

Нейросетевая модель определения пассажиропотока железнодорожного транспорта пригородного сообщения

Битюцкая Анастасия Сергеевна

Филиал «Национальный исследовательский университет «МЭИ» в г. Смоленске

Студент

Кирееенкова Мария Сергеевна

Филиал «Национальный исследовательский университет «МЭИ» в г. Смоленске

Аспирант

Аннотация

Транспортная система представляет собой одну из важнейших отраслей экономики страны. В общей структуре пассажиропотока пригородное железнодорожное сообщение составляет 90% всего объема пассажирских перевозок, что делает особенно актуальной задачу исследования, разработки и совершенствования экономико-математических инструментов для прогнозирования пригородного пассажиропотока. Настоящая работа посвящена разработке экономико-математических инструментов, позволяющих осуществлять поддержку принятия решений по управлению предприятием железнодорожного пригородного сообщения на основе применения нейросетевых моделей реализующих технологии глубинного обучения для прогнозирования пригородного пассажиропотока

Ключевые слова: нейросетевая модель, пассажиропоток, железнодорожный транспорт пригородного сообщения

Neural network model for determining passenger traffic of suburban railway transport

Bityutskaya Anastasia Sergeevna

Branch of «National research University «MPEI» in Smolensk student

Kireenkova Maria Sergeevna

Branch of «National research University «MPEI» in Smolensk post-graduate student

Abstract

The transport system is one of the most important sectors of the country's economy. In the overall structure of passenger traffic, suburban railway traffic accounts for 90% of the total passenger traffic, which makes it particularly urgent

to research, develop and improve economic and mathematical tools for forecasting suburban passenger traffic. This work is devoted to the development of economic and mathematical tools to support decision-making on the management of the railway commuter on the basis of the use of neural network models implementing deep learning technology to predict suburban passenger traffic

Keywords: neural network model, passenger traffic, suburban railway transport

1. Анализ современного состояния пассажирского железнодорожного сообщения в субъектах Российской Федерации

Одной из ключевых транспортных отраслей является железнодорожная, регламентируемая Федеральным законом «О железнодорожном транспорте в Российской Федерации» [1]. В России эта отрасль представлена государственной, вертикально интегрированной компанией ОАО «Российские Железные Дороги» (РЖД). По данным Росстата в январе-апреле 2018 года грузооборот на железнодорожном транспорте составил 852,5 млрд тонно-километров, автомобильном 74,6 млрд, морском 10,1 млрд, внутреннем водном 8,3 млрд, воздушном 2,3 млрд., трубопроводном 898,1 млрд тонно-километров. Пассажиروоборот транспорта общего пользования за этот же период составил 146,5 млрд. пассажиро-километров, в том числе на железнодорожном 32,7 млрд., автомобильном 36,5 млрд, воздушном 77,4 млрд пасс.-километров. Приведенные данные показывают, что доля железнодорожного транспорта в грузоперевозках на порядок больше чем автомобильного и воздушного, в то время как в пассажирских перевозках она сопоставима с ними (и даже меньше, чем у воздушного транспорта). Кроме того, как заявляет руководство РЖД, пассажирские перевозки убыточны, особенно такой их сегмент, как пригородное сообщение. Эти данные объясняют желание РЖД снять с себя бремя пассажирских перевозок, но так как это невозможно, учитывая социальную значимость данного вида транспорта, то по возможности, минимизировать связанные с ними издержки. Одно из направлений этой работы связано с применением руководством вокзалов методов прогнозирования пассажиропотока, которое позволяет обеспечивать оптимальную загрузку поездов и устранять не эффективное использование подвижного состава.

Анализ современного состояния пассажирского железнодорожного сообщения в субъектах Российской Федерации, показывающий, что влияние пригородного сообщения для ОАО «Российские железные дороги» (РЖД) возрастает – так, перевозки пассажиров в 2017 году, по оперативным данным, выросли на 7,8% по сравнению с аналогичным периодом прошлого года – до 1,12 млрд человек, при этом в дальнем следовании пассажироперевозки выросли на 0,8%, до 102,3 млн человек, а в пригородном сообщении – на 8,5%, до 1,016 млрд. Представленные числа показывают, что пригородное сообщение растет опережающими темпами и, следовательно, требует к себе повышенного внимания со стороны менеджмента компании,

актуализируя исследования в области совершенствования экономико-математических методов прогнозирования пассажиропотока.

В настоящее время системы планирования ресурсов (ERP-систем, от англ. Enterprise Resource Planning), применяемые на железнодорожном транспорте, а также экономико-математические модели и методы прогнозирования пассажиропотока, применяемые в РЖД, достаточно разнообразны, однако в основном они базируются на статистическом анализе данных (формализованные методы) и экспертных заключениях (интуитивные), а также на их комбинации. Применяются для прогнозирования пассажиропотока и искусственные нейронные сети, но только для данных, представленных в виде временных рядов. В ряде моделей рассматриваются так называемые обратные постановки, когда по имеющимся наблюдениям пассажиропотока приходится восстанавливать причины его изменения и на этой основе строить прогностические суждения. Методы решения подобных задач базируются как на регуляризации решений, так и на интеллектуальных подходах.

Расширением методологической базы построения экономико-математических моделей прогнозирования пассажиропотока может служить использование в них методов глубинного обучения (deep learning) для извлечения и использования скрытых закономерностей в поступающей информации. Сферы применения глубинного обучения распространяются на различные задачи, но чаще всего это обработка изображений, а учитывая, что при анализе пассажиропотоков данные от видеочкамер в настоящее время практически не используются, это направление исследований представляет интерес при создании прогностических моделей.

2. Разработка нейросетевой модели для поддержки принятия решений по управлению предприятием железнодорожного пригородного сообщения на основе краткосрочного и среднесрочного прогнозирования пассажиропотока

В данной главе представлена обобщенная структура прогнозной модели на основе нейронных сетей (рисунок 1).

Разработанный метод прогнозирования пассажиропотока адаптируется для каждого железнодорожного вокзала с учетом особенностей организации контроля и управления пассажиропотоком и состоит из нескольких этапов:

- конкретизация исходных данных (источников информации о пассажиропотоке, выделение факторов, если это возможно, влияющих на дальнейший прогноз пассажиропотока);
- предварительная подготовка исходных данных (Data Preprocessing) для возможности дальнейшей их обработки выбранными технологиями;
- разработка структуры системы машинного обучения и ее реализация;
- применение системы машинного обучения.

Предполагается, что для прогноза пассажиропотока уже могут применяться какие-либо модели под номерами 1, ..., Nm, показанные на

рисунке 1. Под исходными данными для прогноза пассажиропотока понимается та информация, которая используется для осуществления прогноза моделями 1, ..., N_m , а также системой глубокого обучения, на вход которой также поступают данные с камер видеонаблюдения расположенных в разных точках вокзала.

На первом этапе проводится конкретизация исходных данных, предполагающая формирование перечня источников информации, которые будут использованы для выполнения прогноза. Полагаем, что такой перечень уже имеется для применяемых моделей 1, ..., N_m и на нем, как и на предварительной подготовке данных, больше не будем останавливаться. Дополнительно добавляются изображения от видеокамер (для акцентирования этого момента на рисунке 1 добавлен блок «Данные, поступающие с видеокамер») которые используются системой глубокого обучения.



Рисунок 1 – Структура модели прогнозирования пригородного пассажиропотока

На втором этапе выполняется подготовка данных для возможности выявления в них скрытых закономерностей и дальнейшего прогнозирования на основе распознавания изображений сверточными нейронными сетями. Если эти данные уже являются изображениями, проводится их нормализация, то есть, приведение к выбранному стандартному размеру. Если данные представлены в числовой форме, то выполняется их визуализация каким

либо методом. Второй этап является важной составляющей успеха прогнозирования, так как корректно сформированные обучающие наборы данных для нейронной сети позволят ожидать, что сеть сработает с минимальной ошибкой. Данная процедура – одна из последних, которая требует затрат человеческого труда, так как процесс обучения сети на подготовленных данных и ее работа уже проходят в автономном режиме.

Изображения могут формироваться из разных источников, с учетом пространственной и временной дискретизации данных. Часть изображений формируется непосредственно из видеопотока с видеокамер, другие – могут быть получены с помощью специальных преобразований числовых данных, например, данных о динамике продажи билетов на соответствующее направление пригородного сообщения или результатов, полученных на основе применения других моделей.

Для прогноза на некоторый интервал времени Δt необходимо иметь данные за Nt интервалов Δt до момента времени t_p , в который требуется получение прогноза. Величина Δt определяет временной лаг прогноза (краткосрочный или среднесрочный). Изображения могут быть представлены в любом графическом формате, но далее они должны быть преобразованы к одному единому формату. Для определенности был выбран формат jrg, использующий аддитивную цветовую модель RGB. В таком формате каждое изображение содержит три цветовых канала (красный, зеленый, голубой) представленные матрицами размера $n \times m$, где n – количество пикселей по вертикали, m – по горизонтали. В результате, каждая фотография представляется матрицей размера $n \times m \times 3$.

Для визуализации числовых данных предложено применение метода, базирующегося на преобразовании Фурье и мел-частотных кепстральных коэффициентах, применяемый в задачах машинного распознавания речи.

Обозначим визуализируемый процесс (например, данные, поступающие из автоматизированной системы продажи билетов) как $s[t]$. Этот сигнал на заданном промежутке времени перед анализируемым моментом t_p делится на K фрагментов по N отсчетов, пересекающихся на $N/2$ своей ширины: $s[t] \rightarrow S_n[t], n=1, \dots, K$. Каждый фрагмент подвергается дискретному Фурье-преобразованию и вычисляется спектральная плотность мощности [12]:

$$\operatorname{Re}(X_n[k]) = \frac{2}{N} \sum_{i=1}^N S_n[i] \cos(2\pi k(i-1)/N), \operatorname{Im}(X_n[k]) = \frac{2}{N} \sum_{i=1}^N S_n[i] \sin(2\pi k(i-1)/N),$$

$$P_n[k] = A_n[k]^2, \quad A_n[k] = \sqrt{\operatorname{Re}(X_n[k])^2 + \operatorname{Im}(X_n[k])^2},$$

где $k=1, \dots, M, M=N/2$.

Термин кепстр (cepstrum) определяет результат дискретного косинусного преобразования от логарифма амплитудного спектра сигнала [13]. На его основе рассчитываются мел-частотные кепстральные коэффициенты. При нахождении этих коэффициентов применяют специальный банк фильтров, а в наиболее простом случае можно

использовать равномерную (одинаковую на всем диапазоне частот) шкалу. Вычисления проводятся по взаимнообратным формулам[12]:

$$f_{mel}(f_{hz}) = 1127 \ln\left(1 + \frac{f_{hz}}{700}\right), \quad f_{hz}(f_{mel}) = 700(e^{(f_{mel}/1127)-1}),$$

где f_{hz} – частоты спектра, f_{mel} – мел-коэффициенты.

Нижнюю f_l и верхнюю f_h граничные частоты находят из условия обеспечения корректности преобразований – надо чтобы f_h не была больше половины частоты дискретизации. Для реализации различной чувствительности к частотам задается число фильтров P в банке фильтров (на практике бывает достаточно $P=12$) и частоты переводятся в мелы:

$$f_l^m = f_{mel}(f_l), \quad f_h^m = f_{mel}(f_h).$$

Выбирают отрезок мел-коэффициентов $[f_l^m, f_h^m]$ и разбивают его на $P+1$ одинаковых не перекрывающихся интервалов $[f_1^m, f_{j+1}^m]$, $j=1, \dots, P+1$ длиной $len = (f_h^m - f_l^m)/(P+1)$, вычисляют их середины: $C_m[i] = f_1^m + i \cdot len$, $i=1, \dots, P$. После этого производится их пересчет в шкалу частот (центры полос пропускания фильтров) и центры полос пропускания переводятся в номера отсчетов матрицы $P_n[k]$:

$$C[i] = f_{hz}(C_m[i]), i=1, \dots, P, \quad f_{smp}[i] = \frac{M}{F_s} C[i], i=1, \dots, P,$$

где F_s – частота дискретизации сигнала $s[t]$.

Выполнив расчет суммы произведений отсчетов спектральной плотности на частотную характеристику соответствующего фильтра:

$$X_n[i] = \sum_{k=1}^M P_n[k] H_i, i=1, \dots, P,$$

$$H_i[k] = \begin{cases} 0, k < f_{smp}[i-1] \\ \frac{(k - f_{smp}[i-1])}{f_{smp}[i] - f_{smp}[i-1]}, f_{smp}[i-1] \leq k < f_{smp}[i], \\ \frac{(f_{smp}[i+1] - k)}{f_{smp}[i+1] - f_{smp}[i]}, f_{smp}[i] \leq k \leq f_{smp}[i+1], \\ 0, k > f_{smp}[i+1] \end{cases}$$

и проводя косинусное преобразование, получаем:

$$C_n[j] = \sum_{k=1}^P \ln(X_n[k]) \cos\left(j(k - 0.5) \frac{\pi}{P}\right), i=1, \dots, P, j=1, \dots, J,$$

где $C_n[j]$ – матрица кепстральных коэффициентов, J – количество коэффициентов ($J < P$).

Полученная матрица $C_n[j]$ может быть интерпретирована как изображение (битовая карта), отражающая скрытые характеристики и закономерности анализируемого пригородного маршрута.

Перед подачей изображений, поступающих с видеокамер, битовых карт или других источников на входы сверточных нейронных сетей их необходимо нормировать к одному размеру, чтобы обеспечить унификацию архитектуры сети. Если для формирования прогноза доступны P каналов

поступления визуальной информации, то архитектура системы машинного обучения будет иметь вид, показанный на рисунке 2.

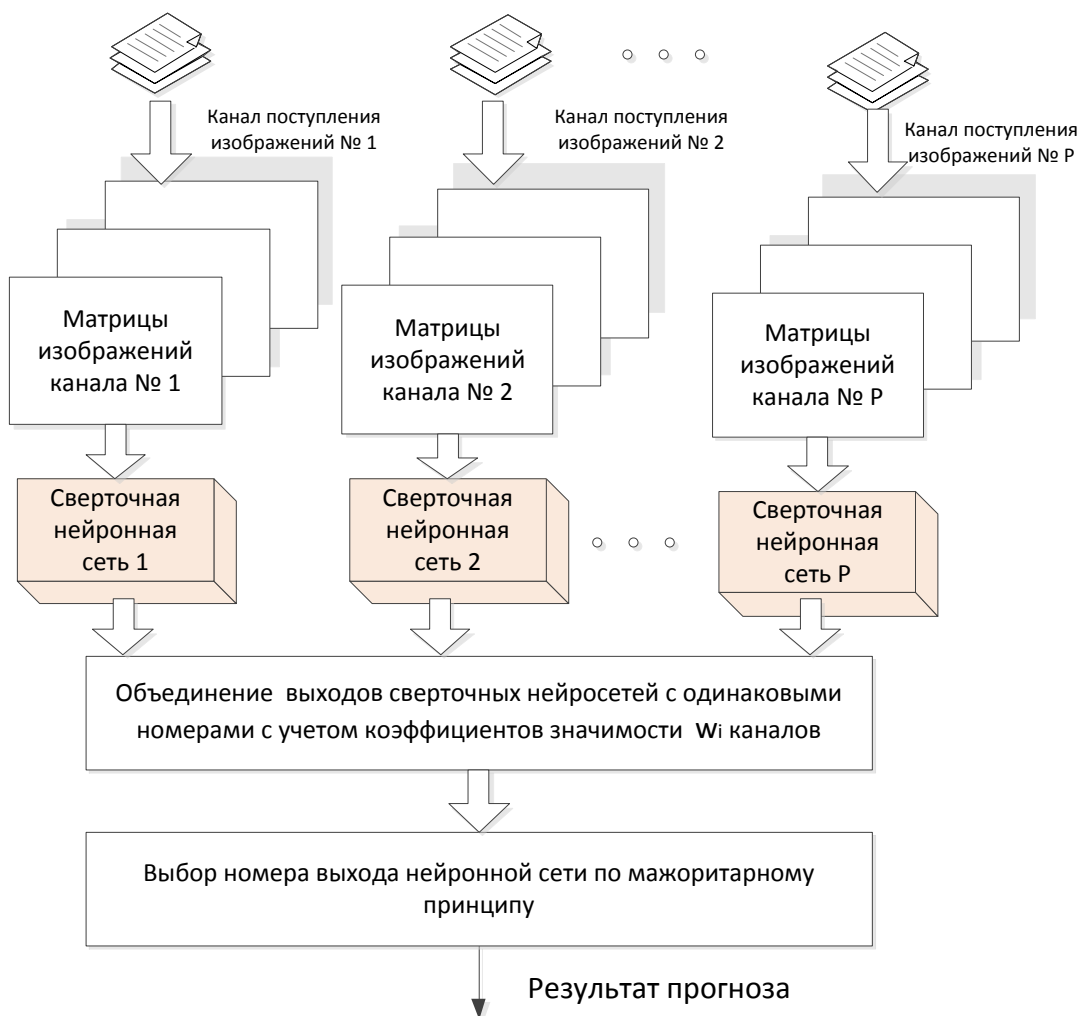


Рисунок 2 – Архитектура системы машинного обучения

На втором этапе также необходимо разбить данные на обучающие выборки, соответствующие тому или иному количеству пассажиров. Здесь следует учитывать, что с математической точки зрения сверточные сети при распознавании изображений выполняют процедуру классификации. Для адаптации ее к задаче прогноза предварительно составляется таблицу соответствия классов с номерами $1, \dots, N_{\text{кл}}$ тому или иному прогнозному значению диапазона пассажиропотока.

3. Алгоритмическое и программное обеспечения, практической реализация разработанной нейросетевой модели для поддержки принятия решений по управлению предприятием железнодорожного пригородного сообщения применяемой для прогноза пассажиропотока

Данная глава содержит детализацию представляемого алгоритма прогнозирования пригородного пассажиропотока. В рамках этого разработана диаграмма потоков данных в нотации Йордана, показанная на

рисунке 3. Работы 2 -4 реализуются на подготовительных этапах решения задачи прогнозирования, а работы 5 и 6 обеспечивает программное обеспечение.

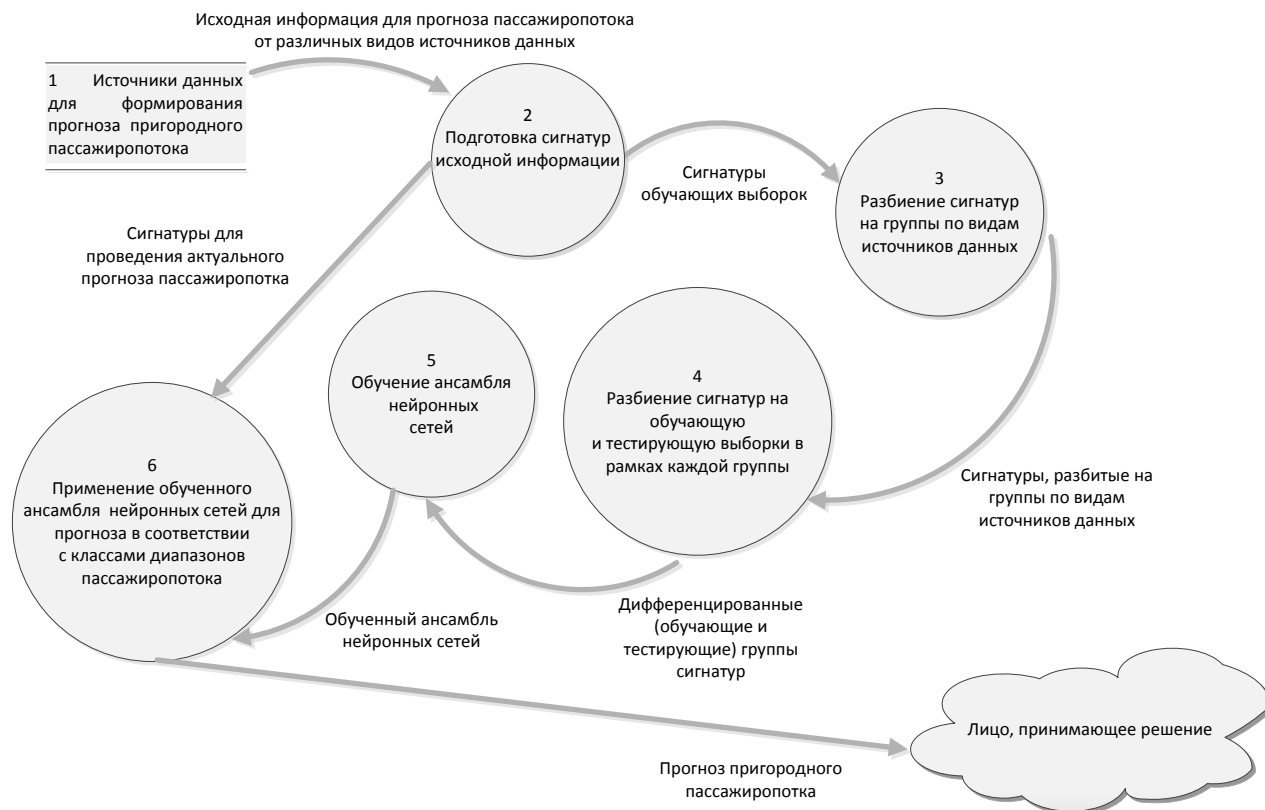


Рисунок 3 – Диаграмма потоков данных нейросетевой модели

При работе алгоритма вначале осуществляется распределение сигнатур от каждого источника данных на классы, которые соответствуют тому или иному диапазону пассажиропотока. Изображения сигнатур представляются в формате RGB, поэтому каждое изображение является трехмерной матрицей чисел (тензором), каждая страница которой отвечает за интенсивность пикселей соответствующего цвета задаваемой числами из диапазона от 0 до 255. Этот диапазон в программе нормируется к диапазону $[0, 1]$ для удобства дальнейшего применения нейронных сетей.

Пусть K_v – количество групп сигнатур (источников, от которых поступает информация), N_c – количество поддиапазонов (классов), на которые разбит возможный максимально ожидаемый пассажиропоток (верхний диапазон при этом может быть открытым).

Такой подход позволяет свести задачу прогнозирования к задаче классификации, которую выполняет нейронная сеть. Сигнатуры, соответствующие различным классам, помещаются в различные папки с названиями: `class_1`, `class_2`, ..., `class_Nc` (по количеству поддиапазонов). Внутри этих папок сигнатуры дополнительно дифференцируются по группам, так как разные источники информации получают различные структуры сигнатур. Дополнительно формируется папка `analiz` – папка для

анализируемых сигнатур, на основе которых будет формироваться текущий прогноз.

Отдельно рассмотрим задание интервала прогноза, так называемый временной лаг при формировании среднесрочного или краткосрочного прогноза. Для этого обучающая выборка формируется таким образом, что входные данные для нейронной сети (изображения с камер видеонаблюдения или визуализированные данные) берутся с отставанием от соответствующих выходных на заданную величину лага, которая определяется ЛПР (лицом, принимающим решение).

Вначале работы алгоритма необходимо задать несколько конфигурирующих сеть параметров. Одним из них является параметр `batch_size`, определяющий размер ограниченного прямоугольного фрагмента, к которому применяется операция свертки. Такой прием позволяет уменьшить размерность пространства одновременно подстраиваемых весов синапсов сети и ускорить процесс обучения. Другими параметрами являются $n \times m$, а также количество эпох обучения сети `nb_epoch`, которые также задаются вначале работы алгоритма и могут изменяться если допустимая ошибка обучения `eps_dor` оказывается меньше текущего значения ошибки `eps_train`.

В результате работы алгоритма для одной группы сигнатур формируется вектор \mathbf{r} размера $N_c \times 1$, каждый элемент которого характеризует принадлежность сигнатуры из папки `analiz` к тому или иному классу. Применение алгоритма для всех групп сигнатур позволяет сформировать матрицу $R = \{\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_{K_v}\}$:

$$R = \left(\begin{pmatrix} \mathbf{r}_{1,1} \\ \mathbf{r}_{2,1} \\ \dots \\ \mathbf{r}_{N_c,1} \end{pmatrix} \begin{pmatrix} \mathbf{r}_{1,2} \\ \mathbf{r}_{2,2} \\ \dots \\ \mathbf{r}_{N_c,2} \end{pmatrix} \dots \begin{pmatrix} \mathbf{r}_{1,K_v} \\ \mathbf{r}_{2,K_v} \\ \dots \\ \mathbf{r}_{N_c,K_v} \end{pmatrix} \right) = \begin{pmatrix} \mathbf{r}_{1,1} & \mathbf{r}_{1,2} & \dots & \mathbf{r}_{1,K_v} \\ \mathbf{r}_{2,1} & \mathbf{r}_{2,2} & \dots & \mathbf{r}_{2,K_v} \\ \dots & \dots & \dots & \dots \\ \mathbf{r}_{N_c,1} & \mathbf{r}_{N_c,2} & \dots & \mathbf{r}_{N_c,K_v} \end{pmatrix},$$

содержащую вектора \mathbf{r} для каждой группы сигнатур.

Экспертным путем задается степень значимости каждого источника данных с помощью набора весовых коэффициентов: $w = \{w_1, \dots, w_{K_v}\}^T$ при соблюдении условия:

$$\sum_{i=1}^{K_v} w_i = 1.$$

Найденная матрица R принадлежностей к классам умножается на вектор w по столбцам поэлементно, в результате получаем матрицу:

$$R_s = \begin{pmatrix} w_1 r_{1,1} & w_2 r_{1,2} & \dots & w_{K_v} r_{1,K_v} \\ w_1 r_{2,1} & w_2 r_{2,2} & \dots & w_{K_v} r_{2,K_v} \\ \dots & \dots & \dots & \dots \\ w_1 r_{N_c,1} & w_2 r_{N_c,2} & \dots & w_{K_v} r_{N_c,K_v} \end{pmatrix}.$$

На основе R_s проводится вычисление вектора Z , содержащего суммы элементов строк матрицы R_s :

$$Z = \left(\sum_{j=1}^{K_v} R_{s_{1,j}} \quad \sum_{j=1}^{K_v} R_{s_{2,j}} \quad \dots \quad \sum_{j=1}^{K_v} R_{s_{N_c,j}} \right)^T.$$

Далее применяется мажоритарный принцип, то есть находится номер строки с максимальным элементом вектора Z и принимается в качестве номера класса, который, соответственно, указывает прогнозируемый диапазон пассажиропотока. Структура алгоритма для одной группы сигнатур представлена на рисунке 4.

Учитывая, что исходный изображения с видеокamer или визуализированная информация может иметь различное разрешение по ширине и высоте, алгоритм предполагает предварительную нормировку размера изображений к некоторому одинаковому размеру $n \times m$, где n – количество пикселей по вертикали, m – по горизонтали.

В данной главе описана архитектура программной среды в которой осуществлялась реализация алгоритма. Разработка проводилась на языке Python 3.6 для операционной системы Linux (дистрибутив Linux, основанный на Ubuntu) в кроссплатформенной интерактивной среде Spyder устанавливаемой при установке сборки Anaconda. Для возможности работы с нейронными сетями был подключен бэкенд Keras, по умолчанию работающий с библиотекой машинного обучения Tensor Flow. Для ускорения процесса обучения CNN он был переведен на графическую видеокарту Nvidia с поддержкой технологии CUDA, которая совместно с Tensor Flow распараллеливает потоки вычислений, но пользователь этого не замечает и получает значительный выигрыш времени обучения.

Представлены результаты имитационного эксперимента по применению разработанных методов. В основу эксперимента положена идея имитации сигнала, поступающего с одного канала о количестве проданных билетов со статистическими характеристиками (математическим ожиданием и дисперсией), сходственным сигналу $s[t]$ от автоматизированной системы продажи билетов.

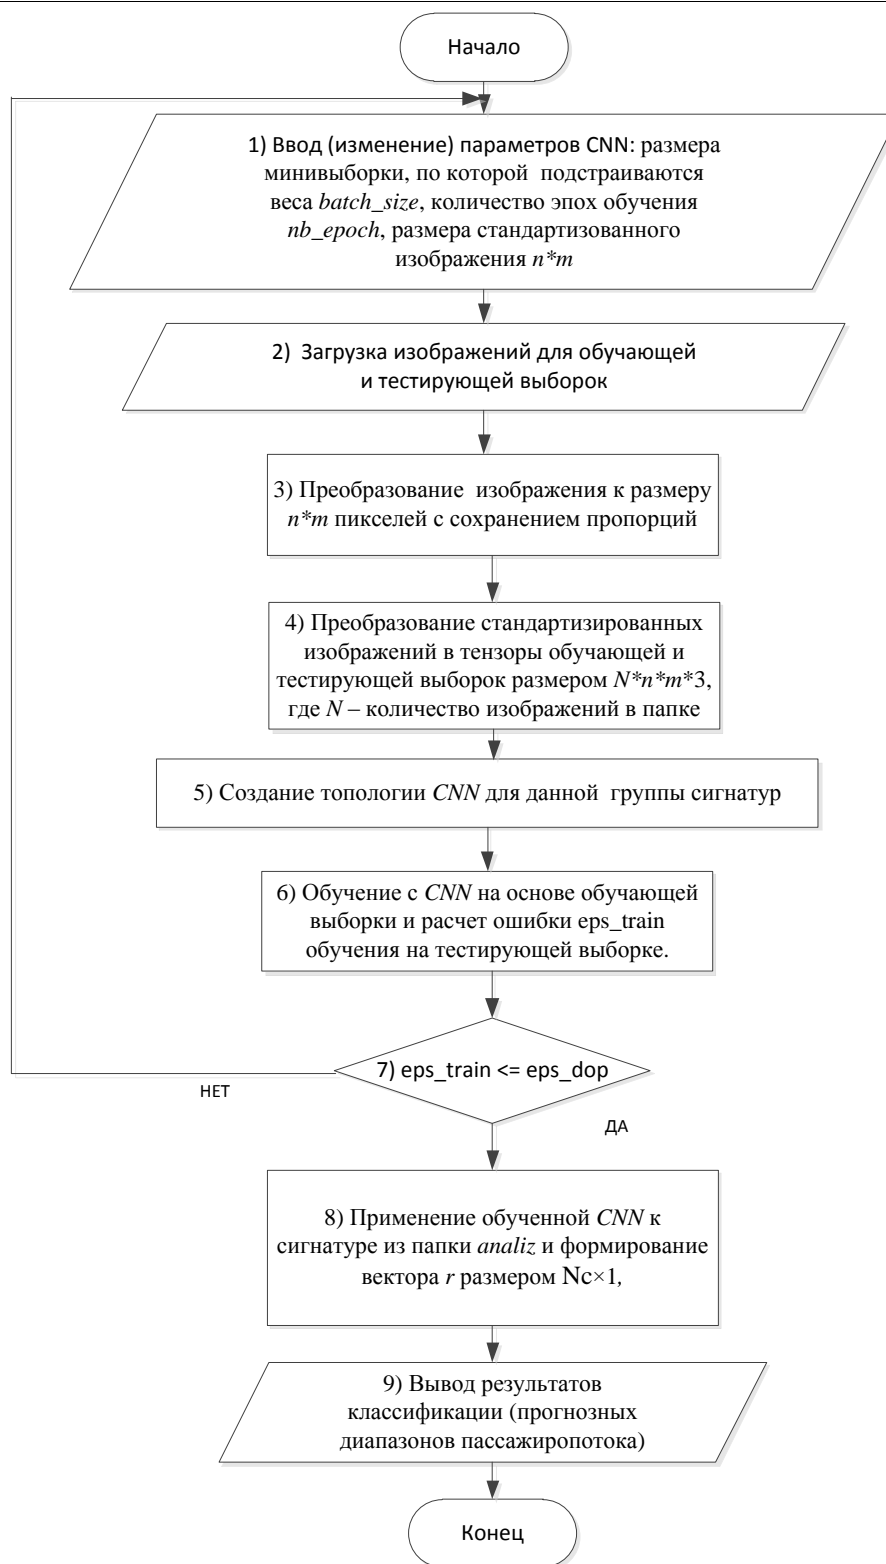


Рисунок 4 – Схема алгоритма обработки сигнатур одной группы

Выбранные количество классов и диапазоны пассажиропотока, соответствующие каждому классу представлены в таблице 1.

Таблица 1 – Структура таблицы соответствия класса диапазону прогноза пассажиропотока

| | | | | | |
|--|----------------|--------------|--------------|--------------|-------------|
| Диапазон пассажиропотока, количество человек | [1; 99] | [100; 299] | [300; 499] | [500; 699] | [700; 1000] |
| Нормированный диапазон | [0.001; 0.099] | [0.1; 0.299] | [0.3; 0.499] | [0.5; 0.699] | [0.7; 1.0] |
| Номер класса | 1 | 2 | 3 | 4 | 5 |

Сигнал $s[t]$ был смоделирован на 91 день и создавался наложением случайного шума на гармонический тренд, имитирующий сезонность пассажиропотока. Осуществлялся краткосрочный прогноз с $Nt=7$, $\Delta t=1$ день. Проблемой при использовании сверточных сетей является необходимость иметь большое количество данных в обучающей выборке. Однако, используя нормировку обучающей выборки по количеству проданных билетов, такую информацию можно достаточно быстро получить обрабатывая данные со всех направлений. Таким образом, входом сети будут являться указанные нормированные изображения для разных направлений, а выходом – номер класса.

Обязательным этапом выполнения классификации является оценка ее качества. Для этого применились метрики *precision* (точность) и *recall* (полнота):

$$\text{precision} = TP / (TP + FP), \quad \text{recall} = TP / (TP + FN),$$

где TP – TruePositive, определено как пассажиропоток относится к данному классу и он на самом деле к нему относится; TN – TrueNegative, определено как пассажиропоток не относится к данному классу и он на самом деле к нему не относится; FP – FalsePositive, определено как пассажиропоток относится к данному классу, но на самом деле он к нему не относится; FN – FalseNegative, определено как пассажиропоток не относится к данному классу, но на самом деле он к нему относится.

В данном эксперименте первый прогноз дается на 8 день продаж, а затем производится сдвигка на один день вперед. Это позволило последовательно получать прогноз на каждый оставшийся 84 день. Так как прогнозирование в данном контексте сводилось к задаче классификации, то выходом системы служил номер класса. Например, если было получено решение, что пассажиропоток относится ко второму классу, то это означает, что ожидаемый поток пассажиров предположительно будет находиться, как следует из таблицы 1, в диапазоне [100; 299].

Расчет метрик *precision* и *recall* удобно проводить на основе матрицы неточностей (*confusionmatrix*) [16]. Данная матрица заполняется в результате эксперимента и в рассматриваемом случае будет иметь сумму элементов, равную 84, что соответствует количеству прогнозов:

$$Q = \begin{pmatrix} 7 & 3 & 0 & 0 & 0 \\ 3 & 12 & 2 & 0 & 0 \\ 2 & 0 & 17 & 3 & 2 \\ 0 & 0 & 3 & 19 & 3 \\ 0 & 0 & 1 & 1 & 6 \end{pmatrix}.$$

В матрице Q количество строк и столбцов соответствует числу классов – в данном случае пять (см. таблицу 1). Столбцы отражают истинные классы пассажиропотока, полученные после наступления прогнозируемого момента. Строки характеризуют результат прогноза по предложенному методу. При анализе результатов работы прогнозирующего алгоритма инкрементируется число, стоящее на пересечении строки класса который вернул классификатор и столбца класса, к которому действительно относится пассажиропоток. Результирующие метрики *precision* и *recall* классификатора рассчитываются как среднее арифметическое соответствующей метрики по каждому классу:

$$precision = \frac{1}{5} \sum_{i=1}^5 \frac{Q_{i,i}}{\sum_{j=1}^5 Q_{i,j}}, \quad recall = \frac{1}{5} \sum_{j=1}^5 \frac{Q_{j,j}}{\sum_{i=1}^5 Q_{i,j}}.$$

На основании матрицы Q в данном случае рассчитываем $precision=0,73$, $recall=0,70$, что свидетельствует о хорошем качестве классификации, так как указанные параметры не опускаются ниже 70 %.

Выводы: проведенное исследование позволило решить актуальную научную задачу разработки и обоснования новых экономико-математических инструментов для поддержки принятия решений по управлению предприятием железнодорожного пригородного сообщения на основе применения глубоких искусственных нейронных сетей для прогнозирования пассажирского потока.

Решенная научная задача имеет существенное значение для развития теории и практики планирования загрузки подвижного состава пригородного сообщения и информационного обеспечения управленческой деятельности в рамках единой ERP-системы железнодорожного предприятия.

В данной работе представлены и обоснованы следующие новые инструменты: структура модели прогноза пассажиропотока пригородного железнодорожного сообщения на основе глубоких нейронных сетей; архитектура системы машинного обучения, применяемая в рамках предложенной модели прогноза; методы формирования обучающих выборок для глубоких нейронных сетей при проведении краткосрочных и среднесрочных прогнозов пригородного пассажиропотока; алгоритм программного обеспечения реализующего предложенную модель прогнозирования.

Практическое использование разработанной модели позволило обеспечить качество прогноза пассажиропотока на уровне выше 70% и сократить издержки связанные с обеспечением пригородного сообщения Смоленской области.

Библиографический список

1. Федеральный закон "О железнодорожном транспорте в Российской Федерации" от 10.01.2003 N 17-ФЗ (последняя редакция) "// Официальный сайт компании «КонсультантПлюс» URL: http://www.consultant.ru/document/cons_doc_LAW_40443/
2. Киреевкова М.С., Пучков А.Ю., Лобанева Е.И. Экономико-математическая нейросетевая модель для прогнозирования пассажиропотока железнодорожного пригородного сообщения // Транспортное дело России. 2018. № 4.С. 96-101.
3. Тюкаев Д.А., Пучков А.Ю., Киреевкова М.С. Алгоритм классификации сигнатур в экономико-математической модели прогнозирования пригородного пассажиропотока на основе нейронных сетей // Транспортное дело России. 2018. № 4.С.108-112.
4. Битюцкая А.С., Киреевкова М.С. Нейросетевая модель прогнозирования пассажиропотока железнодорожного пригородного сообщения // Сборник научных трудов по материалам VIII международной научно-технической конференции «Энергетика, информатика, инновации - 2018», Смоленск: филиал МЭИ в г. Смоленске, 2018.