

Григорьев Я. Ю., Альхименко И. Н.
Ya. Yu. Grigoriev, I. N. Alkhimenko

ИСПОЛЬЗОВАНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ ИЗМЕНЕНИЙ БЕРЕГОВОЙ ЛИНИИ РЕКИ АМУР

USING MACHINE LEARNING FOR THE TASK OF PREDICTING CHANGES IN THE COASTLINE OF THE AMUR RIVER

Григорьев Ян Юрьевич – кандидат физико-математических наук, доцент, проректор по учебной работе Комсомольского-на-Амуре государственного университета (Россия, Комсомольск-на-Амуре).

Yan Yu. Grigoriev – PhD in Physics and Mathematics, Associate Professor, Vice-Rector for Academic Affairs, Komsomolsk-na-Amure State University (Russia, Komsomolsk-on-Amur).

Альхименко Игорь Николаевич – студент Комсомольского-на-Амуре государственного университета (Россия, Комсомольск-на-Амуре).

Igor N. Alkhimenko – Student, Komsomolsk-na-Amure State University (Russia, Komsomolsk-on-Amur).

Аннотация. В работе рассматриваются подходы к решению задач прогнозирования изменения наблюдаемых областей с заданными характеристиками методами машинного обучения на примере задачи прогнозирования изменения береговой линии реки Амур. Производится сравнение методов, и выбирается базовый метод с наибольшей предсказательной способностью для построения интеллектуальной системы. Рассматривается модификация алгоритма путём введения дополнительных характеристик, описывающих скорости и ускорения изменения точек границ. Анализ результатов исследования производится на основе оценки относительной и среднеквадратической ошибок.

Summary. The paper considers approaches to solving problems of forecasting changes in observed areas with given characteristics using machine learning methods on the example of the problem of forecasting changes in the Amur River coastline. The methods are compared and the basic method with the highest predictive ability for building an intelligent system is selected. Modification of the algorithm by introducing additional characteristics describing velocities and accelerations of boundary point changes is considered. The results of the study are analyzed based on relative and RMS error estimation.

Ключевые слова: прогнозирование, береговая линия, дистанционное зондирование, машинное обучение, модификация модели.

Key words: forecasting, coastline, remote sensing, machine learning, model modification.

УДК 004.92

Введение. Проблема обнаружения отклонений состояния земной поверхности от нормального является одной из ключевых задач, решаемых научным сообществом. Для принятия стратегии действия по предотвращению последствий нештатных ситуаций необходимо производить оценку процессов во времени. Задача является актуальной для таких динамических процессов, как разливы нефти, распространение вредных веществ, предсказание паводковой ситуации и т. п.

Для построения модели и оценки её адекватности рассматривается сезонное половодье реки Амур. Данные о паводковом состоянии используются для обучения интеллектуальной системы прогнозирования изменения береговой линии. Применяется интегрированный подход, объединяющий несколько моделей, позволяющих на основе компьютерного зрения строить единую прогнозную модель изменения наблюдаемых областей. Учитываются скорость и ускорение изменений границ береговой линии, что позволяет обучать предсказательную модель без учёта дополнительных характеристик наблюдаемых участков.

На первом этапе исследования сравниваются некоторые наиболее подходящие для исследуемых процессов методы машинного обучения. На основе статистических оценок (среднеквадратичного отклонения) выбирается базовый метод с наименьшей погрешностью результатов.

Базовая модель модифицируется путём введения дополнительных характеристик, описывающих скорости и ускорения изменения береговой линии. Результаты работы методов оцениваются при помощи среднеквадратичной и относительной ошибок.

Методы и материалы. В работе используются данные, полученные с сенсоров спутника Sentinel-2 L2A (см. табл. 1) при помощи ресурса Sentinel-hub. Используются спектральные снимки.

Таблица 1

Спектральные каналы Sentinel-2 L2A

Спектральный канал	Центральная длина волны, нм	Ширина канала, нм
Band 1 – Coastal aerosol	442,7 – 453,9	21
Band 2 – Blue	492,4 – 506,6	66
Band 3 – Green	559,8 – 590,0	36
Band 4 – Red	664,6 – 680,0	31
Band 5 – Vegetation red edge	704,1 – 740,0	15
Band 6 – Vegetation red edge	740,5 – 760,0	15
Band 7 – Vegetation red edge	782,8 – 900,0	20
Band 8 – Vegetation red edge	832,8 – 850,0	106
Band 9 – Water vapour	945,1 – 950,0	20
Band 11 – SWIR	1613,7 – 1700,0	91
Band 12 – SWIR	2202,4 – 2300,0	175
Band 8A – NIR	864,7 – 885,0	21

Первоначально обрабатываются изображения, полученные с использованием 4, 3 и 2 спектральных каналов (см. рис. 1), затем используются 3 и 11 спектральные каналы для классификации воды при помощи индекса NDSI (см. рис. 2).




Рис. 1. Спутниковое изображение реки Амур



Рис. 2. Классификация области интереса при помощи индекса NDSI

На основе изображений с выделенной водной поверхностью создаются бинарные маски при помощи алгоритма k -ближайших средних. На бинарных изображениях фиксируется присутствие шумов, обусловленных влиянием географических особенностей исследуемой местности, погодными явлениями или человеческой деятельностью. Обработка шумов на изображениях осуществляется при помощи гауссова ядра размером 5×5 пикселей.

После удаления шумов на бинарных масках выделяются границы реки при помощи метода Кэнни (см. рис. 3).




Рис. 3. Границы реки Амур

Формируется матрица координат пикселей, принадлежащих к границе исследуемой области, записываемая в файл формата .csv.

Задача прогнозирования состоит в нахождении целевых меток y (верхняя и нижняя границы) для соответствующего фиксированного x . Пиксели в файле .csv группируются по датам, затем по координатам x .

Оценивается эффективность некоторых методов машинного обучения для задачи прогнозирования. На вход поступают следующие данные: дата, координата x , координата y нижней границы, координата y верхней границы. Каждый объект анализа (пиксель) описывается парой значений (x, y) представляющих собой координаты в декартовой системе. Значения x соответствуют ширине изображения.

Для выбора базового метода машинного обучения производится сравнение 4 методов: 1 – линейная регрессия, 2 – случайный лес, 3 – метод опорных векторов, 4 – градиентный бустинг.

В табл. 2 представлены результаты сравнения методов на основе оценки относительной и среднеквадратической ошибок.

Таблица 2

Сравнение моделей машинного обучения

Ошибка	Линейная регрессия	Случайный лес	Градиентный бустинг	Метод опорных векторов
Среднеквадратическая, пиксели	410,6	386,189	385,779	383,86
Средняя относительная, %	1,35	0,97	0,97	0,95

В качестве базового метода машинного обучения выбирается метод опорных векторов (Support Vector Regression, SVR) (см. рис. 4).




Рис. 4. Результат предсказания по методу опорных векторов

Построение прогнозных моделей. После выбора базового метода машинного обучения и проведения предварительной обработки данных реализуются 2 модели. Первая модель – базовая, использующая обучающие данные с указанием положения границ реки в соответствующие моменты времени. Вторая модель – модифицированная.

Для реализации моделей машинного обучения решается задача нахождения функций $y_i = f_i(x_i)$, $i = \overline{1,2}$, описывающих верхнюю и нижнюю границы рек, обеспечивающих минимальную ошибку предсказания в эpsilon-области. Для оценки эффективности предсказательной моде-

ли и её успешного обучения используется функция потерь: $L(y_i, f(x_i)) = \begin{cases} 0 & \text{при } |y_i - f(x_i)| \leq \epsilon \\ |y_i - f(x_i)| - \epsilon & \text{иначе} \end{cases}$, где y_i – истинное значение, $f(x_i)$ – предсказанное значение, ϵ – ширина эпсилон-области. Для нахождения регрессионной функции, описывающей изменения береговой линии, решается следующая оптимизационная задача: $\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$, где ω – вектор весов модели, b – параметр, отвечающий за вертикальное смещение линии регрессии относительно оси y , $\|\omega\|^2$ – евклидова норма весов модели, $\|\omega\|^2 = \sqrt{\sum_{i=1}^n \omega_i^2}$, C – параметр нормирования максимизации ширины эпсилон-области и минимизации ошибок, ξ_i – ошибки отклонения в большую сторону от предсказанных значений, ξ_i^* – ошибки отклонения в меньшую сторону от предсказанных значений. Задача решается при заданных ограничениях:

$$\begin{cases} y_i - (\omega^T x_i + b) \leq \epsilon + \xi_i \\ (\omega^T x_i + b) - y_i \leq \epsilon + \xi_i^* \\ \xi_i^*, \xi_i \geq 0 \end{cases}$$

где ϵ – ширина допустимой погрешности предсказания.

Для нахождения оптимальных весов ω и смещения b решается задача Каруша – Куна – Таккера, представляемая следующим образом: $\alpha_i(\epsilon - |y_i - f_i(x_i)|) = 0$, где α_i – множитель Лагранжа для i -го набора данных.

Оценка предсказательной способности базовой модели определяется относительной и среднеквадратической ошибками.

Ставится задача повышения точности предсказательной модели путем её модификации, обеспечивающейся введением весовых коэффициентов, определяемых скоростью v и ускорением a изменения координат точек границ береговой линии. После группировки набора данных по дате и координате x для каждого пикселя находятся значения: 1) $v_j = y_{j+1} - y_j$, 2) $a_j = v_{j+1} - v_j$, $j = \overline{1, 1200}$ (при $t = 1$).

Результаты работы базовой и модифицированной моделей оцениваются при помощи среднеквадратической и относительной ошибок. По сравнению с базовой, точность модифицированной модели выше на 6 % (см. табл. 3).

Таблица 3

Сравнение базовой и модифицированной моделей

Ошибки	Верхняя береговая линия (базовая модель)	Нижняя береговая линия (базовая модель)	Верхняя береговая линия (с весами)	Нижняя береговая линия (с весами)
Среднеквадратическая, пиксели	6,524	6,048	5,767	5,481
Относительная, %	0,75	1,28	0,71	1,17

Введение данных параметров позволяет производить обучение модели более эффективно за счёт корректной обработки интервалов постоянства функции, которые обусловлены стоячей водой и сезонной составляющей.

Если наблюдается более двух точек границ, соответствующих одному значению абсциссы, то изображение разбивается на отдельные части таким образом, чтобы привести исходные данные к стандартному виду, содержащему 2 точки (верхняя и нижняя границы).

Данные ситуации возникают, когда имеются резкие изменения формы русла реки, раздвоение русла или наличие протоков. Наглядно результаты моделирования представлены на рис. 5-6.



Рис. 5. Реальная и прогнозные предсказываемые границы

Графическое представление результатов работы (см. рис. 5) и оценка среднеквадратической и относительной ошибок позволяют сделать вывод о том, что введение дополнительных параметров скорости и ускорения изменений границ береговой линии существенно повлияло на точность прогнозной модели.




Рис. 6. Сравнение границ (обработка)

Общая схема работы интеллектуальной системы представлена на рис. 7.



Рис. 7. Блок-схема работы интеллектуальной системы

Заключение. В результате исследования разработана интеллектуальная система оценки динамики изменения границ контролируемой области на примере береговой линии реки Амур на основе спектральных спутниковых данных. Произведён сравнительный анализ некоторых методов машинного обучения, в качестве базового выбран метод опорных векторов. Введены дополнительные характеристики в виде скорости и ускорения изменения функций, описывающих береговые линии. Введение дополнительных характеристик обеспечило повышение точности модели в среднем на 6 %. На текущем этапе работы в интеллектуальную систему интегрируется модель

временного ряда, обеспечивающая оценку сезонной составляющей. Учёт дополнительной информации позволит обеспечить повышение точности прогноза модифицированной модели.

ЛИТЕРАТУРА

1. Детектирование состояния поверхности / Е. П. Жарикова, И. А. Трещев, Я. Ю. Григорьев, А. Л. Григорьева // Учёные записки Комсомольского-на-Амуре государственного технического университета. Науки о природе и технике. – 2019. – № III-1 (39). – С. 58-63.
2. Zharikova, E. P. Surface state detection / E. P. Zharikova, J. U. Grigoriev, A. L. Grigoryeva // 2019 International Multi-Conference on Industrial Engineering and Modern Technologies, FarEastCon 2019. – 2019. – P. 8934205.
3. Жарикова, Е. П. Применение искусственного интеллекта в задачах анализа состояния акваторий / Е. П. Жарикова, Я. Ю. Григорьев, А. Л. Григорьева // Морские интеллектуальные технологии. – 2021. – Т. 2. – № 2 (52). – С. 129-133.
4. Амосов, О. С. Моделирование обнаружения и распознавания аномального поведения динамических систем / О. С. Амосов, С. Г. Амосова // Управление развитием крупномасштабных систем MLSD'2020. Труды тринадцатой международной конференции / под общ. ред. С. Н. Васильева, А. Д. Цвиркуна. – М.: Институт проблем управления им. В. А. Трапезникова РАН, 2020. – С. 1151-1158.
5. Zharikova, E. P. Applications of Computer Vision in Cross-Sectoral Tasks / Zharikova E. P., Grigoriev Y. Y., Grigorieva A. L. // Current Problems and Ways of Industry Development: Equipment and Technologies. – Warsaw, 2021. – P. 415-426.
6. Жарикова, Е. П. Применение методов машинного обучения в задачах мониторинга мирового океана и континентальных поверхностных вод / Е. П. Жарикова, Я. Ю. Григорьев, А. Л. Григорьева // Учёные записки Комсомольского-на-Амуре государственного технического университета. Науки о природе и технике. – 2022. – № VII (63). – С. 33-40.
7. Жарикова, Е. П. Анализ изменения спектральных характеристик водной поверхности реки Амур / Е. П. Жарикова, А. Л. Григорьева, Я. Ю. Григорьев // Учёные записки Комсомольского-на-Амуре государственного технического университета. Науки о природе и технике. – 2023. – № VII (71). – С. 28-39.
8. Вьюгин, В. В. Элементы математической теории машинного обучения: учеб. пособие / В. В. Вьюгин. – М.: МФТИ, 2010. – 231 с.