

Геоинформатика. 2024. № 3. С. 21–29.
Geoinformatika. 2024;(3):21–29.

Применение ГИС-технологий

Научная статья
 УДК 550.834.05
<https://doi.org/10.47148/1609-364X-2024-3-21-29>

Применение алгоритмов классификации машинного обучения для прогноза вероятности наличия русел по сейсмическим данным

© 2024 г. — Мария Юрьевна Орешкова^{1,а)}, Александр Васильевич Буторин^{1,2}

¹Группа компаний «Газпром нефть»; Санкт-Петербург, Россия

² Санкт-Петербургский государственный университет, Институт наук о Земле; Санкт-Петербург, Россия

^{а)}wintersurprise@mail.ru

Аннотация: В статье анализируется применение различных алгоритмов классификации (Random Forest, Extra Trees, Gradient Boosting, Multi-layer Perceptron, Gaussian Naive Bayes, Voting Classifier) на основе машинного обучения “с учителем” как по отдельным сейсмическим атрибутам (амплитудные, фазовые, частотные), так и по совокупности сейсмических атрибутов, рассчитанных в интервале развития русловых систем для вероятностной оценки наличия русел. Объектом исследования являются отложения тюменской свиты группы месторождений, расположенных на территории Ханты-Мансийского автономного округа. Целью данной статьи является описание поиска наиболее эффективных сейсмических атрибутов и методов классификации машинного обучения для оптимизации методики и повышения точности прогноза вероятности наличия русловых систем.

Ключевые слова: *сейсморазведка; динамическая интерпретация; классификация.*

Для цитирования: Орешкова М.Ю., Буторин А.В. Применение алгоритмов классификации машинного обучения для прогноза вероятности наличия русел по сейсмическим данным // Геоинформатика. — 2024. — № 3. — С. 21–29. <https://doi.org/10.47148/1609-364X-2024-3-21-29>.

Application of GIS-technologies

Original article

Application of machine learning classification algorithms to predict probability of channel presence from seismic data

© 2024 — Maria Yu. Oreshkova^{1,а)}, Alexandr V. Butorin^{1,2}

¹Gazprom Neft Group of Companies; St. Petersburg, Russia

²St. Petersburg State University; St. Petersburg, Russia

^{а)}wintersurprise@mail.ru

Abstract: The article analyzes the application of various classification algorithms (Random Forest, Extra Trees, Gradient Boosting, Multi-layer Perceptron, Gaussian Naive Bayes, Voting Classifier) based on supervised machine learning, both for individual seismic attributes (amplitude, phase, frequency) and for a set of seismic attributes calculated in the interval of channel system development for probabilistic assessment of presence of channels. The object of the study is the deposits of the Tyumen suite of a group of deposits located in the Khanty-Mansiysk Autonomous Okrug. The purpose of this work is to find the most effective seismic attributes and machine learning classification methods to optimize the methodology and improve the accuracy of forecasting the probability of channel system presence.

Key words: *seismic exploration; dynamic interpretation; classification.*

For citation: Oreshkova M.Yu., Butorin A.V. Application of machine learning classification algorithms to predict probability of channel presence from seismic data. *Geoinformatika*. 2024;(3):21–29. <https://doi.org/10.47148/1609-364X-2024-3-21-29>. In Russ.

Введение

Наиболее полная информация о фациальном районировании изучаемой территории может быть получена по результатам комплексного анализа сейсмических атрибутов (амплитудных, фазовых и частотных) в целевом интервале, так как характеристики сейсмического отклика связаны с геологическими и петроупругими свойствами пласта, что дает возможность перейти к более детальному изучению его фациального строения. Различные

атрибуты динамического анализа, несмотря на взаимосвязь изучаемых характеристик, могут рассматриваться как по отдельности, так и в совокупности, что позволяет взглянуть на сейсмический отклик под разными углами [2]. Именно поэтому в рамках данного исследования анализируется применение различных алгоритмов классификации на основе машинного обучения «с учителем» как по отдельным сейсмическим атрибутам, так и по совокупности сейсмических атрибутов, рассчитанных в

интервале развития русловых систем для прогноза вероятности наличия определенной сейсмофации.

В данной статье показано развитие методики применения алгоритма классификации Random Forest для решения задачи фашиального районирования, подробно описанной в статье [1], в которой авторами использован метод классификации Random Forest Classifier для прогноза вероятности наличия русловых систем. Вектор признаков, которым выполнялась классификация, представлял собой значения амплитуд для каждой трассы, в заданном по времени окне 20 мс (рис. 1).

Целью статьи является описание поиска наиболее эффективных сейсмических атрибутов (амплитудных, фазовых и частотных) и методов классификации машинного обучения для оптимизации методики и повышения точности прогноза вероятности наличия русел. Результаты прогноза вероятности наличия русловых систем в дальнейшем могут быть использованы при геологической интерпретации и вероятностной оценке ресурсной базы.

Объектом исследования являются отложения тюменской свиты группы месторождений, расположенных на территории Ханты-Мансийского автономного округа.

Тюменская свита характеризуется преобладанием русловых фаций, связанных с развитием сложных речных систем, и низкой изученностью скважинами, что затрудняет геологическую интерпретацию получаемых результатов. На сейсмических атрибутах палеорула и палеоканалы выделяются вручную детерминистическим способом, ручная интерпретация достаточно субъективна и не учитывает индивидуальных особенностей зрительного восприятия интерпретатора. Ввиду этого вопрос автоматизации процесса интерпретации, минимизации субъективного взгляда для оценки

влияния отложения типа «русло» на форму отражения остается актуальным.

Методика и результаты

В данной статье рассматривается применение алгоритмов обучения «с учителем», требующих на вход априорную информацию в виде экспертной разметки об идентифицированной фашиальной обстановке некоторой области площади исследования. Наиболее распространенным вариантом классификации сейсмофаций является классификация по форме трассы. В данном исследовании рассматривается возможность классификации как по форме трассы, так и по фазовым и частотным параметрам сейсмического отклика в целевом интервале с учетом априорной геологической информации.

Для анализа применимости классификаций по различным сейсмическим атрибутам использовалась индексная карта для обучения, представляющая массив из значений 1 и 2, где 1 — зона отсутствия русел, 2 — зона русел, составляющая порядка 10 % исследуемой площади (рис. 2 F). Вектор признаков включает значения пяти атрибутов (амплитуда, мгновенная фаза, мгновенная частота, огибающая, sweetness) для каждой трассы, извлеченные в заданном временном интервале 20 мс. Таким образом, обучающая выборка представляет набор атрибутов в окне 20 мс для каждой трассы (10 карт с шагом 2 мс для каждого атрибута, т. е. 50 карт) и соответствующее значение класса «русло», «не русло». Карты средних значений используемых атрибутов в окне 20 мс представлены на рис. 2. Атрибуты рассчитывались с применением преобразования Гильберта, заключающегося в представлении трассы как комплексной величины, где действительная часть представлена самой трассой, а мнимая является результатом поворота фазы на 90° , реализованного с помощью библиотеки SciPy [3]. Подобное представление трассы позволило перейти к оценке «мгновенных» параметров — амплитуды, частоты, фазы и т. д.

Рис. 1. Временной разрез, демонстрирующий целевой интервал в окне сейсмической записи 20 мс от отражающего горизонта J_3 , и положение разреза на амплитудном слайсе

Fig. 1. A time section showing target interval in seismic recording window 20 ms from the reflecting horizon J_3 , and position of section on amplitude slice


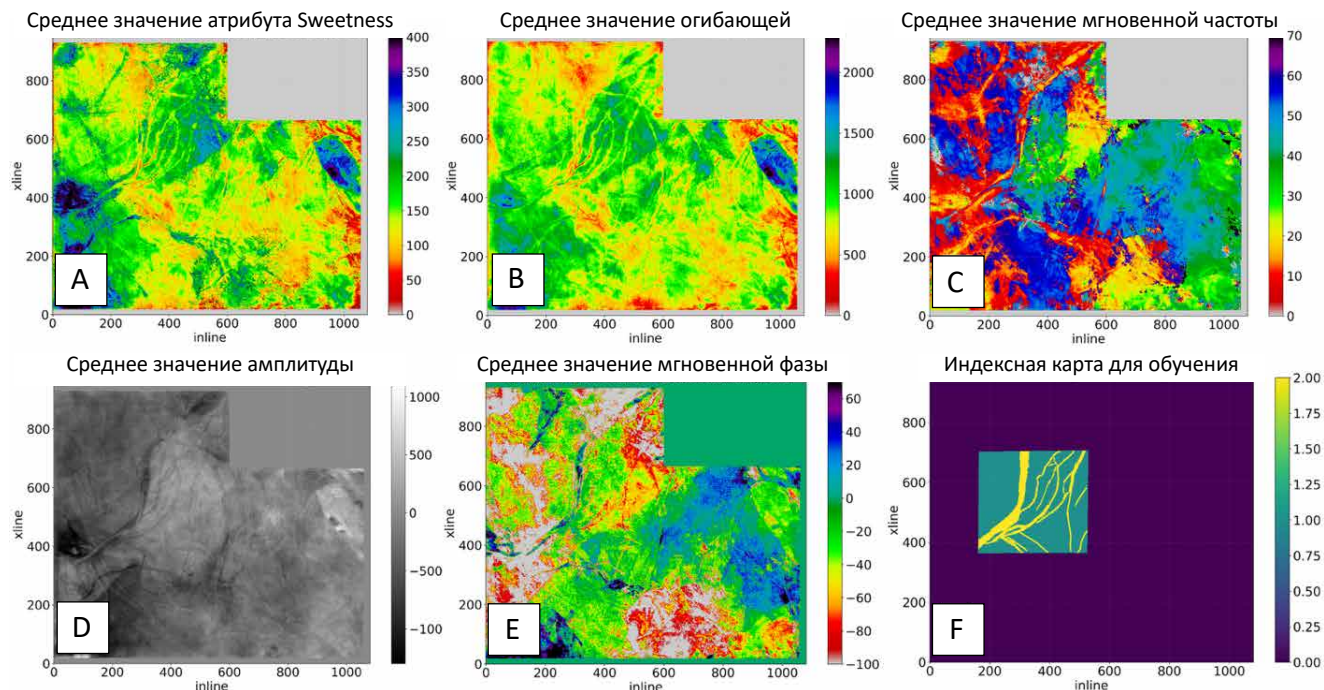


Рис. 2. Карты сейсмических атрибутов, снятые в окне сейсмической записи 20 мс от отражающего горизонта J_3
 A — атрибут sweetness, B — атрибут огибающей, C — атрибут мгновенной частоты, D — атрибут амплитуды, E — атрибут мгновенной фазы, F — индексная карта, используемая для обучения классификатора

*Fig. 2. Maps of seismic attributes taken in seismic recording window 20 ms from the reflecting horizon J_3
 A — sweetness attribute, B — envelope attribute, C — instantaneous frequency attribute, D — amplitude attribute, E — instantaneous phase attribute, F — index map used to train classifier*



На вход для работы классификатора подавался вектор признаков как в качестве набора значений каждого отдельного атрибута, так и совокупности атрибутов, и использовался классификатор случайного леса (Random Forest Classifier). Настройка оптимальных гиперпараметров классификатора выполнялась с помощью алгоритма поиска по сетке GridSearchCV библиотеки scikit-learn [4], ко-

торый позволяет выбрать наилучшие параметры настройки модели. Так, при использовании карты признаков по совокупности атрибутов (50 карт) использовался ансамбль из 17 решающих деревьев, ограниченных по глубине ветвления 40 узлами. В ходе тестирования применения каждого набора атрибутов анализировались метрики машинного обучения: точность (precision), чувстви-

Табл. 1. Оценка качества классификации по различным сейсмическим атрибутам

Tab. 1. Assessment of classification quality by various seismic attributes

Атрибут	Не русло			Русло		
	Precision	Recall	f1 score	Precision	Recall	f1 score
Амплитуда	0,95	0,91	0,93	0,66	0,80	0,72
Огибающая	0,94	0,94	0,94	0,73	0,73	0,73
Мгновенная фаза	0,92	0,93	0,93	0,68	0,64	0,66
Мгновенная частота	0,92	0,94	0,93	0,71	0,62	0,66
Sweetness	0,94	0,94	0,94	0,75	0,73	0,74
Совокупность атрибутов	0,95	0,95	0,95	0,79	0,79	0,79

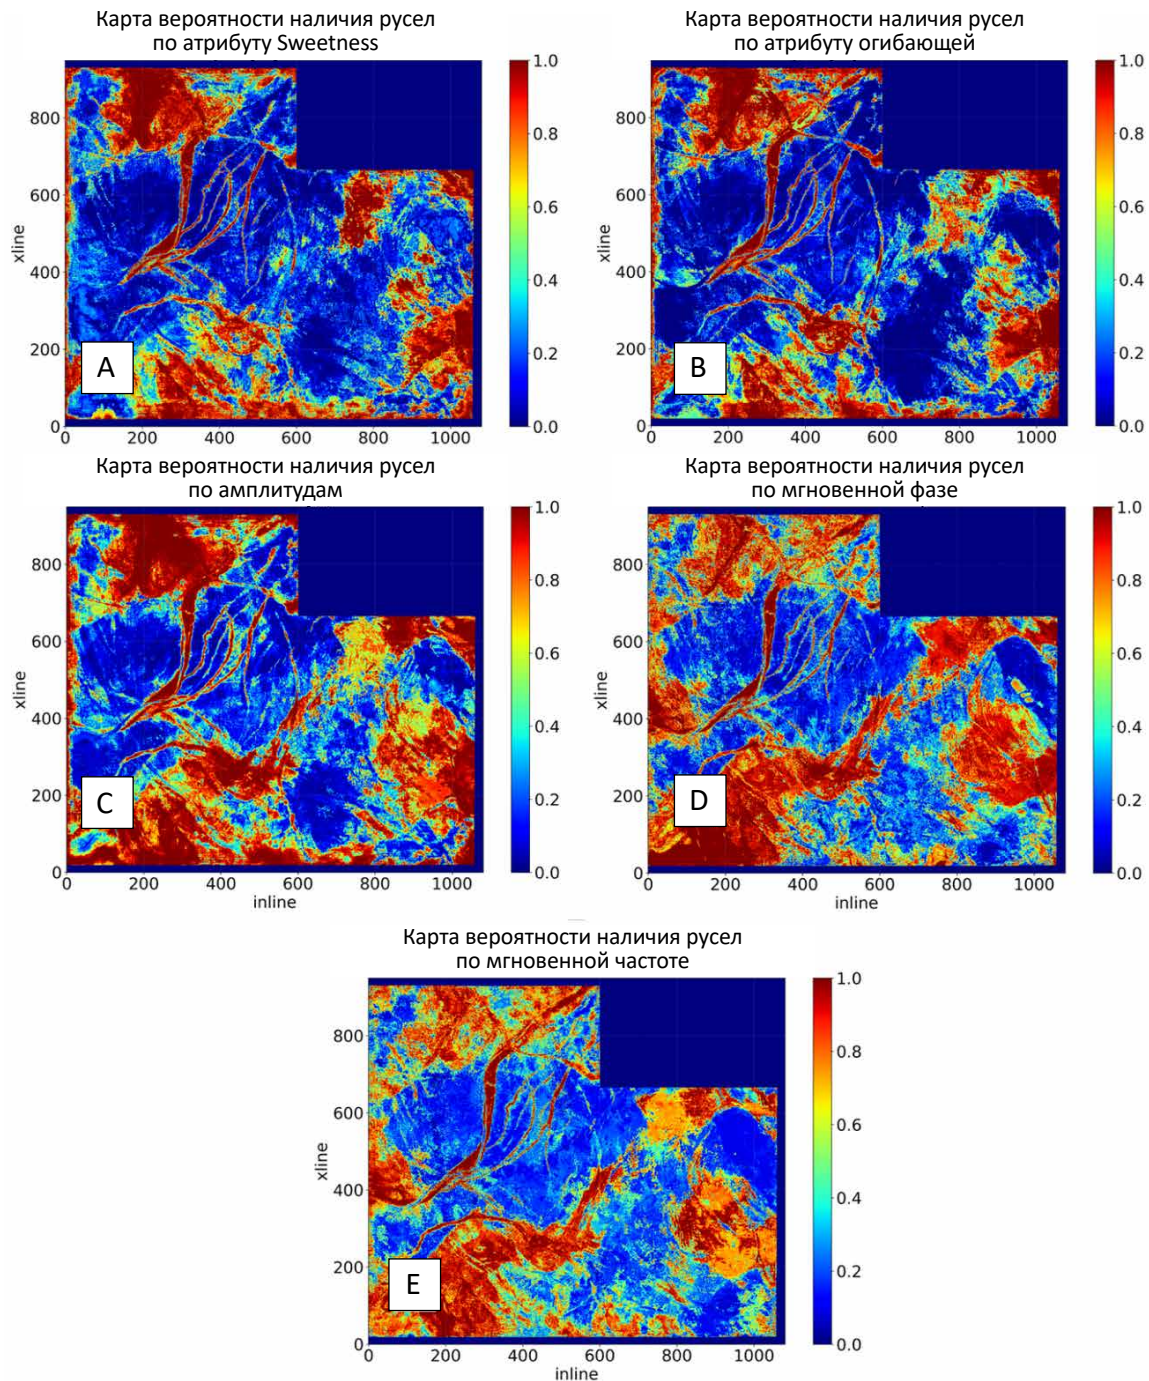
ность (recall) и F -мера (f1 score), представленные в табл. 1.

По каждому набору значений определенного атрибута строились карты прогноза вероятности наличия русел, представленные на рис. 3.

Наиболее точный прогноз наличия палеорусловых систем достигается путем применения совокуп-

ности динамических атрибутов, при этом метрика точности (precision) для класса «не русло» составила 95 %, а для класса «русло» — 79 %. Стоит отметить, что карта вероятности наличия русел, полученная по атрибуту мгновенной частоты, наиболее информативна с геологической точки зрения, так как более детально и корректно отображает наличие палеорусла в северной части изучаемой площади.

Рис. 3. Карты вероятности наличия русловых систем
Fig. 3. Maps of probability of presence of channel systems



A — по атрибуту sweetness, B — по атрибуту огибающей, C — по значениям амплитуд, D — по атрибуту мгновенной фазы, E — по атрибуту мгновенной частоты
A — by sweetness attribute, B — by envelope attribute, C — by amplitude values, D — by instantaneous phase attribute, E — by instantaneous frequency attribute

В настоящее время существуют различные алгоритмы классификации машинного обучения, отличающиеся своей архитектурой, эффективностью и точностью прогноза. В рамках данного исследования анализировались следующие алгоритмы классификации, реализованные в библиотеке scikit-learn [5]:

1. Random Forest Classifier (классификатор случайного леса)

Алгоритм заключается в использовании ансамбля решающих деревьев. В качестве исходных данных рассматриваются пары объектов $\{x, y\}$, где x — вектор признаков (значения амплитуд), а y — метка класса (значение с обучающей карты). Основным элементом Random Forest является дерево решений. При построении дерева решений на каждом шаге выбираются признак из вектора x и значение порога, который делит входную выборку на две части — данный процесс является ветвлением дерева решений. Разделение может происходить до момента, когда в каждой полученной подвыборке остаются только элементы, относящиеся к одному классу, что будет давать ответ дерева решений. Подобный алгоритм однозначно классифицирует входную выборку данных, но при этом является «переобученным», т. е. будет давать ошибки на выборке, не входящей в обучающий массив. Ключевая идея метода Random Forest заключается в использовании ансамбля (множества) деревьев решения, при этом в рамках алгоритма происходит осреднение ответов, полученных каждым отдельным деревом. Подобный подход позволяет получить эффективный инструмент, более устойчивый к переобучению [1].

2. Extra Trees Classifier (классификатор дерева решений, чрезвычайно рандомизированные деревья)

Это тип метода ансамблевого обучения, который объединяет результаты нескольких декоррелированных деревьев решений, собранных в «лесу» (ансамбле деревьев), для вывода результата классификации. По своей концепции он очень похож на классификатор случайного леса и отличается от него только способом построения деревьев решений в лесу. Каждое дерево решений в лесу дополнительных деревьев строится на основе исходной обучающей выборки. Затем на каждом тестовом узле каждому дереву предоставляется случайная выборка из k признаков из набора признаков, из которой каждое дерево решений должно выбрать лучший признак для разделения данных на основе некоторых математических критериев (обычно индекса Джини). Эта случайная выборка функций приводит к созданию нескольких декоррелированных деревьев решений. Чтобы выполнить выбор признаков с использованием указанной выше структуры леса, во время построения леса для каждого признака необходимо нормализованное

общее сокращение математических критериев, используемых при принятии решения о разделении признаков. Это значение называется важностью Джини признака. Чтобы выполнить выбор функций, каждая функция упорядочивается в порядке убывания в соответствии с важностью Джини каждой функции, и пользователь выбирает первые k функций по своему выбору [6].

3. Gradient Boosting Classifier (классификатор градиентного бустинга)

Градиентный бустинг — это один из видов метода ансамблевого обучения, который обучает модель последовательно, и каждая новая модель пытается исправить предыдущую модель. Он объединяет нескольких «слабых учеников» в «сильных учеников». Каждая новая модель обучается минимизировать функцию потерь, такую как среднеквадратическая ошибка или перекрестная энтропия предыдущей модели. На каждой итерации алгоритм вычисляет градиент функции потерь относительно предсказаний текущего ансамбля, а затем обучает новую слабую модель для минимизации этого градиента. Затем прогнозы новой модели добавляются в ансамбль, и процесс повторяется до тех пор, пока не будет выполнен критерий остановки [6].

4. Gaussian Naive Bayes (гауссов наивный байесовский классификатор)

Алгоритм вероятностной классификации Gaussian Naive Bayes (GNB) основан на теореме Байеса. Учитывая метку класса, предполагается, что объекты подчиняются гауссовскому распределению и условно независимы. Для непрерывных данных GNB особенно полезен. Алгоритм вычисляет дисперсию и среднее значение каждого признака для каждого класса во время обучения. На этапе прогнозирования он определяет, к какому классу с наибольшей вероятностью принадлежит экземпляр путем расчета вероятности каждого класса. В мире машинного обучения гауссов наивный байесовский алгоритм — это простой, но мощный алгоритм, используемый для задач классификации [6].

5. Multi-layer Perceptron Classifier (классификатор с использованием многослойных перцептронов)

Это своего рода искусственная нейронная сеть, которая имеет несколько слоев связанных узлов (также известных как нейроны) и часто используется для различных задач машинного обучения, включая классификацию и регрессию. Архитектура алгоритма включает:

1. Входной слой: состоит из нейронов, которые непосредственно воспринимают функции набора данных. Каждый нейрон во входном слое представляет собой объект, а общее число нейронов входного слоя равно общему числу объектов набора данных.

2. Скрытый слой: между входным и выходным слоями может существовать один или несколько скрытых слоев. Число нейронов в каждом скрытом слое (это гиперпараметр, который вы можете выбрать) варьирует в зависимости от скрытого слоя. Эти скрытые слои необходимы для распознавания сложных закономерностей в данных.

3. Выходной уровень: окончательные прогнозы или выходные данные генерируются выходным слоем с использованием данных, обработанных на скрытых уровнях.

В многоклассовой классификации участвует столько нейронов, сколько существует классов, и каждый нейрон генерирует оценку вероятности для определенного класса [6].

6. Voting Classifier (классификатор голосования)

Создавая различные модели прогнозирования и алгоритмы классификаций, возникает необходимость их совместной интеграции и использования подходов ансамблевого обучения, объединяющих множество базовых моделей для получения более эффективной и точной модели. Теория, лежащая в основе этого подхода, заключается в возможности уменьшения систематической ошибки и вариаций, а также повышении производительности, объединяя прогнозы многих моделей.

Классификатор голосования — это модель машинного обучения, которая накапливает опыт путем обучения на наборе нескольких моделей и

прогнозирует результат (класс) на основе класса с наибольшей вероятностью. Чтобы спрогнозировать выходной класс на основе большинства голосов, он усредняет результаты каждого классификатора, предоставленного в классификаторе голосования. Идея состоит в том, чтобы построить единую модель, которая учится на основе различных моделей и прогнозирует выходные данные на основе их совокупного большинства голосов для каждого выходного класса, а не строит отдельные специализированные модели и определяет точность для каждой из них [6].

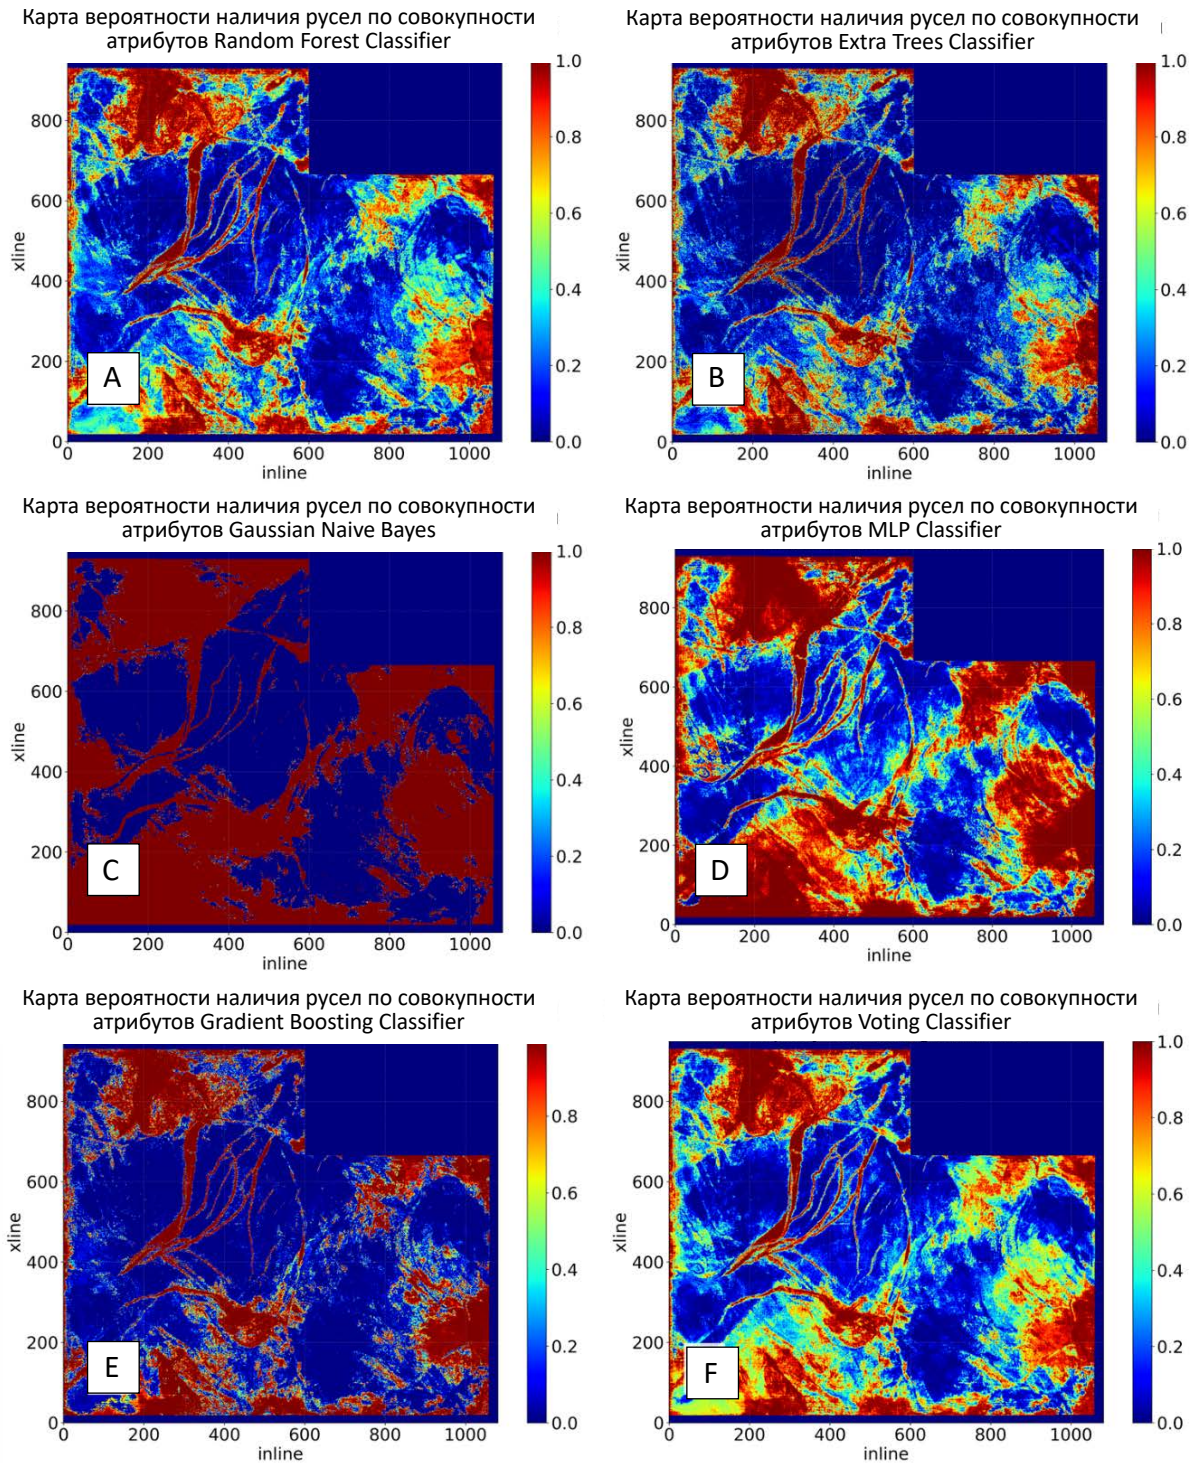
В результате тестирования описанных алгоритмов классификации, для каждой модели были подобраны наилучшие гиперпараметры и получены карты прогноза вероятности наличия русловых отложений по совокупности атрибутов, представленные на рис. 4, а также проанализированы метрики машинного обучения: точность (precision), чувствительность (recall) и F -мера (f1 score), представленные в табл. 2.

Наибольшее значения метрики чувствительности (precision) для данного конкретного примера для класса «русло» достигнуты с применением классификатора Extra Trees Classifier (классификатор чрезвычайно рандомизированных деревьев), а метрики точности (recall) для Random Forest Classifier (классификатор случайного леса). Но оптимальной и рекомендованной к дальнейшему использованию при геологической интерпретации является прогнозная карта, полученная с приме-

Табл. 2. Оценка качества классификации при применении различных классификаторов
Tab. 2. Assessment of classification quality when using various classifiers

Классификатор	Не русло			Русло		
	Precision	Recall	f1 score	Precision	Recall	f1 score
Random Forest Classifier	0,95	0,95	0,95	0,79	0,79	0,79
Extra Trees Classifier	0,93	0,98	0,95	0,88	0,66	0,75
Gradient Boosting Classifier	0,94	0,96	0,95	0,82	0,75	0,79
Gaussian Naive Bayes	0,92	0,93	0,92	0,68	0,62	0,65
Multi-layer Perceptron Classifier	0,95	0,88	0,91	0,61	0,81	0,69
Voting Classifier	0,95	0,97	0,96	0,84	0,75	0,79

Рис. 4. Карты вероятности наличия русловых систем по совокупности атрибутов при использовании различных классификаторов
Fig. 4. Probability maps of presence of channel systems based on a set of attributes when using various classifiers



A — Random Forest Classifier, B — Extra Trees Classifier, C — Gradient Boosting Classifier, D — Gaussian Naive Bayes, E — Multi-layer Perceptron Classifier, F — Voting Classifier
 A — Random Forest Classifier, B — Extra Trees Classifier, C — Gradient Boosting Classifier, D — Gaussian Naive Bayes, E — Multi-layer Perceptron Classifier, F — Voting Classifier

нием классификатора Voting Classifier (классификатор голосования). Этот классификатор в данном случае объединяет модели Random Forest, Extra Trees Classifier и Multi-layer Perceptron Classifier для получения более эффективной и точной модели. Метрика точности (precision) для класса «не русло» составила 95 %, а для класса «русло» 84 – %.

Заключение

В статье проанализировано применение различных алгоритмов классификации (Random Forest, Extra Trees, Gradient Boosting, Multi-layer Perceptron, Gaussian Naive Bayes, Voting Classifier) на основе машинного обучения «с учителем» как по отдельным сейсмическим атрибутам (амплитудные, фазовые, частотные), так и по совокупности сейсмических атрибутов, рассчитанных в интервале развития русловых систем для вероятностной оценки наличия русловых систем.

Наиболее эффективный и точный прогноз в соответствии с метриками машинного обучения получается при использовании в качестве вектора признаков совокупности амплитудных, частотных и фазовых сейсмических атрибутов одновременно. С точки зрения детальности идентификации палеорусловых систем по сейсмическим атрибутам

имеет преимущество карта вероятности наличия русел, полученная по атрибуту мгновенной частоты.

Анализируя полученные прогнозные карты вероятности наличия русел, стоит отдельно отметить области повышенной вероятности наличия русел в северной, южной и юго-восточной частях площади исследования. По результатам кластеризации установлено, что в этих фрагментарных областях амплитудные, фазовые, частотные характеристики являются схожими с характеристиками более контрастно выраженных русел, и соответственно, также обладают достаточно высокой вероятностью наличия русел. Теоретически это могут быть размытые части русел, форма которых не так ярко и очевидно выражена на сейсмическом изображении.

Для оптимизации методики и повышения точности прогноза вероятности наличия русловых отложений рекомендуется на каждом конкретном примере тестировать различные алгоритмы классификаций машинного обучения и в соответствии с полученными метриками и картами прогноза выбирать наиболее предпочтительные варианты. Использование классификатора Voting Classifier как инструмента для построения ансамбля базовых моделей классификации позволяет повысить точность и эффективность итогового прогноза.

Список источников

1. Буторин А.В., Мохов Г.В. Применение метода классификации Random Forest для решения задачи фациального районирования по данным сейсморазведки // ПРОНЕФТЬ. Профессионально о нефти. – 2021. – Т. 6. – № 3. – С. 23–29. DOI: 10.51890/2587-7399-2021-6-3-23-29.
2. Ольнева Т.В. Сейсмофациальный анализ. Образы геологических процессов и явлений в сейсмическом изображении. – М. – Ижевск: ИКИ РАН, 2017. – 152 с.
3. Hilbert [Электронный ресурс] // SciPy documentation 1.14.0. – 2024. – Режим доступа: <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.hilbert.html> (дата обращения: 02.08.2024).
4. GridSearchCV [Электронный ресурс] // Scikit-Learn 1.5.1. – 2024. – Режим доступа: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html (дата обращения: 02.08.2024).
5. Ensembles: Gradient boosting, random forests, bagging, voting, stacking [Электронный ресурс] // Scikit-Learn 1.5.1. – 2024. – Режим доступа: <https://scikit-learn.org/stable/modules/ensemble.html> (дата обращения: 02.08.2024).
6. Machine Learning Tutorial [Электронный ресурс] / GeeksforGeeks. – 20.06.2024. – Режим доступа: <https://www.geeksforgeeks.org/machine-learning/?ref=lbp> (дата обращения: 31.07.2024).

References

1. Butorin A.V., Mokhov G.V. Application of the Random Forest classification method for facies zoning according to seismic data. *PRONEFT. Professionals about oil*. 2021;6(3):23–29. DOI: 10.51890/2587-7399-2021-6-3-23-29.
2. Ol'neva T.V. Seismofatsial'nyi analiz. Obrazy geologicheskikh protsessov i yavlenii v seismicheskom izobrazhenii [Seismic facies analysis. Images of geological processes and phenomena in seismic representation]. Moscow–Izhevsk: IKI RAN; 2017. 152 p.
3. Hilbert. In: SciPy documentation 1.14.0. 2024. Available at: <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.hilbert.html> (accessed 02.08.2024).
4. GridSearchCV. In: Scikit-Learn 1.5.1. 2024. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html (accessed 02.08.2024).
5. Ensembles: Gradient boosting, random forests, bagging, voting, stacking. In: Scikit-Learn 1.5.1. 2024. Available at: <https://scikit-learn.org/stable/modules/ensemble.html> (accessed 02.08.2024).
6. Machine Learning Tutorial. GeeksforGeeks. 20.06.2024. Available at: <https://www.geeksforgeeks.org/machine-learning/?ref=lbp> (accessed 31.07.2024).

Статья поступила в редакцию 29.07.2024 г., одобрена после рецензирования 11.08.2024 г., принята к публикации 01.09.2024 г.
The article was submitted 29.07.2024; approved after reviewing 11.08.2024; accepted for publication 01.09.2024.

Информация об авторах

Орешкова Мария Юрьевна

Ведущий специалист
 Группа компаний «Газпром нефть»
 190000 Санкт-Петербург, ул. Почтамтская, д. 3–5
 e-mail: wintersurprise@mail.ru

Буторин Александр Васильевич

Кандидат геолого-минералогических наук
 Доцент кафедры геофизики
 Санкт-Петербургский государственный университет
 199034 Санкт-Петербург, Университетская наб., д. 7–9
 Руководитель проекта по развитию дисциплины
 «сейсморазведка»
 Группа компаний «Газпром нефть»
 190000 Санкт-Петербург, ул. Почтамтская, д. 3–5
 e-mail: a.butorin@spbu.ru
 ORCID: 0000-0002-6074-1439
 Scopus Author ID: 56370048400
 Researcher ID: B-7405-2019
 SPIN-код: 8474-6120
 Author ID: 877389

Information about authors

Maria Yu. Oreshkova

Leading Specialist
 Gazprom нефt company group
 3-5, Pochtamtskaya str., St. Petersburg, 190000, Russia
 e-mail: wintersurprise@mail.ru

Alexandr V. Butorin

Candidate of Geological and Mineralogical Sciences
 Associate Professor
 Institute of Earth Sciences, Saint Petersburg State University
 7-9, Universitetskaya nab., St. Petersburg, 199034, Russia
 Head of seismic discipline
 Gazprom нефt company group
 3-5, Pochtamtskaya str., St. Petersburg, 190000, Russia
 e-mail: a.butorin@spbu.ru
 ORCID: 0000-0002-6074-1439
 Scopus Author ID: 56370048400
 Researcher ID: B-7405-2019
 SPIN-код: 8474-6120
 Author ID: 877389