



Possibilities for the application of computer neural networks in the statistical analysis of petrophysical data

Atanas Kisyov¹

¹- University of Mining and Geology, Department of Applied Geophysics, e-mail: at.kisyov@gmail.com

Keywords: neural networks, petrophysics, statistical analysis

Abstract

Some difficulties are often occurring when classical analytical methods are applied for processing and statistical analysis of petrophysical data. They are caused by the close (overlapping) values for the physical parameters of various samples. The development of artificial intelligence in the field of information technologies provides a solution to such problems. Computer neural networks can be successfully used as they are universal approximators and applied as analysis tools they can give the best fit to the distribution of any continuous function.

The possibilities for the application of computer neural networks are presented by the performed statistical analysis of 720 granodiorites samples from the Panagyurishte ore region.

Възможности за приложение на компютърните невронни мрежи при статистически анализ на петрофизични данни

Атанас Кисъов¹

¹- Катедра „Приложна геофизика“, Минно-геоложки университет „Св. Иван Рилски“, e-mail: at.kisyov@gmail.com

Ключови думи: невронни мрежи, петрофизика, статистически анализ

Въведение


Невронните мрежи са универсални апроксиматори и като инструменти те могат да се сближат с всяка непрекъсната функция с произволна точност. Следователно невронните мрежи са приложими за решаването на различни геофизични задачи. Въпреки това, използването на множеството методи и техники, които се разработват за да се повиши ефективността и да се улесни използването на невронните мрежи, все още не са широко разпространени в приложната геофизика. Следователно, ефективността на тези средства все още не е изследвана в пълната си степен.

Невронните мрежи са най-типичният представител на програмните системи, които следват т. нар. конекционистки подход в изкуствения интелект. Обобщено има два подхода към изкуствения интелект: символен и конекционистки. Най-съществената разлика между тях е свързана с отношението им към представянето на знанията.

Работата със знания е една от съществените отличителни черти на програмните системи с изкуствен интелект. Според едно от популярните определения *интелектът е способност за формулиране, натрупване и използване на знания (Intelligence is applied knowledge)*. Терминът “знание” в системите с изкуствен интелект се използва за означаване на *кодирания опит на агентите*. Опитът е източникът на знания (информация) за решаването на задачи. Чрез *определението “кодиран” се означава обстоятелството, че знанията са формулирани, записани и готови за използване* (Нишева, Шипков. 1995). Съществена за системите с изкуствен интелект е възможността за преход от работа с данни към работа със знания. Традиционните програмни системи работят с информация, организирана във вид на бази от данни, докато за системите с изкуствения интелект и по-точно за т. нар. системи, основани на знания (Knowledge-based systems) е характерна работата с бази от знания. Има фундаментална разлика между възможностите, които предоставят тези два типа системи за съхранение и предоставяне на информация. При базите данни е възможно извличане само на такава информация, която е представена в явен вид в базата. При базите знание е възможно извършването на разсъждения (извод), в резултат на което може да се генерира нова информация, която не присъства в явен вид в базата.

Историческото развитие на невронните мрежи

Първите стъпки по пътя на развитието на компютърната невронни мрежи са взети от видния психолог Уилям Джеймс (1890) в края на 19-ти век, изследващ функциите на паметта в мозъка. По късно 1943г. Уорън Маккълч (Warren McCulloch), заедно с Уолтър Питс (Walter Pitts), базирайки се на работата на Уилям Джеймс, описват поведението на мозъка, като математически модели на невронната функция. Създават първият прост невронен модел, който *изпълнява логически изчисления със зададени ограничения*, и доказват, че техния невронен модел може да изчисли всеки краен логически израз (Poulton, 2001, Stergiou and Siganos,).



Фиг.1 Схема на McCulloch-Pitts неврони

Десетилетието между 1946 и 1958 свидетелства за раждането на компютърните неврони и поделянето на невронната мрежа между научните изследвания и "изкуствения интелект".

Уайл Мински (While Minsky), студент в Принстън, конструирала първия неврокомпютър, наричан „SNARC“ /Stochastic Neural-Analog Reinforcement Computer/. Състоящ се от 40 електронни "неврони" свързани с регулируеми връзки, обучаващ се чрез малки корекции на напрежението и полярността на връзките.

През 1958 година, когато психолога Франк Розенблат (Frank Rosenblatt) и инженера Чарлс Уитман (Charles Wightman) разработват **Марк I Перцептронен неврокомпютър**, с учебен алгоритъм на математическа основа, както и психологически и неврологични връзки, **Марк I** успява успешно да разпознава образи и прави асоциации. Така Розенблат за първи път формулира термина „*Перцептронен*“, състоящ от три слоя: **входен** (четящ входния модел), **междинен** (свързващ слой) и **изходен** (*отговор на задачата, като използва подхода „победителя взима всичко“ - т.е може да има само едно решение.*



Фиг.2 Схема на Перцептрон

Голяма част от основното развитие в компютърните невронни мрежи все още е стремежа за по-тясно изучаване и копиране на биологичните невронни мрежи. Най-новите архитектури са разработени с определена биологична или психологическа вярност (Kriesel, 2005).

С развитието възможностите на компютърните технологии, напредъка в разработването на изчислителни алгоритми, пресъздаващи работата на биологичната нервна система при „*взимането на решения*“ при решаването за различни типове задачи, набира все по-голяма популярност (Zhan, Poulton et. all 2002).

Основни типове модели на компютърните невронни мрежи

Могат да се определят пет основни характеристики на невронните мрежи, които обикновено се използват за класификационни признаци при определянето на типовете модели. Тези характеристики са: топологията на мрежата, параметрите на обработващите елементи, типът на входните стойности, използваното обучаващо правило и методът за обучение на мрежата.

Според топологията на мрежата

Най-често срещани са невронните мрежи съставени от няколко обособени (последователни) слоя от елементи (неврони), при които елементите от най-ниския слой играят ролята на входни устройства на мрежата (възприемат сигнали от външната среда), а елементите от най-горния слой играят ролята на

изходни устройства на мрежата (извеждат резултата от работата на мрежата, който по същество се получава въз основа на входните сигнали и теглата на връзките в системата). Често при тези невронни мрежи връзките са еднопосочни и свързват елементите от един слой с елементи от слоя, разположен непосредствено над него.

В зависимост от броя на слоевете в мрежата се говори за *двуслойни невронни мрежи* (при тях има само входен и изходен слой) и *многослойни невронни мрежи* - при тях има поне един вътрешен (скрит) слой.



Трислойна мрежа


Двуслойна мрежа

Фиг.3. Примери за двуслойни и многослойни невронни мрежи

Според параметрите на елементите

Тук се включват теглата и посоката на връзките, видът на активационната функция. При повечето невронни мрежи връзките са еднопосочни и са ориентирани от елементите от даден слой към елементите от слоя, разположен непосредствено над него. Съществуват обаче и невронни мрежи (такива са например *мрежите на Хонфийлд*), при които всеки елемент е свързан с двупосочни връзки с всички свои съседи. При тези мрежи понятието слой до голяма степен губи своя смисъл.

Най-често срещаните типове активационни функции показани на фигура 4. По оста x се задава сумата от входните сигнали (сумата от активиращите напрежения на входните елементи), а по оста y - сумата от изходните сигнали (сумата от активиращите напрежения на изходните елементи). Най-популярните функции за илюстрирани на фигура 4. **а, б, в, г са** сигмоидалната и варианти на стъпаловидна функция (Haykin, 2006, Calderon-Macias, Carlos).



Фиг.4 Типове активационни функции

Според типа на входните стойности

Входните стойности на мрежата (т. е. сигналите, които получават елементите от входния слой) могат да бъдат двоични (0 или 1) или аналогови (реални числа).

Според обучаващото правило

Най-често невронните мрежи се използват за решаване на задачи, свързани с разпознаване (класификация). При това създаването на мрежа, предназначена за решаване на дадена задача, обикновено се извършва по следната обща схема. Най-напред се определя топологията на мрежата, т.



е. броят на слоевете и броят на елементите във всеки слой. Броят на елементите от входния слой се определя от обема на входните данни, а броят на елементите от изходния от броя на разпознаваните класове. Размерите на скритите слоеве, които обикновено са нула, един или два на брой, най-често се определят итеративно в зависимост от конкретната задача. След определянето на топологията на мрежата се преминава към нейното обучаване, т. е. към определянето на подходящи стойности на теглата на връзките между елементите. За целта най-често първоначално се задават случайни стойности на търсените тегла, след което многократно се изпълнява следната процедура. Избира се пример от обучаващото множество. Този пример се състои от вектор от входни стойности и съответен вектор от правилни (желателни, очаквани) изходни стойности на мрежата. След това се определят действителният изход на мрежата за разглеждания входен вектор и разликата между желателния и действителния изход. Накрая се променят текущите тегла на връзките така, че новият изход да бъде по-близък до желателния. Правилото, по което се променят теглата на връзките, се нарича *обучаващо правило* (обучаващ алгоритъм) на мрежата (Никитин. 1986).

Примери за по-известни обучаващи правила са правило за обучение на *персептрона* (алгоритъм за обучение с фиксирано нарастване), алгоритъм за обучение с *обратно разпространение на грешката* (back-propagation algorithm), *насочено случайно търсене* /directed random search/, *устойчиво обратно разпространение* /resilient back-propagation/, *Квази-Нютонов метод* / Quasi-Newton method /, *Левенберг - Марквард метод* /Levenberg-Marquardt method /, *правило за конкурентно обучение* и др.

Според метода на обучение

Съществуват два основни типа обучение на невронните мрежи - обучение с учител (надзирано обучение) и самообучение (надзирано обучение). При обучението с учител се следи разликата между получения и очаквания изходен резултат на мрежата („*учителят*“ задава очаквания изход на мрежата) и интерактивно се извършват корекции на теглата на връзките съгласно избраното обучаващо правило. При самообучението липсва учител, т. е. липсват предварителни данни за правилния изход на мрежата. Теглата на връзките се настройват така, че представянето на данните в мрежата да е най-добро съгласно използвания (зададения) критерий за качеството на представянето. В зависимост от използвания метод на обучение невронните мрежи се разделят на: обучавани с учител и самообучаващи се (Van der Baan, Mirko 2005).

Невронните мрежи могат да бъдат използвани под формата на класификационен или за регресионен анализ, когато трябва да се определи конкретна стойност въз основа на получения модел.

Когато се анализират геофизичните данни, търсим модели, свързани с конкретни "цели". Тези цели са или с геоложки характер като газови и петролни хоризонти, водоносен хоризонт, или минерални залежи; Също така цели свързани с човешката дейност: взаимодействие със земята като опасни отпадъци, неексплодирани артилерийски снаряди, тунели, и т.н.

И в двата случая имаме за мярка физическа стойност приписана на „*целта*“, който се различава от стойностите на околните площи.

Анализ на гранодиоритите от Панагюрския руден район

Реализирането на класификационни процедури чрез използване на невронни мрежи е осъществено в обща извадка от изследвани проби на гранодиорити и гранодиоритови порфирити от естествени разкрития и сондажи. Извадка е характеризирана чрез три петрофизични параметъра – плътност, магнитна възприемчивост и коефициент на поляризуемост. Дефинирани са три възможни групи проби с близки петрофизични характеристики, по които ще бъде реализирано “обучението” за прогнозиране.

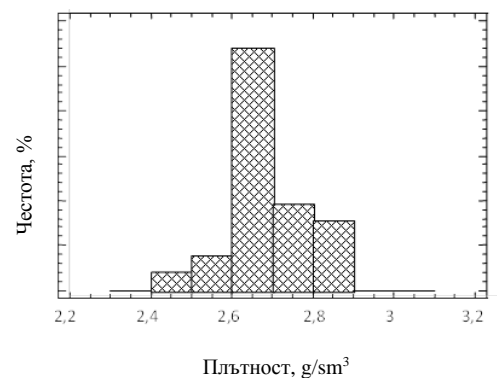
Основните статистически характеристики за гранодиоритите и гранодиоритовите порфирити са систематизирани в таблица 1.

Таблица 1. - Систематизирани данни за плътността, магнитната възприемчивост и коефициента на поляризуемост на гранодиорити и гранодиоритови порфири в Панагюрски руден район (разкрития и сондажи)

№ по ред	Вид на скалата	Местоположение	Общ брой на пробите, $N_{\Sigma} N$	Диапазон на изменение min - max	Средна стойност	Стандартно отклонение S	Асиметрия A	Ексцес E
Плътност g/cm^3	Гранодиорит	Σ (Естествени разкрития и сондажи) Пълна извадка	170	2,36 – 2,80	2,59	0,08	-0,25	0,86
	Гранодиоритов порфирит	Пълна извадка	479	2,29 – 2,89	2,61	0,07	0,61	12,30
	Гранодиоритов порфирит	$2,40 < \rho \leq 2,80$	468 (479)	2,41 – 2,80	2,61	0,06	1,67	4,30
Магнитна възприемчивост	Гранодиорит	Σ (Естествени разкрития и сондажи) Пълна извадка	170	0 – 35226	1300	4218	34,87	98,05
	Гранодиоритов порфирит	Пълна извадка	483	0 – 37052	1148	3037	56	252
	Гранодиоритов порфирит	$0 < \chi < 10000 \cdot 10^{-5} SI$	166 (483)	72 – 9152	2425	2081	6,36	2,34
Коефициент на поляризуемост	Гранодиорит	Σ (Естествени разкрития и сондажи) Пълна извадка	154	0,18–30,54	2,91	2,78	34,81	162,29
	Гранодиорит	Σ (Естествени разкрития и сондажи) $\eta < 10 \%$	153 (154)	0,18 – 9,98	2,73	1,65	11,10	17,45
	Гранодиорит	Σ (Естествени разкрития и сондажи) $\eta < 6 \%$	146 (154) (153)	0,18 – 5,59	2,49	1,09	2,47	0,21
	Гранодиоритов порфирит	Пълна извадка	474	0,35 – 32,2	3,36	3,24	39,06	119,06
	Гранодиоритов порфирит	$\eta < 10 \%$	457 (474)	0,35 – 9,86	2,87	1,71	16,58	17,48


Петрофизичните свойства на гранодиоритите и гранодиоритовите порфири са изследвани по много голям брой проби. Конкретно са анализирани извадки за 8 сондажа в участъците „Цар Асен“, „Попинци“, „Сивата грамада“ и „Боримечково“ (Радичев, Димовски. 2010).

Статистическите данни за плътността варират в много широк диапазон – от средна стойност 2,69 g/cm^3 за сондаж С-28, обект „Цар Асен“ до 2,57 g/cm^3 за сондаж С-72, обект „Попинци“. Основната група е в интервала 2,6 - 2,7 g/cm^3 . Добре изразената дясна асиметрия вероятно се обуславя от присъствието в различно количество на рудни минерали. (Фиг. 5.)



Фиг. 5. Хистограма на разпределението на плътността за гранодиоритов порфирит от С - 26 в обект „Цар Асен“

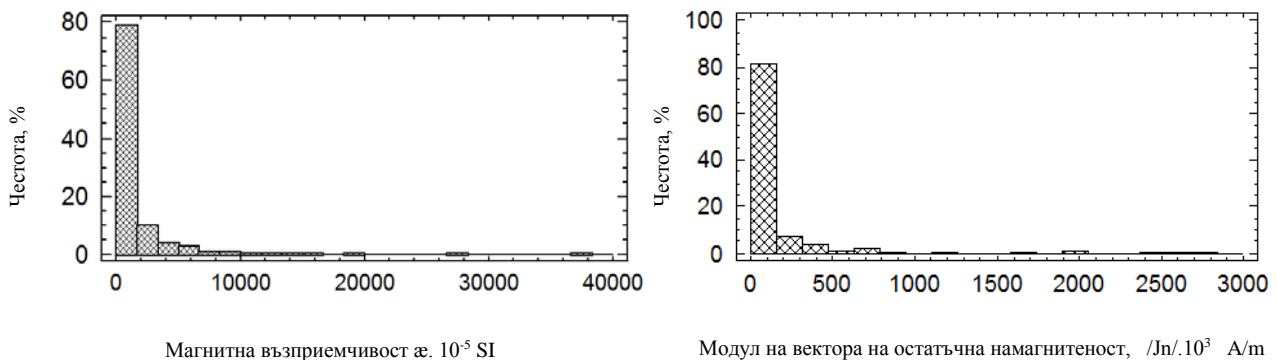
Хистограмата на разпределение на плътността за пълната извадка от гранодиоритови порфири (N = 479) се илюстрира на фигура 6.18,а. Разпределението е нормално. Диапазонът на изменение е много голям – от 2,29 g/cm³ до 2,89 g/cm³, а средната стойност за плътността е 2,61 g/cm³. (Фигура 6.)



Фиг.6. Хистограми на разпределението на плътността за гранодиоритов порфири: пълна извадка (а) и за $2,40 < \rho \leq 2,80 \text{ g/cm}^3$ (б).

Получените статистически характеристики за изследваните извадки показват, че за условията на Панагюрски руден район, освен първичните предпоставки на формиране на магмените скали твърде съществено и с различна степен на изява е влиянието на две разнопосочни въздействия – присъствието на тежки рудни минерали и разуплътняващия ефект от хидротермално-метасоматичните процеси.

Статистическият анализ показва, че магнитните параметри се разполагат в широк диапазон от стойности. Диапазонът на изменение на магнитната възприемчивост е в границите на 0 – до около $15000 \cdot 10^{-5} \text{ SI}$, а за вектора на остатъчна намагнитеност – от 0 – до около $3500 \cdot 10^{-3} \text{ A/m}$. От извадките за двата магнитни параметъра се набелязва разслояване на три групи.



Фиг. 7. Хистограми на разпределението на магнитната възприемчивост и разпределението на модула на вектора на остатъчна намагнитеност на гранодиоритов порфирит, за пълна извадка

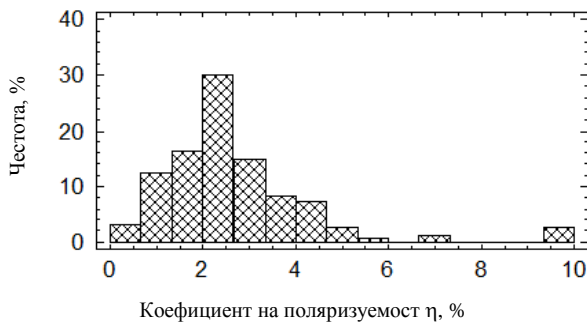
Анализът показва, че тези групи не се привързват към отделни участъци, а изразяват общи тенденции. С най-голям брой проби се оформя първата група със стойност за магнитната възприемчивост $500 \cdot 10^{-5} - 700 \cdot 10^{-5} \text{ SI}$ и на модула на вектора на остатъчна намагнитеност $40 \cdot 10^{-3} - 100 \cdot 10^{-3} \text{ A/m}$. Независимо от общите елементи на разпределение отсъства еднозначна корелационна връзка между тях (Радичев, Димовски. 2010).

Разпределение на коефициента на поляризуемост на гранодиоритите и гранодиоритовите порфири в района Попинци – Попово дере, съдържа една група с аномално висока стойност (30,54%), а основната група ($\eta < 10\%$) се разпределя нормално със средна стойност 4,61%, относително завишена от няколко проби с коефициент на поляризуемост около 9%.




Фиг. 8. Хистограма на разпределението на коефициента на поляризуемост η за гранодиорити от сондажи С – 60, С-61 и С-62 в участък Попинци – Попово дере: извадка за $\eta < 10\%$

За пробите от сондажи данните са редуцирана за $\eta < 6$, за да се изключи влиянието на пробите с относително висока поляризуемост, свързана с присъствието на електроннопроводящи минерали. Разпределението на параметъра в общи линии съответства на разпределението за пробите от естествени разкрития (0 - 10 %).



(а)




(б)

Фиг.9. Хистограми на разпределението на коефициента на поляризуемост на гранодиорити; за $\eta < 10\%$ (а) и за $\eta < 6\%$ (б);

Получени резултати

Приставени са хистограмите на разпределението на групите, получени при използването на различни активационни функции, в процеса на класификация на невронните мрежи. Вероятностните принадлежности варират в широки граници за всички класификатори. Освен това се наблюдава много широк диапазон на количествените съотношения между отделните групи за различните невронни мрежи. Това очевидно се обуславя от силно изразената хетерогенна характеристика на пробите.





Фиг.10. Хистограми на разпределението на обособените групи проби чрез разновариантни невронни мрежи

Таблица 2. Систематизирани данните от класифицирането на всички проби, включени в изследваната извадка от гранодиорити чрез невронни мрежи.

Класификатор	Група			сума	Група		
	1	2	3		1	2	3
	Брой на пробите				Процент		
<i>Identity</i>	433	78	202	720	60,1389	10,8333	28,0556
<i>Exponential</i>	306	88	319	720	42,5	12,2222	44,3056
<i>Gauss</i>	264	105	344	720	36,6667	14,5833	47,7778
<i>Logistic</i>	419	64	230	720	58,1944	8,8889	31,9444
<i>Sine</i>	492	95	125	720	68,3333	13,1944	17,3611

Заклучение

Въз основа на извършените изследвания са постигнати следните основни резултати:

Обработена е извадка от гранодиорити, характеризирани чрез три петрофизични параметъра – плътност, магнитна възприемчивост и коефициент на поляризуемост. Дефинирани са три възможни групи проби с близки петрофизични характеристики. По тези групи е реализирано “обучението” за прогнозиране.

От представените в таблица 2 систематизирани резултати, може да се направи анализ, който показва, че вероятностните принадлежности варират в широки граници, което както вече се посочи, е напълно мотивирано от силно изразената хетерогенна характеристика на пробите. Независимо от това и при петте използвани невронни мрежи ясно се отделят различните типове групи. Изключение прави само мрежата използваща гаусова активационна функция, при която отношението на групите се отличава спрямо останалите тестови мрежи.

Като основен извод може да се каже, че невронни мрежи за целите на прогнозирането и класифицирането по петрофизични данни, еднозначно успява да отдели различните скални разновидности, макар тяхната силно изразена хетерогенност.



Литература

- Никитин, А.А.. 1986. Теоретические основы обработки геофизической информации. Москва. Недра.
- Нишева, А.М., Шипков, Д. 1995. "Искусствен интелект," издателство Интеграл, Добрич
- Радичев, Р., Димовски, Ст. 2010. Плътнос, магнитни свойства и коефициент на поляризуемост за основни видове скали в панагюрски руден район. Приложно-ориентирано използване на данните. София. ISBN 978-954-353-107-3, 278 стр.
- Справочник геофизика, 1989. Физические свойства горных пород и полезных ископаемых. Недра, Москва
- Calderon-Macias, Carlos., Sen, Mrinal.; Geophysical Interpretation by Artificial Neural Systems – University of Texas at Austin
- Haykin, Simon. 2006. Neural Networks – McMaster University Hamilton, Ontario, Canada
- Kriesel, David. 2005. A Brief Introduction to Neural Networks; University of Bonn, Germany, <http://www.dkriesel.com>
- Poulton, Mary M. 2001 - Computational neural networks for geophysical data processing- The University of Arizona Tucson, USA, 2001
- Stergiou, Christos., Siganos, Dimitrios – Neural Networks - Imperial College of Science Technology and Medicine, Queen's Gate, London
- Van der Baan, Mirko. Jutten, Christian. 2000. Neural networks in geophysical applications - Geophysics, vol. 65, no. 4; p. 1032–1047.
- Zhan, Lin , Poulton, Mary M., Wang, Tsili. 2002. Borehole electrical resistivity modeling using neural networks - Geophysics, vol. 67, p. 1790–1797