

## ОПЫТ РЕШЕНИЯ ЗАДАЧИ ПАРАМЕТРИЧЕСКОГО ОЦЕНИВАНИЯ ЦИФРОВЫХ МОДЕЛЕЙ НЕФТЯНОГО МЕСТОРОЖДЕНИЯ

*А.В. Гагарин, Г.А. Макеев, Р.А. Байков, В.Г. Волков*

## AN EXPERIENCE OF PARAMETRIC ESTIMATION OF DIGITAL OIL RESERVOIR MODELS

*A.V. Gagarin, G.A. Makeev, R.A. Baikov, V.G. Volkov*

В статье рассматривается автоматизированная система идентификации параметров цифровых моделей нефтяного месторождения. Исследуется применение методов оптимизации общего назначения, разработанных интеллектуальных алгоритмов оптимизации и других инструментов для поиска решения, анализа чувствительности и взаимозависимостей между искомыми параметрами. Предложенная система может быть использована в любых инженерных приложениях, где значение целевой функции зависит от результатов ресурсоемких расчетов.

*Ключевые слова: идентификация параметров, оптимизация, генетические алгоритмы, нейронные сети, гидродинамическое моделирование*

A system that is designed to identify parameters of digital oil reservoir models is presented in this paper. An application of common optimization methods, proposed intelligent optimization algorithms and other tools for finding solution, making sensitivity analysis and searching for hidden dependencies between parameters of interest is investigated. The system developed is suited for solving optimization tasks with fitness function value depending on results of resource consuming calculations.

*Keywords: parameters' identification, an optimization, genetic algorithms, neural networks, hydrodynamic models*

### Введение

Решение задач параметрического оценивания и анализа чувствительности геолого-гидродинамических моделей (ГДМ) принципиально требует проведения массовых расчетов моделей с привлечением всех доступных вычислительных ресурсов, что сопряжено со значительными временными затратами и проведением большого объема рутинной работы специалистов по моделированию. Общий поток работ включает в себя, в частности:

- генерацию множества вариантов некоторой модели;
- распределение задач по доступным вычислительным мощностям;
- сбор и обработку результатов выполнения моделей.

Для формализации задачи параметрического оценивания предположим, что объект исследования (ОИ) характеризуется контролируруемыми выходными сигналами  $\mathbf{y}(k) = (y_1(k), y_2(k), \dots, y_m(k))$ , которые регистрируются в ходе натурального эксперимента в дискретные моменты времени  $t_k, k = 1, 2, \dots$  [11, 12]. Им соответствуют выходные сигналы  $\hat{\mathbf{y}}(k | \mathbf{x}) = (\hat{y}_1(k | \mathbf{x}), \hat{y}_2(k | \mathbf{x}), \dots, \hat{y}_m(k | \mathbf{x}))$  цифровой модели ОИ, определяемой вектором параметров  $\mathbf{x}$ . Невязкой  $\varepsilon(k, \mathbf{x})$  называется разность между выходными сигналами ОИ  $\mathbf{y}(k)$  и настраиваемой модели  $\hat{\mathbf{y}}(k | \mathbf{x})$ :  $\varepsilon(k, \mathbf{x}) = \mathbf{y}(k) - \hat{\mathbf{y}}(k | \mathbf{x})$ . Пусть имеются данные наблюдения  $\mathbf{y}(1), \dots, \mathbf{y}(N)$  за ОИ в  $N$  различных моментов времени. Тогда задача параметрического оценивания модели заключается в выборе из всего множества параметров  $\mathbf{x} \in D_M$  некоторого оптимального вектора  $\mathbf{x}^{\text{opt}}$  таким образом, чтобы невязка  $\varepsilon(k, \mathbf{x}^{\text{opt}}), k = 1, \dots, N$  была по возможности мала.

Как правило, данная задача сводится к задаче минимизации целевой функции (ЦФ) вида:

$$f(\mathbf{x}) = \sum_{k=1}^N \varepsilon(k, \mathbf{x})^T \cdot \mathbf{W} \cdot \varepsilon(k, \mathbf{x}), \quad (1)$$

где  $\mathbf{W}$  — матрица весовых коэффициентов.

Данная функция является мерой близости настраиваемой модели к реальному ОИ и отражает качество идентификации ее параметров. Соответственно,

$$\mathbf{x}^{\text{opt}} = \underset{\mathbf{x} \in D_M}{\operatorname{argmin}} f(\mathbf{x}).$$

На практике ищется минимум  $f(\mathbf{x})$  с заданным порогом  $\delta$ , позволяющим контролировать точность получаемого результата. Иными словами, необходимо найти решение  $\mathbf{x}^*$  такое, что:

$$f(\mathbf{x}^*) < f(\mathbf{x}^{\text{opt}}) + \delta. \quad (2)$$

Для нахождения минимума  $f(\mathbf{x})$ , удовлетворяющего условию (2), обычно применяются итерационные методы оптимизации, генерирующие последовательность приближений  $\{\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(N_o)}\}$  такую, что  $\mathbf{x}^{(N_o)} \in D_M^*$  (то есть  $\mathbf{x}^{(N_o)}$  удовлетворяет условию (2)). Значение индекса  $N_o$  показывает количество приближений, требуемых для нахождения оптимума ЦФ с заданным порогом. На практике, в дополнение к критерию (2) часто применяется ограничение по времени, когда оптимизация останавливается по условию  $N_o = N_o^{\text{max}}$ .

В зависимости от сложности модели и величины  $N$ , ресурсоемкость вычисления  $\hat{\mathbf{y}}(k | \mathbf{x}), k = 1, \dots, N$ , может быть велика. Например, время численного моделирования течения многофазной смеси жидкости и газа в пористой среде, широко используемое в моделях нефтяных месторождений, даже на современных суперкомпьютерах с применением коммерческих симуляторов, таких как Shlumberger ECLIPSE, Roxar Tempest MORE, NGT BOS<sup>1</sup> и т. д., может исчисляться сутками. Задача оптимизации ГДМ является примером некорректно поставленной обратной задачи с ЦФ вида (1). У нее может не существовать решения, может существовать больше одного решения, и неизвестна устойчивость решения. В таких условиях одним из методов решения могут быть методы глобальной и локальной оптимизации общего назначения, такие как градиентные и генетические алгоритмы [1–3, 6]. Среди особенностей задачи моделирования можно выделить большое количество искомых параметров и возможную неявную зависимость между этими параметрами.

В связи с этим большую актуальность приобретает задача автоматизации процесса многовариантного моделирования, то есть полного цикла генерации вариантов моделей, их рас-

<sup>1</sup>Разработка ООО «РН-УфаНИПИнефть»

чета и обработки результатов для решения различных прикладных задач. Результатом работы должна стать единая универсальная среда выполнения возможных сценариев для оптимизации моделей, пользуясь которой специалисты смогут сосредоточиться на решении только принципиальных задач моделирования.

## 1. Описание разработанной системы

Разрабатываемая система автоматизированной оптимизации ГДМ основана на совместном использовании вычислительной среды MATLAB и гидродинамического симулятора NGT BOS Core. Типичный цикл оптимизации модели с помощью этой системы включает следующие этапы (рис. 1).

На первом этапе производится выбор варьируемых параметров модели, определяется вид ЦФ, и способ преобразования аргументов целевой функции в варьируемые параметры модели. Далее под параметрами понимаются именно аргументы ЦФ.

На втором этапе определяется область поиска оптимальных значений параметров (границы) и шаги дискретизации области поиска по всем параметрам.

На третьем этапе анализируется чувствительность ЦФ к искомым параметрам, определяются однородные и неоднородные области параметрического пространства.

На четвертом этапе с помощью алгоритмов оптимизации общего назначения (генетических, градиентных и т.д.) система самостоятельно выполняет цикл, в котором генерируются ГДМ, соответствующие приближениям  $\mathbf{x}^{(v)}$ , производится численное моделирование, необходимое для вычисления ЦФ и обрабатываются результаты расчета.

На пятом этапе анализируются найденные решения и кластеры решений, определяется их устойчивость.

И на шестом этапе строятся отчеты по лучшим найденным решениям и интегральные отчеты в разрезе всех рассчитанных решений.

### 1.1. Матрица «параметры-оценки»

Параметры и соответствующие им рассчитанные значения ЦФ в системе формируют матрицу параметров и оценок (расширенный и отформатированный вид ее приведен на рис. 2). Матрица имеет  $n + l$  столбцов и  $e$  строк, где  $n$  — количество параметров, а  $l$  — количество оценок. Каждая строка соответствует одному эксперименту (одной ГДМ). Все модели различаются только значениями  $n$  варьируемых параметров, а в остальном идентичны.

Добавление новой строки в матрицу «параметры-оценки» приводит к автоматическому




Рис. 1. Общая структура системы

	Параметры				Состояние	Оценки			
	P1	P2	...	PN		E1	E2	...	EM
№ эксп.	Забойное давление там-то	Длина трещины такой-то	...	Признак установки эквалайзера		Общая добыча нефти	Газовый фактор на скважине такой-то		Средняя обводненность
1	250	50		1	...	120	1		0.7
2	300	75		1	...	130	1		0.7
					...				
E	250	50		1	<b>рассчитывается</b>				

Рис. 2. Пример матрицы параметров и оценок

созданию новой гидродинамической модели. Система позволяет произвести численное моделирование как на локальном компьютере, так и на кластере. После проведения численного моделирования вычисляется значение ЦФ, соответствующее данной ГДМ.

Поскольку матрица «параметры-оценки» доступна в среде MATLAB, то добавляться новые строки могут:

- на основе приближений  $x^{(\nu)}$ , генерируемых алгоритмом оптимизации;
- вручную, если специалисту требуется проверить модель с заданными набором параметров;
- функцией группового добавления: например, в соответствии с алгоритмом планирования эксперимента (экспериментальный дизайн).

Важной особенностью матрицы «параметры-оценки» является то, что в ней не может быть двух моделей, все параметры которых совпадают. Это означает, что численное моделирование с уникальным набором параметров модели производится только один раз.

### 1.2. Параметризация модели

Система позволяет использовать в качестве аргумента ЦФ любое значение, прямо или опосредованно влияющее на параметры ГДМ. С точки зрения системы любой аргумент ЦФ имеет свою область определения и шаг дискретизации. С помощью языка MATLAB можно производить сложные преобразования аргументов ЦФ в параметры ГДМ. Формально, преобразование аргументов ЦФ в параметры модели в разработанной системе выполняется с помощью двух механизмов:

- подстановка на место параметра ГДМ аргумента целевой функции;
- вызов некоторой функции MATLAB, осуществляющей преобразование аргументов ЦФ в параметры ГДМ.

### 1.3. Применяемые алгоритмы оптимизации

Поскольку задача параметрического оценивания модели формулируется в виде задачи оптимизации, важнейшую роль в системе играет используемый алгоритм оптимизации, в значительной степени определяющий способность исследования пространства поиска, скорость поиска решения, возможность нахождения глобального оптимума и т.д.

Разработанная система построена по модульному принципу и позволяет использовать различные оптимизационные блоки, обладающие одинаковым программным интерфейсом (API). В частности, на данный момент система включает реализации градиентного поиска, усовершенствованных генетических алгоритмов (ГА), эвристического алгоритма, основанного на методе кригинга (Kriging), алгоритма Монте-Карло. Кроме того, имеются также

модули планирования эксперимента, факторного анализа, анализа чувствительности и зависимостей между параметрами и оценками.

Поскольку нахождение параметров адекватной модели, обладающей хорошими прогнозными свойствами — нетривиальная задача, которую невозможно полностью автоматизировать, специалист по моделированию может на различных уровнях настраивать поведение системы. В частности, именно он определяет оптимизационное ядро для решения прикладных задач. Однако, на практике в общем случае ЦФ имеет очень сложную форму, и область локализации ее глобального оптимума неизвестна, поэтому целесообразно на начальном этапе использовать алгоритмы с возможностями глобальной оптимизации и уже на этапе уточнения решения переходить к методам локального поиска.

### 1.3.1. Гибридный генетический нейросетевой алгоритм

Хорошо известно, что использование стандартного ГА предполагает на каждой итерации для каждого набора параметров (хромосомы в терминах ГА) вычисление значений ЦФ, включающее в себя моделирование ОИ (то есть расчет значений  $\hat{y}(k | \mathbf{x})$ ). Разработанный гибридный генетический нейросетевой алгоритм (ГА+НС) является модификацией стандартного ГА, в дальнейшем называемого *главным*, на каждой итерации которого создается нейросетевая аппроксимация  $\tilde{f}(\mathbf{x})$  целевой функции  $f(\mathbf{x})$ , предназначенная для получения прогноза  $\tilde{\mathbf{x}}^*$  оптимального решения функции  $f(\mathbf{x})$ . В большинстве случаев  $\tilde{f}(\mathbf{x})$  будет вычисляться значительно быстрее  $f(\mathbf{x})$ , поскольку не требует предварительного расчета модели. Поиск  $\tilde{\mathbf{x}}^*$  осуществляется с помощью дополнительного ГА, в дальнейшем называемого *вспомогательным*, для которого в качестве ЦФ используется  $\tilde{f}(\mathbf{x})$  (то есть значения, вычисляемые нейронной сетью). Найденный прогноз затем добавляется в популяцию потомков главного ГА на текущей итерации, и цикл повторяется.

Адекватный прогноз  $\tilde{\mathbf{x}}^*$  оптимального решения может значительно ускорить эволюционный поиск основного ГА. Если прогноз окажется неудачным, эволюционные механизмы обеспечат стабильность оптимизации. Приближения  $\mathbf{x}$ , генерируемые основным ГА на протяжении всего процесса оптимизации, вместе с соответствующими значениями ЦФ  $f(\mathbf{x})$  участвуют в формировании обучающей выборки для НС (стандартный ГА хранит лишь текущую популяцию фиксированного размера). Вспомогательный ГА может выполнять значительно более интенсивный поиск по сравнению с главным ГА (большой размер популяции, много итераций и т. п.) и с большой вероятностью находить глобальный оптимум  $\tilde{f}$ , так как данная функция вычисляется сравнительно быстро.

В современной литературе методы идентификации систем, основанные на замене сложной модели реального ОИ на значительно менее ресурсоемкую модель, приближенно воспроизводящую отклик исходной модели, называются суррогатным моделированием или метамоделированием [8,10]. Суррогатные модели ОИ обычно строятся с минимальным привлечением данных из предметной области на основе имеющихся вычислительных экспериментов с исходной моделью или данных наблюдения за реальным ОИ с помощью различных методов построения аппроксимации многомерных зависимостей (аппроксимирующие полиномы, сплайны, радиально-базисные функции, кригинг, нейронные сети и т. д.). Прямое применение данного подхода с использованием НС для построения суррогатной модели путем обучения на заранее подготовленной обучающей выборке, и дальнейшего применения ГА для идентификации параметров суррогатной модели описано, например, в работах [5, 7, 9]. Такую схему можно рассматривать как одну итерацию нейросетевого контура предлагаемого алгоритма ГА+НС. Отличительной особенностью ГА+НС является то, что НС используется не для построения отображения  $(\mathbf{x}, k) \mapsto \hat{y}(k | \mathbf{x})$ , а для аппроксимации ЦФ (которая, в свою очередь зависит от  $y(k)$  и  $\hat{y}(k | \mathbf{x})$ ). Кроме того, предлагаемый алгоритм не требует

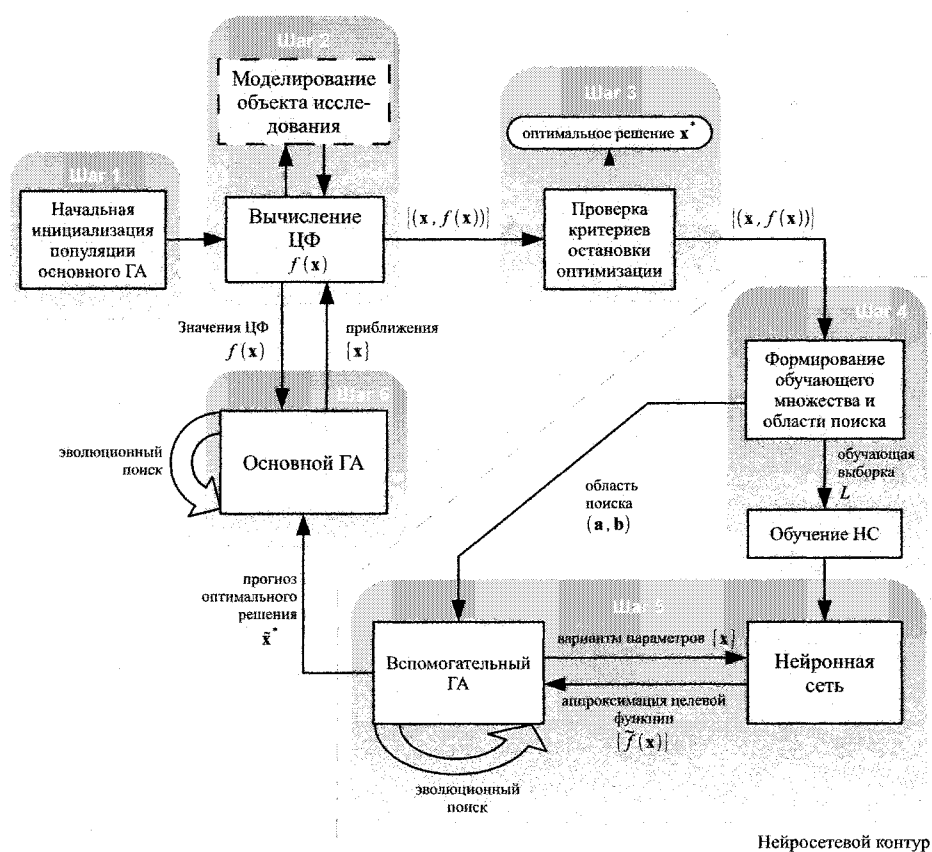


Рис. 3. Схема алгоритма ГА+НС

наличия априорно заданной обучающей выборки, нейросетевая аппроксимация  $\tilde{f}$  строится динамически на каждой итерации главного ГА на основе имеющегося на данный момент множества пар  $\{(x, f(x))\}$ .

Наиболее близкий аналог ГА+НС предлагается в работе [4]. Гибридный алгоритм в [4] не содержит вспомогательного ГА, поскольку на вход НС подается значение ЦФ, а на выходе получается прогноз соответствующего вектора искомых параметров. Однако такая схема имеет очевидный недостаток, заключающийся в некорректности обратной задачи, решаемой НС.

### 1.3.2. Кригинг-оптимизатор

Кригинг – семейство геостатистических алгоритмов интерполяции неизвестной случайной величины в некоторой точке по известным реализациям этой случайной величины в некоторых других точках. В общем виде значение  $Z^*(u)$  в интерполируемой точке  $u$  определяется следующим образом: через известные реализации случайных величин в точках  $u_\alpha$ ,  $\alpha = \overline{1, n}$ :

$$Z^*(u) = m(u) + \sum_{\alpha=1}^{n(u)} \lambda_\alpha(u) (Z(u_\alpha) - m(u_\alpha)),$$

где  $Z(u_\alpha)$ ,  $Z(u)$  – реализации случайных величин в точках  $u$  и  $u_\alpha$ ;

$m(u_\alpha)$ ,  $m(u)$  – математические ожидания этих случайных величин;

$\lambda_\alpha(u)$ ,  $\alpha = \overline{1, n}$  – веса известных реализаций, меняющиеся при переходе к следующей точке  $u$ .

Основная идея кригинга в том, что веса  $\lambda_\alpha(u)$ ,  $\alpha = \overline{1, n}$  выбираются так, чтобы интерполируемое значение  $Z^*(u)$  соотносилось с истинным (неизвестным) значением  $Z(u)$  в этой же точке следующим образом:

$$E(Z^*(u) - Z(u)) = 0,$$

$$D(Z^*(u) - Z(u)) \rightarrow \min.$$

Данные, которыми оперирует кригинг, включают не только значения  $Z(u_\alpha)$ , но и априорную информацию о моделируемых случайных величинах в виде ковариационной функции  $Cov(Z(u), Z(u+h)) = C_R(h)$  при допущении, что последняя не зависит от положения  $u$ , а зависит только от расстояния  $h$  между точками.

Кригинг-оптимизатор — набор параллельно работающих эвристик, основанных на кригинг-интерполяции параметрического пространства и принятии решений о новых точках на основании результата интерполяции.

Использование кригинг-интерполяции в данном случае не имеет под собой твердой математической основы, так как в случае параметрического пространства целевой функции нельзя говорить о каких-либо случайных величинах, тем более об их ковариациях. Однако использование кригинг-интерполяции как еще одного алгоритма интерполяции, обладающего свойствами сохранения значений в известных точках и удовлетворительного управляемого сглаживания, вполне допустимо.

Кригинг получает на вход все имеющиеся наборы аргументов и значений ЦФ, рассматриваемые как реализации некоторой случайной величины, и строит:

- оценку мат. ожидания  $E$  в требуемых точках — прогноз значения ЦФ в неизвестной точке;
- оценку дисперсии  $D$  в требуемых точках — в некотором смысле, меру «неизвестности» параметрического пространства в неизвестной точке (она же мера удаленности неизвестной точки от всех известных);
- оценку «локальной изменчивости» вида  $LD = \frac{\sum_{i=1}^N \lambda_i (y_i - E)^2}{N}$  — в некотором смысле меру неоднородности параметрического пространства в неизвестной точке.

Эвристические стратегии поиска, используемые кригинг-оптимизатором, выбирают место в параметрическом пространстве для создания новой точки так, чтобы:

- мат. ожидание  $E \rightarrow \max$  — попытка воспользоваться интерполяцией для поиска оптимального значения;
- дисперсия  $D \rightarrow \max$  — исследование неизвестных областей параметрического пространства;
- локальная изменчивость  $LD \rightarrow \max$  — исследование областей параметрического пространства с высокой изменчивостью;
- $D \cdot LD \rightarrow \max$  — исследование неизвестных областей параметрического пространства с высокой изменчивостью.

Кригинг-оптимизатор обладает следующими достоинствами:

- одновременно использует все эвристики в определенном соотношении;
- не имеет «истории», может быть остановлен в любой момент и запущен опять;
- равномерно заполняет параметрическое пространство, но в отличие от регулярных методов, делает это при любом имеющемся количестве «попыток».

### 1.3.3. Модули планирования экспериментов

Модули планирования экспериментов предназначены для исследования параметрического пространства путем заполнения его множеством точек в соответствии с некоторым алгоритмом планирования эксперимента:

- случайный засев;
- полный факторный анализ;
- алгоритм Box-Behnken Design;
- алгоритм Central Composite Design.

### 1.3.4. Модули анализа чувствительности и независимости параметров

Выделение независимых аргументов или групп аргументов ЦФ, основанное на определении чувствительности ЦФ, а также контролируемых параметров модели  $y(k)$  к аргументам ЦФ, является эффективным способом уменьшения размерности пространства поиска.

Анализ чувствительности в разработанной системе основан на оценке частных производных по каждому параметру в некоторых (заданных пользователем или выбираемых вручную) точках. Результатом работы блока оценки чувствительности является матрица, где каждой строке соответствует аргумент ЦФ, а каждому столбцу соответствует контролируемый параметр или значение ЦФ. Элемент матрицы содержит значение чувствительности контролируемого параметра к соответствующему аргументу ЦФ. Такая матрица позволяет выявить разбиение аргументов ЦФ на независимые группы.

## 2. Опыт применения для задач моделирования

В этом разделе приводится описание задач оптимизации ГДМ, для которых была применена разработанная система. В общем виде все задачи следуют одной и той же схеме. Раз система оптимизации умеет менять только числа, и с помощью алгоритмов параметрической оптимизации находить оптимальные их значения для некоторой определенной функции, то для любой фактической задачи моделирования требуется:

- параметризовать модель, то есть определить набор изменяемых численных параметров со своими областями определения, и определить процесс трансформации определенных значений параметров в конкретные (часто достаточно большие и сложные) изменения в модели;
- определить целевую функцию, которая для рассчитанной модели возвращает некоторое число, характеризующее то, насколько текущая модель «близка» к поставленной цели;
- запустить систему параметрической оптимизации, которая решает задачу оптимизации путем расчета большого количества ГДМ.

Далее приведено несколько примеров, которые должны проиллюстрировать разнообразие задач, которые могут быть решены в рамках разработанной системы.

### 2.1. Настройка относительных фазовых проницаемостей в виде степенных функций

Относительная проницаемость указывает на способность нефти и воды одновременно течь в пористой среде и определяется как отношение эффективной проницаемости фазы



к абсолютной (когда порода заполнена только одной фазой). ОФП задается в виде кривой зависимости относительной проницаемости данной фазы (нефть, вода, газ) от водонасыщенности, нормированной к диапазону [0; 1]. Форма кривых ОФП воды и нефти аппроксимировалась степенными функциями, форма которых задавалась с помощью восьми параметров. Задача заключалась в поиске таких значений этих параметров, чтобы результаты расчета полученной гидродинамической модели, минимизировали следующую ЦФ:

$$f(\mathbf{x}) = \sum_{k=1}^N \sum_{i=1}^m \sum_{j=1}^u \frac{(y_{i,j}(k) - \hat{y}_{i,j}(k | \mathbf{x}))^2}{\sigma_i^2},$$

- где  $k$  — номер временного шага;  
 $i$  — индекс интересующего контрольного параметра;  
 $j$  — номер скважины;  
 $\sigma_i$  — дисперсия наблюдаемых значений  $i$ -го параметра.

Учитывались следующие контрольные величины: мгновенные и суммарные дебиты воды и нефти, дебит жидкости, суммарный объем закачки, обводненность скважин. Исторические значения этих величин были предварительно получены из результатов расчета модели с экспертно заданными ОФП. Эти данные были приняты в качестве эталонных и использовались для сравнения с расчетными значениями в процессе оптимизации. В качестве ядра оптимизации применялся алгоритм ГА+НС.

В ходе оптимизации было сделано 10 итераций алгоритма ГА+НС, на каждой из которых оценивалась популяция из 10 моделей. Результаты эксперимента представлены на рисунках 4 и 5.




Рис. 4. Начальное приближение контрольных величин




Рис. 5. Контрольные величины после оптимизации

## 2.2. Подбор петрофизической зависимости между проницаемостью и пористостью

Трехмерные массивы, определяющие пористость и проницаемость в каждой ячейке модели месторождения представляют собой часть численной модели, с которой работает симулятор. Исходными данными для построения этих кубов являются разнообразные исследования ядра скважин при бурении и в процессе работы скважины и прочие источники информации, обладающие различной достоверностью.

Принято считать, что статистически пористость  $m$  и проницаемость  $k$  связаны соотношением  $m = a + b \cdot \log_{10} k$ , где  $a$  и  $b$  — константы для некоторого региона. Эти константы, как правило, находятся каким-нибудь методом линейной регрессии по облаку точек  $(m, \log_{10} k)$  (рисунок 6, слева).




Рис. 6. Зависимость между пористостью и проницаемостью

Была решена задача в следующей постановке. Куб пористости модели был зафиксирован, как обладающий достаточной достоверностью. Выбирались некоторые значения  $a$  и  $b$ , и по приведенному выше петрофизическому соотношению из куба пористости рассчитывался куб проницаемости. Фактически, в облаке точек проводилась новая прямая, и все точки «сажались по вертикали» на эту прямую: значение  $m$  оставалось одно и то же, значение  $\log_{10} k$  менялось (правый рисунок).

Полученная модель рассчитывалась на симуляторе, и далее рассчитывалась невязка между историческими и расчетными значениями добычи нефти и воды. Таким образом, задача сводилась к задаче параметрической оптимизации петрофизических параметров  $a$  и  $b$  для минимизации численного значения невязки. И уже эта задача параметрической оптимизации решалась стандартными средствами разработанной системы. Таким образом, система оптимизации варьировала целый куб проницаемости ГДМ путем параметризации этого куба всего двумя параметрами.

## 2.3. Адаптация карты проницаемости

Данные трехмерного куба проницаемости в модели, как правило, являются вторичными, пересчитанными из данных куба пористости по принятым (пусть и в результате эксперимента) петрофизическим зависимостям. Принято считать, что эти данные можно менять в процессе оптимизации модели, однако изменения не должны приводить к очевидно нефизичным результатам. Одним из таких изменений, например, является повышение или понижение проницаемости в ячейках куба, прилегающих к скважинам, однако такое изменение должно быть «плавным».

Для адаптации куба проницаемости был реализован следующий алгоритм. Выбирались некоторые значения множителей на проницаемость на некоторых скважинах, полученные значения добавлялись в пустую «карту множителей», которая после этого заполнялась це-

ликом интерполяцией добавленных множителей. Каждый горизонтальный слой куба проницаемости затем умножался на гладкую карту множителей. Полученная модель рассчитывалась на симуляторе, и вычислялась невязка между историческими и расчетными значениями добычи нефти и воды.




Рис. 7. Преобразование карты проницаемости

На рисунке 7 показан фрагмент одного горизонтального слоя начального куба проницаемости и четыре скважины. На левой нижней и правой верхней скважинах множитель устанавливался равным 1. На левой верхней скважине он был равен 2, а на правой нижней множитель был равен 3. На среднем рисунке показан фрагмент интерполированной карты множителей. На правом рисунке показан фрагмент произведения слоя начальной пористости на карту множителей. Задача заключалась в параметрической оптимизации некоторого ограниченного числа множителей на проницаемость на некоторых скважинах для минимизации численного значения невязки. И, опять-таки, после параметризации задачи она была решена стандартными средствами разработанной системы. Таким образом, система оптимизации варьировала целый куб проницаемости ГДМ путем параметризации этого куба значениями множителей на некотором наборе скважин.

#### 2.4. Оптимизация траектории скважины

Задачи, так или иначе связанные с оптимизацией траекторий новых скважин, могут быть поставлены множеством различных способов. Это может быть выбор местоположения устья скважины, подбор схемы и параметров размещения групп скважин на месторождении (системы разработки), выбор направления и угла наклона сегмента горизонтальной скважины и т.д.

Во всех этих постановках требуется, как и во всех предыдущих задачах оптимизации, выбрать правильную параметризацию, чтобы система оптимизации вносила изменения в модель, меняя только малое количество численных параметров.




Рис. 8. Оптимизация траектории скважины

Например, в случае, если траектория скважины задается в модели путем определения координат всех точек траектории, фиксация  $X$  и  $Y$  координат начала и конца некоторого сегмента, но варьирова  $Z$  координату этих точек в некоторых пределах (красные отрезки на

рисунке), мы получаем задачу выбора угла наклона сегмента горизонтальной скважины. Данная задача решалась одновременно с выбором марки устройства управления лабиринтным притоком, которое устанавливается на скважину для предотвращения преждевременного прорыва газа. Целевой функцией в этом случае была максимизация добычи нефти при минимизации (или контроле неперевышения некоторого порога) добычи газа.

## Выводы

1. Использование кластерных вычислений позволяет эффективно решать разнообразные обратные задачи при идентификации параметров ГДМ путем решения множества прямых задач.
2. Использование разработанных алгоритмов оптимизации позволяет резко сократить количество численных экспериментов.
3. Разработанная система оптимизации ГДМ активно и успешно используется сотрудниками РН-УфаНИПИнефть при адаптации ГДМ.

*Статья рекомендована к печати программным комитетом международной научной конференции «Параллельные вычислительные технологии 2010» <http://agora.guru.ru/pavt>.*

## Литература

1. Ballester, P. J. A parallel real-coded genetic algorithm for history matching and its application to a real petroleum reservoir / P. J. Ballester, J. N. Carter // J. of Petroleum Science and Engineering. – 2007. – V. 59. – P. 157 – 168.
2. Evolutionary algorithms applied to history matching of complex reservoirs / R. Schulze-Riegert, J. Axmann, O. Haase, et al. // SPE Reservoir Evaluation & Engineering. – 2002. – V. 5, №. 2. – P. 163 – 173.
3. Gomez, S. Gradient-based history-matching with a global optimization method / S. Gomez, O. Gosselin, J. Barker // Society of Petroleum Engineering J. – 2001. – V. 6. – P. 200 – 208.
4. Javadi, A.A. A hybrid intelligent genetic algorithm / A.A. Javadi, R. Farmani, T.P. Tan // Advanced Engineering Informatics. – 2005. – V. 19, №. 4. – P. 255 – 262.
5. Kuo, J.-T. A hybrid neural-genetic algorithm for reservoir water quality management. / J.-T. Kuo, Y.-Y. Wang, W.-S. Lung // Water Res. – 2006. – Apr. – V. 40, №. 7. – P. 1367 – 1376.
6. Soleng, H. Oil reservoir production forecasting with uncertainty estimation using genetic algorithms / H. Soleng // Proc. Congress on Evolutionary Computation CEC 99. – V. 2. – 1999. – 6 – 9 July.
7. Srinivas, V. An integrated approach for optimum design of bridge decks using genetic algorithms and artificial neural networks / V. Srinivas, K. Ramanjaneyulu // Advances in Engineering Software. – 2006. – №. 38. – P. 475 – 487.
8. Wang, G.G. Review of metamodeling techniques in support of engineering design optimization / G.G. Wang, S. Shan // J. of Mechanical Design. – 2007. – V. 129, №. 4. – P. 370 – 380.

9. Wang, L. A hybrid genetic algorithm-neural network strategy for simulation optimization / L. Wang // Applied Mathematics and Computation. – 2005. – V. 170. – P. 1329 – 1343.
10. Кулешов, А.П. Когнитивные технологии в основанных на данных адаптивных моделях сложных объектов / А.П. Кулешов // Информационные технологии и вычислительные системы. – 2008. – № 1. – С. 18 – 29.
11. Льюнг, Л. Идентификация систем. Теория для пользователя: пер. с англ. / Л. Льюнг; Под ред. Я.З. Цыпкина. – М.: Наука; Гл. ред. физ.-мат. лит., 1991. – 432 с.
12. Цыпкин, Я.З. Информационная теория идентификации / Я.З. Цыпкин. – М.: Наука. Физматлит, 1995. – 336 с.

Гагарин Александр Владимирович, научный сотрудник ООО «РН-УфаНИПИнефть», unidentity@gmail.com.

Макеев Григорий Анатольевич, доцент кафедры ВМиК, Уфимский государственный авиационный технический университет, г.Уфа, grigorym@ufanet.ru.

Байков Рафаель Анварович, доцент кафедры ВМиК, Уфимский государственный авиационный технический университет, г.Уфа, baikovRA@ufanipi.ru.

Волков Владимир Григорьевич, директор департамента ООО «РН-УфаНИПИнефть», volkovvg@ufanipi.ru.

*Поступила в редакцию 7 апреля 2010 г.*