

УДК 550.8.05:004.8.032.26

ГЕОЛОГИЧЕСКАЯ ИНТЕРПРЕТАЦИЯ С ПРИМЕНЕНИЕМ ОБУЧАЕМЫХ НЕЙРОННЫХ СЕТЕЙ В «НЕЙРОИНФОРМГЕО» ДАННЫХ ГИС ТАЛАКАНСКОГО НЕФТЕГАЗОКОНДЕНСАТНОГО МЕСТОРОЖДЕНИЯ

Д.О. Гафуров

Томский политехнический университет
E-mail: den78@kgf.ru

Описана методика интерпретации данных геофизических исследований скважин математическим аппаратом обучаемых нейронных сетей, реализованным в интеллектуальной геоинформационной системе "НейроИнформГео".

Геологический объект, начиная с нефтегазоносной провинции и кончая образцом породы, является сложно организованной системой и описывается большим числом характеристик, имеющих разную физическую природу и находящихся в тесных взаимосвязях друг с другом. Горные породы в зависимости от условий их образования и распространения обладают индивидуальным минеральным составом, а также структурными и текстурными признаками, определяемыми на основе лабораторных исследований отобранного керна. В большинстве случаев керн отбирается не по всему продуктивному интервалу, что обусловлено высокой стоимостью применения бурения с отбором керна.

В данной статье рассмотрена и предложена методика создания опорной геолого-геофизической модели месторождения углеводородов на основе обучения нейронных сетей и результаты прогнозирования литотипов пород по комплексу данных ГИС в скважинах с отсутствием керна, на примере залежей углеводородов осинского горизонта Талаканского нефтегазоконденсатного месторождения.

Комплексирование геологических данных и ГИС производилось с использованием математического аппарата нейронных сетей, реализованного в интеллектуальной геоинформационной системе "НейроИнформГео", по методике разработанной ООО "ИнформГеоСервис" (О.М. Гафуров) совместно с ЗАО "Красноярскгеофизика" (А.А. Конторович, А.С. Ефимов, Н.Б. Красильникова, Д.О. Гафуров и др.) [1].

Талаканское нефтегазоконденсатного месторождение расположено в пределах Приленского структурно-денудационного плато Среднесибирского плоскогорья, в административном отношении на территории Ленского улуса Республики Саха (Якутия), в 210 км юго-западнее г. Ленска. В геологическом строении месторождения принимают участие образования архея – нижнего протерозоя (фундамент), протерозоя (рифей и венд), палеозоя (кембрий), мезозоя и четвертичные отложения.

Основным объектом исследований является осинский продуктивный горизонт верхнебилюрской подсыты (нижний кембрий). Горизонт сложен на разных частях территории органогенными доломитизированными известняками и доломитами, причем в нижней части пачки преобладают известня-

ки, а в верхней – доломиты. Известняки серые, коричневато-серые, массивные, иногда пористые и мелкокавернозные. Доломиты светло-коричневато-серые, тонкозернистые, известковистые, кавернозные. Во многих разрезах порода имеет сложную текстуру, возникшую в результате интенсивных вторичных процессов. Отмечаются стилолитовые швы, гнезда ангидрита. Толщина горизонта на месторождении 28...53 м.

В комплексных исследованиях, которые проводились на Талаканском месторождении Институтом проблем нефти и газа СО РАН (г. Якутск) совместно с сотрудниками ИГАиБМ СО РАН и ОАО «Якутскгеофизика» (г. Якутск), СНИИГГиМС (г. Новосибирск) особое значение придавались литогенетической типизации пород осинского горизонта, основанных на разнеуровневом фациальном анализе и петрографических особенностях продуктивных отложений. Несмотря на уже выполненные работы, проблемы с формированием наиболее качественных коллекторов и их распространением по площади месторождения остались не решены, что связано, прежде всего, с ограниченным количеством скважин с представительным выходом керна, и, как следствие, ограниченностью фациального анализа, основанного на петрографических особенностях отложений. Всеми исследователями отмечается крайняя неоднородность первичного фациального строения осинского горизонта, значительно осложненного впоследствии многоэтапными тектоническими процессами. В связи с этим возможность прогнозировать литотипы в скважинах, где отсутствует отбор керна или его вынос мал и неrepresentателен, особенно актуальна для построения адекватной геологической модели месторождения.

Сложный минеральный состав и структура пустотного пространства карбонатных коллекторов требуют использования для определения литотипов комплексирования методов ГИС.

Первоначально при интерпретации данных ГИС в ЗАО "Красноярскгеофизика", использовалась методика, основанная на построении литологической модели скелета породы. Определение общей пористости (K_n) и компонентного состава карбонатных коллекторов осуществлялось решением системы линейных уравнений в соответствии с установленной литологической моделью скелета

(доломит, глина, соль, известняк, ангидрит). Основной интерпретации служили петрофизические зависимости и константы, полученные при лабораторных исследованиях керна. Однако, модель, построенная в результате интерпретации данным методом, не дала возможности выделить требуемые для фациального анализа литотипы в разрезах скважин. Наличие сложных, нелинейных связей между данными ГИС и породой требовало иного подхода к решению задачи, что и привело к разработке методики основанной на применении математического аппарата нейронных сетей, обладающего свойством моделирования сложных нелинейных зависимостей в массивах данных и адаптации ее к конкретным производственным задачам (О.М. Гафуров, Д.О. Гафуров) [1, 2].

Искусственной нейронной сетью называют устройство, состоящее из большого числа простых параллельно работающих процессорных элементов – нейронов, соединенных адаптивными линиями передачи информации – связями или синапсами [3]. В нейронной сети выделена группа связей, по которым она получает информацию из внешнего мира, и группа связей, с которых снимаются выдаваемые сетью сигналы. Нейронные сети применяются для решения различных задач классификации и прогнозирования. Нейронная сеть обучается решению задач на основе обучающей выборки – “задачника”, состоящего из набора пар “вход – требуемый выход”, и далее способна решать примеры, не входя-

щие в обучающую выборку [3, 4]. Входные данные для нейронной сети представляли из себя результаты комплекса ГИС, проведенном во всех скважинах и привязанным к интервалам отбора керна.

Комплекс ГИС включал в себя:

1. Гамма-каротаж (ГК).
2. Нейтронный гамма-каротаж (НГК).
3. Кавернометрия (ДС).
4. Акустический каротаж (АК).
5. Боковой электрический каротаж (БК).
6. Микробоковой электрический каротаж (МБК).
7. Плотностной гамма-гамма каротаж (ГГК).

Ни один из перечисленных методов не дает возможности однозначно выделять нужные нам литотипы, и необходимо комплексирование геологических данных исследований керна в скважинах где он был отобран и методов ГИС. Задача осложняется ограниченностью числа скважин, где был проведен полный комплекс ГИС. Скважины с наиболее полным комплексом ГИС в основном приурочены к Центрально-Талаканскому блоку и составляют всего 37,5 % от общего количества скважин на исследуемой площади.

Предлагаемая методика обучения нейронной сети в ИГС «НейроИнформГео» состоит из последовательно выполняемых шагов с возвратом и переобучением, в случае неудовлетворительного прогноза литотипов на каждом из этапов:

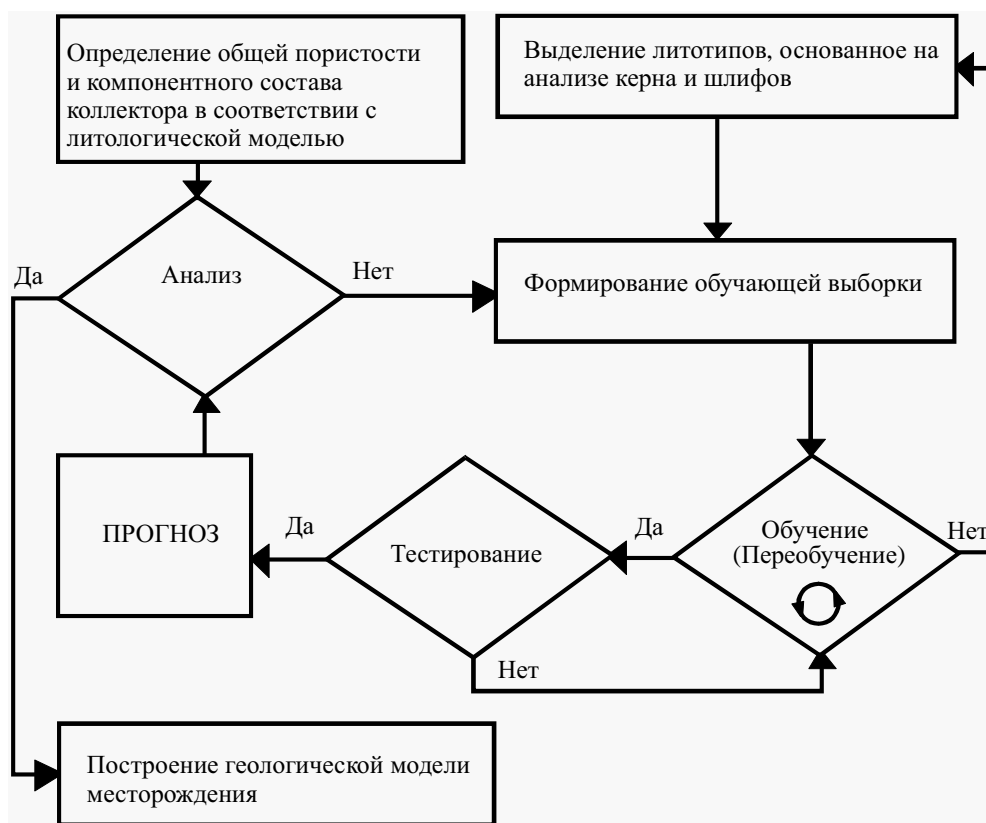


Рис. 1. Принципиальная схема методики интерпретации данных ГИС на основе обучаемых нейронных сетей “НейроИнформГео”

1. Скважины были распределены по группам с равным количеством произведенных в них геофизических исследований и отбором керна из продуктивного горизонта.
2. По мере сокращения комплекса ГИС в скважинах нейронная сеть переобучалась, прогноз подтверждался керном и принятой и рассчитанной литологической моделью, в местах его отсутствия. Данное сопоставление необходимо для своевременного обнаружения противоречий и их ликвидации переобучением сети с формированием более достоверной выборки.
3. Одновременно определялись общая пористости (K_n) и компонентный состав карбонатного коллектора посредством решения системы линейных уравнений в соответствии с установленной литологической моделью скелета (доломит, глина, соль, известняк, ангидрид) [5].
4. Производилось выделение литотипов основанное на анализе описания керна и шлифов, с учетом комплекса физических свойств характеризующих каждый литотип, и возможности его выделения комплексом методов ГИС. Основными критериями выделения послужили коэффициенты пористости и глинистости, полученные при анализе керна материала. В результате было выделено девять классов литотипов, слагающих осинский горизонт, табл. 1. Последние три относятся к коллектору.

Таблица 1. Выделенные литотипы осинского горизонта

Описание	Коэффициент	
	Пористости, % K_n	Глинистости, % K_m
Соли	<1	–
Глинистые породы	до 2	>25
Доломиты засоленные, известковистые, сульфатные, глинистые	до 1	10...12
Глинистый доломит. Известняки доломитистые	2...6	10...21
Ангидрито-доломит известковистый (плотный) сильно глинистый	до 2	10...12
Доломит ангидритисто-слабоглинистый	2...6	10...12
Доломит слабоглинисто битуминозный за-сульфаченный	6...10	–
Доломит органогенный пористый с незначительной примесью терригенного материала, сульфатов и солей	10...15	–
Доломит органогенный высокопористый коэффициент пористости	≥15	–

5. Формирование обучающей выборки для распознавания в скважинах с отсутствием выноса керна выделенных литотипов. К скважинам, участвующим в обучении, при формировании обучающей выборки предъявлялись следующие требования:
 - а) Использоваться должен только качественный каротаж. Необходимо проверить все привязки каротажа и керна перед обучением.

- б) Продуктивный горизонт должен быть представлен максимальным выходом керна в скважинах, участвующих в обучении нейросети.
 - в) Разрез скважины должен быть дифференцированным, т.е. представлен как можно большим числом выделенных литотипов.
 - г) Скважины должны представлять зоны с различным характером насыщения, вскрывать собственно нефтяную, водо-нефтяную и газо-нефтяную или газовую зоны.
6. Распознавание по данным ГИС в скважинах с отсутствием выноса керна выделенных литотипов.

Рассмотрим отдельные этапы геологической интерпретации данных ГИС более подробно.

Обучение. Обучение нейронной сети проводится на задачнике – наборе векторов данных и решений. В каждом векторе данных выделены сигналы, которые подаются нейронной сети – данные ГИС, и известные решения которые требуется получить от сети при заданных входных сигналах (класс литотипа). Обучение сети происходит как минимизация некоторой функции невязки (оценка) по всем векторам обучающего множества. Минимизация происходит путем такой подстройки обучаемых параметров сети, чтобы сеть выдавала выходные сигналы наиболее близкие к требуемым. В общем случае задача нахождения некой функциональной зависимости $Y=F(X)$, где X – входной, а Y – выходной векторы, при ограниченном наборе входных данных, имеет бесконечное множество решений. Для ограничения пространства поиска при обучении ставится задача минимизации целевой функции ошибки нейронной сети, которая находится по методу наименьших квадратов:

$$E(w) = \frac{1}{2} \sum_{j=1}^p (y_j - d_j)^2,$$

где y_j – значение j -ого выхода нейросети, d_j – целевое значение j -ого выхода, p – число нейронов в выходном слое.

Успешность обучения зависит от ряда факторов:

- 1) Точность решения задачи.
Не следует требовать от сети точности, превышающей точность измерения данных.
- 2) Непротиворечивость задачника.
В задачнике не должны присутствовать вектора данных, у которых одинаковы входные сигналы и разные выходные. Перед обучением производится анализ обучающего множества, вычисляется выборочная константа Липшица, для обнаружения конфликтных примеров.
- 3) Выбор оптимальной архитектуры сети.
В геоинформационной системе “НейроИнформГео” реализованы сети слоистой архитектуры с возможностью произвольного выбора количества слоев нейронов и их количества в каждом слое, не зависящем от числа входных и выходных сигналов.
- 3) Алгоритм обучения сети.

В системе реализовано несколько методов обучения:

- а) Нейронные сети обратного распространения (*back propagation*).
- а) Градиентный спуск.
- б) Метод сопряженных градиентов (*Флетчера-Ривса*).

При формировании обучающей выборки, выборочная константа Липшица вычислялась для каждого цикла обучения, конфликтных примеров обнаружено не было. Вопрос выбора структуры (числа уровней, количества нейронов, типов связей) решался методом эмпирического подбора. Простейшие соображения, когда все параметры сети выбираются по максимуму “с запасом” просто не работают. Незадействованные свободные параметры сети начинают произвольным образом подстраиваться под шум и случайные выбросы обучающей выборки, отклоняя процесс обучения нейронной сети от оптимального. В результате исследования выбрана сеть слоистой архитектуры, где каждый нейрон в слое принимает все выходные сигналы нейронов предыдущего слоя, а его выходной сигнал рассылается всем нейронам следующего слоя. Всего 10 слоев по 30 нейронов в каждом скрытом слое. Передаточная функция нейронов выбрана сигмоидальная:

$$F(x) = \frac{x}{c + |x|},$$

где x – сигнал, поступающий с сумматора, c – константа, называемая характеристикой нейрона (параметр крутизны сигмоиды).

Выбор функции такого вида обусловлен тем, что она гладкая, непрерывная на всем диапазоне переменных X , диапазон значений всегда ограничен.

Функция ошибки $E(w)$ нейронной сети, благодаря тому, что в ней используются нелинейные пороговые функции, представляет собой довольно сложную “овражистую” поверхность с большим числом локальных минимумов, в связи с чем обучение нейронной сети производилось усовершенствованным методом обратного распространения ошибки, методом сопряженных градиентов (*Флетчера-Ривса*) [4].

Всего было обработано 64 скважины, по выше предложенной методике в 6 циклов обучения и распознавания (рис. 1). В одном цикле обучения участвуют только скважины с одинаковым комплексом ГИС.

На первом этапе в обучающую выборку были выбраны три скважины с наиболее полным отбором керн осинского горизонта билирской свиты из зон месторождения углеводородов с различным характером насыщения установленного по результатам испытания скважин

В каждом цикле обучения и распознавания точность решения задачи уменьшалась пропорционально сокращению использовавшегося комплек-

са ГИС. Каждая обучающая выборка тестировалась, при этом выводились значения полей файла данных, которые являлись выходными для сети (классы литотипов), и значения прогноза этих полей нейронной сетью. Далее рассчитывалась невязка между исходным и спрогнозированным значением, уровень уверенности сети в этом ответе. Определение уверенности заключалось в определении разности между максимальным значением выхода и значением другого выхода, которое является ближайшим к максимальному, таким образом, чем выше была уверенность, тем больше вероятность того, что сеть давала правильный ответ. Для каждой обучающей выборки выводится статистика правильности решения, табл. 2:

- а) “Правильно” – число правильных прогнозов (и % от общего числа примеров).
- б) “Неуверенно” – число правильных, но не 100 % уверенных прогнозов.
- в) “Неправильно” – число неправильных ответов сети.
- г) “Всего” – общее количество сделанных сетью прогнозов (решенных примеров).

Таблица 2. Результаты тестирования обучающих выборок

Цикл обучения	Комплекс ГИС	Правильно		Неуверенно		Неправильно		Всего
		кол.	%	кол.	%	кол.	%	
1	ГК, НГК, ДС, АК, ГГКП, МБК, БК	1523	99,61	4	0,26	2	0,13	1529
2	ГК, НГК, ДС, АК, МБК, БК	2042	97,70	39	1,87	9	0,43	2090
3	ГК, НГК, ДС, АК, БК	2404	95,43	88	3,49	27	1,08	2519
4	ГК, НГК, ДС, АК	2379	94,44	102	4,05	38	1,51	2519
5	ГК, НГК, ДС	1975	78,40	367	14,57	177	7,03	2519
6	ГК, НГК, АК	1705	67,69	523	20,76	291	11,55	2519

Количество примеров во 2 и 3 циклах обучения увеличивается с уменьшением комплекса ГИС табл. 2, что связано с необходимостью добавления в обучающую выборку данных по новым скважинам с представительным выходом керн, но отсутствием какого-либо из видов каротажа. В 4–6 циклах обучения количество примеров остается постоянным в связи с отсутствием скважин с представительным выходом керн, и как следствие, отсутствием возможности увеличить обучающую выборку.

Тестирование, прогноз, анализ. В скважинах, использовавшихся при обучении и прогнозе в первом цикле, был проведен наиболее полный комплекс ГИС, табл. 2. Всего в первый цикл обработано 24 скважины, три из которых были обучающими. При проверке обучающей выборки выбраны три скважины, проинтерпретированные по данным керн. В тестируемых скважинах был хороший выход керн, что позволило объективно оценить прогноз литотипов, выданный нейросетью.

Во второй цикл обучения вошли скважины без использования в комплексе ГИС плотностного ка-

ротажа. При обучении была добавлена еще одна скважина. Как видно из табл. 2, несмотря на увеличение обучающей выборки, правильно решенных примеров в обучающей выборке несколько меньше, чем при первом цикле обучения, что несомненно связано с отсутствием данных по плотностному каротажу. Всего во втором цикле обучения обработано 23 скважины с последующей проверкой результатов прогноза по имеющемуся керну в тестируемых скважинах.

В третьем цикле обучения отсутствовали данные микробоккового каротажа, в обучающую выборку добавлена еще одна скважина. Высокий процент правильно решенных примеров 95,43 % при тестировании обучающей выборки и после на тестовых скважинах табл. 2–3, показывает на незначительное влияние на обучающую выборку микробоккового каротажа, что подтвердилось при расчете коэффициентов значимости.

В 4–6 цикле обучения новых скважин в обучающую выборку добавлено не было, количество примеров остается постоянным. Количество правильно решенных примеров от 3-его цикла к 6-му уменьшается, что очевидно связано с постепенным уменьшением видов каротажа в использовавшемся комплексе ГИС. Результаты прогноза в данных циклах сопоставлялись непосредственно с ранее построенной литологической моделью. Наличие спрогнозированного коллектора подтверждалось данными прямых методов исследований, такими как гидродинамический каротаж и опробование пласта приборами на кабеле, а также прямыми качественными признаками, такими как проникновение в пласты фильтрата промывочной жидкости и др.




Рис. 2. Значимость видов каротажа при прогнозе литотипов

После обучения сети решать задачу (95,43 % – правильно), во всех циклах обучения вычислялись коэффициенты значимости входов нейронной сети.

Показатели значимости входных сигналов и элементов сети – по существу, вычисленные в линейном приближении абсолютные величины изменения функции оценки при удалении из сети элемента или входного сигнала [3]. При анализе значимо-

сти входов нейронной сети, необходимо чтобы возможные “выбывающие” примеры существенно не влияли на оценку значимости параметров, поэтому использовался метод вычисления средней величины модуля градиента входного параметра по всем примерам обучающей выборки. В нашем случае все входы (полный комплекс ГИС) оказались значимы. В общем, наблюдается следующая закономерность при вычислении коэффициентов значимости во всех циклах обучения нейросети (рис. 2). Низкий показатель значимости микробоккового каротажа можно объяснить влиянием на его показания промывочной жидкости и, как следствие, сильно зашумленными данными и плохой корреляцией с выделенными литотипами. Однако для выделения коллектора, включающего три литотипа, его значимость существенно увеличивается.

Использование данных только по трем видам каротажа (цикл 5, 6), оказывается недостаточным для уверенного выделения литотипов пород. Тем не менее, наблюдается высокий процент совпадения прогноза с принятой литологической моделью и прямыми методами исследований, подтверждающих наличие спрогнозированного коллектора, табл. 3.

Таблица 3. Результаты тестирования обученной нейронной сети на тестовых скважинах

Номер цикла обучения	Тестируемые скважины с хорошим выходом керна	Процент подтверждения прогноза с учетом совпадения ближайших литотипов с данными по керну	Процент совпадения прогноза коллектора с данными по керну
1	179_62	63,00	95,0
	179_82	70,60	
	179_60	75,71	
2	179_75	59,49	90,2
	179_70	75,30	
3	179_48	56,57	63,5
4	179_59	57,80	79,0
5, 6	В данных циклах отсутствуют скважины с представительным выходом керна для проверки		

Построение геологической модели. Обученная нейронная сеть использовалась при прогнозе литотипов по 64 скважинам. Достигнутый результат по тестовым скважинам указывает на существование явной зависимости показаний использованного полного комплекса ГИС от выделенных нами литотипов.

Результаты интерпретации геофизических исследований скважин математическим аппаратом обучаемых нейронных сетей, реализованным в геоинформационной системе “НейроИнформГео”, легли в основу построения геолого-геофизической модели месторождения.

СПИСОК ЛИТЕРАТУРЫ

1. Гафуров Д.О. Опыт обработки и интерпретации данных геофизических исследований скважин (ГИС) интеллектуальной геоинформационной системой «ИнформГео», на примере Тала-

канского нефтегазоконденсатного месторождения / Нейроинформатика и ее приложения: Матер. XII Всеросс. семинара / Под ред. А.Н. Горбаня, Е.М. Миркеса. – Красноярск: ИВМ СО РАН, 2004. – 196 с.

2. Гафуров О.М., Меркулов В.П., Городников М.А., Тищенко Г.И., Сысолятин Н.В. Инновационные методы и технологии нефтегазопроисловых работ и возможные пути их реализации в Томской области / Сб. научных статей: Инновационные методы и технологии нефтегазопроисловых работ и возможные пути их реализации в юго-восточных районах Западной Сибири / Под ред. О.М. Гафурова, Э.В. Кривошеева, Г.И. Тищенко, В.Е. Шафтельского, М.А. Городникова, А.И. Беккермана, В.П. Меркулова. – Томск: ООО «ИнформГеоСервис», «Томский ЦНТИ», 2000. – 177 с.
3. Методы нейронинформатики / Под ред. А.Н. Горбаня. – Красноярск: КГТУ, 1998. – 232 с.
4. Тютюрев В.В., Новосельцев В.Б. Теория нейронных сетей. – Томск: ТПУ, 2001. – 69 с.
5. Методические рекомендации по подсчету геологических запасов нефти и газа объемным методом / Под ред. В.И. Петерсилье, В.И. Пороскуна, Г.Г. Яценко. – М.-Тверь: ООО «Издательство ГЕРС», ВНИГНИ, НПЦ «Тверьгеофизика», 2003. – 256 с.

УДК 551.482.212

ХИМИЧЕСКИЙ СОСТАВ ДОННЫХ ОТЛОЖЕНИЙ РЕКИ ВАСЮГАН И ЕЕ ПРИТОКОВ

О.Г. Савичев, В.А. Базанов*

Томский политехнический университет
E-mail: OSavichev@mail.ru

*НИИ биологии и биофизики при Томском государственном университете

Приведены результаты изучения химического состава донных отложений реки Васюган Томской области и ее притоков. Установлен средний за 1997–2005 гг. уровень содержания нефтепродуктов и более 20-и химических элементов. Выявлены взаимосвязи между концентрациями нефтепродуктов и хлорид-иона в донных отложениях и речных водах. Показано, что донные отложения водотоков в среднем по бассейну реки Васюган характеризуются как умеренно загрязненные и загрязненные.

Введение

Процессы взаимодействия речных вод с донными отложениями играют весьма важную роль в формировании экологического состояния водных объектов, что и определяет необходимость изучения геохимии донных отложений. Особый интерес подобные работы представляют в случае речных систем, испытывающих значительную антропогенную нагрузку, поскольку при этом может происходить как самоочищение вод, так и их вторичное загрязнение. С учетом этого авторами в продолжение и дальнейшее развитие собственных работ и исследований других специалистов [1–3] были выполнены обобщение и анализ имеющейся информации о химическом составе донных отложений реки Васюган Томской области, ее притоков Черталы, Чижалки, Еленкулуныя, Лонтынь-Яха, Махни и ряда малых рек первого и второго порядков (рис.).

Указанные водотоки объединяет характер антропогенного воздействия на их экосистемы, связанного с добычей и транспортировкой нефти и газа. Следствием этого влияния, по данным [1, 3, 4], стало загрязнение речных вод и донных отложений в бассейне р. Васюган нефтепродуктами. Однако его масштабы и реакция водных экосистем до сих пор изучены недостаточно полно. В частности, в настоящее время ощущается дефицит достоверных данных о фоновых содержаниях химических элементов в донных отложениях региона, механизме самоочищения речных вод и донных отложений, трансформации их химического состава по мере изменения порядка водотоков и т.д.




Рисунок. Схема расположения пунктов опробования донных отложений реки Васюган и ее притоков в 1997–2005 гг.

Методика исследований

В процессе выполненных исследований, в соответствии с требованиями [5], были выполнены полевые работы по отбору проб донных отложений и воды, определение их химического состава в аккредитованных лабораториях Томского политехнического университета (ТПУ), ОАО «Томскгеомониторинг», Томской геолого-разведочной экспедиции (микроэлементы – полуколичественный спектраль-