

УДК 656.21

П. К. Рыбин, Р. Р. Ахмедов, А. П. БадецкийПетербургский государственный университет путей сообщения
Императора Александра I**О. А. Медведь**

Санкт-Петербургский техникум железнодорожного транспорта

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ В ЦЕЛЯХ ПРОГНОЗИРОВАНИЯ ПОСТУПЛЕНИЯ ВАГОНОВ В ПОРТ

Прогнозирование является важной составляющей частью планирования эксплуатационной работы как всего железнодорожного транспорта в целом, так и его отдельных подразделений. Чем выше качество прогноза, тем выше качество планирования и, соответственно, организации работы. В статье рассматривается возможность применения математического аппарата искусственных нейронных сетей для прогнозирования количества поступающих в порт вагонов на примере угольных вагонопотоков. Интерес к проблеме взаимодействия железнодорожного и морского транспорта в припортовых транспортных узлах объясняется ее непосредственным влиянием на развитие всего транспортного комплекса России и повышение эффективности его работы.

искусственные нейронные сети, взаимодействие морского и железнодорожного транспорта, многослойный персептрон, прогнозирование, планирование.

Введение

Одним из основных партнеров морского торгового флота по объему грузоперевозок является железнодорожный транспорт, поэтому любая несогласованность действий морского порта и припортовой железнодорожной станции приводит к значительным потерям не только для участников перевозочного процесса, но и для всей экономики страны. Чтобы избежать этого, важно максимально точно определить условия, обеспечивающие четкое взаимодействие припортовых станций и порта [1].

Нарушения единой технологии взаимодействия железнодорожного и морского транспорта в ряде припортовых транспортных узлов часто вызваны сверхнормативным простоем вагонов. Например, в порту Санкт-Петербург простой вагонов в ожидании подачи и уборки доходит в среднем до 19 часов, а среднее время ожидания окончания грузовых операций на погрузочно-выгрузочных фронтах порта – до

30 часов. Причины этого – малая вместимость и большое число грузовых фронтов, расположенных на значительном расстоянии друг от друга, в результате группы разгруженных вагонов вынуждены ожидать окончания грузовых операций со всей партией поступивших вагонов и формирования состава из порожних вагонов для их дальнейшего отправления [2]. Это создает проблемы для железнодорожных компаний-перевозчиков, операторов подвижного состава и его владельцев.

Основным условием четкого взаимодействия железнодорожного и морского транспорта является поступление в порт заданного объема груза в установленные промежутки времени, определяющие условия его выгрузки, которые учитывают допустимую загрузку перегрузочной техники и складских мощностей порта, а также припортовой инфраструктуры железнодорожного транспорта.

Допустимый уровень загрузки портовых мощностей, а также технических и техноло-

гических резервов для освоения заданного объема работы необходимо планировать на основе оперативного прогноза поступления вагонов в порт. При этом горизонт прогноза должен быть максимально продолжительным.

Например, если вагоны подаются в порт с периодом 4 часа, то при оценке складывающейся ситуации даже на одни сутки необходимо достоверно спрогнозировать шесть значений. Таким образом, прогноз величины вагонопотоков на следующие несколько суток представляет собой сложную задачу, поэтому для прогнозирования поступления вагонов в порт желательно использовать математические модели, которые позволяют выявлять сложные зависимости между входными и выходными данными, а также обобщать результаты. Именно такими качествами обладают искусственные нейронные сети (ИНС), показавшие свою эффективность при прогнозировании колебаний вагонопотоков отдельных назначений плана формирования поездов [3]. Кроме того, они имеют ряд преимуществ:

- постоянную оптимизацию своей структуры в режиме реального времени с целью минимизации прогностической ошибки;
- более широкие возможности при анализе сложных динамических систем и закономерностей;

- способность решать задачи, опираясь на неполную и внутренне противоречивую входную информацию.

1 Анализ неравномерности поступающих в порт вагонопотоков

При прогнозировании желательно применять математическую модель, которая является наиболее эффективной с точки зрения затрат времени на расчеты и получаемых результатов. Для упрощения поиска такой модели нейронной сети необходимо выявить и изучить закономерности изменения исследуемых вагонопотоков. С этой целью были собраны и проанализированы собранные статистические данные за 2011–2013 гг. по угольным вагонопотокам, поступающим в порт в течение 4-часовых периодов (рис. 1). Несмотря на то, что исходный ряд обладает высокой динамичностью, можно визуально выделить тренд и периодическую компоненту ряда. Как видно на рис. 1, колебания величины вагонопотоков, поступающих в порт, ежегодно повторяются, наблюдается тенденция к небольшому возрастанию этой величины.

Для выявления в структуре представленного временного ряда пика отклонений от тренда




Рис. 1. Прибытие вагонов в порт в течении 4-часовых периодов за 2011–2013 гг.

и определения продолжительности периодической компоненты был проведен спектральный анализ с использованием одномерных рядов Фурье.

Анализ проводился отдельно для каждого вида неравномерности – годовой, квартальной, месячной, недельной, внутринедельной, суточной. В статье представлены только те виды неравномерности, для которых анализ дал положительный результат (рис. 2–5).

Периодограмма, построенная по данным за три года, позволяет выделить в качестве циклической составляющей (наибольший пик на рис. 2) 2048 периодов, которые суммарно составляют 341 день.

Периодограмма значений вагонопотока за 2011 г. (рис. 3) подтвердила предыдущую гипотезу о 341-дневной циклической составляющей обследованного вагонопотока, поступающего в порт.

На рис. 4 представлена периодограмма значений вагонопотока, поступающего в порт, за II квартал 2013 г. Видно ярко выраженный цикл в 180 периодов (30 суток), что соответствует одному месяцу. Стоит отметить, что анализ квартальной неравномерности всего временного ряда показал схожие результаты,

отличающиеся друг от друга на 1–2 суток. Также проанализирована внутримесячная неравномерность (рис. 5). По результатам определено, что внутри месяца циклическая составляющая вагонопотока равна 46 периодам, т. е. ≈ 8 суток.

С учетом результатов спектрального анализа решено прогнозировать количество прибывающих в адрес порта вагонов на следующие 4 суток по значениям вагонопотока за предыдущие 8 суток.

2 Синтез искусственной нейронной сети и проверка точности прогноза

2.1 Выбор количества слоев и нейронов в сети

Искусственная нейронная сеть создавалась в системе инженерных расчетов MatLab на основе примеров, описанных С. Хайкином [4]. В качестве нейронной сети для прогноза выбран многослойный персептрон (рис. 6), поскольку он является универсальным аппроксиматором сложных нелинейных функций.




Рис. 2. Периодограмма значений поступающего в порт вагонопотока за 2011–2013 гг.




Рис. 3. Периодограмма значений поступающего в порт вагонопотока за 2011 г.




Рис. 4. Периодограмма значений поступающего в порт вагонопотока за II квартал 2013 г.




Рис. 5. Периодограмма месячных значений поступающего в порт вагонопотока в течение 2011–2013 гг.




Рис. 6. Многослойный перцептрон

Сеть состоит из произвольного количества слоев нейронов. Нейроны следующего слоя соединяются с нейронами предыдущего по принципу «каждый с каждым». На вход нейронной сети подаются последовательно векторы входных данных $[X_1, X_2, \dots, X_n]^T$, нейроны входного (сенсорного) слоя распределяют входные сигналы между нейронами скрытого (ассоциативного) слоя. Скрытый слой рассчитывает нелинейное преобразование от линей-

ной комбинации сигналов и подает результат на нейроны выходного (результативного) слоя. Результатом работы сети является вектор выходных данных $[Y_1, Y_2, \dots, Y_m]^T$.

Выбор количества нейронов каждого слоя зависит от сложности задачи, количества имеющихся данных для обучения и от ресурсов машины, на которой моделируется нейронная сеть. Стоит отметить, что в настоящее время нет строго определенной процедуры для вы-

бора количества нейронов и слоев сети. Малое количество нейронов приводит к ухудшению аппроксимационных свойств сети и большой ошибке при работе сети. При увеличении количества слоев и нейронов сети она приобретает свойство отображать все более нелинейную зависимость «вход-выход». Но если нейронов будет слишком много, то сеть «переобучится» и будет неспособна формировать адекватное отображение выходных данных.

На основе анализа и установленной периодической компоненты временного ряда количество нейронов входного и выходного слоя выбирали исходя из условий задачи – по предыдущим восьми суткам спрогнозировать подход вагонов на следующие четверо суток. Таким образом, количество нейронов входного слоя N_x выбирали согласно определенной периодической компоненте – 46, выходного N_y – 24 (4 суток по 6 периодов). Количество нейронов скрытого слоя N подбирали эмпирически с учетом теорем Арнольда – Колмогорова – Хехт-Нильсена [5–7]. Согласно следствию из этих теорем, необходимое число синаптических весов определяется как

$$\frac{N_y Q}{1 + \log_2(Q)} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (1)$$

где N_y – размерность выходного сигнала; Q – число элементов обучающей выборки; N_w – необходимое число синаптических весов; N_x – размерность входного сигнала.

Тогда количество нейронов скрытого слоя составит

$$N = \frac{N_w}{N_x + N_y}. \quad (2)$$

Согласно проведенным расчетам, необходимое число нейронов скрытого слоя составило от 56 до 864. Согласно некоторым практическим рекомендациям, достаточное число нейронов скрытого слоя можно определить как $N_x + N_y$ [8]. Таким образом, сеть пред-

ставляет собой многослойный персептрон с архитектурой (46–70–24).

2.2 Формализация задачи прогнозирования и определение условий обучения сети

Многослойный персептрон осуществляет расчет вектора выходных данных y для любого вектора входных данных x . Тогда исходным условием задачи прогнозирования, которая ставится перед персептроном, является множество векторов $[X_1, X_2, \dots, X_n]^T$, а решением служит множество векторов $[Y_1, Y_2, \dots, Y_n]^T$. Важным этапом формализации является выбор смысла, которым наделяются компоненты вектора входных данных.

Для поставленной задачи компоненты входного вектора задавали в форме $[\text{date}, \text{period}, u_{\text{дп}}]$, где date – число, месяц и год, period – номер периода внутри суток, $u_{\text{дп}}$ – вагонопоток, поступающий в порт в заданный период заданных суток.

В обучающую выборку вошли значения прибывающего вагонопотока за период с 1 января 2011 г. по 2 октября 2013 г. Значения с 3 октября 2013 г. по 31 декабря 2013 г. в обучении сети не участвовали и служили для проверки точности прогноза.

Обучение нейронной сети осуществлялось методом обратного распространения ошибки (back propagation). Количество эпох обучения – 1200. В качестве функции активации нейронов выбрана сигмоидная (логистическая) функция с несимметричной областью изменений, которая в силу своих особенностей (она монотонно возрастает и имеет непрерывную производную) позволяет очень хорошо преобразовывать нелинейные функции. Сигмоидная функция активации задается формулой

$$y = \frac{1}{1 + e^{-s}}, \quad (3)$$

где S – разность между взвешенной суммой входных сигналов и пороговым значением нейрона:

$$S = \sum_{i=1}^n x_i w_i - \theta. \quad (4)$$

Среднеквадратичная ошибка обучения (разница между требуемыми d_i и реальными y_i выходными сигналами МП) определялась как

$$\varepsilon = \frac{1}{2} \sum_{i=1}^l (d_i - y_i)^2. \quad (5)$$

После обучения сети среднеквадратичная ошибка составила $\varepsilon = 0,065$. График изменения среднеквадратичной ошибки в результате

обучения представлен на рис. 7. После обучения с помощью нейронной сети был спрогнозирован вагонопоток на следующие 80 суток (480 значений). Средняя абсолютная ошибка прогнозирования составила 5,45%, что является достаточно хорошим результатом для столь длительного горизонта прогноза. Предсказанные нейронной сетью и фактические значения вагонопотока по периодам представлены в таблице и на рис. 8.

Как видно из таблицы и рис. 8, нейронная сеть дает возможность получить прогноз достаточно высокого уровня точности.




Рис. 7. Изменение среднеквадратичной ошибки в процессе обучения

Предсказанные и фактические значения прибывающего вагонопотока за первые трое суток прогноза

№ периода	Предсказанные значения, ваг.	Фактические значения, ваг.	№ периода	Предсказанные значения, ваг.	Фактические значения, ваг.
1	84,06	84	10	86,34	88
2	86,71	85	11	87,72	87
3	85,88	85	12	84,29	83
4	84,13	84	13	85,05	87
5	86,92	85	14	87,54	88
6	84,32	85	15	87,57	87
7	86,59	87	16	90,08	88
8	87,71	88	17	84,71	87
9	86,36	87	18	89,75	86




Рис. 8. Предсказанный и фактический вагонопоток

Заключение

Качественный прогноз поступления вагонов в адрес порта позволяет более эффективно планировать работу припортовых станций, а также приводит к существенному сокращению непроизводительных простоев вагонов в порту, что, в свою очередь, улучшает условия взаимодействия железнодорожного и морского транспорта. Возможность использования искусственных нейронных сетей для прогнозирования количества поступающих вагонов и высокая эффективность применения этой математической модели подтверждены в результате анализа реальных статистических данных по работе железнодорожных станций, которые обслуживают один из морских портов РФ. Таким образом, при определении потребного путевого развития станций и составлении прогноза изменения величины вагонопотоков, поступающих в адрес портов, грузовых районов, промышленных предприятий и терминально-складских комплексов, представляется целесообразным использование ИНС. В то же время необходимо продолжить исследования возможностей этого математического аппарата при построении прогнозов на более длительный период.

Библиографический список

1. **Об основных** положениях Генеральной схемы развития сети железных дорог ОАО «РЖД» на период до 2020 года / Ф. С. Пехтерев // Экономика железных дорог. – 2012. – № 5. – С. 30–38.
2. **Современный** аспект проблемы взаимодействия железнодорожного и морского транспорта в припортовых транспортных узлах (на примере Санкт-Петербургского морского торгового порта) / Р. Р. Ахмедов // Соврем. науч. исследования и инновации. – 2013. – № 8. – С. 29–32.
3. **Метод** адаптации плана формирования поездов к суточной неравномерности вагонопотоков : дис. ... канд. техн. наук / А. П. Бадецкий. – 2013. – 141 с.
4. **Haykin S.** Neural Networks. A comprehensive Foundation. – 2nd ed. – Prentice Hal., 2005. – 823 p.
5. **О функциях** трех переменных / В. И. Арнольд // ДАН СССР. – 1957. – Т. 114, № 4. – С. 679–681.
6. **О представлении** непрерывных функций нескольких переменных суперпозициями непрерывных функций меньшего числа переменных / А. Н. Колмогоров // ДАН СССР. – 1956. – Т. 108, № 2. – С. 179–182.
7. **Hecht-Nielsen R.** Kolmogorov's Mapping Neural Network Existence Theorem // IEEE First Annual Int. Conf. on Neural Network. – San Diego, 1987. – Vol. 3.
8. **Основные** концепции нейронных сетей / Р. Каллан ; пер с англ. – М. : Вильямс, 2001. – 287 с.