

УДК [528.48:625.72]:528.02  
DOI 10.33764/2411-1759-2022-27-5-19-29

## Прогнозирование осадок оснований автомобильных дорог на высоких насыпях на основе машинного обучения по данным геодезических измерений

Д. Р. Баширова<sup>1\*</sup>, М. Я. Брынь<sup>1</sup>, Д. А. Кривоносов<sup>2</sup>

<sup>1</sup> Петербургский государственный университет путей сообщения Императора Александра I,  
г. Санкт-Петербург, Российская Федерация

<sup>2</sup> ООО «Трансстроймеханизация», г. Москва, Российская Федерация

\* e-mail: bashirovadinara97@gmail.com

**Аннотация.** Описаны исследования по прогнозированию осадок оснований автомобильных дорог на высоких насыпях по данным геодезических наблюдений, а также рассмотрен вопрос их представления в виде математической модели, учитывающей закономерности развития деформационного процесса и позволяющей выявить тренд к возрастанию или убыванию наблюдаемых осадок. Отмечено, что обязательные требования к составлению прогнозных моделей по геодезическим данным на сегодняшний день отсутствуют, при этом построение таких моделей важно для рационального планирования ремонтных работ и уточнения периодичности геодезических наблюдений. Целью исследования является разработка методики выполнения прогнозирования осадок оснований автомобильных дорог на высоких насыпях. Применены следующие методы машинного обучения: линейная регрессия, адаптивная линейная регрессия, экспоненциальное сглаживание, методы опорных векторов и случайного леса. После обучения моделей и подбора их параметров было выполнено предсказание на тестовом наборе. В качестве показателей, характеризовавших качество моделей, выступали: средняя квадратическая ошибка, средний абсолютный процент ошибки, средний процент ошибки, коэффициент детерминации, коэффициент несоответствия Тейла. Минимальное значение средней квадратической ошибки  $RMSE = 0,8$  мм было получено при использовании метода опорных векторов.

**Ключевые слова:** автомобильные дороги, деформации, осадки, прогнозирование, машинное обучение, средняя квадратическая ошибка, коэффициент детерминации

### Введение

Обеспечение безопасности строящихся и эксплуатируемых объектов, в том числе линейных сооружений на высоких насыпях, – актуальная задача, важным составным аспектом которой является оценка развития деформационных процессов [1–10]. Отметим, что для выявления их закономерностей по результатам геодезических наблюдений выполняется построение математической модели, которая дает возможность выявить тенденцию к возрастанию или убыванию наблюдаемых деформаций [1, 3, 9, 11, 12]. Таким образом, реализуемое моделирование позволяет осуществить прогнозную экстраполяцию.

Подчеркнем, что прогнозирование деформаций выполняется с целью как рационального планирования работ по поддержанию эксплуатационных характеристик объекта, так и уточнения периодичности геодезических наблюдений [4]. Определение периодич-

ности наблюдений является значимым, так как, с одной стороны, необходимо увеличивать временной интервал между циклами наблюдений, а с другой, – избегать пропуска момента изменения величины деформации.

Отметим, что высокие требования точности относятся как к горизонтальным, так и к вертикальным смещениям оснований автомобильных дорог, которые являются основными видами деформаций. В данном исследовании остановимся на определении осадок, под которыми понимаются смещения сооружения в вертикальной плоскости, вызванные сжатием грунтов или уменьшением вертикальных размеров сооружения или его частей [4, 13].

Мониторинг деформаций автомобильных дорог на высоких насыпях производится в течение всего периода строительства, а в некоторых случаях и в период эксплуатации, до завершения стабилизации земляного полотна [14]. Измерения могут проводиться по-

стоянно (в случае сложных геологических условий или при высоком уровне ответственности сооружений), периодически или однократно. К объектам постоянного мониторинга относят, в том числе основания автомобильных дорог при устройстве сооружений на грунтах с низкой несущей способностью и при возведении насыпи высотой более 12 м. Таким образом, ввиду постоянно выполняемого мониторинга вертикальных перемещений такого линейного объекта и отсутствия регламентированной периодичности его выполнения [14], построение прогнозной модели является целесообразным.

Прогнозирование деформаций может осуществляться по двум основным направлениям: составление комплексной прогнозной модели с учетом нагрузки на основание, сезонности колебания уровня грунтовых вод, изменения термических условий, сейсмичности и других и по геодезическим данным. Отметим, что после определения однородности наблюдаемого процесса, степени зависимости прогнозируемого и опорного параметров необходимо подобрать такую функцию, которая бы максимально отражала процесс протекания деформаций [1, 4]. В работе прогноз осуществляется только по результатам геодезических наблюдений.

Целью статьи является составление прогнозных моделей по геодезическим данным на основе методов машинного обучения, их исследование и проверка достоверности полученных прогнозных значений. В качестве объекта исследования рассмотрена автомобильная дорога на высокой насыпи, взаимодействующая с грунтовым основанием и внешней средой, что отражается в результатах геодезических наблюдений. Предмет исследования – осадки основания рассматриваемого линейного сооружения.

### ***Основные требования к созданию прогнозных моделей***

На сегодняшний день рекомендации по построению прогнозных моделей указаны в нормативных документах, регламентирующих геодезический мониторинг зданий и сооружений только повышенного уровня от-

ветственности [7, 10, 15]. Например, согласно стандарту [7], устанавливающему требования к выполнению геодезического мониторинга на объектах использования атомной энергии, для проведения прогнозирования необходимо: составить временной ряд, подобрать трендовую функцию, выполнить ее экстраполяцию, скорректировать прогноз с учетом результатов анализа на текущий момент.

Подчеркнуто, что шаг по времени, т. е. промежуток времени между циклами, должен быть одинаков. Также отмечено, что выполнение прогнозирования по результатам геодезических наблюдений может выполняться только на глубину не более 20–25 % от длины наблюдаемого ряда [7, 10]. Представленные выше стандарты рекомендуют при отсутствии одинакового нарастания рядов использовать процедуру экспоненциального или полиномиального сглаживания, кубической сплайн-интерполяции.

В результате проведенного анализа можно сделать вывод, что общих требований к составлению математических моделей по геодезическим данным не представлено, существуют только рекомендации к их построению для зданий и сооружений повышенного уровня ответственности.

### ***Обзор исследований в области прогнозирования деформаций***

Построению прогнозных моделей различными методами посвящено множество работ как отечественных [1–4, 6, 8, 9, 13, 16–23], так и зарубежных авторов [5, 11, 12].

Большой вклад в исследование прогнозных моделей по данным геодезического мониторинга внес Ю. П. Гуляев [3], который для прогнозирования применял динамические модели, а в качестве переменных использовал входной сигнал и его последовательные производные. Прогнозные модели динамического типа также отражены в исследованиях Б. Т. Мазурова [9].

Наиболее распространенными методами прогнозирования, применяемыми в геодезической практике, являются следующие [3, 4, 16, 18].

## Методы и материалы

1. Метод множественного корреляционного анализа. Метод позволяет оценить степень взаимосвязи между переменными и выявить влияние одного фактора на изменение другого. Степень надежности полученной регрессионной модели определяют по  $F$ -критерию (критерию Фишера).

2. Аппроксимация линейной, полиномиальной различных степеней, логарифмической, периодической функциями. При этом коэффициенты уравнений определяются методом наименьших квадратов.

3. Логарифмический ряд. Метод дифференцирования функций, выполняющийся в два этапа: нахождение логарифма функции и вычисление его производных.

Таким образом, для выполнения прогнозирования используются как линейные, так и нелинейные регрессионные модели. Отметим, что не все процессы могут быть описаны линейной функцией, так как она обладает низкой адаптивной способностью. Подчеркнем, что среди недостатков нелинейных моделей можно выделить сложность определения параметров таких моделей, медленную сходимость вычислительного процесса [16].

В последнее время в области прогнозирования все большее распространение получают методы машинного обучения, однако на сегодняшний день широкого применения в геодезической практике они не нашли [19], а также отсутствуют исследования по сравнению прогнозных моделей, выполненных на основе этих методов [5]. Целью машинного обучения является создание адаптирующихся систем без явного кодирования алгоритма, т. е. систем, способных обучаться [24]. Как отмечается в [5, 24], методы машинного обучения обладают рядом преимуществ: единообразие используемой методики, вне зависимости от применяемой модели обучения; осуществимостью моделирования линейных и нелинейных процессов; высокой скоростью получения решения; достаточной визуализацией результатов.

В данной работе рассмотрено применение методов машинного обучения для прогнозирования осадок по данным геодезических наблюдений на примере изменения отметки одной из деформационных марок.

В работе решается задача прогнозирования для временных рядов. Временной ряд – это значения некоторой величины, измеренные через некоторые равные промежутки времени  $\Delta t$  [25].

Выделяют следующие виды временных рядов [16, 25]: временные ряды абсолютных, относительных показателей, средних величин, одномерные и многомерные, моментные и интервальные временные ряды, равноотстоящие и неравноотстоящие, полные и неполные (в зависимости от наличия пропусков).

Если принять  $\Delta t = 1$ , начальное значение  $t_1 = 1$ ,  $t_i = i$ , где  $i = 1, 2, \dots, n$ , тогда временной ряд можно представить в виде последовательности:

$$y_1, y_2, \dots, y_n,$$

где все элементы последовательности принадлежат множеству действительных чисел ( $\mathbb{R}$ ), т. е.  $y_n \in \mathbb{R}$ . Отметим, что под задачей прогнозирования временных рядов понимают нахождение функции  $F$  [1, 16, 25]:

$$y_{n+d}(w) = F(y_1, y_2, \dots, y_n, w),$$

где  $d \in \{1, 2, \dots, D\}$  – отсрочка прогноза;  $D$  – горизонт прогнозирования;  $w$  – вектор параметров модели.

Таким образом, зная результаты геодезических измерений в прошлом, необходимо отыскать их значения в будущем.

В качестве основных проблем прогнозирования временных рядов можно выделить следующие [16, 25]: временных рядов может быть большое количество, поведение рядов может описываться разными моделями, модель должна оперативно перестраиваться на следующий момент времени, функция потерь может быть неквадратичной.

Рассмотрим указанные выше методы машинного обучения для решения задач прогнозирования временных рядов.

*Линейная модель авторегрессии.* В данной модели в роли признаков выступают  $n$  предыдущих наблюдений временного ряда [25]:

$$\hat{y}_{t+1}(w) = \sum_{j=1}^n w_j y_{t-j+1}, w \in \mathbb{R}.$$

Будем считать выполненные геодезические наблюдения в разных циклах независимыми. Тогда функцию потерь можно выразить через целевую функцию метода наименьших квадратов и представить в виде:

$$Q_t(w) = \sum_{i=t_0}^t (\hat{y}_i(w) - y_i)^2 \rightarrow \min.$$

*Адаптивная модель авторегрессии.* Модель авторегрессии, которая прогнозирует  $t+1$  значение как линейную комбинацию предыдущих элементов ряда:

$$\hat{y}_{t+1}(w) = \sum_{j=1}^n w_j y_{t-j+1}, w \in \mathbb{R}.$$

Для того чтобы актуализировать модель при увеличении обучающей выборки, необходимо изменить коэффициенты  $w_j$ . Ошибка прогноза  $\varepsilon_t = y_t - \hat{y}_t$ , где  $\hat{y}_t$  – прогноз, сделанный на шаге  $t-1$ . На каждом шаге необходимо уменьшить текущий квадрат ошибки  $\varepsilon_t^2 \rightarrow \min_w$ . В каждый момент времени совершаем один шаг градиентного спуска, выбрав в качестве функции потерь лишь одно слагаемое из суммы по всей выборке, характеризующее ее изменение в данный момент времени:

$$w_j = w_j + h_t \varepsilon_t y_{t-j+1},$$

где  $h_t$  – градиентный шаг, который определяется по формуле:

$$h_t = \frac{\alpha}{\sum_{j=1}^n y_{t-j+1}^2},$$

где  $\alpha$  – аналог параметра сглаживания. Чем больше коэффициент, тем выше адаптивность модели.

*Экспоненциальное сглаживание.* Одним из самых распространенных способов выравнивания временного ряда является экспоненциальное сглаживание, которое представляет собой фильтр, на вход которого последовательно подаются члены временного ряда, на выходе формируются значения экспоненциальной средней. Экспоненциальное сглаживание можно выполнить по следующей формуле:

$$S_t = \alpha y_t + (1 - \alpha) S_{t-1},$$

где  $S_t$  – экспоненциальная средняя;  $\alpha$  – параметр сглаживания.

*Метод опорных векторов.* В основе метода лежит перевод исходных признаков в пространство более высокой размерности. Отметим, что каждый входной вектор формируется как последовательность исходных данных с задержками по времени. Суть метода – построение гиперплоскости, которая описывает распределение с заданной точностью. Метод выполняет расчет коэффициентов путем минимизации квадратичных потерь. Вычисления выполняются суммированием по всем образцам ядер (функций от входных данных). Функции могут быть как линейными, так и нелинейными (полиномиальные, радиальные базисные функции, сигмоида) [24]. В нашей задаче будет использоваться радиальная базисная функция:

$$K(x, x') = e^{-\gamma \|x - x'\|^2},$$

где  $x, x'$  – векторы признаков;  $\gamma$  – скаляр, который определяет какое влияние оказывает один обучающий пример;  $\|x - x'\|^2$  – квадрат евклидова расстояния между двумя векторами признаков.

Отметим, что в методе есть два настраиваемых параметра:  $\varepsilon$  – определяет ширину области вокруг оценочной гиперплоскости (точки, попавшие в эту область, считаются правильными предсказаниями и не штрафуются);  $C$  – параметр регуляризации.

*Метод случайного леса.* Модель основана на использовании ансамбля решающих дере-

вьев. Принцип работы алгоритма заключается в следующем: создаются случайные выборки из набора данных, для каждой такой выборки строится дерево решений и на его основе получают предсказание, проводится голосование за каждый полученный прогноз и выбирается предсказание с наибольшим количеством голосов. Признак в каждой вершине дерева выбирается из случайного под-

множества  $k$  из  $n$  признаков. Для решения регрессионных задач обычно задается  $k = \frac{n}{3}$ .

### Оценка качества прогнозирования

Для оценки качества выполненного прогнозирования, как правило, рассчитываются параметры, представленные в табл. 1 [25].

Таблица 1

Характеристики качества прогнозных моделей

Название показателя	Формула для расчета	Характеристика показателя
Ошибка прогноза $\varepsilon_t$	$\varepsilon_t = y_t - \hat{y}_t,$ <p>где <math>y_t</math> – фактическое значение показателя на момент времени <math>t</math>;  <math>\hat{y}_t</math> – значение показателя, определенное по модели, на момент времени <math>t</math></p>	Модельная погрешность (модельный остаток) – разница между фактическим и прогнозным значениями. Может быть рассчитана для каждого прогноза и представлять временной ряд ошибок прогноза
Средняя квадратическая ошибка $RMSE$	$RMSE = \sqrt{\frac{\sum_{t=1}^n \varepsilon_t^2}{n-1}}$	Имеет те же преимущества, что и квадрат средней квадратической ошибки (MSE), но погрешности измеряются в тех же единицах, что и целевой признак
Средний абсолютный процент ошибки $MAPE$	$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{ \varepsilon_t }{ y_t } \times 100 \%$	Позволяет понять на сколько процентов разошлись прогнозные и фактические значения
Коэффициент детерминации $R^2$	$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2},$ <p>где <math>\bar{y}</math> – среднее значение показателя</p>	Характеризует степень сходства фактических и прогнозных значений. Чем ближе значение к 1, тем выше качество выполненного прогнозирования
Коэффициент несоответствия Тейла $\mathfrak{S}$	$\mathfrak{S} = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n y_t^2 + \sum_{t=1}^n \hat{y}_t^2}}$	Индекс определяет степень схожести фактических и предсказанных значений. Чем ближе значение к 0, тем выше качество выполненного прогнозирования

Таким образом, рассмотренные методы машинного обучения и показатели, применяемые для построения и оценки качества прогнозных моделей, могут быть использованы при прогнозировании осадок.

### Экспериментальные исследования

Выполним прогнозирование осадок оснований автомобильных дорог на высоких насыпях на примере объекта «Строительство

автомобильной дороги Владивосток – Находка – порт Восточный на участке км 18+500 – км 40+800 в Приморском крае». В качестве примера предлагается рассмотреть наблюдательный поперечник, расположенный на ПК 38+00 трассы строящейся автомобильной дороги, на котором было проведено тридцать циклов измерений.

Отметим, что в рамках исследования было рассмотрено десять наблюдательных поперечников, по данным которых были получены подобные результаты. В этой связи было решено подробно разобрать все этапы построения прогнозных моделей на

примере одного наблюдательного поперечника.

Отметим, что осадочные марки были установлены через каждые 50 м на всю длину участка со слабым основанием. Для снятия одного поперечника были использованы три деформационные марки: две по бровкам насыпи, а третья посередине насыпи. На рисунке отображен график, на котором представлены вертикальные перемещения марок, находящихся на левой, правой кромках и оси автомобильной дороги, а также средние вертикальные перемещения марок. Превышения определялись по программе нивелирования II класса.

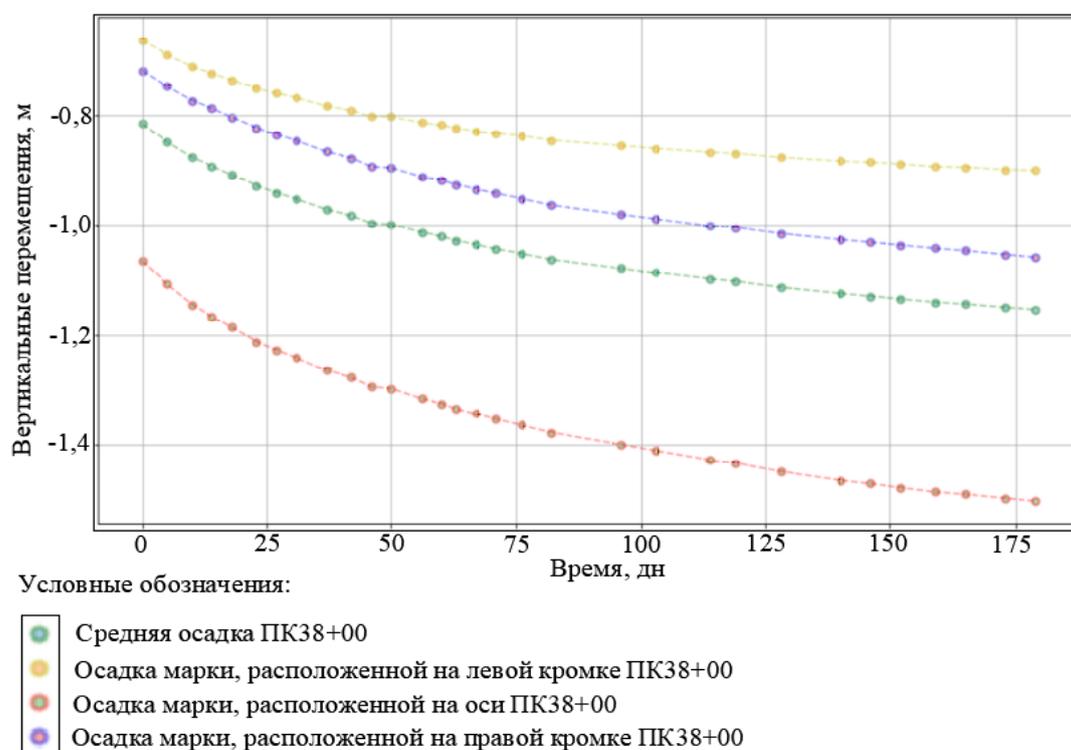


График вертикальных перемещений геодзических марок на пикете ПК38+00

В рассматриваемом случае единственный признак, который был использован в решении задачи прогнозирования, – дата выполнения наблюдений (входной признак), а зависимая переменная – осадка марки (целевой признак).

Необходимо учесть, что в данной задаче при разделении данных на обучающий и тестовый наборы важно выбрать дату, которая будет разделять выборки. В качестве способа хранения дат были выбраны дни от момента

выполнения нулевого цикла измерения. На первом этапе была выполнена предварительная обработка данных, а именно их масштабирование (такие данные имеют нулевое среднее значение и единичную дисперсию).

После подготовки данных было выполнено построение прогнозных моделей выбранными методами. Для вычисления метрик применена процедура перекрестной проверки, в результате был исключен риск переобучения моделей. Процедура заключалась

в разбиении на  $k$  меньших наборов. Отметим, что для модели временных рядов необходимо применять перекрестную проверку на скользкой основе.

Далее было выполнено построение выбранных моделей и подбор параметров.

Рассмотрим выполнение моделирования на примере построения адаптивной прогнозной модели (модели линейной регрессии на основе градиентного спуска). В качестве оценочной метрики была использована средняя квадратическая ошибка. Таким образом, в рассматриваемом случае было необходимо минимизировать среднее расстояние между прогнозными и фактическими значениями. В качестве гиперпараметров для модели выступали: критерий остановки  $tol$  (сообщает модели, когда необходимо прекратить итерацию) и начальная скорость обучения  $eta0$ . Для их подбора была применена кросс-валидация, выполнен перебор параметров и сравнение значений средней квадратической ошибки полученных моделей. Таким образом, были подобраны следующие значения параметров:  $tol = 0,0004$ ,  $eta0 = 0,06$ . Также

были рассчитаны средние квадратические ошибки для обучающего и тестового набора, которые составили 1 и 3 мм соответственно. Таким образом, было проверено, что проблема с переобучением отсутствует. На следующем этапе была построена кривая обучения, которая отражает функцию ошибок в зависимости от объема тренировочной выборки. Исходя из кривой обучения, был сделан вывод, что по мере увеличения объема выборки средняя квадратическая ошибка и кросс-валидация сходились. В рассмотренном случае двадцати значений было достаточно для выполнения прогнозирования данным методом.

Далее были выполнены аналогичные действия для моделей линейной и полиномиальной регрессии, экспоненциального сглаживания, метода опорных векторов и случайного леса.

На следующем этапе был выполнен расчет показателей, характеризующих качество проведенного прогнозирования для всех примененных методов. Результаты расчета представлены в табл. 2.

Таблица 2

Расчет основных показателей оценки качества моделей

Название показателя	Прогнозные модели				
	Линейная регрессия	Экспоненциальное сглаживание	Адаптивная регрессионная модель	Метод опорных векторов	Модель случайного леса
Среднеквадратическое ошибка $RMSE$ , мм	41,3	12,1	3,1	0,8	7,0
Средний абсолютный процент ошибки $MAPE$ , %	4,58	1,42	0,35	0,09	0,73
Коэффициент детерминации $R^2$	0,53	0,64	0,81	0,98	0,33
Коэффициент несоответствия Тейла $\vartheta$	0,75	0,41	0,07	0,03	0,20

В качестве основного критерия выбора метода прогнозирования применялась средняя квадратическая ошибка. Проанализировав представленные в таблице показатели оценки качества прогнозных моделей, были сделаны следующие выводы:

– низкое качество моделей линейной регрессии и случайного леса указывает на то, что процесс осадки основания автомобильной дороги не может быть описан этими методами, так как они не учитывают закономерности развития деформационного процесса;

– заслуживают внимания методы адаптивной линейной регрессии (значение  $RMSE$  составило 3,1 мм) и метода опорных векторов ( $RMSE = 0,8$  мм). Также данные методы показали близкое к нулю значение коэффициента несоответствия Тейла, что говорит о близости фактических и предсказанных значений осадки;

– минимальное значение  $RMSE = 0,8$  мм было получено у метода опорных векторов, также отмечено, что метод показал высокое качество прогнозирования и при учете совокупности показателей оценки качества моделей.

### Заключение

Таким образом, разработана методика выполнения прогнозирования осадок основания автомобильных дорог на высоких насыпях на основе машинного обучения, которая включает составление временного ряда, масштабирование признаков, разбиение на обучающий

и тестовый наборы, обучение моделей и подбор параметров на основе кросс-валидации, предсказание значений для тестового набора, проверку качества выполненного моделирования на основе расчета основных показателей, применяемых для оценки качества полученного прогноза.

По данной методике были выполнены экспериментальные исследования по построению прогнозных моделей на основе геодезических наблюдений.

В работе выполнено сравнение полученных прогнозных значений величины осадки с фактическими отметками. Получены результаты расчетов основных показателей оценки качества моделей. В результате был сделан вывод о высоком качестве моделей метода опорных векторов и линейной регрессии на основе градиентного спуска. При этом моделью, наиболее полно описывающей деформационный процесс, стала модель, построенная на основе метода опорных векторов.

### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Брынь М. Я., Шевченко Г. Г. Построение прогнозной модели поисковым методом нелинейного программирования по геодезическим данным // Инженерные изыскания. – 2019. – Т. 13, № 4. – С. 48–58.
2. Голюк В. П., Назаров Д. Г. Комплексный подход к геодезическому контролю укладки асфальтобетонного покрытия на примере строительства автодорожного мостового перехода через Керченский пролив // Интерэкспо ГЕО-Сибирь. XVI Междунар. науч. конгр. : Национальная науч. конф. с междунар. участием «Геодезия, геоинформатика, картография, маркшейдерия» : сб. материалов в 8 т. (Новосибирск, 18 июня – 8 июля 2020 г.). – Новосибирск : СГУГиТ, 2020. Т. 1, № 1. – С. 106–119.
3. Гуляев Ю. П. Прогнозирование деформаций сооружений на основе результатов геодезических наблюдений : монография. – Новосибирск : СГГА, 2008. – 256 с.
4. Зайцев А. К., Марфенко С. В., Михелев С. В. и др. Геодезические методы исследования деформаций сооружений. – М. : Недра, 1991. – 272 с.
5. He P., Xu F., Sun S. Nonlinear deformation prediction of tunnel surrounding rock with computational intelligence approaches // Geomatics Natural Hazards & Risk. – 2020. – Vol. 11, Iss. 1. – P. 414–427.
6. Kuzin A. A., Grishchenkova E. N., Mustafin M. G. Prediction of natural and technogenic negative processes based on the analysis of relief and geological structure // Procedia Engineering. – 2017. – Vol. 189. – P. 744–751.
7. Стандарт организации. Объекты использования атомной энергии. Геодезический мониторинг зданий и сооружений в период строительства и эксплуатации (СТО СРО-С 60542960 00043-2015) : разработан ООО «Центр технических компетенций атомной отрасли»: внесен Советом СРО НП «СОЮЗАТОМСТРОЙ»: утвержден и введен в действие Протоколом общего собрания СРО НП «СОЮЗАТОМСТРОЙ» № 11 от 12.02.15 г. – М., 2015. – 157 с.
8. Кобелева Н. Н. Методические особенности построения прогнозных моделей для изучения деформаций высоких плотин // Вестник СГУГиТ. – 2017. – Т. 22, № 2. – С. 55–66.
9. Мазуров Б. Т., Панкрушин В. К., Середович В. А. Математическое моделирование и идентификация напряженно-деформированного состояния геодинамических систем в аспекте прогноза природных и техногенных катастроф // Вестник СГГА. – 2004. – Вып. 9. – С. 30–35.

10. Стандарт организации. Объекты использования атомной энергии. Геодезический мониторинг зданий и сооружений в период строительства и эксплуатации (СТО НОСТРОЙ 2.1.198-2016) : разработан ООО «Центр технических компетенций атомной отрасли» – М., 2016. – 158 с.
11. Lu F., Zeng H. Application of Kalman Filter Model in the Landslide Deformation Forecast // Scientific Reports. – 2020. – Vol. 10, Iss. 1.
12. Ma P., Zhang F., Lin H. Prediction of InSAR time-series deformation using deep convolutional neural networks // Remote Sensing Letters. – 2020. – Vol. 11, Iss. 2. – P. 137–145.
13. Симонян В. Изучение оползневых процессов геодезическими методами. – 2-е изд. – М. : МГСУ, 2015. – 171 с.
14. ОДМ 218.5.015-2019 Методические рекомендации по измерению деформаций земляного полотна автомобильных дорог с применением принципов инклинометрии. – М. : Росавтодор, 2019. – 39 с.
15. Методика геодезического мониторинга технического состояния высотных и уникальных зданий и сооружений. МДС 13-22.2009 / ООО «ТЕКТОПЛАН». – М. : ОАО «ЦПП», 2010. – 76 с.
16. Шевченко Г. Г. Разработка технологии геодезического мониторинга зданий и сооружений способом свободного стационарирования с использованием поискового метода нелинейного программирования : дисс. ... канд. техн. наук. – СПб., 2020. – 212 с.
17. Гуляев Ю. П., Хорошилов В. С., Лисицкий Д. В. О корректном подходе к математическому моделированию деформационных процессов инженерных сооружений по геодезическим данным // Изв. вузов. Геодезия и аэрофотосъемка. – 2014. – № 4. – С. 22–30.
18. Поздышева О.Н. Прогнозирование деформаций строительных конструкций по результатам геодезических наблюдений // Международный научно-исследовательский журнал. – 2017. – № 2–2 (56). – С. 56–58.
19. Грищенкова Е. Н., Мустафин М. Г. Использование нейронной сети для уточнения прогнозируемых деформаций земной поверхности // Маркшейдерский вестник. – 2018. – № 1 (122). – С. 53–57.
20. Харченко Б. А. Анализ и прогнозирование деформаций сооружений по геодезическим данным на основе программного комплекса Mathcad-15 // Интерэкспо ГЕО-Сибирь-2015. XI Междунар. науч. конгр. : Междунар. науч. конф. «Геодезия, геоинформатика, картография, маркшейдерия» : сб. материалов в 2 т. (Новосибирск, 13–25 апреля 2015 г.). – Новосибирск : СГУГиТ, 2015. Т. 1. – С. 21–27.
21. Горохова Е. И. Геомониторинг инженерных сооружений и прогнозирование их деформаций по данным лазерного сканирования // Вестник СГУГиТ. – 2016. – Вып. 2 (34). – С. 65–72.
22. Мурзинцев П. П., Павлов М. М., Репин А. С. Особенности геодезического обеспечения строительства автодороги и пространственного мониторинга на Бованенковском месторождении // Геодезия и картография. – 2016. – № 2. – С. 2–5. – DOI 10.22389/0016-7126-2016-908-2-2-5.
23. Новиков Ю. А., Краев А. Н. Геодезические наблюдения за осадками здания в рамках проведения геотехнического мониторинга // Вестник СГУГиТ. – 2019. – Т. 24, № 1. – С. 28–41. – DOI 10.33764/2411-1759-2019-24-1-28-41.
24. Воронина В. В., Михеев А. В., Ярушкина Н. Г., Святков К. В. Теория и практика машинного обучения : учеб. пособие. – Ульяновск : УлГТУ, 2017. – 290 с.
25. Садовникова Н. А., Шмойлова Р. А. Анализ временных рядов и прогнозирование : учебно-методический комплекс. – Вып. 3. – М. : Изд. центр ЕАОИ, 2009. – 264 с.

### Об авторах

*Динара Ринатовна Баширова* – аспирант кафедры инженерной геодезии.

*Михаил Ярославович Брынъ* – доктор технических наук, профессор, профессор кафедры инженерной геодезии.

*Денис Алексеевич Кривонос* – начальник управления геодезических работ.

Получено 13.05.2022

© Д. Р. Баширова, М. Я. Брынъ, Д. А. Кривонос, 2022

## Forecasting high road embankment settlements based on machine learning and geodetic measurement data

D. R. Bashirova<sup>1\*</sup>, M. Ya. Bryn<sup>1</sup>, D. A. Krivonosov<sup>2</sup>

<sup>1</sup> Emperor Alexander I St. Petersburg State Transport University, St. Petersburg, Russian Federation

<sup>2</sup> LLC "Transstroymekhanizatsiya", Moscow, Russian Federation

\* e-mail: bashirovadinara97 @ gmail.com

**Abstract.** The paper describes the research on forecasting of road base settlements on high embankments by means of geodetic observations, and also considers the question of geodetic data representation in the form of a mathematical model which takes into account the laws of settlements development and also allows to reveal upward or downward trends of the observed deformations. The relevance and novelty of the research is that there are no requirements for making forecast models by the geodetic observation data. Whereas it is noted that building of such models is important for rational planning of repair works and more accurate determination of geodetic observations periodicity. The aim of the study is to develop a method of geodetic monitoring of foundation settlements on high embankments. The following machine learning methods were considered: linear regression, adaptive linear regression, exponential smoothing, support vectors, and random forest. After models were trained and their parameters were chosen, the forecast on a test set was carried out. The parameters that characterized the quality of the models were: root mean square error, mean absolute error percentage, mean error percentage, determination coefficient, and Theil's coefficient of variance. Minimal value of root mean squared error  $RMSE = 0,8$  mm was obtained by the method of support vectors. The support vectors method showed the highest forecast accuracy when taking into account all indicators of model quality assessment.

**Keywords:** highways, deformations, settlements, forecast, machine learning, root mean square error, coefficient of determination

## REFERENCES

1. Bryn, M. Ya., & Shevchenko, G. G. (2019). Construction of forecast model by the search method of nonlinear programming on geodetic data. *Inzhenernye izyskaniya [Engineering Surveys]*, 13(4), 48–58 [in Russian].
2. Goluk, V. P., & Nazarov, D. G. (2020). Integrated approach to the geodesic control of the installation of asphalt-concrete coating on the example of the construction of the road bridge transition across the Kerch sheet. In *Sbornik materialov Interekspo GEO-Sibir': Natsional'noy nauchnoy konferentsii s mezhdunarodnym uchastiem: T. 1, no. 1. Geodeziya, geoinformatika, kartografiya, marksheyderiya [Proceedings of Interexpo GEO-Siberia: National Scientific Conference with International Participation: Vol. 1, No. 1. Geodesy, Geoinformatics, Cartography, Mine Surveying]* (pp. 106–119). Novosibirsk: SSUGT Publ. [in Russian].
3. Gulyaev, Yu. P. (2008). *Prognozirovaniye deformatsiy sooruzheniy na osnove rezul'tatov geo-dezicheskikh nablyudeniy [Structures deformations prediction based on the results of geodetic observations]*. Novosibirsk: SSGA Publ., 256 p. [in Russian].
4. Zaitsev, A. K., Marfenko, S. V., Mikhelev, D. Sh. & et al. (1991). *Geodezicheskie metody issledovaniya deformatsii sooruzhenii [Geodesic methods for studying deformations of structures]*. Moscow: Nedra Publ. 272 p. [in Russian].
5. He, P., Xu, F., & Sun, S. (2020). Nonlinear deformation prediction of tunnel surrounding rock with computational intelligence approaches. *Geomatics Natural Hazards & Risk*, 11(1), 414–427.
6. Kuzin, A. A., Grishchenkova, E. N., & Mustafin, M. G. (2017). Prediction of natural and technogenic negative processes based on the analysis of relief and geological structure. *Procedia Engineering*, 189, 744–751.
7. Standard of the organization. Facilities for the Use of Atomic Energy. (2015). STO SRO-S 60542960 00043-2015. Geodetic monitoring of buildings and structures during construction and operation. Developed by LLC "Center of technical competence of nuclear industry. Moscow, 157 p. [in Russian].
8. Kobeleva, N. N. (2017). Methodical peculiarities of prognostic mathematical modelling for deformation survey of high dams. *Vestnik SGUGiT [Vestnik SSUGT]*, 22(2), 55–66 [in Russian].
9. Mazurov, B. T., Pankrushin, V. K., & Seredovich, V. A. (2004). Mathematical modeling and identification of the stress-strain state of geodynamic systems in the aspect of natural and man-made catastrophes forecasting. *Vestnik SSGA [Vestnik SSGA]*, 9, 30–35 [in Russian].

10. Standard of the organization. Facilities for the Use of Atomic Energy. (2016). STO NOSTROI 2.1.198-2016. Geodetic monitoring of buildings and structures during construction and operation. Developed by LLC "Center of technical competence of the nuclear industry". Moscow, 158 p. [in Russian].
11. Lu, F., & Zeng, H. (2020). Application of Kalman Filter Model in the Landslide Deformation Forecast. *Scientific Reports*, 10(1).
12. Ma, P., Zhang, F., & Lin, H. (2020). Prediction of InSAR time-series deformation using deep convolutional neural networks. *Remote Sensing Letters*, 11(2), 137–145.
13. Simonyan, V. V. (2011). *Izuchenie opolznevnykh protsessov geodezicheskimi metodami [Study of landslide processes by geodetic methods]* (2nd ed.). Moscow: MGSU Publ., 172 p. [in Russian].
14. Industry Road Guidance Document of May 18, 2020 No. 218.5.015. Methodological guidelines for measuring deformations of the road bed using the principles of inclinometry. Moscow: Rosavtodor Publ., 39 p. [in Russian].
15. Methodology of geodetic monitoring of the technical condition of high-rise and uni-rise buildings and constructions. (2010). MDS 13-22.2009 / LLC "TECTOPLAN". Moscow: JSC "TSPP" Publ., 76 p. [in Russian].
16. Shevchenko, G. G. (2021). Development of technology for geodesic monitoring of buildings and structures by the method of free positioning using the search method of non-linear programming. *Ph. D. thesis*. Saint Petersburg, 212 p. [in Russian].
17. Gulyaev, Yu. P., Khoroshilov, V. S., & Lisickij, D. V. (2014). On the correct approach to mathematical modeling of deformation processes of engineering structures based on geodetic data. *Izvestiya vuzov. Geodeziya i aerofotos'emka [Izvestiya Vuzov. Geodesy and Aerophotosurveying]*, 4, 22–30 [in Russian].
18. Pozdysheva, O. N. (2017). Forecasting of deformations of building structures according to the results of geodetic observation. *Mezhdunarodnyj nauchno-issledovatel'skij zhurnal [International Scientific and Research Journal]*, 2–2(56), 56–58 [in Russian].
19. Grishchenkova, E. N., & Mustafin, M. G. (2018). Use of neural networks for refinement of predicted earth surface deformations. *Markshejderskiy vestnik [Surveyor's Bulletin]*, 1(122), 53–57 [in Russian].
20. Kharchenko, B. A. (2015). Analysis and prediction of the buildings deformations using the geodetic data are based on the program product the Mathcad-15. In *Sbornik materialov Interekspo GEO-Sibir'-2015: Mezhdunarodnoy nauchnoy konferentsii: T. 1. Geodeziya, geoinformatika, kartografiya, marksheyderiya [Proceedings of Interexpo GEO-Siberia-2015: International Scientific Conference: Vol. 1. Geodesy, Geoinformatics, Cartography, Mine Surveying]* (pp. 21–27). Novosibirsk: SSUGT Publ. [in Russian].
21. Gorokhova, E. I. (2016). Geomonitoring of engineering structures and forecasting their deformations using laser scanning data. *Vestnik SGUGiT [Vestnik SSUGT]*, 2(34), 65–72 [in Russian].
22. Murzintsev, P. P., Pavlov, M. M., & Repin, A. S. (2016). Features of geodetic support for the construction of the highway and spatial monitoring at the Bovanenkovo field. *Geodeziya i kartografiya [Geodesy and Cartography]*, 2, 2–5 [in Russian].
23. Novikov, Yu. A., & Kraev, A. N. (2019). Geodetic overseeing by building settlements within carrying out geotechnical monitoring. *Vestnik SGUGiT [Vestnik SSUGT]*, 24(1), 28–41 [in Russian].
24. Voronina, V. V., Mikheev, A. V., Yarushkina, N. G., & Sviatov, K. V. (2017). *Teoriya i praktika mashinnogo obucheniya [Theory and practice of machine learning]*. Ulianovsk: UGTU Publ., 290 p. [in Russian].
25. Sadovnikova, N. A., & Shmoilova, R. A. (2009). *Analiz vremennykh riadov i prognozirovaniye [Time series analysis and forecasting training complex]*. Moscow: EOI Publ., 264 [in Russian].

#### Author details

Dinara R. Bashirova – Ph. D. student, Department of Engineering Geodesy.

Mikhail Ya. Bryn – D. Sc., Professor, Department of Engineering Geodesy.

Denis A. Krivonosov – Head of Surveying Department.

Received 13.05.2022

© D. R. Bashirova, M. Ya. Bryn, D. A. Krivonosov, 2022