

УДК 622.276. 004.8

**НЕЙРОСЕТЕВАЯ МЕТОДИКА ОЦЕНКИ КОНЕЧНОГО
КОЭФФИЦИЕНТА ИЗВЛЕЧЕНИЯ НЕФТИ
(на примере месторождений Самарской области)**

Булгаков С.А.

Самарский государственный технический университет, г. Самара

e-mail: renigm.samgtu@gmail.com

Аннотация. Для месторождений Самарской области предложена методика определения коэффициента конечного нефтеизвлечения с использованием нелинейной математической модели. Методика базируется на применении математического аппарата нейронных сетей. Обоснованы оптимальные параметры многослойного перцептрона для решения поставленной задачи. Показано, что рассчитанный таким образом коэффициент конечного нефтеизвлечения оказывается ближе к фактическому значению по сравнению с методиками, основанными на многомерном регрессионном анализе.

Ключевые слова: перцептрон, многофакторный анализ, топология, нормализация, пласт, фильтрация, КИН.

Одной из самых значимых характеристик разработки нефтяного месторождения является коэффициент извлечения нефти (КИН). Данный параметр следует считать технико-экономическим показателем, так как, с одной стороны, он влияет на рентабельность инвестирования в разработку месторождения, а с другой стороны, характеризует успешность предлагаемых технологических и технических решений по разработке месторождения. Достоверность оперативного прогнозирования КИН может стать определяющим фактором при формировании портфеля перспективных структур при проведении геологоразведочных работ – поиске новых залежей нефти. Важно иметь верные представления о достигаемом конечном КИН при выполнении работ по мониторингу разработки месторождения, при анализе разработки и решении многих других задач.

Для «прямого» расчета КИН применяются различные методики, которые можно объединить в несколько групп: 1) экстрополяционные; 2) гидродинамические; 3) статистические.

Экстрополяционные методики используются для уточнения конечного КИН, их также называют «характеристикам вытеснения». Экстрополяционные методики базируются на обработке данных по добыче нефти на рассматриваемом месторождении за прошлый период и экстраполяции динамики добычи на

перспективу. В этом заключается основной минус данных методик – все они требуют наличия долгосрочного периода эксплуатации месторождения, максимального разбуривания месторождения уже в первые годы разработки. Применяя указанные методики, по сути, можно с достаточной степенью достоверности оценить только успешность предложенной для месторождения системы разработки на основе расчетов «базовой добычи» нефти.

Гидродинамические методики. Решением ЦКР (Центральной Комиссии по разработке) Роснедра с 2000 года проектные документы предписывается составлять на основе 3D геологических и гидродинамических моделей продуктивных пластов. Казалось бы, теперь КИН можно посчитать простым делением накопленной добычи нефти на геологические запасы. Но это заблуждение - полностью отказаться от альтернативной оценки КИН нельзя, так как накопленная добыча зависит от эффективности предлагаемой системы разработки, планируемых методов увеличения нефтеотдачи (МУН), а главное, достоверности построенной модели. Следовательно, для определения конечного КИН нужно будет рассматривать сотни возможных вариантов разработки. Для сокращения объемов вычислений, качественной оценки КИН и уточнения результатов гидродинамического моделирования эффективнее использовать эмпирические или полуаналитические формулы.

Статистические методики или методы многомерного регрессионного анализа позволяют на основе обобщения опыта длительно разрабатываемых месторождений установить статистическую связь величины КИН с большим числом факторов, оказывающих существенное влияние на полноту извлечения нефти. Существует множество статистических моделей [7,8]. Ниже представлены те, что были протестированы для группы месторождений Самарской области.

1. Статистическая зависимость С.В. Кожакина, полученная по результатам исследования 42 объектов Волго-Уральской области с терригенными поровыми коллекторами, разрабатываемыми в условиях водонапорного режима.

2. Статистическая зависимость В.Г.Гомзикова, Н.А.Молотовой, полученная по результатам анализа 50 объектов Урало-Поволжья с учетом размеров водонефтяных зон, нефтенасыщенности и пластовой температуры.

3. Обновленная статистическая зависимость для КИН, полученная В.К. Гомзиковым (1976 г.) на основе результатов исследований по нескольким залежам Ставрополя и охватывающая более широкий диапазон изменения пластовой температуры и нефтенасыщенности.

4. Зависимость, полученная В.К. Гомзиковым (1978 г.) для 35 пластов Азербайджана, справедливая в условиях значительного снижения пластового давления, плотной сетки скважин и конечной обводненности добываемой продукции 95%.

5. Собственная статистическая зависимость И.И. Абызбаева и Г.Г.Насырова, полученная применительно к залежам Башкирии и Куйбышевской

области, подстилаемым подошвенной водой и содержащим нефть повышенной вязкости (10-30 мПа·с).

6. Статистическая модель, полученная М.Т.Абасовым и Л.А. Султановым по 36 залежам Азербайджана и Туркмении, которая базируется, в основном, на темпе отбора нефти и коэффициенте безводной нефтеотдачи.

7. Собственная статистическая зависимость Бочарова Т.Ю., полученная по 36 залежам Азербайджана и справедливая для поровых коллекторов терригенного типа.

8. Зависимость для КИН Американского исследовательского института (АНИ), рассчитанная по 40 терригенным залежам.

В таблице 1 сведены все формулы и описаны коэффициенты по методикам определения КИН, указанным выше.

Таблица 1. Статистические формы, используемые для расчета КИН

Автор	Формула
Гомзиков В.К. (1976 г.)	$\eta = 0,333 - 0,0089 \cdot \mu_0 + 0,121 \cdot \lg(K_{\text{ПР}}) + 0,0013 \cdot t_0 + 0,0038 \cdot h +$ $+ 0,149 \cdot K_{\text{П}} - 0,085 \cdot W + 0,173 \cdot S_{\text{H}} - 0,00053 \cdot S_{\text{общ}}$
Гомзиков В.Г., Молотова Н.А.	$\eta = 0,195 - 0,0078 \cdot \mu_0 + 0,0821 \cdot \lg(K_{\text{ПР}}) + 0,00146 \cdot t_0 + 0,0039 \cdot h +$ $+ 0,18 \cdot K_{\text{П}} - 0,054 \cdot W + 0,27 \cdot S_{\text{H}} - 0,00086 \cdot S_{\text{общ}}$
Гомзиков В.К. (1978 г.)	$\eta = -0,674 - 0,01 \cdot \mu_0 + 0,306 \cdot K_{\text{П}} + 0,0019 \cdot h + 1,998 \cdot m +$ $+ 0,144 \cdot \lg(K_{\text{ПР}}) + 0,71 \cdot b$
Кожакин С.В.	$\eta = 0,507 - 0,167 \cdot \lg(\mu_0) + 0,0275 \cdot \lg(K_{\text{ПР}}) - 0,05 \cdot V_{\text{ПР}} +$ $+ 0,0018 \cdot h + 0,171 \cdot K_{\text{П}} - 0,000855 \cdot S_{\text{общ}}$
АНИ	$\eta = 0,11403 + 0,2719 \cdot \lg(K_{\text{ПР}} \cdot 1000) + 0,25569 \cdot (1 - S_{\text{H}}) -$ $- 0,1355 \cdot \lg(\mu_{\text{H}}) - 1,538 \cdot m - 0,00115 \cdot h$
Абасов М.Т., Султанов Л.А.	$\eta = 0,153 + 0,053 \cdot T_{\text{H}} + 0,025 \cdot \ln(K_{\text{ПР}} \cdot 100) - 0,0021 \cdot$ $\cdot (\eta_{\text{БЕЗВ}} \cdot 100 - 19,9) \cdot (T_{\text{H}} - 5,59) + 3,25 \cdot \left(\frac{1}{S_{\text{общ}}} - 0,17 \right)^2$
Абызбаев И.И., Насыров Г.Г.	$\eta = \left(\frac{20,606 + 0,3845 \cdot V_{\text{Ф}} + 65,5104 \cdot \text{tg} \alpha - 0,2712 \cdot S_{\text{общ}} +}{+ 35,678 \cdot K_{\text{П}} - 0,0306 \cdot K_{\text{ПР}}} \right) \cdot \frac{1}{100}$

Бочаров Т.Ю.	$\eta = \left(\frac{20,7 - 0,6737 \cdot \mu_H + 14,9867 \cdot \lg(K_{PP}) + 7,2 \cdot V_B - 0,3067 \cdot S_{общ} +}{+ 0,392 \cdot q + 0,1434 \cdot \eta_{БЕЗВ}} \right) \cdot \frac{1}{100}$
<p>η - коэффициент нефтеотдачи (КИН), д. ед., μ_0 - соотношение вязкостей нефти и воды, д. ед., K_{PP} - проницаемость, мкм², t_0 - пластовая температура, °С, h - эффективная нефтенасыщенная толщина, м, K_{II} - коэффициент песчанности, д. ед., W - размеры водонефтяной зоны, д. ед., S_H - нефтенасыщенность, д. ед., $S_{общ}$ - плотность сетки скважин, га/скв., V_B - объем отобранной воды в поровом объеме, д. ед.</p>	<p>V_{PP} - коэффициент вариации проницаемости, д. ед., T_H - темп отбора нефти, %, $\eta_{БЕЗВ}$ - коэффициент безводной нефтеотдачи, д. ед., V_Φ - скорость фильтрации жидкости, м/год, $tg\alpha$ - показатель процесса вытеснения, д. ед., m - пористость, д. ед., b - объемный коэффициент нефти, д. ед., μ_H - вязкость нефти, мПа·с, q - уровень максимальной годовой добычи, тыс. т.</p>

Для тестирования возможностей методов статистического расчета КИН была отобрана группа из 15 пластов пашийского горизонта различных месторождений, которые характеризуются высокой степенью выработанности запасов (более 90%) и высокой текущей обводненностью (более 90%). Добыча на рассматриваемых пластах ведется длительный период - более 30 лет. Таким образом, извлекаемые запасы, утвержденные в Государственной комиссии по запасам, можно считать как фактически достигаемыми, так и физически достоверными, подтверждаемыми промысловыми данными. Результаты расчетов КИН приведены на рисунке 1.

Таблица 2. Относительные ошибки при расчете КИН по статистическим методикам (в сравнении с фактически достигаемым значением)

Методики	Гомзиков В.К. (1976г.)	Гомзиков В.Г., Молотова Н.А.	Гомзиков В.К. (1978г.)	Кожакин С.В.	АНИ	Абасов М.Т., Султанов Л.А.	Абызбаев И.И., Насыров Г.Г.	Бочаров Т.Ю.
1	25,5	32,4	17,0	31,5	12,7	20,3	58,2	51,0
2	6,7	11,2	26,4	9,9	8,9	12,7	50,6	48,2
3	12,0	23,0	36,0	27,8	21,3	17,9	40,7	72,2
4	25,4	34,8	0,2	49,3	28,9	29,0	65,4	40,1
5	7,8	19,9	24,6	35,4	16,0	29,0	55,9	88,8
6	44,6	49,3	32,8	55,5	50,2	35,1	81,8	74,7
7	12,7	18,0	3,0	6,6	15,1	23,1	32,1	46,8
8	15,0	10,2	7,5	25,5	30,9	26,5	12,8	39,2
9	26,8	27,8	11,6	43,8	34,1	21,7	28,9	44,8
10	20,6	19,6	35,1	11,0	1,1	9,6	6,3	15,4
11	22,9	21,4	5,4	23,1	25,4	14,2	38,6	26,8
12	32,5	30,5	15,2	28,6	36,8	38,9	52,3	48,7
13	12,4	17,3	48,2	1,2	9,7	9,8	14,5	15,4
14	23,3	19,8	16,3	18,5	40,3	37,1	30,8	51,0
15	13,9	18,2	15,9	11,4	1,6	25,5	74,9	20,8
Средняя относительная ошибка, %	20,1	23,5	19,7	25,3	22,2	23,4	42,9	45,6

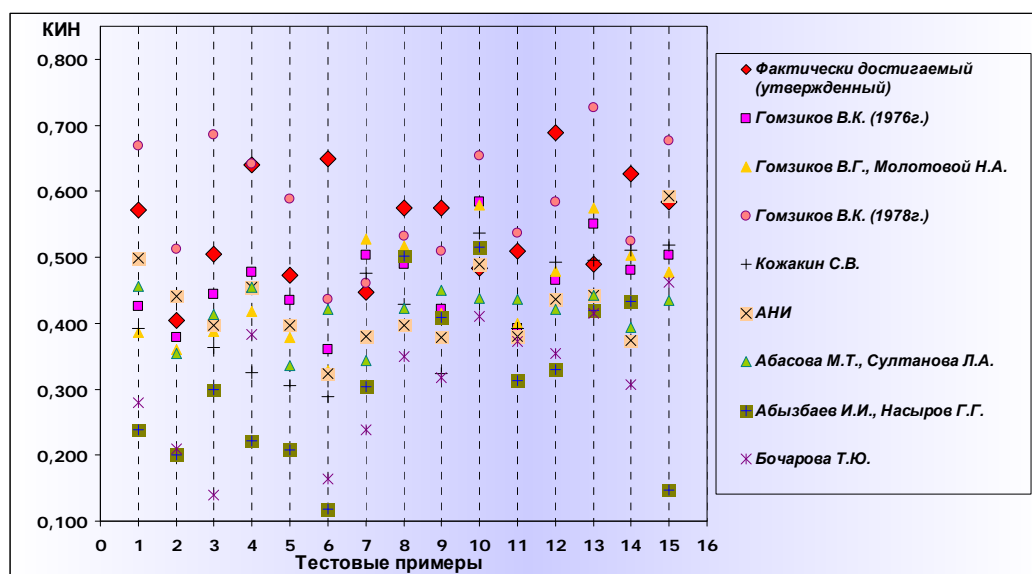


Рисунок . 1. Сопоставление результатов расчета КИН различными статистическими методами

Из данных, приведенных на рисунке 1, следует, что практически по всем статистическим методикам для терригенных коллекторов расчетный КИН ниже, чем фактически достигаемый. Видимо, фильтрация в рассматриваемых пластах происходит в более благоприятных условиях, чем предполагается для «стандартных» терригенных коллекторов. Данные по отклонению расчетов от фактических уровней приведены в таблице 2. Если рассматривать средние показатели, то наиболее достоверным является метод Гомзикова В.К. (1978 г.),

однако, для тестовых пластов № 3, 6, 10, 13 (таблица 2) полученные отклонения КИН от фактического значения достаточно критичны, показатели относительной ошибки более 30%.

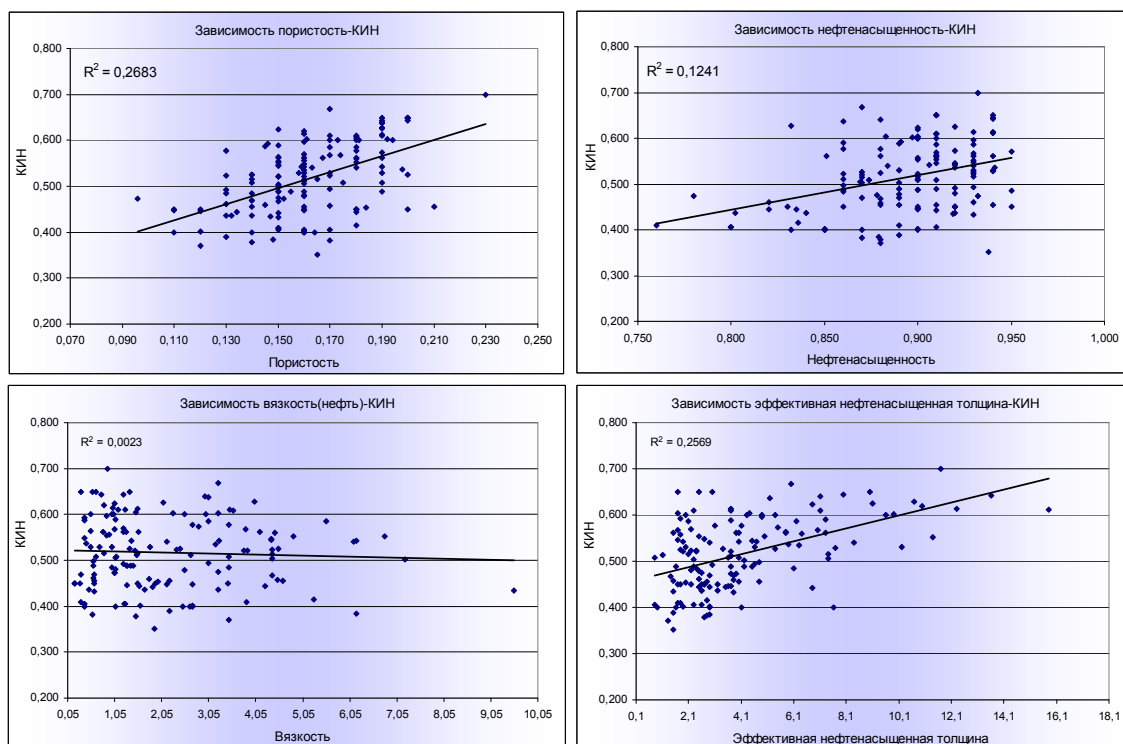


Рисунок 2. Зависимости КИН от некоторых основных геологических параметров

Если построить зависимость от КИН для каждой переменной, используемой в статистических методах, то можно видеть, что данные рассеяны в виде «облака», круглого, эллиптического или вообще неопределенной формы (рисунок 2). Прямую линию, близкую к большинству данных, в таком случае провести весьма затруднительно. Однако множественный регрессионный анализ, на котором основываются все существующие статистические методики оценки КИН, исходит из основного допущения о наличии некой линейной функциональной зависимости между исходными данными и результатом расчетов. Из рисунка 2 очевидна нелинейность функциональной зависимости КИН от приведенных факторов, следовательно, применять множественный регрессионный анализ нецелесообразно. Неадекватность регрессионной модели выражается низким коэффициентом детерминации R (менее 0,3), который характеризует величину остаточной необъясненной дисперсии, или разброс данных около линии регрессии. Данный факт объясняет низкую степень сходимости расчетного и фактически достигаемого КИН.

Так как линейной связи между КИН и геолого-физическими характеристиками пластов не существует, то для более точного расчета КИН необходимо учесть этот факт в математической модели. Для решения этой

проблемы нужно использовать метод, позволяющий идентифицировать неизвестную нелинейную функциональную зависимость при большом числе входных показателей (различных параметров нефтяных пластов). В данном случае один из возможных способов - это привлечение модели, использующей математический аппарат искусственных нейронных сетей.

Нейронная сеть – вид математической модели, которая строится по принципу организации и функционирования сетей нервных клеток (нейронов) мозга. В основе их построения лежит идея о том, что нейроны можно моделировать довольно простыми автоматами (называемыми искусственными нейронами [9]), а вся сложность мозга, гибкость его функционирования и другие важнейшие качества определяются связями между нейронами.

Поставленная задача определения конечного КИН является предикционной, для решения этого класса задач зачастую применяется классический многослойный перцептрон Розенблатта [1].

Архитектура многослойного перцептрона состоит из последовательно соединённых слоев, где нейрон каждого слоя своими входами связан со всеми нейронами предыдущего слоя, а выходами – следующего. Сигналы, поступающие на искусственный нейрон, называются «синапсами». Каждый нейрон рассчитывает нелинейное преобразование (согласно собственной функции активации) от линейной комбинации сигналов предыдущего слоя. Многослойные нейронные сети обучаются при помощи алгоритма обратного распространения ошибки, который в свою очередь является методом градиентного спуска в пространстве весов с целью минимизации суммарной ошибки сети [1].

Одним из критериев достоверности (точности) модели является среднеквадратичная ошибка. Для ее минимизации в процессе обучения нейронных сетей предусматривается выполнение процедуры кросс-проверки. Она заключается в разделении обучающего множества на два (тренировочное и тестовое множества), обучении на тренировочном множестве с проверкой способности «прогнозирования» на тестовом множестве (т.е. на данных, не участвовавших в обучении). Если ошибки, полученные при таких вычислениях (так называемые «ошибка обучения» и «ошибка прогноза»), сопоставимы по величине, то можно сделать вывод об устойчивости расчетов, выполняемых на данной модели искусственной нейронной сети (ИНС). Такая процедура может служить критерием выбора параметров нейронной сети: чем меньше разница между ошибками тренировочного и тестового множеств, тем более достоверны оценочные результаты расчетов нейронной сети.

Для синтеза модели нейронной сети должны быть определены ее параметры, а именно:

- ✓ *вход/выход модели;*
- ✓ *топология;*
- ✓ *активационная функция;*
- ✓ *способ нормировки входных параметров.*

Вход модели. Выбор входных параметров (или входного вектора) обусловлен стремлением наиболее полно охарактеризовать все значимые свойства нефтяного пласта и насыщающего его флюида. К таким свойствам были отнесены:

1. Геометрически-структурные свойства пласта. Они включают параметры, характеризующие как размеры пласта (*площадь залежи нефти, эффективную нефтенасыщенную толщину*), так и его анизотропию (неоднородность) по простиранию (*песчанистость, расчлененность*), а также параметры, описывающие емкостную (вмещающую) характеристику пласта (*пористость, нефенасыщенность*).

2. Физико-химические свойства флюидов, насыщающих пласт-коллектор (*вязкость нефти, содержание парафинов в нефти, вязкость воды*).

3. Энергетические свойства пласта (*пластовая температура, пластовое давление и давление насыщения нефти газом*).

4. Геомеханические характеристики пласта и флюидов (*коэффициенты сжимаемости породы, нефти, воды*).

5. Фильтрационные свойства пласта и дренируемой в нем жидкости (*коэффициент вытеснения*).

Существует множество предпосылок для определения отложений пашийского горизонта верхнего девона нефтяных месторождений Самарской области как коллекторов с двойной пористостью [3,4,5], когда в пласте существуют зоны или пропластки с супер-проницаемостью, в десятки и даже сотни раз превышающей проницаемость на других участках. В связи с этим будет неверно характеризовать фильтрационную проводимость коллектора только средней проницаемостью по матрице породы, то есть значениями проницаемости, стоящими на балансе и полученными в результате проведения геофизических и гидродинамических исследований скважин, анализа керна. Определение вторичной проницаемости – задача трудоемкая и требующая наличия специфических исследований. Поэтому было решено отказаться от учета на входе модели коэффициента проницаемости, как не в полной мере характеризующего фильтрационные возможности пласта-коллектора.

Выход модели. На выходе мы должны получить единственный параметр – КИН, поэтому во внешнем слое у ИНС будет один нейрон.

Топология. А.Н. Колмогоровым (1956, 1957 г.г.) и В.И. Арнольдом (1957 г.) была доказана теорема, согласно которой любая непрерывная функция от n переменных может быть представлена с помощью сложения и суперпозиций непрерывных функций одного переменного. Роль этой теоремы состоит в том, что она показывает принципиальную возможность точного представления сколь угодно сложных функциональных зависимостей с помощью конструкций из простых элементов, типа искусственных нейронов. Сравнительно недавно несколькими авторами : Хорник, Штайнкомб, Уайт (Hornick, Stinchcombe, White, 1989 г.), Кибенко (Cybenko, 1989 г.), Фунахаши (Funahashi, 1989 г.) было

доказано, что любую функцию от многих переменных вида $F(x_1, x_2, \dots, x_n)$ можно приблизить с любой заданной точностью с помощью простой трехслойной ИНС с достаточным количеством нейронов во втором (скрытом) слое и правильно подобранными синаптическими коэффициентами.

Для расчетов оптимального числа нейронов была использована известная теорема Арнольда-Колмогорова-Хехт-Нильсена [2]. Необходимое количество нейронов в скрытых слоях перцептрона можно определить по формуле, являющейся следствием данной теоремы:

$$\frac{N_y Q}{1 + \log_2(Q)} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y. \quad (1)$$

где N_y — размерность выходного сигнала; Q — число элементов множества обучающих примеров; N_w — необходимое число синаптических связей; N_x — размерность входного сигнала.

Оценив с помощью этой формулы необходимое число синаптических связей N_w , можно рассчитать необходимое число нейронов в скрытых слоях. Например, число нейронов скрытого слоя двухслойного перцептрона будет равно:

$$N = \frac{N_w}{N_x + N_y}. \quad (2)$$

Для рассматриваемого случая: при 146 обучающих примерах, 16 входных параметрах и одном выходном число синаптических связей находится в диапазоне $17,92 \leq N_w \leq 184,37$, тогда как число нейронов может изменяться в диапазоне $1,05 \leq N_w \leq 10,84$. Среднее значение составляет около 5,945, число нейронов принято равным 6.

Способ нормировки входных параметров. Поскольку все вычисления, осуществляемые методом ИНС, подразумевают определенные правила представления синаптических коэффициентов и значений активационных функций, входные значения не могут подаваться на вход ИНС в произвольном виде. Входные данные должны быть нормализованы и находиться в диапазоне 0 ... 1. Для этого может быть использован простейший способ нормировки [1], согласно которому для каждого компонента входного вектора применяется следующая формула:

$$x_i = \frac{x_i - \min x_i}{\max x_i - \min x_i}. \quad (3)$$

где $\max x_i$ и $\min x_i$ - максимальное и минимальное значения для всей обучающей выборки. Выходные векторы при обработке данных пересчитываются по этой же формуле, а затем преобразовываются в истинные значения.




Рисунок 3. Тестовая модель ИНС

Активационная функция. В качестве передаточной функции была выбрана сигмоида (гладкая монотонная нелинейная S-образная логистическая функция) как наиболее подходящая при нормализации входного вектора в диапазоне $0 \dots 1$ [1].

После определения параметров ИНС получен многослойный перцептрон с одним скрытым слоем, содержащим 6 нейронов, 16-мерным входным вектором и одномерным выходным вектором. Обучение данной сети произведено на массиве данных по 146 нефтяным пластам верхнего девона по методу обратного распространения ошибки, длительность обучения - 400 эпох.

Для получения более устойчивых результатов обучения и устранения появления возможного эффекта «переобучения» ИНС (эффект оверфиттинга) через каждые 50 эпох была заложена процедура «перемешивания» входного обучающего массива данных. Перед проведением обучения выполнялась процедура кросс-проверки для удаления из обучающего массива «нестабильных» входных примеров.

Для оценки результатов обучения были использованы следующие критерии точности расчетов на предложенной модели ИНС:

- абсолютное отклонение (погрешность) – рассчитывается как разница между действительным и расчетным значением параметра, является оценкой абсолютной ошибки измерения;
- относительная ошибка (погрешность) – погрешность измерения, выраженная отношением абсолютной погрешности расчета параметра к действительному значению данной величины;
- среднеквадратическая ошибка (RMS) – для вычисления все отдельные абсолютные ошибки возводились в квадрат, суммировались, сумма делилась на общее число абсолютных ошибок, затем из всего извлекался квадратный корень. Полученное в результате число характеризует суммарную ошибку, описанная характеристика применяется при оценке результатов обучения и тестирования ИНС.

Ошибка обучения (RMS) синтезированной ИНС составила $4,69 \cdot 10^{-2}$, средняя относительная погрешность 7,6%, максимальная абсолютная ошибка 0,134. Результаты обучения были признаны удовлетворительными, и модель ИНС испытана на тех же тестовых примерах, что и статистические методики. Оценка результатов расчетов приведена в таблице 3, цветом выделены минимальные погрешности для каждого типа при выполнении расчетов КИН по рассматриваемым распространенным статистическим методикам.

Таблица 3. Сравнение результатов расчетов по статистическим методикам и по модели ИНС с фактически достигаемыми значениями КИН

Методики	Гомзиков В.К. (1976г.)	Гомзиков В.Г., Молотовой Н.А.	Гомзиков В.К. (1978г.)	Кожакин С.В.	АНИ	Абасова М.Т., Султанова Л.А.	Абызбаев И.И., Насыров Г.Г.	Бочарова Т.Ю.	ИНС
Максимальная относительная ошибка, %	44,6	49,3	48,2	55,5	50,2	38,9	81,8	88,8	22,7
Среднеквадратическая ошибка (RMS) $\cdot 10^{-2}$, д.ед	13,6	15,2	12,5	17,7	16,0	15,0	28,0	27,7	6,9
Максимальное абсолютное отклонение, д.ед	0,289	0,320	0,236	0,360	0,325	0,268	0,531	0,485	0,110

При тестировании разработанной модели ИНС получены следующие результаты. Максимальная относительная ошибка составила 22,7%, что практически в два раза меньше, чем наилучший результат по статистическим регрессионным методикам. Характерны также наименьшие значения среднеквадратической и максимальной абсолютной ошибок: $6,9 \cdot 10^{-2}$ и 0,110 соответственно. Это доказывает, что результаты тестирования спроектированного трехслойного перцептрона наиболее близки к фактическим по всему тестовому массиву. Для ряда месторождений ОАО «Лукойл» [8] также была доказана возможность получения достоверных прогнозных оценок КИН.

Выводы

В результате тестирования существующих методик оценки конечного КИН обнаружена неточность применения статистических методов, обусловленная нелинейной зависимостью между геологическими параметрами и КИН. Точность расчетов можно повысить, используя математическую модель многослойного перцептрона.

В ходе создания модели ИНС определены оптимальные параметры сети для обучения на массиве данных по 146 нефтенасыщенным пластам верхнего девона месторождений Самарской области.

Разработанная модель ИНС показала высокую точность при тестировании на 15 различных геологических объектах ($RMS = 6,9 \cdot 10^{-2}$), полученная погрешность в два раза ниже, чем для существующих статистических методик оценки КИН.

Достоинством модели ИНС является возможность актуализации результатов расчетов, если в этом возникает необходимость, например, в случае уточнения некоторых геологических параметров по результатам дополнительных исследований или открытия новых залежей нефти (добавление данных в обучающий массив), уточнения размеров и границ нефтенасыщенного пласта в результате бурения, проведения сейсморазведочных работ и т.д. Выполнение подобных обновлений и уточнение итоговой модели ИНС будет малотрудоемкой задачей и позволит улучшать качество прогнозной оценки конечного КИН. Следовательно, существует возможность использования модели ИНС для расчета КИН при недостатке данных, что может оказаться полезным при планировании геолого-разведочных работ и программ обустройства и ввода в эксплуатацию неразработанных залежей нефти.

Работа выполнена при частичной поддержке ФГБОУ «СамГТУ» (грант получен по решению Ученого совета от 27.04.2012, №8).

Литература

1. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. Новосибирск: Наука, 1996. 276 с.
2. Ясницкий Л.Н. Искусственный интеллект. М.: БИНОМ, 2011. 240 с.
3. Булгаков С.А. Исследование пластов Пашийского горизонта вероятностно-статистическим экспресс-методом // Электронный научный журнал «Нефтегазовое дело», 2011. № 2. С. 222-231. [сайт] URL: http://www.ogbus.ru/authors/Bulgakov/Bulgakov_1.pdf (дата обращения 25.02.2013).
4. Ольховская В.А., Булгаков С.А. Диагностирование фактора трещиноватости в терригенном пласте по геологическим данным и результатам ГДИ // Нефть. Газ. Новации. 2010. № 4. С. 6-9.
5. Аширов К.Б. Геологическая обстановка формирования нефтяных и нефтегазовых месторождений Среднего Поволжья. М.: Недра, 1965. 171 с.
6. РД 39-0147035-214-86. Методическое руководство по расчету коэффициентов извлечения нефти из недр. М.: Министерство нефтяной промышленности СССР, 1986. 254 с.
7. Шавалиев А.М. Статистические исследования нефтеотдачи и водонефтяного фактора месторождений Урало-Поволжья // Нефтяное хозяйство. 1981. № 12. С. 30-32.
8. Мандрик И.Э. Научно-методические основы оптимизации технологического процесса повышения нефтеотдачи пластов: автореф. дис... докт. технических наук. М., 2008. 48 с.
9. McCulloch W., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics, 1943. 7:115. 100-133 p.

**DESIGN OF NEURAL NETWORK FOR OIL RECOVERY EVALUATION
(on the example of Samara region oilfields)**

S.A. Bulgakov
Samara state technical university
e-mail: renigm.samgtu@gmail.com

Abstract. The author proposes the method to determine the ultimate oil recovery factor using a nonlinear simulation model optimization algorithm for Samara region oilfields. The technique is based on the application of mathematical tools of neural networks. For the given input parameters the author has used the optimal parameters to validate the multilayer perceptron. He has also demonstrated that the so calculated ultimate oil recovery factor is closer to the actual value as compared to the methods based on multivariate regression analysis.

Keywords: perceptron, multivariate analysis, synapsis, topology, normalization, layer, filtration, oil recovery.

References

1. Gorban A.N., Rossiev D.A. Neyronnie seti na personalnom computere (Neural network on personal computer). Novosibirsk: Nayka, 1996. 276 p.
2. Yasnitskiy L.N. Isskustvenniy intelekt (Artificial intelligence). Moscow.: BINOM, 2011. 240 p.
3. Bulgakov S.A. Issledovanie plastov Pashiyskogo gorizonta veroyatnostno-statisticheskim express-metodom (Study of pashiysky horizon layers by statistically distributed express method) // Electronic scientific journal Neftegazovoe delo. 2011. Issue 2. pp. 222-231. [website] URL: http://www.ogbus.ru/authors/Bulgakov/Bulgakov_1.pdf (request data 25.02.2013)
4. Olkhovskaya V.A., Bulgakov S.A. Diagnostirovanie faktora treshchinovatosti v terrigenom plaste po geologicheskim dannym i rezul'tatam GDI (Use of geological data and the results of well testing for diagnosing a factor of fracturing in terrigenous formation) // Neft'. Gaz. Novatsii, 2010, Issue 4, pp. 6-9.
5. Ashirov K.B. Geologicheskay obstanovka formirovaniy neftynix i neftegazovix mestorogdeniy Srednego Povolgiy (Geological conditions of formation of oil and gas fields of the Middle Volga). M.: Nedra, 1965. 171 p.
6. RD 39-0147035-214-86. Metoditsytskoe rucovodstvo po raschetu koeffitsientov izvlecheniy is nefti iz neдр (Methodological guidance on the calculation of the coefficients of oil recovery). M.: Ministerstvo neftianoy promishlennosti USSR, 1986. 254 p.

7. Shaliev A.M. Statisticheskie issledovaniya nefteodachi I vodoneftianogo factora mestorogdeniy Uralo-Povolgia (Statistical research of oil recovery and water-oil ratio fields of the Ural-Volga region) // Neftianoe hoziaystvo, 1981. Issue 12, pp. 30-32.

8. Mandrik I.E. Nauchno-metodicheskie osnovi optimizacii texnologicheskogo processa povisheniy nefteodachi plastov (Methodological bases for process optimization of enhanced oil recovery): syn. dis. doc. technical science. M., 2008. 48 p.

9. McCulloch W., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics, 1943. 7:115. 100-133 p.

Сведения об авторе

Булгаков С. А., аспирант кафедры «Разработка и эксплуатация нефтяных и газовых месторождений», Самарский Государственный технический университет

S.A. Bulgakov, postgraduate of the department «Development and exploitation of oil and gas fields», Samara State technical university.

e-mail: posthole89@mail.ru

renigm.samgtu@gmail.com