

## ЛИТОФАЦИАЛЬНЫЙ АНАЛИЗ И ВОЗМОЖНОСТИ ПРОГНОЗИРОВАНИЯ СВОЙСТВ ПО ДАННЫМ ГЕОФИЗИЧЕСКИХ ИССЛЕДОВАНИЙ И СЕЙСМОРАЗВЕДКИ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Е.С. Колбикова

*Успешность стратегии разработки любого месторождения зависит от степени изученности геологического строения его основных резервуаров. По мере разбуривания площади представление о строении залежи углеводородов уточняется, но в случае сложной структуры пустотного пространства резервуаров и литологической неоднородности разреза по площади геологические неопределённости и риски при последующем заложении скважин остаются высокими. По этим причинам одними из основных проблем при добыче углеводородов являются прогнозирование типов горных пород и распределение содержания флюидов по всему коллектору вдали от скважин, поскольку определение свойств горных пород является основным источником неопределённости в исследованиях моделирования коллектора [1, 2]. В предлагаемом проекте будут продемонстрированы алгоритмы, основанные на методах машинного обучения, которые позволяют прогнозировать распределение литологии и неопределённость литофациальной изменчивости в разрезе.*

*Ключевые слова: классификация, методы машинного обучения, литотипизация, прогноз фаций, кластерная модель, прогнозирование свойств, уточнение ФЕС.*

Классификация данных основывалась на детальном описании литологических характеристик отложений целевого объекта. Объект представлен отложениями девонского возраста преимущественно карбонатными отложениями, относящимися к фаменскому ярусу.

Для литотипизации карбонатных отложений фаменского яруса использовались результаты ядерных исследований, в результате которых на основе макроописания образцов керна были выделены основные литологические разности с учётом коллекторского потенциала горных пород.

Настройка кластерной модели, позволяющей решать задачи как по литотипизации разреза, так и по прогнозу характера насыщения, выполнялась в несколько этапов.

В начале процесса выполнялась настройка кластерной модели, позволяющей выделить классы известняков с учётом их коллекторского потенциала. На этапе на-

стройки фациальной модели по данным геофизических исследований (далее – ГИС) и керна использовался многомерный статистический алгоритм распознавания MRGC, обеспечивающий эффективную интеграцию геолого-геофизической информации. Алгоритм основан на методе К-ближайших соседей и путём комбинирования различных критериев позволяет решать проблему нелинейности связей между каротажными откликами и соответствующей им литологией [3–5]. В качестве обучения использовался набор модельных кривых, представляющий из себя комплекс методов ГИС. В качестве ассоциированной кривой для сравнения электрофаций с литологической кривой использовался результат фациального деления, выполненного по данным макроописания керна. Обученная модель распознала группу литофаций и позволила дифференцировать 5 литологических разностей, в т.ч. 2 литотипа в интервалах коллекторов – грейнстоуны с высоким

и умеренным коллекторским потенциалом. Пример настроенной фациальной модели и распространённой на весь интервал исследования в одной из скважин приведён

на рис. 1. В результате было выполнено распространение полученных литотипов на 10 скв. из различных фациальных зон.

Результаты классификации также были




Рисунок 1. Литофациальная модель по данным ГИС и керна

использованы для настройки зависимости проницаемости от пористости  $K_{пр} = f(K_p)$  на керне. В результате уточнения зависимостей с учётом выделенных фациальных групп и получения двух регрессий в интервале коллекторов удалось получить луч-

шую согласованность между прогнозными значениями проницаемости по ГИС и  $K_{пр}$  по гидродинамическому каротажу в целевом интервале (рис. 2).

В рамках второго этапа моделирования электрофаций осуществлялось дальней-




Рисунок 2. Уточнение прогнозных значений Kpr по ГИС

шее обучение модели с привлечением различных методов удельного электрического сопротивления (индукционного и бокового каротажа), а также результатов опробования и интерпретации геофизических исследований скважин в целях получения фациальной модели, позволяющей дифференцировать коллекторы с различным типом насыщения. После обучения в целях проверки качества кластерной модели был выполнен анализ подобия алгоритмом Similarity Threshold Method для проверки когерентности между модельными (обучение выполнялось по трем скважинам) и обрабатываемыми данными (интервалы и скважины, на которые распространялась фациальная модель). На финальной стадии подготовки итоговой фациальной модели для её последующего распространения в объёме выполнялся апскейлинг, т.е. масштабирование фаций (рис. 3), с учётом

вертикального разрешения сейсмических данных.

Процесс распространения литологической информации в межскважинное пространство был выполнен с применением алгоритма Democratic Neural Networks Association и включал в себя несколько этапов.

На первом этапе осуществлялся подбор входной информации и оценка её качества. Рассчитывались кубы сейсмических атрибутов, и наиболее репрезентативные, показывающие наибольшую дифференциацию фаций, подавались на вход следующего этапа, в рамках которого выбранные кубы сейсмических атрибутов и сглаженные исходные литологические кривые объединялись в единый набор данных, на основе которого происходило обучение нейронных сетей. Верификация результатов прогноза осуществлялась с помощью «слепой» скважины. В результате были




Рисунок 3. Итоговые масштабированные фации по ГИС

получены кубы литофаций (рис. 4) и кубы вероятности существования различных литотипов [3].

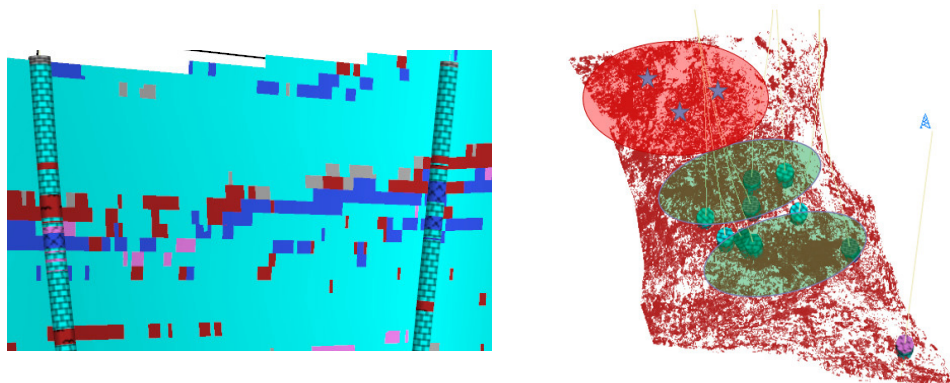
На основании сравнения карт распределения нефтенасыщенности по данным кластерного анализа (рис. 5) с картой начальных нефтенасыщенных толщин по целевому горизонту следует отметить относительно высокую сходимость основных продуктивных зон. В центральной области месторождения, отмечающейся значительной разбуренностью, наблюдается самый большой этаж нефтеносности, в то время как краевые области месторождения, осложнённые покрывками и несколькими гидродинамически изолированными залежами, мало изучены на текущий момент и представляют большой интерес в плане перспективности. Выделенная по результатам кластерного анализа зона повышенного нефтенасыщения на севере месторождения, вероятно, связана с насыщением перспективных пачек, и с целью

доразведки в данную зону будет рекомендовано бурение пилотных стволов трёх скважин [6].

Классические атрибуты и инверсия демонстрируют ограничения при описании гетерогенной модели насыщения. Применение нейросетевых подходов позволяет настроить сложные, неочевидные и нелинейные зависимости, недоступные классическим методам.

Совокупный анализ всей доступной скважинной и сейсмической информации методами машинного обучения позволил выполнить прогноз пространственного развития фаций, выделенных по скважинным данным. Достигнуто повышение детальности и достоверности интерпретации. Уточнены перспективные зоны с улучшенными коллекторскими свойствами и повышенной нефтенасыщенностью на изучаемой площади, минимизированы геологические риски при последующем заложении скважин.

Использование небольшого объёма



**Рисунок 5. Объемное распределение нефтенасыщенных фаций**

разномасштабной геолого-геофизической информации с применением Machine Learning алгоритмов в области промыслово-геофизической и сейсмической интерпретации позволяет достичь повышения достоверности интерпретации и уточне-

ния местоположения перспективных зон с улучшенными коллекторскими свойствами на изучаемой площади, а также минимизировать геологические риски при последующем заложении скважин [6].

#### **Список использованной литературы**

1. Hami-Eddine K., Klein P., and Richard L. Well Facies-based supervised classification on prestack. – SEG Annual Meeting, Houston, Texas, October 2009.
2. Hami-Eddine K., Klein P., Richard L., de Ribet B. and Grout M., A new technique for lithology and fluid content prediction from prestack data: An application to a carbonate reservoir. – The 13th SEGJ International Symposium, Tokyo, Japan, April 2019.
3. Ye Shin-Ju, Rabiller P. A new tool for electrofacies analysis: Multi-Resolution Graph-Based Clustering. – 41st Annual Logging Symposium SPWLA, 2000.
4. Ye Shin-Ju, Rabiller P. Automated Electrofacies Ordering. – Petrophysics, 2005, v. 46, N 6.
5. Zhou Y., and Goldman S. Democratic co-learning. – 16th IEEE International Conference on Tools with Artificial Intelligence, 2004.
6. Kolbikova E., Gusev S., Garaev A., Malinovskaya O., Kamilevich R. Forecast of prospective oil saturation zones in the Devonian carbonate deposits of the Kharyaginsky field based on geological and geophysical information analysis by using machine learning methods. – SPE-206520, SPE Russian Petroleum Technology Conference, 2021.

## **ЛИТОФАЦИАЛДЫҚ ТАЛДАУ ЖӘНЕ ГЕОФИЗИКАЛЫҚ ЗЕРТТЕУЛЕР МЕН СЕЙСМОБАРЛАУ ДЕРЕКТЕРІ БОЙЫНША ҚОЙНАУҚАТ ҚАСИЕТТЕРІН МАШИНАЛЫҚ ӨНДЕУ АРҚЫЛЫ БОЛЖАУ МҮМКІНДІКТЕРІ**

**Е.С. Колбикова**

*Кез-келген кен-орнын игеру стратегиясының сәттілігі оның негізгі қойнауқаттардың геологиялық құрылымын зерттеу дәрежесіне байланысты.*

Алаңды бұрғылау дәрежесі артқан сайын көмірсутегі кен-орнының құрылымы туралы түсінік нақтылана түседі, дегенмен қойнауқаттар қуыс-кеңістігінің күрделі құрылымы және аудан бойынша қимасының литологиялық жағынан түрлі болуына байланысты геологиялық белгісіздіктер мен ұңғымалардың орнын кейіннен таңдау қауіпті тәуекелдерді жоғарылатады. Осы себептерге байланысты көмірсутектер өндірісіндегі негізгі проблемалардың бірі - тау жыныстарының түрлерін болжау және ұңғымалардан алыс тұрған коллекторлардағы сұйықтықтың таралуы болып табылады. Өйткені, тау жыныстарының қасиеттерін анықтау коллекторлық модельдеу зерттеулеріндегі белгісіздіктің негізгі себебі болып саналады [1, 2]. Ұсынылған жобада қойнауқаттардың литологиялық қалыптасуы мен секцияда литофаксиялық өзгеріштіктің белгісіздігін болжауға мүмкіндік беретін есептеуші машинаны пайдаланып оқыту әдістеріне негізделген Алгоритмдер көрсетілген.

Түйін-сөздер: жіктеу, машиналық өңдеу әдістері, литологиялық түрлерге бөлу, фациялық болжау, кластерлік нұсқа (модель), қасиеттерді болжау, ФКҚ нақтылау.

## LITHOFACIAL ANALYSIS AND POSSIBILITIES FOR PREDICTION OF PROPERTIES ON GEOPHYSICAL RESEARCH AND SEISMIC EXPLORATION DATA BY METHODS OF MACHINE LEARNING

E.S. Kolbikova

*The success of a development strategy for any field depends on the degree of knowledge of the geological structure of its main reservoirs. As the area is drilled out, the concept of the structure of the hydrocarbon accumulation is refined, but in the case of a complex structure of the void space of the reservoirs and the lithological heterogeneity of the section over the area, geological uncertainties and risks during the subsequent placement of wells remain high. For these reasons, one of the main problems in hydrocarbon production is predicting rock types and the distribution of fluids throughout the reservoir away from wells, since the determination of rock properties is a major source of uncertainty in reservoir modeling studies [1, 2]. The proposed project will demonstrate algorithms based on machine learning methods that allow predicting the distribution of lithology and the uncertainty of lithofacies variability in the section.*

*Key words: classification, machine learning methods, lithotyping, facies forecast, cluster model, property prediction, specification of reservoir properties.*

### Информация об авторе

**Колбикова Елена Сергеевна** – руководитель направления по петрофизике и интерпретации ГИС.

ООО «Роксар Парадайм – ПО и Решения», г. Москва, Россия