

Таким образом, использование видеоэндоскопа для осмотра фитинговых упоров специализированных платформ на местах погрузки, выгрузки или технических станциях без снятия контейнеров позволит сократить следующие временные и финансовые потери:

- исключить нежелательные маневровые операции по выводу порожних вагонов на пути станции для осмотра, или дополнительных переформирований контейнерного поезда, тем самым снизив загрузку маневрового локомотива и, соответственно, эксплуатационные расходы;
- минимизировать отвлечение ОРВ и приемосдатчиков груза и багажа контейнерных площадок от основного процесса работы;
- сократить количество грузовых операций с контейнером, тем самым снизив эксплуатационные расходы, приходящиеся на грузоподъемные механизмы;
- обеспечить повышение безопасности движения поездов и сохранность перевозимых контейнеров и грузов.

Список литературы

- 1 Технология осмотра фитинговых вагонов-платформ, следующих по замкнутым кольцевым маршрутам на инфраструктуре ОАО «РЖД» № 911-2020 ПКБ ЦВ. – 2021. – 9 с.
- 2 Гудок. – Вып. 18 (26867). – 2021. – 4 февр. [Электронный ресурс]. – Режим доступа : <https://gudok.ru/newspaper/>. – Дата доступа : 25.08.2022.
- 3 Гудок. – Вып. 233 (26842). – 2019. – 18 дек. [Электронный ресурс]. – Режим доступа : <https://gudok.ru/newspaper/>. – Дата доступа : 25.08.2022.
- 4 Москвичева, Е. Е. К вопросу совершенствования производственной деятельности контейнерных терминалов / Е. Е. Москвичева, Д. В. Васильев // Наука и образование транспорту. – 2019. – № 1. – С. 149–154.
- 5 Москвичева, Е. Е. Цифровая трансформация станционных технологических процессов / Е. Е. Москвичева // Наука и образование транспорту. – 2020. – № 1. – С. 133–135.

УДК 004.942

МЕТОДЫ ПРОГНОЗИРОВАНИЯ И ПРЕДОТВРАЩЕНИЯ ПРАВОНАРУШЕНИЙ НА ЖЕЛЕЗНОДОРОЖНОМ, АВТОМОБИЛЬНОМ И ВОДНОМ ТРАНСПОРТЕ

М. И. МУКОНИНА, В. Д. ШВАЛОВ

*Ростовский государственный университет путей сообщения,
г. Ростов-на-Дону, Российская Федерация*

Прогнозирование правонарушений является одной из самых сложных задач, особенно когда анализ имеет тенденцию оценивать предполагаемые деяния. В этой работе мы используем стратегию модели временных рядов и систем машинного тестирования для оценки степени правонарушений. В рамках нашего исследования были применены различные методы прогнозирования количества возможных правонарушений на объектах железнодорожного, автомобильного и водного транспорта на ближайшие пять лет.

Прогнозирование временных рядов – это один из универсальных подходов, позволяющих решать задачу прогнозирования с использованием большого набора данных. Временной ряд относится к последовательности данных, результаты которой получены после обучения и тестирования системы в заданных временных интервалах. Полученные результаты становятся первичными данными для следующей итерации обучения и тестирования.

Метод Бокса – Дженкинса [1] предполагает, что стационарный временной ряд можно аппроксимировать с помощью модели авторегрессии – скользящего среднего (ARMA). Однако если временной ряд нестационарен, его можно аппроксимировать интегрированной моделью авторегрессии (ARIMA). Метод состоит из четырех этапов: идентификация, оценка, диагностическая проверка и прогнозирование. Метод ARIMA полезен для анализа данных с корреляцией между соседними наблюдениями и анализа многомерных временных рядов.

На первом этапе модель использует данные вместе с другой связанной информацией для выбора подкласса, чтобы он мог дать наилучшие обобщенные данные. На втором этапе модель использует данные для получения коэффициентов. На третьем этапе метод Бокса – Дженкинса оценивает модель в рамках имеющихся данных. Затем он проверяет области, в которых модель может быть улучшена при диагностической проверке, после чего прогнозируются результаты четвертого этапа.

Для прогнозирования в методе простого среднего используется среднее значение всех данных. В методе скользящего среднего каждое новое наблюдение становится переменной. Рассчитывают новое среднее значение, отбрасывая старое значение и добавляя новое значение. Затем полученное скользящее среднее используют для прогнозирования следующего периода.

Нейронные сети зарекомендовали себя в выявлении скрытых особенностей, которые упускают другие алгоритмы [2]. В рамках нашей работы была реализована искусственная нейронная сеть (ИНС), которая содержит несколько скрытых слоев и функцию активации в виде выпрямленного линейного блока (*ReLU*), которая возвращает значение x , если x положительно, и 0 – в противном случае (рисунок 1). Модель ИНС будет фиксировать отношения между разными временами года, местоположениями, полом и возрастными группами, а также то, как уровень правонарушений изменяется в течение сезона, в определенном месте в зависимости от пола или возрастной группы. Программный код для реализации разработанной модели ИНС на языке *Python* представлен на рисунке 2.

Среди существующих функций активации функция активации *ReLU* чаще всего используется в случае свёрточных нейронных сетей, принимая во внимание операции по обработке изображений и задачи классификации изображений. Подход, использованный в нашем решении, оказался высокоэффективным с точки зрения точности и запоминаемости, «потери с течением времени» сокращаются с точки зрения количества эпох. *ReLU* действует как модифицированная функция идентичности, которая равна нулю на отрицательной оси x и идентичности на положительной оси x . Это помогает сохранить значения признаков и, таким образом, предоставляет конкретные числовые значения в качестве входных данных для следующего уровня ИНС.

Большинство практических приложений машинного обучения используют контролируемое обучение, в котором у нас есть одна или несколько входных переменных или функций (X) и результирующая переменная или метка (Y). Для того чтобы модель могла предсказать значения Y , необходимо использовать любой алгоритм для определения функции сопоставления от функций к метке на основе новых функций, которые заранее неизвестны. Основная цель обучения – использовать эффективное сопоставление, чтобы при появлении новой входной функции или данных (X) модель могла предсказать правильную метку (Y) для этого конкретного набора значений. Данный процесс классифицируется как пример контролируемого обучения. Алгоритм многократно делает прогнозы на обучающих данных для желаемого количества циклов, чтобы изучить отображение, и корректируется путем внесения обновлений для изучения нового метода отображения. Процесс повторного обучения останавливается, когда алгоритм достигает приемлемого уровня производительности.




Рисунок 1 – График функции *ReLU*

```
rm(list = ls())
data=read.csv(file.choose(),header = T);data
attach(data)
plot.ts(data$TOTALCRIME,main="Number of crime",xlab="YEAR",ylab="TOTALCRIME")
plot.ts(data$Diff)
library(tseries)
adf.test(Diff,alternative="stationary")
acf(data$Diff,main="ACF of AR(1) process")
acf(data$Diff,main="ACF of MA(1) process")
pacf(data$Diff,main="PACF of AR(1) process")
pacf(data$Diff,main="PACF of MA(1) process")
fit=arima(data$Diff,order=c(1,1,1))
fit
fit1=arima(data$Diff,order=c(2,1,1))
fit2=arima(data$Diff,order=c(2,1,2))
fit3=arima(data$Diff,order=c(1,0,2))
fit4=arima(data$Diff,order=c(1,0,1))
par(mfrow=c(1,1))
tsdiag(fit2)
data.pred=predict(fit2,n.ahead=5)
data.pred
Box.test(fit$residuals,lag=1)
```

Рисунок 2 – Построение ИНС на языке *Python*

В качестве алгоритма машинного обучения был выбран алгоритм *KNN* [3], который применяется для автоматической классификации объектов или регрессии, использовали «евклидово расстояние» для вычисления расстояния до ближайшего соседа. В регрессоре *KNN* прогнозируемое значение является средним значением из ближайших соседей. На рисунке 3 показан псевдокод алгоритма регрессионного теста *KNN*.

Для оценки работоспособности ИНС, построенной по принципам, которые изложены в рамках нашей работы, было проведено тестирование алгоритмов машинного обучения на находящемся в свободном доступе наборе данных, в результате которого было установлено, что процент верных ответов, полученных ИНС после обучения, составляет 86,95 % (рисунок 4).

```

from sklearn.neighbors import KNeighborsRegressor as KNR
knr = KNR(n_neighbors=10)
knr.fit(years, y_new)
knr_df = pd.DataFrame()
knr_df['Actual'] = list(y_new[:5])
y_pred = knr.predict(x_fut)
knr_df['Predicted'] = y_pred
knr_df['Difference'] = y_pred - y_new[5,:]
knr_df.to_excel('KNR.xls', index=False)
plot(x_fut, y_pred, 'rx-', 'KNN')

```

Рисунок 3 – Псевдокод алгоритма регрессионного теста KNN

```

Console 1/A x
300/300 [=====] - 1s 5ms/step - loss: 0.3088 - mae: 0.0347 - accuracy: 0.8925
Epoch 96/100
300/300 [=====] - 1s 5ms/step - loss: 0.3079 - mae: 0.0346 - accuracy: 0.8927
Epoch 97/100
300/300 [=====] - 1s 5ms/step - loss: 0.3070 - mae: 0.0345 - accuracy: 0.8927
Epoch 98/100
300/300 [=====] - 1s 5ms/step - loss: 0.3061 - mae: 0.0344 - accuracy: 0.8937
Epoch 99/100
300/300 [=====] - 1s 5ms/step - loss: 0.3053 - mae: 0.0343 - accuracy: 0.8933
Epoch 100/100
300/300 [=====] - 1s 5ms/step - loss: 0.3046 - mae: 0.0342 - accuracy: 0.8935
313/313 [=====] - 1s 2ms/step - loss: 0.3644 - mae: 0.0381 - accuracy: 0.8695
Процент верных ответов на тестовых данных: 86.95

```

Рисунок 4 – Результат работы ИНС

Таким образом, применение различных методов прогнозирования и предотвращения нарушений правил пользования средствами железнодорожного, автомобильного и водного транспорта позволит идентифицировать человека, нарушающего правила пользования объектами транспортной системы, а также составить статистику, позволяющую заранее спрогнозировать опасные участки транспортной инфраструктуры и предотвратить правонарушения.

Список литературы

- 1 **Mohri, M.** Foundations of machine learning / M. Mohri, A. Rostamizadeh, A. Talwalkar. – Cambridge, MA : The MIT Press, 2018 – 488 p.
- 2 **Давыдов, Ю. В.** Анализ способов построения гибридных интеллектуальных систем на основе приближенных множеств и искусственных нейронных сетей / Ю. В. Давыдов, М. А. Бутакова // Актуальные проблемы и перспективы развития транспорта, промышленности и экономики России : сб. науч. тр. Всерос. нац. науч.-практ. конф. ТрансПромЭк-2018. – Ростов н/Д, 2018. – Т. 1. Технические науки. – С. 29–33.
- 3 **Шумский, С. А.** Машинный интеллект. Очерки по теории машинного обучения и искусственного интеллекта / С. А. Шумский. – М. : РИОР, 2019. – 340 с.

УДК 656.2.08

ПОВЫШЕНИЕ БЕЗОПАСНОСТИ И ЭНЕРГОЭФФЕКТИВНОСТИ ПЕРЕВОЗОЧНОГО ПРОЦЕССА

В. Я. НЕГРЕЙ, Д. В. КОЗЛОВИЧ

Белорусский государственный университет транспорта, г. Гомель

Стратегической задачей развития железнодорожного транспорта является повышение безопасности и энергоэффективности перевозочного процесса.

В настоящее время для оценки безопасности работы железнодорожного транспорта отсутствуют эталонные показатели, относительно слабо исследовано взаимодействие энергетической эффективности и безопасности [1]. Например, срыв стоп-крана, экстренное торможение, задержка поезда у запрещающих сигналов, неграфиковые остановки поездов, опоздание пассажирских поездов, предупреждение и ограничения скорости, повреждение вагонов на сортировочных, участковых и грузовых станциях и другие примеры негативно сказываются на уровне безопасности и энергоэффективности перевозочного процесса.

Массовый характер носит ограничение скорости движения грузовых поездов. В статье показано, что процесс движения поездов по участку при ограничении носит логико-вероятностный характер [2]. Исследования показали, что колебания продолжительности реакции машинистов и продолжительности срабатывания тормозов, а также в значительной мере случайный характер коэффициента сцепления необходимо учитывать при выборе длины ограничения и обеспечения безопасности движения.

Ряд ситуаций с высоким уровнем опасности: срыв стоп-крана, экстренное торможение, опасные соударения вагонов при расформировании-формировании поездов, скрытые повреждения подвижного состава при выполнении погрузочно-разгрузочных работ и другие причины – снижают энергоэффективность перевозочного процесса. Другими словами, снижение уровня безопасности приводит к существенным энергетическим и материальным потерям. Поэтому учёт влияния безопасности перевозочного процесса позволяет существенно повысить энергоэффективность работы транспорта.