

МИННО – ГЕОЛОЖКИ УНИВЕРСИТЕТ “СВ. ИВАН РИЛСКИ”

Веселин Иванов Христов

**МОДЕЛИРАНЕ ПОКАЗАТЕЛИ НА НАХОДИЩА НА
ПОДЗЕМНИ БОГАТСТВА И СВЪРЗАНИ С ТЯХ
ОБЕКТИ ЧРЕЗ КОМПЮТЪРНИ СИСТЕМИ**

АВТОРЕФЕРАТ

на дисертация
за получаване на образователно научна степен „Доктор”

Научна специалност **„Маркшайдерство”**

Научни консултанти:

доц. д-р Станислав Топалов

доц. д-р Петко Лалов

София – 2013г.

Дисертационният труд е обсъден и насочен за защита на разширено заседание на катедра „Маркшайдерство и геодезия” при Минно геоложки университет „Св. Иван Рилски” – гр. София.

Данни за дисертационния труд:

- страници – 100
- фигури -38
- таблици – 13
- цитирана литература – 50
- публикации свързани с дисертацията – 7

Номерата на таблиците и фигурите в автореферата съответстват на номерацията в дисертационния труд.

Защитата на дисертацията ще се състои на от часа в зала на МГУ „Св. И. Рилски”, гр. София на заседание на научното жури.

Автор Веселин Иванов Христов

Научни консултанти:

доц. д-р Станислав Топалов

доц. д-р Петко Лалов

Заглавие: МОДЕЛИРАНЕ ПОКАЗАТЕЛИ НА НАХОДИЩА НА ПОДЗЕМНИ БОГАТСТВА И СВЪРЗАНИ С ТЯХ ОБЕКТИ ЧРЕЗ КОМПЮТЪРНИ СИСТЕМИ

Увод

Търсенето на минерални суровини зависи от състоянието на световната икономика и развитието на секторите, в които се извършва потреблението им. Стимулирането на развитието на минната промишленост в света се обуславя от ръста на световната икономика. Темповете на преработващата промишленост надвишават възможностите на минната, а индустриалното производство формира близо 50% от световния брутен продукт. Понастоящем в света се добиват над 150 вида полезни изкопаеми. Независимо, че запасите се отработват интензивно, те ежегодно се увеличават с 1,5 %, което добре кореспондира с ръста на населението в света.

Безалтернативното използване на резултати от научни изследвания и разработки на доказали се в практиката теории и иновационни технологии при оценката и структурирането на отрасли и осигуряване на приоритет на пазарните принципи е пътя, който бе възприет в миннодобивния отрасъл през последната декада на миналия век. В минното дело в европейски и световен мащаб, дори в страни с успешна икономика, се наблюдава известно съкращаване на научните изследвания. В развиващите се страни няма достатъчно човешки потенциал за провеждане на научни изследвания в минното дело, а в страните с бивша планова икономика – липсват достатъчно съвременни средства – информационни технологии, хардуер, специализиран софтуер и др.

Основните насоки на развитие на открития добив, свързани с иновации в техниката, организацията, автоматизацията на технологичните процеси се изразяват в:

- увеличаване на единичната мощност на основното товарно-транспортно оборудване;
- използване предимно на автомобилния транспорт, в това число и на циклично поточни технологии;
- автоматизация на управлението на транспортния поток, в това число с използване на GPS;
- сервизно обслужване на техниката в рудника от фирмите производители и др.
- екосъобразност при разработването на различните по минерален и химичен състав находища.

У нас след структурните промени на миннодобивния отрасъл делът на открития начин на разработване значително превъзхожда подземния добив.

Настоящото научно изследване е осъществено за обекти, чиито продукт е добито по открит начин подземно природно богатство.

Металогенните находища, разработвани в момента по открит начин у нас са със сложен структурен характер, водещ до високи рискове при прогнозиране на количествените и качествените показатели като екологосъобразността се определя от съдържанията на арсен, сяра и др. вредни вещества. В същото време производството на електроенергия в значителна

степен е осигурено от добив на въглища, предимно лигнитни. Тези въглища са богати на съдържание на сяра, фосфор и др. В минната дейност и в двата случая доскоро не се отчиташе отражението на присъствието на вредните компоненти в екосистемата. Причините за това – обективни и субективни, се допълват и от липсата на конкретни изследвания.

Ниските съдържания в рудите на цветни метали и високото пепелно съдържание във въглищните находища и сложния характер на изменчивостта им увеличават стремежа за привличане на нетрадиционни методи и прилагане на информационни технологии при тяхното изучаване. Това наложи изследването да бъде осъществено за условията на рудниците „Елаците” и „Асарел”, ТЕЦ „Кремиковци” и др. чрез апробация на приложни и авторови програмни продукти. За целта е използвана информация от хронологично реализираните етапи на проучване и мониторингови отчети.

Цел на настоящото научно изследване е неформално доказване, че *методите на минно геометричния анализ, базиращи се на геологомаркшайдерската информация за находищата и на информацията от последващата преработка на добитите минерални суровини са с определена приложна стойност при формиране на решения на технологични задачи, управление на качеството на добиваната суровина, и мониторинга на последствията от добива и опазването на околната среда.*

Постигането на тази цел изисква решаването на широк кръг от задачи, до степен на приложимост в практиката. Усилията са насочени към апробиране и разработване, в областта на специализирания софтуер на продукти, успешно решаващи:

- *прогнозни задачи в земните недра;*
- *класификации по количествени и качествени критерии на качествени показатели на находища в земните недра и екотовари;*
- *поведение на флуиди в различни състояния в райони, близки до преработването / потреблението на подземни богатства.*

Основните задачи на настоящето научно изследване на този етап изискват:

- *детайлно изучаване на опита и резултатите от предходни научни изследвания, обхващащи ги в тематично и технологично отношение (умишлено вградено в изложението на всяка глава на настоящия труд);*
- *апробиране на алгоритми и програмни продукти за автоматизираното им решаване;*
- *оценка на възможността за мултиплициране на ползваните методи и средства за решаване на определени прагматични задачи от областта на геологията, минното дело, екологията, опазването на околната среда и водите и т.н.*

За решаването на посочените основни задачи са използвани данни от активни и пасивни експерименти, осъществявани в геологопроучвателното и минното дело, планирани наблюдения за влиянието на екотовари. Общият обем информация надхвърля изискванията за създаване на статистически

съвкупности, осигуряващи надеждни решения. Информационните технологии са в основата на решаването на посочените задачи. Използваните методи се основават на теориите на едномерния и многомерния статистически анализ, случайните функции, временните редове, теорията на изкуствения интелект, механика на флуидите и т.н.

Актуалността на разработката се определя от:

- *многообразието на информацията, отнасяща се до земните недра, минните технологии, последствията от преработването / потреблението на подземни богатства и т.н., изискващо оценката на различни по професионална квалификация специалисти;*
- *възможностите за постигане на резултати (вкл. и междинни), ползвани от специалистите за оценки свързани с: целесъобразността за разработване на находището, определяне на стратегии за отработването му, възможностите за управление на качеството на добития продукт (руда, концентрат и др.), проследяването на последващи процеси от преработването / потреблението на подземни богатства;*
- *обогащаването на определен клас математични методи, използвани в геологопроучвателното и минното дело с алгоритми и технологии с такива, които в определена степен и приближение представят преобразуваното геохимично поле върху земната повърхност.*

I. Аспекти на компютърното моделиране при проучване и добив на подземни богатства

Компютърното моделиране има за цел да представи различни аспекти на реалния свят, тяхното взаимодействие и динамика чрез хардуерни и софтуерни средства. То се явява като четвърти стълб на научните изследвания и инженерното проектиране в допълнение на теоретичния анализ, експериментирането и математическото моделиране. В наши дни компютърното моделиране играе все по-важна роля в областта на проучването, добива и използването на полезни изкопаеми, както и в много други области.

Една от причините за това е, че стана възможна транслацията на математическите модели към алгоритми, които се изпълняват на мощни компютри. Развитието през последните 50 години на дисциплини, например числени методи, позволи различни уравнения получени при математическото моделиране (алгебрични, функционални, диференциални, интегрални и т.н.) да се решат алгоритмично. Това позволи за кратко време изключително сложни и трудни проблеми да намерят своето решение. На базата на този успех във все повече области започна използването на компютърно моделиране, включително и в геолого-проучвателното и минното дело.

В развитието на самата информатика се развиват следните направления:

- изкуствен интелект - невронни мрежи, генетични алгоритми, дълбочинен анализ на данни (data mining);
- дискретни структури – алгоритми върху дървета и графи и др.

Друга причина за широкото прилагане на компютърното моделиране в инженерните дейности е развитието на графичните хардуерни и софтуерни средства, на базата на които се развиха такива приложения като CAD, CAM и GIS системите и продукти за двумерна и тримерна симулация.

Компютърното моделиране в геолого-проучвателното и минното дело се характеризира със специфика и особености.

1.1. Особенности при моделиране на находища от природни подземни богатства

С навлизането на компютърната техника и информационните технологии в минното дело се очертават две основни направления на тяхното приложение:

- управление на информационните потоци и използване на компютъризирани технически средства по време на функционирането на минното предприятие;
- използване на подпомогнати от компютри и информационни технологии средства за вземане на решения при проучване, проектиране и изследване на формите и свойствата на находища на подземни богатства и свързани с тях обекти.

Изучаването и разработването на находищата на природни подземни богатства, се характеризират с редица особености, които се вземат предвид при

тяхното моделиране - етапи на изучаване, респективно с обем и плътност на наличната информация и нейната надеждност при избора на технология за моделиране; подбор на средства и адекватност на избрания модел.

От друга страна рудникът следва да се разглежда като специфична производствена система с редица особености: рудникът е сложна, цялостна, добивна, стохастична, динамична, инерционна, кибернетична система.

Включването в компютърни модели на натрупаните през вековете знания при изучаване и разработване на находищата, от една страна и на натрупващите се знания за конкретно находище, от друга би довело до интензификация и обективност на използване на тези знания. Еволюцията на методите и средствата за събиране, систематизиране, обработване и пространствено представяне на резултатите включително и за геологомаркшайдерската информация значително облекчава нейното използване в компютърните модели. Чрез тях се автоматизира дълбочинната обработка и анализ на големи масиви данни свързани с решаването на конкретни геоложки, маркшайдерски и минно технологични задачи. Един от методите за решаване на посочените задачи е статистическото моделиране.

1.2. Статистически модели при изучаване на находищата от подземни богатства

В геологопроучвателното и минното дело моделирането е утвърдено средство за изучаване на обекти, форма, свойства и процеси. При изучаването на недрата то има познавателна и методологична функция.

Находищата на подземни богатства са сложни и многостранни природни обекти. Предвид целите и задачите, могат да се изградят множество теоретични модели за определено находище. Използват се основно три вида теоретични модели: дискретен йерархичен за строежа на недрата; на полето на разпределението на свойствата и на генезиса на находището.

През втората половина на миналия век, теорията на случайните процеси е намерила приложение във формализацията на някои явления и в използвани технологии, включително и такива от областта на проучването и разработването на находищата.

От физична гледна точка, за представянето на случайния процес е допустимо да се използва само една реализация. От математическа гледна точка отделната реализация е детерминирана функция на времето. Чрез нея могат да се определят статистическите свойства на процеса, при условие, че са изпълнени някои изисквания. Свойствата на случайните процеси могат да се опишат чрез вероятностни характеристики – разпределение на вероятностите, корелационната функция, спектралната функция, интервал на корелация, ефективна ширина на спектъра и т.н. Случайните процеси, анализирани в приложните науки, са **стационарни, нестационарни, ергодични, неергодични и др.** Теорията на случайните процеси се използва с определен успех при описание на геохимични полета, при прогнозиране на геолого-геофизични характеристики, интерполация на геоложки характеристики, в тренд-анализа,

геостатистиката, при изчисляване на запасите от подземни богатства, в хидрогеологията, при изследването на тектонски явления и др.

При решаването на много задачи от геологопроучването се използва количествена оценка на пространствената изменчивост на геоложките свойства. Случайните по характер (геоложки) процеси, при подобни изследвания позволява да бъде използван апарата на теорията на случайните функции.

Основните характеристики на случайната функция са: математическо очакване M_x , дисперсия D_x , корелационна функция $K_x(\tau, \tau')$ и структурна функция $\gamma(\tau, \tau')$ на дисперсиите. Характеристиките на случайните функции са функции.

Теорията на случайните процеси/функции, реализирана в редица изследвания дава възможност да се проследи поведението на геоложки показатели в зависимост от един или няколко неслучайни параметъра.

През 60-те години на миналия век се появява направлението геостатистика. Тя е реализация на теорията на случайните функции.

Основна цел на геостатистическото моделиране е оценката на средните значения на изучаваните параметри в границите на проучвания участък или блок, като функция от тяхната пространствена изменчивост, в зависимост от геометричните особености на оценявания блок, пространственото положение, размерите, формите и ориентираността на проучвателните сондажи, изработки и проби. С помощта на корелационната или структурната функция, се определя дисперсията и ковариацията на разпространение на значението на изследвания показател на оценявания обект – свойство, структура и т.н.

За практическото използване на геостатистическите модели е необходимо да се определи зависимостта между дисперсията на средните значения на изучаваното свойство и тежестните коефициенти от параметрите на природната изменчивост на полезното изкопаемо, параметрите на проучвателната мрежа, геометрията на пробите и блоковете. Широкото използване на геостатистическите методи в практиката трябва да се предшества от изучаване на характеристиките на изменчивостта на параметрите с помощта на теорията на случайните функции, основана на експериментални проучвателни и експлоатационни данни.

Инженерният подход за моделиране на минно-геоложки обекти е по ефективен при използване на специализирани програмни продукти.

1.3. Програмни системи за моделиране на минно геоложки обекти

Системите за компютърно моделиране могат да се разделят на общо целеви и специализирани. От друга страна според това, до каква степен подпомагат изследователите при изграждането на модела, те могат да се разделят на:

- Инструменти подпомагащи процеса на моделиране, където могат да бъдат включени широк спектър от програмни системи, като се започне от електронните таблици, например Microsoft Excel и се стигне до системи за математически и статистически пресмятания, например Mathematica на Wolfram Research и Statistica на StatSoft Inc.

- Шел системи. Те съдържат всички необходими средства за изграждане на модела, обикновено се нуждаят от запълване с конкретни данни. Повечето са отворени и допускат надграждане.
- Завършени (затворени) системи. Това са системи изградени да моделират точно определена задача. Необходимо е само да бъдат захранвани с конкретни данни.

Съвременното световно ниво на компютърните графични системи за минната промишленост се характеризира с разнообразие, активност и динамичност на развитието, готовност за удовлетворяване практически на всякакви специфични изисквания на клиентите – при наличие на необходимите средства у тях и достатъчно квалифициран персонал за овладяване на сложните програмни продукти.

Като наложили се в практиката специализирани компютърни системи могат да се посочат: DATAMINE, VULCAN (MAPTEK), MINESCAPE (MINCOM), GEMCOM, MINEFRAME и др.

В заключение може да се посочи, че специализираните системи успешно решават кръга задачи, точно за които са създадени, но в известна степен техен недостатък е, че те са трудно приложими извън тях. От друга страна общоцелевите системи изискват високо квалифицирани специалисти и повече усилия при тяхното прилагане, но пък могат да се използват при решаването на разнородни по характер задачи и проблеми.

Напоследък в много от тези системи се влагат средства на изкуствения интелект.

1.4. Компютърно моделиране чрез изкуствени невронни мрежи

Научното направление изкуствен интелект е клон на информатиката, чиято задача е да разработи софтуерни и хардуерни средства, моделиращи поведението на човека и в частност неговата интелигентност.

Различни направления и средства на изкуствения интелект се използват в изучаването и разработването на находищата на природни подземни богатства. Такива са:

- роботика – в роботизирани добивни комплекси;
- разпознаване на образи – за автоматично класифициране на аерогеоснимки, на добитата руда в обогатителните фабрики и др.;
- автоматизирано интелигентно управление – на лентови транспортни системи, вентилация на подземни рудници и др.;
- експертни системи – като съветващи системи при вземане на оперативни решения и при проектирането;
- генетични алгоритми и невронни мрежи – при компютърното моделиране.

В дисертационния труд се използва апарата на невронните мрежи при решаване на задачи за класификация, моделиране и прогнозиране показателите на рудни находища у нас.

Като начало на изкуствените невронни мрежи или накратко само невронни мрежи се счита разработеният през 1943 г. опростен модел на


невронната клетка като градивен елемент на изчислителна схема. Невронните мрежи като средство на изкуствения интелект се характеризират със следните основни свойства:

- те са опростен модел на свързаните един с друг неврони в човешкия мозък.
- извършват паралелна обработка на информацията, което им дава възможност с малко на брой стъпки да решават сложни задачи.
- нуждаят се от първоначално обучение или самоорганизация.

Невронната мрежа представлява множество от възли наречени неврони, свързани с насочени връзки, всяка от която има тегло w_{ij} . Съществуват две основни архитектури на невронните мрежи:

- С разпространение напред (feed forward). При тях данните се движат стриктно от входните неврони към изходните, т.е. няма обратна връзка.
- Рекурентни мрежи. При тях съществуват обратни връзки. В този случай към данните идващи от входа се добавят данни идващи по обратната връзка и се получава нещо като памет на мрежата за предходните и състояния. Мрежата има устойчиви и неустойчиви състояния.

В представените тук изследвания се използват невронни мрежи без обратни връзки. Невроните в такава мрежа са разпределени в слоеве: в първия слой са входните неврони, получаващи входните данни ($x_1, x_2, \dots, x_n$), в крайния слой са изходните неврони, които формират изходните данни ($o_1, o_2, \dots, o_m$), останалите слоеве се наричат вътрешни (скрити). Всеки неврон от един слой е свързан с всички неврони от следващия слой. В повечето случаи невроните с изключение на входните имат връзка с околната среда наречена влияние (bias) θ . Всеки неврон i има входна функция i_i , която формира обобщения вход от всички входящи в него връзки и активираща функция F_i , която формира изхода a_i на неврона. Използват се различни активиращи функции на неврона, (Фигура 1.4.2).



Фиг. 1.4.2. Видове активиращи функции на неврон

За да се използва невронната мрежа тя трябва да се обучи. Съществуват два основни вида обучения:

- **С учител**. Формира се обучаваща извадка, състояща се от определен брой обучаващи примери. Всеки пример се състои от данни за входовете на мрежата и целеви стойности за изходите на мрежата. С помощта на тази извадка се извършва обучението.

- **Без учител.** В този случай няма данни за целеви изход на мрежата, а се използват само входни извадки. Обучението се свежда до това, че при достатъчно близки според някаква мярка входни извадки да се получат еднакви или близки изходи.

Използват се различни алгоритми за обучение на невронните мрежи, например: метод на обратното разпространение (back propagation), метод на бързото разпространение (fast propagation), градиентни методи, конкурентни методи, метод на Хеб, метод на Кохонен и др.

През последните 20-30 години са разработени многобройни видове невронни мрежи, които трудно могат да бъдат изброени и класифицирани в рамките само на една точка. Поради това тук са разгледани накратко само тези намерили приложения или споменати в настоящия материал.

Персептрон. Той има един, два или повече скрити слоеве. Използва се главно обучение с обратно разпространение, но също спрегнато градиентно спускане, квази-нютонев метод и др. Тези мрежи се използват при решаване на сложни задачи като разпознаване на реч, разпознаване на сложни образи, машинен превод и др.

Мрежи с радиални базисни функции. Това е трислойна мрежа с разпространение напред, в която невроните от скрития среден слой са радиални, а невроните от изходния слой са с псевдо-линейна активираща функция. Активиращата функция на радиалния неврон се нарича радиална базисна функция и зависи от разстоянието на входния сигнал до точка определена като централна точка на неврона. Обучението на мрежата включва два етапа: намиране на оптимални централни точки за радиалните неврони и обучение на невроните от изходния слой. Обучаващи методи са: методи на подизвадките и на k – средното. Често наричат тези мрежи универсален апроксиматор и те могат да апроксимират сложни многомерни функции.

Обобщени регресионни невронни мрежи. Основните им характеристики са: мрежа с два скрити слоя, с разпространение напред. Първият слой е с радиални неврони. Препоръчва се броят им да е равен на обучаващите данни, което е трудно постижимо при голям брой данни. Вторият скрит слой се състои от неврони, които са с един в повече от изходните. Задачата им е да изчислят претеглено средно от сигналите на невроните от предния слой и да го дадат на невроните от изходния слой. Обучението на този вид мрежи е сходно с това на тези с радиални базисни функции. Те работят по-бавно и изискват повече памет. Могат да се използват при регресионно моделиране.

Класифициращи мрежи. Те принадлежат към самоорганизиращите се мрежи. Необходимо е мрежата да се обучи така, че при подаване на данни на входните възли тя да може да определи, към кой клас тези данни принадлежат. Невронната мрежа има само два слоя възли - входен и изходен и всеки входен възел е свързан с всички изходни. Всички връзки имат тегла. Броят на входните възли е равен на размерността на входните данни. Броят на изходните възли е равен на броя на класовете.

В наши дни невронните мрежи намират широко разпространение в различни области. Могат да се обособят четири групи приложения:

- **Моделиране.** Осъществява се чрез извършван от невронни мрежи апроксимационен или регресионен анализ на (в общия случай) многомерни данни. Така мрежите стават средство на едно ново направление наречено дълбочинен анализ на данни (data mining).
- **Прогнозиране.** На базата на регресионен анализ или анализ чрез временни редове извършен чрез невронни мрежи се осъществяват предсказване на показатели в минното дело и геологията (Точка 3.2).
- **Класифициране.** Невронни мрежи се използват за класифициране на данни и на обекти от реалния свят в някои случаи в реално време. Широко се прилагат невронни мрежи при разпознаване на образи, например в системи за идентификация, разпознаване на ръкописен и растерен текст, разпознаване на минерали, аерогеоснимки, руда постъпваща в обогатителна фабрика, задачи от геомеханиката и др.
- **Контрол и управление.** Предварително обучени невронни мрежи се монтират в управляващи блокове и агрегати на различни устройства и извършват автоматичен контрол и управление в реално време. Например в минните предприятия могат да участват в управлението на различни добивни комплекси, лентови транспортни системи, да контролират показатели при обогатяване на рудата и др.

II. Изследване на характера, формите и свойствата на недрата (геохимични полета)

Един от основните подходи при изучаването на свойствата/структурата на находищата на подземни богатства е възприемането на теорията за полевата им форма. В тази теория се приема, че генезиса на находището в общия случай предопределя неговата слоисто-струиста структура. Това означава, че ако вземем някакво свойство на определена точка от находището на природно подземно богатство (например съдържание на някаква полезна компонента), то се явява функция $V(x, y, z, t)$ на координатите на точката и времето, която отговаря на следните четири условия:

1. крайност, т.е. стойността на V не може да е безкрайно голяма,
2. еднозначност, т.е. за всяка точка от полето с координати (x, y, z) и за дадена епоха t функцията V има само една определена стойност,
3. непрекъснатост, съгласно която при незначително малки премествания на точката стойността на функцията се променя незначително малко
4. плавност, съгласно която повърхностите образувани от еднакви стойности на V нямат остри чупки или особени точки.

В реалните находища е възможно някои от тези условия да не са изпълнени навсякъде (локални натрупвания, първични или вторични изменения, тектонски процеси). Това изисква прецизното им изясняване и при необходимост обособяване на части от находището, за които тези условия са изпълнени.

Наред с теорията за полевата форма, тенденциите за оценка на свойствата (формата) преминават през:

- оценки за стационарност и ергодичност
- изясняване на структурата на находището – класификационен и клъстерен анализ.

2.1. Стационарност на основен геоложки фактор (съдържание на мед) проверка или приемане априори? [6]

Стационарността на геоложките фактори, чрез които се оценяват находищата, особено тези на металогените, има теоретична и методична значимост. Чрез апарата на стационарните случайни процеси може да се изследва нееднородността на вътрешния строеж на природните натрупвания на подземни богатства и се извърши количествено описание на наблюдаваната изменчивост, с отделяне на елементите на нееднородност в зависимост от геометрията на проучвателната мрежа. В дисертационния труд е изследван стационарният характер на т. нар. пространствени променливи (вслучая съдържание на мед) чрез математическото очакване, дисперсиите, автокорелацията и т.н.

2.1.1. Хипотеза за стационарност на геоложки показател - форми и някои приложения

В практиката се е наложило становището, че прилагане на апарата на случайните функции при пространственото моделиране на свойствата и показателите на находището, е възможно, ако изменението на показател е стационарно. Въпросът за стационарността всъщност е въпрос за коректен избор на мащаба на разглеждане на анализираното явление.

В специализираната литература по геостатистика често се срещат препратки към теорията за стационарността, а в някои източници се твърди, че стационарността е необходима за прилагане методите на геостатистиката на практика.

В геостатистиката се приема допускането, че една променлива е **стационарна**, ако нейното разпределение е инвариантно към транскации в пространството (т.е. не зависи от местоположението). Така стационарната случайна функция е хомогенна и се повтаря в пространството, което дава възможност за статистически изводи въз основа на единични реализации. Съществуват различни форми на стационарност:

Силна (строга) стационарност. Нека $Z(x)$ е случайна функция, например съдържание на мед в проба с координати x . Тази случайна функция е строго стационарна, ако за всяка произволно дълга извадка от проби $(x_1, x_2, \dots, x_n)$ и всяко произволно изместване на разстояние τ на извадката - $(x_1 + \tau, x_2 + \tau, \dots, x_n + \tau)$, разпределението на случайната функция остава едно и също. За да се провери това изискване е необходимо да се проверят за еднаквост всичките моменти на произволна извадка със всякакви нейни транскации в пространството.

Слаба (отслабена) стационарност. Тя още се нарича стационарност от втори ред. В този случай се проверяват за постоянност само първите два момента – математическото очакване (средната стойност) и ковариацията на различни транслирани една спрямо друга извадки

Вътрешна хипотеза. В този случай се твърди, че съществува стационарност от втори ред, ако за разликата между две извадки, т.е. $Z(X) - Z(X + \tau)$ са изпълнени условията:

- 1) $E(Z(X) - Z(X + \tau)) = 0$ за всяко X и τ ,
- 2) $\gamma(\tau) = 0.5 \text{Var}[Z(X) - Z(X + \tau)]$.

Слаба стационарност с дрейф. В някои случаи в изследваната случайна величина се наблюдава наличието на тренд в някакво направление. Тогава тя може да се представи като сума от тренда и остатък (residual) $Z(X) = Y(X) + Tr(X)$, където $Y(X)$ е остатъка, а $Tr(X)$ е тренда - гладка функция независеща от $Y(X)$. Случайната функция $Z(X)$ е слабо стационарна с дрейф, ако за $Y(X)$ са изпълнени условията на вътрешната хипотеза, а $Tr(X)$ е линейна комбинация от известни независими функции.

Как да се определи стационарна ли е променливата? Един от начините, даващ отговор на този въпрос, е изследване характера на структурната функция/вариограмата.

Съществува обаче и друга гледна точка. Стационарността (в чист вид или в нейните слаби форми) се определя от свойствата на случайната функция – именно функцията за цялата съвкупност, а не по няколко примера (проби) от единствената реализация.

В по-късните етапи на изследване на характера на изменение на геоложките фактори, с включване на данните от предварителното и експлоатационно опробване обемът и плътността на информацията значително нарастват и дават възможност за формиране на реализации на функцията на изменение в различни местоположения и направления.

2.1.2. Обект на изследване


Находище „Елаците” - Етрополска Стара планина е открито през 1952 г. и детайлно проучено през периода 1959 – 1968 г. Пространственото разпределение на основния полезен компонент – съдържание на мед в рудното тяло е изследвано достатъчно пълно и е описано подробно още в първите геоложки доклади. По-късно (1993 г.) е извършена геометризация за разпределението на съдържанието на мед и други минерали като са използвани данни за групови проби от детайлното проучване (20959 бр.) и данни от експлоатационното проучване (2509 бр.).

В рудите от находището са установени 61 минерала – 48 рудни и 13 нерудни, като главните рудни са халкопирит и пирит. Рудите в находището, предвид изискванията на обогатителните технологии, са разделени на три сорта: сулфидни – с окисна мед до 10 %; смесени – с окисна мед от 10 до 30 % и оксидни – с окисна мед над 30 %.


2.1.3. Технология на изследване и анализ на резултатите

Целта на настоящото изследване е определяне на характера на съдържанието на мед между хоризонти 1015 и 940 по отношение на неговата стационарност. За осигуряване на по-голяма масовост на данните са използвани стойностите на показателя от етапа на експлоатационното проучване (7327 проби в 6 хоризонта).

Технологията на изследването изисква формиране на редове от информация за съдържанието на мед – реализации на случайната функция, представяща изменението му в определено произволно направление през определена стъпка τ . Поради несъвпадането на направленията на изследване с мрежата на опробване е приложен следният подход: изчисляват се координатите на точките по избрано направление през стъпка τ и след което се изчислява притеглено средно на съдържанието на мед от пробите попадащи в околностите на точките със зададен радиус на търсене. Теглата на пробите, които са по-близо до центъра на околността са по-големи. За всеки експлоатационен хоризонт се изчисляват стойностите на съдържанието на мед по 12 радиално разположени около геометричния център основни направления (Фигура 2.1.1) и след това за всяко направление тези стойности се изчисляват за още 60 успоредни на него направления (Фигура 2.1.2).



Фиг. 2.1.1. 12 основни радиални направления, хоризонт 1015, стъпка 35m, брой точки 20




Фиг. 2.1.2. Успоредни на едно радиално направление

За извършване на изчисленията са разработени 3 макроса на Microsoft Visual Basic® for Applications (VBA):

1. За изчисляване координатите на по 2 крайни точки от основните радиални направления. Програмата намира геометричния център на всички проби в хоризонта, намира двете най-отдалечени проби и след това намира ротациите им около геометричния център според броя на радиалните направления.
2. За изчисляване координатите на по 2 крайни точки от успоредните на дадено основно направление. Програмата намира транслираните през зададеното разстояние крайни точки на успоредните линии, като половината линии са от едната страна на направлението, а друга половина от другата страна.
3. За изчисляване претегленото средно на съдържанието на мед по дадено направление през зададена стъпка и радиус. Програмата намира координатите на точките от направлението през зададената стъпка, изчислява претегленото средно от съдържанието на пробите попадащи в кръга със зададения радиус.

3 всеки хоризонт са изчислени 12 основни радиални направления, а за всяко направление са изчислени по 60 успоредни на него направления на разстояние едно от друго от 10 m. По всяко направление са изчислени 150 притеглени средни стойности на съдържанието на мед през стъпка 5, радиус 10. По този начин за всяко от 12-те основни направления са получени в табличен вид ансамбли от по 61 успоредни реализации на случайни функции. За всяко сечение отместено на стъпка τ в даден ансамбъл (61 точки) са определени математическото очакване и дисперсията.

Освен това са определени чрез STATISTICA 7 стойностите и графиките на автокорелационните функции на реализациите за всички направления.




Фиг. 2.1.4. Автокорелационна функция - хоризонт 985 - направление 1-1

Във всяко от основните направления за отделните хоризонти се наблюдава сходство в характера на изменение на съдържанието на мед и степента на отклонение. Подобно сходство се забелязва и между отделните основни направления, което подсказва за изотропен характер на изменение на изследвания геоложки показател и в границите на всеки хоризонт. Слабото

изменение на математическото очакване и дисперсията дават основание за издигане хипотезата за стационарност от втори ред на съдържанието на мед (Фигура 2.1.5).

Анализът на стойностите и графиките на автокорелационните функции (72 броя) за основните направления, за всеки хоризонт показват, че те имат намаляващ характер, което доказва наличието на стационарност на случайната функция – изменение на съдържанието на мед в отделните хоризонти и в различните направления за тях. В някои случаи се забелязва и периодичност в изменението на автокорелационните функции, което предполага и периодичност в изменението на случайните функции.



Фиг. 2.1.5. Математическо очакване и дисперсия на две направления на шестте хоризонта

2.2. Класификационен и клъстерен анализ в медно находище за целите на оперативното планиране на добива в открит рудник [5]

Класификацията и клъстеризацията са изследователски средства за анализ на данни, които насочват към групиране на различни обекти по такъв начин, че степента на близост между два обекта да е максимална, ако те принадлежат към една и съща група и минимална в обратния случай. Тези изследователски средства са приложени за целите на откриването на наличие на определени класове и клъстери и очертаване на тяхното положение в работния хоризонт. Благодарение на този анализ се решават следните по-значими задачи важни за минно-добивната дейност:

- определени са границите на еднородни, по отношение на съдържанието на мед и сяра, зони (класове) в отделните добивни хоризонти,
- определяне на класове, обособени по съчетание на полезен и вреден компонент
- проследено е присъствието и изменението на едни и същи класове в добивните хоризонти, разгледани в дълбочина,
- предложена е авторова програма за намиране разделението на определен клас в един хоризонт на клъстери и определяне границите и площта на посочен (изборно) клъстер – основа за изчисляване количеството полезен компонент в него,

Разкриването на наличие на еднородни участъци (класове и клъстери) и качествено им и количествено описание подпомага минното планиране и снижава риска при вземане на технологични решения.

Изследването е извършено за условията на находище Асарел. В него са формирани са три типа мед: първично сулфидна, вторично сулфидна и окисна. Основен неруден минерал е кварца. Халкоцитът и ковелинът от вторичните сулфидни руди са с промишлен интерес. Оксидните руди имат голямо сярно съдържание. Минерализационната ера е над кредата. Зоната на главния вид руда е 1200 m, на вторичния вид е 120 m, а на оксидния – 12 m от земната повърхност. Средното съдържание на мед е около 0.4%.

Получената геолого-маркшайдерска информация от детайлното, пред експлоатационното и експлоатационното проучване е база за извършения анализ. Данните носят следната информация – пространствени координати, съдържание на мед и съдържание на сяра.

2.2.1. Научна обосновка

Класификацията е един от най-първите основни методи на научното познание. Под класификация се разбира отнасянето на обекти от дадено множество към няколко предварително зададени класове. Тя може да е едномерна (по един признак) или многомерна (по няколко признака). Използват следните методи:

- класификационни експертни правила,
- математически формули,
- дърво на решенията,
- бейсовска (наивна) класификация,
- невронни мрежи,
- по метода на опорните вектори,
- статистически методи, най-често линейна регресия,
- по метода на най-близкия съсед,
- генетични алгоритми,
- по метода на Case-Based Reasoning (CBR) – разсъждение базирано на предишен опит.

Терминът клъстерен анализ обхваща различни алгоритми и методи за групиране на обекти от подобен вид към съответни категории. Той се явява

логическо продължение на класификацията, но е по-сложен. Характеризира се с това, че класовете от обекти (кълстери) първоначално не са известни. Резултатът от кълстеризацията се явява разбиването на данните на групи.

В практиката геолозите и минните инженери често изпитват нужда от класифициране на геоложки обекти и процеси. То е необходимо да се подчинява на следните правила:

- еднаква база се прилага в една класификация;
- обемът на класифициран клас е равен на сумата от обемите на подкласовете;
- класове и подкласове не се пресичат;
- подразделянето на подкласове се извършва последователно.


Най-често геолозите решават следните два класификационни проблема:

1. Естествено разделяне на геоложките обекти в ясно очертани групи наречени класове, кълстери или таксони, които могат да са на някакво разстояние една от друга.

2. Типизиране, в което обектите са разделени на малък брой групи лежащи на неголеми разстояния.

Типизирането винаги има решение, докато задачата за кълстеризиране не винаги е решима, т.е. съществува само един кълстер.

Класификация на геоложки обекти може да се направи числено, по качества или чрез класификационни белези. Могат да се използват формални математически методи и/или неформални евристични методи. При евристичните методи групирането се извършва от специалисти на основата на тяхно експертно знание.




Фиг. 2.2.1. Разпределение на данните за мед и сяра а) логнормално за медта и б) нормално за сярата

Резултатите от минно геометричния анализ на основния параметър – съдържание на мед – показват, че разпределението е твърде различно от нормалното и има положителна асиметрия, т.е. съществува реална възможност за издигане на нулева хипотеза за логнормалното му статистическо разпределение (Фигура 2.2.1 а). Другият параметър – съдържание на сяра – има

разпределение, което е по-близко до нормалното (Фигура 2.2.1 b). Изследването на характера на изменение на съдържанието на мед чрез теорията на случайните функции дава основание да се потвърди анизотропията му.


Първоначално за намиране на групирането на качествените показатели на рудата са приложени формални подходи на клъстерния анализ. Чрез системата STATISTICA 7.0 на StatSoft Inc. са реализирани два статистически алгоритъма – йерархична клъстеризация (tree clustering) и клъстеризиране чрез К – средни (K-mean clustering). За съжаление резултатите от тяхното прилагане не са удовлетворителни. Причината за този резултат вероятно е в относително плавния характер на изменение на съдържанието на мед. Не се наблюдава групиране в пространството на рудното поле на ясно различими граници между пробите с различно съдържание на мед.



Фиг 2.2.2. Резултати от класифициране чрез експертно групиране на съдържанието на мед за трите добивни хоризонта.

Това е основанието да се приложи алтернативният подход – експертно класифициране. Експертната оценка за определяне броя на групите и границите на изменение на параметрите вътре във всяка група, е използвана като мяра за сходство. Броят на групите е определен по технологични съображения - режим на първична преработка на минералите. Групирания са осъществени по: съдържание на мед, съдържание на сяра и съдържание на мед и сяра едновременно, съответстващи на изследваните три избрани производствени режима. Стойностите на съдържанието на мед и съдържанието на сяра са разделени на по пет интервала – като така се получават пет групи. Разглеждането на съдържанието на мед и сяра едновременно е извършено чрез разделяне на девет групи – по три интервала за всеки от двата показателя. При определянето границите на петте групи на съдържанието на мед е взето предвид логнормалното разпределение на този параметър. Така са получени интервали с различна дължина. Интервалите за съдържанието на сяра са с еднаква дължина и са центрирани спрямо средната стойност на този параметър.

Деветте групи представящи двата показателя заедно са дефинирани по критерия – ниско, средно и високо съдържание.



Фиг. 2.2.3. Резултати от класифициране чрез експертно групиране на съдържанието на сяра за трите добивни хоризонта

На базата на това групиране са дефинирани съответни логически функции чрез които е определено всяка проба, към кой клас принадлежи (Фигури 2.2.2 и 2.2.3).

2.2.2. Резултати от класификацията

Анализът на разположението на отделните класове за всеки добивен хоризонт разкрива известно препокриване на отделните групи. Фигура 2.2.2 показва резултата от класифициране чрез експертно групиране за съдържанието на мед в местата на опробване от трите производствени хоризонта. Вертикално може да се проследи взаимното разположение на класовете в един хоризонт, докато хоризонтално е показано изменението на класовете в дълбочина (Н – 870 → Н – 855 → Н – 840). По същия начин на Фигура 2.2.3 са показани класовете на съдържанието на сяра.

Фигура 2.2.2 показва, че в един и същ хоризонт има някакво пространствено групиране на съдържанието на мед в различни интервали, т.е. формират се класове. От друга страна тези класове частично се препокриват в следния ред – всеки клас с по-високо съдържание лежи над тези с по-ниско. Това заключение е валидно и за трите добивни хоризонта. Разглеждайки местоположението на всеки клас в дълбочина (за трите изследвани хоризонта) преобладава заключението, че местоположението на класовете относително се запазва и нещо повече - формата им донякъде също се запазва, което е твърде важно да се знае във фазата на оперативното планиране на минните дейности.

От Фигура 2.2.3 се вижда, че съдържанието на сярата е групирано пространствено по аналогичен начин, но с по-малко препокриване между


отделните класове в един и същ хоризонт. Между съдържанието на мед и съдържанието на сяра не съществува корелационна връзка ($r=0,38$).

2.2.3. Класификация чрез невронни мрежи

След като е извършена експертната класификация, се поставя задачата: може ли да се обучи класифицираща невронна мрежа, която да определя една нова проба към кой клас принадлежи.

Класифициращите невронни мрежи принадлежат към самоорганизиращите се мрежи. Необходимо е те да се обучат така, че когато проба се подаде на входните възли на такава мрежа, тя да може да определи, към кой клас тази проба принадлежи. Когато мрежата е добре обучена, подавайки една входна проба към нея ще се активира само един изходен възел наречен победител – възелът отговорен за класа на входната проба. За да се обучи класифициращата мрежа е необходимо да се подготви обучаваща извадка от входни даннови проби и изходен вектор със същата дължина като броя проби в извадката, чието елементи са кодови номера или етикети на класовете формирани от входните данни.

Системата STATISTICA 7.0 има модул “Neural Networks”, включващ класифициращи мрежи. В рамките на това изследване, като е използван този модул, са обучени седем класифициращи мрежи – три за съдържанието на мед (по една за всеки от трите добивни хоризонта), три за съдържанието на сяра (пак по същата причина) и една за съдържанието на мед и сяра, разглеждани едновременно. В процеса на обучението са използвани резултатите от експертното групиране. Шестте мрежи имат по един входен възел – съответно за съдържанието на мед и съдържанието на сяра и по пет изходни възела за петте възможни класа (Фигура 2.2.4 а). Седмата мрежа има два входни възела – по един за съдържанието на мед и съдържанието на сяра и девет изходни възела за деветте възможни класа (Фигура 2.2.4b).



Фиг. 2.2.4. Архитектура на класифициращи невронни мрежи - а) съдържание на мед или сяра поотделно; б) съдържание на мед и сяра, разглеждани едновременно

Таблица 2.2.1. Резултати от обучението на седем класифициращи мрежи

Съдържание, хоризонт	Класифицираща мрежа	Обучаваща грешка	Обучаващ модел	Корелация
CU, Н 870	1:1-5:1	0.020478	KM,LV5000	0.88
S, Н 870	1:1-5:1	0.040118	KM,LV5000	0.95
CU, S, Н 870	2:2-9:1	0.055307	KM,LV5000	0.77
CU, Н 855	1:1-5:1	0.028372	KM,LV5000	0.83
S, Н 855	1:1-5:1	0.037801	KM,LV5000	0.95
CU, Н 840	1:1-5:1	0.029989	KM,LV5000	0.90
S, Н 840	1:1-5:1	0.036000	KM,LV5000	0.95

Резултатите от обучението на седемте класифициращи мрежи са показани в Таблица 2.2.1. В последната колона е посочена стойността на коефициента на корелация между обучаващите класове и предсказаните от мрежата класове. Връзката между тях е значима според стойностите на корелационните коефициенти. Стойността на грешката при обучение може да се оцени като приемлива. Този резултат показва, че класифициращи невронни мрежи могат да се използват за предсказване на качествени показатели на находището.


2.2.4. Пространствено клъстеризиране за фиксирано съдържание

От фигури 2.2.2 и 2.2.3 се вижда, че пробите, които влизат в един клас са разпръснати неравномерно на различни места из целия изследван хоризонт.


След като, на базата на експертно знание, пробите в границите на един добивен хоризонт са разделени на групи според стойностите на съдържанието на изследваните компоненти, възниква задачата за очертаване на местата, в които се концентрират пробите от една група. Така се разделя класът на няколко пространствени клъстера. Това би имало важно значение при планирането на добива, защото за рудата попадаща в даден клъстер ще се знае, че съдържанието на добиваната компонента е от някаква известна минимална стойност до някаква известна максимална стойност.

В този втори етап е приложен формален метод на клъстеризация, като е използвано евклидово разстояние и метода на най-близкия съсед за определяне на разстояние между клъстерите. За целта е разработена програма на Visual Basic for Application за MS Excel, която ползва класифицирането в един хоризонт.

Програмата чрез рекурсивен алгоритъм намира клъстерите и за всеки от тях генерира неговия номер и таблица с координатите на пробите попадащи в него. Като се задават различни максимални разстояния на пробите попадащи в един клъстер за даден вид клъстеризиране, програмата намира различни системи от клъстери..



а) по максимално разстояние 40 m



б) по максимално разстояние 60 m

Фиг. 2.2.5. Клъстеризиране на клас № 3 за съдържание на мед от хоризонт 840

След намирането на клъстерите, е възможно се определят техните граници и площи. От номера на клас и от площта на негов клъстер може да се получи оценка за добива на съответното съдържание (например мед).

В рамките на това изследване е разработена втора програма на VBA за MS Excel, която по зададен номер на намерен вече клъстер намира точките от него, които определят минималния описващ го изпъкнал многоъгълник и площта на този многоъгълник. На фигура 2.2.5 б е очертан намерения такъв многоъгълник за клъстер 2, чиято площ е 33722 m². За намиране върховете на многоъгълника е използван алгоритъмът на монотонната верига на Андрю.

При планиране за определен период се предвижда изземване на обеми, които с известно приближение са близки до правилни тела (експлоатационни блокове/полета). Възможностите за вписване на определен брой експлоатационни блокове/ полета зависят от възприетата технологична схема на добив и от сложността и размерите на многоъгълника, описващ клъстера.

III. Прогнозиране на показатели на рудно находище чрез невронни мрежи

Показателите на находищата се делят на две групи – количествени и качествени. При изчисляването на запасите те са минно геометрични, а при управление на запасите са качествени. Обединяването в една група се е наложило поради факта, че не само качествените, но и количествените – дебелина, дълбочина на залягане, дебелина на прослойките скали и др. влияят на качеството на добиваната суровина. Прогнозирането на показателите на находището – съдържание на химически компоненти, дебелина на рудния масив, наклон на рудната жила, вместиците скали и т.н. е сложна техническа задача, поради:

- ограничеността на информацията, явяваща се пречка за статистическо прогнозиране;
- разнородността в подходите на евристичните методи за прогнозиране;
- разнородността на целите и критериите за оценка на прогнозните модели.

Моделите, които се разглеждат, почиват на реални данни от открит рудник за добив на медна руда. Те са тясно свързани помежду си. Разработени са модели съвместно с колеги от катедра „Маркшайдерство и геодезия”. Данните са осигурени от различни етапи на изучаване на находището (детайлно проучване, пред експлоатационно проучване и експлоатационно проучване).

3.1. Прогнозиране на стойността на геоложки показател [3]

Чрез невронни мрежи се прогнозира стойността на геоложки показатели в различна степен на проучване на рудни находища. В случая изследването се базира на първично необработени данни от проучването. Изследването се реализира на базата на детайлното и впоследствие на пред експлоатационното и експлоатационното проучване.

Използвани са:

- мрежи с радиални базисни функции (Radial Basis Function - RBF),
- обобщени регресионни невронни мрежи (Generalized Regression Neural Networks - GRNN), и
- многослойни перцептрони (Multilayer Perceptrons - MLP), в случая трислоен перцептрон (MLP 3 с един входен, един вътрешен и един изходен слой) и четирослоен перцептрон (MLP 4 с един входен, два вътрешни и един изходен слой).

3.1.1. Предпоставки за използване на невронни мрежи при прогнозиране на геоложки показатели

Методите на математическата статистика, ползвани доминиращо до края на XX век в изследването на находищата на минерални суровини, по-късно се допълват от геостатистическите и евристичните модели.

Изкуственият интелект в изследването на минерални находища налага:

- разбиране и разработване на компютърни технологии,

- моделиране на параметрите на находището, оценката на моделите и използването им във фазите на неговото проучване и разработка, опазване на земните недра,

- разработване на голям брой решения и избор на оптималното в реално време, както и възприемането на минералните находища като мултифункционални и мултипараметрични системи.

Една от целите на прогнозирането е получаване на оценка на бъдещи стойности на данни (информация) във времето и/или в пространството, които са базирани на вече известни данни. Напоследък заедно с традиционните методи (параметрични модели) за търсене на регулярност в известните данни се прилагат методите на невронните мрежи.

3.1.2. Обект на изследване

Обектът на изследване е находище Асарел - детайлно проучено със сондажна мрежа (100m x 100m). Поради високата изменчивост на съдържанието на мед, на много места плътността на мрежата е увеличавана на 50m x 50m. Резултатите от минно геометричния анализ на параметъра – съдържание на мед – показват, че емпиричното разпределение е различно от нормалното и е с отрицателна асиметрия. Изследването на характера на изменчивостта на съдържанието чрез теорията на случайните функции дава основание да се твърди наличие на анизотропия в изменението на основния показател. Степента на неопределеност намалява по скалата I (200×200 m) → II (50×50 m) → III (25×25 m), които съответстват на фазите на проучвателно, предексплоатационно и експлоатационно проучване на находището.

3.1.3. База и технология на изследване

Отчитайки количеството начална информация, последователността на нейното добиване и цената на придобиването на информацията може да се поставят въпросите:

- Може ли да обучена невронна мрежа с данни от първоначален етап на проучване на находището, така че тя да прогнозира основния показател – приет за параметър на находището при следващите етапи (класическа задача), и какво е влиянието върху ефективността на прогнозата в зависимост от изменението на съотношението между обучаващи и тестващи данни.

- Запазва ли се типа на невронната мрежа и нейната продуктивност в следващите фази на проучване еднаква плътност на информацията, но с изместване на обучаващата извадка.

- Каква е връзката между количеството информация и надеждността на избора на модели за прогнозиране.

Всички операции за търсене на отговора на първия подвъпрос са се отразили в конструирането на модела за прогнозиране – невронна мрежа – чрез обучение основано на информация, зададена в мрежа 200x200 m и сравняване на качеството на обучението.

За изчисленията е използван софтуерният продукт Statistica 7.0 и по-конкретно модулът Statistica Neural Networks.

Конструирането на една невронна мрежа включва следните стъпки:

- избор на типа невронна мрежа, която е най-подходяща за даденото изследване;
- определяне на серия от конфигурации (брой на слоевете, брой на възлите във всеки слой и т.н.);
- извършване на многократни експерименти с всяка една от конфигурациите;
- подбор, корекция и довършване на обучението на избрани конфигурации;
- финално тестване на избраната най-добра невронна мрежа.

Модулът Statistica Neural Networks включва инструмента Intelligent Problem Solver - IPS, за автоматично създаване, трениране и тестване на много на брой мрежи едновременно, с различни характеристики. След обучението той избира по зададен критерий (най-често – минимална грешка на обучение) определен брой най-добри. За целите са извършени експерименти с различни типове мрежи с различни параметри (брой на скритите слоеве, методи и фази на обучение, трансферни функции във възлите и др.). Изпълнени са разнообразни обучаващи серии по няколко обучаващи схеми. Стойността на грешката при обучението е избрана като „право” за по-нататъшно изследване на най-добрата мрежа.

IPS включва най-модерните алгоритми, като например регуляризация и анализ на точността. Този модул може да тества стотици мрежови комбинации, концентрирайки се върху конкретни обещаващи мрежови архитектури. IPS търси едновременно за наличие на оптимални мрежи от различни типове (например, многослойни персептрони и мрежи с радиални базисни функции). Друго предимство на IPS е високата скорост на неговото изпълнение.

Информацията за съдържанието на мед включва:

- равнинните координати на пробите (в областта на добивния хоризонт),
- стойности на съдържанието на мед.

По този начин невронната мрежа ще има две входни променливи (x и y координата) и една изходна (процент на съдържанието на мед). В първия етап на проучването на находището пробите са 68 на брой, във втория – 232, а в третия - 826. По време на анализа чрез IPS данните са разделени на три групи за: обучение, тестване по време на обучението и тестване след обучението.


В първия етап всичките използвани 68 проби са разпределени по следния начин: 16 са използвани за обучение (те са от проучвателна мрежа 200x200 m), 52 са използвани за тестване. Направени са паралелни измествания в мрежата от проби и са избрани групи от по 16 обучаващи данни. Успешните (тези с най-малка грешка от обучението), определени от IPS, са показани на Таблица 3.1.1. Първата и четвъртата са от вида многослоен персептрон (едната с един скрит слой съдържащ 9 възела, а другата с два скрити слоя съответно с 9 и 7 възела). Невронната мрежа (Generalized Regression Neural Network - GRNN)

е регресионна. Тя има два скрити слоя – 28 възела в първия и 2 във втория. Мрежата, с радиални базисни функции (Radial Basis Function - RBF), има един скрит слой с 15 възела.

Таблица 3.1.1. Невронни мрежи определени от IPS (200x200 m)

Вид	Грешка при обучение	Грешка при тестване	Модел на обучение
MLP 2:2-9-7-1:1	0.0014	0.2234	BP100,CG20,CG167b
GRNN 2:2-28-2-1:1	3.2108	2.3579	SS
RBF 2:2-15-1:1	1.5991	2.3790	KM,KN,PI
MLP 2:2-9-1:1	0.0340	0.1798	BP100,CG20,CG337b

Приложените модели на обучение са: с обратна връзка (Back Propagation - BP), градиентно спускане (Conjugate Gradient - CG), с подизвадка ((Sub) Sample - SS), чрез K-средно (K-Means (Center Assignment) - KM), чрез K-ти най-близък съсед (K-Nearest Neighbor (Deviation Assignment) - KN) и чрез псевдо обръщане (Pseudo-Invert (Linear Least Squares Optimization) - PI), със съответния брой трениращи епохи.



Фиг. 3.1.1. Грешки при обучение и тестване на определените чрез IPS 10 най-подходящи мрежи от вида MLP

Използвана е минимална стойност на грешката при обучение като критерии за избор на успешна мрежа. От изложеното в Таблица 3.1.1, мрежата MLP (2:2-9-7-1:1) с два скрити слоя е най-подходящата, следваща е MLP 2:2-9-1:1. Грешките на другите две мрежи са значително по-големи.

Във втория етап на изследването броят на обучаващите проби е приблизително удвоен за сметка на тестващите проби. Резултатите за вида на мрежата и нейните характеристики са аналогични – отново MLP(2:2-9-7-1:1) с два скрити слоя се оказва най-подходящата. Фигура 3.1.1 показва грешките при обучение и тестване на 10-те най добри мрежи от вида MLP.

Таблица 3.1.2. Резултати от IPS при втора фаза на проучване на находището

Вид	Грешка при обучение	Грешка при тестване	Модел на обучение
GRNN 2:2-68-2-1:1	3.9636	5.8304	SS
MLP 2:2-7-1:1	0.0994	0.2019	BP100,CG20,CG205b
MLP 2:2-9-8-1:1	0.0411	0.2105	BP100,CG20,CG445b
RBF 2:2-68-1:1	0.0000	5.0968	SS,KN,PI

Във втората фаза на проучване на находището, броят на пробите (за съдържание на мед) нараства до 300 броя. Те са разпределени както следва: 68 са за обучение (позиционирани в мрежа 100x100 m), а останалите са за тестване (в мрежа 50x50 m). Най-добрите мрежи след втората фаза, определени от IPS, са показани в Таблица 3.1.2. Според посочения критерий отново най-подходящата мрежа е MLP с два скрити слоя..

В третата фаза броят на пробите за съдържание на мед нараства до 894. Те са разпределени както следва: 68 са използваните за обучение (позиционирани в мрежа 100x100 m), а останалите са използвани за тестване (ситуирани в мрежа 25x25 m). Най-добрите мрежи избрани от IPS са описани в Таблица 3.1.3. Според същия критерий отново най-добрата мрежа е MLP с два скрити слоя..

Таблица 3.1.3. Резултати от IPS при трета фаза на проучване на находището

Вид	Грешка при обучение	Грешка при тестване	Модел на обучение
GRNN 2:2-68-2-1:1	3.9636	5.9988	SS
MLP 2:2-9-1:1	0.0964	0.2134	BP100,CG20,CG261b
MLP 2:2-9-7-1:1	0.0168	0.2390	BP100,CG20,CG753b
RBF 2:2-68-1:1	0.0000	5.5121	SS,KN,PI

Анализирайки резултатите може да бъде направено следното обобщение: По критериите минимална грешка при обучение и най-малка грешка при тестване най-добрият вид мрежа е MLP (с два скрити слоя, съответно с 9 възела в първия и 7 възела във втория слой).


Напомняме, че IPS препоръчва обучение в три фази:

- ✓ в първа фаза методът е BP със 100 епохи,
- ✓ във втората фаза на обучение CG с 20 епохи и
- ✓ CG с 261 епохи в третата фаза.


Последната стъпка на изследването включва конструиране на невронна мрежа, използвайки инструмента Statistica Custom Network Design. Според получените резултати от апробацията на IPS е избрана невронна мрежа от вида MLP с два скрити слоя, съответно с 9 възела в първия и 7 слоя във втория. За трансферна функция е предпочетена логистична крива.

За конкретния случай обучението е извършено върху 1194 проби за съдържанието на мед като: 68 от тях са използвани за обучение, 232 – за

първоначално тестване по време на обучението и 826 за крайното тестване. Мрежовата архитектура е показана на Фигура 3.1.2.



Фиг. 3.1.2. MLP с два скрити слоя (9 възела в първия слой и 7 във втория)



Фиг. 3.1.3. Обучение на конструираната мрежа MLP с два скрити слоя

Изменението на грешките при обучение и при подбора (грешка при тестване по време на обучаващия процес) могат да се наблюдават в реално време (Фигура. 3.1.3). Процесът на обучение може да бъде прекъсван, коригиран и продължен.

Конструирането на мрежа MLP с два скрити слоя, нейното обучение (грешка при обучение 0.669) за сондажи в мрежа от 100×100 m и нейното тестване (грешка при тестване 0.325) върху данни в мрежа от 25×25 m показва, че избраната мрежа би осигурила надеждна прогноза за съдържанието на мед в находището.

3.1.4. Обобщение

Върху реални данни от различни фази на проучването на метасоматично находище са обучени три вида невронни мрежи (MLP, RBF и GRNN) използвайки модула IPS – софтуерен инструмент на програмната система Statistica.

Броят на пробите при първия етап на проучването се определя от мрежа 200×200 m. Резултатите от обучението и тестването показват, че с паралелно изместване на местоположението на взетите проби, но със съща гъстота (200×200 m), най-добрата мрежа (според критерия за минимална грешка при обучение) е MLP с два скрити слоя. MLP с един скрит слой показва сходни положителни резултати (вж. Таблица 3.1.1). Грешката при обучение при различни варианти на изместване е в същия порядък, което всъщност отговаря на втория въпрос от точка 3.1.3.

Същите видове невронни мрежи са използвани за обучение и тестване отново чрез IPS при по-голям обем проби предоставени от втората и третата фази на проучване на находището (сондажна мрежа с размери 100×100 m и сондажна мрежа с размери 50×50 m). Отново MLP с два скрити слоя е най-подходящата мрежа (вж. Таблицы 3.1.2 и 3.1.3) за прогнозиране на съдържанието на мед.

Постигнатите резултати дават дефинитивно положителен отговор, че може да се обучи невронна мрежа за прогнозиране на основния показател – съдържание на мед в находището. Съотношението между обучаващи и тестващи данни не влияе значително върху качеството на прогнозирането на съдържанието на мед.

Основавайки се на резултатите получени от работата на IPS е конструирана, обучена и тествана мрежа от вида MLP с два скрити слоя, съответно с 9 възела в първия слой и 7 възела във втория. Тя е обучена използвайки данни разположени в мрежа 100×100 m, и е тествана по време на обучението чрез данни в мрежа от 50×50 m, а накрая е тествана с данни в мрежа 25×25 m. Всички резултати показват, че прогнозният модел (MLP с два скрити слоя) е надежден след първия етап на проучване и може да се използва във втория и третия посочени етапи.

3.2. Определяне тримерния модел на изменение на съдържанието на мед чрез невронни мрежи [4]

В 3.1. е извършен успешен опит за създаване на двумерен модел за прогнозиране на основния качествен показател (съдържанието на мед) с програмната система Statistica 7.0. - модула Statistica Neural Networks (SNN) и информацията за съдържанието на мед от три добивни хоризонта (x , y , z , Cu)

3.2.1 Въведение

Степента на проучване на рудното тяло и неговата геоложка сложност са тясно свързани по познати причини. Геоложката сложност и изменчивостта на съдържанието определят вида на методите на проучване.

Трудността да се оцени геоложката сложност и непостоянният характер на изменение на рудното тяло (или негови части) произтича от хипотетичния характер на входните геоложки данни. Методите на интерполация и екстраполация, ограничени от местоположението на точките на извадката, са съществени за инженерните решения. Оценката на геоложката сложност на находищата е задача, която за целите на практиката се налага да бъде решена в пространството поради:

- начина на изчисляване на запасите – природните натрупвания се оприличават на равнообемни правилни тела – цилиндри, конуси и т.н.;
- добивния процес се планира и реализира в обема на рудното тяло;
- движението на запасите се отчита за обеми, определени от движението на забойната линия и нормалната дебелина на тялото.

Посочените съображения дават основание за формулиране на следната задача: *Ако съществува достоверен модел за разпределението на геоложки показател в няколко последователни добивни хоризонта в дълбочина, може ли да се прогнозира с приемлива точност разпределението на показателя в следващия хоризонт.*

3.2.2. Решение на задачата


Информацията от експлоатационното проучване на находището от четири хоризонта са организирани в таблици (в MS Excel). Входни променливи са координатите X , Y и H . Изходна променлива е съдържанието на мед. Данните от четирите последователни добивни хоризонта са разделени на две главни групи. Първата група съдържа информация (2540 точкови проби) от три последователни хоризонта като тези данни служат за обучение на невронните мрежи. Тези от втората група (690 точкови проби) са от четвъртия добивен хоризонт (най-долния в конкретния случай) - служат за тестване на вече обучените мрежи.

В първия етап от изследването е използван подмодулът IPS на модула SNN на Statistica 7, като са обучени и тествани невронни мрежи от вида RBF, GRNN и MLP с един и два скрити слоя с горепосочените обеми данни. За избягване на нежелана прекалена апроксимация броят на възлите в скритите слоеве е ограничен между 5 и 10. В резултат на изпълнението на IPS са определени няколко невронни мрежи от различни видове с различни параметри. При съблюдаване на същия критерий – най-малка грешка при обучението и при тестването е избрана като най-подходяща MLP с два скрити слоя - 10 възела в първия, 7 възела във втория.

Таблица 3.2.1. Най-добра мрежа получена от IPS

IPS търсене				
№	Вид	Грешка при обучение	Грешка при тестване	Модел на обучение
11	MLP 3:3-10-7-1:1	0.06534	0.06573	BP100,CG20,CG26b

В Таблица 3.2.1 са посочени грешките при обучение и при тестване по време на обучението, а нейната архитектура е показана на Фигура 3.2.1.



Фиг. 3.2.1. Multi Layer Perceptron избран от IPS като най-добра мрежа




Фиг. 3.2.2. Обучаващ процес на CND

През втория етап на търсенето на решението се наложи конструиране на невронна мрежа, като за целта е използван подмодулът Custom Network Design (CND) на Statistica. Всички начални характеристики съответстват на препоръките на IPS, т.е. на тези от Таблица 3.2.1 и Фигура 3.2.1. За целта са избрани: логистична трансферна функция, нормално разпределение на началните стойности на теглата на връзките и три етапа на обучения. Използвани са: алгоритъмът на обратното разпространение (Back Propagation) със 100 епохи в първия етап и алгоритъмът на последователно градиентно спускане (Conjugate Gradient Descent) с 500 епохи във втория и третия етапи.


Като резултат от процеса на обучение са получени грешка на обучението 0.07 и грешка на тестване 0.073. Графиката от Фигура 3.2.2 показва тенденцията и динамиката на намаляването на грешката при обучението по време на процеса на обучение.

На фигура 3.2.3 е показано поведението на обучената невронна мрежа при нейното изпълнение с тестващите данни. Ясно се вижда, че сходството между реалните данни за съдържанието на мед *Cu* и тези от изхода на невронната мрежа е много силно изразено.



Фиг. 3.2.3. Резултат от работата на обучената невронна мрежа върху тестващите данни

Тъй като числовата оценка на сходството е задължителна, за количественото оценяване на връзката между реалните и от невронната мрежа (предсказаните) данни е използван корелационен анализ. На Фигура 3.2.4 са дадени корелационните полета. От анализа на полетата се вижда, че надлъжната ос е значително по-голяма от напречната – условие за наличие на линейна връзка между факторния и резултантния показател. Стойностите на корелационните коефициенти при обучение е показател, че качеството на обучението е добро. Стойността на корелационния коефициент между реалните тестващи данни и предсказаните от невронната мрежа е по-малка (0.62), но е значима, което гарантира надеждна прогноза на съдържанието на мед чрез изградената невронна мрежа.



a) $R = 0.79$

b) $R = 0.81$

c) $R = 0.62$

Фиг.3.2.4. Корелационни полета и коефициенти на корелация между:

- a) всички реални данни за Cu и данните от изхода на невронната мрежа,
- b) обучаващите реални данни за Cu и данните от изхода на невронната мрежа,
- c) тестващите реални данни за Cu и данните от изхода на невронната мрежа

3.3. Влияние на плътността на геоложката информация на качеството на обучение на невронна мрежа [7]

В различните етапи на проучването на дадено находище се вземат проби. Разстоянието между съседните проби (плътност, гъстота) е различно. В предходните две точки е показано, че чрез невронни мрежи може да се направи модел, адекватен на отделни характеристики на находището. Моделът може да се използва за изучаване и прогноза на качествените показатели. Въпросът е каква да е плътността (гъстотата) на геоложката информация, чрез която се обучава невронната мрежа, така че да дава достатъчно точна прогноза на качеството на рудата, тъй като качеството на рудата е интегрален показател от химичния, минераложкия състав, обогатимостта, спекаемостта и т.н. Доминиращо при определяне качество на рудата е съдържанието на мед.


Броят, равномерността и плътността на обучаващите данни оказват съществено влияние върху качеството на обучение на невронните мрежи. Големият брой проби е свързан със значителни разходи. Затова е необходимо да се намери оптимално съотношение между броя на обучаващите данни (пробите) и качеството на обучение на мрежата, т.е. качеството на прогноза.

3.3.1. Определяне на оптимална плътност на обучаващите данни за невронната мрежа


Нека е представена информацията за съдържанието на мед от няколко добивни хоризонта. Тя е получена от геоложките и маркшайдерските снимки. Голямата плътност, осигурена от етапа на изучаване на находището и начина на нейното организиране в цифров вид дава възможност за промяна на плътността на данните в интерактивен режим.

Разреждането е осъществено чрез определяне на възли на регулярна мрежа по аналогия на детайлното проучване със сондажни изработки. Формирани са варианти на регулярна мрежа с различни разстояния между възлите. По технологичните условия на добива и елементите на взривното поле, данните от експлоатационното опробване не са в геометрично правилна мрежа (Фигура 3.3.1a). Това налага търсене на метод за определяне стойностите на съдържанието на мед, които да бъдат присвоени във възлите на регулярната мрежа (Фигура 3.3.1б). За всеки възел е използвана информацията от

експлоатационното опробване попадаща в кръгова околност с определен радиус. Радиусът зависи от изменчивостта на съдържанието на мед и той не трябва да е по-голям от радиуса на автокорелация. Априори допускаме, че характерът на изменчивостта е изотропен. Попадащите в околността на възела проби имат различно влияние върху присвоената стойност на съдържанието на мед във възела, поради което е подходящо тази стойност да се изчислява чрез претеглено средно., като теглото на всяка проба зависи от разстоянието и до възела. Чрез авторова програма на Visual Basic for Application за MS Excel за даден хоризонт се определя регулярна мрежа. По зададена стъпка и радиус от потребителя се определят координатите на възлите на мрежата и присвоените стойности на съдържанието на мед – претеглена средна стойност в областта със зададения радиус.



а) експлоатационно опробване –
1954 проби



б) възли (243 бр.) на регулярна
мрежа със стъпка 30 м

Фигура 3.3.1. Хоризонт 1015, експлоатационна и регулярна мрежа на информацията


3.3.3. Резултати и коментари

Таблица 3.3.1. Брой на възлите в регулярните мрежи по хоризонти

стъпка (Lag)	10	20	30	40	50	60	70	Експ.
Хоризонт 1015	1878	512	243	147	100	70	58	140
Хоризонт 1000	1705	466	219	134	88	66	48	136
Хоризонт 985	1341	371	178	107	72	58	41	135
Хоризонт 970	1193	332	158	97	70	48	37	134
Хоризонт 955	824	229	116	72	46	37	28	135
Хоризонт 940	482	142	72	44	29	22	18	131
Средна стойност	1237	342	164	100	68	50	38	135

При разреждане на регулярната мрежа с размери (стъпка) от 10 до 70 m се увеличава броя на вариантите. Радиусът на търсене е избран да е равен на стъпката. Като отделен вариант са включени и данните от детайлното

проучване. При различните варианти броят на възлите е различен (Таблица 3.3.1). На Фигура 3.3.2 е показано изменението на броя на възлите в зависимост от възприетата стъпка на регулярната мрежа. Определените стойности на геоложкия параметър (съдържание на мед) в тези възли са използвани за обучение на невронни мрежи.



Фигура 3.3.2. Брой на възлите в регулярните мрежи по хоризонти


За всеки вариант на регулярна мрежа чрез IPS на Statistica 7 са обучавани различни невронни мрежи – многослойни персептрони, като те са тествани върху всички данни за хоризонта от експлоатационното проучване. Избрана е от класираните най-добрата според критерия най-малка грешка при тестване. Това са четири-слойни персептрони с два вътрешни слоя. Входният слой има два възела – координатите на пробата (възела), изходният слой има един възел – съдържанието на мед в пробата. По-ранните изследвания показват, че малкият брой възли във всеки вътрешен слой не дава добра точност, поради глобализиране на модела. От друга страна прекалено големият брой възли води до преобучаване на мрежата и грешката при тестване нараства. В това изследване сме ограничили броя на възлите във вътрешните слоеве между 6 и 9. В Таблица 3.3.2 са представени грешките при тестване на всички най-добре обучени невронни мрежи за 6-те хоризонта, за всички варианти на разреждане.

Грешките при тестване на най-подходящите (най-добре обучени) невронни мрежи са дадени в Таблица 3.3.2. Грешките при обучението и тестването са дадени на Фигура. 3.3.3.б., а с прекъснатата линия е показана тенденцията на изменение на средноаритметичната грешка при тестването на най-добрите мрежи по хоризонти.


На Фигура 3.3.3 са показани съответните грешки при обучение и тестване на най-подходящите мрежи за отделните хоризонти. В тях не се забелязва изявена закономерност. Може да се отбележи, че при обучението върху данни с по-малка плътност, невронните мрежи постигат по-малка грешка при обучението. При тестването, същите мрежи дават по-голяма грешка.

Таблица 3.3.2. Грешки при тестване на най-добре обучените невронни мрежи

стъпка (Lag)	10	20	30	40	50	60	70	Експ.
Хоризонт 1015	0.076	0.088	0.086	0.100	0.109	0.120	0.148	0.095
Хоризонт 1000	0.058	0.110	0.062	0.131	0.158	0.176	0.187	0.106
Хоризонт 985	0.037	0.036	0.041	0.064	0.178	0.182	0.249	0.144
Хоризонт 970	0.049	0.047	0.090	0.139	0.107	0.215	0.208	0.063
Хоризонт 955	0.074	0.082	0.119	0.140	0.212	0.142	0.270	0.137
Хоризонт 940	0.071	0.110	0.174	0.234	0.178	0.292	0.186	0.132
Средна стойност	0.061	0.079	0.095	0.135	0.157	0.188	0.208	0.113




а)




б)

Фигура. 3.3.3. Грешки при обучението и тестването на най-добрите мрежи по хоризонти

За целите на прогнозирането определящи за неговата точност са грешките при тестване, тъй като то се извършва върху реални данни с максимална гъстота – тези от експлоатационното проучване. На Фигура 3.3.3.б. е показана също графиката на изменението на средно аритметичната грешка при тестване по хоризонти (прекъсната линия). Средните грешки са най-близки до грешките при тестване при плътност 30 и 40 m (най-високи стойности на корелационния коефициент – 0.84). Грешките при плътност 30 m са по-малки от средните.



а)




б)

Фигура 3.3.4. Графики на средното аритметичната стойност и на дисперсията на грешките от изучаваните добивни хоризонти при обучение (а) и тестване (б) в зависимост от стъпката на регулярните мрежи

От Таблица 3.3.1 и Фигура 3.3.1 се вижда, че броят на възлите на регулярните мрежи със стъпка до 30 m е относително малък. При мрежите с по-голяма плътност на възлите броят им рязко нараства (в пъти).

На Фигура 3.3.4 са показани графиките на средната аритметична стойност и дисперсията на грешките от отделните хоризонти при обучение и тестване в зависимост от стъпката на регулярните мрежи (плътността на обучаващите данни). Стойностите на грешките в началната точка 0 в графиките са тези от невронните мрежи обучени с данните от детайлното проучване.

Графиките потвърждават, че с намаляване плътността на данните, невронните мрежи се обучават с по-малка грешка (Фигура 3.3.4а), но грешката при тестване се увеличава (Фигура 3.3.4б). От графиките се вижда, че дисперсията на грешките е сравнително постоянна, т.е. не зависи от плътността на обучаващите данни. Това е признак за постигната известна устойчивост на качеството на обучението на невронните мрежи в различните хоризонти независимо от стъпката на регулярната мрежа.



Фигура 3.3.5. Графика на средната грешка при тестване в зависимост от средния брой възли на регулярни мрежи

Необходимо е да се намери оптималната стойност на съотношението на грешката при тестване спрямо броя проби (тяхната гъстота), чрез които невронната мрежа се обучава. На Фигура 3.3.5 е показана връзката на средната грешка при тестване (последен ред на Таблица 3.3.2) от средния брой възли на регулярните мрежи (последен ред на Таблица 3.3.1). Вижда се, че грешката рязко нараства при по-малка плътност на обучаващите данни от 30 x 30 m (164 бр.). Това потвърждава коментара на Фигура 3.3.3б.

3.3.4. Изводи


Изследванията дават възможност за следните обобщения:

1. Разработена е програма на Visual Basic for Application за MS Excel, която извлича от масива пространствено определени данни стойностите на геоложкия показател (в случая съдържание на мед) в регулярна мрежа с различна плътност, определена от потребителя.

2. Чрез разработената програма са формирани 42 регулярни мрежи – по 7 на всеки добивен хоризонт.

С тях са обучавани множество невронни мрежи и са избрани най-добрите чрез критерия минимална грешка при тестването.

Полученият резултат от изследването за влиянието на различните плътности на обучаващите данни, показва (Фигура 3.3.6) че при плътност 30×30 m грешката при тестване е сравнително малка (под 0.1), а броя на възлите (пробите) е относително малък (под 200).



Фиг. 3.3.6 Сравнение между изменението на средна грешка при тестване и средния брой на възлите на регулярните мрежи спрямо изменението на стъпката

Точната плътност може да се намери по следния начин: ако $f_{cn}(x)$ и $f_{er}(x)$ са регресионните функции съответно на броя на възлите и грешките за $x \in [10, 70]$ (Фигура 3.3.6), то

$$\text{Min} \left(\frac{f_{cn}(x)}{|f_{cn}(10) - f_{cn}(70)|} + \frac{f_{er}(x)}{|f_{er}(10) - f_{er}(70)|} \right), x \in [10, 70] \quad (1)$$

е оптималното разстояние между пробите. Чрез MS Excel лесно се намира, че

$$f_{cn}(x) = 72745x^{-1.7824}, \text{ при } R^2 = 0.9996 \quad (2)$$

$$f_{er}(x) = 0.000006x^2 + 0.0012x + 0.0357, \text{ при } R^2 = 0.9917 \quad (3)$$

Чрез Mathematica 7 от (1), (2) и (3) се получава, че оптималното разстояние е $x = 24.35$ m, което до голяма степен потвърждава направеното по-горе предположение.

IV. Компютърно моделиране в минната екология

При възобновяване на концесионния модел за разработване на находищата за добив на подземни природни богатства, екологосъобразните норми в минната промишленост заеха определено място. Появи се ново научно направление – *минна екология*.

Минната екология включва мероприятия свързани с опазване на околната среда по време на експлоатацията на минното предприятие и рекултивация на терените по време и след изчерпване на запасите от подземни богатства.

При проучването със сондажни и минни изработки и при разработването на находищата на подземни богатства се нарушава естествения ландшафт на земната повърхност. Това налага възстановяване на повърхността, което е отделен етап от общия минно технологичен процес. Възстановяването – рекултивацията се състои от два основни етапа – техническа и биологична рекултивация. За двата етапа се изготвят технически проекти и се планират отделните дейности, осигуряващи срочното и качествено изпълнение на проектите.

Обектите на първия етап в нарушени участъци от земната повърхност са изгражданите външни и вътрешни насипища. Вторият етап на възстановяването е свързан с внасяне на плодороден хумусен слой и засаждане на подходящи растителни видове. В определени случаи е подходящо (или препоръчително) залесяване с горски насаждения.

По време на експлоатацията са възможни различни замърсявания на околната среда като например, изхвърляне на газове и прах, а също така на замърсена вода от мината и / или от обогатителната фабрика. Точковите източници на замърсяването са базата за създаването на модели. В практиката са се наложили два типа модели – на разпространение на замърсители във въздушна и водна среда.

4.1. Изследване на замърсяване с аерозоли базирано на модела на Pasquill и Gifford [1]

Аналитичният модел на Pasquill и Gifford за разпространение на концентрацията на аерозолите в атмосферния въздух се описва със следната зависимост:

$$C = \frac{Q}{\pi u \sigma_x \sigma_y} e^{-\frac{1}{2} \left[\left(\frac{H}{\sigma_x} \right)^2 + \left(\frac{y}{\sigma_y} \right)^2 \right]} \quad (1)$$

където:

C е концентрацията на аерозола, изчислена на нивото на земята на определено разстояние от източника;

Q - количеството на емисията на източника, g/s;

u - средната скорост на вятъра, m/s;

y - разстоянието от източника по y -координатата, x е по посока на вятъра в координатната система (x,y) с център, който представлява източника на замърсяване;

H - ефективната височина на комина, m;

σ_x и σ_y са съответно коефициентите на дифузия на аерозола по осите x и y .


Зависимост (1) дава реални стойности за концентрацията C като функция на x и y само в полуравнината, определена от посоката на вятъра. Определянето на коефициентите на дифузия σ_x и σ_y се извършва на базата на експериментално снети семейство от криви, задаващи зависимостта им от разстоянието x от източника за шест осреднени типа атмосферни условия. Шестте типа съответстват на скорости на вятъра между 0 и 2, 2 и 6 и по-големи от 6 m/s и на силна, средна и слаба слънчева радиация. За анализа е избран слабо нестабилен тип на атмосферните условия (u е между 4 и 6 m/s и средна слънчева радиация), който отговаря на най-разпространения тип атмосферни влияния. Коефициентите σ_x и σ_y се определят на базата на прости регресионни модели:

$$\sigma_x = a_1 x + b_1 \quad \sigma_y = a_2 x + b_2,$$

където за коефициентите a_1 , a_2 , b_1 и b_2 са получени съответните стойности 0.58; -0.97; 0.028; 55.01.

За останалите параметри се приемат следните стойности:

- височина на източника $H = 80$ m, което представлява средна височина на комините в България;
- сила на вятъра $u = 6$ m/s, което отговаря на слабо нестабилен тип атмосферни условия;
- количество на емисията $Q = 579.05$ g/s, съответстващо на емисията на ТЕЦ "Кремиковци".



Фиг.4.1.1. Изменение на концентрацията C като функция на x и y

Като се приложи зависимост (1) за приетите параметри, се получава графиката за изменението на концентрацията C като функция на x и y (Фигура.

4.1.1). На графиката се вижда ясно, че концентрацията в мястото на източника е най-висока и постепенно намалява експоненциално по посоката x на вятъра, докато по посоката y , перпендикулярна на посоката на вятъра, концентрацията има близко до нормалното разпространение.


Предлаганият модел може да се приложи и за анализ на замърсяването с газове и въздушнопреносим прах (с големина на частиците до $50\text{ }\mu\text{к}$). При този случай обаче трябва да се подберат други коефициенти на дифузия. Моделът има практическо приложение за разстояние до 100 km от източника на замърсяване.

4.1.1. Анализ и коментар на получените резултати

Нека да проследим как се изменя концентрацията на замърсяване от следните фактори:

- a) височина на източника;
- b) сила на вятъра;
- c) размери (маса) на емисията;
- d) вид на изхвърлянето на замърсителя.

Изследванията се извършват при априорно приемане, че един от посочените фактори е променлива величина, а останалите са фиксирани, непроменливи. Този принцип на изследване е познат при многофакторния анализ.




Фиг. 4.1.2. Изменение на C по оста x за три стойности на височината (40, 80, 120 m)

Изменение на концентрацията C според височината H на източника.


На Фигура 4.1.2 е показано изменението на C по оста x за три стойности на височината (40, 80, 120 m) при непроменяеми стойности на останалите параметри. От графиката се вижда, че C е най-голяма при най-малка височина на комина и обратно - тя е най-малка при най-висок комин. Височината на комина влияе върху концентрацията главно в ограничена област около

източника, като от известно разстояние (над 500 m) нататък такова въздействие практически не се наблюдава.

Влияние на силата на вятъра u върху концентрацията C . На Фигура 4.1.3. е показано изменението на C при стойности на вятъра 3, 6 и 12 m/s. От графиката се вижда, че най-голяма концентрация съществува при най-ниска стойност за u и обратно, като това съотношение се запазва независимо от x .




Фиг. 4.1.3. Изменение на C при стойности на вятъра 3, 6 и 12 m/s




Фиг. 4.1.4. Изменение на C при стойности количеството Q (379.05, 579.05 и 779.05 g/s)

Изменението на концентрацията от количеството Q на емисията на аерозола. За различни стойности на емисията (379.05, 579.05 и 779.05 g/s) изменението на концентрацията C е дадено на Фигура 4.1.4. От тези зависимости се вижда, че най-висока концентрация се регистрира при най-голяма емисия. Това съотношение се запазва независимо от разстоянието x от източника.



Фиг. 4.1.5. Графика на количеството Q при залпово замърсяване



Фиг. 4.1.6. Графика на концентрацията при залпово замърсяване

Начинът на изхвърляне на замърсяването може да е с плавно или залпово увеличаване на количеството Q . Вторият случай с краткотрайно (залпово) увеличаване на замърсяването може да се моделира, като във формула (1) за Q се зададе зависимост (2). В случая емисията Q рязко нараства от 579.05 g/s до приблизително 800 g/s. На Фигура 3.1.5 е представена графика за Q 160 s след пиковото изхвърляне на аерозола.

$$Q_i = \frac{500}{\sqrt{2\pi}} e^{-\frac{(i-20)^2}{2}} + 579.05 \quad (2)$$

$i = 0, 1, 2, \dots, 40$. са времеви интервали съответстващи на 4 s.

Залповото изхвърляне на замърсителя (Фигура 4.1.5) съответства на вторичен пик на концентрацията, показан на Фигура 4.1.6. Този пик е по-ясно изразен по посока на вятъра (оста x), докато по оста y той е по-слаб.

Наред с посочените изследвания на факторите са определени формата и площта на замърсяването. Основните емисии на замърсители от ТЕЦ "Кремиковци" са дадени в Таблица 4.1.1.

Таблица 4.1.1 Емисии на замърсители от ТЕЦ "Кремиковци"

NO_x	SO₂	Прах
1.03 m/ден	10.27 m/ден	38,.6 m/ден
11,92 g/s	118,87 g/s	448,61 g/s.

Пределните допустими норми на тези замърсители, определени от Министерството на околната среда и водите (МОСВ) за 1991 г., са посочени в Таблица 4.1.2.

Таблица 4.1.2. Пределно допустими норми, МОСВ за 1991 г.

NO_x	SO₂	Прах
0.085 mg/m ³	0.5 mg/m ³	0.5 mg/m ³


Кривата, определяща района с концентрация C над пределно допустимата концентрация $C_{ПДК}$ се получава чрез следната зависимост:

$$y = \pm \sqrt{2 \ln \left(\frac{Q}{\pi u C_{ПДК} \sigma_x \sigma_y} \right) - \left(\frac{H}{\sigma_x} \right)^2} \quad (3)$$

Тя се получава като пресечна крива между повърхнината на концентрацията, получена от формула (1), и равнината $C = C_{ПДК}$.

Максималната концентрация на NO_x, изпускана от ТЕЦ "Кремиковци", е 0.081 mg/m³ и е по-малка от пределно допустимите 0.085 mg/m³. На Фигура 4.1.7 са показани кривите, ограждащи областите със замърсяване над пределно допустимото за SO₂ и прах. Максималното отдалечаване на тези криви от източника е съответно 310.63 m и 995.1 m. Заградените площи от тези криви, които представляват замърсените райони с концентрация над ПДК, са съответно: за SO₂ - 20 190 m², и за прах - 148 900 m².

Ако се приеме за база нормите на ПДК за SO₂ и прах в САЩ - съответно 0,365 и 0,26 mg/m³, то замърсените площи нарастват на 38 720 m² за SO₂ и 294 000 m² за прах, т. е. два пъти по-големи от тези, изчислени с българските норми.



Фиг. 4.1.7. Област на замърсяване над ПДК за SO_2 и прах

4.1.2. Изводи

Получените резултати от анализа на замърсяването дават основание за следните оценки за концентрацията:

- ♦ на емитирания аерозол, която е по-голяма при по-ниски комини и по-малка при по-високи. При определено разстояние от източника концентрациите за трите изследвани височини практически съвпадат, т. е. височината на източника престава да влияе (Фигура 4.1.2).

- ♦ на емитирания аерозол - тя е по-голяма при по-малка скорост на вятъра и обратно, като това съотношение се запазва независимо от разстоянието от източника. Посоченото съотношение е валидно при постоянен вятър (Фигура 4.1.3).

- ♦ на емитирания аерозол - по-голяма при по-голяма емисия, като това съотношение не зависи от разстоянието от източника (Фигура 4.1.4).

- ♦ при залпово замърсяване се получава втори пик в графиката на концентрацията, който е по-ясно изразен по посока на вятъра (Фигура 4.1.6).

- ♦ изследвани са формата и площта на терена, замърсен от източника с концентрация на аерозола над ПДК за конкретни видове замърсители, показани чрез зависимост (3) и Фигура 4.1.7. Констатира се, че при по-строги норми за ПДК се получават значително по-големи замърсени площи.

Проблемите на пречистването, самопречистването и екологичния мониторинг при замърсителите на атмосферата от най-голям мащаб, каквито са ТЕЦ, са сред най-актуалните. Ето защо адаптацията на модела на Pasquill и Gifford е добра възможност за компютърна оценка и прогнозиране на екологичната обстановка, повлияна от крупни атмосферни замърсители.

Предлаганият подход може да бъде използван за прогнозиране и оценка на замърсяването на околната среда с газове, аерозоли и прах.

4.2. Експериментална оценка на замърсяването с прах от ТЕЦ "Кремиковци"[1]

За да се изчисли количеството прах, което пада на земята в околността на ТЕЦ "Кремиковци", е използвана следната зависимост на Г. Марчук:

$$J = a \int_0^t \int_G C_{\text{ПРАХ}} dG dt \quad (1)$$

където:

t е периодът от време на действие на източника (приемаме, че $t = 24$ h);

$C_{\text{прах}}$ - концентрацията на падащия прах (приемаме, че цялото количество прах, емитирано от ТЕЦ, пада върху земята);


G - площта, върху която се определя падналият прах;

a - константата, определяща дифузията на праха, приемаме, че

$$a = c \frac{\sigma_x + \sigma_y}{2}.$$

Тук σ_x и σ_y са съответните средни дифузии за интервала $[x_{\min}, x_{\max}]$, а c се изчислява, като приемаме, че 90% от емитирания за денонощие прах пада върху площта G , т.е

$$J = 0.9 Q t.$$



Фиг. 4.2.1. Графика на разпространението на прах според Таблица 2.1.1

Изхождайки от общото изпуснато количество прах Q за едно денонощие според формула (1) разпределението на падналият прах е изчислено в мрежа от точки разположени на 100 m една от друга. Изчислените количества прах паднали в тези точки са дадени в Таблица 4.2.1. Графиката съответстваща на тази таблица е показана на Фигура 4.2.1. От нея се вижда, че най-голямо количество прах има около източника и по посока на вятъра.

Получените резултати са сходни на тези за разпространението на аерозоли, които са представени в Точка 4.1.1. От Фигура 4.1.7 се вижда, че

районът замърсен с прах над пределно допустимите норми ($294\,000\text{ m}^2$) е със значително по-големи размери от този замърсен с аерозол ($38\,720\text{ m}^2$), при еднакви атмосферни условия.

Таблица 4.2.1. Количества прах (g/m^2) в мрежа от точки през 100 m

x \ y	-500	-400	-300	-200	-100	0	100	200	300	400	500
100	0	0	0	0.8	75.1	335.1	75.1	0.8	0	0	0
200	0	0	0	1.4	85.3	332.8	85.3	1.4	0	0	0
300	0	0	0	1.7	69.8	242.1	69.8	1.7	0	0	0
400	0	0	0	1.9	58.2	182.0	58.2	1.9	0	0	0
500	0	0	0	2.1	49.9	142.6	49.9	2.1	0	0	0
600	0	0	0	2.4	435	1155	43.8	2.4	0	0	0
700	0	0	0	2.6	39.1	95.9	39.1	2.6	0	0	0
800	0	0	0	2.9	35.3	81.2	35.3	2.9	0	0	0
900	0	0	0.1	3.1	32.1	69.9	32.1	3.1	0.1	0	0
1000	0	0	0.1	3.3	29.5	60.9	29.5	3.3	0.1	0	0
1100	0	0	0.1	3.5	27.2	53.6	27.2	3.5	0.1	0	0
1200	0	0	0.2	3.7	25.2	47.7	25.2	3.7	0.2	0	0
1300	0	0	0.2	3.9	23.5	42.7	23.5	3.9	0.2	0	0
1400	0	0	0.2	4.0	21.9	38.5	21.9	4.0	0.2	0	0
1500	0	0	0.3	4.2	20.5	34.9	20.5	4.2	0.3	0	0
1600	0	0	0.3	4.3	19.3	315	19.3	4.3	0.3	0	0
1700	0	0	0.4	4.4	18.1	29.1	18.1	4.4	0.4	0	0

4.3. Модели за разпространяване на замърсители във водни басейни [2]

При замърсяване на водните басейни с различни видове минерални и органични замърсители отделяни от битови и промишлени източници се поставят следните основни проблеми:

- определяне вида на изхвърления замърсител;
- определяне начина на въздействие на замърсителя върху водния басейн: точково или дифузионно въздействие;
- определяне на продължителността на действието на източника на замърсяване;
- определяне на площта засегната от замърсителя.

Разгледано е разпространението на концентрацията на точков замърсител във воден басейн при еднократно (залпово) въздействие и при продължително въздействие за определени периоди от време. Разпространението на концентрацията на разтворено в течност вещество с маса m като функция на времето на разпространение t и разстоянието от точката на изхвърляне r се определя според чрез зависимостта:

$$C(r,t) = \frac{m}{8\rho(\pi Dt)^{3/2}} e^{-\frac{r^2}{4Dt}} \quad (1)$$

където D е коефициент на дифузия на замърсителя, ρ е плътността на течността.

От теорията на течностите е известно, че коефициента на дифузия за еднородна течност се изменя по следния закон:

$$D = \frac{d^3}{6\tau_0} e^{-\frac{M}{kT}} \quad (2)$$

където d е средното разстояние между молекулите на определения вид течност, τ_0 е средния период на колебание на молекулите около положението на равновесие, W е енергията на активация на молекулите на съответната течност и T е температурата. От (2) следва, че коефициентът на дифузия расте с увеличаване на температурата. Този факт се обяснява с нарастването на разстоянието между молекулите на течността и намаляване на времето за релаксация (периода на колебание) на молекулите в нея.

В реални условия трябва да се вземе предвид процеса на разреждане на отпадъчните води в речния басейн. При този процес могат да се различат следните физически явления :

- разреждане в хомогенна, среда;
- разреждане в стратифицирана среда;
- първоначално разреждане в близост до източник на изпускане;
- вторично разреждане при отчитане коефициентите на хоризонтална и вертикална дифузия;
- процес на разреждане при кръгла и плоска струя.

Степента на първоначално разреждане N_0 може да се определи по формулата на Седервал [И. Дядовски, 1995] :

$$N_0 = 0.54 Fr_0 (0.38 \frac{z_0}{d_0 Fr_0} + 0.66)^{5/3} \quad (3)$$

където Fr_0 е обобщеното число на Фруд, z_0 е дълбочината на заустване на източника на замърсяване. v_0 е диаметъра на изпускателния отвор, d_0 е скоростта на изтичане на струята. Числото на Фруд може да се определи със следната формула:

$$Fr_0 = \frac{v_0}{\sqrt{\frac{\rho_s - \rho_0}{\rho_0} g d_0}} \quad (4)$$


Коефициентите ρ_s , ρ_0 са съответно плътностите на отпадъчната течност и водата от басейна. За да се избегне явлението интрузия (обратно вливане на вода от басейна в изпускателя) е необходимо $Fr_0 > 1$. Степента на вторично разреждане може да се определи по метода на Т. Гърданов за стационарен източник и променлив коефициент на хоризонтална турбулентна дифузия:

$$N = \frac{(B_0^{2/3} - 0.08 \frac{x}{v})^{3/2}}{B_0} = \frac{A}{B_0} \quad (5)$$

където A е широчината на разсейващото поле от замърсяващи вещества. B_0 е дължината на разсейващия изпускател, v е средната скорост на течението на реката, x е разстоянието от точката на изпускане. Коефициента на хоризонтална турбулентна дифузия може да се получи чрез:

$$D_x = 0.01(B_0^{2/3} + 0.08 \frac{x}{v})^2 \quad (6)$$

Графиката на изменение на коефициента на хоризонтална дифузия като функция на x е дадена на Фигура 4.3.1. От нея се вижда, че този коефициент нараства параболично с нарастването на разстоянието от източника x и за разстояние от 10000 м достига стойност 1600.



Фиг. 4.3.1. Изменение на коефициента хоризонтална турбулентна дифузия D_0 като функция на x


На базата на зависимостта за разпространението на концентрацията на разтворено вещество в течност (1) могат да се разгледат следните случаи:

4.3.1. Еднократно изпускане на замърсител във воден басейн без течение

Разпространението на концентрацията C в дадена точка (x,y) от повърхността на водата в момента t може да се получи след заместване на разстоянието r от центъра на координатната система с $r^2 = x^2 + y^2$ във формула (1),

$$C(x, y, t) = \frac{m}{8\rho(\pi Dt)^{3/2}} e^{-\frac{x^2+y^2}{4Dt}} \quad (7)$$


където: m е масата на замърсителя, ρ - плътността на водата, а D - дифузията на замърсителя във водата. Тук координатната система е определена с начало точката на вливане на замърсителя. Концентрацията се разпространява кръгообразно около точката на замърсяване, като тя е най-голяма в центъра и намалява с отдалечаване от него (Фигура 4.3.2). С течение на времето замърсеното петно нараства, но концентрацията намалява (Фигура 4.3.3).



Фиг. 4.3.2. Разпространение на концентрацията в басейн без течение при еднократно изпускане на замърсителя

В този случай може да се поставят задачите за:

- диаметъра или площта на замърсяване по-голямо от дадена концентрация в даден момент от времето;
- след колко време замърсяването в точката на изпускане ще спадне под някаква зададена пределно допустима концентрация $C_{\text{ПДК}}$.



Фиг. 4.3.3. Разпространяване на замърсяването в момент t_1 и момент t_2

Решенията на тези задачи се получава по следния начин: В първата задача като се има предвид, че диаметърът е $\left(\frac{d}{2}\right)^2 = x^2 + y^2$ и като се замести в (7), след което се реши полученото уравнение спрямо d , се получава

$$d(t, C) = 4 \sqrt{Dt \operatorname{Log} \frac{8C\rho(\pi Dt)^{3/2}}{m}} \quad (8)$$

Във втората задача $x^2 + y^2 = 0$ и от (7) намираме t .


$$t = \frac{1}{4\pi D} \left(\frac{m}{\rho C_{\text{ПДК}}} \right)^{\frac{2}{3}} \quad (9)$$

4.3.2. Еднократно изпускане на замърсител във воден басейн с течение

Нека (7) се разгледа като уравнение спрямо x . След решение на това уравнение се получава разстоянието по оста x , което изминава замърсителя с дадена концентрация C в даден момент от времето t . Ако към това разстояние се добави vt (допълнителния път изминат от замърсителя в резултат на течението) и отново се намери концентрацията C , ще се получи формулата

$$C(x, y, t) = \frac{m}{8\rho(\pi Dt)^{3/2}} e^{-\frac{(x-vt)^2 + y^2}{4Dt}} \quad (10)$$

където v е скоростта на течението. Координатната система е ориентирана така, че оста x съвпада с посоката на течението. Петното със замърсителя отново има формата на кръг, който с течението на времето се разширява и концентрацията намалява, обаче този кръг за разлика от предния случай се отнася надолу по течението (Фигура 4.3.4),



Фиг. 4.3.4. Разнасяне на замърсител в басейн с течение при единични изпускане

Могат да се поставят задачи за:

- определяне момента t , когато през дадена точка от водния басейн преминава замърсител с максимална концентрация.

Решението се намира по следния начин: Търси се първата производна по времето на $C(x, y, t)$ от (10). Полученият израз се приравнява на 0.

$$\frac{Dm(-6Dt - t^2v^2 + x^2 + y^2)}{32\pi^{3/2}\rho(Dt)^{7/2}e^{-\frac{(x-vt)^2 + y^2}{4Dt}}} = 0 \quad (11)$$

За да има решение уравнението (11) трябва:

$$-6Dt - t^2v^2 + x^2 + y^2 = 0$$

Това е квадратно уравнение, което има решение

$$t = \frac{-3D + \sqrt{9D^2 + v^2(x^2 + y^2)}}{v^2} \quad (12)$$

- откриване местоположението на неизвестен източник на замърсяване, времето и количеството на изпуснатия замърсител.

Това става по следния начин: откриват се три точки от петното с еднаква концентрация C_1 , намират се центърът P и радиусът R на окръжността минаваща през трите точки, измерва се концентрацията C_P в точката P , след което по формули

$$t = \frac{R^2}{4D \log \frac{C_P}{C_1}} \quad (13)$$

$$m = 8C_P \rho (\pi D t)^{3/2} \quad (14)$$


се определят неизвестната маса m и време t на замърсяването, а източника се намира на разстояние vt от точка P нагоре по течението.

4.3.3. Непрекъснато изпускане на замърсител във воден басейн с течение

Този случай може да се изведе от предходния. Непрекъснатото изпускане на замърсител може да се разглежда като многократни единични изпускания. Тогава формулата за концентрацията на замърсителя се получава чрез интегриране по времето на формула (10).

$$C(x, y, t) = \int_{t_0}^t \frac{m}{8\rho\sqrt{(\pi D \tau)^3}} e^{-\frac{(x-v\tau)^2 + y^2}{4D\tau}} d\tau \quad (15)$$

където m е изхвърлената маса на замърсителя за единица време. За съжаление този интеграл няма аналитично решение. Той може да се сведе до функция на грешката, която се дава в таблици или може направо да се използва числено интегриране. Разпространението на концентрацията и показано на Фигура 4.3.5.




Фиг. 4.3.5. Разнасяне на замърсител в басейн с течение при непрекъснато изпускане

4.3.4. Непрекъснато изпускане на замърсител във воден басейн с течение и с бряг

В този случай замърсителят, след като достигне брега, една част от него се отлага на брега, а останалата част започва да се разпространява обратно навътре в басейна. Тогава формулата за разпространение при бряг успореден на оста x добива следния вид

$$C(x, y, t) = \begin{cases} 0, & |y| > b \\ \int_{t_0}^t \frac{m}{8\rho\sqrt{(\pi D \tau)^3}} \left(e^{-\frac{(x-v\tau)^2+y^2}{4D\tau}} + k e^{-\frac{(x-v\tau)^2+(2b\pm y)^2}{4D\tau}} \right) d\tau & (16) \end{cases}$$

където b е разстоянието до брега, а k е коефициента на отлагане. На Фигура 4.3.6 са дадени графики на концентрациите със и без бряг напречно на течението



Фиг.4.3.6. Графики на концентрациите с и без бряг напречно на течението

Заключение и насоки за бъдещи изследвания

Настоящият труд обхваща изследвания в период, през който за условията на нашата страна настъпиха структурни промени, включително и в геологопроучвателното и минното дело. През този период информатиката и информационните технологии заеха определящо място в миннодобивния отрасъл. Проблемите и решенията свързани с опазването на околната среда и водите, дълго време омаловажавани, по време на структурните промени и с приемането на пазарните принципи у нас, станаха неделима част от дейностите по осигуряване на суровини и енергия за промишлеността.

Моделният подход, осигурен с достиженията на информационните технологии, се превърна в мощно средство за генериране на решения, оценки и прогнози по отношение на проучването и разработването на находищата на подземни богатства и постигане на тяхната екологосъобразност. Традиционно възприетият моделен подход (съществуващ повече от век) в слабо организирани системи, за каквито се считат находищата на природни подземни богатства, на настоящия етап на развитие на промишлеността и икономиката е обогатен със съвременни средства за обработка на информацията и по този начин осигурява по-пълно и по-облекчено съвместно разглеждане на причинителите и последствията – добива на подземните богатства и екологичните замърсявания причинени от този добив.

Изследванията обхващат модели за оценка на геохимично поле по съдържание на мед и сяра в двете най-големи находища за добив на медна руда у нас, разработвани по открит начин. Тази оценка включва решаването на следните задачи:

- Определяне стационарността на основен геоложки фактор (съдържание на мед) на находище. Извършеният анализ показва наличие на слаба стационарност на изследваното находище по отношение съдържанието на мед.
- Класификационен и клъстерен анализ в медно находище за целите на оперативното планиране на добива в открит рудник. Извършено е класификация по отношение на съдържанието на мед и на сяра и по двата показателя едновременно в няколко добивни хоризонта, определени са контурите и лицата на клъстерите, на които се разделя даден клас в конкретен хоризонт.
- Прогнозиране на стойността на геоложки показател (съдържание на мед) чрез невронна мрежа в един хоризонт. Изследването показва, че може да се обучи невронна мрежа, която с достатъчно голяма точност може да се използва за прогнозиране.
- Определяне тримерния модел на изменение на съдържанието на мед чрез невронни мрежи. Невронни мрежи са обучени върху данни от три последователни добивни хоризонта на медно находище. Отново се оказва, че многопластов персептрон с два скрити слоя дава най-подходящи

результати. След това с този персептрон е направена прогноза в следващ четвърти хоризонт, която корелира с реалните данни от хоризонта

- Влияние на плътността на геоложката информация на качеството на обучение на невронна мрежа. Чрез авторова програма, на базата на данни от експлоатационното проучване от седем добивни хоризонта са получени 42 регулярни мрежи с различна плътност. Върху тях са обучени невронни мрежи. Резултатите показват, че проби взети с плътност 30 x 30 м могат да обучат невронна мрежа по-такъв начин, че тя да дава достатъчно добра прогноза.

В областта на минната екология са направени следните модели:

- Изследване на замърсяване с аерозоли базирано на модела на Pasquill и Gifford. На базата на този модел и разгледано влиянието на концентрацията, на количеството на замърсителя, на силата на вятъра и на височината на комина върху разпространението на аерозола. определени са вида и площта на замърсения район.
- Експериментална оценка на замърсяването с прах от ТЕЦ "Кремиковци". Въз основа на данни за изпускания от централата прах са направени количествени оценки за неговото разпространяване.
- Модели за разпространяване на замърсители във водни басейни. Намерени са функции описващи разпространяването на замърсители във водни басейни, без и с течение и с брегове.

През последните години в осигуряването на процесите при проучването и разработването на находищата и мониторинга за опазването на околната среда навигационните и сканиращи системи заемат все по-определящо място. В обектите на находищата „Елаците” и „Асарел” експрес анализаторите, GPS, сканиращите системи и други средства, осигуряват информация, която пълноценно може да се използва от предлаганите модели. Това от своя страна изисква, както проверка и адаптация, така и прагматичност в оценките на получените резултати, както и технологично време. На базата на експрес анализиране, GPS позициониране и сканиращите системи става възможно разработването на системи за прогнозиране в реално или почти реално време. Тук важна роля биха играли вече обучени да прогнозират невронни мрежи.

В областта на минната екология важна роля играят системите за мониторинг на околната среда в района на добивния комплекс – наличието на газове и прах във въздуха, на различни замърсители във водните басейни и подпочвените води, замърсяването на почвата с тежки метали, цианиди и др. Данните събирани от тези системи е необходимо да бъдат дълбочинно изследвани и обобщени. Системите за ранно предупреждение захранвани с данни от мониторинга се нуждаят от адекватни модели на районите на замърсяване за да може да се вземат навременни и подходящи мерки за реакция. Други въпроси подлежащи на детайлно изучаване са тези за рекултивация на засегнатите от добива райони. Например търсенето на подходящи горски насаждения, чрез които замърсените участъци ще се укрепят и / или самопочистят, а от друга страна ще се прогнозира завършеността на предназначението на рекултивирания терен.

Публикации на автора свързани с дисертацията

1. Analysis of Air Pollution with Aerosols and Dust Based on the Mathematical Model of Pasquill and Gifford - V.Christov and St. Dimoff, in ISU, Wissenschaft und Umwelt, no.2, 1995, 85-88.
2. Модели за разпространяване на замърсители във водни басейни. - Станислав Димов и Веселин Христов, в “7-ми международен симпозиум по приложение на математически модели и компютри в минното дело, геологията и металургията”, София, 28-30.10.1998г., стр.264-270.
3. Prognostication of Geological Parameters Value Using Neural Networks, - St. Topalov, V. Hristov – in the Proceedings of International Society for Mine Surveying XIII International Congress, Budapest, Hungary, 24-28 September 2007, No 048, избрана и публикувана в Institute of Mine Surveyors of South Africa Journal, Vol. XXXIV, No. 2, June 2010, 18 – 25.
4. Investigation of 3D copper grade changeability by Neural Networks in metasomatic ore deposit - St. Topalov, V. Hristov – in Proceedings of the 9th WSEAS International Conferences on: NEURAL NETWORKS (NN'08), Sofia, Bulgaria, May 2-4, 2008, 58 – 62.
5. Cluster Analysis of Copper Ore Types by Neural Networks in Aid of Mine Operations Planning – V. Hristov, St. Topalov – in 3rd Balkan Mine Congress, October 1 – 3 2009, Izmir, Turkey.
6. Стационарност на основен геоложки фактор – съдържание на мед – проверка или приемане априори. – В. Христов, Ст. Топалов, в Proceedings of the XI-th National Conference With International Participation of the Open and Underwater Mining of Minerals, 19–23 June 2011, Varna, Bulgaria, 195- 201
7. Influence of geological information density on the training quality of neural networks as forecast models - V. Hristov, St. Topalov. in The 6th Jordanian International Mining Conference, 01 – 03 November 2011, Amman