

18. Осипов Г.С. Приобретение знаний интеллектуальными системами: Основы теории и технологии. — М.: Физматлит, 1997. — 112 с.
19. Холодная М.А. Психологические механизмы интеллектуальной одаренности // Вопросы психологии. — 1993. — № 1. — С. 32—39.
20. Холодная М.А., Кострикина И.С., Берестнева О.Г. Проблемы продуктивной реализации интеллектуального потенциала личности // Вестник Томского государственного педагогического университета. — 2002. — Вып 3 (31). — С. 45—50.
21. Quinlan J.R. Induction of Decision Trees // Machine Learning. — 198. — № 1. — P. 1—81.
22. User's Guide, WizWhy Version 2. — WizSoft Inc. — <http://www.wizsoft.com>.
23. Vtoghoff P.E. Incremental Induction of Decision Trees // Machine Learning. — 1989. — № 4. — P. 161—186.

УДК 622.692.12

## ИССЛЕДОВАНИЕ ТОЧНОСТНЫХ ХАРАКТЕРИСТИК ПРОГНОЗА ПОКАЗАТЕЛЕЙ НЕФТЕДОБЫЧИ С ИСПОЛЬЗОВАНИЕМ ЛИНЕЙНОЙ НЕЙРОННОЙ СЕТИ

Б.П. Иваненко

Институт "Кибернетический центр" ТПУ  
E-mail: boris@cc.tpu.edu.ru, ivanenko\_boris@mail.ru

*Рассматривается возможность применения линейных нейронных сетей при решении задач прогноза технологических показателей нефтедобычи. Исследуются эффективность и помехоустойчивость нейросетевых алгоритмов.*

В опубликованных ранее работах [1—4] в основном рассматривались методологические проблемы решения задач нефтепромысловой геологии с использованием нейросетевых алгоритмов. При этом выбор архитектуры сети осуществлялся исходя из принципа ее универсальности, а основные расчеты осуществлялись с использованием многослойной нейронной сети обучающейся по методу "*back propagation*" и способной решать нелинейные задачи. Однако, на наш взгляд, не следует пренебрегать и более простыми линейными нейронными сетями.

Зачастую можно встретить такую ситуацию, когда задача на первый взгляд кажущаяся сложной и нелинейной, на самом деле может быть успешно решена линейными методами. Таким примером может служить задача прогноза показателей нефтедобычи по данным ежемесячных регламентных наблюдений.

Цель работы — исследование точностных характеристик и помехоустойчивости нейросетевых методов прогноза показателей нефтедобычи с использованием линейных нейронных сетей.

На языке нейронных сетей линейная модель представляется сетью без промежуточных слоев, которая в выходном слое содержит только линейные элементы (т.е. элементы с линейной функцией активации). Веса соответствуют элементам матрицы, а пороги — компонентам вектора смещения. Во время работы сеть фактически умножает вектор входов на матрицу весов, а затем к полученному вектору прибавляет вектор смещения. Одним из наиболее распространенных методов обучения линейной нейронной сети является стандартный алгоритм линейной оптимизации, основанный на псевдообратных матрицах, а также алгоритм с адаптивной настройкой шага обучения [5, 6].

Исследования проводились с использованием методов имитационного моделирования по схеме замкнутого численного эксперимента. Известно [8, 9], что все разнообразие моделей можно условно свести к трем типам: физическая (натурная) модель, аналоговая и математическая. Примером математической модели в нашем случае могут служить системы тех или иных уравнений, описывающих процессы фильтрации жидкостей в пористых средах [7, 9]. Однако, учитывая то, что основной целью исследований являются не сами процессы фильтрации, а нейросетевые методы, можно ограничиться достаточно простой физической моделью, описывающей процессы перераспределения давления в пласте под воздействием работы системы добывающих и нагнетательных скважин, а именно на модели одномерной однофазной фильтрации жидкости.

В основе данной модели лежит широко применяемая формула Тэйса [9], согласно которой понижение давления в  $\Delta p(r, t)$  в любой момент времени  $t$  в точке пласта, расположенной на расстоянии  $r$  от возмущающей скважины определяется до и после остановки скважины в момент времени  $T$  следующими формулами:

$$\Delta p(r, t) = \frac{Q\mu}{4\pi bk} \left[ \text{Ei}\left(\frac{r^2}{4\chi t}\right) \right] \quad \text{при } t \leq T,$$

$$\Delta p(r, t) = \frac{Q\mu}{4\pi bk} \left( \text{Ei}\left(\frac{r^2}{4\chi t}\right) + \text{Ei}\left(\frac{r^2}{4\chi(t-T)}\right) \right) \quad \text{при } t > T, \quad (*)$$

где  $\text{Ei}(-x) = \int_{-x}^{\infty} \frac{e^{-u}}{u} du$  — интегральная показательная функция.

В данной формуле  $Q$  — среднесуточный дебит скважины,  $\mu$  — вязкость жидкости,  $k$  — проницаемость пласта,  $b$  — толщина пласта,  $\chi$  — коэффициент пьезопроводности.

Формула (\*) позволяет легко рассчитать поле давлений в любой точке пласта, создаваемое работающей скважиной. В свою очередь, для системы работающих в различных режимах скважин, давление в любой точке пласта может быть рассчитано как сумма полей давлений от отдельных скважин.

Данная расчетная схема была реализована на ПЭВМ. При ее численной реализации учитывался тот факт, что по результатам расчетов должна быть построена обучающая выборка, по составу совпадающая со стандартным набором параметров, содержащихся в соответствующих базах данных заполняемых в процессе разработки реальных месторождений.

Сделаем ряд замечаний относительно методов обучения нейронных сетей. Как известно, для обучения нейронной сети требуется обучающая выборка, состоящая из отдельных примеров, каждый из которых представляет собой задачу одного и того же типа с соответствующим набором входных параметров и ответом.

В нашем случае моделируемая согласно (\*) система полностью определяется координатами добывающих и нагнетательных скважин, режимами их эксплуатации, временем их работы и простоя, геологическими характеристиками пласта. Отметим,

что конкретный вид обучающей выборки зависит от типа решаемой задачи, но согласно [1–4] их можно условно разделить на два типа – вертикальные и горизонтальные (табл. 1, 2).

В табл. 1 приняты следующие обозначения:  $t_i$  ( $i=1,2, \dots, m$ ) – время отбора информации,  $m$  – количество примеров в обучающей выборке для всех скважин,  $Inj_{ij}$  ( $i=1,2, \dots, m_k, j=1,2, \dots, N_i$ ) – объемы закачки для нагнетательных скважин,  $N_i$  – количество нагнетательных скважин,  $Ti_{ij}$  ( $i=1,2, \dots, m_k, j=1,2, \dots, N_i$ ) – время работы нагнетательных скважин,  $Tr_{ij}$  ( $i=1,2, \dots, m_k, j=1,2, \dots, N_p$ ) – время работы добывающих скважин,  $N_p$  – количество добывающих скважин.

Отметим, что в общем случае в поля обучения могут быть включены данные о пластовых и забойных давлениях, глубинах погружения насосов, динамическом уровне, технологических характеристиках оборудования, геологических характеристиках пласта и т.д.

Согласно [1–4] горизонтальные выборки в основном используются при решении задач исследования интерференции скважин и разделения эффектов от проводимых геолого-технических мероприятий, а также для решения задач прогноза суммарной добычи нефти для выделенных фрагментов (ячеек) месторождения.

Таблица 1. Структура простейшей горизонтальной обучающей выборки

| Параметры обучения      |             |             |     |               |            |            |     |                     |            |            |     |                 | Параметры прогноза |
|-------------------------|-------------|-------------|-----|---------------|------------|------------|-----|---------------------|------------|------------|-----|-----------------|--------------------|
| Нагнетательные скважины |             |             |     |               |            |            |     | Добывающие скважины |            |            |     | Суммарный дебит |                    |
| $t_{1,1}$               | $Inj_{1,1}$ | $Inj_{1,2}$ | ... | $Inj_{1,N_i}$ | $Ti_{1,1}$ | $Ti_{1,2}$ | ... | $Ti_{1,N_i}$        | $Tr_{1,1}$ | $Tr_{1,2}$ | ... | $Tr_{1,N_i}$    | $S_{1,1}$          |
| $t_{2,1}$               | $Inj_{2,1}$ | $Inj_{2,2}$ | ... | $Inj_{2,N_i}$ | $Ti_{2,1}$ | $Ti_{2,2}$ | ... | $Ti_{2,N_i}$        | $Tr_{2,1}$ | $Tr_{2,2}$ | ... | $Tr_{2,N_i}$    | $S_{2,1}$          |
| ...                     | ...         | ...         | ... | ...           | ...        | ...        | ... | ...                 | ...        | ...        | ... | ...             | ...                |
| $t_{m,1}$               | $Inj_{m,1}$ | $Inj_{m,2}$ | ... | $Inj_{m,N_i}$ | $Ti_{m,1}$ | $Ti_{m,2}$ | ... | $Ti_{m,N_i}$        | $Tr_{m,1}$ | $Tr_{m,2}$ | ... | $Tr_{m,N_i}$    | $S_{m,1}$          |

Таблица 2. Структура простейшей вертикальной обучающей выборки

| Параметры обучения      |              |              |   |                |             |             |   |                     |              |          | Параметры прогноза |
|-------------------------|--------------|--------------|---|----------------|-------------|-------------|---|---------------------|--------------|----------|--------------------|
| Нагнетательные скважины |              |              |   |                |             |             |   | Добывающие скважины |              | Дебит    |                    |
| $t_{1,1}$               | $Inj_{1,1}$  | $Inj_{1,2}$  | – | $Inj_{1,N_i}$  | $Ti_{1,1}$  | $Ti_{1,2}$  | – | $Ti_{1,N_i}$        | $Tr_{1,1}$   | $X_1$    | $Q_{1,1}$          |
| $t_{2,1}$               | $Inj_{2,1}$  | $Inj_{2,2}$  | – | $Inj_{2,N_i}$  | $Ti_{2,1}$  | $Ti_{2,2}$  | – | $Ti_{2,N_i}$        | $Tr_{2,1}$   | $X_1$    | $Q_{2,1}$          |
| –                       | –            | –            | – | –              | –           | –           | – | –                   | –            |          | –                  |
| $t_{m1,1}$              | $Inj_{m1,1}$ | $Inj_{m1,2}$ | – | $Inj_{m1,N_i}$ | $Ti_{m1,1}$ | $Ti_{m1,2}$ | – | $Ti_{m1,N_i}$       | $Tr_{m1,1}$  | $X_1$    | $Q_{m1,1}$         |
| $t_{1,2}$               | $Inj_{1,1}$  | $Inj_{1,2}$  | – | $Inj_{1,N_i}$  | $Ti_{1,1}$  | $Ti_{1,2}$  | – | $Ti_{1,N_i}$        | $Tr_{1,2}$   | $X_2$    | $Q_{1,2}$          |
| $t_{2,2}$               | $Inj_{2,1}$  | $Inj_{2,2}$  | – | $Inj_{2,N_i}$  | $Ti_{2,1}$  | $Ti_{2,2}$  | – | $Ti_{2,N_i}$        | $Tr_{2,2}$   | $X_2$    | $Q_{2,2}$          |
| –                       | –            | –            | – | –              | –           | –           | – | –                   | –            |          | –                  |
| $t_{m2,2}$              | $Inj_{m1,1}$ | $Inj_{m1,2}$ | – | $Inj_{m1,N_i}$ | $Ti_{m1,1}$ | $Ti_{m1,2}$ | – | $Ti_{m1,N_i}$       | $Tr_{m1,2}$  | $X_2$    | $Q_{m1,2}$         |
| –                       | –            | –            | – | –              | –           | –           | – | –                   | –            |          | –                  |
| $t_{1,Np}$              | $Inj_{1,1}$  | $Inj_{1,2}$  | – | $Inj_{1,N_i}$  | $Ti_{1,1}$  | $Ti_{1,2}$  | – | $Ti_{1,N_i}$        | $Tr_{1,Np}$  | $X_{Np}$ | $Q_{1,Np}$         |
| $t_{2,Np}$              | $Inj_{2,1}$  | $Inj_{2,2}$  | – | $Inj_{2,N_i}$  | $Ti_{2,1}$  | $Ti_{2,2}$  | – | $Ti_{2,N_i}$        | $Tr_{2,Np}$  | $X_{Np}$ | $Q_{2,Np}$         |
| –                       | –            | –            | – | –              | –           | –           | – | –                   | –            |          | –                  |
| $t_{mk,Np}$             | $Inj_{m1,1}$ | $Inj_{m1,2}$ | – | $Inj_{m1,N_i}$ | $Ti_{m1,1}$ | $Ti_{m1,2}$ | – | $Ti_{m1,N_i}$       | $Tr_{m1,Np}$ | $X_{Np}$ | $Q_{mk,Np}$        |

Их существенный и неустранимый недостаток – количество полей обучения возрастает прямо пропорционально количеству скважин и, следовательно, область их применения ограничена исследованиями выделенных ячеек месторождения с количеством скважин порядка 30–50, в то время как число скважин в отдельных месторождениях может быть порядка нескольких сотен и даже тысяч.

Второй существенный недостаток подобных выборок – высокие требования к входной информации, т.к. наличие пробелов в данных по отдельным скважинам для различных моментов времени приводит к тому, что соответствующие строки в обучающей выборке приходится отбрасывать, либо заменять их приближенными значениями.

В свою очередь вертикальные обучающие выборки предназначены для решения задач прогноза добычи нефти по отдельным скважинам и решения задач классификации [1–4]. Они менее чувствительны к наличию пробелов в базах данных, но абсолютно не приспособлены к решению таких задач, как исследование интерференции скважин. В табл. 2 приведена структура простейшей обучающей выборки. В ней приняты следующие обозначения:  $t_i$  ( $i=1,2,\dots,m$ ) – время отбора информации  $m$  – количество примеров в обучающей выборке для всех скважин,  $Inj_{ij}$  ( $i=1,2,\dots,m_k, j=1,2,\dots,N_i$ ) – приемистости либо объемы закачки для нагнетательных скважин,  $N_i$  – количество нагнетательных скважин,  $T_{ij}$  ( $i=1,2,\dots,m_k, j=1,2,\dots,N_i$ ) – время работы нагнетательных скважин,  $Tr_{ij}$  ( $i=1,2,\dots,m_k, j=1,2,\dots,N_p$ ) – время работы добывающих скважин,  $N_p$  – количество добывающих скважин,  $Q_{ij}$  ( $i=1,2,\dots,m_k, j=1,2,\dots,N_p$ ) – дебиты добывающих скважин,  $X_i$  ( $i=1,2,\dots,N_p$ ) – координаты, либо номера добывающих скважин.

Построим простейшую горизонтальную выборку, где полями обучения нейронной сети будут: текущее время, координаты, время работы и объем закачки для нагнетательных скважин, время работы добывающих скважин и их координаты, а в качестве прогнозируемого параметра выберем суммарный среднесуточный дебит добывающих скважин, либо дебит для одной из добывающих скважин. Очевидно, что при такой постановке задачи мы сознательно ограничиваем набор входных данных (количество полей обучения). Более того, и при выборе периода обучения сети, мы также ограничивали период обучения до 2,5...3 лет.

Причиной этого служит тот факт, что в реальной ситуации в процессе разработки нефтяного пласта его коллекторские свойства могут изменяться в весьма значительной степени. Следовательно, выбрав большой временной период обучения, мы столкнемся с тем фактом, что примеры, содержащиеся в обучающей выборке, не будут однородными по содержанию.

Иными словами, обучив нейронную сеть и сведя ошибки обучения к минимуму, мы, тем не менее, не сможем гарантировать того, что ошибки обобщения на период прогноза будут небольшими. Таким обра-

зом, время обучения сети надо выбирать оптимальным образом. Согласно [10] этот период не должен превышать 2,5...3 года. Именно поэтому при расчетах обучающих выборок с использованием соотношений (\*) выбирался четырехлетний расчетный период, а именно 3 года для обучения и 1 год для прогноза.

Рассмотрим схему проведения замкнутого численного эксперимента, предназначенного для исследования эффективности нейросетевых методов прогноза показателей нефтедобычи. Согласно общепринятой методике [1–4, 7–8] она состоит из нескольких этапов, а именно:

1. Задаются схема расположения скважин, время разработки и параметры пласта, характеристики скважин.
2. На основе соотношений (1) строится горизонтальная обучающая выборка (в данном конкретном случае 36 примеров для обучения и 12 для прогноза).
3. Моделируется погрешность эксперимента. При этом в соответствующие поля обучающей выборки в период обучения вносится заданная случайная относительная погрешность определенного уровня.
4. Строится нейронная сеть определенной архитектуры (в данном случае линейная) на ее вход подаются зашумленные данные, и проводится ее обучение.
5. На вход обученной нейронной сети подаются данные за весь исследуемый период (обучение-прогноз) и на выходе получаем искомое решение.
6. Рассчитываются ошибки обучения и прогноза.

Обратимся к полученным результатам, но прежде отметим, что оценка точности обучения и прогноза рассчитывалась для четырех уровней вносимой относительной погрешности, которые задавали следующим образом 0, 10, 20, 30 % для дебитов и приемистостей и, соответственно, 0, 2, 4, 6 % для времени работы скважин.

Цель данных расчетов – оценить помехоустойчивость линейной сети в зависимости от уровня вносимой погрешности и количества добывающих скважин.

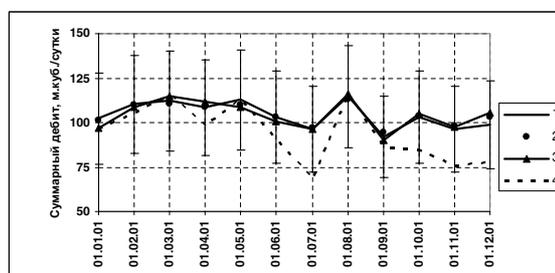
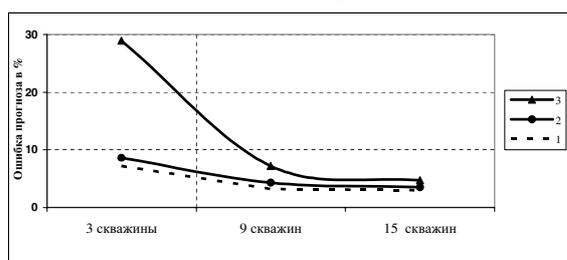


Рис. 1. Прогноз суммарного дебита для системы из 2-х нагнетательных и 3-х добывающих скважин. Доверительный интервал 25 %. Расстояние между скважинами 400 м. Горизонтальные выборки: 1) точные значения суммарного дебита, 2, 3, 4) прогнозные значения, полученные при 10, 20, 30 % уровне вносимых погрешностей

В качестве примера на рис. 1 приведем результаты прогноза суммарного дебита. Здесь и далее расчеты проводились для следующей схемы расположения скважин: в ряду скважин между двумя нагнетательными скважинами расположены три добывающих. При проведении расчетов изменялось лишь количество скважин, расстояние между ними и характеристики пласта.

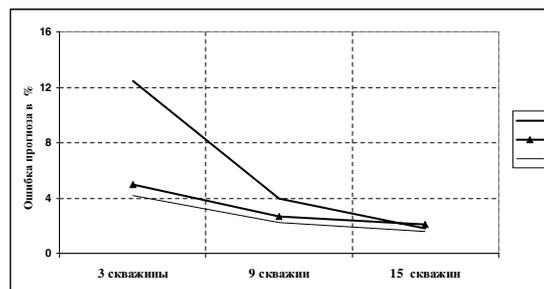
Анализируя представленные на рис. 1 графики легко заметить что для данной системы ошибки прогноза суммарного дебита не превышают 30 %. В свою очередь, аналогичные расчеты показали, что для системы состоящей из 4 нагнетательных и 9 добывающих скважин ошибки прогноза уже не превышают 10 %. Более детальное рассмотрение позволяет заметить, что для горизонтальной обучающей выборки увеличение количества добывающих скважин приводит к уменьшению ошибок прогноза суммарного дебита. Этот эффект можно оценить количественно. С этой целью рассчитывались максимальные и средние оценки погрешностей прогноза для различных уровней вносимых погрешностей и количества скважин в исследуемых системах.

Соответствующие оценки погрешностей прогноза в зависимости от числа скважин и уровней вносимых погрешностей представлены на рис. 2 и рис. 3. Приведенные на них зависимости хорошо иллюстрируют эффект уменьшения ошибок прогноза суммарного дебита при увеличении количества полей обучающей выборки и позволяют количественно оценить среднюю и максимальную ошибку прогноза в зависимости от уровня вносимых погрешностей и количества добывающих скважин. Отметим, что, как показали детальные расчеты, дальнейшее увеличение числа скважин не приводит к уменьшению ошибок прогноза.



**Рис. 2.** Оценка максимальных погрешностей прогноза суммарного дебита в зависимости от уровня вносимых погрешностей и количества скважин. Горизонтальные выборки: 1, 2, 3) погрешность прогноза при 10, 20, 30 % уровне вносимых погрешностей

Перейдем далее к исследованию точностных характеристик нейровычислений с использованием линейной сети и вертикальных обучающих выборок. С этой целью поступим следующим образом: построим вертикальные выборки, используя уже полученные ранее расчетные данные. Такой прием позволит нам легче сопоставить результаты моделирования для этих двух типов обучающих выборок и сделать соответствующие выводы и рекомендации.



**Рис. 3.** Оценка средних погрешностей прогноза суммарного дебита в зависимости от уровня вносимых погрешностей и количества скважин. Горизонтальные выборки: 1, 2, 3) погрешность прогноза при 10, 20, 30 % уровне вносимых погрешностей

Однако если ранее прогнозируемым параметром являлась суммарная добыча, то в данном случае эту характеристику можно определить лишь как результат суммирования результатов прогноза для отдельных скважин и соответствующие оценки нужно строить для каждой отдельно взятой скважины. Поэтому при построении оценок качества прогноза и обучения мы остановились на следующем варианте.

Максимальные оценки обучения и прогноза выбираются из всей совокупности прогнозных данных, т.е. результатов обучения и прогноза по всем скважинам. Аналогично можно рассчитать и средние ошибки обучения и прогноза. Эти характеристики были рассчитаны для ранее используемых систем. В отличие от результатов прогноза суммарного дебита получаемого с использованием горизонтальной обучающей выборки здесь в явной форме не наблюдается эффект уменьшения ошибок обучения и прогноза в зависимости от числа скважин. Однако при последующем расчете суммарных дебитов на основе данных прогноза по отдельным скважинам эффект уменьшения ошибок прогноза наблюдается, но причина его появления скрыта в регуляризирующих свойствах нейросетевых алгоритмов.

Рассмотрим представленные в табл. 3 данные. Легко видеть, что в данном случае максимальные ошибки обучения для отдельных скважин могут превышать уровень вносимых погрешностей. При этом характер зависимости ошибок обучения и прогноза перестает монотонно зависеть от количества скважин, а скорее определяется уровнем вносимых погрешностей. Но, тем не менее, как и в случае применения горизонтальных выборок можно сказать, что максимальная ошибка прогноза суммарного дебита не превышает погрешностей определения полей обучающей выборки (приемистостей, дебитов) и убывает с увеличением числа исследуемых скважин,

Таким образом, на основании результатов численного моделирования можно сделать следующие выводы:

**Таблица 3.** Вертикальные выборки. Зависимость средних и максимальных ошибок прогноза суммарного дебита в зависимости от числа добывающих скважин при различном уровне вносимых погрешностей

| Погрешность в %              | Количество скважин |      |      |      |     |      |      |      |     |      |      |      |
|------------------------------|--------------------|------|------|------|-----|------|------|------|-----|------|------|------|
|                              | 3                  |      |      |      | 9   |      |      |      | 15  |      |      |      |
| Вносимая                     | 0                  | 10   | 20   | 30   | 0   | 10   | 20   | 30   | 0   | 10   | 20   | 30   |
| Максимальная ошибка обучения | 2,5                | 13,3 | 35,8 | 37,9 | 2,8 | 13,4 | 26,9 | 35,9 | 4,8 | 12,4 | 24,6 | 48,9 |
| Средняя ошибка обучения      | 1,1                | 5,6  | 12,0 | 15,4 | 1,0 | 4,7  | 9,4  | 18,8 | 1,4 | 4,2  | 6,8  | 13,3 |
| Максимальная ошибка прогноза | 2,2                | 2,5  | 13,9 | 12,1 | 2,2 | 7,2  | 5,0  | 4,6  | 3,3 | 2,5  | 3,5  | 7,5  |
| Средняя ошибка прогноза      | 0,9                | 1,3  | 8,8  | 3,3  | 1,1 | 2,6  | 3,3  | 2,2  | 1,7 | 1,7  | 1,9  | 3,3  |

1. Линейные нейронные сети при минимальном наборе параметров обучения позволяют эффективно решать задачи прогноза суммарного дебита для выделенных фрагментов (ячеек) нефтяного месторождения.
2. Использование как горизонтальных, так и вертикальных обучающих выборок позволяет за
3. счет увеличения количества полей обучения (количества исследуемых скважин) минимизировать ошибки прогноза.
3. Максимальная ошибка прогноза суммарного дебита не превышает погрешностей определения полей обучающей выборки и убывает с увеличением числа исследуемых скважин.

#### СПИСОК ЛИТЕРАТУРЫ

1. Иваненко Б.П., Проказов С.А. Нейросетевые методы имитационного моделирования процессов нефтедобычи // Нейрокомпьютеры: разработка и применение. — 2003. — № 7. — С. 43—49.
2. Иваненко Б.П., Муслимов Э.Я., Парфенов А.Н. Применение нейронных сетей для имитационного моделирования систем взаимодействующих нефтяных скважин // Химия нефти и газа: Сб. трудов IV Междунар. конф. — Томск, 2000. — Т. 2. — С. 112—117.
3. Ivanenko B.P Application of neural network technology for modeling well operation and fluid filtration processes in oil reservoir // The Third Russian-Korean International Symposium on Science and Technology, KORUS'99, Abstracts, June 22—25 at Novosibirsk State Technical University. — Novosibirsk, Russia, 1999. — Vol. 2. — P. 297—299.
4. Иваненко Б.П. Оценка интерференции скважин нейросетевыми методами // Нейроинформатика и ее приложения: Тез. докл. 10 Всеросс. семина. — Красноярск, 2002. — С. 58—61.
5. Golovko V., Savitsky Ju., Gladyschuk V. Predicting Neural Net // Proc. Int. Conf. CM NDT-D5. — Berlin, 1995. — P. 348—353.
6. Нейронные сети. Statistica Neural Networks. — М.: Горячая линия-Телеком, 2000. — 182 с.
7. Булыгин В.Я., Булыгин Д.В. Имитация разработки залежей нефти. — М.: Недра, 1990. — 224 с.
8. Марчук Г.И. Методы вычислительной математики. — М.: Наука, 1977. — 456 с.
9. Справочник по нефтепромысловой геологии // Под ред. Н.Е. Быкова и др. — М.: Недра, 1981. — 525 с.
10. Ковалев В.С., Житомирский В.М. Прогноз разработки нефтяных месторождений и эффективность систем заводнения. — М.: Недра, 1976. — 247 с.