

УДК 004.8:551.24

## СИСТЕМА КАРТИРОВАНИЯ ЕСТЕСТВЕННЫХ КАНАЛОВ ФИЛЬТРАЦИИ НА ОСНОВЕ ДАННЫХ СЕЙСМОРАЗВЕДКИ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

А. В. ВОХМИНЦЕВ<sup>1</sup>, А. В. МЕЛЬНИКОВ<sup>2</sup>

<sup>1</sup>vav@csu.ru, <sup>2</sup>MelnikovAV@uriit.ru

<sup>1</sup>ФГБОУ ВО «Челябинский государственный университет» (ЧелГУ)

<sup>1,2</sup>ОАО «Югорский государственный университет» (ЮГУ)

<sup>2</sup>Югорский научно-исследовательский институт информационных технологий (ЮНИИТ)

*Поступила в редакцию 12.04.2021*

**Аннотация.** Предложена система для решения задачи интерпретации зон трещиноватостей, использующая анализ сейсмических срезов на двумерных изображениях с использованием техник глубокого машинного обучения. Предложенная система основана на методе картирования каналов фильтрации на основе данных сейсморазведки, алгоритме выбора признаков на основе автокодировщика и алгоритме синтеза новых изображений на основе генеративных состязательных сетей. Автокодировщики обеспечивают высокую информативность с низкой внутрикласовой и высокой межкласовой вариативностью. Для обучения нейронной сети использована выборка данных на основе базы данных сейсморазведочной информации с положением ранее закартированных зон трещиноватости в объеме 70 разрезов волнового поля для месторождений нефти и газа в Ямало-Ненецком и Ханты-Мансийском автономном округе. Проведено компьютерное моделирование для задачи идентификации геологических слоев на двумерных срезах сейсмокуба, полученные результаты моделирования представлены и обсуждены.

**Ключевые слова:** картирование трещинных систем; сейсморазведка; методы машинного обучения и искусственного интеллекта; автокодировщик; геологический срез; генеративная состязательная сеть.

### ВВЕДЕНИЕ

Залежи газа на месторождениях Ямало-Ненецкого автономного округа (ЯНАО) характеризуются коллекторами с низкими фильтрационно-емкостными свойствами, поэтому эти ресурсы относятся к трудно-извлекаемым. В связи с сокращением добычи газа на территории ЯНАО по причине выработки запасов стандартных месторождений большее значение представляет разработка технологии обнаружения трудно-извлекаемых запасов нефти и газа. В условиях низких фильтрационно-емкостных характеристик нефтенасыщенных пород юрского и доюрского комплексов наиболее эффективным решением является разработка месторождений посредством вскрытия природных каналов фильтрации (зон трещиноватости), картируемых по данным сейсморазведки [1]. Картирование естественных каналов фильтрации требует обработки больших массивов данных сейсморазведки и разработки для этих целей соответствующей информационной технологии картографирования.

До появления методов машинного обучения данные сейсморазведки обрабатывались специалистами-интерпретаторами, которые производили ручное выделение геологических

слоев, разломов и горизонтов на сейсмических разрезах и кубах (рис. 1). Главные проблемы при обработке данных сейсморазведки связаны с неоднозначностью интерпретации данных и ростом их объема [2]. Кроме того, сейсмические данные приходится получать в сложных геологических условиях в связи с антропогенным воздействием человека в зонах добычи полезных ископаемых. Интерпретатор при анализе данных допускает множество ошибок, например, пропускает различные особенности геологического разреза. На сегодняшний день предложено множество решений задачи интерпретации с помощью многослойных сетей прямого распространения [3], сверточных нейронных сетей [4], деревьев решений [5].

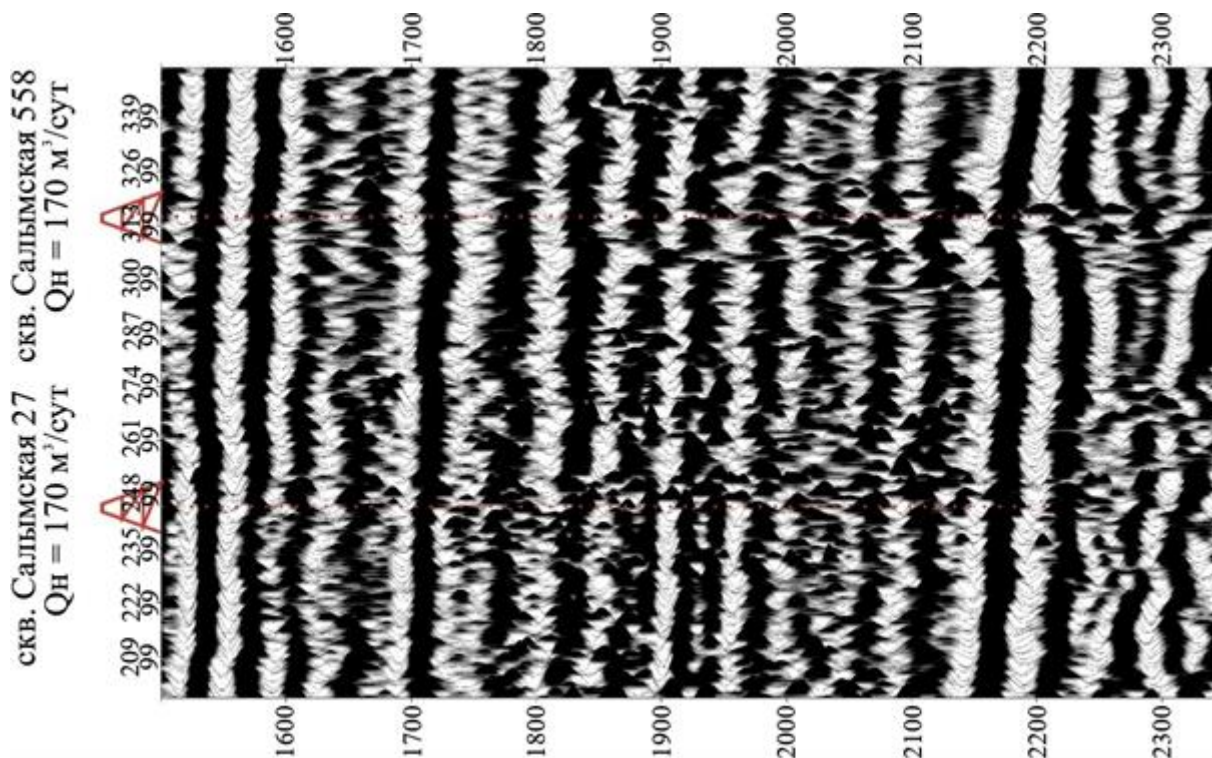


Рис. 1. Результаты целевой обработки и дешифрирования зон трещиноватости по данным сейсморазведки (скважина Салымская)

Решение задачи интерпретации данных в указанных работах производится для конкретного региона добычи полезных ископаемых, поэтому используемые при анализе наборы данных являются уникальными и содержат особенности геологических пород исследуемого региона нефтедобычи [6]. Данное обстоятельство объясняется различным набором аппаратных и программных средств, которые используются как для проведения сейсморазведки, так и для преобразования данных с сейсмодатчиков в формат, который можно использовать в процессе интерпретации. Поэтому решение задачи разметки геологических данных в общем случае привязано к конкретному эксперименту. Вместе с тем, при анализе данных сейсморазведки принято использовать эталонные сейсмические данные для оценки качества проведения эксперимента. Специалисты Data Science очень часто используют эталонный набор данных Open Seismic Repository [7] для верификации методов машинного обучения, которые содержат информацию о геологических породах в районе акватории Северного моря. Перспективные методы обнаружения зон трещиноватости основаны на анализе данных в виде сейсмического куба. В этом случае сеймотрассы в кубе, соответствующие определенному классу в кубе, представляют из себя трехмерные объекты (поверхности), поэтому задача интерпретации при разметке данных сводится к задаче сравнения трехмерных поверхностей.

Данные методы можно поделить на две группы: первые используют регулярные и нерегулярные решетки для сопоставления поверхностей, вторые основаны на решении задачи ре-

гистрации данных – вычисления расстояния между точками в трехмерном пространстве на основе определенной метрики, например, точка–точка или точка–плоскость [8]. В предлагаемой работе рассматриваются методы для автоматизации выделения зон трещиноватостей на 2D-изображениях (сейсмический разрез). Данная статья организована следующим образом: в первом разделе дана постановка задачи, представлен метод картирования каналов фильтрации на основе данных сейсморазведки, во втором разделе представлен алгоритм выбора признаков на основе автокодировщика, в третьем разделе представлен алгоритм синтеза новых изображений, в четвертом – представлены и обсуждены полученные результаты компьютерного моделирования.

## МЕТОД КАРТИРОВАНИЯ КАНАЛОВ ФИЛЬТРАЦИИ НА ОСНОВЕ ДАННЫХ СЕЙСМОРАЗВЕДКИ. ПОСТАНОВКА ЗАДАЧИ

Для разработки системы картирования естественных каналов фильтрации на основе данных сейсморазведки с применением нейронных сетей глубокого обучения с качеством распознавания, близким к возможностям человека, в работе разработан новый математический метод на основе автокодировщика [9], включающий в себя обработку изображений, выбор признаков и классификацию. Выбор признаков проводится автоматически с использованием техник глубокого обучения. Главная проблема, которую необходимо решить – это использование глубокого обучения при относительно небольшом объеме данных [10]. Для увеличения объема данных в работе используются генеративные состязательные сети (Generative Adversarial Networks) для синтеза новых изображений на основе уже существующей базы данных [11]. Состязательная сеть позволяет идентифицировать сейсмотрассы вне зависимости от изменения масштаба и небольшого поворота изображения вне плоскости сцены.

Таким образом, для разработки системы картирования естественных каналов фильтрации на основе данных сейсморазведки необходимо решить следующие задачи:

- *разработать* алгоритм нормализации изображений, содержащих сейсмотрассы [12];
- *разработать* алгоритм выбора признаков на основе автокодировщика [13, 14] для обеспечения высокой информативности с низкой внутриклассовой и высокой межклассовой вариативностью;
- *разработать* алгоритм для определения соответствия изображений и архитектуру глубокой сверточной нейронной сети для классификации изображений [15].

Под автокодировщиком понимается нейронная сеть, реализующая отображение входа сети на себя, при этом в процессе отображения внутри автокодировщика происходит сужение размерности входных данных. Для того чтобы получить на выходе автокодировщика объект, близкий к входным данным, необходимо выделить основные признаки входа. Применительно к задаче картирования естественных каналов фильтрации автокодировщики позволяют выделять на изображениях информативные зоны, которые содержат результаты интерпретации сейсмотрасс. Значительным преимуществом автокодировщиков является отсутствие необходимости размечать входные данные, что упрощает процесс построения нейронной сети [9, 16]. Также частично решается проблема пополнения базы изображений, так как после обучения автокодировщика можно в качестве входных данных использовать изображения, полученные автокодировщиком [10]. Для поставленной задачи был разработан автокодировщик, представляющий собой глубокую искусственную нейронную сверточную сеть ResNet с 29 слоями. Для ее настройки применялась техника глубокого остаточного обучения.

## АЛГОРИТМ ВЫБОРА ПРИЗНАКОВ НА ОСНОВЕ АВТОКОДИРОВЩИКА ДЛЯ ИНТЕРПРЕТАЦИИ ДАННЫХ НА СЕЙСМИЧЕСКИХ РАЗРЕЗАХ

Обобщенный автокодировщик состоит из двух частей: кодировщика и декодировщика. Автокодировщик карт ввода  $x_i \in R^{d_x}$  к уменьшенному скрытому представлению  $y_i \in R^{d_y}$  задается функцией  $g$  следующего вида:

$$y_i = g(W' x_i), \quad (1)$$

где  $g$  может быть как функцией тождества для линейной проекции, так и сигмидной функцией вида  $\frac{1}{1+e^{-w_x}}$  для нелинейного отображения.

Параметр  $W'$  есть весовая матрица размером  $dy \times dx$ . В работе игнорируются условия смещения нейронной сети для упрощения представления структуры автокодировщиков. Декодировщик реконструирует  $x_i \in R^{d_x}$  из скрытого представления (слоя)  $y_i$

$$x'_i = f(W' y_i) \quad (2)$$

Общая ошибка реконструкции  $E$  для  $n$  образцов может быть вычислена следующим образом:

$$E(W, W') \sum_{i=1}^n e_i(W, W') = \sum_{i=1}^n \sum_{j \in \Omega_i} s_{ij} L(x_j, x'_i), \quad (3)$$

где  $L$  – ошибка реконструкции;  $\Omega_i = \{j, k, \dots\}$  – набор индексированных образцов с определенными весами  $S_i = \{s_{ij}, s_{ik}, \dots\}$  для  $x_i$ .

Обобщенный автоматический автокодировщик обучает параметры  $(W, W')$ , минимизируя общую ошибку реконструкции  $E$ . Представим алгоритм итеративной процедуры обучения для обобщенного автокодировщика. Входная обучающая выборка  $\{x_i\}_1^n$ . Параметры:  $\Theta = (W, W')$ . Система обозначений:  $\Omega_i$  – реконструированное множество для  $x_i$ ,  $S_i$  – набор реконструированных весов  $x_i$ ,  $\{y_i\}_1^n$  – скрытое представление.

Шаг 1. Вычислим реконструированные веса  $S_i$  из  $\{x_i\}_1^n$  и определим реконструируемый набор  $\Omega_i$ , например, используя метод ближайшего соседа (k-nearest neighbor).

Шаг 2. Минимизируем общую ошибку реконструкции  $E$  в выражении (3), используя стохастический метод градиентного спуска и обновим значения весов  $\Theta$  для  $t$  шагов.

Шаг 3. Вычислим скрытое представление (слой)  $\{y_i\}_1^n$ , и обновим  $S_i$  и  $\Omega_i$  из  $\{y_i\}_1^n$  соответственно.

Шаг 4. Повторяем шаги 2 и 3 до тех пор, пока алгоритм не сойдется.

#### АЛГОРИТМ СИНТЕЗА НОВЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ГЕНЕРАТИВНЫХ СОСТЯЗАТЕЛЬНЫХ СЕТЕЙ И БАЗЫ ДАННЫХ ИЗОБРАЖЕНИЙ

При использовании линейных вложенных графов можно предположить, что низкоразмерные представления могут быть получены на основе линейной проекции  $y = X^T w$ , где  $w$  есть проекция вектора  $X = [x_1, x_2, \dots, x_n]$ . Пусть  $w^T X B X^T w = c$ , тогда целевая функция LGE может быть получена как:

$$w^* = \underset{c \text{ от } w^T w \neq c}{\operatorname{argmin}} \sum_{i,j} \|w^T x_i - w^T x_j\|^2 s_{ij}. \quad (4)$$

Генеративная состязательная сеть стремится использовать пространственную информацию между пикселями изображения. Для простоты предполагается, что изображение в градациях серого цвета определяется следующей функцией:

$$\begin{aligned} I: \{1, \dots, n_1\} \times \{1, \dots, n_2\} \rightarrow \\ W \subseteq R, (i, j) \mapsto I_{i,j}. \end{aligned} \quad (5)$$

Изображение  $I$  может быть представлено массивом размером  $n_1 \times n_2$ . Учитывая фильтр, дискретная свертка изображения  $I$  с фильтром  $K$  задается так, что изображение  $I$  может быть представлено как массив размера  $n_1 \times n_2$ . Если учесть, что  $K \in R^{2h_1+1 \times 2h_2+1}$ , то дискретная свертка изображения  $I$  с фильтром  $K$  может быть задана следующей функцией:

$$(I * K)_{r,s} = \sum_{u=-h_1}^{h_1} \sum_{v=-h_2}^{h_2} K_{u,v} I_{r+u, s+v}, \tag{6}$$

где фильтр  $K$  задается следующей матрицей:

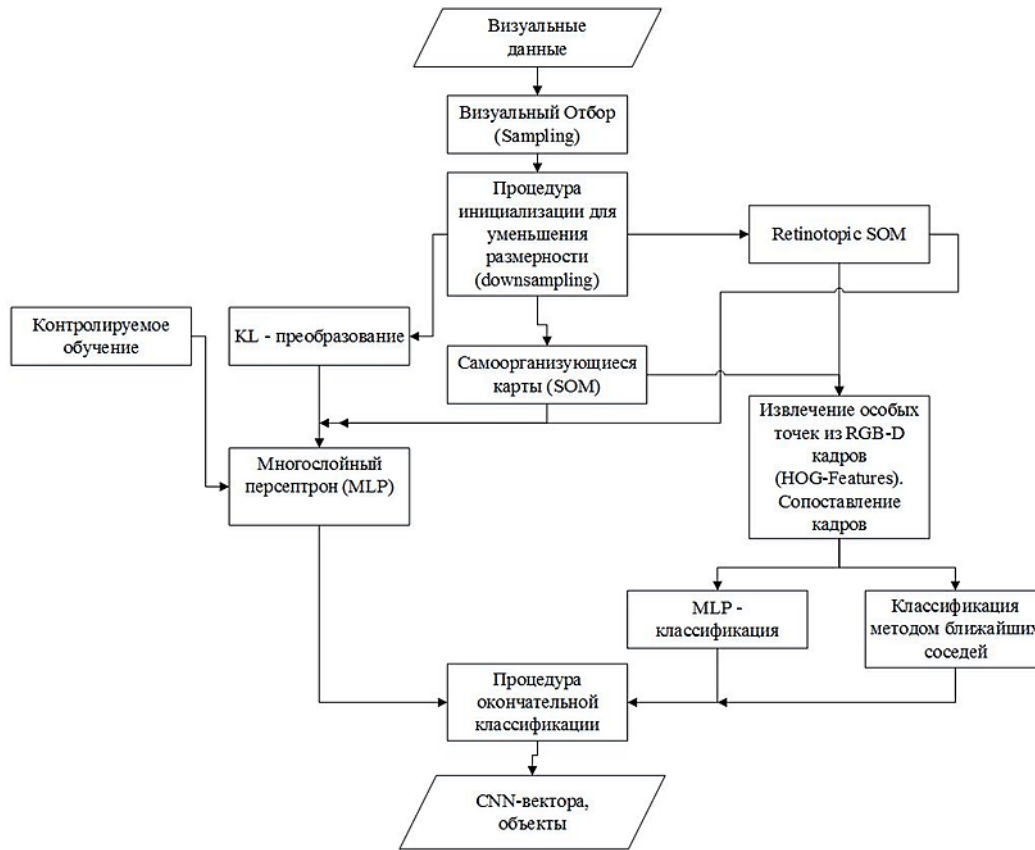
$$K = \begin{pmatrix} K_{-h_1, -h_2} & \dots & K_{-h_1, h_2} \\ \dots & K_{0,0} & \dots \\ K_{h_1, -h_2} & \dots & K_{h_1, h_2} \end{pmatrix}. \tag{7}$$

Поведение данной операции по отношению к границам изображения должно быть определено правильно. Для сглаживания будем использовать фильтр в виде дискретного гауссовского фильтра  $KG(\sigma)$ , который может быть задан в виде следующей формулы

$$(K_{G(\sigma)})_{r,s} = \frac{1}{\sqrt{2\pi\delta^2}} \exp\left(-\frac{r^2 + s^2}{2\delta^2}\right), \tag{8}$$

где  $\sigma$  – стандартное отклонение гауссовского распределения.

Алгоритм синтеза новых изображений на основе генеративных состязательных сетей и базы данных изображений представлен на рис. 2.



**Рис. 2.** Блок-диаграмма алгоритма синтеза новых изображений на основе генеративных состязательных сетей и базы данных изображений

### КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

Для проведения компьютерного моделирования была подготовлена обучающая выборка для задачи выявления зон трещиноватости на основе 3D-сейсморазведочной информации и получены следующие научно-технические результаты:

- *разрезы* волнового поля с шагом 50 метров;
- *выявленные* в волновом поле положения зон трещиноватости;
- *классифицированные* волновые поля на уровне отражающего горизонта «Б» на три класса: «Зоны трещиноватости», «Фон», «Отсутствие зон трещиноватости»;
- *временные* разрезы в формате jpeg с приведенной на них классификацией.

Данная выборка была подготовлена специалистами компании ООО «Новосибирский Научно-технический центр» (ННТЦ, г. Новосибирск) [17].

Пример с результатами автоматической процедуры интерпретации данных сейсморазведки с выделением геологических слоев, разломов и горизонтов для подготовленной обучающей выборки на сейсмических разрезах скважины Салымская представлен на рис. 3.




Рис. 3. Результаты целевой обработки и дешифрирования зон трещиноватости по данным сейсморазведки (скважина Салымская)

Продemonстрируем эффективность предложенного метода картирования каналов фильтрации на основе данных сейсморазведки для выбора признаков с использованием методов глубокого обучения на основе автокодировщиков при моделировании распределения структурированных выходных переменных. Обучение разработанного автокодировщика проводилось с использованием подготовленной обучающей выборки данных. Для компьютерного моделирования произведено обучение данных моделей и сравнение их производительности. Результаты представлены в табл. 1–3.

Таблица 1

**Сравнение точности и производительности нейронных сетей в 1-ом квадранте**

Модель НС	I квадрант	
	Гипотеза	Эксперт
Точность, значение ошибки		
Baseline	100	98,96
CVAE (Монте-Карло)	45,33	44,88
Предложенная CVAE	41,11	40,03
Вычислительная сложность, сек		
Baseline	2,9	
CVAE (Монте-Карло)	2,45	
Предложенная CVAE	1,78	

Для подтверждения эффективности предложенного метода создана искусственная экспериментальная настройка для структурированного прогнозирования выходных данных с использованием обучающей выборки данных и генеративной состязательной нейронной сети. Проведем сравнение трех нейронных сетей (НС): эталонная базовая модель нейронной сети

(Baseline), CVAE модель на основе подхода Монте-Карло и предложенная модифицированная модель на основе CVAE.

Таблица 2

### Сравнение точности и производительности нейронных сетей в 2-ом квадранте

Модель НС	2 квадрант	
	Гипотеза	Эксперт
Точность, значение ошибки		
Baseline	68,21	67,98
CVAE (Монте-Карло)	36,21	36,06
Предложенная CVAE	31,13	30,56
Вычислительная сложность, сек		
Baseline	2,41	
CVAE (Монте-Карло)	2,07	
Предложенная CVAE	1,72	

Результаты сравнительного анализа показали, что разработанный автокодировщик позволяет хорошо извлекать характерные для процесса интерпретации данных области на данных сейсморазведки.

Таблица 3

### Сравнение точности и производительности нейронных сетей в 3-ом квадранте

Модель НС	3 квадрант	
	Гипотеза	Эксперт
Точность, значение ошибки		
Baseline	18,16	17,95
CVAE (Монте-Карло)	15,15	15,11
Предложенная CVAE	13,23	12,85
Вычислительная сложность, сек		
Baseline	2,36	
CVAE (Монте-Карло)	1,76	
Предложенная CVAE	1,46	

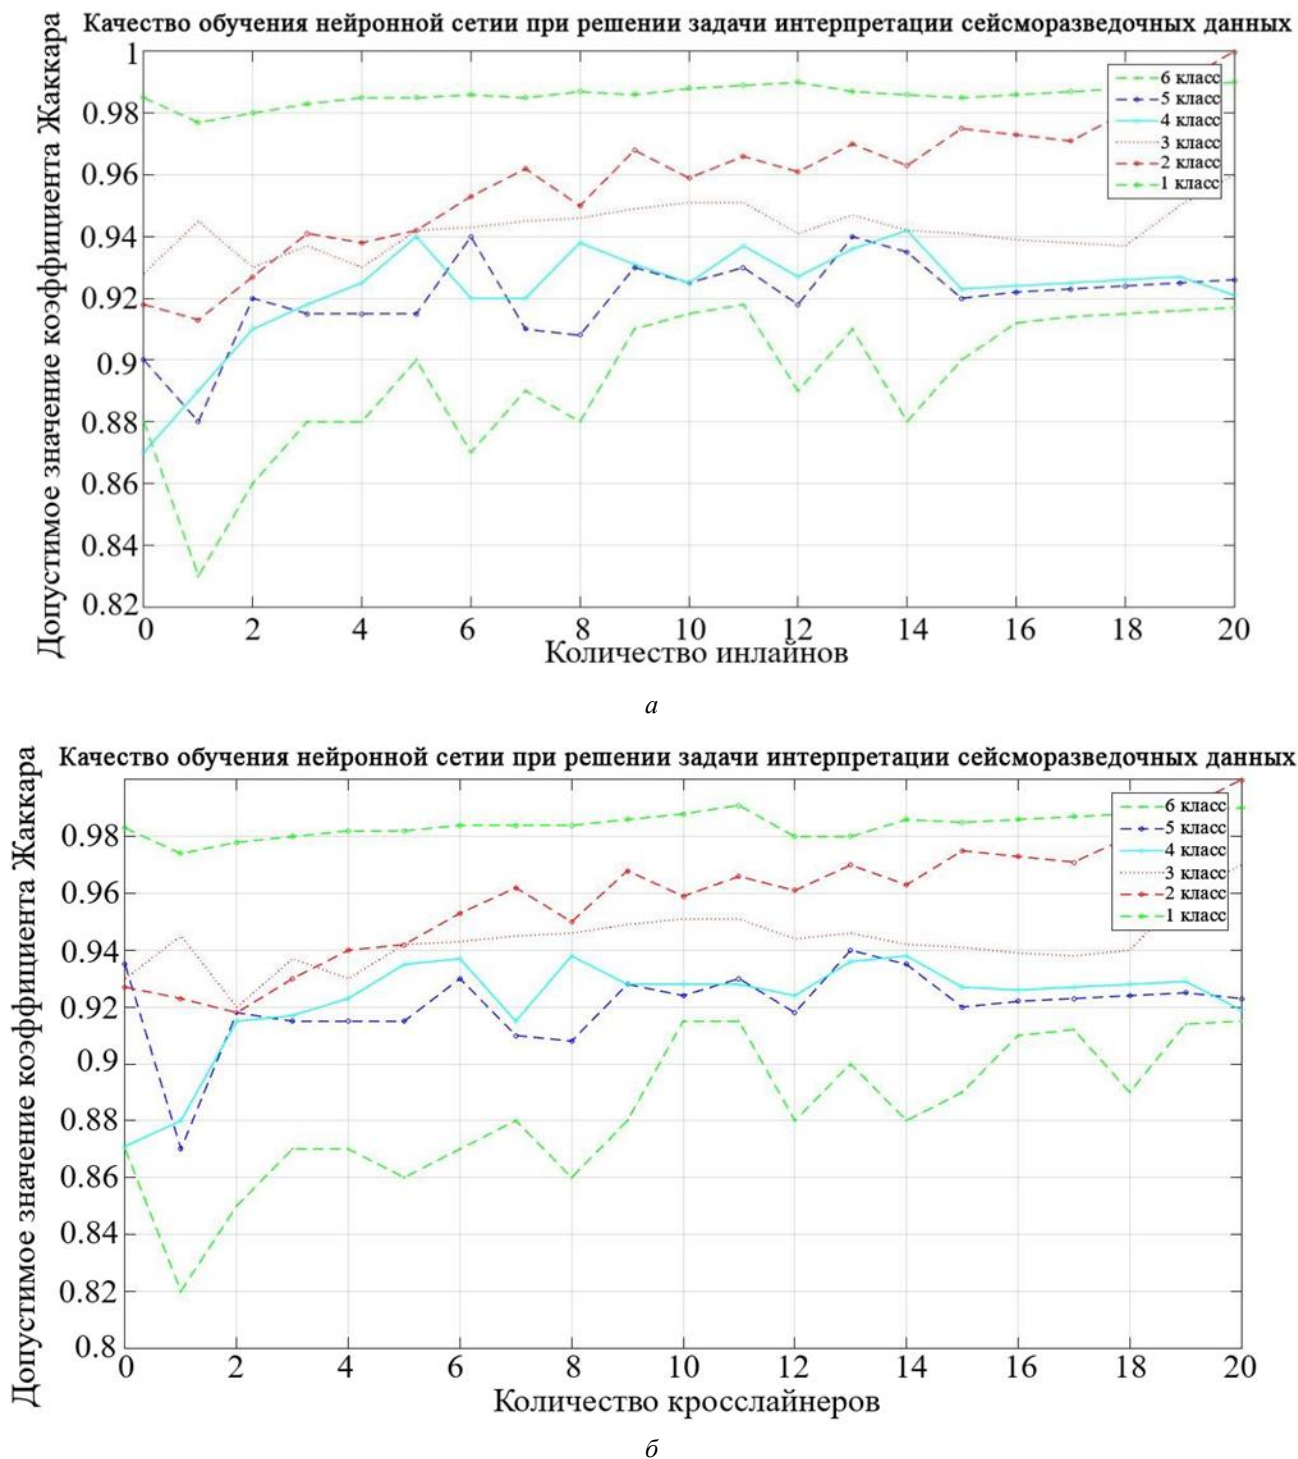
Другой важной проблемой при интерпретации данных сейсморазведки на изображениях является их зашумленность. При наличии значительных помех автокодировщик не способен адекватно выделять признаки. Для решения этой задачи часто применяется алгоритм регуляризации двумерной полной вариации, позволяющий подавлять шум на изображениях.

Вычисление экстремальной функции задачи регуляризации основано на редукции двумерной задачи регуляризации к одномерной. Данный алгоритм позволяет в комбинации с нейросетевым автокодировщиком выделять характерные области на данных сейсморазведки, даже в случае наличия существенных помех.

В данной работе была исследована одна из задач интерпретации сейсморазведочных данных, а именно задача идентификации геологических слоев на двумерных срезах сейсмокуба. Принято выделять два типа срезов в сейсмическом кубе: инлайны и кросслайны в зависимости от разбиения сейсмокуба на вертикальные и горизонтальные срезы вдоль или поперек оси расположения сейсмических датчиков на поверхности Земли соответственно.

Для оценки качества работы метода интерпретации сейсморазведочных данных, который осуществляет идентификацию зон трещиноватостей на 2D-изображениях с использованием методов машинного обучения, было проведено обучение автокодировщика на выборках инлайнов, содержащих от 5 до 20 равномерно распределенных по сейсмическому кубу геоло-

гических срезов данных. Проверка качества работы автокодировщика проводилась на оставшихся в подготовленной выборке данных инлайнах (рис. 4, а) и на всех кросслайнах (рис. 4, б). В работе была исследована зависимость качества обучения автокодировщика от количества срезов (инлайнов и кросслайнов) в обучающей выборке с использованием коэффициента Жаккара, в связи с этим предварительная обработка двумерных изображений, содержащих геологические срезы данных, не проводилась.



**Рис. 4.** Результаты целевой обработки и дешифрирования зон трещиноватости по данным сейсморазведки (скважина Салымская):

а – зависимость коэффициента Жаккара от количества инлайнов;

б – зависимость коэффициента Жаккара от количества кросслайнов



В процессе анализа подготовленной обучающей выборки данных было установлено, что результатами интерпретации каждого сейсмического среза в кубе являются 6 геологических слоев, которые на рис. 4, *а* и *б* обозначены классами.

В результате сравнительного анализа зависимостей графиков на рис. 4, *а* и *б* было установлено, что можно получить высокое значение оценки качества обучения с использованием коэффициента Жаккара для 9-ти геологических срезов (инлайн). Далее с увеличением числа инлайнов значение оценки качества продолжает улучшаться, но с меньшей скоростью. Таким образом, можно сделать вывод, что для обучения автокодировщика в задаче идентификации геологических слоев на двумерных срезах сейсмокуба достаточно небольшого количества размеченных человеком изображений. Из рис. 4, *б* можно сделать вывод, что высокая оценка качества обучения также получается и для кросслайнов, несмотря на то, что для обучения автокодировщика использовались только инлайн срезы данных. Таким образом, можно сделать вывод об инвариантно-сти предложенного метода машинного обучения разметки двумерных сейсморазведочных данных от типа используемых геологических срезов данных.

### ЗАКЛЮЧЕНИЕ

В работе предложен метод выбора признаков на 2D-изображениях с использованием автокодировщика для обеспечения высокой информативности с низкой внутриклассовой и высокой межклассовой вариативностью.

На основе предложенного метода выбора признаков создана система для решения задачи интерпретации зон трещиноватостей, использующая анализ сейсмических срезов на двумерных изображениях с использованием техник глубокого машинного обучения. Предложенная система основана на методе картирования каналов фильтрации на основе данных сейсморазведки, алгоритме выбора признаков на основе автокодировщика и алгоритме синтеза новых изображений на основе генеративных состязательных сетей.

В результате компьютерного моделирования была проведена автоматическая интерпретация данных сейсморазведки на сейсмических разрезах скважины Салымская. Результаты сравнительного анализа показали, что модифицированная модель на основе CVAE позволяет лучше извлекать характерные для процесса интерпретации данных области на данных сейсморазведки, чем известные модели автокодировщиков.

В работе была исследована зависимость качества обучения автокодировщика от количества срезов (инлайн и кросслайнов) в обучающей выборке с использованием коэффициент Жаккара. Было установлено, что при идентификации геологических слоев на двумерных срезах сейсмокуба достаточно использовать небольшой набор размеченных изображений. Дополнительно было установлено, что коэффициент Жаккара не позволяет в полной мере оценить качество результата, получаемого при автоматической интерпретации данных с использованием автокодировщика. Для точной оценки качества геологической разметки данных необходимо исследовать полученные маски с привлечением человека.

### СПИСОК ЛИТЕРАТУРЫ

1. Глухманчук Е. Д., Крупицкий В. В., Леонтьевский А. В. Межслоевой сдвиг в породах баженовской свиты как региональный фактор внутрiformационного разрывообразования // Недропользование XXI век. 2014. № 5(49). С. 24–26. [ E. D. Glukhmanchuk, V. V. Krupitsky, A. V. Leontievsky, "The interlayer shift in the rocks of the bazhenov formation as a regional factor intraformational faulting in rocks", (in Russian), in *Nedropol'zovanie XXI vek*, no. 5 (49), pp. 24-26, 2014. ]
2. Глухманчук Е. Д., Василевский А. Н. Характеристика зон трещиноватости по неоднородности структуры поля деформаций отражающих горизонтов // Геология и геофизика. 2013. Т. 54, № 1. С. 106–112. [ E. D. Glukhmanchuk, A. N. Vasilevsky, "Description of fracture zones based on the structural inhomogeneity of the reflector deformation field", (in Russian), in *Geologiya i geofizika*, vol. 54, no. 1, pp. 106-112, 2013. ]
3. Peters B., Haber E., Granek J. Neural-networks for geophysicists and their application to seismic data interpretation. [Электронный ресурс]. URL: <https://arxiv.org/pdf/1903.11215.pdf> (дата обращения 02.04.2021). [ B. Peters, F. Haber, J. Granek (2021, Apr. 2). *Neural-networks for geophysicists and their application to seismic data interpretation* [Online]. Available: <https://arxiv.org/pdf/1903.11215.pdf> ]

4. **Wu H., Zhang B.** A deep convolutional encoder-decoder neural network in assisting seismic horizon tracking // arXiv preprint: 1804.06814. 2018. DOI: 10.1190/geo2018-0672.1. [ H. Wu, B. Zhang, "A deep convolutional encoder-decoder neural network in assisting seismic horizon tracking", in *arXiv preprint: 1804.06814*, 2018. DOI: 10.1190/geo2018-0672. ]
5. **Seismic facies analysis using machine learning** / T. Wrona, et al. // SEG Library. Geophysics. 2018. Vol. 83, Iss. 5. Pp. B281-B287 DOI: 10.1190/geo2017-0595.1. [ T. Wrona, et al., "Seismic facies analysis using machine learning", in *SEG Library. Geophysics*, vol. 83, Iss. 5, pp. B281-B287, 2018. DOI: 10.1190/geo2017-0595.1.
6. **Трещинно-блоковая** структура Салымского месторождения как ведущий фактор в эффективной выработке запасов баженовской свиты / Е. Д. Глухманчук [и др.] // Пути реализации нефтегазового и рудного потенциала. Ханты-Мансийск: Югра, 2013. С. 24–26. [ E. D. Glukhmanchuk, et al., *The fractured block structure of the Salymskoye field as a leading factor in the efficient development of the Bazhenov formation reserves*, (in Russian). Khanty-Mansiysk: Ugra, 2013. ]
7. **Netherlands Dataset: A New Public Dataset for Machine Learning in Seismic Interpretation** / R.-M. Silva, et al. [Электронный ресурс]. URL: <https://www.researchgate.net/publication/332139063> (дата обращения 02.04.2021). [ R.-M. Silva, et al. (2021, Apr. 2). *Netherlands Dataset: A New Public Dataset for Machine Learning in Seismic Interpretation* [Online]. Available: <https://www.researchgate.net/publication/332139063> ]
8. **Convolutional Neural Networks and Face Recognition Task** / A. Sochenkova, et al. // Proceedings SPIE of the XL Applications of Digital Image Processing, (San Diego–USA, 6–10 August 2017). San Diego: SPIE, 2017. Vol. 10396. Pp. 103962L-1. [ A. Sochenkova, et al., "Convolutional Neural Networks and Face Recognition Task", in *Proc. SPIE of the XL Applications of Digital Image Processing (SPIE-2017)*, 2017, pp. 103962L-1. ]
9. **LeCun Y.** Convolutional networks for images, speech and time series // The Handbook of Brain Theory and Neural Networks. Cambridge: MIT Press Cambridge, 1996. Pp. 255-258. [ Y. LeCun, "Convolutional networks for images, speech and time series", in *The Handbook of Brain Theory and Neural Networks*. Cambridge: MIT Press Cambridge, 1996. ]
10. **Hybrid convolutional neural networks for articulatory and acoustic information based speech recognition** / V. Mitra, et al. // Journal Speech Communication. 2017. Vol. 89 (C). Pp. 103-112. [ V. Mitra, et al., "Hybrid convolutional neural networks for articulatory and acoustic information based speech recognition", in *Journal Speech Communication*, vol. 89 (C), pp. 103-112, 2017. ]
11. **Generalized Autoencoder: A Neural Network Framework for Dimensionality Reduction** / W. Wang, et al. // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (Columbus, Ohio–USA, 12–16 June 2014). Columbus: IEEE, 2014. Pp. 490-497. [ W. Wang, et al., "Generalized Autoencoder: A Neural Network Framework for Dimensionality Reduction", in *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (SVRP-2014)*, Columbus, Ohio–USA, 2014, pp. 490-497. ]
12. **Forsyth D., Ponce J.** Computer Vision: A Modern Approach. NY: Prentice Hall Professional Technical Reference, 2002. 720 p. [ D. Forsyth, J. Ponce, *Computer Vision: A Modern Approach*. NY: Prentice Hall Professional Technical Reference, 2002. ]
13. **Contractive auto-encoders: Explicit invariance during feature extraction** / S. Rifai, et al. // Proceedings of the 28th International Conference on Machine Learning (Bellevue, Washington–USA, 28 June–2 July 2011). Bellevue, 2011. Pp. 833-840. [ S. Rifai, et al., "Contractive auto-encoders: Explicit invariance during feature extraction", in *Proc. of the 28th International Conference on Machine Learning*, Bellevue, Washington–USA, 2011, pp. 833-840. ]
14. **LeCun Y., Kavukvuoglu K., Farabet C.** Convolutional networks and applications in vision // Proc. of International Symposium on Circuits and Systems (Paris–France, 30 May–2 June 2010). Bellevue, 2010. Pp. 253-256. [ Y. LeCun, K. Kavukvuoglu, C. Farabet, "Convolutional networks and applications in vision", in *Proc. International Symposium on Circuits and Systems*, Paris–France, 2010, pp. 253-256. ]
15. **Sochenkov I., Vokhmintsev A.** Visual duplicates image search for a non-cooperative person recognition at a distance // Procedia Engineering. 2015. Vol. 129. Pp. 440-445. [ I. Sochenkov, A. Vokhmintsev, "Visual duplicates image search for a non-cooperative person recognition at a distance," in *Procedia Engineering*, vol. 129, pp. 440-445, 2015. ]
16. **Lee H., Ekanadham C., Ng A.** Sparse deep belief net model for visual area v2 // Proc. of the 20th International Conference on Neural Information Processing Systems (Stanford, CA–USA, 2007). USA: Stanford, 2007. Pp. 873-880. [ H. Lee, C. Ekanadham, A. Ng, "Sparse deep belief net model for visual area v2", in *Proc. of the 20th International Conference on Neural Information Processing System*, Stanford, CA–USA, 2007, pp. 873-880. ]
17. **Новосибирский Научно-Технический Центр» (ННТЦ).** Цифровые технологии в строительстве скважин и разработке месторождений. [Электронный ресурс]. URL: <https://nntc.pro> (дата обращения 02.04.2021). [ *Novosibirsk Scientific and Technical Center "(NSTC). Digital technologies in well construction and field development* (2021, Apr. 2). [Online]. Available: <https://nntc.pro> ]

#### ОБ АВТОРАХ

**ВОХМИНЦЕВ Александр Владиславович**, зав. науч.-иссл. лабораторией Челябинского государственного университета. Доц. Югорского государственного университета. Д-р техн. наук (УГАТУ, 2020). Иссл. в обл. цифровой обработки информации и машинного обучения.

**МЕЛЬНИКОВ Андрей Витальевич**, дир. Югорского науч.-иссл. института информационных технологий, проф. Югорского государственного университета. Д-р техн. наук (Южно-уральский государственный университет, 1996). Иссл. в обл. искусственного интеллекта и машинного обучения.

**METADATA**

**Title:** A system for mapping natural filtration channels based on seismic data and machine learning methods.

**Authors:** A. V. Vokhmintcev<sup>1</sup>, A. V. Melnikov<sup>2</sup>

**Affiliation:**

<sup>1</sup> Chelyabinsk State University (CU), Russia.

<sup>1,2</sup> Ugra State University (YUGU), Russia.

<sup>2</sup> Ugra Research Institute of Information Technologies (UNIIT), Russia.

**Email:** <sup>1</sup>vav@csu.ru, <sup>2</sup>MelnikovAV@uriit.ru

**Language:** Russian.

**Source:** Vestnik UGATU (scientific journal of Ufa State Aviation Technical University), vol. 25, no. 3 (93), pp. 109-119, 2021. ISSN 2225-2789 (Online), ISSN 1992-6502 (Print).

**Abstract:** In this paper the system for solving the problem of interpretation of fracture zones was proposed, using the analysis of seismic sections on two-dimensional images based on of deep machine learning techniques. The proposed system is based on the filtering channels mapping on seismic data, the algorithm for selecting features using an auto-encoder and the algorithm for synthesizing new images using on generative adversarial networks. Auto-encoders provide high information content with low intra-class and high inter-class variability. To train the neural network, we used a data sample based on seismic database with the location of previously mapped fracture zones in the volume of 70 sections of the wave field for oil and gas fields in the Yamalo-Nenets and Khanty-Mansi Autonomous Okrug. Computer simulation for the problem of identification of geological layers on two-dimensional sections of a seismocube is carried out, the obtained simulation results were presented and discussed.

**Key words:** fractured systems mapping; seismic exploration; machine learning and artificial intelligence methods; auto-encoder; geological cross-section; generative adversarial network.

**About authors:**

**VOKHMINTSEV, Alexander Vladislavovich**, Head of the Research Laboratory of Chelyabinsk State University. Assoc. Prof. of Ugra State University. Dr. of Tech. Sci. (USATU, 2020). Research in the field of digital information processing and machine learning.

**MELNIKOV, Andrey Vitalievich**, Director of the Ugra Research Institute of Information Technologies, Prof. of the Ugra State University. Dr. of Tech. Sci. (South Ural State University, 1996). Research in the field of artificial intelligence and machine learning.