

Программный комплекс IP_Seis для прогноза нефтегазовой продуктивности изучаемых пластов на основе нейронных сетей и инверсионных построений

И.И. ПРИЕЗЖЕВ, д.т.н.,

ГЕН. ДИРЕКТОР ООО АЙПИЛАБ

РЕЗИДЕНТ ИННОВАЦИОННОГО ЦЕНТРА СКОЛКОВО



Направление разработки

Разработка программного обеспечения для прогноза параметров продуктивности нефтегазовых формаций на основе:

1. Глубоких нейронных сетей с инновационным гибридным обучением (генетические алгоритмы и градиентные методы).
2. Сейсмической инверсии по полным, угловым и азимутальным суммам.
3. Анализа трещиноватости по сейсмическим данным.

Прогнозируемые параметры

- Данные добычи имеют многофакторный нелинейный характер
 - Какие факторы?
 - Как факторы соотносятся с друг другом?
 - Нормирование по времени и по пространству
- Другие параметры непосредственно связанные с добычей нефти и газа
 - Эффективные толщины
 - Пористость
 - Насыщенность
 - Эффективные емкости
- Для прогноза нужно использовать соответствующий аппарат
 - Нелинейный
 - С высокой степенью свободы
 - Решение некорректных и нестабильных задач


Какие факторы влияют на дебит для горизонтальных скважин?

Геологический потенциал или качество резервуара – как возможность геологической формации в заданной точке пространства производить добычу углеводороды.

Качество бурения как
контакт траектории горизонтальной скважины
с резервуаром

Качество заканчивания и стимуляции
(Completion quality stimulation quality)

Влияние заканчивания и стимуляции на дебит скважины



Какие отношения между факторами влияющие на дебит?

Обычная линейная модель в виде суммы факторов:

$$PR = \sum_{i=1}^N a_i * F_i = \text{GeologyPR} + \text{DrillingPR} + \text{CompletionPR}$$

Предлагаемая модель в виде произведения факторов:

$$PR = GP * DQ * CQ$$

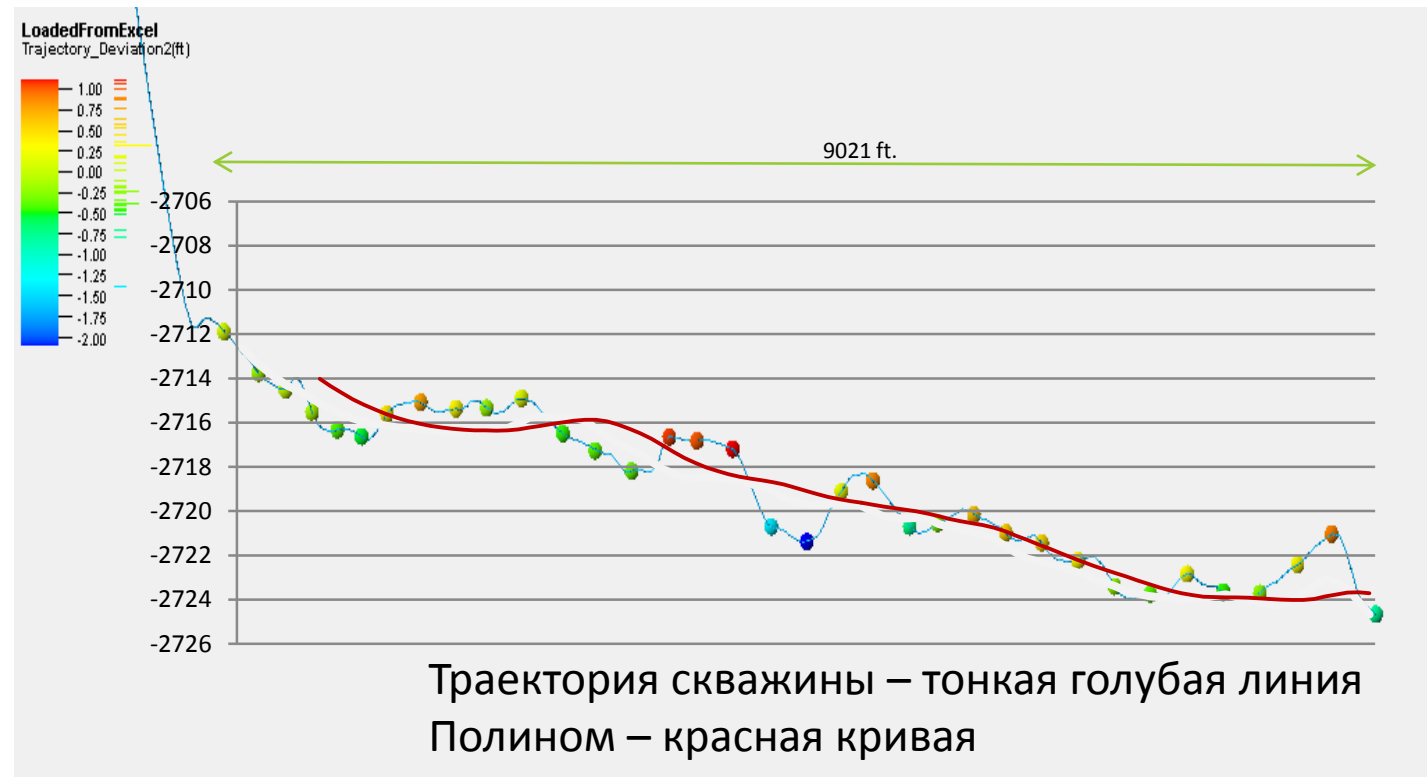
PR - Дебит скважины (production rate).

GP - Геологический потенциал как максимальный возможный дебит ($PR \leq GP$).

DQ - Качество бурения как коэффициент контакта траектории с резервуаром ($0 < DQ \leq 1$)

CQ - Качество стимуляции или заканчивания ($0 < CQ \leq 1$)

Оценка качества бурения



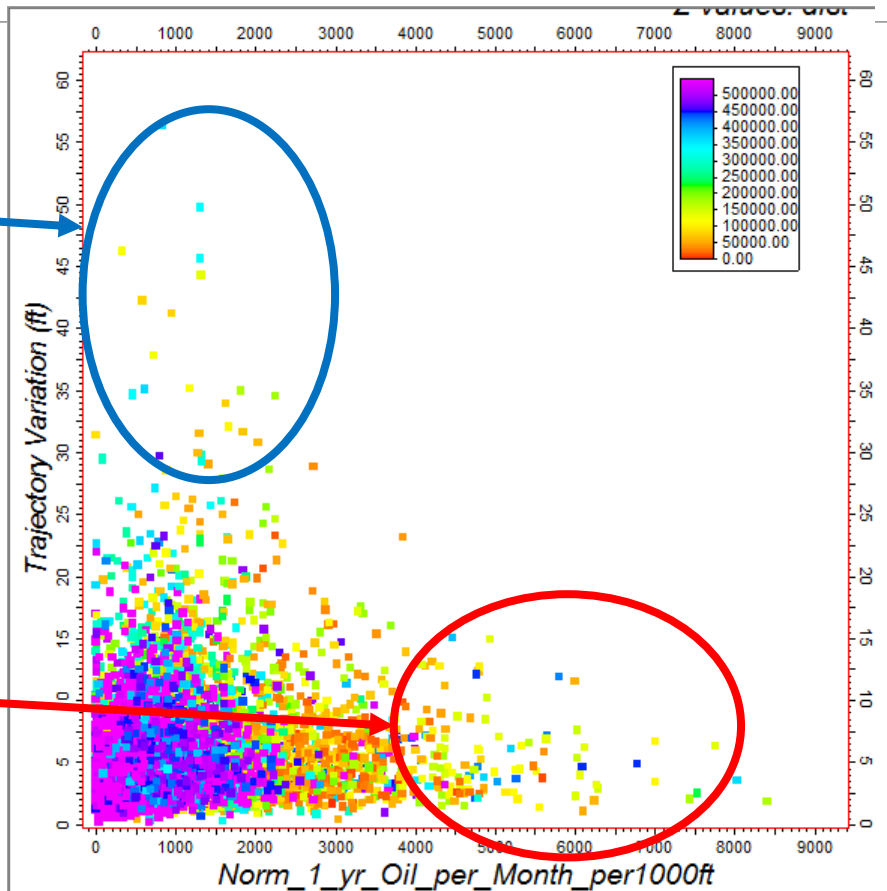
Траектория скважины – тонкая голубая линия
Полином – красная кривая
Цветные точки – отклонение от полинома

Вариации траектории для 12000 горизонтальных скважин в Eagle Ford

Плохие скважины


Хорошие скважины

Цветом показаны дистанция от места с хорошими скважинами (EP Energy license block)



Глубокая нейронная сеть

Deep neural network



Основная идея глубоких нейронных сетей

Произвести генерализацию информации в первых слоях сети без учителя и выполнять обучение с полным соединением только в упрощенных слоях.

Методы автоассоциации:


Autoencoder

Restricted Boltzmann machine

Конволюция (фильтрация)

Классификация без учителя

Autoencoder – сжатие картинки методом «Узкого горлышка» и выделение значимых значений



Предлагаемая схема обучения нейронных сетей

Generation

(set of neural networks initially use random)

NN 1

NN 2

NN 3

....

NN m

error 1

error 2

error 3

....

error m

Selection

(several NN with smallest error)

NN 3

NN 15

NN 21

NN 57


Build New Generation

Gradient one iteration


$$\xi^{n+1} = \xi^n + \alpha^n [\mathcal{J}^* \mathcal{J}]^{-1} \sum_{l=1+L} [\frac{\partial F(x^l, \xi^n)}{\partial \xi}]^* [y^l - F(x^l, \xi^n)];$$

$$\alpha^n = - \frac{\left\langle \phi^n \left| \sum_l \frac{\partial F(x^l, \xi^n)}{\partial \xi} [\mathcal{J}^* \mathcal{J}]^{-1} \sum_{l1} \left[\frac{\partial F(x^{l1}, \xi^n)}{\partial \xi} \right]^* [y^{l1} - F(x^{l1}, \xi^n)] \right\rangle}{\left\| \sum_l \frac{\partial F(x^l, \xi^n)}{\partial \xi} [\mathcal{J}^* \mathcal{J}]^{-1} \sum_{l1} \left[\frac{\partial F(x^{l1}, \xi^n)}{\partial \xi} \right]^* [y^{l1} - F(x^{l1}, \xi^n)] \right\|}$$

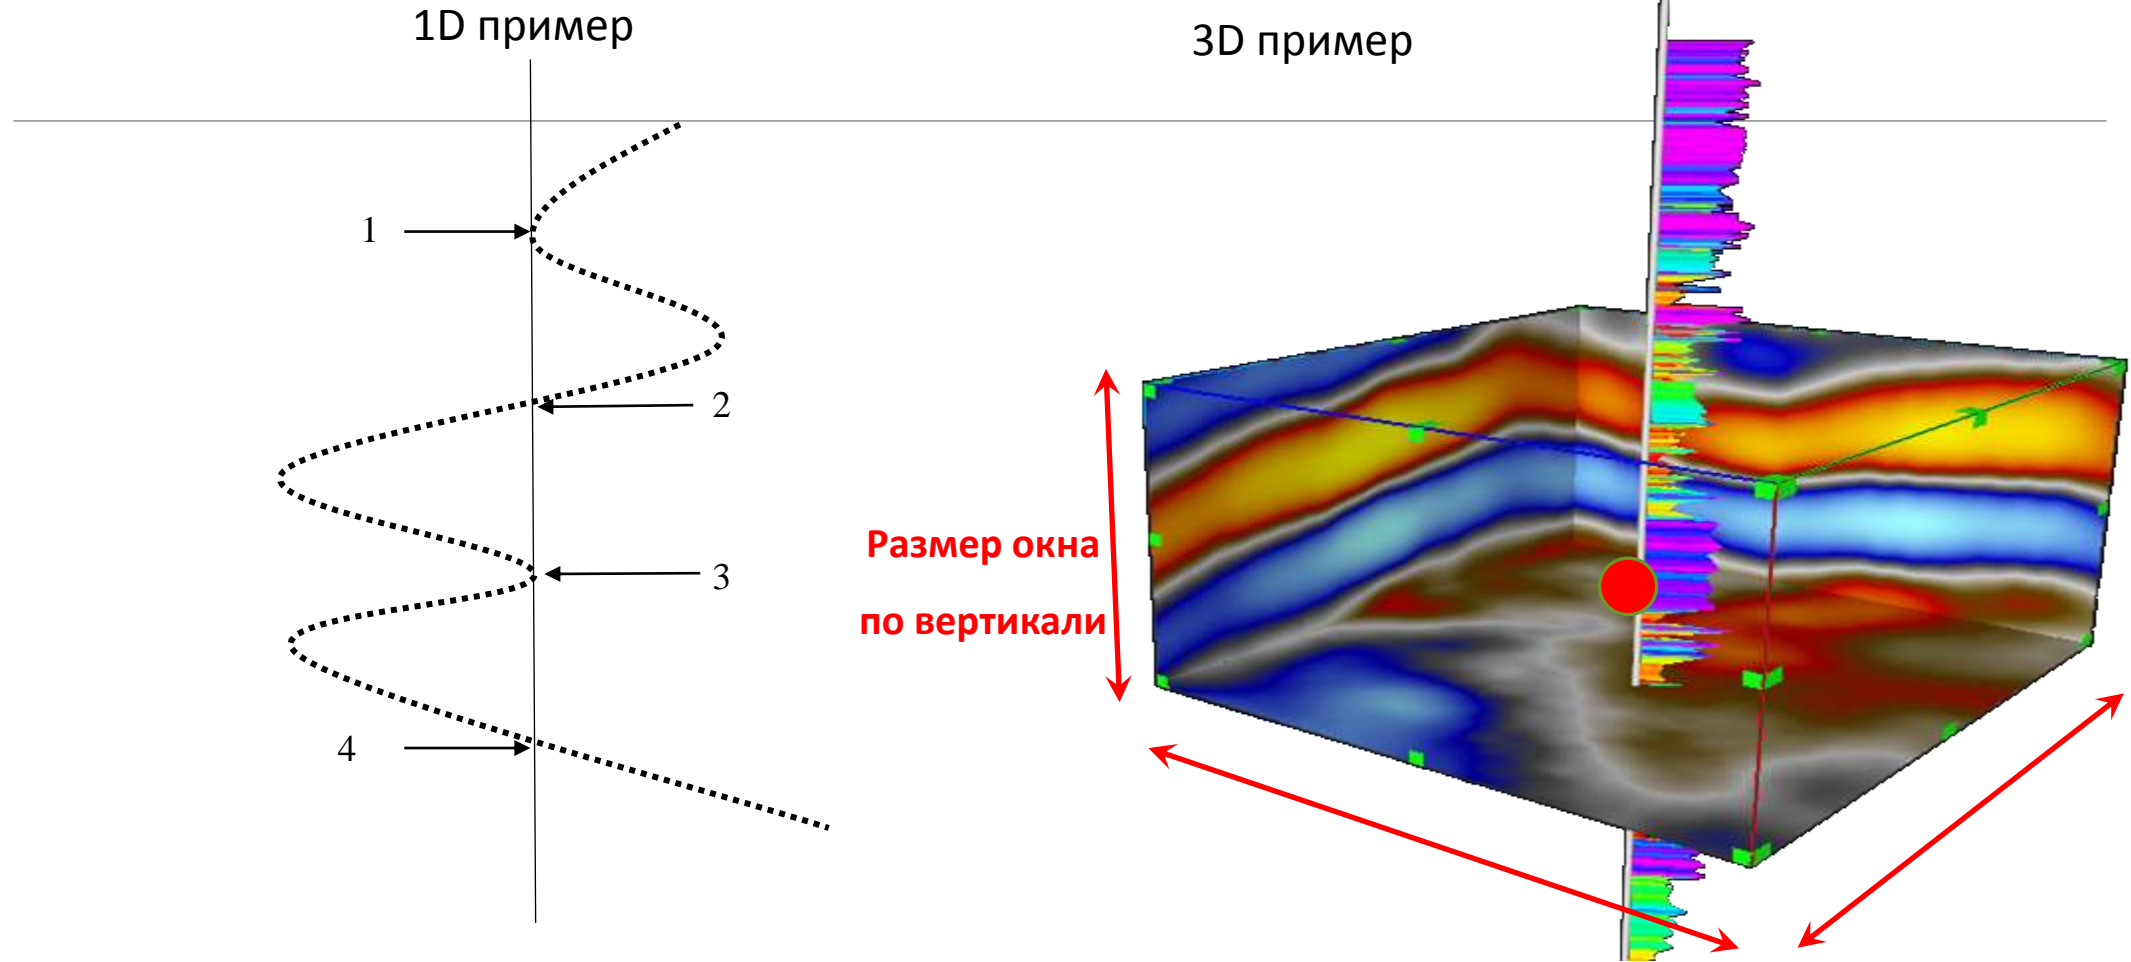
Cross-over



Mutation



Использование скользящих окон на входе



Сложность – большая корреляция входных данных

Программный комплекс IP_Seis

1. Ядро комплекса

- Ввод/вывод
- Средства визуализации
- Статистический анализ
- Сохранение и восстановление проекта

2. Набор функциональных модулей

- Максимальная автономность
- Возможность использования как плагин в Petrel
- Возможность использования как плагин в других системах

Ядро комплекса IP_Seis

1. Ввод/вывод
 - Набор точек (Excel file)
 - Поверхности (CPS3 ASCII, IRAP ASCII, ZMAP ASCII,...)
 - Well header, trajectory (Excel file)
 - SEG-Y
 - LAS
2. Средства визуализации
 - Карта
 - Разрез
 - 3D (в работе)
3. Статистический анализ
 - Кросс плот
 - Гистограмма
4. Сохранение и восстановление проекта

Работа с поверхностями (набор карт - 2D атрибутов)

1. DNN_SurfaceAttributes - модуль для прогноза эффективных параметров по набору 2D атрибутов (набор карт) на основе глубоких нейронных сетей. Результат – несколько карт с прогнозами P10, P50, P90 и разброс прогноза (стандартное отклонение).

SOM_Clustering – модуль для выделения сейсмофаций по набору 2D атрибутов (набор карт) на основе В качестве алгоритма для классификации используется стандартный алгоритм SOM (self-organized map).

DNN_Fracture_Detection модуль выделения зон трещиноватости и скрытых разломов по набору 2D атрибутов (набор карт) на основе глубоких нейронных сетей.

Вспомогательные модули (извлечение атрибутов на поверхность из сейсмического куба)

Работа с сейсмическими кубами

DNN_CubeAttribute - модуль для прогноза эффективных параметров по набору 3D атрибутов (набор сейсмических кубов) на основе глубоких нейронных сетей. Результат – несколько кубов с прогнозами P10, P50, P90 и разброс прогноза (стандартное отклонение) для заданного слоя (кровля – подошва области интереса).

Poststack_Inversion – модуль классической сейсмической инверсии для оценки акустического импеданса на основе обращения уравнения конволюции. Технология может использовать сейсмический импульс или включить его оценку одновременно с инверсией для каждой трассы. Модуль также включает реализацию технологии Color Inversion и выравнивание спектра сейсмического сигнала.

S2L_Inversion – модуль инверсионных построений на основе совместного использования нескольких сейсмических кубов (кубы до суммирования и/или азимутальные кубы) и набора каротажных кривых (например AI, Vp/Vs, density, Fast velocity, Slow velocity ,...).

ML_FractureDetection - модуль для прогноза зон трещиноватости и скрытых разломов по данным сейсморазведки. Модуль основан на применении алгоритмов машинного обучения (Machine learning), что позволяет эффективно решать задачу такого прогноза. Сравнение результатов выделения зон трещиноватости и скрытых разломов на основе различных технологий и нашего подхода, показывает большую разрешающую способность.

DNN_SOM_SeisFacies – модуль для выделения сейсмофаций по форме сейсмического сигнала в изучаемом пласте. Данный модуль использует для классификации объёмный сигнал (суб-куб - несколько трасс). В качестве алгоритма для классификации используется стандартный алгоритм SOM (self-organized map) и инновационный подход на основе глубоких нейронных сетях.

IP_Seis

The image displays a software interface for seismic data processing, featuring a main window titled "Seismic" and a floating "Deep Neural Network" (DNN) configuration window.

Seismic Window:

- File Window Help:** Standard menu options.
- Tree View:** Shows a project structure including "SeismicCubeC:\Projects\Vas\Cu", "VirtualCube DNN Attribute", "PointSet C:\Projects\Vas\points", "Surface C:\Projects\Vas\top_cha", "Surface C:\Projects\Vas\Bot_cha", "PointSetNN", and "SeismicCubeC:\Users\ivanp\Do".
- Main Display:** Two seismic plots for "Inline=602". The top plot shows a grayscale seismic cube with time on the y-axis (ranging from -3800 to -4363.2) and samples on the x-axis (ranging from 0 to 140.8). The bottom plot shows a color-coded seismic cube with time on the y-axis (ranging from 0 to -704) and samples on the x-axis (ranging from 0 to 176).

Deep Neural Network Window:

- Input data:** Seismic cube: SeismicCubeC:.
- Train data:** Max lag inlines: 1, Max lag xlines: 1, Max lag samples: 5.
- Graphics:** Polygon: [Empty]
- Parameters:** Tikhonov alpha: 0.01, Iterations: 100, Cross validation (%): 10, Hidden layer1 nodes: 3, Hidden layer2 nodes: [Empty], Hidden layer3 nodes: [Empty].
- Use Surface:** Top: C:\Projects\Vas\top_ch, Bottom: C:\Projects\Vas\Bot_ch.
- Use Constant:** Top: 0, Bottom: -100000.
- Buttons:** Calculate results, Cancel.

IP_Seis

The screenshot displays the IP_Seis software interface, which is used for seismic data processing and machine learning applications. The main window is titled "IP Seismic" and features a menu bar (File, Window, Help) and a toolbar. A file explorer on the left shows a list of files, including "PorP10", "ThicknessP10", "Thickness_PorP10", "PorP50", "ThicknessP50", "Thickness_PorP50", "PorP90", "ThicknessP90", "Thickness_PorP90", and "PointSetNN". The main display area shows two maps: "Surface=Thickness_PorP50" and "Surface=PorP50". A color scale on the right indicates values from 2 to 5. A "Function" dialog box is open, showing regression equations and R-squared values for two data series: "Thickness_PorMean - Thickness_PorP50" (Linear regression = $-6.30 \times X + 241.82$, $R^2=0.5175$, $R=0.7194$) and "Thickness_PorMean - Thickness_PorP90" (Linear regression = $-3.26 \times X + 202.75$, $R^2=0.9620$, $R=0.9808$). A scatter plot shows the relationship between "Thickness_PorP50" and "Thickness_PorMean". A histogram on the right shows the distribution of values, with a color scale from 0.06 to 0.16. The "DNN_SurfaceAttributes" dialog box is also visible, showing training options such as "Surface", "Max lag i", "Max lag j", "Number realizations", "Logarithm option", "Tikhonov alpha", "Iterations", "Cross validation (%)", "Deep learning option", "Hidden layer1 nodes", "Hidden layer2 nodes", "Hidden layer3 nodes", "Hidden layer4 nodes", and "Hidden layer5 nodes".

IP Seismic

File Window Help

Surface=Thickness_PorP50

Surface=PorP50

Function

Reset X Xmin: 0.02 Xmax: 0.14

- Thickness_PorMean - Thickness_PorP50
Linear regression = $-6.30 \times X + 241.82$
 $R^2=0.5175$, $R=0.7194$
- Thickness_PorMean - Thickness_PorP90
Linear regression = $-3.26 \times X + 202.75$
 $R^2=0.9620$, $R=0.9808$

Thickness_PorP50

Thickness_PorMean

HostID=5840AF18BFEBF8FF000406E3
DateStart=24.09.2016
DateEnd=25.10.2016

DNN_SurfaceAttributes

Input data Train data Graphics

Surface: [] C:\Projects\Wik ^
Z
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli
[x] Mean ampli

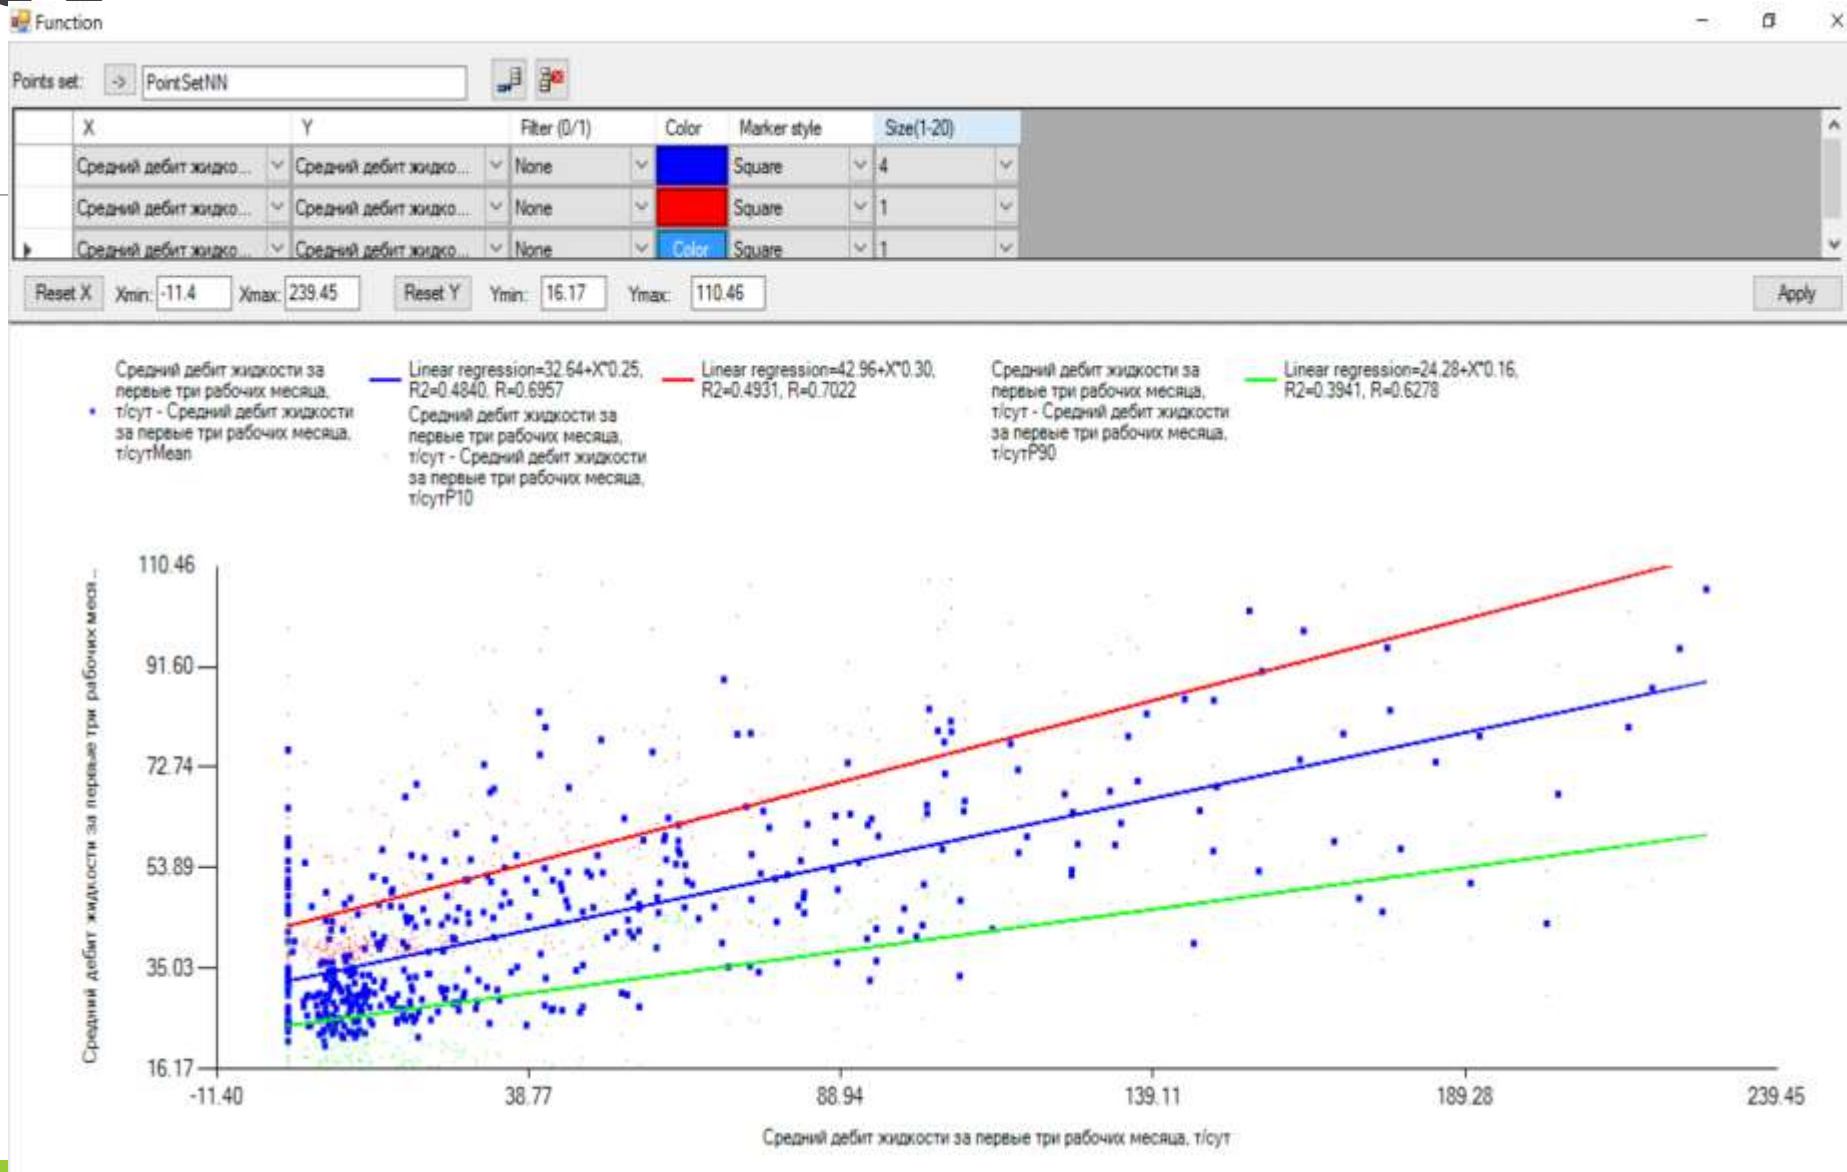
Max lag i: 2
Max lag j: 2

Number realizations: 25
Logarithm option: No

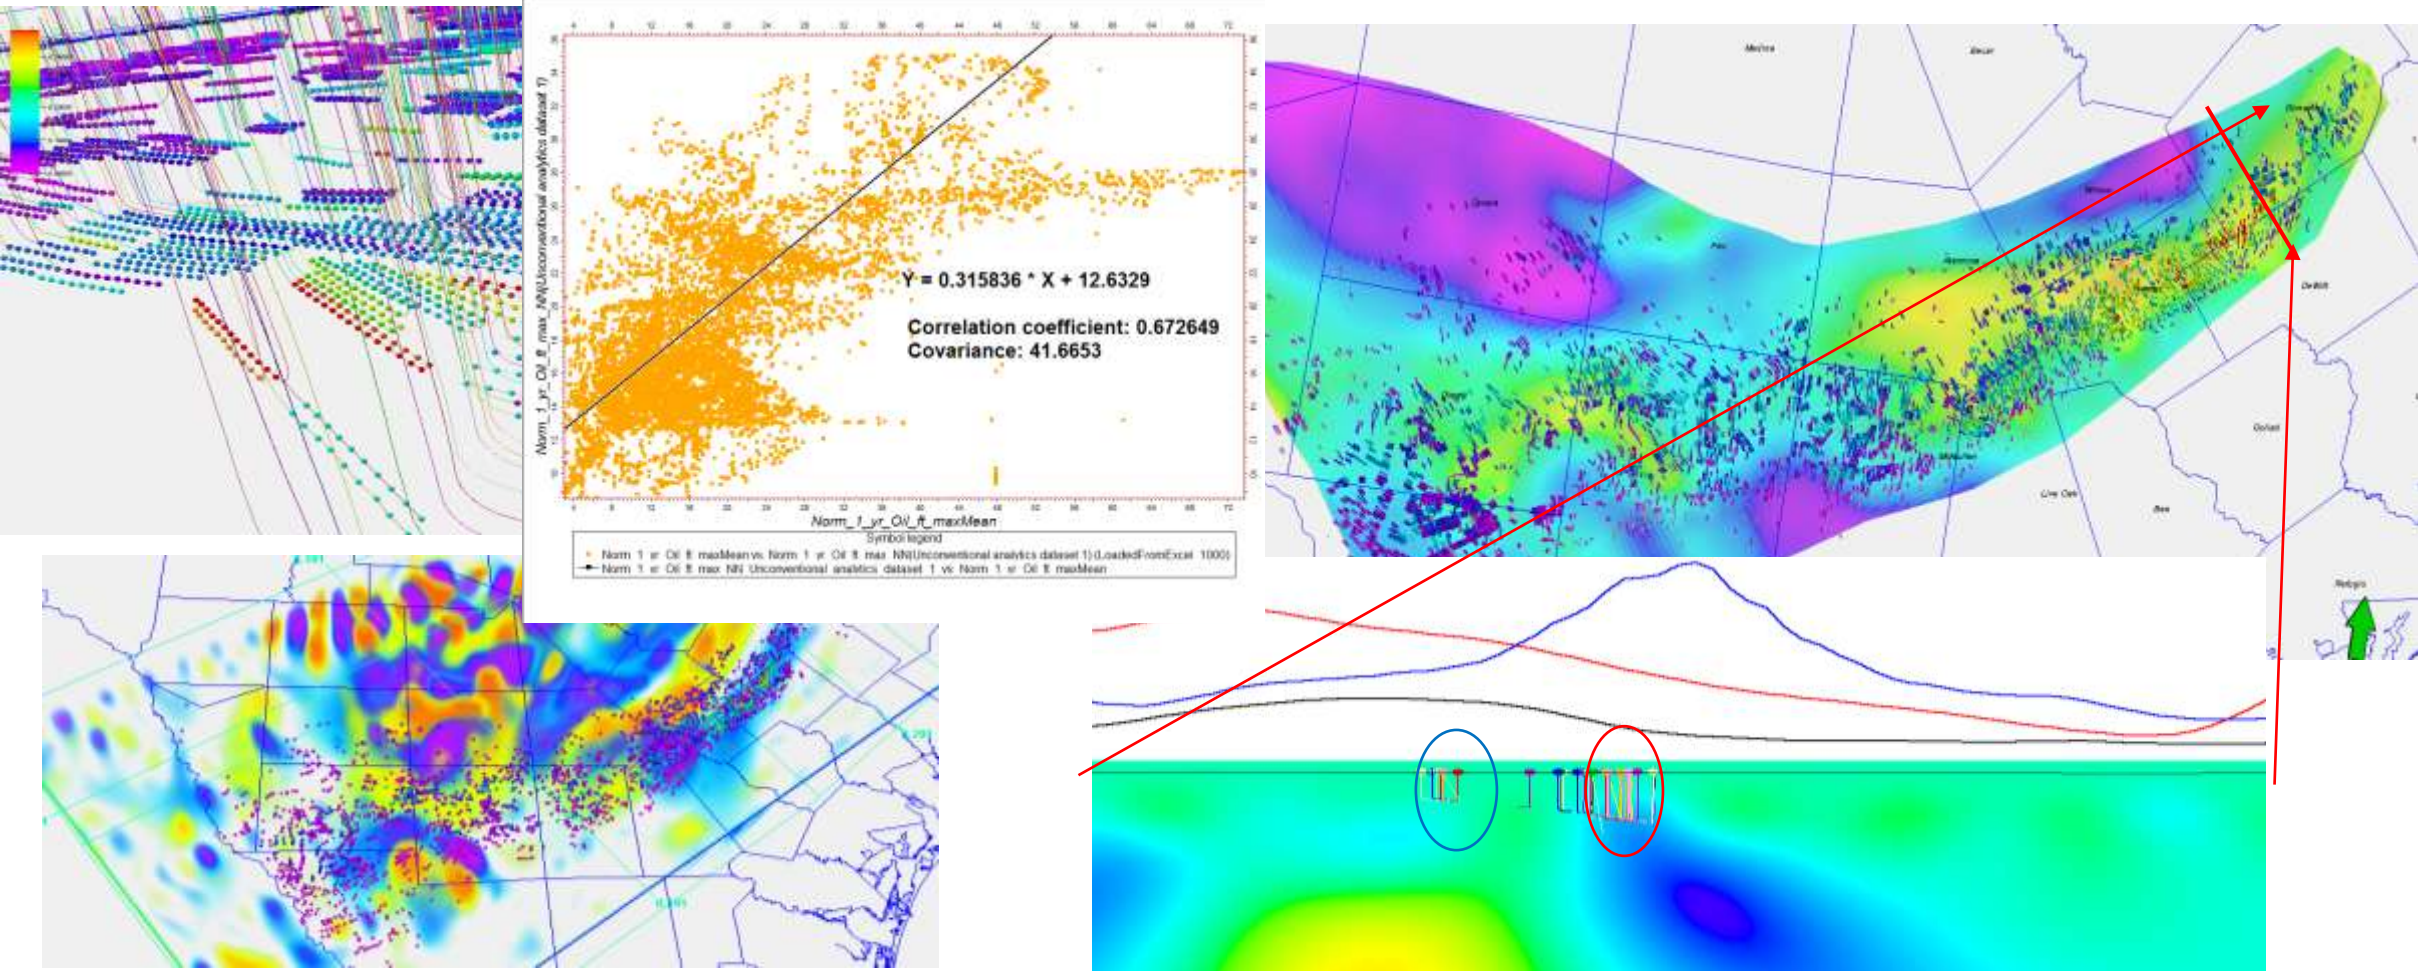
Tikhonov alpha: 0.001
Iterations: 1000
Cross validation (%): 10
Deep learning option: Kohone
Hidden layer1 nodes: 15
Hidden layer2 nodes: 11
Hidden layer3 nodes: 7
Hidden layer4 nodes: 5
Hidden layer5 nodes: 3

Calculate results Correlation analysis Cancel


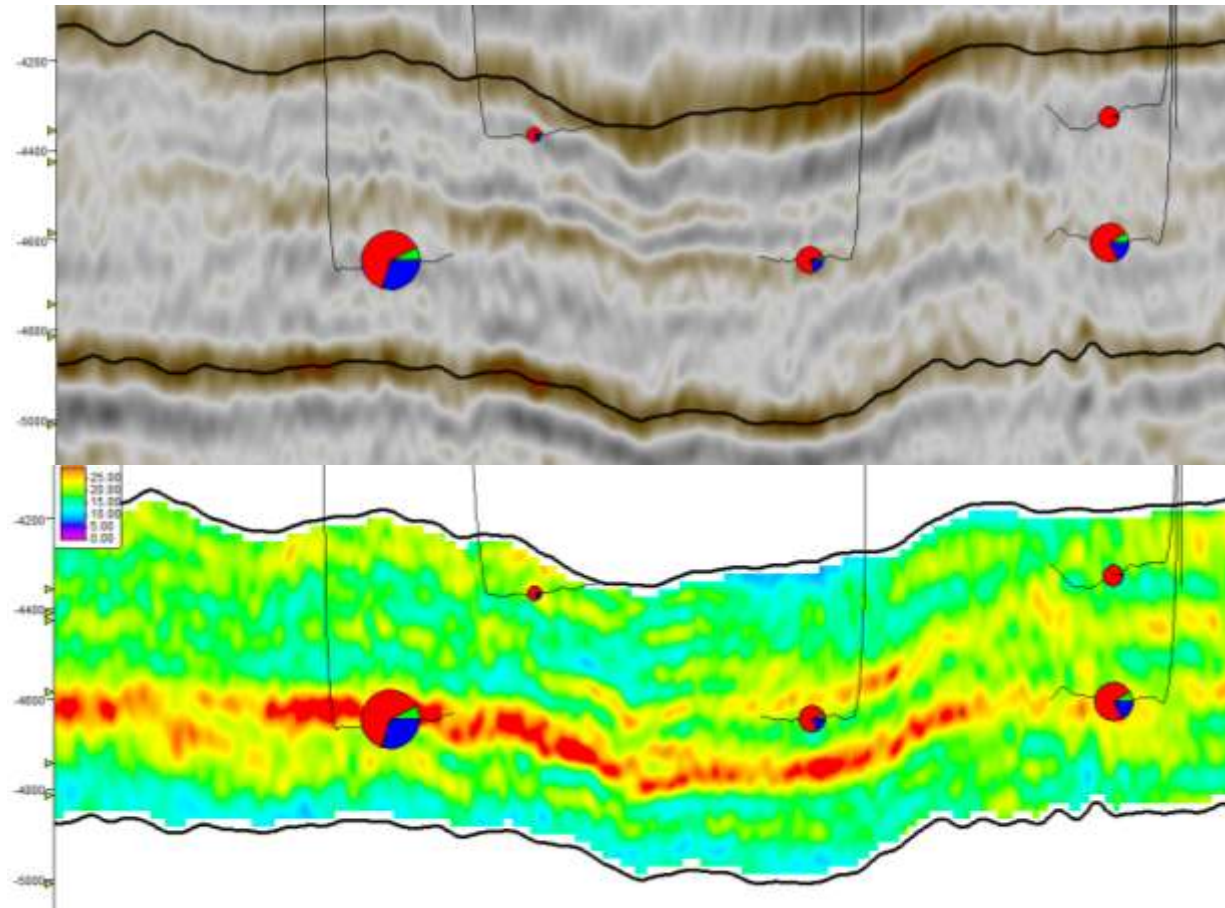
Прогноз продуктивности P10, P50, P90




Пример в Eagle Ford (12 тыс. скважин)



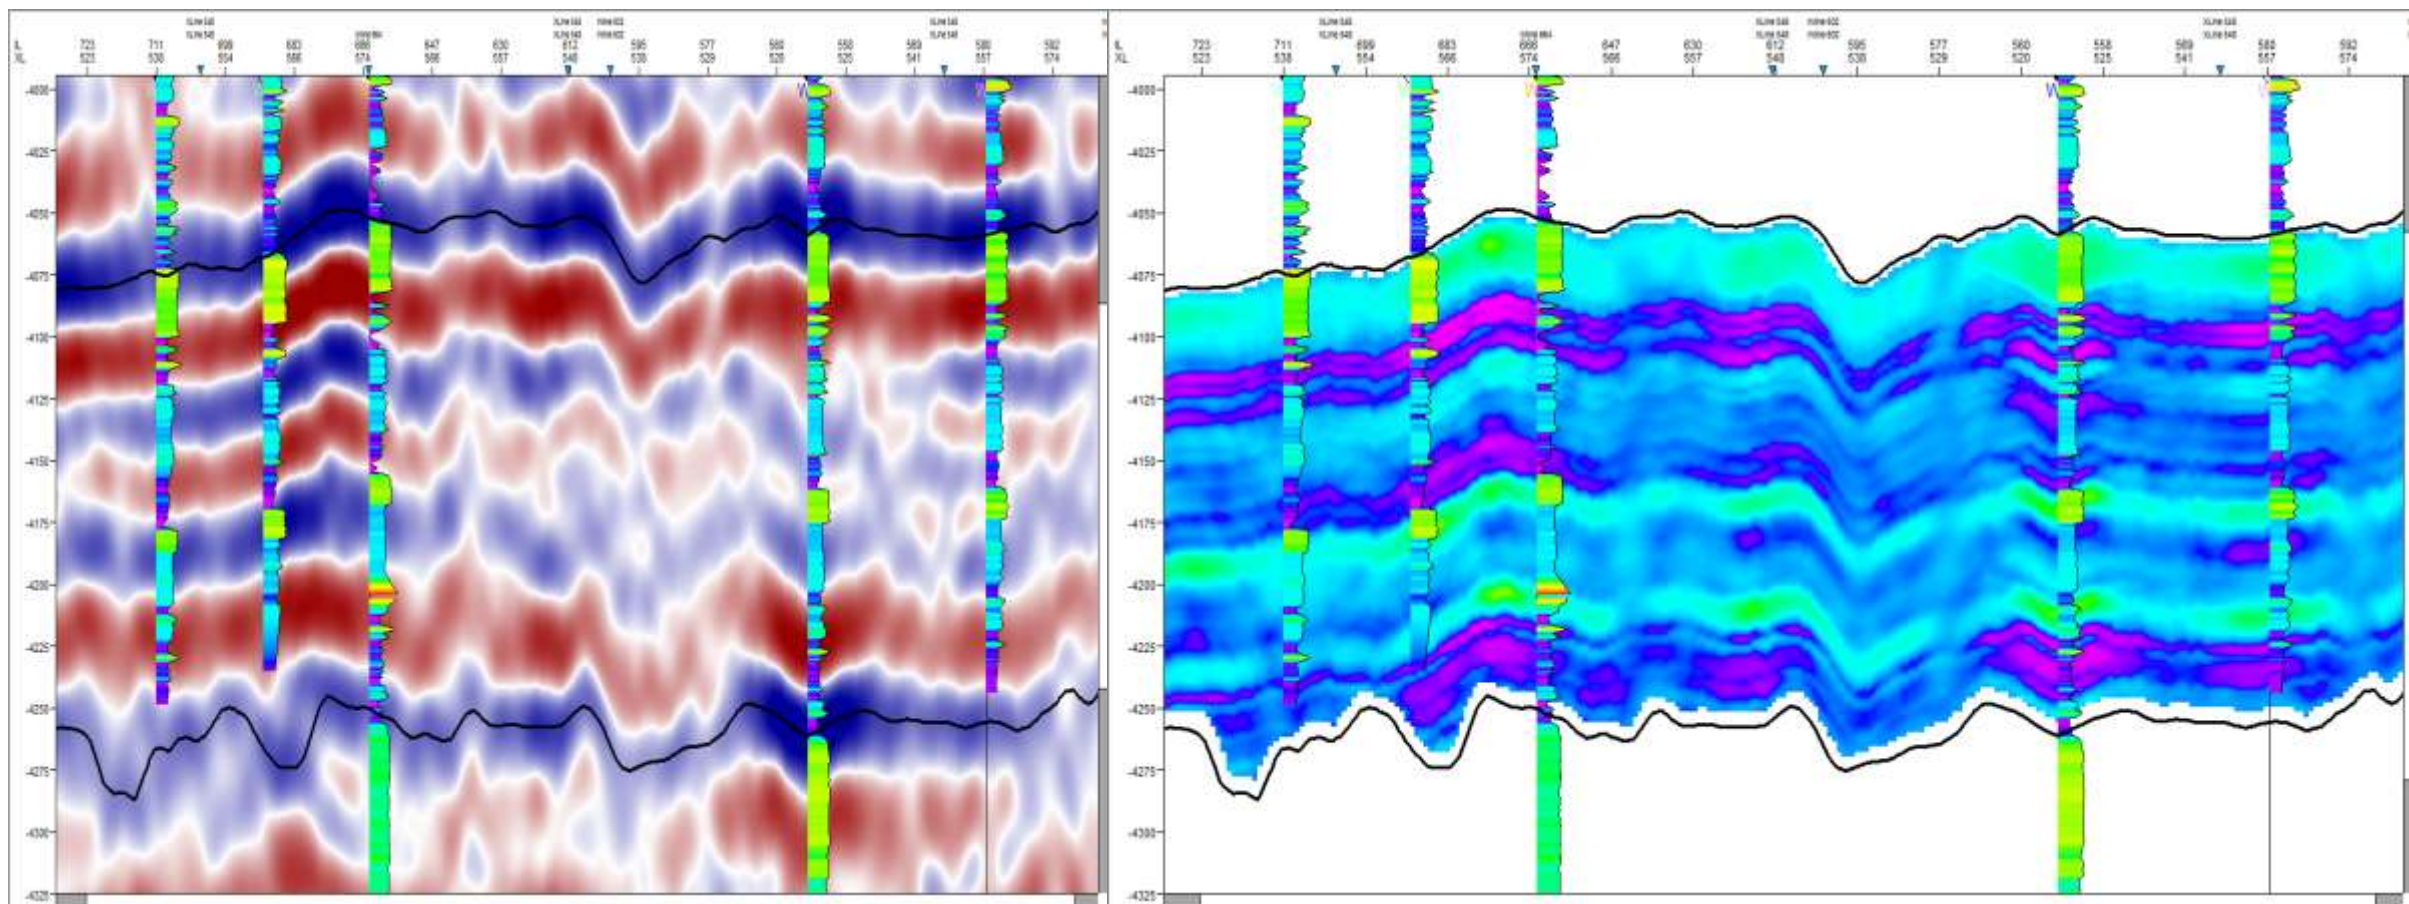
3D пример (Avalon dataset)




3D Sweet Spot analysis




Прогноз данных каротажа



Variance Cube



ML attribute



Заключение

1. Предлагается программный комплекс для решения задач глубокой интерпретации геолого-геофизических данных на основе

- Глубоких нейронных сетей
- Инверсионных построений
- Классификации
- Ортогональных разложений

2. Функциональные модули могут легко встроены в любую систему как плагины

3. Программный комплекс может применяться как дешевое автономное рабочее место

Статья в GEOPHYSICS,

VOL. 81, NO. 4 (JULY-AUGUST 2016); P. 1–9, 6 FIGS. 10.1190/GEO2015-0297.1

Hybrid combination genetic algorithm and controlled gradient method to train a neural network

Alexander Kobrunov¹ and Ivan Priezzhev²

ABSTRACT

Multivariate predictive analysis is a widely used tool in the petroleum industry in situations in which the deterministic nature of the relationship between a variable that requires prediction and a variable that is used for the purposes of such prediction is unknown or very complex. For example, to perform a sweet-spot analysis, it is necessary to predict potential oil and gas production rates on a map, using various geologic and geophysical attribute maps (porosity, density, seismic attributes, gravity, magnetic, etc.) and the initial oil and gas production rates of several control or training wells located in the area of interest. We have developed a new technology that allows for building a stable nonlinear predictive operator by using the combination of a neural network, a genetic algorithm, and a controlled gradient method. The main

idea behind the proposed technology is to combine stochastic and deterministic approaches during the construction of the predictive operator at the training stage. The proposed technology avoids many disadvantages of the genetic algorithm and gradients methods, such as a high level of dependency on the initial values; the phenomenon of over-fitting (overtraining), which results in creation of an operator with unstable predictability; and a low speed of decreasing error during iteration, and, as a result, a low level of prediction quality. However, the above-mentioned combination uses the advantages of both methods and allows for finding a solution significantly closer to a global minimum for the objective function, compared to simple gradient methods, such as back propagation. The combination of these methods together with Tikhonov regularization allows for building stable predictions in spatial or/and time coordinates.