

УДК 681.518:622.32

И. Ф. НУГАЕВ

ПРИМЕНЕНИЕ РАДИАЛЬНО-БАЗИСНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ МОДЕЛИРОВАНИЯ ПРОЦЕССОВ ФОРМИРОВАНИЯ ТРАЕКТОРИЙ НЕФТЕГАЗОВЫХ СКВАЖИН

Рассматривается проблема моделирования траекторий бурящихся нефтегазовых скважин для решения задач оперативного управления бурением. Показана возможность построения эффективных нелинейных динамических моделей движения бурового инструмента на основе нейросетевых технологий. Представлен оптимальный подход к идентификации структуры и параметров данных моделей на базе двух RBF-нейросетей. Приведен подход к решению задачи сглаживания и восстановления исходных данных с помощью вспомогательных RBF-нейросетей, регуляризируемых на основе предложенного критерия. Рассмотрен пример идентификации нейросетевой модели движения бурового инструмента. *Бурение нефтегазовых скважин; управление траекторией скважины; нейросетевая модель движения бурового инструмента; сглаживание и восстановление данных на базе RBF-нейросети*

К числу основных задач современных АСУ процессом бурения нефтегазовых скважин относятся прогнозирование траектории ствола бурящейся скважины и принятие оперативных решений по ее коррекции [1, 2, 4]. Эффективность решения данных задач во многом определяется качеством применяемых моделей движения бурового инструмента.

Известны способы построения моделей движения бурового инструмента на основе кинематического подхода, отражающего основные физические закономерности данного процесса [1, 2]. Однако действие на объект множества случайных возмущающих воздействий геологического и технологического характера делает затруднительным применение моделей данного типа.

Одним из направлений решения задачи повышения точности прогноза и управления является применение статистических подходов, основанных на идентификации динамической модели движения бурового инструмента по оперативным данным, отражающим весь спектр действующих на объект факторов. Известны практические результаты решения данного типа задач на основе нейросетевых технологий [3].

В данной статье представлен подход к решению задачи идентификации нелинейной динамической модели движения бурового ин-

струмента на основе статистического подхода и радиально-базисных нейронных сетей.

1. ПОСТАНОВКА ЗАДАЧИ

1.1. Обобщенная модель движения бурового инструмента

Пространственное положение точки траектории скважины определяется следующим множеством координат (рис. 1):

- прямоугольные координаты (x, y, z) ;
- цилиндрические координаты:

θ — зенитный угол, угол между касательной к траектории в данной точке траектории и вертикалью;

α — азимутальный угол, угол между горизонтальной проекцией касательной к траектории в данной точке и направлением на магнитный Север.

Для описания всей траектории применяется множество параметрических зависимостей вида:

$$X(l) = (\theta(l), \alpha(l), x(l), y(l), z(l)), l \in [l_0, l_k], \quad (1)$$

здесь X — вектор координат пространственного положения точки траектории скважины;

l — длина траектории скважины (параметр).

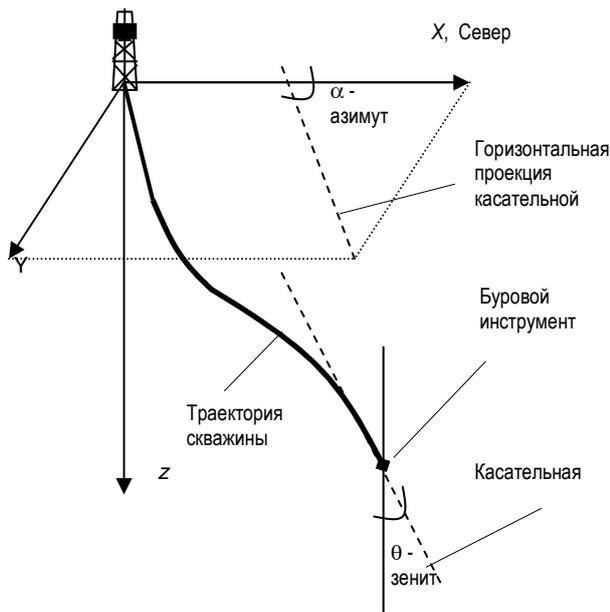


Рис. 1. Координаты траектории скважины

Математическая модель движения бурового инструмента должна описывать траекторию скважины в форме (1) в условиях действия управляющих (U) и возмущающих (V) воздействий (рис. 2).

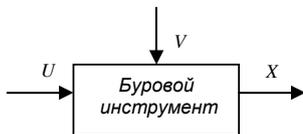


Рис. 2. Буровой инструмент как объект управления

Управляющие воздействия (U) представляют собой множество технологических параметров: осевое давление на долото, структура и геометрические параметры компоновки низа бурильной колонны и др. Возмущающие воздействия (V) представляют собой множество геологических параметров разбуриваемой породы: углы наклона геологических пластов по зениту и азимуту, коэффициент анизотропии породы и др.

Учитывая то, что прямоугольные координаты связаны с цилиндрическими известными соотношениями:

$$\begin{aligned} \frac{dx}{dl} &= \sin \theta \cdot \cos \alpha; \\ \frac{dy}{dl} &= \sin \theta \cdot \sin \alpha; \\ \frac{dz}{dl} &= \cos \theta, \end{aligned} \quad (2)$$

обобщенная математическая модель движения бурового инструмента может быть выражена уравнениями относительно цилиндрических координат:

$$\begin{aligned} \frac{d^n \theta}{dl^n} &= f_\theta(\theta, \dots, \frac{d^{n1} \theta}{dl^{n1}}, \alpha, \dots, \frac{d^{n2} \alpha}{dl^{n2}}, U, V); \\ \frac{d^m \alpha}{dl^m} &= f_\alpha(\theta, \dots, \frac{d^{m1} \theta}{dl^{m1}}, \alpha, \dots, \frac{d^{m2} \alpha}{dl^{m2}}, U, V); \end{aligned} \quad (3)$$

$(n1, n2 < n; m1, m2 < m)$

Особенностью бурового инструмента как объекта управления является его многорежимность, связанная с применением буровых инструментов с различными структурами [4]. Каждому режиму соответствует своя структура модели (3) и вектор управляющих воздействий U .

Различают два класса режимов:

1) ориентируемые режимы (ориентируемый тип бурового инструмента), в рамках которых применяется регулирующий принцип управления $U = var$; для данных режимов идентификация модели (3) на основе статистического подхода целесообразна в форме разностных уравнений (управляющая форма модели):

$$\begin{aligned} \theta_{i+1} &= f_\theta(\theta_i, \dots, \theta_{i-n1}, \alpha_i, \dots, \alpha_{i-n2}, U_i); \\ \alpha_{i+1} &= f_\alpha(\theta_i, \dots, \theta_{i-m1}, \alpha_i, \dots, \alpha_{i-m2}, U_i). \end{aligned} \quad (4)$$

2) неориентируемые режимы (неориентируемый тип бурового инструмента), в рамках которых применяется позиционный принцип управления $U = const$; данные режимы отличаются отсутствием статистической информации о зависимости координат от управляющих воздействий $U = const$, в данном случае идентификация возможна в ограниченной форме (прогнозирующая форма модели):

$$\begin{aligned} \theta_{i+1} &= f_\theta(\theta_i, \dots, \theta_{i-n1}, \alpha_i, \dots, \alpha_{i-n2}); \\ \alpha_{i+1} &= f_\alpha(\theta_i, \dots, \theta_{i-m1}, \alpha_i, \dots, \alpha_{i-m2}). \end{aligned} \quad (5)$$

1.2. Постановка задачи идентификации

Исходные данные:

- таблица измеренных цилиндрических координат (инклинометрия):

а) ориентируемый режим: $l_i, \theta_i, \alpha_i, U_i, i = \overline{1, N}$,

б) неориентируемый режим: $l_i, \theta_i, \alpha_i, U = const, i = \overline{1, N}$,

где N – число точек измерений.

Требуется:

- идентифицировать модель движения бурового инструмента:

а) для ориентируемых режимов — в форме управляющей модели (4);

б) для неориентируемых режимов — в форме прогнозирующей модели (5);

включая:

а) структурную идентификацию:

- структуры аргументов функций правых частей (n_1, n_2, m_1, m_2);

- класс функций правых частей (f_θ, f_α);

б) параметрическую идентификацию: параметры функций (f_θ, f_α).

2. ПОСТРОЕНИЕ МОДЕЛИ НА ОСНОВЕ RBF-НЕЙРОСЕТЕЙ

2.1. Обобщенная структура и параметры нейросетевой модели

Для формирования нейросетевой модели движения бурового инструмента выбран класс радиально-базисных нейросетей (RBF-нейросети). Обобщенная структура модели на базе двух RBF-нейросетей, отражающих уравнения систем (4) и (5), показана на рис. 3. Управляющая и прогнозирующая формы модели отличаются соответственно наличием или отсутствием входа управления (U_{i-1}). В качестве нейросетей, входящих в модель, приняты двухслойные RBF-нейросети с количеством нейронов скрытого слоя, равным числу обучающих пар; функции активации нейронов скрытого слоя — Гауссовы; функции нейронов выходного слоя — линейные.

Структура нейросетевой модели (рис. 3) полностью определяется структурой входов RBF-нейросетей, соответствующих структуре аргументов (n_1, n_2, m_1, m_2) функций правых частей разностных уравнений (4–5).

Параметрами, определяющими настройку нейросетевой модели для заданной обучающей выборки, являются наклоны (расширения) функций Гаусса RBF-нейросетей ($\sigma_{RBF\theta}, \sigma_{RBF\alpha}$).

2.2. Задача идентификации нейросетевой модели

Под задачей идентификации нейросетевой модели (рис. 3) понимается выбор ее структуры (n_1, n_2, m_1, m_2) и параметров ($\sigma_{RBF\theta}, \sigma_{RBF\alpha}$), обеспечивающих оптимальное значение показателя ее эффективности (J):

$$J \xrightarrow{n_1, n_2, m_1, m_2, \sigma_\theta, \sigma_\alpha} \min. \quad (6)$$

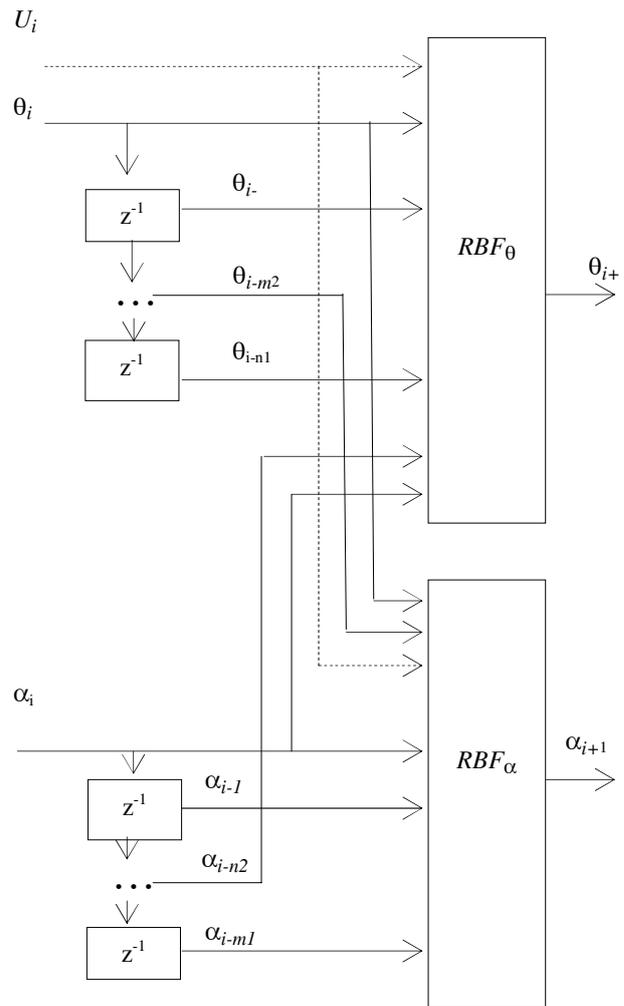


Рис. 3. Обобщенная структура нейросетевой модели движения бурового инструмента

Для оценки эффективности модели исходный интервал измеренных данных ($L_{И}$) разбивается на интервалы обучения ($L_{О}$) и контроля ($L_{К}$). Данные интервала обучения применяются для обучения нейросетей модели, а данные интервала контроля для оценки ее эффективности:

$$L_{И} = L_{О} \cap L_{К}, \quad L_{О} \in [l_0, l_1], \quad L_{К} \in [l_1, l_2]. \quad (7)$$

В качестве критерия эффективности модели применен аддитивный критерий точности прогноза, состоящий из среднеквадратических отклонений прогнозируемых координат

нат от измеренных на интервале контроля:

$$J = J_\theta + J_\alpha;$$

$$J_\theta = \sqrt{\frac{1}{|L_k|} \int_{l_1}^{l_2} (\theta_{И}(l) - \theta_{П}(l))^2 dl};$$

$$J_\alpha = \sqrt{\frac{1}{|L_k|} \int_{l_1}^{l_2} (\alpha_{И}(l) - \alpha_{П}(l))^2 dl},$$
(8)

где J_θ, J_α – погрешность прогноза соответственно зенитного и азимутального углов;

$\theta_{И}(l), \theta_{П}(l); \alpha_{И}(l), \alpha_{П}(l)$ – соответственно измеренные и прогнозируемые координаты на интервале контроля.

3. ПОДГОТОВКА ОБУЧАЮЩЕЙ ВЫБОРКИ

3.1. Сглаживание и восстановление исходных данных

Обучающая выборка для нейросетевой модели строится на основе таблицы измеренных данных $(l_i, \theta_i, \alpha_i, U_i, i = \overline{1, N})$, которые характеризуются наличием измерительных шумов и неравномерностью замеров по длине скважины (шаг по длине скважины между соседними измерениями колеблется от 1 до 50 м). Это обуславливает необходимость предварительной обработки данных, включая их сглаживание и восстановление.

Для решения указанных задач предлагается сглаживающая аппроксимация измеренных данных (инклинометрии) функциями по длине скважины:

$$\theta \approx \theta_{RBF}(l), \alpha \approx \alpha_{RBF}(l), l \in [l_1, l_n] \quad (9)$$

на базе вспомогательных сглаживающих RBF-нейросетей (рис. 4).

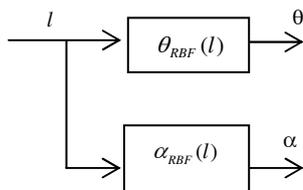


Рис. 4. Сглаживающие RBF-нейросети

Для обеспечения оптимального сглаживания применена регуляризация сглаживающих RBF-нейросетей путем минимизации

критериев:

$$E_\theta \xrightarrow{\sigma_\theta} \min;$$

$$E_\alpha \xrightarrow{\sigma_\alpha} \min;$$

$$E_\theta = E_{\theta_O} + E_{\theta_P};$$

$$E_\alpha = E_{\alpha_O} + E_{\alpha_P},$$
(10)

где $E_{\theta_O}, E_{\alpha_O}$ – ошибки обучения;

$E_{\theta_P}, E_{\alpha_P}$ – степени сглаженности, равные максимумам модулей скорости изменения аппроксимирующей функции на интервале сглаживания:

$$E_{\theta_P} = \max \left| \frac{\theta_{RBF}(l_i) - \theta_{RBF}(l_{i-1})}{l_i - l_{i-1}} \right|;$$

$$E_{\alpha_P} = \max \left| \frac{\alpha_{RBF}(l_i) - \alpha_{RBF}(l_{i-1})}{l_i - l_{i-1}} \right|; i = \overline{1, N},$$
(11)

где $\sigma_\theta, \sigma_\alpha$ – регуляризирующие параметры, в качестве которых выступают наклоны (ширина) радиально-базисных функций соответствующих сглаживающих RBF-нейросетей (рис. 4).

Пример влияния параметра σ_θ на форму аппроксимирующей функции показан на рис. 5, где непрерывными линиями показаны сглаживающие кривые, а точками – измеренные данные.

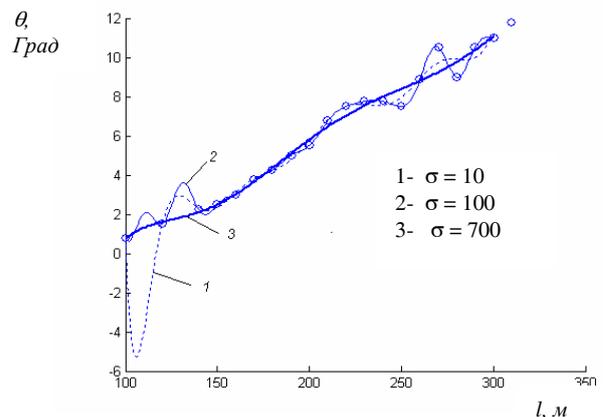


Рис. 5. Сглаживание при различных значениях наклона радиально-базисных функций σ

Сглаживающие функции (9) являются по существу трендовыми моделями рядов $\theta_i, \alpha_i, i = \overline{1, N}$, отражающими их систематические составляющие. Правильность (адекватность) выбора функций (9) может быть оценена известными статистическими методами, например, по степени случайности остаточных последовательностей:

Таблица

№	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
$l, \text{ м}$	100	120	140	150	160	170	180	190	200	210	220	230	240	250	260	270	280	290
$\theta, \text{ град}$	0,75	1,5	2,25	2,5	3	3,75	4,25	5,5	6,75	7,5	7,75	7,75	7,5	8,85	10,5	9	10,5	11
$\alpha, \text{ град}$	350	300	280	305	305	305	310	320	330	340	330	320	310	300	293	288	287	287

- случайность колебаний уровней остаточной последовательности;
- соответствие распределения случайной компоненты нормальному закону распределения;
- равенство математического ожидания случайной компоненты нулю;
- независимость значений уровней случайной компоненты.

3.2. Построение обучающей выборки

Следующим шагом подготовки данных является построение обучающих выборок для RBF-нейросетей модели (см. рис. 3) на основе сглаживающих функций (9):

- разбиение области идентификации (L) на интервал обучения (L_O) и контроля (L_K):

$$L_{\text{И}} = L_O \cap L_K; |L_O| \leq |0,5L|;$$

дискретизация сглаженных данных на интервале обучения:

$$l_i, \theta_i, \alpha_i, U_i, i = \overline{1, k}; \quad k = \frac{|L_O|}{\Delta l}; \Delta l = l_i - l_{i-1};$$

построение обучающих выборок для RBF-нейросетей модели на основе дискретизированных данных:

$$\begin{aligned} & \{(\theta_{RBF}(l_j); \theta_{RBF}(l_j - \Delta l), \dots, \theta_{RBF}(l_j - n1\Delta l), \\ & \alpha_{RBF}(l_j - \Delta l), \dots, \alpha_{RBF}(l_j - n2\Delta l), U(l_j))\}; \\ & \{\alpha_{RBF}(l_j); \alpha_{RBF}(l_j - \Delta l), \dots, \alpha_{RBF}(l_j - m1\Delta l), \\ & \theta_{RBF}(l_j - \Delta l), \dots, \theta_{RBF}(l_j - m2\Delta l), U(l_j)\}; \\ & j = \overline{\max(n1, n2, m1, m2), k}, \end{aligned}$$

где $U(l)$ — известная функция управления.

Шаг дискретизации Δl , с точки зрения идентифицируемых разностных уравнений (4–5), является приращением аргумента при численном дифференцировании:

$$\frac{d\theta}{dl} \Big|_{l_i} \approx \frac{\theta_i - \theta_{i-1}}{\Delta l_i}; \quad \frac{d\alpha}{dl} \Big|_{l_i} \approx \frac{\alpha_i - \alpha_{i-1}}{\Delta l_i} \quad (12)$$

и определяет точность модели. Требованиям к эффективному значению Δl можно считать следующее: шаг дискретизации аргумента (Δl) должен быть достаточно малым, чтобы в рамках соответствующего ему интервала

$[l_i, l_{i-1}]$, значения производных можно было считать постоянными с допустимой степенью точности:

$$\dot{\theta}(l) \approx \text{const}, \dot{\alpha}(l) \approx \text{const}, l \in [l_{i-1}, l_i].$$

Анализ реальных траекторий скважин показывает, что с высокой степенью точности в качестве интервала дискретизации можно считать величину 1... 5 м длины траектории.

4. ПРИМЕР ИДЕНТИФИКАЦИИ НЕЙРОСЕТЕВОЙ МОДЕЛИ

Дано: данные инклинометрии, представляющие собой таблицу измерения угловых координат на участке бурения с неизменным технологическим режимом ($U = \text{const}$) (таблица).

Требуется: идентифицировать модель движения бурового инструмента в форме прогнозирующей модели (5).

Решение:

1) сглаживание и восстановление данных:

- структура сглаживающих RBF-нейросетей соответствует рис. 2;
- число нейронов внутренних слоев равно числу исходных точек — 18;
- регуляризация сглаживающих RBF-нейросети в соответствии с критериями (10) путем выбора оптимальных наклонов (расширений) радиально-базисных функции: $E_\theta = 0,08$; $E_\alpha = 3,2$.

Результаты сглаживающей аппроксимации инклинометрических данных показаны на рис. 6.

2) формирование обучающего множества:

- интервал идентификации (L) — 140 м;
- интервал обучения (L_O) — 70 м;
- интервал контроля (L_K) — 70 м;
- интервал дискретизации (Δl) — 5 м.

Интервалы и данные показаны на рис. 7.

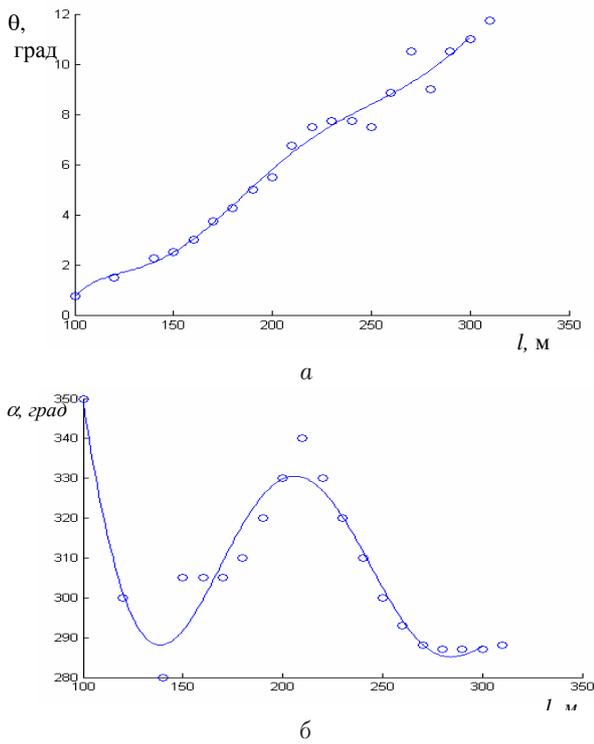


Рис. 6. Сглаживание измеренных данных на базе вспомогательных RBF-нейросетей (o — измеренные точки, — — сглаживающая кривая)

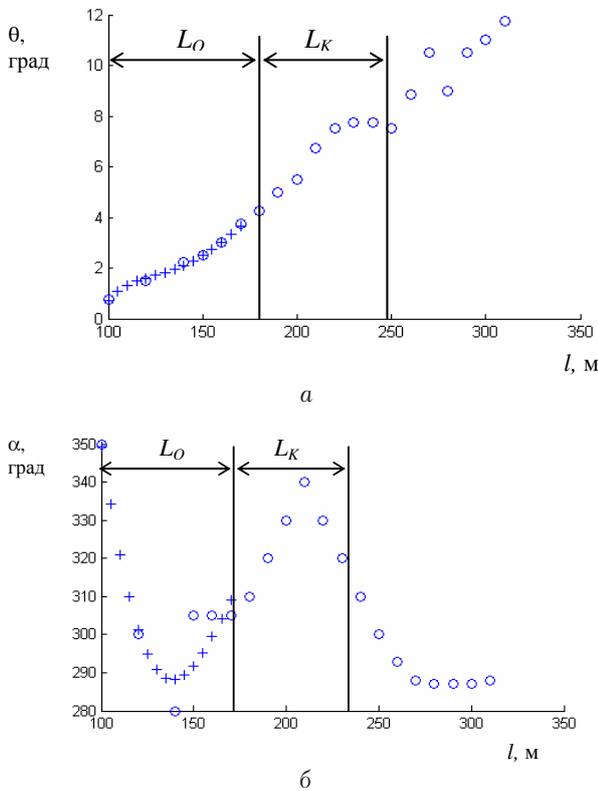


Рис. 7. Интервалы данных (+ — дискретизированные сглаженные данные, o — измеренные данные)

3) идентификация прогнозирующей модели в соответствии с постановкой задачи (5). Полученная оптимальная структура модели показана на рис. 8.

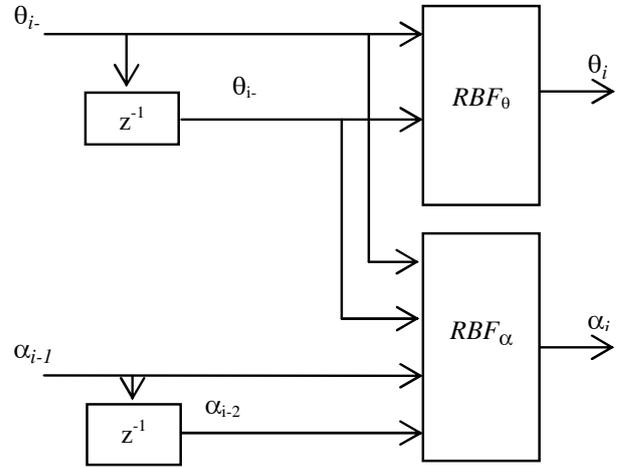


Рис. 8. Структура прогнозирующей модели

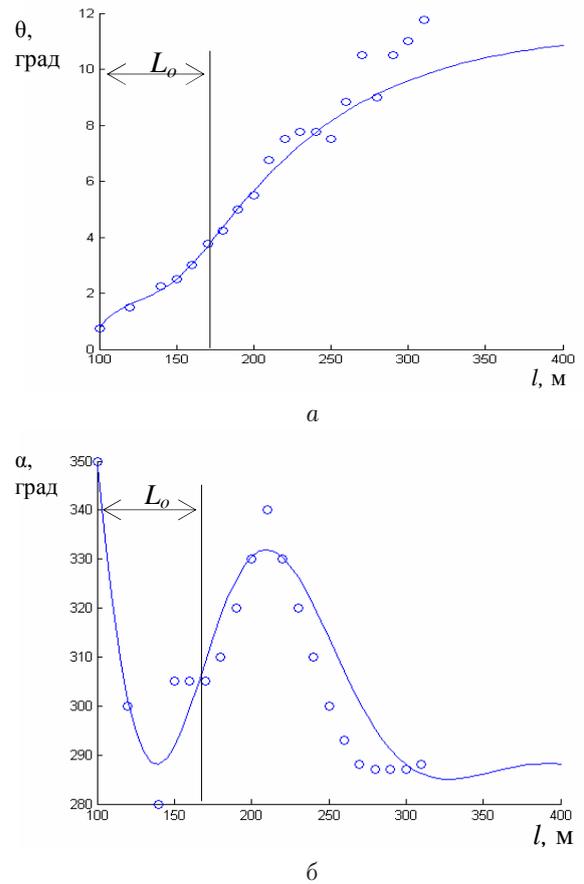


Рис. 9. Пример прогноза траекторий (L_o — интервал обучения, сплошная линия — прогнозируемые траектории, o — измеренные точки)

Получена следующая структура аргументов прогнозирующей модели (5), соответ-

ствующая нейросетевой модели:

$$\begin{aligned}\theta_i &= f_\theta(\theta_{i-1}, \theta_{i-2}); \\ \alpha_i &= f_\beta(\theta_{i-1}, \theta_{i-2}, \alpha_{i-1}, \alpha_{i-2}); \\ n1 &= 2, n2 = 0, m1 = 2, m2 = 2.\end{aligned}$$

На рис. 9 показан пример прогноза траекторий угловых координат на основе полуконной нейросетевой прогнозирующей модели [5, 6].

Полученные результаты вычислительных экспериментов показали перспективность применения нейросетевых моделей движения бурового инструмента для повышения точности решения задач прогнозирования и управления траекториями нефтегазовых скважин по сравнению с существующими кинематическими подходами.

ЗАКЛЮЧЕНИЕ

В результате проведенных исследований показана возможность построения эффективных динамических моделей движения бурового инструмента для оперативного управления бурением на основе нейросетевых технологий.

Получены следующие результаты:

- разработан и исследован оптимальный подход к идентификации структуры и параметров нейросетевой модели движения бурового инструмента на базе двух RBF-нейросетей;
- разработан подход к решению задачи сглаживания и восстановления исходных данных с помощью вспомогательных RBF-нейросетей, регуляризируемых на основе предложенного критерия;
- проведены экспериментальные исследования эффективности нейросетевых моделей для прогноза траекторий бурящихся нефтяных скважин, в результате которых сделан вывод о возможности значительного повыше-

ния точности прогноза по сравнению с традиционными кинематическими подходами построения моделей.

СПИСОК ЛИТЕРАТУРЫ

1. **Сушон, Л. Я.** Управление искривлением наклонных скважин в Западной Сибири / Л. Я. Сушон, П. В. Емельянов, Р. Т. Муллағалиев. М.: Недра, 1988. 124 с.
2. **Калинин, А. Г.** Бурение наклонных скважин / А. Г. Калинин, Н. А. Григорян, Б. З. Султанов. М.: Недра, 1990. 348 с.
3. **Минаев, Ю. Н.** Методы и алгоритмы идентификации и прогнозирования в условиях неопределенности в нейросетевом и логическом базисе / Ю. Н. Минаев, О. Ю. Филимонова. М.: Горячая линия–Телеком, 2003. 205 с.
4. **Алимбеков, Р. И.** Компьютеризированные технологии управления бурением наклонно-направленных скважин / Р. И. Алимбеков, В. И. Васильев, И. Ф. Нугаев [и др.] // Нефтяное хозяйство. 2000. № 12. С. 120–122.
5. **Нугаев, И. Ф.** Автоматизированная система моделирования траекторий наклонно-направленных скважин / И. Ф. Нугаев // Автоматизация, телемеханизация и связь в нефтяной промышленности. 2006. № 5. С. 14–18.
6. **Нугаев, И. Ф.** Прогнозирующее управление траекторией нефтегазовой скважины на основе нейросетевой модели движения бурового инструмента / И. Ф. Нугаев // Нейрокомпьютеры. 2007. № 10. С. 10–15.

ОБ АВТОРЕ



Нугаев Ильдар Фидаилевич, доц. каф. пром. электрон. Дипл. инж. электрон. техники (УАИ, 1985). Канд. техн. наук по АСУ. Иссл. в обл. интеллект. автоматич. управл. сложн. системами.