DOI: 10.24412/2076-6785-2022-8-36-39 УДК 004.855.5 I Научная статья

# Сравнительный анализ применения 2D/3D сегментационных моделей в задаче выделения сейсмических горизонтов

**Канониров А.П.**
ООО «Тюменский нефтяной научный центр», Тюмень, Россия
apkanonirov@tnnc.rosneft.ru

## Аннотация
**В данной работе сравнивается два подхода к решению задачи выделения сейсмических горизонтов по частично заданным положениям горизонтов в кубе сейсмических амплитуд. Первый подход заключается в обучении нейронной сети архитектуры U-Net для двумерных данных по продольным и поперечным срезам куба, второй подход — в преобразовании стандартной архитектуры U-Net в трехмерную и обучении по 3D-кубам сейсмических данных. Оба подхода протестированы на данных по месторождению F3 Netherlands, находящихся в открытом доступе. Трехмерная модель дает более точный прогноз, а двухмерная модель обучается в разы быстрее и требует меньших вычислительных ресурсов.**

**Материалы и методы**
Выполнен сравнительный анализ качества решения задачи выделения сейсмических горизонтов для 2D- и 3D-архитектур сегментационной сверточной нейронной сети U-Net, определены достоинства и недостатки каждого из подходов. Приведены практические рекомендации по оценке и обучению моделей на новых данных.

**Ключевые слова**
сейсморазведка, метод отраженных волн, геология, сегментация, компьютерное зрение, U-Net, сейсмические горизонты, нейронные сети

**Для цитирования**
Канониров А.П. Сравнительный анализ применения 2D/3D сегментационных моделей в задаче выделения сейсмических горизонтов // Экспозиция Нефть Газ. 2022. № 8. С. 36–39. DOI: 10.24412/2076-6785-2022-8-36-39

**Поступила в редакцию:** 21.11.2022


UDC 004.855.5 I Original paper

# Comparative analysis of the application of 2D/3D segmentation models in the task of identifying seismic horizons

**Kanonirov A.P.**
“Tyumen petroleum research center” LLC, Tyumen, Russia
apkanonirov@tnnc.rosneft.ru

## Abstract
**In this paper, two approaches to solving the problem of identifying seismic horizons by partially specified positions of horizons in a cube of seismic amplitudes are compared. The first approach is to train a neural network of the U-Net architecture for two-dimensional data on longitudinal and transverse sections of the cube. The second approach is to transform the standard U-Net architecture into a three-dimensional one and train it on 3D cubes of seismic data. Both approaches have been tested on publicly available data on the F3 Netherlands field. A three-dimensional model gives a more accurate forecast, and a two-dimensional model learns much faster and requires fewer computing resources.**

**Materials and methods**
A comparative analysis of the quality of solving the problem of seismic horizons allocation for 2D and 3D architectures of the segmentation convolutional neural network U-Net is performed. The advantages and disadvantages of each of the approaches are determined. Practical recommendations for evaluating and training models on new data are given.

**Keywords**
seismic exploration, reflected wave method, geology, segmentation, computer vision, U-Net, seismic horizons, neural networks

**For citation**
Kanonirov A.P. Comparative analysis of the application of 2D/3D segmentation models in the task of identifying seismic horizons. Exposition Oil Gas, 2022, issue 8, P. 36–39. (In Russ). DOI: 10.24412/2076-6785-2022-8-36-39

**Received:** 21.11.2022

Сейсморазведка методом отраженных волн является популярным методом поиска углеводородов. Проходя через геологические слои с разными свойствами, сейсмические волны предоставляют информацию о геофизических характеристиках возможного нефтяного месторождения, позволяющую сформировать двумерное изображение — сейсмический разрез (2D) или трехмерный массив данных – сейсмический куб (3D). Их анализ помогает экспертам находить потенциальные залежи нефти и лучше планировать буровые работы. Точная оценка необходимости в дополнительном бурении также снижает воздействие на окружающую среду. Поскольку понимание геологической структуры возможных запасов углеводородов имеет решающее значение, а объем данных сейсмической разведки возрастает, появляется острая необходимость в разработке методов автоматизации контроля качества получаемой информации [1] и ее интерпретации.

С увеличением вычислительных мощностей и накоплением больших объемов данных получило широкое распространение применение нейронных сетей для решения различных задач нефтегазовой отрасли, например, классификация пород по фотографиям керна [2]. В этом исследовании сравниваются два метода определения породы на основе методов машинного обучения: графические идентификаторы и сверточные нейронные сети. Сверточные нейронные сети — ResNet, ResNeXt и Inception — сравнивались с классификатором XGBoost на основе двух типов графических идентификаторов: цвета (средний цвет, преобладающие цвета) и текстуры (энтропия, число Эйлера, контрастность, однородность).

Сверточные нейронные сети (CNN) — архитектура нейронных сетей, которая состоит из сверточных слоев, способных автоматически выделять наиболее полезные признаки. Начальные слои служат для выделения общих признаков, таких как края, цвета и формы. Затем глубокие слои на основе общих признаков строят более специфические, что позволяет, фильтруя маловажные детали и выделяя существенное, описывать пространственные и временные зависимости в изображении [11].

Нейронные сети для семантической сегментации представляют собой архитектуру кодер-декодер, которая состоит из сверточных слоев [12]. Кодировщик в данной архитектуре служит для обнаружения и классификации объектов, а декодировщик необходим для локализации объекта. Семантическая сегментация — это процесс, при котором каждому пикселю на изображении ставится в соответствие подходящая ему метка определенного класса.

Обработка сейсмических данных включает в себя решение таких задач, как классификация и сегментация. В [13] представлена новая архитектура CNN, которая используется для обнаружения соли, анализируя подаваемые ей на вход кубы сейсмических данных. В [14] CNN используется для обнаружения разломов в трехмерных сейсмических данных. Вход в сеть состоит из трех ортогональных срезов 24×24, а линии на пересечении классифицируются как разлом или не разлом. Также фильтрация шума, выделение разломов и фаций для сейсмических данных с помощью нейронных сетей представлены в исследованиях [7, 8, 9], а в работах [4, 5] они применяются для трассировки сейсмических горизонтов.

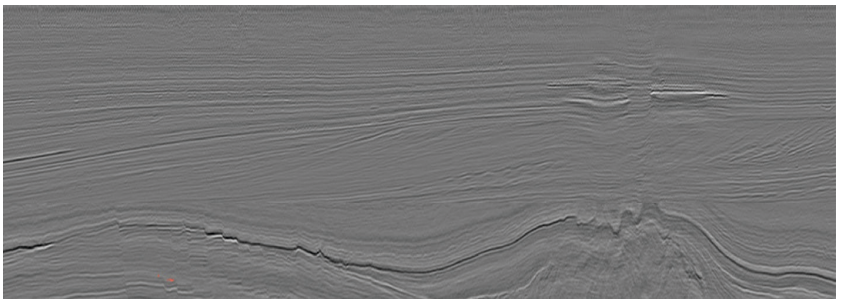

*Рис. 1. Пример изображения сейсмических данных с линией горизонта*
*Fig. 1. An example of an image of seismic data with a horizon line*

В работе рассматривается задача трассировки сейсмических горизонтов по данным сейсмических амплитуд, заданных в виде трехмерного куба. Сейсмический горизонт — это граница между двумя различными типами пород, в простых случаях она хорошо прослеживается на двумерных срезах. Такая граница представляет собой поверхность, которую можно провести внутри куба.

Современный подход к трассировке сейсмических горизонтов сводится к решению задачи сегментации с помощью сверточных нейронных сетей, которым на вход подается куб сейсмических амплитуд, на выходе получается куб вероятностей наличия сейсмического горизонта [11].

Целью данного исследования было на примере сегментационной сверточной нейронной сети U-Net сравнить качество решения задачи выделения сейсмических горизонтов для 2D- и 3D-данных.

Оба подхода используют одинаковый набор входных данных по месторождению F3 Netherlands, сбор которых был произведен в Северном море. Данные находятся в открытом доступе и содержат информацию 9 горизонтов и журналы бурения 4 скважин [3].

Представленный набор данных состоит из горизонтов в формате XYZ и 3 204 изображений, представляющих собой 1 602 сейсмические линии в формате TIFF и 1 602 помеченных изображения в формате PNG (рис. 1). Помеченные изображения были созданы путем взятия пересечения между сейсмическими линиями и горизонтальными поверхностями.

Для сравнения двухмерной и трехмерной архитектур U-Net обучающий набор входных данных был представлен как куб сейсмических амплитуд $H$ — матрица размерности $il \times xl \times t$, где $il$, $xl$ — количество ячеек куба в продольном и поперечном направлениях; $t$ — количество временных отсчетов. Отметки трассируемого горизонта заданы матрицей $L$ той же размерности, что $H$. Матрица $L$ при этом может содержать три значения: 0 — горизонт отсутствует, 1 — горизонт присутствует, -100 — нет информации. Стоит отметить, что эксперт, заполняющий матрицу $L$, может заполнять ее как по выбранным срезам в продольном и поперечном направлениях, так и по отдельным трассам/участкам.

В работе используется модификация ставшей уже классической нейронной сети U-Net [6] (рис. 2), оптимизированной для решения задачи выделения сейсмических горизонтов [4].

Для двумерных и трехмерных данных используется одинаковая ее архитектура, единственное отличие — это размерности операторов свертки, нормализации (BN) и пулинга (maxpool). Для 2D-варианта нейросети на вход подается срез сейсмического куба Q размерности $M \times N$, для 3D-варианта — это будет куб размерности $M \times N \times N$, где $M$ — количество отсчетов по вертикали (временная шкала), $N$ — количество отсчетов по горизонтали. На выходе получается соответствующего

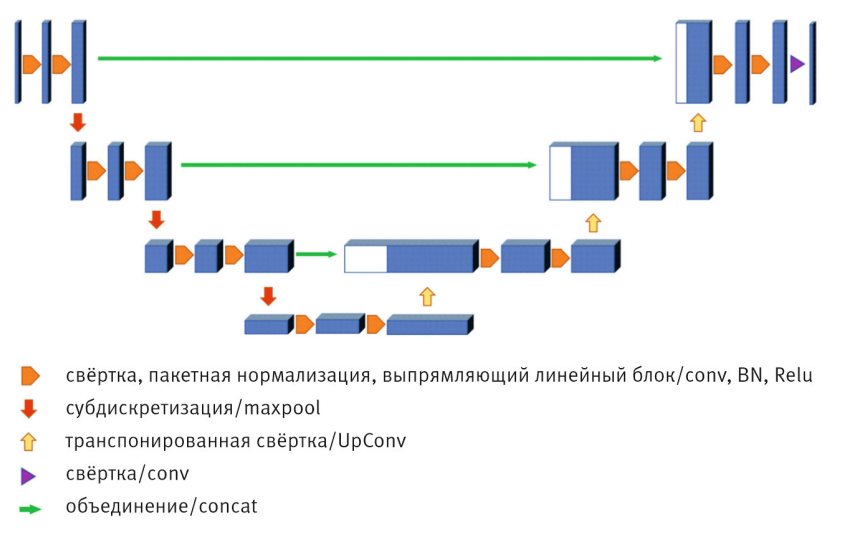


*Рис. 2. Архитектура сети U-Net*
*Fig. 2. U-Net network architecture*

размера матрица, содержащая значения вероятностей наличия горизонта.

Для оценки качества выделения сейсмических горизонтов с помощью 2D- и 3D-архитектур U-Net используется метрика DICE [10]. Обозначая пиксели, принадлежащие истинному положению горизонта, как A, а пиксели, принадлежащие к предсказанному положению, как B, метрика DICE вычисляется по формуле (1):

$$D(A,B)=\frac{2\times|A\cap B|}{|A|\cup|B|}. \qquad (1)$$

Трассировка и оценка полученных результатов для 2D- и 3D-подходов производилась по каждому из 9 горизонтов. Все вычисления производились с помощью видеокарты NVIDIA GeForce GTX 1650 MAX-Q. Общее время обучения для 2D-архитектуры заняло 4,3 часа, а для 3D — 12,8 часа. Ниже представлена таблица с данными метрики качества экспериментов на тестовой выборке.

Подход на основе 3D-архитектуры показывает более точные результаты для всех горизонтов, чем 2D. Средний прирост метрики на 0,1 можно считать значимым результатом, поскольку границы сегментируемых горизонтов являются довольно тонкими линиями, а значит, увеличение значения качества сегментации достигается за счет выделения более сложных зависимостей, например, резких изгибов. На рисунке 3 в левом столбце изображены результаты сегментации 2D-архитектуры, а в правом — 3D.

Такой эффект достигается потому, что 3D U-Net решает поставленную задачу, используя трехмерные сверточные ядра, которые позволяют использовать межсрезовый контекст внутри сейсмического куба, что и приводит к повышению производительности. Однако увеличиваются и вычислительные затраты в результате увеличения количества параметров нейронной сети.

*Табл. 1. Значения метрики качества для 2D- и 3D-архитектур*
*Tab. 1. Quality metric values for 2D and 3D architectures*

| Горизонт | DICE | |
|---|---|---|
| | 2D | 3D |
| H1 | 0,83 | 0,96 |
| H2 | 0,88 | 0,94 |
| H3 | 0,75 | 0,93 |
| H4 | 0,72 | 0,85 |
| H5 | 0,77 | 0,91 |
| H6 | 0,80 | 0,87 |
| H7 | 0,72 | 0,83 |
| H8 | 0,81 | 0,95 |
| H9 | 0,90 | 0,98 |
| H1–H9 | Среднее значение DICE | |
| | 0,798 | 0,913 |

**Итоги**

Из результатов экспериментов, представленных в таблице 1, следует, что оба подхода показывают высокое качество сегментации сейсмических горизонтов. Для обучения 2D U-Net требуется в разы меньше временных затрат, но при этом теряется пространственная информация о зависимостях между срезами одного сейсмического куба.

На практике предлагается использовать сначала архитектуру на основе 2D, так как это позволит чаще проводить повторные эксперименты и таким образом более точно настроить гиперпараметры модели. Если полученное качество сегментации не является удовлетворительным, то стоит попробовать подход на основе 3D-архитектуры, уменьшив количество экземпляров в обучающей выборке, что позволит увеличить количество экспериментов для настройки гиперпараметров перед основным этапом обучения.

**Выводы**

Результаты исследования могут быть использованы как при обучении моделей для сегментирования сейсмических горизонтов на новых обучающих образцах, так и при решении других задач сегментации на трехмерных данных.

**Литература**

1 Щербич А.Ю., Кутрунов В.Н. Алгоритм расчета выпукло-вогнутого контура площади сейсмической съемки // Вестник

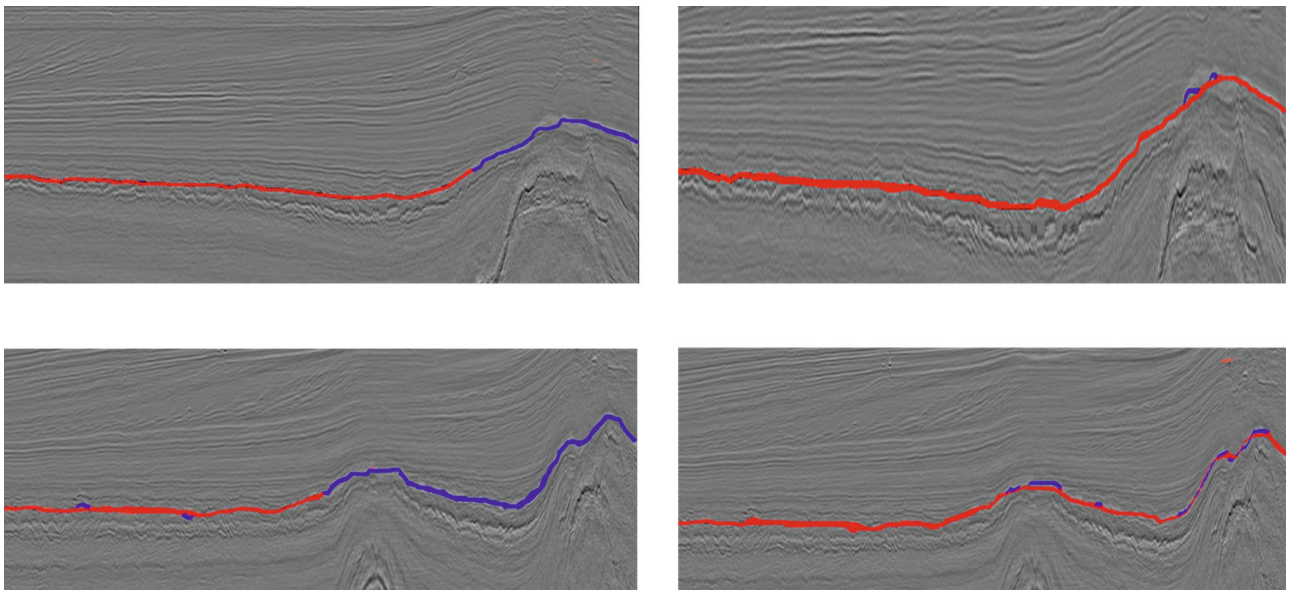

*Рис. 3. Сегментированные линии горизонта. Красный цвет — результат выделения нейронной сетью. Синий цвет — реальная траектория линии горизонта*
*Fig. 3. Segmented horizon lines. The red color is the result of selection by the neural network. Blue color is the real trajectory of the horizon line*

ТюмГУ. Физико-математические науки. Информатика 2014. № 7. С. 166–177.
2 Дьячков С.М. Ядрышникова О.А., Поляков Д.В., Девятка Н.П., Чермянин П.И., Дмитриевский М.В. Автоматическое определение породы по фотографиям керна современными методами машинного обучения // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2021. Том 7. № 4. С. 181–198.
3 Silva R., Baroni L., Ferreira R., Civitarese D., Szwarcman D., Brazil E.V. Netherlands Dataset: A new public dataset for machine learning in seismic interpretation. ArXiv. Computer science, 2019, 6 p. (In Eng).
4 Koryagin A., Mylzenova D., Khudorozhkov R., Tsimfer S. Seismic horizon detection with neural networks. ArXiv. Geology, 2020. 5 p. (In Eng).
5 Tschannen V., Delescluse M, Ettrich N., Keuper J. Extracting horizon surfaces from 3D seismic data using deep learning. Geophysics, 2020, Vol. 85, P. 17–26. (In Eng).
5 Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Lecture notes in computer science, Vol. 9351, P. 234–241. (In Eng).
7 Alaudah Y, Michalowicz P., Alfarraj M., Al-Regib G. A Machine learning benchmark for facies classification. ArXiv. Computer Science, Geology, 2019, 13 p. (In Eng).
8 Abid B., Khan B.M, Memon R.A. Seismic facies segmentation using ensemble of convolutional neural networks. Hindawi. Wireless communications and mobile computing, 2022, Vol. 2022, 13 p. (In Eng).
9 Civitarese D., Szwarcman D., Brazil E.V., Zadrozny B. Semantic Segmentation of Seismic Images. ArXiv. Geology, Computer Science, 2019, 7 p. (In Eng).
10 Bertels J., Eelbode T., Berman M., Vandermeulen D., Maes F., Bisschops R., Blaschko M.B. Optimizing the dice score and jaccard index for medical image segmentation: theory and practice. ArXiv, 2019, 9 p. (In Eng).
11 Aloysius N., Geetha M. A review on deep convolutional neural networks. International conference on communication and signal processing, India, 2017, April 6–8, 5 p. (In Eng).
12 Badrinarayanan V., Kendall A., Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. IEEE Transactions on pattern analysis and machine intelligence, 2017, Vol. 39, issue 12, P. 2481–2495. (In Eng).
13 Waldeland A.U., Jensen A.C., Gelius L.J., Solberg A. Convolutional neural networks for automated seismic interpretation. The Leading Edge, 2018, Vol. 37, issue 7, P. 529–537. (In Eng).
14 Wei Xiong, Xu Ji, Yue Ma, Yuxiang Wang, Nasher M. AlBinHassan, Mustafa N. Ali, Yi Luo. Seismic fault detection with convolutional neural network. Geophysics, 2018, Vol. 83, issue 5, P. 97–103. (In Eng).

## ENGLISH

**Results**

From the experimental results presented in table 1, it follows that both approaches show high quality segmentation of seismic horizons. It takes several times less time to train 2D U-Net, but at the same time, spatial information about the dependencies between slices of one seismic cube is lost.

In practice, for the first step recommend to use a 2D-based architecture, since this will allow repeated experiments to be carried out more often and thus more precisely adjust the hyperparameters of the model. If the resulting segmentation quality is not satisfactory, then it is worth trying a 3D architecture-based approach by reducing the number of instances in the training sample, which will increase the number of experiments to configure hyperparameters before the main stage of training.

**Conclusions**

The results of the study can be used both in training models for segmentation of seismic horizons on new training samples, and in solving other segmentation problems on three-dimensional data.

**References**

1. Shcherbich A.Yu., Kutrunov V.N. Computation algorithm of convexo-concave contour of the seismic survey. Bulletin of TSU. Physical and mathematical sciences. Informatics, 2014, issue 7, P. 166–177. (In Russ).
2. Dyachkov S.M., Yadryshnikova O.A., Polyakov D.V., Devyatka N.P., Chermyanin P.I., Dmitrievskiy M.V. Automatic rock identification from core photos using modern machine learning methids. Tyumen state university herald. Physical and mathematical modeling. Oil, gas, energy, 2021, Vol. 7, issue 4, P. 181–198. (In Russ).
3. Silva R, Baroni L., Ferreira R., Civitarese D., Szwarcman D., Brazil E.V. Netherlands Dataset: A new public dataset for machine learning in seismic interpretation. ArXiv, Computer Science, 2019, 6 p. (In Eng).
4. Koryagin A., Mylzenova D., Khudorozhkov R., Tsimfer S. Seismic horizon detection with neural networks. ArXiv. Geology, 2020. 5 p. (In Eng).
5. Tschannen V., Delescluse M, Ettrich N., Keuper J. Extracting horizon surfaces from 3D seismic data using deep learning. Geophysics, 2020, Vol. 85, P. 17–26. (In Eng).
6. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Lecture notes in computer science, Vol. 9351, P. 234–241. (In Eng).
7. Alaudah Y, Michalowicz P., Alfarraj M., Al-Regib G. A Machine learning benchmark for facies classification. ArXiv. Computer Science, Geology, 2019, 13 p. (In Eng).
8. Abid B., Khan B.M, Memon R.A. Seismic facies segmentation using ensemble of convolutional neural networks. Hindawi. Wireless communications and mobile computing, 2022, Vol. 2022, 13 p. (In Eng).
9. Civitarese D., Szwarcman D., Brazil E.V., Zadrozny B. Semantic Segmentation of Seismic Images. ArXiv. Geology, Computer Science, 2019, 7 p. (In Eng).
10. Bertels J., Eelbode T., Berman M., Vandermeulen D., Maes F., Bisschops R., Blaschko B.M. Optimizing the dice score and jaccard index for medical image segmentation: theory and practice. ArXiv, 2019, 9 p. (In Eng).
11. Aloysius N., Geetha M. A review on deep convolutional neural networks. International conference on communication and signal processing, India, 2017 April 6–8, 5 p. (In Eng).
12. Badrinarayanan V., Kendall A., Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. IEEE Transactions on pattern analysis and machine intelligence, 2017, Vol. 39, issue 12, P. 2481–2495. (In Eng).
13. Waldeland A.U., Jensen A.C., Gelius L.J., Solberg A. Convolutional neural networks for automated seismic interpretation. The Leading Edge, 2018, Vol. 37, issue 7, P. 529–537. (In Eng).
14. Wei Xiong, Xu Ji, Yue Ma, Yuxiang Wang, Nasher M. AlBinHassan, Mustafa N. Ali, Yi Luo. Seismic fault detection with convolutional neural network. Geophysics, 2018, Vol. 83, issue 5, P. 97–103. (In Eng).

**ИНФОРМАЦИЯ ОБ АВТОРАХ I INFORMATION ABOUT THE AUTHORS**

**Канониров Александр Петрович,** ведущий специалист отдела прототипов и развития технологий,
ООО «Тюменский нефтяной научный центр», Тюмень, Россия
**Для контактов: apkanonirov@tnnc.rosneft.ru**

**Kanonirov Alexander Petrovich,** leading specialist of the department of prototypes and technology development,
“Tyumen petroleum research center” LLC, Tyumen, Russia
**Corresponding author: apkanonirov@tnnc.rosneft.ru**