

УДК 656.224

*А. А. ЕРОФЕЕВ*

*Белорусский государственный университет транспорта, г. Гомель  
Erofeev\_AA@bsut.by*

## **ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ РЕШЕНИИ ЭКСПЛУАТАЦИОННЫХ ЗАДАЧ В СИСТЕМЕ СМЕННО-СУТОЧНОГО ПЛАНИРОВАНИЯ ГРУЗОВОЙ РАБОТЫ ЖЕЛЕЗНОДОРОЖНЫХ СТАНЦИЙ**

Рассмотрен опыт внедрения на Белорусской железной дороге автоматизированной системы сменно-суточного планирования грузовой работы. Сформулирована проблематика применения технологии искусственного интеллекта при решении эксплуатационных задач. Определена структура априорной модели ССП и структура базы знаний системы. Предложено прогнозирование погрузки и выгрузки дороги с использованием алгоритмов машинного обучения, основанных на регрессионном анализе данных. Приведено описание анализируемых массивов, целевой функции, функции качества и алгоритма прогнозирования.

В рамках создания на Белорусской железной дороге интеллектуальной системы управления перевозочным процессом (ИСУПП) разработана и внедрена автоматизированная система сменно-суточного планирования грузовой работы (АС ССП) [1]. Автоматизация с ее помощью процесса поддержки принятия управленческих решений в режиме реального времени и повышение уровня детализации, в первую очередь, вагонной модели позволили отказаться от традиционного способа оперативного планирования погрузки и выгрузки.

Ранее планирование выполнялось на базе экспертных решений, основанных на укрупненной информации о наличии вагонов и грузов, среднестатистических параметрах перевозочного процесса. Всё это не позволяло в полной мере исключить влияние так называемого «человеческого фактора» и добиться улучшения показателей эксплуатации вагонного парка. В результате увеличивался пробег порожних вагонов, тормозилось выполнение заявок на перевозку грузов, замедлялось продвижение грузопотоков, не всегда удавалось согласовывать между собой планы поездной и грузовой работы. Автоматизация задач оперативного планирования грузовой работы позволила решить эти проблемы [2]. Однако точность формируемых в АС ССП планов остается недостаточно высокой (на уровне 80–90 %). Повышение

достоверности планирования может быть достигнуто путем использования в системе технологий искусственного интеллекта.

Интеллектуализация решения задач ССП направлена на оптимизацию использования подвижного состава различных перевозчиков и удовлетворение потребностей клиентов в грузовых перевозках. Априорная модель ССП основана на следующих видах информации:

1 Условно-постоянная информация:

- план формирования грузовых поездов;
- технический план эксплуатационной работы;
- технические ограничения и условия использования инфраструктуры;
- нормативы выполнения технологических операций.

2 Переменная информация:

- актуальный график движения грузовых поездов;
- заявки на погрузку (отправочная модель дороги);
- текущая дислокация и технологическое состояние подвижного состава на дорожном полигоне (вагонная модель полигона);
- оперативные данные о состоянии объектов инфраструктуры (состояние грузовых фронтов, путей станций, вызванные отказами технических средств ограничения);

- результаты эксплуатационной работы за отчетный период;
- заявки соседних железных дорог на передачу поездов и вагонов по стыковым пунктам;
- прогноз состояния тяговых ресурсов в плановом периоде (локомотивная модель работы полигона и функция прогнозирования состояния локомотивов и наличия локомотивных бригад на период планирования).

Функциональную структуру ССП дополняет *база знаний* системы, содержащая плановые и контрольные формы по планированию погрузки и выгрузки, уточняющие расчетные коэффициенты, и *триады базы знаний* (исходные данные – плановые показатели – итоги реализации планов) за все отчетные периоды.

Гибридный решатель эксплуатационных задач (ГБРЭЗ) в АС ССП может быть представлен в виде следующих эксплуатационных задач:

- планирования количественных значений грузовой работы;
- планирования временных значений грузовой работы;
- согласование, корректировка и утверждение ССП.

При ССП одной из задач является объективное определение возможности выполнения грузовых операций с конкретными вагонами, которые находятся в пределах полигона сбора информации. Часто могут наблюдаться ситуации, когда находящийся на более дальнем расстоянии от станции назначения вагон успевают выгрузить в плановые сутки, а находящийся ближе – нет. В связи с этим возникает алеаторная неопределенность исходной для планирования информации.

В целях повышения качества планирования в рамках ИСУПП необходимо предусмотреть модуль прогнозирования, обеспечивающий эффективное определение возможности выполнения операций с вагоном в зависимости от его местонахождения и других значимых параметров эксплуатационной обстановки. Прогнозирование погрузки-выгрузки дороги предлагается выполнять с использованием *алгоритмов машинного обучения, основанных на регрессионном анализе данных.*

Задачей прогнозирования является предсказание числового значения погрузки и выгрузки вагонов на станции  $S_i$  по данным о состоянии эксплуатационной обстановки на полигоне управление. Задачей функционирования алгоритма обучения является определение функции  $f: R_n \rightarrow R$ .

Мера качества  $P$  определяется следующими выражениями:

$$\sum |P_{\text{погр}}| = \sum |(U_{\text{п.план}}^i + U_{\text{п.внеплан}}^i) - U_{\text{п.факт}}^i| \rightarrow 0, \quad (1)$$

$$\sum |P_{\text{выгр}}| = \sum |U_{\text{в.план}}^i - U_{\text{в.факт}}^i| \rightarrow 0, \quad (2)$$

где  $P_{\text{погр}}$ ,  $P_{\text{выгр}}$  – мера качества соответственно плана погрузки и плана выгрузки;  $U_{\text{п.план}}^i$ ,  $U_{\text{п.внеплан}}^i$ ,  $U_{\text{п.факт}}^i$  – соответственно плановое, внеплановое и фактическое значение величины погрузки за период планирования по  $i$ -му объекту управления (станции, клиенту), вагонов;  $U_{\text{в.план}}^i$ ,  $U_{\text{в.факт}}^i$  – соответственно плановое и фактическое значение величины выгрузки за период планирования по  $i$ -му объекту управления (станции, клиенту), вагонов.

Выполнение равенств (1) и (2) обеспечивает минимизацию отклонений суммы плановой и внеплановой погрузки, а также плановой выгрузки от их выполненных значений за плановый период по каждому объекту управления.

Целью является построение модели, которая на основании данных об эксплуатационной обстановке на полигоне  $x \in R_n$ , определяет множество вагонов, подлежащих погрузке и выгрузке в плановый период  $y \in \mathbb{R}$ . Результатом линейной регрессии является линейная функция входных данных.

Обозначим  $y'$  значение  $y$ , предсказанное моделью. Определим результат модели в виде

$$y' = wx, \quad (3)$$

где  $w \in \mathbb{R}^n$  – вектор весов параметров, характеризующих эксплуатационную обстановку на полигоне.

Признаки (факторы)  $x_n$ , влияющие на план погрузки:

- количество поданных заявок на погрузку в установленный период;
- грузоотправитель;
- груз;
- станция отправления;
- день недели;
- месяц года;
- избыток/недостаток порожних вагонов на полигоне.

Признаки (факторы)  $x_b$ , влияющие на план выгрузки:

- станция/участок дислокации отправки;
- станция назначения;
- РПС;
- груз;
- грузополучатель;
- день недели;
- месяц года;
- избыток/недостаток порожних вагонов на полигоне;
- коэффициент загрузки участков на маршруте следования;
- наличие «окон» на маршруте следования от станции или участка дислокации до станции назначения.

Задача прогнозирования значений погрузки и выгрузки имеет следующий вид. Имеется массив информации о выполненных погрузке и выгрузке вагонов за ретроспективный период  $T$ , который включает в себя информацию о плановых и фактических значениях показателей и формализованное описание эксплуатационной обстановки на полигоне.

Данный массив разделяется на две части:

- матрица плана с  $m$  примерами для оценки качества работы модели;
- матрица плана с  $m'$  примерами для обучения модели.

На основании данных о фактически выполненных показателях формируется вектор меток, содержащий правильные значения  $y$  для каждого из этих примеров. Для оценки качества модели формируется матрица плана  $X_{(test)}$ , включающая векторы меток регрессии  $y_{(test)}$ .

Оценку качества модели предлагается выполнять путем вычисления среднеквадратической ошибки модели на тестовом наборе. Если вектор  $\bar{y}_{test}$  содержит предсказания модели на тестовом наборе, то среднеквадратическая ошибка определяется по формуле

$$MSE_{test} = \frac{1}{m} \sum_i (\bar{y}_{test} - y_{test})_i^2. \quad (4)$$

Эта мера ошибки обращается в 0, когда  $\bar{y}_{test} = y_{test}$ . Кроме того,

$$MSE_{test} = \frac{1}{m} \left\| \bar{y}_{test} - y_{test} \right\|_2^2. \quad (5)$$

Поэтому ошибка тем больше, чем больше евклидово расстояние между предсказаниями и метками.

Требуется разработать алгоритм машинного обучения, который улучшает веса  $w$  таким образом, что  $MSE_{test}$  уменьшается по мере того, как алгоритм получает новый опыт, наблюдая обучающий набор  $(X_{train}, y_{train})$ , т. е. минимизировать среднеквадратическую ошибку на обучающем наборе  $MSE_{train}$ .

Для минимизации  $MSE_{train}$  необходимо приравнять градиент нулю и решить получившееся уравнение (т. е. получить нормальное уравнение):

$$\begin{aligned}
 \nabla_w MSE_{train} &= 0, \\
 \Rightarrow \nabla_w \frac{1}{m} \left\| \bar{y}_{train} - y_{train} \right\|_2^2 &= 0, \\
 \Rightarrow \nabla_w \frac{1}{m} \left\| X_{train} w - y_{train} \right\|_2^2 &= 0, \tag{6} \\
 \Rightarrow \nabla_w (X_{train} w - y_{train})^T (X_{train} w - y_{train}) &= 0, \\
 \Rightarrow \nabla_w (w^T X_{train}^T X_{train} w - 2w^T X_{train}^T y_{train} + y_{train}^T y_{train}) &= 0, \\
 \Rightarrow 2(X_{train}^T X_{train} w - X_{train}^T y_{train}) &= 0, \\
 \Rightarrow w = (X_{train}^T X_{train})^{-1} X_{train}^T y_{train}.
 \end{aligned}$$

При использовании алгоритма машинного обучения формируется обучающий набор, который используется для минимизации ошибки обучения, а также тестовый набор для оценки качества обучений.

Качество работы алгоритма машинного обучения можно определить следующим образом:

- 1) сделать ошибку обучения как можно меньше;
- 2) сократить разрыв между ошибками обучения и тестирования.

Повышение качества модели прогнозирования может быть достигнуто за счет оптимизации емкости модели. Недостаточная емкость приводит к недообучению, и модель не позволяет получить достаточно малую ошибку на обучающем наборе. Избыточная емкость приводит к переобучению, когда разрыв между ошибками обучения и тестирования слишком велик (рисунок 1).

В ИСУПП предлагается применять следующие ключевые способы управления емкостью модели:

- модификация числа признаков с одновременным добавлением ассоциированных с этими признаками параметров;
- определение семейства функций, из которого можно выбирать алгоритм обучения в процессе варьирования параметров (репрезентативная емкость модели);
- управление величиной обучающей и тестовой выборки.

Количественное выражение емкости модели предлагается оценивать при помощи размерности Вапника – Червоненкиса (VC-размерность), измеряющей емкость бинарного классификатора [3].




Рисунок 1 – Связь между емкостью модели и ошибкой

VC-размерность определяется как наибольшее возможное значение  $m$ , такое, что существует обучающий набор  $m$  разных точек  $x$ , которые классификатор может пометить произвольным образом.

Так как ошибка обобщения измеряется посредством  $MSE$ , а увеличение емкости влечет за собой повышение дисперсии и снижение смещения, то оценку оптимальной емкости модели предлагается производить путем перекрестной проверки смещения и дисперсии. В этом случае смещение измеряет ожидаемое отклонение от истинного значения функции или параметра, а дисперсия – это мера отклонения от ожидаемого значения оценки в произвольной выборке данных.

Среднеквадратическая ошибка ( $MSE$ ) обеих оценок вычисляется по формуле

$$MSE = E[(\Theta_m' - \Theta)^2] = Bias(\Theta_m')^2 + Var(\Theta_m') . \quad (7)$$

При обучении больших моделей, репрезентативная емкость которых достаточна для переобучения, возможны случаи, когда ошибка обучения монотонно убывает со временем, а ошибка на контрольном наборе снова начинает расти. Следовательно, модель с более низкой ошибкой на контрольном наборе можно получить путем возврата к тем значениям параметров, которые существовали на момент наименьшей ошибки. В таких случаях предлагается использовать стратегию ранней остановки [4].

Каждый раз, когда ошибка на контрольном наборе улучшается, копия параметров модели сохраняется. Когда алгоритм обучения завершается, возвращаются не последние параметры, а те, которые имеют наименьшие ошибки. Алгоритм обучения следует остановить, когда на протяжении заранее заданного числа итераций не удастся улучшить параметры, по сравнению с наилучшими, запомненными ранее.

При такой постановке задачи обучения количество итераций, при которых не удастся улучшить решение, следует рассматривать как гиперпараметр модели (его использование позволяет управлять емкостью модели).

На основании накопленных с АС СПП данных о прогнозных и фактических значениях погрузки и выгрузки за 2019–2020 гг. установлено, что минимальная среднеквадратическая ошибка наблюдается при величине выборки от 50 до 70 предшествующих плановому периоду суток и составляет от 3 до 7 % прогнозируемой величины.

Дополнение обучающей выборки данными за аналогичный месяц предыдущего года увеличивает обучающую выборку до 80–100 значений. При этом *MSE* снижается до 2,5–5 %.

#### СПИСОК ЛИТЕРАТУРЫ

1 *Ерофеев, А. А.* Разработка интеллектуальной системы управления перевозочным процессом на Белорусской железной дороге / А. А. Ерофеев, О. А. Терещенко, В. В. Лавицкий // Железнодорожный транспорт. – 2020. – № 6. – С. 74–77.

2 *Ерофеев, А. А.* Автоматизация оперативного планирования грузовой работы / А. А. Ерофеев, П. М. Дулуб, О. А. Терещенко // Железнодорожный транспорт. – 2018. – № 7. – С. 11.

3 *Hastie, T.* Chapter 7.9. Vapnik – Chervonenkis Dimension / Т. Hastie, R. Tibshirani, J. Friedman // The Elements of Statistical Learning: Data Mining, Inference, and Prediction. – 2nd ed. – Springer-Verlag, 2009. – 746 p.

4 *Гудфеллоу, Я.* Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль ; пер. с англ. А. А. Слинкина. – 2-е изд., испр. – М. : ДМК Пресс, 2018. – 652 с.

*A. A. EROFEEV*

### **ARTIFICIAL INTELLIGENCE TECHNOLOGIES FOR SOLVING OPERATIONAL PROBLEMS IN THE SYSTEM OF DAILY SHIFT PLANNING OF CARGO WORK RAILWAY STATION**

The experience of introducing an automated system of shift-daily planning of cargo work on the Belarusian railway is considered. The problems of using artificial intelligence technology in solving operational problems are formulated. The structure of the a priori model of the SDP and the structure of the knowledge base of the system are determined. It is proposed to predict the loading and unloading of the road using machine learning algorithms based on data regression analysis. The descriptions of the analyzed arrays, the objective function, the quality function and the prediction algorithm are given.

Получено 01.12.2022