ismeretlen) kerestem az intervallum inverziós probléma megoldását.

6.2.3.1 Szintetikus adatrendszer generálása hatványfüggvények segítségével

A 5.1.1 fejezetben definiált MODELL-1 paramétereit (ld. 1. táblázat) megtartva a harmadik, szénhidrogén-tároló réteg fontosabb modellparamétereit (porozitást, víztelítettséget, agyagtartalmat) a (4.24) sorfejtés alkalmazásával negyedfokú hatványfüggvényekkel közelíttem, amely újabb 15 ismeretlent (sorfejtési együtthatót) jelentett. E mellett a harmadik réteg kiseper zónájának víztelítettsége egy újabb ismeretlent jelent. A VSD paramétert az inverziós ismeretlenek köréből „felszabadítva”, a (3.11) egyenlet felhasználásával determinisztikusan számítottam. Az új inverziós célmodellt MODELL-2-nek neveztem el, melynek paramétereit a 24. táblázatban és 23/a - 24/a ábrán láthatók. A MODELL-2 harmadik rétegében a petrofizikai paramétereket a következő mélységfüggvények szerint vettem fel

$$\left. \begin{aligned} f_1(z) &= -0.3994z^4 + 1.6782z^3 - 2.3931z^2 + 1.2711z + 0.1014 \\ f_2(z) &= 0.4902z^4 - 2.2032z^3 + 3.6155z^2 - 2.3423z + 0.7735 \\ f_3(z) &= 1.3195z^4 - 5.7097z^3 + 8.1082z^2 - 3.9980z + 0.7379 \\ f_4(z) &= 1 - f_1(z) - f_3(z) \end{aligned} \right\} (Z_2 \leq z < Z_3) .$$

A sorfejtés során az $f(z)$ hatványfüggvények mélységkoordinátáit a $8.0 \leq z < 16.0$ m intervallumból a $0 \leq z < 5.0$ intervallumba ($dz=0.0625$ mintavételi távolság mellett) transzformáltam. Ezzel lehetőség nyílt a sorfejtési együtthatók értékeinek több nagyságrenddel való csökkentésére, mely az inverzió stabilitását jelentősen növeli. Az inverzió során a direkt feladat ismételt alkalmazásakor a $0 \leq z < 5.0$ intervallumban történő sorfejtés végrehajtásával kapott petrofizikai paramétereket a harmadik réteg mélységtartományához rendeltem.

H(m)	POR	SX0	SW	VSH	VSD
6.0	0.2	0.8	0.4	0.3	0.5
2.0	0.1	1.0	1.0	0.8	0.1
8.0	$f_1(z)$	0.8	$f_2(z)$	$f_3(z)$	$f_4(z)$
4.0	0.1	1.0	1.0	0.6	0.3

24. táblázat

MODELL-2 négyréteges inverziós célmodell

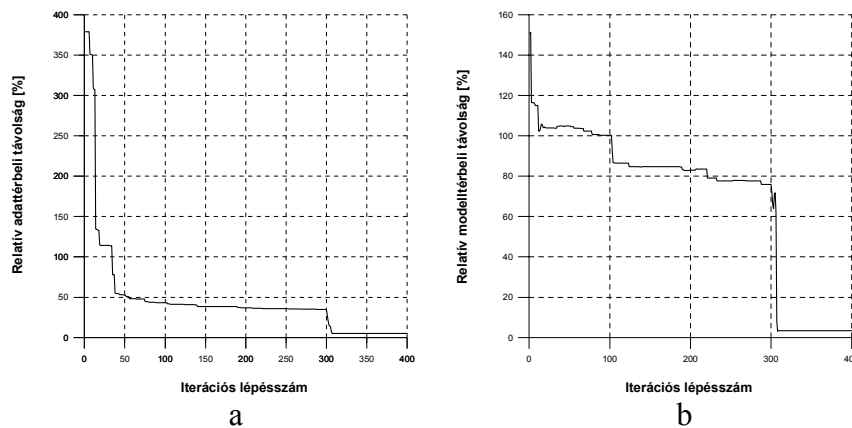
A zajjal terhelt szintetikus szelvényadatokat MODELL-2 alapján (3.3)-(3.9) elméleti szonda-válaszegyenletek felhasználásával $dz=0.1$ m mintavételi közszelvényekkel számítottam. A szelvénykonstansok értékeit a 4. melléklet tartalmazza. A szintetikus szelvényeket 5 %-os, Gauss-eloszlásból származó hibával terheltem, mely sorrendben a (VI) bemenő adatrendszert képezi. Az inverzió bemenő szelvényeit a 7. melléklet tartalmazza.

6.2.3.2 Az FGA+DLSQ-I kombinált inverziós módszer alkalmazása

A 4.2 fejezetben bevezetett FGA+DLSQ-I (globális és linearizált optimalizáció kombinációján alapuló intervallum inverziós) eljárást használtam fel MODELL-2 paramétereinek meghatározására. A megoldás jóságát (4.3) és (4.25) mérőszámokkal jellemeztem.

Az algoritmust kezdetben FGA-I eljárással indítottam $S=30$ véletlen modelltől álló kezdeti populációval. A sorfejtési együtthatók keresési intervallumát $-1 \leq B \leq 1$ szerint adtam meg. A genetikus operátor-kombináció versenyszelekcióból (500 ismétlésszám mellett), heurisztikus keresztezésből és egyenletes eloszlást követő mutációból állt. A reprodukció műveletét elitizmussal vettem figyelembe. Az FGA-I optimalizációt $q=300$. iterációs lépés után váltottam fel DLSQ-I módszerre. A 22. ábrán látható, hogy a relatív modellterbeli távolság e lépés után ugrásszerűen lecsökkent. Ennek legfőbb oka a harmadik rétegbeli sorfejtési együtthatók helyes kombinációjának megtalálása. A linearizált optimalizáció során ugyanis a sorfejtési együtthatók keresési intervallumát (az optimum környékén) már nem korlátoztam, azonban a globális inverzióban erre azért volt szükség, nehogy nagyon eltávolodjunk a modellterben a megoldástól és elveszzen a véletlen keresés hatékonysága.

Az FGA+DLSQ-I kombinált inverziós módszerrel becsült modellparaméterek pontosságát a 25. táblázaton keresztül vizsgálhatjuk. A startmodell $D_{d,0}=375$ %-ot meghaladó relatív adattérbeli távolsága ellenére az inverziós eljárás konvergensenek bizonyult. E távoli kiindulási modell mellett (mely a sorfejtési együtthatók értékeinek véletlen generálásából adódik) optimális megoldást kaptunk, valamint a harmadik rétegben jó közelítéssel ugyanazt a sorfejtési együttható kombinációt kaptuk eredményül, melyek MODELL-2-ben szerepeltek. A becsült petrofizikai paraméterek és sorfejtési együtthatók, valamint azok hibái a 26. táblázatban találhatóak (ahol VSD paraméter a harmadik rétegben nem inverziós ismeretlen). Megállapítható, hogy a hiba mértéke a homogén rétegekben igen kicsi, illetve a fizikai jelentéssel nem rendelkező sorfejtési együtthatók hibája is kis mértékű.



22. ábra

A a, relatív adattérbeli távolság vs. iterációs lépésszám és
b, relatív modelltérbeli távolság vs. iterációs lépésszám
FGA+DLSQ-I inverzió folyamán

(VI) adatrendszer				
$D_{d,0}$	$D_{m,0}$	D_d	D_m	t
378.9 %	150.7 %	5.21 %	3.47 %	00:06:57

25. táblázat

Az 5 %-os Gauss-zajjal terhelt (VI) adatrendszer
FGA+DLSQ-I inverziós eredményei

A 23. és 24. ábrák az ismert és a becsült modell összehasonlítását teszik lehetővé. Látható hogy az eredményszelvények igen jól illeszkednek egymásra. A tárolójellemzők rétegbeli változását a harmadik rétegben pontosabban írtuk le, mint rétegben homogén petrofizikai paramétereket feltételezve. Látható pl., hogy a szénhidrogén-tároló rétegben a $z=12-14$ m közötti agyagtartalom-növekedést, és a $z=14$ m-től a nagyobb mélységek felé történő víztartalom-növekedést egységugrás-függvényekkel nem, vagy csak további alrétegek (további ismeretlenek) bevezetésével tudnánk csak meghatározni.

A becsült paraméterek megbízhatósága a 8. melléklet táblázatát alkotó korrelációs mátrix elemein keresztül vizsgálható. A (4.17) alapján számított $S=0.29$ korrelációs átlag a paraméterek elfogadhatóságát tükrözi. A harmadik rétegben azonban észrevehető néhány 1-hez közeli korrelációs együttható is. Ez a mélységkoordináta magasabb hatványait befolyásoló sorfejtési együtthatók között fordul elő, pl. a harmadik réteg porozitása esetén $\text{corr}(B_4, B_5)=0.99$. E szoros kapcsolat a kisebb kitevők esetén lazul, pl. $\text{corr}(B_1, B_5)=-0.52$. Mivel a hatványfüggvények nem ortogonális függvényrendszert képeznek, ezért sokféle sorfejtési együttható kombináció képes leírni ugyanazt a petrofizikai paramétert. Látható, hogy ez a jelenség a petrofizikai paraméterek harmadik rétegbeli finom változásait leíró, a mélységkoordináta magasabb hatványai esetén fordulnak elő. Ezzel együtt az inverzió megbízhatónak bizonyult, és e probléma szükség esetén javítható ortogonális függvényrendszerek szerinti sorfejtéssel, pl. Legendre-polinomokkal. Látható még, hogy az első, második és negyedik homogén rétegben, továbbá a harmadik rétegben a sorfejtési együtthatók és a konstans SX0 kapcsolatát leíró korrelációs együtthatók igen kicsik, még a teljes korrelálatlanság is előfordul a harmadik rétegbeli víztelítettségek (SX03 és SW3_B5) között.

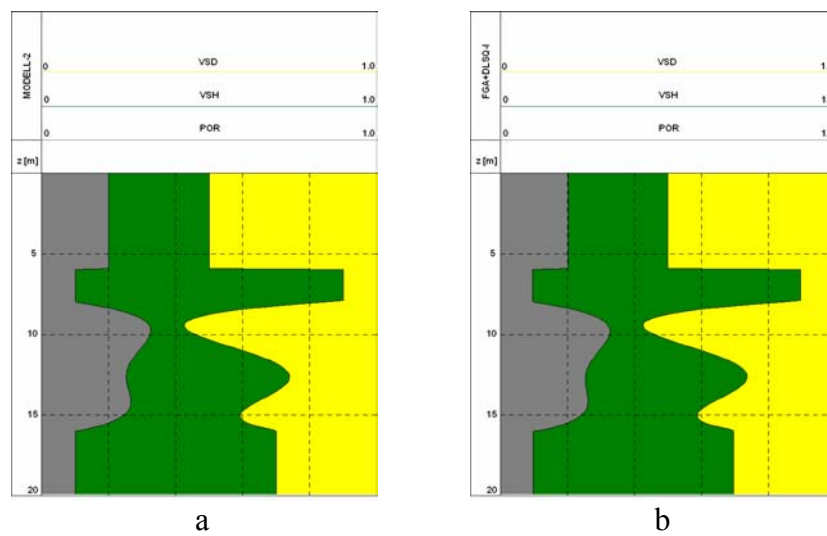
Réteg	B	POR	SX0	SW	VSH	VSD
1	-	0.2003 (±0.0020)	0.8063 (±0.0046)	0.4002 (±0.0022)	0.2980 (±0.0029)	0.4978 (±0.0047)
2	-	0.0954 (±0.0037)	1.0000 (±0.0069)	1.0000 (±0.0095)	0.7998 (±0.0022)	0.1032 (±0.0080)
3	B ₁	0.0991 (±0.0075)	0.8042 (±0.0034)	0.7608 (±0.0109)	0.7377 (±0.0079)	-
	B ₂	1.2582 (±0.0530)		-2.2391 (±0.0629)	-3.9884 (±0.0552)	
	B ₃	-2.3170 (±0.1142)		3.3857 (±0.1222)	8.0646 (±0.1195)	
	B ₄	1.5956 (±0.0895)		-2.0142 (±0.0924)	-5.6695 (±0.0945)	
	B ₅	-0.375 (±0.0229)		0.4397 (±0.0236)	1.3088 (±0.0244)	
4	-	0.0964 (±0.0024)	1.0000 (±0.0052)	1.0000 (±0.0066)	0.5981 (±0.003)	0.2987 (±0.0057)

26. táblázat

Az 5 %-os Gauss-zajjal terhelt (VI) adatrendszer
FGA+DLSQ-I inverziójával becsült paraméterek és hibáik

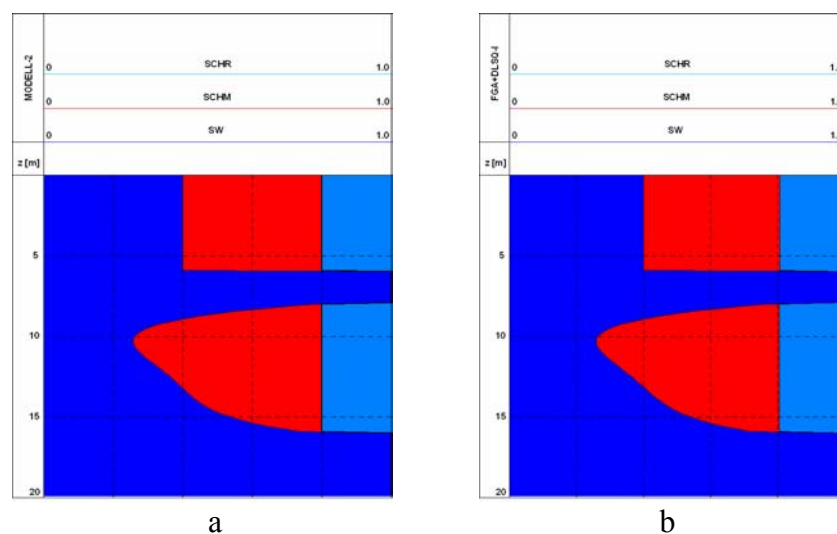
Ebben a fejezetben a mélyfűrési geofizikai adatok feldolgozását új, linearizált és globális optimalizáción alapuló intervallum inverziós eljárásokkal (DLSQ-I, LAD-I, MMSA-I, FGA-I) végeztem el. Végrehajtottam a petrofizikai paraméterek és réteghatár-koordináták szimultán

meghatározását új, globális optimalizáción alapuló intervallum inverziós algoritmusokkal (MMSA-H, FGA-H), majd rezisztens MMSA-H eljárást fejlesztettem, mely javította a hagyományos MSA módszer kiugró adatokkal szembeni érzékenységét, valamint növelte a konvergencia sebességet. Az intervallum inverzió keretein belül először rétegenként homogén modellen, majd intervallumon vertikálisan változó petrofizikai paraméterek meghatározása céljából hatványfüggvény szerinti sorfejtésen alapuló intervallum inverziós eljárást alkalmaztam. Az FGA+DLSQ-I kombinált inverziós algoritmussal a valós kódolású genetikus algoritmus konvergencia-sebességét egy nagyságrenddel növeltem, valamint a becsült paraméterek hibájának és megbízhatóságának egyetlen inverziós futtatásból történő számítását valósítottam meg.



23. ábra

Az a, MODEL-2 ismert porozitás, agyag- és homoktartalom és b, az FGA+DLSQ-I inverzióval nyert porozitás, agyag- és homoktartalom szelvények



24. ábra

Az a, MODEL-2 ismert szaturációs és b, az FGA+DLSQ-I inverzióval nyert szaturációs szelvények

7. ÉRZÉKENYSÉGI FÜGGVÉNYEK VIZSGÁLATA ÉS INVERZIÓS ALKALMAZÁSA

Az inverz feladat megoldásánál érdemes figyelembe venni azt a tényt, hogy a petrofizikai paraméterek szonda-válaszfüggvényekre gyakorolt hatása különböző. E hatások mértékét az ún. paraméter-érzékenységi függvényeken keresztül vizsgálhatjuk. A válaszgyenletek érzékenysége arról tájékoztat, hogy a közetfizikai paraméterek egyedi megváltozása milyen mértékben befolyásolja a számított szelvényadatok értékét. Az érzékenységi függvények felszíni geofizikai alkalmazását DOBRÓKA (1988) vezette be telephullámok abszorpciós-diszperziós tulajdonságainak vizsgálatánál, majd GYULAI (1995) a geoelektromos gyakorlatban széles körben alkalmazta. E munkák alapján képeztem a (3.3)-(3.10) mélyfúrású geofizikai válaszfüggvényekre vonatkozó érzékenységi függvényeket. A (2.3) egyenlet mellett a j -edik elméleti szonda-válaszfüggvény i -edik petrofizikai paraméterre vonatkozó érzékenységét

$$\psi_i^{(j)} = \frac{\partial g^{(j)}(\vec{m})}{\partial m_i} \cdot \frac{m_i}{g^{(j)}(\vec{m})} \quad (7.1)$$

dimenziótlan mennyiséggel definiáltam. E mennyiségek számítása diszkrét adatrendszer esetén úgy történik, hogy kiválasztunk egy petrofizikai paramétert és annak értékét egy kis pozitív számmal megnöveljük, úgy, hogy a többi paraméter értéke változatlan maradjon, majd numerikus differenciálással származtatjuk az adott szelvénynek a kiválasztott paraméterre vonatkozó érzékenységét a paraméter lehetséges értékeinek tartományában.

Az inverziós eljárásban az eltérő paraméter-érzékenységek következménye az, hogy az iterációs lépések során az adattérbeli változásokra érzékeny paramétereket nem tudják követni a kevésbé érzékeny paraméterek. Általában az érzékenyebbek gyorsabban konvergálnak, míg a kevésbé változékonyak lemaradnak, mely linearizált inverziónál lokális minimumban való stabilizálódást okozhat. A tapasztalat azt mutatja, hogy a válaszgyenletekből számított adatok azokra a paraméterekre reagálnak a legérzékenyebben melyek a legtöbb válaszfüggvényben jelen vannak, és melyekre a (7.1) paraméter-érzékenységi függvény értéke nagy. Ugyanezen paraméterek meghatározása inverziós szempontból is kedvezőbb. Azokat a paramétereket, melyek alig befolyásolják a szelvényértékeket, érdemes más módszerrel vagy determinisztikus úton meghatározni. Az inverzió során ezek értékét végig ismertnek feltételezve, javíthatjuk a többi paraméterre vonatkozó inverzió pontosságát. Az inverziós ismeretlenek mellett a válaszgyenletek texturális, zónális és egyéb szelvénykonstansokra vonatkozó paraméter-érzékenységei is eltérők. Nagy érzékenységek, pl. a kevésbé megbízható függvénykonstansok (cementációs és szaturációs kitevő, tortuozitási együttható, kompakciós tényező stb.), melyek nemlineáris kapcsolatban vannak a szelvényadatokkal, így nagymértékben el-

ronthatják az inverziós eredményeket. FERENCZY (1995) szerint a válaszfüggvények konstansokra vonatkozó érzékenysége a legnagyobb mértékben a nemlineáris és különböző előjelű konstansokkal rendelkező válaszegyenleteknél jelentkezik elsősorban a kis- és nagy porozitás tartományában. A fentiek alapján levonhatjuk azt a következtetést, hogy az előzetes érzékenységi vizsgálatok elvégzése után az inverzió hatékonyabban végrehajtható, pontosabb paraméterbecslés valósítható meg az inverziós ismeretlenek megfelelő megválasztásával.

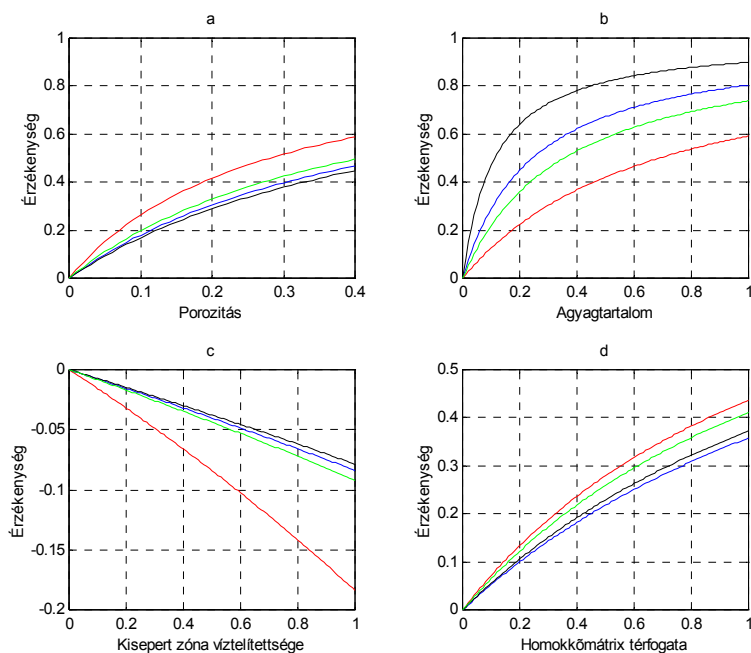
A paraméterérzékenységi vizsgálatokat (3.3)-(3.9) válaszegyenleteken, MODELL-1 paramétereire vonatkozóan végeztem. A (7.1) formulát numerikus differenciálással számítottam

$$\Psi_{ij} = \frac{d_j^{(sz)}(m_i + h) - d_j^{(sz)}(m_i)}{h} \cdot \frac{m_i}{d_j^{(sz)}(m_i)}, \quad (7.2)$$

ahol Ψ_{ij} a d_j -edik számított szelvényadat m_i -edik petrofizikai paraméterre vonatkozó érzékenysége, és a $h=0.01$ növekmény a modellparaméterek $\Delta m=1$ %-os megváltozását írta elő.

Az inverziós ismeretlenekre nézve lineáris válaszegyenletekre (SPTH, DETH, ATTH) vonatkozó paraméter-érzékenységek a paraméterek értékének növekedésével, a függvénykonstansok értékeitől és a kőzetek összetételétől függően, különböző mértékben növekednek. Az érzékenységi függvény monoton csökkenése a negatív ordináta-tengely irányában ugyanúgy az érzékenység növekedését jelenti, azonban az adatok és a térfogatjellemző paraméterek ellentétes irányú változására enged következtetni. A (3.4) természetes potenciálszelvény agyagtartalom érzékenysége az agyagtartalom monoton növekvő (nemlineáris) függvénye, ahol az érzékenység az agyagtartalom növekedésével negatív irányban ugrásszerűen nő. A (3.3) természetes gamma szelvény paraméter-érzékenységei monoton növekvő (nemlineáris) függvények. A GR szelvény elsősorban a kőzetmátrix és az agyag mennyiségére érzékeny, mivel a gamma sugarak elnyelése a kőzetvázban a legintenzívebb. E két szelvényt litológiai tagolásra alkalmazzuk, mivel nagy agyagtartalom érzékenységük miatt kiváló agyagindikátorok. A (3.5) sűrűség-szelvény porozitás érzékenysége nemlineáris növekvő függvénye a porozitásnak, mely a közepes porozításoknál már a maximális érzékenységhez tart, ennek megfelelően közepes, de inkább nagy porozitású képződmények esetén a legalkalmasabb a módszer a hézagterfogat meghatározására. E monoton növekvési trendet követi a (3.6) neutronporozitás szelvény porozitás-érzékenysége is a $POR > 2$ % tartományban, azonban $POR < 2$ % esetén a porozitás-érzékenység a porozitás csökkenésével nullára csökken. Ennek az az oka, hogy a beérkező neutronok számát ebben a tartományban egyre inkább a kőzetmátrix befolyásolja, és még a porozitás hatása nem számottevő (a neutronszelvényénél általában 1-2 % a mérési hiba nagyságrendje is).

A térfogatjellemző petrofizikai paraméterekre nézve lineáris válaszfüggvények közül példaként bemutatom (3.7) akusztikus válaszfüggvény paraméter-érzékenységi függvényeit. A 29. ábrán eltérő színű görbék az akusztikus szelvény MODELL-1 paramétereire vonatkozó (7.2) alapján számított paraméter-érzékenységeit külön mutatják a modell egyes rétegeiben. Látható, hogy a porozitás és agyagtartalom érzékenysége monoton növekvő függvénye a porozitásnak ill. az agyagtartalomnak. Az agyagtartalomra vonatkozó érzékenység a szénhidrogén-tárolóban a legnagyobb, mely abból a szempontból kedvező, hogy a szennyező agyag mennyiségét pontosan meg tudjuk határozni a produktív zónában. Viszont a víztelítettség szemben mutatott relatíve kisebb érzékenység arra utal, hogy az agyagtartalom a pórusrésben található fluidumok mennyiségi meghatározását nehezíti. Az akusztikus szelvény porozitás-érzékenysége nagy (porozitáskövető szelvény), viszont ebben a szintetikus példában a szénhidrogén-tároló rétegben legkisebb a porozitás-érzékenység.




25. ábra

Az akusztikus terjedési idő szelvény porozitás-, agyagtartalom-, víztelítettség-, homoktartalom érzékenységi függvényei. Jelölések: MODELL-1 1. réteg (piros vonal), 2. réteg (kék vonal), 3. réteg (fekete vonal), 4. réteg (zöld vonal)


A nemlineáris válaszfüggvények (GRTH, KTH, UTH, THTH, PORNTH, RMLLTH, RLLDTH) közül tekintsük példaként a (3.8)-(3.9) fajlagos ellenállás válaszegyenleteket, melyek egymással hasonló viselkedést mutatnak. Az agyagtartalom érzékenységük $VSH \sim 45\%$ körül maximumot mutatnak, melyet a 26. ábrán a mélybehatolású laterolog szondára vonatkozó nemlineáris agyagtartalom érzékenységi függvényről olvashatunk le. Természetesen a válaszfüggvényekre vonatkozó paraméter-érzékenységek több dimenzióban is vizsgálhatók. A

27. ábrán a mikrolaterolog szelvény két tárolójellemzőre (porozitás, agyagtartalom) vonatkozó érzékenységi függvényét ábrázoltam.



26. ábra

A mélybehatolású laterolog szelvény porozitás-, víztelítettség-, agyagtartalom-érzékenységi függvényei. Jelölések: MODELL-1 1. réteg (piros vonal), 2. réteg (kék vonal), 3. réteg (fekete vonal), 4. réteg (zöld vonal)



27. ábra

A mikrolaterolog szelvény agyagtartalom érzékenységi függvénye a gyakorlati porozitás és agyagtartalom tartományban

A fenti érzékenységi vizsgálatok rámutatnak arra, hogy a mélyfúrési geofizikai válaszfüggvények petrofizikai paraméterekkel szemben mutatott érzékenysége eltérő (az egyes paraméter tartományokban). Ez a jelenség természetesen hatással van az inverzió kimenetelére. A következő példában linearizált inverziós eljárást alkalmazva szeretném igazolni azt az állí-

tást, miszerint az inverziós célmodellt relatíve nagy érzékenységgű paraméterekkel definiálva, jobb az inverzióval becsült modell alapján számított és mért szelvényadatok illeszkedése, mint a kisebb érzékenységgű paraméterekkel felépített modell esetén. Ebből a célból két négyréteges modellt állítottam fel, melyek csak a harmadik réteg összetételében különböznek. A 27. táblázatban definiált MODELL-3 harmadik rétegét nagy agyagtartalom jellemzi. Láttuk, hogy a mélyfúrési geofizikai válaszfüggvények alapján számított szelvényadatokat az agyagtartalom általában nagymértékben befolyásolja, nagy az agyagtartalom érzékenységgük. Ha a (3.3)-(3.9) válaszfüggvények alkalmazásával $\Delta m=1\%$ -kal megváltoztatom MODELL-3 minden paramétereit, külön-külön egymás után kiszámítva (7.2) deriváltakat, az azokból kapott összes szelvényre vonatkozó átlagos paraméter-érzékenység abszolút értéke $\Psi=0.81$. A 28. táblázatban megadott MODELL-4 harmadik rétegéhez kis agyagtartalmat rendeltem, ennek megfelelően az átlagos abszolút érzékenység csak $\Psi=0.59$.

H(m)	POR	SX0	SW	VSH	VSD
6.0	0.15	1.0	1.0	0.40	0.45
2.0	0.10	1.0	1.0	0.50	0.40
<u>8.0</u>	<u>0.03</u>	<u>1.0</u>	<u>1.0</u>	<u>0.87</u>	<u>0.10</u>
4.0	0.15	1.0	1.0	0.40	0.45

27. táblázat

MODELL-3 négyréteges inverziós célmodell

H(m)	POR	SX0	SW	VSH	VSD
6.0	0.15	1.0	1.0	0.40	0.45
2.0	0.10	1.0	1.0	0.50	0.40
<u>8.0</u>	<u>0.09</u>	<u>1.0</u>	<u>1.0</u>	<u>0.11</u>	<u>0.80</u>
4.0	0.15	1.0	1.0	0.40	0.45

28. táblázat

MODELL-4 négyréteges inverziós célmodell

Az inverziós vizsgálathoz szintetikus szelvényadatokat számítottam, a MODELL-3 paramétereinek alapján a VII. számú, majd MODELL-4 alapján a VIII. számú adatrendszerrel. Ezeket külön-külön 6 %-os, Gauss-eloszlásból származó véletlen zajjal terheltem. Az inverziós kísérletet mélységpontenkénti, csillapított legkisebb négyzetek módszerén (DLSQ-P) alapuló eljárással végeztem el, melynek eredményeként kapott (4.5) átlagos adattérbeli és (4.6) modell-térbeli távolságokat a 29. táblázatban találhatjuk. A kezdeti modell-távolság nem túl távoli startmodellt feltételez. Látható, hogy a $D_{d,3}$ harmadik rétegben számított relatív adattérbeli és $D_{m,3}$ modell-térbeli távolság tekintetében a két eredménymodell nagymértékben különbözik


egymástól. MODELL-3 esetén a relatív adattérbeli és modelltérbeli távolságok értéke a négy rétegre vonatkozó átlagértéknél kisebb a harmadik rétegben, míg MODELL-4 esetén nagymértékben meghaladják azokat.

Modell	$D_{d,0}$	$D_{m,0}$	D_d	D_m	$D_{d,3}$	$D_{m,3}$
MODELL-3	75.0 %	15.0 %	6.71 %	2.18 %	6.39 %	2.05 %
MODELL-4	75.0 %	15.0 %	10.43 %	2.26 %	15.93 %	2.39 %

29. táblázat

A (VII) és (VIII) adatrendszeren végzett DLSQ-P inverzió eredményei

A DLSQ-P inverziós eljárással nyert modellek relatív adattérbeli és modelltérbeli távolságainak mélységi eloszlását a 28. ábra mutatja. A 28/a ábrán szembevetendő, hogy MODELL-4 közelítése esetén a harmadik rétegben a pontbeli megoldásokhoz relatíve nagy adattérbeli távolság tartozik. Itt az inverzió pontatlanabb paramétereket adott. Nyilvánvaló, hogy a kisebb érzékenységű paraméterek a harmadik rétegben lokális minimumba terelték a linearizált algoritmust, míg MODELL-4 harmadik rétegében a nagyobb érzékenységű paraméterek gyorsabban és valószínűleg egyszerre felvehették optimális értéküket. Megállapítható, hogy a becült paraméterek pontossági mérőszámai tükrözik az eltérő paraméter-érzékenység okozta hibát.



28. ábra

Az a, adattérbeli távolság-mélység b, modelltérbeli távolság-mélység függvény DLSQ-P inverzió esetén. Kék vonal: MODELL-3, fekete vonal: MODELL-4.

Ebben a fejezetben a mélyfúrési geofizikai elméleti szonda-válaszfüggvények petrofizikai paraméterekre vonatkozó érzékenységét definiáltam és vizsgáltam. Meghatároztam a (3.3)-(3.9) elméleti szonda-válaszfüggvényekre vonatkozó paraméter-érzékenységi függvényeket a porozitás, víztelítettség, agyagtartalom, és a homoktartalom tekintetében. Linearizált pontonkénti inverziós eljárással kimutattam a paraméter-érzékenység és az inverziós ismeretlenek meghatározhatóságának kapcsolatát.

8. TEREPI ADATOK INVERZIÓJA

A terepi adatok kiértékelését pontonkénti és intervallum inverziós módszerek alkalmazásával végeztem el (ld. 4. fejezet). Az 5. és 6. fejezetben szerzett inverziós tesztelési tapasztalatok alapján globális és kombinált inverziós módszereket választottam a fúrólukban mért szelvények feldolgozására.

8.1 AZ INVERZ FELADAT BEMUTATÁSA

Az inverziós kiértékelés bemenő adatrendszerét egy magyarországi szénhidrogén-kutató fúrásban (Fúrás-1) mért karotázs szelvények adatai képezték, melyet a MOL Rt. Petrofizika bocsátott rendelkezésemre. Először mélységpontonkénti inverziót hajtottam végre, majd a vizsgált mélységintervallum adatain intervallum inverziós kiértékelést végeztem. Ez utóbbi módszerrel automatikus rétegvastagság-meghatározás is történt, továbbá az egyik tároló kőzetben hatványfüggvény szerinti sorfejtést alkalmazva vertikálisan változó petrofizikai paramétereket számítottam.

A Fúrás-1-ben kiválasztott négy réteges összlet (melyben a szelvények szénhidrogén-tárolást indikáltak) a földtani jelentés alapján a felső-pannonban (pliocén) helyezkedik el. Oldalfalmintavétel és furadékvizsgálatok szerint a porózus, permeábilis rétegek jó tárolóképességgel rendelkező mederhomokkővek, melyekben helyenként aleurit csíkok, és padok vannak. A homokkő világosszürke, apró illetve finomszemű, laza, közepesen osztályozott és lekerekített szemcsézetű. Az aleurit világos-, középszürke, szürkés-zöld színű, puha, finomhomokos, aprócsillámos összetételű. A vékonycsiszolatban dominánsan homokkő (durva aleurit) látható. A rétegtartalom gáz (metán, etán, propán, valamint kis mennyiségű CO₂), olajfázis nincs. A homokkővek később a termelés során éghető gázt és párlatot adtak. A fúrólukat hagyományosan mélyítették (vertikális fúrás), kálium-klorid tartalmú iszappal öblítették, melynek sűrűsége $DEM=1.12 \text{ gcm}^{-3}$ volt.

A vizsgált szakaszon a mérés maximális szelvényezési program szerint történt, ahol a szelvények a természetes potenciál és a mikrolaterolog kivételével kvantitatív értelmezésre alkalmasnak bizonyultak. A természetes potenciált az alkalmazott fúróiszap SP kialakulására vonatkozó kedvezőtlen tulajdonságai miatt alkalmatlannak találtam kvantitatív interpretációra, illetve a mikroellenállás szelvényt terhelő nagy hibák következtében nem lehetett felhasználni SX0 számítására. A mérési anyagból így a következő korrigált szelvényeket használtam fel az inverziós kiértékelés számára: GAMMA RAY [API] természetes gamma, KÁLIUM [%] kálium spektrális gamma, URÁN [ppm] urán spektrális gamma, THÓRIUM [ppm] tóri-

um spektrális gamma, RT [ohmm] valódi fajlagos ellenállás, CDL [gcm^{-3}] kompenzált sűrűség (Lithodensity), CNL [%] kompenzált neutron, AT [$\mu\text{s/l}$] akusztikus terjedési idő. A vizsgált szakasz mélységre illesztett és lyukhatásra korrigált (0-18.1 m közé transzformált) szelvényei képezik az inverziós vizsgálatok bemenő adatrendszerét. A IX. karotázs adatrendszer szelvényei a 29. ábrán láthatók. A szelvényeken elkülöníthető rétegeket közetfizikai jellegük-nél fogva egy zónába soroltam, melyek litológiai leírása a kisebb mélységtől a nagyobb felé haladva: agyag, gáztároló homokkő, agyag, majd ismét gáztároló homokkő. A litológiai leírást és a gáztárolást a 9. melléklet neutron-porozitás - sűrűség, sűrűség - akusztikus terjedési idő, kálium - tórium, és kálium - urán crossplot-jai is alátámasztják. A crossplot-okon jól látható az egymátrixú kőzettani összetétel, a száraz illetve shale-agyag tartománya, valamint a gázhatás. A kiértékelés során az összletben a következő jellemzőket tekintettem inverziós ismeretlennek: POR (effektív porozitás), SX0 (kisepert zóna víztelítettsége), SW (érintetlen zóna víztelítettsége), VSH (agyagtartalom), VSD (homok fajlagos térfogata).

A direkt feladat megoldása során (3.3)-(3.10) válaszegyenleteket alkalmaztam. Az egyenletek közül módosításra csak az AT és CNL szelvények szorultak, az előbbit kompaktióra, az utóbbit exkavációs hatásra korrigáltam. A mért adatok és a tárolójellemzők kapcsolatát leíró lokális válaszegyenletekben lévő szelvénykonstansokat crossplot technikával, illetve ismert számítási eljárásokkal, a kútkönyvi és magadatokkal összevetve határoztam meg. A terepi konstansok értékei a 10. mellékletben találhatóak.


Fúrás-1 szelvényeinek interpretációját a szolnoki MOL Rt. Petrofizikán már korábban elvégezték, a Baker Atlas EXPRESS - CLASS determinisztikus elven működő agyagos homokkőtároló értelmező programjával. Ezen eredményekkel vettem össze később saját inverziós eredményeimet. A 11. mellékletben Fúrás-1 egy nagyobb, potenciális szénhidrogéntároló szakaszának a CLASS programmal kiértékelt kompozit szelvénye látható, melyen az általam vizsgált négy réteg az xy00 m környezetében, a mélységskálán szürkével jelölt mélységintervallumban helyezkedik el. E rövid áttekintés után végezzük el IX. adatrendszeren az inverziós vizsgálatokat.

8.2 MÉLYSÉGPONTONKÉNTI INVERZIÓS VIZSGÁLATOK

A Fúrás-1-ben mért (IX) adatrendszer mélységpontenkénti inverzióját a DLSQ-P és az MMSA-P ($\mu=1$, $\nu=0$) algoritmussal végeztem el. Az inverz feladat kismértékben túlhatározott, mivel pontonként $N=8$ adatból $N=5$ modellparamétert kellett meghatároznom (ld. 8.1 fejezet).

A DLSQ-P eljárást mélységpontonként $q_{\max}=50$ iterációs lépésszámmal futtattam, a szintetikus teszteknel alkalmazott csillapítási tényező mellett. A numerikus differenciálást

$h=0.001$ növekmény mellett végeztem. Az MMSA-P algoritmus maximális iterációs lépésszámát $q_{\max}=10000$ -nek választottam, ami tekintélyesen megnövelte a futási időt a linearizált módszerhez képest. A kezdeti hőmérsékletet $T_0=10^{-5}$ -ről (2.18) hűtési szabály szerint lassan csökkentettem. A maximális paraméterváltoztatás lépésenként $b_{\max}=0.1$ volt, melyet $q=1000$ lépésenként 85 %-kal csökkentettem. A véletlen keresés során szükség volt az anyagmérleg és a víztelítettségekre vonatkozó tapasztalati szabályozó egyenletekre.



29. ábra

Fúrás-1-ben mért (IX) számú karotázs adatrendszer szelvényei

A DLSQ-P és MMSA-P módszerrel végzett pontonkénti inverziós eredményeket a 30. táblázatban hasonlíthatjuk össze. Itt látható, hogy a globális optimalizáció az adattérben körülbelül 1 %-kal pontosabb paraméterbecslést hajtott végre, azonban ehhez jelentős futási időtöbbletre van szükség (a modell-távolság az egzakt modell hiányában nem számítható).

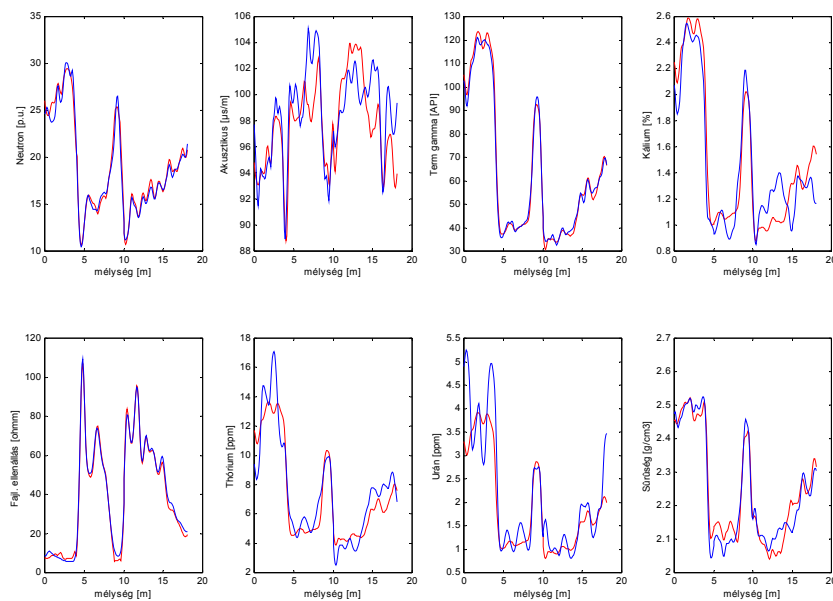
Tekintsük az MMSA-P inverziós eredményeket. A teljes intervallumon végzett pontonkénti futtatások eredményeképpen ábrázolhatjuk, hogy hogyan illeszkednek a becsült petrofizikai paraméterek alapján számított szondaadatokat a valódi mért szelvényadatokra. A 30. ábrán kék vonallal ábrázoltam a (IX) adatrendszer mért szelvényeit, piros görbével pedig a

teoretikus szelvényadatokat. Megállapítható, hogy a természetes gamma, neutron és az ellenállás szelvények esetén igen pontos az illeszkedés, az alkalmazott válaszegyenletek megfelelőek. Az akusztikus és spektrális gamma szelvények eltérése nagyobb, mely a mátrixösszetételre vonatkozó nagyobb érzékenységgel és a statisztikus ingadozással indokolható (pl. az urán szelvény elhagyásával kismértékű javulást tapasztaltam az adattérben). A 31. ábrán a becsült tárolóparaméterek szelvényei szerepelnek, melyek szépen követik a vertikális változásokat. E szakaszon az értelmezés keretében két gáztárolót különítettem el a 4-8.5 m és 10-18 m mélység-intervallumokban.

Módszer	$D_{d,0}$	D_d	t
LSQ-P	68.57 %	11.85 %	00:01:56
MMSA-P		10.83 %	00:25:01

30. táblázat

A (IX) adatrendszer pontonkénti inverziós eredményei




30. ábra

Az MMSA-P inverzióval becsült modellen számított és a mért szelvényadatok egyezése (kék görbék: (IX) mért szelvényei, piros görbék: számított szelvények)

8.3 INTERVALLUM INVERZIÓS VIZSGÁLATOK

Az intervallum inverziós algoritmus alkalmazása során a teljes vizsgált mélységintervallumon mért szelvényadatokat szimultán, egy inverziós eljárásban invertáljuk. Ekkor az inverz feladat a pontonkénti inverzióhoz képest jelentősen megnövekedett adatszám mellett nagymértékben túlhatározottá válik. Ezt kihasználva a tárolójellemző petrofizikai paraméterek

mellett a rétegvastagságokat is ismeretlennek tekintettem, kimutatva így a tároló- és azok zárórétegeinek határait. Ezután az intervallum inverzióval nyert réteghatár-koordináták rögzített értékei mellett, a második gáztároló réteg térfogatjellemző paramétereinek vertikális rétegbeli változását feltételezve, hatványfüggvény szerinti sorfejtésen alapuló kombinált inverziós módszert alkalmaztam a negyedik réteg tárolóparamétereinek meghatározása céljából.



31. ábra

Az MMSA-P inverzióval nyert petrofizikai paraméterek szelvényei

8.3.1 Intervallum inverzió automatikus réteghatár meghatározással

Az ismeretlen rétegvastagságok mellett végzett MMSA-H ($\mu=1$, $\nu=0$) inverziót megelőzte az MMSA-I ($\mu=1$, $\nu=0$) intervallum inverzió, mely a rétegvastagságokat ismert mennyiségeként kezelte. Ezeket az MMSA-P inverziós eredményszelvényeken manuálisan jelöltem ki.

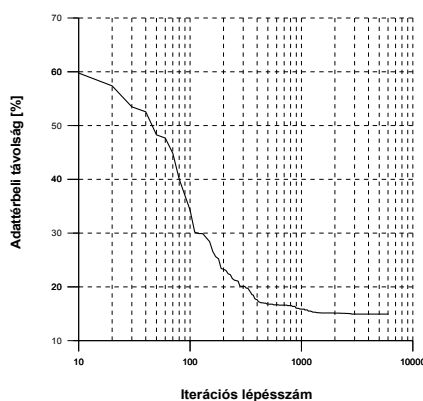
Mindkét intervallum inverziós módszer esetén a teljes intervallum adatszámát a mélységpontok száma ($P=182$) és a szelvények számának ($N=8$) szorzata adja meg, tehát $N^*=1456$. Az MMSA-I inverzió esetén a modellparaméterek száma $M^*=20$. Az MMSA-H módszernél ugyanezt a rétegszám ($R=4$) és a rétegjellemző paraméterek számának ($M=5$) szorzata, valamint a négy rétegvastagság paraméter adta, tehát $M^{**}=24$. Látható, hogy a túlhatározottság csak kis mértékben csökkent az előző esethez képest. Az MMSA-I eljárás során a maximális iterációs lépésszámot $q_{\max}=8000$ -nek, a kezdeti hőmérsékletet $T_0=10^{-5}$ -nek választottam, melyre (2.18) hűtést alkalmaztam. A maximális paraméterváltoztatás $b_{\max}=0.1$ volt, melyet $q=500$ lépésként 85 %-kal csökkentettem. Az MMSA-H eljárás iterációs lépéseinek a száma $q_{\max}=6000$ volt. Az algoritmust kiegészítettem egy új folyamatjellemző paraméterrel, a $b_{\max 2}=0.3$ [m] paraméter a rétegvastagságok lépéskénti maximális változását írta elő, mely-

nek csökkentési üteme $q=500$ lépésenként az aktuális érték 80 %-a volt. Emellett szükség volt az anyagmérleg egyenlet és a petrofizikai paraméterek lehetséges tapasztalati értékeit szabályozó matematikai korlátozó egyenletek felhasználására is. A két inverziós kiértékelés eredményét a 31. táblázat alapján összehasonlítva, megállapítható, hogy a rétegvastagságok bevezetésével nem romlott az intervallum inverzió pontossága. A relatíve nagy adattérbeli távolság a rétegenként homogén modell szerinti sorfejtés közelítéséből, az eltérő vertikális felbontóképességű szelvények adatai révén és a válasze egyenletekből adódó modell hibákból adódik. A 32. ábrán látható, hogy az MMSA-H eljárás konvergens.

Módszer	$D_{d,0}$	D_d	t
MMSA-I	68.57 %	14.92 %	00:08:01
MMSA-H		14.92 %	00:07:58

31. táblázat

A (IX) adatrendszer intervallum inverziós eredményei rétegenként homogén modell esetén




32. ábra

A relatív adattérbeli távolság vs. iterációs lépésszám MMSA-H inverzió folyamán

A 33. ábrán az MMSA-H módszerrel becsült rétegjellemzők szelvényei és a réteghatárkoordináták láthatók. A becsült rétegvastagságok $H_1=4.2$ m, $H_2=4.3$ m, $H_3=1.4$ m, valamint $H_4=8.3$ m-nek adódtak. A vizsgált szakaszon két gáztároló réteget mutatott ki az intervallum inverzió, melyek kvantitatív jellemzőit közvetlenül leolvashatjuk az ábráról. Ez azért előnyös, mivel az iparban a tárolójellemzőket a pontonkénti eredmények átlagából számítják a tároló rétegek minőségi jellemzése céljából. Az intervallum inverziós módszerrel azonban közvetlenül (a pontonkénti inverziónál megbízhatóbb eljárással) kaphatunk információt a produktív szakaszok rétegvastagságairól és a tárolási tulajdonságokat jellemző paramétereikről. Ez alapján a módszer javasolható a szénhidrogén telepek minősítésére.

A Fúrás-1 vizsgált szakaszán lévő produktív zónák kvantitatív jellemzését a 32. táblázat mutatja. Ebből kitűnik, hogy két nagy porozitású, kis mértékben szennyezett homokkötőtarólóról van szó, melyek azonos litológiájúak. Az azonos pórustérfogat mellett a szaturációs értékek között néhány százaléknyi különbség van. Az SCHM=SX0-SW mozgásképes gáztelítettség az első tárolóközvetben 52 %, a másodikban 50 % eredményeim szerint. Az SCHR=1-SX0 maradék gáztelítettség pedig az első esetben 25 %, a másodikban pedig 22 %. A MOL Rt. Petrofizikán a jelenleg alkalmazott minőségi besorolás szerint a két gáztároló II-es minősítésű telepnek felel meg, mely igen jó tárolási tulajdonsággal jellemezhető.



33. ábra

Az MMSA-H inverzióval nyert petrofizikai paraméterek szelvényei

CH-tároló	POR	SX0	SW	VSH	VSD	SCHM	SCHR
0 - 4.2 m	27 %	75 %	23 %	7 %	65 %	52 %	25 %
9.9 - 18.1 m	27 %	78 %	28 %	7 %	66 %	50 %	22 %

32. táblázat


Szénhidrogén telepek minősítési paraméterei MMSA-H inverzió alapján

8.3.2 Rétegben vertikálisan változó petrofizikai paraméterek meghatározása FGA+DLSQ-I kombinált inverziós módszerrel

A valós földtani szituációk esetén a petrofizikai paraméterek rétegen belüli gyors vertikális változása gyakori jelenség. Ez intervallum inverzió során elsősorban a tároló rétegekben lényeges, ugyanis itt szükség lehet a rétegenként homogén modell szerinti sorfejtést alkalmazó intervallum inverziós eredmények javítására. Ebből a célból a IX. adatrendszer 9.9-18.1 m-es szakaszán található gáztároló rétegben a POR, SX0, SW és VSH petrofizikai paramétereket

negyedfokú hatványfüggvényekkel közelítettem, a VSD paramétert determinisztikus elven, az anyagmérleg egyenlet felhasználásával mélységpontonként számítottam. Ezzel az eljárással a homogén modell szerinti sorfejtést alkalmazó intervallum inverzióhoz képest, a mért és számított adatok eltérésében javulást vártam.

A fenti tárolóparaméterek meghatározására FGA+DLSQ-I kombinált intervallum inverziós módszert alkalmaztam, ahol $N^*=1456$ adatszám mellett $M^*=35$ ismeretlen (első három homogén rétegben $3*5$ petrofizikai paraméter, a negyedik rétegben $4*5$ sorfejtési együttható) állt. A futtatást FGA-I genetikus algoritmussal indítottam 100 véletlen modell mellett. A modellparaméterek keresési terét homogén rétegek esetén a matematikai szabályozó egyenletekkel szűkítettem, a negyedik rétegben pedig a sorfejtési együtthatókat $-0.5 \leq B \leq 0.5$ intervallumra korlátoztam. Az FGA-I algoritmus a (2.12) adattérbeli távolság -1-szeres értékéből képzett fitness függvényt maximalizálta $q=200$ iterációs lépésszámgig. Ez alatt a modellparamétereket versenyszelekcióval (generációnként 2000 ismétléssel), egyszerű keresztezéssel és egyenletes eloszlású mutációval számítottam. Majd a $q=200$. generáció után csillapított legkisebb négyzetek elvén alapuló linearizált optimalizációt (DLSQ-I módszert) alkalmaztam a $q_{max}=300$ iterációs lépéssel bezárólag. Az inverziós eljárás konvergensenek és stabilnak bizonyult. A 34. ábra mutatja a relatív adattérbeli távolság csökkenését a gyorsított konvergencia során.



34. ábra

A relatív adattérbeli távolság vs. iterációs lépésszám
FGA+DLSQ-I inverzió folyamán

Az inverziós eredmények a 33. táblázatban láthatók, ahol $D_{d,0}$ a kezdeti modellpopuláció maximális fitness-ű egyedének, D_d pedig az eredménymodell relatív adattérbeli távolsága. Célkitűzésemnek megfelelően, a negyedik rétegbeli inhomogén modell szerinti sorfejtés jobb adattérbeli illeszkedést biztosított, mint a homogén rétegnek megfelelő sorfejtés (ld. 31 és 33. táblázat). A becsült modellparaméterek hibáit a 34. táblázat tartalmazza, melyhez a (2.15)-ben szereplő adattérbeli kovariancia mátrix elemeit HORVÁTH (1973) alapján határoztam meg. A

bemenő szelvényadatok hibáinak megadásánál figyelembe vettem a Baker Atlas és a Schlumberger vállalat mérőeszközeinek pontosságára vonatkozó tájékoztató adatokat is, ezzel a hibákat 7 % (CNL), 2 % (AT), 5 % (GR), 1 % (K), 2 % (RT), 3 % (TH), 3 % (U), 1 % (CDL) szerint adtam meg. A 34. táblázatban látható, hogy az első három homogén réteg paramétereinek és a negyedik inhomogén réteg B_1 sorfejtési együtthatóinak becslési hibája kicsi. A mélység magasabb hatványaihoz tartozó együtthatók esetén azonban a belső csatolások miatt megnő a hiba mértéke is (a hatvány-függvényrendszer nem ortogonális). Ezzel együtt az $S=0.31$ korrelációs átlag elfogadható eredményre utal.

(IX) adatrendszer		
$D_{d,0}$	D_d	t
59.07 %	13.37 %	00:14:07

33. táblázat

A (IX) adatrendszer FGA+DLSQ-I inverziós eredményei


Réteg	B	POR	SX0	SW	VSH	VSD
1	-	0.1016 (±0.0017)	0.9981 (±0.0156)	0.9976 (±0.0138)	0.5774 (±0.0024)	0.3210 (±0.0022)
2	-	0.2652 (±0.0014)	0.7521 (±0.0038)	0.2282 (±0.0011)	0.0750 (±0.0008)	0.6598 (±0.0014)
3	-	0.1662 (±0.0027)	0.9964 (±0.0150)	0.9893 (±0.0136)	0.3426 (±0.0029)	0.4912 (±0.0031)
4	B_1	0.2772 (±0.0022)	0.6792 (±0.0097)	0.2535 (±0.0022)	0.0695 (±0.0024)	-
	B_2	0.0259 (±0.0062)	0.5920 (±0.1081)	-0.9936 (±0.0248)	-0.5239 (±0.0346)	
	B_3	-0.0010 (±0.0001)	-0.7756 (±0.4059)	4.0267 (±0.1111)	1.8603 (±0.1493)	
	B_4	-0.007 (±0.0002)	-0.7400 (±0.6329)	-6.2749 (±0.2013)	-1.8523 (±0.2366)	
	B_5	-0.1734 (±0.0067)	1.3497 (±0.3458)	3.6961 (±0.1235)	0.7219 (±0.1228)	

34. táblázat

A FGA+DLSQ-I inverzióval nyert petrofizikai paraméterek és hibáik

A 35. ábrán látható, hogy a negyedik rétegbeli agyagtartalom és víztelítettség változást az FGA+DLSQ-I módszer pontosabban képezte le, mint az MMSA-I eljárás. Megállapítható, hogy $z=17$ m környékén a szénhidrogén-tárolóban átmeneti zóna alakul ki, melyet a homogén réteg szerinti sorfejtéses eljárás nem mutatott ki. E zóna alatt a mélységgel nemlineárisan nő a víztelítettség és az agyagtartalom, továbbá csökken a gáztelítettség. Természetesen a tároló-jellemzők e vertikális felbontása még tovább finomítható, magasabb kitevőjű hatványfüggvények vagy egyéb alkalmasan megválasztott függvényrendszerek szerinti sorfejtéssel. A számí-

tások nemcsak egy rétegben, hanem minden gazdaságilag fontosabb rétegben is elvégezhetők, azonban ez az ismeretlenek számának növekedésével, azaz a túlhatározottság csökkenésével jár, mely a paraméterbecslés pontosságának a rovására mehet. Az ismeretlen sorfejtési együtthatók számát ezért csak szükséges mértékben célszerű növelni.



35. ábra

Az FGA+DLSQ-I inverzióval nyert petrofizikai paraméterek szelvényei

Ebben a fejezetben egy szénhidrogén-kutató fúrásban mért mélyfúrési geofizikai adatrendszer mélységpontenkénti- és intervallum inverziós kiértékelését végeztem el. Intervallum inverzióval rétegjellemző paramétereket számítottam, valamint elvégeztem a réteghatárkoordináták automatikus inverziós meghatározását. Az intervallum inverziós módszer közvetlen felhasználását javasoltam a szénhidrogén telepek minősítése területén. Végül rétegenként homogén modell szerinti sorfejtésen alapuló intervallum inverziós módszert javítottam, intervallumon vertikálisan változó petrofizikai paraméterek meghatározására alkalmas kombinált FGA+DLSQ-I inverziós eljárás segítségével.

9. MÉLYFÚRÁSI GEOFIZIKAI ADATOK PONTONKÉNTI ÉS INTERVALLUM INVERZIÓJÁNAK ÖSSZEHAJONLÍTÁSA SZINTETIKUS ÉS TEREPI ADATRENDSZEREK ESETÉN

A mélyfúrási geofizikai értelmezés inverziós módszereinek összehasonlítása során az 5-8. fejezet eredményeire támaszkodom. Az elemzés keretében saját fejlesztésű, linearizált és globális optimalizációs technikákon alapuló mélységpontonkénti és intervallum inverziós eljárásokat hasonlítok egymással össze.

A mélységpontonkénti inverziós feladat kismértékben túlhatározott, mely rendkívül érzékenyen reagál az adattérbeli zajra. Ezzel együtt a legkisebb négyzetek módszerén (LSQ) alapuló linearizált pontonkénti inverzió közeli startmodell esetén stabil megoldást ad, azonban a modellterben az egzakt modelltől egyre távolabbi startmodellek alkalmazása esetén megnő a divergens megoldásokat tartalmazó mélységpontok száma. Ez lényegében annyit jelent, hogy az LSQ-P eljárás akkor alkalmazható sikeresen, ha elegendő és megfelelő a priori ismeretünk van a kezdeti modell megalkotásához, és a megoldástól nem túl nagy távolságról indítjuk az eljárást. Az előzetes információ hiányában viszont megnő a lokális minimumban való stabilizálódás vagy a numerikus divergencia veszélye. Általában a mélyfúrási geofizikai gyakorlatban elegendő információ áll rendelkezésre szelvény, mag és egyéb geofizikai adatok révén, ennek ellenére az LSQ-P eljárás legtöbbször numerikusan instabillá válik. Munkámban az LSQ-P módszert numerikusan a csillapított legkisebb négyzetek módszerével stabilizáltam.

Zajjal terhelt szintetikus szelvényadatok inverzióját elsőként a DLSQ-P módszerrel végeztem el, mely nemcsak Gauss-zajjal terhelt, hanem kiugró adatokat tartalmazó szelvényadatok kiértékelése esetén is konvergens megoldást szolgáltatott. A becsült petrofizikai paramétereket az adattérbeli zajnak megfelelő hiba terhelte. A 4. ábrán összehasonlítható a kiugró adatokat nem tartalmazó, illetve az outlier-ekkel terhelt adatrendszerrel fellépő becslési hiba mértéke, mely utóbbi esetben a kiugró adatok mélységpontjaiban lokálisan hirtelen megnő. Az utóbbi esetben a paraméterek konfidencia-intervalluma is láthatóan „szélesebb”.

A pontonkénti inverziós eredmények pontosságát globális optimalizációs módszerekkel tovább javítottam. Az MMSA-P és FGA-P eljárásokkal globális optimumkeresést valósítottam meg (ezt az SA módszernél a logaritmusos hűtési eljárás garantálta), mellyel kb. 0.15 %-nyi javulást értem el (közeli startmodell esetén) az adattérben linearizált optimalizációval szemben. Vizsgálataim kiterjedtek olyan startmodellre is, mely a megoldástól igen nagy adattérbeli távolsággal ($D_{d,0}=5542\%$) és erősen korrelált paraméterekkel rendelkeztek. Ebben az esetben a linearizált inverzió minden mélységpontban divergensnek bizonyult és a hagyományos Metropolis algoritmus konvergenciája is nagymértékben lelassult. A problémát a linearizált csillapított legkisebb négyzetek módszerével (DLSQ) analóg módon megalkotott

módosított SA eljárással (MMSA-P) kezeltem. Az (4.5) energiafüggvényen alapuló MMSA-P eljárás az extrém startmodell ellenére is megtalálta az optimumot, és a hagyományos Metropolis algoritmus eredményénél ~50 %-kal pontosabb megoldást szolgáltatott a gyorsabb konvergencia révén (ld. 8. táblázat). A hatékony globális optimalizációt végrehajtó algoritmusok hátránya azonban az időigényesség. A mért futási idők a linearizált inverziós módszerekkel szemben átlagosan megháromszorozódtak. Érdekes azonban a globális optimalizációs módszer kiválasztásánál figyelembe venni azt a tényt, hogy míg az MMSA-P módszer kb. ugyanannyi idő alatt egy modellt tökéletesít, addig FGA-P eljárás szimultán módon nagyszámú (jelen esetben 20) különböző modellt javít, és az eljárás végén az optimális modellek sorozatát állítja elő. Ebben a tekintetben az utóbbi módszer megbízhatósága nagyobb.

A mélységpontonkénti inverzióval szemben az intervallum inverziós technika nagymértékben túlhatározott inverz problémát képez. A futtatások során kiderült, hogy már a linearizált DLSQ-I módszer is lényegesen stabilabb és pontosabb inverziót eredményezett a pontonkénti eljárásokkal szemben. A 2. és 11. táblázat alapján összehasonlítva a DLSQ-P és DLSQ-I eljárásokkal kapott inverziós eredményeket, a modelltérbeli távolság $D_{m,mp}=2.28$ %-ról $D_{m,int}=0.54$ %-ra csökkenése nagymértékű javulást mutat a paraméterbecslés jósága tekintetében. A relatív adattérbeli távolság ugyanitt csak kis mértékben javult, hiszen ennek értéke az adattérbeli zajnál kisebb nem lehet. Az intervallum inverzió pontosságát a becsült paraméterek hibája is jellemzi, a 2. ábrát és a 12. táblázatot összehasonlítva megállapíthatjuk, hogy az intervallum inverzióval becsült modellparaméterek hibája kb. egy nagyságrenddel kisebb, mint pontonkénti inverzió esetén. A paraméterek megbízhatóságát az $S=0.17$ kismértékű korrelációt jellemző korrelációs átlag is alátámasztja.

Az MMSA-P algoritmus mintájára a (4.22) energiafüggvény felhasználásával MMSA-I néven globális intervallum inverziós algoritmust fejlesztettem ki. E két módszert az 5. és 15. táblázat eredményei alapján összevetve, azt tapasztaljuk, hogy a modelltérbeli távolság $D_{m,mp}=2.25$ %-ról $D_{m,int}=0.38$ %-ra csökkent. A MMSA-I módszert ezután kipróbáltam kiugró zajt tartalmazó adatrendszer inverziója esetén is. A (4.22) $\mu=v=2$ és $\mu=v=1$ paraméterekkel kifejlesztett MMSA-I módszerekkel végeztem inverziós kísérletet. A 16. táblázatban látható, hogy a relatív adattérbeli távolságban 45 %-os és a modelltérbeli távolság értékeiben 42 %-os javulás következik be $\mu=v=1$ energiafüggvény minimalizálása esetén $\mu=v=2$ energiafüggvény alkalmazásával szemben. E szignifikáns javulás azt bizonyítja, hogy az MMSA-I módszer rezisztenciája az energiafüggvény megfelelő megválasztásával növelhető. Ezzel igen hatékony és stabil globális intervallum inverziót lehet megvalósítani.

Az intervallum inverzió stabilitása nem romlott további inverziós ismeretlenek bevezetése mellett sem. A réteghatárok meghatározása alapvető az értelmezés szempontjából, azonban azok eddig nem tartoztak a mélyfúrési geofizikai inverzió problémakörébe. A hagyományos szeparált pontonkénti inverzió a rétegvastagságok meghatározására alkalmatlan, ezért a réteghatárokat szükségszerűen manuálisan, inverziós eljárásen kívül lehetett eddig meghatározni. Az intervallum inverzió keretein belül a réteghatár-koordináták automatikus meghatározására is van lehetőség. A rétegvastagságokkal, mint modellparaméterekkel a nagymértékű túlhatározottság nem csökkent számottevően, és az inverziós eljárás stabil maradt. Az ismeretlen réteghatárok mellett végzett globális intervallum inverziós tesztlések minden esetben konvergens eljárást mutattak. A rétegvastagságok – melyek kezdeti (startmodellbeli) értékei igen nagy modell és adattérbeli távolságot eredményeztek a megoldástól – konvergáltak az összes modellparaméter közül a leggyorsabban valódi értékeik felé (szintetikus és terepi vizsgálatok esetén egyaránt). Miután felvették optimális értéküket, már nem változtak az inverzió során, csak a többi petrofizikai ismeretlen javult (pl. ld. 17. és 21. ábra). Ez is az eljárás stabilitását támasztja alá. A túlhatározottság kismértékű csökkenése miatt, az ismeretlen rétegvastagságok mellett végzett intervallum inverziónál kicsiny romlás tapasztalható a paraméterbecslés pontosságában, azonban ez pl. MMSA-H inverzió esetén még mindig több mint 50 %-kal pontosabb eredményt jelentett a pontonkénti MMSA-P inverzióval szemben (ld. 5. és 20. táblázat). Ugyanakkor kiugró adatok jelenléte esetén is konvergens és rezisztens MMSA-H eljárást sikerült konstruálni csak úgy, mint fix réteghatárok melletti inverzió esetén (ld. 21. táblázat).

Az intervallum inverziót az előzőekben ismertetett esetekben homogén modell szerinti sorfejtésen alapuló algoritmussal végeztem. A módszer azonban lehetővé teszi a petrofizikai paraméterek bonyolultabb mélységfüggésének a meghatározását is, ismert bázisfüggvényrendszer szerinti sorfejtésen keresztül. Gyakran előfordul, hogy a petrofizikai paraméterek a rétegen belül gyors vertikális változást mutatnak. A bázisfüggvények megválasztásával tetszőleges mértékben közelíthetjük e változásokat. A vertikális felbontás növelése viszont több ismeretlen bevezetésével jár, amely az inverzió stabilitását és pontosságát csökkenti. Vizsgálataim során negyedfokú hatványfüggvény szerinti sorfejtést alkalmaztam. A 24. táblázatban szereplő célmodell esetén a homogén modell ismerete nélkül (összes sorfejtési együttható ismeretlen) kerestem az intervallum inverziós feladat megoldását. A sorfejtési együtthatók lehetséges széles tartományának köszönhető nagy kezdeti adattérbeli távolsággal jellemezhető startmodell ($D_{d,0}=378\%$) nyilvánvalóvá tette, hogy (kezdetben) globális optimalizációs módszer szükséges alkalmazni. E módszerek azonban nagy ismeretlenség esetén igen lassúak, továbbá nem nyújtanak módot egy futtatásból megadni a becsült paraméterek hibáját és meg-

bízhatóságát. E probléma kiküszöbölésére globális és linearizált optimalizáción alapuló kombinált intervallum inverziós módszert fejlesztettem ki. A módszer lényege az, hogy startmodell-független globális optimalizációval kezdve a keresést, nagy valószínűséggel eljutunk a globális optimum környékére, ahonnan linearizált módszerrel folytatva az eljárást, igen gyorsan kaphatjuk meg a megoldást, továbbá az utolsó lépésben a becsült paraméterek hibáját és megbízhatóságát kvantitatív módon becsülni tudjuk. A kombinált inverzió globális optimalizációs részéhez a valós kódolású genetikus algoritmust választottam, mivel annak adaptációs képessége jobbnak bizonyult a gyakorlatban a Simulated Annealing eljárásnál. E tulajdonságot az optimalizációs alkalmazások során úgy jellemzik, mint a “változó körülmények között is elfogadható teljesítményt” (ÁLMOS et al., 2002). Ez azt jelenti, hogy a genetikus algoritmus folyamatjellemző paramétereit nem kell újra beállítani ugyanazon inverziós célmodell paramétereinek eltérő értékeinél, míg ez Simulated Annealing módszernél gyakran nem teljesül. Ezt a képességet örökölte az általam kifejlesztett kombinált inverziós módszer is. Az FGA+DLSQ-I kombinált intervallum inverziós futtatások zajjal terhelt szintetikus adatokon bebizonyították, hogy a rétegben vertikális változást mutató paraméterek értékei igen jól leképezhetők, a megoldástól extrém távoli startmodellek esetén is. Ezt a becsült paraméterek értékei, hibája és korrelációs együtthatói is alátámasztják (ld. 26. táblázat és 8. melléklet). A CPU idők tekintetében is jelentős csökkenést tapasztaltam globális optimalizációs módszerekkel szemben, mivel az FGA+DLSQ-I algoritmus futási ideje $t=6$ min 54 sec volt, míg egy hasonló FGA-I inverziót $t=1$ h 48 min idő alatt végeztem.

Valódi karotázis adatok inverziója céljából egy magyarországi szénhidrogén-kutató fúrásban mért szelvényanyagot használtam fel. Mélységpontonkénti inverziós eredményeimet a MOL Rt. Petrofizikán használt determinisztikus elvű értelmezési rendszerrel számított paraméterszelvényeivel hasonlítottam össze. Az MMSA-P inverzióval kapott tárolójellemzők értékei (ld. 31. ábra) jó egyezést mutattak a Baker Atlas Express-CLASS programjával végzett kiértékeléssel (ld. 11. melléklet). A CLASS szelvényeken kijelölt réteghatárok jó egyezést mutatnak az MMSA-H intervallum inverzióval meghatározott réteghatárokkal. A mért és számított szelvények illeszkedése elfogadható, azonban ez nem tükrözi a modell térbeli egyezést, aminek mértéke az eredménygörbék természetes lefutása és a tárolóparaméterek fizikai realitása miatt feltételezhetően kisebb. A homogén modell szerinti sorfejtést alkalmazó intervallum inverzió az adattérben pontatlanabbnak adódott a pontonkénti inverzióval, ugyanis az nem veszi figyelembe a rétegbeli gyors vertikális változásokat, hanem egyetlen rétegjellemző paramétert becsül rétegenként. E rétegjellemzők azonban közvetlenül felhasználhatók a tárolók minőségi jellemzésében. Ebben a tekintetben eredményeim jó egyezést mutatnak a MOL

Rt. Petrofizikán CLASS módszerrel számított tárolóparaméterek értékeivel. Az intervallum inverziós módszer javítása érdekében terepi adatok kiértékelésére alkalmas FGA+DLSQ-I kombinált inverziós módszert fejlesztettem ki. A tárolóparamétereket egy gáztároló rétegben negyedfokú hatványfüggvény szerinti sorfejtéssel közelítettem. A 31. és 33. táblázat összevetése után megállapítható, hogy már egyetlen réteg „finomabb” felbontásával ~10 %-os javulást érhetünk el a mért és számított szelvények illeszkedése terén. Ez a javulás tovább fokozható, ha minden rétegben (elsősorban a tárolókban) hasonló sorfejtést alkalmazunk.

10. ÖSSZEFOGLALÁS

Doktori értekezésemben a Miskolci Egyetem Geofizikai Tanszékén végzett mélyfúrési geofizikai értelmezés tárgyköréhez kapcsolódó módszerfejlesztésben elért eddigi eredményeimet foglaltam össze. Kutatómunkám alapját a Dr. Dobróka Mihály vezetésével működő tanszéki Inverziós és Tomográfiai Kutatócsoport eddigi két évtizedes munkája jelentette. A mélyfúrési geofizikai inverzióból írtam 1999-ben megvédett diplomamunkámat is, melyben a további kutatásra irányuló célkitűzéseimet igyekeztem doktori munkámban megvalósítani.

A dolgozatban modern mélyfúrési geofizikai inverziós eljárások fejlesztésén és alkalmazásán keresztül az inverziós szelvénykiértékelés elméleti és gyakorlati kérdéseivel foglalkoztam. Megvizsgáltam 10 új mélyfúrési geofizikai inverziós eljárás hatékonyságát, pontosságát, azok előnyeit és hátrányos tulajdonságait. A fejlesztések során először zajjal terhelt szintetikus adatrendszeren végzett inverziós futtatásokat elemeztem, majd a tesztelési fázis után, terepi mért adatrendszeren alkalmaztam az inverziós eljárásokat. A dolgozatban öt modellen, kilenc adatrendszer segítségével végeztem inverziós vizsgálatokat.

A hagyományos mélységpontként végzett mélyfúrési geofizikai inverzió mellett egy új módszert vezettem be, az ún. intervallum inverziós eljárást, mely számos előnyt rejt magában a konvencionális pontonként végzett (szeparált) inverzióval szemben. Az inverziós eljárásokat megvizsgáltam az iparban használatos linearizált optimalizációs, valamint az ott ez idáig még nem alkalmazott globális optimalizációt végző algoritmusok segítségével. A globális szélsőérték kereső eljárások hatékonynak bizonyultak az optimális modell megtalálására, azonban ez gyakran csak relatíve lassú konvergencia mellett valósult meg. Ugyanakkor a becsült paraméterek pontosságának és megbízhatóságának jellemzését e módszerek egyetlen futtatásból nem tették lehetővé. E problémák kezelésére módosított, valamint lineáris módszerekkel kombinált globális inverziós módszert fejlesztettem ki. Megvizsgáltam azt az esetet, amikor méréseinket hirtelen kiugró zaj terheli, pl. ahol kavernásodás, vagy hirtelen, gyors lyukátmérő változások nagy amplitúdójú véletlen zajként jelennek meg a mérési adatrendszerben. E problémára előnyösen alkalmazhatók a rezisztens inverziós eljárások, melyeket alkalmas célfüggvény megválasztásával vezettem be az intervallum inverzióba. Bebizonyítottam, hogy ezen modern elveken alapuló inverziós eljárásokkal pontosabb és megbízhatóbb eredményeket érhetünk el a petrofizikai paraméterek becslése területén, valamint a mélyfúrési geofizikai adatrendszerből még több információ nyerhető ki, mint a hagyományos mélységpontkénti inverziós módszerekkel.

Az inverziós kutatások során érintettem a mélyfűrési geofizikai direkt modellezés néhány kérdését. A mélyfűrési geofizikai direkt feladatban szereplő válaszfüggvények paraméter-érzékenységeit a paraméterek inverziós meghatározhatóságának vonatkozásában elemeztem. Az érzékenységi függvények hasznos információval szolgálnak arról, hogy az inverz feladatban szereplő ismeretlenek milyen mértékben befolyásolják a szelvényadatokat egyes paramétertartományokban. Az iteratív inverziós algoritmusok futása során az adott modellterületi tartományban kis érzékenységet mutató paramétereket megfelelő a priori információ birtokában, állandó (fix) értéken tartva, növelhetjük az inverz feladat túlhatározottságát, és javíthatjuk az inverziós eredmények minőségét.

A tesztelések alapján arra a következtetésre jutottam, hogy a globális optimalizáción alapuló intervallum inverziós módszerek a leghatékonyabbak a szelvényértelmezésben, melyek ipari alkalmazása célszerű lehet a jelenleg alkalmazott pontonkénti determinisztikus és inverziós módszerek mellett. E módszer startmodell-független, igen pontos, stabil és megbízható, emellett információt tud szolgáltatni a réteghatárok helyzetéről, melyre a hagyományos pontonkénti inverzió nem képes.

A rétegvastagságok inverziós ismeretlenként való kezelése és becslése mellett az intervallum inverziós eljárás véleményem szerint tovább fejleszthető zonális és/vagy texturális paraméterek automatikus meghatározására. E figyelemre méltó tulajdonsága révén a módszert célszerű lenne kihasználni a pontosabb és a még következetesebb szelvényértelmezés céljából, hiszen igény lenne, pl. a texturális tulajdonságoktól függő kiértékelési paraméterek (cementációs tényező, szaturációs kitevő, tortuozitási együttható) más forrásból (nemcsak irodalmi vagy regressziós analízis) történő meghatározására. Ennek egy korszerű lehetőségét az intervallum inverzió keretein belül látom megvalósulni, mely képes automatikusan, tetszőleges mélység-intervallumonként (rétegenként vagy zónánként) szelvényyszerűen megbecsülni a paraméterek értékét.

Az alkalmazott globális optimalizációs módszerek létjogosultságát a mélyfűrési geofizikai direkt feladat „egyszerűsége” és gyorsasága is alátámasztja. E módszerek konvergencia sebessége tovább növelhető a dolgozatban bemutatott kombinált inverziós módszer alkalmazásával, mely egyben megoldja a becsült paraméterek hibája és megbízhatósága jellemzésének problémáját is. Az intervallum inverzióba könnyen beépíthetők további szelvénytípusok válaszegyenletei (direkt feladat fejlesztése), továbbá a módszer közvetlenül alkalmazható szénhidrogén-tárolók minőségének jellemzésére. Az intervallum inverziós módszer az ipari gyakorlatban végzett operatív petrofizikai értelmezés számára rétegjellemzőket szolgáltat, melyek pontossága és megbízhatósága nagyobb, mint a hagyományos pontonkénti inverziós

paramétereiből számított petrofizikai paraméterek rétegbeli átlagértéke, ugyanis a szénhidrogént tároló réteg teljes adatrendszerének információját egyszerre használja fel a petrofizikai paraméterek számításánál, nemcsak egyetlen pontét. A módszer könnyen továbbfejleszthető, mivel tetszőleges bázisfüggvény-szerinti sorfejtéssel diszkretizálja a petrofizikai paraméterek mélységi eloszlását. A dolgozatban hatványfüggvényekkel dolgoztam, azonban alkalmas lehet további ortogonális függvényrendszerek szerinti sorfejtés is (pl. trigonometrikus, Walsh függvények, Chebishev polinomok stb.), mellyel a paraméterek közötti korreláció és a becslési hiba tovább csökkenthető. A jövőben az intervallum inverziós módszert elképzelhetőnek tartom alkalmazni automatikus rétegvastagság meghatározáson alapuló, több fúrásban mért mélyfúrési geofizikai szelvényadatok együttes inverziójára, 2-D és 3-D tárolók modellezésére, valamint fúrások közötti automatikus réteggörrelációra.

Köszönetnyilvánítás

Elsőként szeretnék köszönetet mondani témavezetői munkájáért Dr. Dobróka Mihály professzor úrnak, a Miskolci Egyetem Geofizikai Tanszék vezetőjének. Köszönöm lelkiismeretes oktatói és nevelői munkáját, valamint a számos korszerű tudományos ismeretet, melyet széles körű szakmai tapasztalata alapján átadott nekem. Örömet fejezem ki, hogy közös munkánk során bölcs tanácsokkal valamint tudományos szemlélettel látott el, és gondosan irányította eddigi szakmai fejlődésemet.

Mint a Miskolci Egyetem Geofizikai Tanszékének tanársegéde köszönetemet fejezem ki oktató és doktorandusz kollegáimnak szakmai segítségükért, és azért az építő és nyugodt munkahelyi légkör megteremtéséért, melyben doktori munkámat végezhettem. Külön szeretnék köszönetet mondani Dr. Turai Endre egyetemi docens úrnak értekezésem munkahelyi bírálatáért, és Kopcsa Józsefné Marikának a dolgozatot érintő formai és esztétikai tanácsaiért.

Köszönetemet fejezem ki a szolnoki MOL Rt. Petrofizika munkatársainak a több éve tartó szakmai együttműködésért, mely gyakorlati oldalról nagymértékben növelte ismereteimet. A dolgozatban felhasználtam az általuk rendelkezésre bocsátott terepi mélyfúrési geofizikai adatrendszert, mely a saját fejlesztésű inverziós algoritmusok valós földtani körülmények között történő kipróbálását tette lehetővé. Megköszönöm dr. Kiss Bertalan osztályvezető úrnak a munkahelyi vitán kifejtett bírálati tevékenységét, és azt, hogy lehetővé tette, hogy a MOL Rt. Petrofizikán alkalmazott korszerű szelvényértelmező rendszert felhasználva összehasonlíthattam az iparban végzett eljárások eredményeivel saját inverziós eredményeimet. Doktoranduszként összesen öt hónapot töltöttem Szolnokon szakmai gyakorlat céljából, melyből három hónapot a Magyar Soros Alapítvány anyagi támogatása tett lehetővé a „Mélyfúrési geofizikai adatok feldolgozásának és értelmezésének modern módszerei” című, 222/2/3900. számú téma kapcsán.

Végül szeretnék köszönetet mondani kedves családom tagjainak, Feleségemnek, Édesapámnak, Édesanyámnak és Nagymamámnak, akik szerető gondoskodásukkal, önzetlen segítő szándékukkal és értékes tanácsaikkal lehetővé tették tanulmányaim és munkám kiteljesedését.

IRODALOMJEGYZÉK

ALBERTY M., KHALED H. HASMAMY, 1984: Application of ULTRA to log analysis. SPWLA 25th Annual Logging Symposium, Extended Abstract.

ÁLAMOS A. et al., 2002: Genetikus Algoritmusok. Typotex Kiadó.

BAKER ATLAS, 1996: OPTIMA. Express Reference Manual.

BHATTACHARYA B. B. et al., 1992: Global optimization in the direct interpretation of VES and MTS, submitted to the International Symposium on Mathematical Modeling and Computer Simulations held in Bangalore, India.

DITTMER J. K. and SZYMANSKY J. E., 1995: The stochastic inversion of magnetic and resistivity data using simulated annealing algorithm. *Geophysical Prospecting* 43, pp. 397-416.

DOBRÓKA M., 1988: On the absorption-dispersion characteristics of channel waves propagating in coal seams of varying thickness. *Geophysical Prospecting*, Vol. 36. No.3, pp. 326-328.

DOBRÓKA M., GYULAI Á., ORMOS T., CSÓKÁS J., DRESEN L., 1991: Joint inversion of seismic and geoelectric data recorded in an underground coal mine. *Geophysical Prospecting*, Vol. 39. No. 5, pp. 652.

DOBRÓKA M. (témavezető), 1995.: Együttes inverziós algoritmusok bevezetése a mélyfúrési geofizikai értelmezésbe. Zárójelentés, Miskolci Egyetem Geofizikai Tanszék.

DOBRÓKA M., 2001: Bevezetés a geofizikai inverzióba. *Jegyzet*, Miskolci Egyetemi Kiadó.

DOBRÓKA M., SZABÓ N. P., 2001: The inversion of well log data using Simulated Annealing method. *Geosciences, Publications of the University of Miskolc, Series A – Mining*, Vol. 59, pp. 115-137.

DOBRÓKA M., SZABÓ N. P., 2002: The MSA inversion of openhole well log data. *Intellectual Service for Oil & Gas Industry. Ufa State Petroleum Technological University & University of Miskolc. Analysis, Solutions, Perspectives Vol 2.* pp. 27-38.

ETNYRE L. M., 1984: Practical Application of Weighted Least Squares Methods to formation evaluation. Part I. *The Log Analyst* January-February, Part II. *The Log Analyst*, May-June.

FANG J. H. et al., 1996: Transformation of geochemical log data to mineralogy using Genetic Algorithm. *The Log Analyst*, March-April, pp. 26-31.

FERENCZY L., 1995: Kiegészítés a statisztikus értelmezési rendszerek anyagrészhez. *Tanszéki segédlet*, Miskolci Egyetem, Geofizikai Tanszék.

FERENCZY L. és STEINER F., 1987: Method of the most frequent value in the well-log interpretation. 32nd International Geophysical Symposium. *Proceedings*, Dresden.

FERTL W. H., BALL M. S., CHACE D. M., 1987: The Well Data System (WDS): „An Advanced Formation Evaluation Concept in a Microcomputer Environment” SPE 17034.

FORREST S., 1993: Genetic algorithms: Principles of adaptation applied to computation. Science, Vol. 261, Aug. 1993, pp. 872-878.

GEMAN S. and GEMAN D., 1984: Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. IEEE Trans. Pattern analysis and Machine Intelligence, Vol 6. - No. 6.

GOLDBERG D. E., 1989: Genetic Algorithms in search, optimization and machine learning. Addison-Wesley Publishing Company, Reading, Massachusetts, USA.

GYULAI Á., 1995: Dőlt réteges szerkezetek geoelektromos kutatási lehetőségének vizsgálata analitikus előremodellezéssel. Magyar Geofizika 36 évf., 1. szám.

HALLIBURTON COMPANY, 1993: Directory of ULTRA algorithms. Reference Manual, Version 11.0.

HOLLAND J. H., 1975: Adaptation in natural and artificial systems. University of Michigan Press, Ann Arbor, MI.

HOUCK C. R., JOINES J. A. and KAY M. G., 1995: A genetic algorithm for function optimization - A matlab implementation. North Carolina State University, Research, National Science Foundation DMI-9322834.

KISS B. és FERENCZY L., 1993: Szénhidrogén-tárolók mélyfúrési geofizikai értelmezése I. Nemzeti Tankönyvkiadó.

KIS M., 1996: Geofizikai adatok globális optimalizációja a Simulated Annealing algoritmus alkalmazásával. Magyar geofizika 37. évf. 3. szám.

KIS M., 1998: Felszínközeli földtani szerkezetek vizsgálata szeizmikus és egyenáramú geoelektromos adatok együttes inverziójával. Doktori (PHD) értekezés. Miskolci Egyetem, Geofizikai Tanszék.

KORMOS L., 1987: Statisztikus értelmezési eljárások alkalmazása szénhidrogén tárolók kvantitatív karotázs interpretációjában. Doktori értekezés.

MARQUARDT D. W., 1959: Solution of nonlinear chemical engineering models. Chem. Eng. Prog., 55/1959 No. 6.

MAYER C. et al., 1980: GLOBAL, a new approach to computer-processed log interpretation. SPE 9341.

MENKE W., 1984: Geophysical data analysis – Discrete inverse theory. Academic Press, Inc. London Ltd.


METROPOLIS N. et al., 1953: Equation of state calculations by fast computing machines. J. Chem. Phys. 21, pp. 1087-1092.

- MICHALEWICZ Z., 1992: Genetic Algorithms plus data structures equals evolution programs. Springer-Verlag Inc., AI Series, New York.
- ROTHMAN D. H., 1985: Nonlinear inversion, statistical mechanics, and residual static estimation. *Geophysics* 50, pp. 2784-2796.
- RUGGE P., 1993: A mérnöki tudományok kézikönyve. Springer-Verlag (magyar nyelvű kiadás), pp. A-107.
- SCHLUMBERGER, 1987: Log interpretation principles / applications. Schlumberger Educational Services.
- SEN M. K. and STOFFA P. L., 1991: Nonlinear multiparameter optimization using genetic algorithms: Inversion of plane wave seismograms. *Geophysics*, 56(11), 1794–1810.
- SZABÓ N. P. 1999: Mélyfúrési geofizikai adatok mélységpontonkénti- és intervallum inverziójának vizsgálata linearizált és globális optimalizációs módszerekkel. Diplomamunka. Miskolci Egyetem.
- SZABÓ N. P., 1999. A mélyfúrési geofizikai mérések kiértékelése globális inverziós módszerrel. Doktoranduszok Fóruma, Miskolci Egyetem. A Bányamérnöki Kar Szekciókiadványa, pp. 71-78.
- SZABÓ N. P., 2001: Mélyfúrési geofizikai adatok inverziója a Genetikus Algoritmus alkalmazásával. Doktoranduszok Fóruma, Miskolci Egyetem. A Műszaki Földtudományi Kar Szekciókiadványa, pp. 66-72.
- SZABÓ N. P., DOBRÓKA M., 2001: Float-Encoded Genetic Algorithm used for the inversion of well log data. *Geosciences, Publications of the University of Miskolc, Series A – Mining, Vol. 59, pp. 139-152.*
- SZABÓ N. P., 2003: Applying Genetic Algorithm in the petrophysical interpretation. International Geophysical-Geological-Mining of fluid-Environmental Meeting / Conference and Exhibition, Szolnok 2003. Paper A18.
- SZABÓ N. P., 2004: Global inversion of well log data. *Geophysical Transactions, Vol. 44. Nos. 3-4. pp. 313-329.*
- SZ. B. HORVÁTH, 1973: The accuracy of petrophysical parameters as derived by computer processing. *The Log Analyst*, 1973. November-December, pp. 16-25.
- SZÜCS P. and STEINER F., 1997: Theoretical and practical consequences of the global optimization methods. *Optimum methods in statistics.* Akadémiai Kiadó Budapest.
- TARANTOLA A., 1987: Inverse problem theory - Methods for data fitting and model parameter estimation. Elsevier, pp. 187-190.
- TREITEL S. and HELBIG K., 1997: Seismic Exploration. CD-ROM, Elsevier.

FÜGGELÉK

-
- | | |
|----------------------|---|
| 1. melléklet | Linearizált és globális szélsőérték keresési eljárások működése |
| 2. melléklet | Szelekciós, keresztezési és mutációs operátorok működési sémája |
| 3. melléklet | A (3.3)-(3.10) válaszgyeletek petrofizikai paramétereinek jelölése |
| 4. melléklet | A (3.3)-(3.9) válaszgyeletekben szereplő szelvénykonstansok értékei zajjal terhelt szintetikus adatok inverziójánál |
| 5. melléklet | Az 5 %-os Gauss zajjal terhelt (I), és az 5 %-os Gauss + kiugró zajjal terhelt (II) adatrendszer szintetikus szelvényei |
| 6. melléklet | Az 5%-os Gauss-zajjal terhelt (I) adatrendszer DLSQ-I inverziójával nyert petrofizikai paraméterek korrelációs mátrixa |
| 7. melléklet | Az 5%-os Gauss zajjal terhelt (VI) szintetikus adatrendszer szelvényei |
| 8. melléklet | Az 5%-os Gauss-zajjal terhelt (VI) adatrendszer FGA+DLSQ-I inverziójával nyert petrofizikai paraméterek korrelációs mátrixa |
| 9. melléklet | A (IX) adatrendszer crossplot-jai |
| 10. melléklet | A szelvénykonstansok értékei terepi adatok inverziójánál |
| 11. melléklet | Fúrás-1 determinisztikus elvű (pontonkénti) Express CLASS értelmezése |


1. melléklet



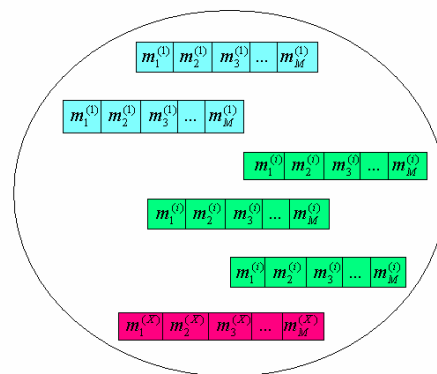
Jelölés	Jelentés
DLSQ	Csillapított legkisebb négyzetek elve
MSA	Metropolis Simulated Annealing algoritmus
E	Célfüggvény
m_i	i-edik modellparaméter
m_j	j-edik modellparaméter
$m_{i,0}$	Startmodell i-edik modellparamétere
$m_{j,0}$	Startmodell j-edik modellparamétere
$m_{i,lok}$	i-edik becsült modellparaméter DLSQ módszerrel
$m_{j,lok}$	j-edik becsült modellparaméter DLSQ módszerrel
$m_{i,glob}$	i-edik becsült modellparaméter MSA módszerrel
$m_{j,glob}$	j-edik becsült modellparaméter MSA módszerrel

2. melléklet


Kiinduló populáció S számú egyeddel




Szelektált populáció S számú egyeddel




Kiinduló modellpár




Keresztezett új modellpár



Kiinduló egyed



Mutált egyed










3. melléklet

Paraméter	Petrofizikai jelentés
ATCH	Szénhidrogén akusztikus terjedési ideje
ATSH	Shale-agyag akusztikus terjedési ideje
ATG	Gáz akusztikus terjedési ideje
ATMA	Mátrix akusztikus terjedési ideje
ATMF	Iszapfiltrátum akusztikus terjedési ideje
ATO	Olaj akusztikus terjedési ideje
ATTH	Akusztikus terjedési idő elméleti értéke
JCH	Segédváltó PORNEX számításában
KMA	Közetmátrix kálium tartalma
KMF	Iszapfiltrátum kálium tartalma
KSH	Shale-agyag kálium tartalma
KTH	Kálium természetes gamma intenzitás elméleti értéke
BA	Tortuozitási együttható
BM	Cementációs kitevő
BN	Szaturációs exponens
DECH	Szénhidrogén sűrűsége
DESH	Shale-agyag sűrűsége
DEMA	Mátrix sűrűsége
DEMF	Iszapfiltrátum sűrűsége
DETH	Sűrűség elméleti értéke
GRCH	Szénhidrogén természetes gamma intenzitása
GRSH	Shale-agyag természetes gamma intenzitása
GRMA	Mátrix természetes gamma intenzitása
GRMF	Iszapfiltrátum természetes gamma intenzitása
GRTH	Természetes gamma elméleti értéke
n	Közetmátrix komponenseinek száma
PMF	Iszapfiltrátum sókoncentrációja
POR	Effektív primer porozitás
PORNEX	Exkavációs hatás korrekció
PORNSH	Shale-agyag neutron porozitása
PORNMA	Mátrix neutron porozitása
PORNMF	Iszapfiltrátum neutron porozitása
PORNTH	Neutron porozitás elméleti értéke
RSH	Shale-agyag fajlagos ellenállása
RTTH	Érintetlen zóna fajlagos ellenállás elméleti értéke
RMF	Iszapfiltrátum fajlagos ellenállása
RX0TH	Kiöblített zóna fajlagos ellenállás elméleti értéke
RW	Rétegvíz fajlagos ellenállása réteghőmérsékleten
SCHB	Szénhidrogén koefficiens
SCHRB	Maradékolaj tényező
SPCHC	Szénhidrogén korrekció
SPSD	Természetes potenciál homokvonal
SPSH	Természetes potenciál shale-alapvonal
SPTH	Természetes potenciál elméleti értéke
SX0	Kisepert zóna víztelítettsége
SW	Érintetlen zóna víztelítettsége
THMF	Iszapfiltrátum tórium tartalma
THMA	Közetmátrix tórium tartalma
THSH	Shale-agyag tórium tartalma
THTH	Tórium természetes gamma intenzitás elméleti értéke
UMF	Iszapfiltrátum urán tartalma
UMA	Közetmátrix urán tartalma
USH	Shale-agyag urán tartalma
UTH	Urán természetes gamma intenzitás elméleti értéke
VSH	Shale-agyag fajlagos térfogata
VMA	Mátrix fajlagos térfogata

4. melléklet

Szelvénykonstans	Érték	Mértékegység
ATSH	330	μs/m
ATG	1260	μs/m
ATSD	182	μs/m
ATMF	620	μs/m
ATO	840	μs/m
BA	1.0	-
BM	2.0	-
BN	2.0	-
DECH	0.8	g/cm ³
DESH	2.46	g/cm ³
DESD	2.65	g/cm ³
DEMF	1.00	g/cm ³
GRCH	0	API
GRSH	100	API
GRSD	25	API
GRMF	0	API
PMF	0.0016	10 ⁶ ppm
PORNSH	0.38	p.u./100
PORNSD	-0.04	p.u./100
PORNMF	1.00	p.u./100
RSH	2.5	ohmm
RMF	2.0	ohmm
RW	0.5	ohmm
SCHB	1.0	-
SPCHC	0	-
SPSD	-42	mV
SPSH	0	mV

5. melléklet







6. melléklet

<i>Korrelációs átlag = 0.17</i>																				
-	POR1	SX01	SW1	VSH1	VSD1	POR2	SX02	SW2	VSH2	VSD2	POR3	SX03	SW3	VSH3	VSD3	POR4	SX04	SW4	VSH4	VSD4
POR1	1.00	0.04	0.48	0.61	0.10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
SX01	0.04	1.00	0.51	-0.67	0.22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
SW1	0.48	0.51	1.00	-0.20	0.22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
VSH1	0.61	-0.67	-0.20	1.00	-0.14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
VSD1	0.10	0.22	0.22	-0.14	1.00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
POR2	0	0	0	0	0	1.00	-0.53	-0.78	-0.23	-0.28	0	0	0	0	0	0	0	0	0	0
SX02	0	0	0	0	0	-0.53	1.00	0.45	-0.09	0.20	0	0	0	0	0	0	0	0	0	0
SW2	0	0	0	0	0	-0.78	0.45	1.00	0.03	0.25	0	0	0	0	0	0	0	0	0	0
VSH2	0	0	0	0	0	-0.23	-0.09	0.03	1.00	-0.10	0	0	0	0	0	0	0	0	0	0
VSD2	0	0	0	0	0	-0.28	0.20	0.25	-0.10	1.00	0	0	0	0	0	0	0	0	0	0
POR3	0	0	0	0	0	0	0	0	0	0	1.00	-0.27	-0.64	-0.47	-0.12	0	0	0	0	0
SX03	0	0	0	0	0	0	0	0	0	0	-0.27	1.00	0.56	-0.56	0.25	0	0	0	0	0
SW3	0	0	0	0	0	0	0	0	0	0	-0.64	0.56	1.00	-0.13	0.21	0	0	0	0	0
VSH3	0	0	0	0	0	0	0	0	0	0	-0.47	-0.56	-0.13	1.00	-0.16	0	0	0	0	0
VSD3	0	0	0	0	0	0	0	0	0	0	-0.12	0.25	0.21	-0.16	1.00	0	0	0	0	0
POR4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.00	-0.28	-0.66	-0.49	-0.15
SX04	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.28	1.00	0.43	-0.36	0.21
SW4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.66	0.43	1.00	-0.03	0.22
VSH4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.49	-0.36	-0.03	1.00	-0.16
VSD4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.15	0.21	0.22	-0.16	1.00

7. melléklet

Korrelációs átlag = 0.17																				
-	POR1	SX01	SW1	VSH1	VSD1	POR2	SX02	SW2	VSH2	VSD2	POR3	SX03	SW3	VSH3	VSD3	POR4	SX04	SW4	VSH4	VSD4
POR1	1.00	0.04	0.48	0.61	0.10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
SX01	0.04	1.00	0.51	-0.67	0.22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
SW1	0.48	0.51	1.00	-0.20	0.22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
VSH1	0.61	-0.67	-0.20	1.00	-0.14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
VSD1	0.10	0.22	0.22	-0.14	1.00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
POR2	0	0	0	0	0	1.00	-0.53	-0.78	-0.23	-0.28	0	0	0	0	0	0	0	0	0	0
SX02	0	0	0	0	0	-0.53	1.00	0.45	-0.09	0.20	0	0	0	0	0	0	0	0	0	0
SW2	0	0	0	0	0	-0.78	0.45	1.00	0.03	0.25	0	0	0	0	0	0	0	0	0	0
VSH2	0	0	0	0	0	-0.23	-0.09	0.03	1.00	-0.10	0	0	0	0	0	0	0	0	0	0
VSD2	0	0	0	0	0	-0.28	0.20	0.25	-0.10	1.00	0	0	0	0	0	0	0	0	0	0
POR3	0	0	0	0	0	0	0	0	0	0	1.00	-0.27	-0.64	-0.47	-0.12	0	0	0	0	0
SX03	0	0	0	0	0	0	0	0	0	0	-0.27	1.00	0.56	-0.56	0.25	0	0	0	0	0
SW3	0	0	0	0	0	0	0	0	0	0	-0.64	0.56	1.00	-0.13	0.21	0	0	0	0	0
VSH3	0	0	0	0	0	0	0	0	0	0	-0.47	-0.56	-0.13	1.00	-0.16	0	0	0	0	0
VSD3	0	0	0	0	0	0	0	0	0	0	-0.12	0.25	0.21	-0.16	1.00	0	0	0	0	0
POR4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.00	-0.28	-0.66	-0.49	-0.15
SX04	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.28	1.00	0.43	-0.36	0.21
SW4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.66	0.43	1.00	-0.03	0.22
VSH4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.49	-0.36	-0.03	1.00	-0.16
VSD4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.15	0.21	0.22	-0.16	1.00

9. melléklet



10. melléklet

Szelvénykonstans	Érték	Mértékegység
ATSH	100	μs/l
ATG	305	μs/l
ATSD	55	μs/l
ATMF	189	μs/l
BA	1	-
KMF	1.5	%
KSD	0.85	%
KSH	3.45	%
BM	1.5	-
BN	1.8	-
DECH	0.11	g/cm ³
DESH	2.54	g/cm ³
DESD	2.65	g/cm ³
DEMF	1.02	g/cm ³
GRCH	0	API
GRSH	160	API
GRSD	14	API
GRMF	0	API
PMF	0.0073	10 ⁶ ppm
PORNSH	0.27	p.u./100
PORNSD	-0.04	p.u./100
PORNMF	1.01	p.u./100
RSH	1.0	ohmm
RMF	0.29	ohmm
RW	0.5	ohmm
SCHB	1.4	-
SPCHC	0	-
SPSD	-42	mV
SPSH	0	mV
TMF	0	ppm
TSD	4.0	ppm
TSH	18.0	ppm
UMF	0	ppm
USD	1.0	ppm
USH	5.0	ppm

11. melléklet

