

## УПРАВЛЕНИЕ ЗАПАСАМИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

СТУПАК А.А.

«Южно-Уральский государственный университет (Национальный исследовательский университет)», Челябинск, Россия

**Аннотация.** В статье исследуется вопрос оптимизации управления запасами через минимизацию затрат на них на крупных торговых предприятиях с широким номенклатурным рядом за счёт прогнозирования данных нейронными сетями. Основная задача данной статьи – выявить проблемы системы управления запасами в ходе анализа структуры и составляющих затрат на запасы, а также сравнить прогнозные и плановые показатели по заданным параметрам и предложить рекомендации по оптимизации системы управления запасами. Новизна заключается в анализе и доработке новых методов системы управления запасами с использованием инновационных технологий по прогнозированию данных. В статье представлены рекомендации по использованию разработанной системы прогнозирования, а также алгоритм принятия решений, основанный на итоговых показателях прогноза, аргументирующие целесообразность использования рекомендованных нововведений.

**Ключевые слова:** управление товарными запасами, оптимизация, минимизация издержек, нейронные сети, прогнозирование данных, логистика.

### Введение

Актуальность исследования. В процессе развития, а также по мере изменения экономических условий все предприятия сталкиваются с необходимостью совершенствования своих экономических структур. При этом предприятия преследуют две основные цели: повысить эффективность использования внутренних ресурсов и адаптироваться к новым внешним условиям. Одной из проблем достижения этих целей является задача повышения эффективности управления цепями поставок. Управленческая концепция и организационная стратегия цепей поставок заключается в интегрированном подходе к планированию и управлению всеми потоками информации о сырье, материалах, товарах, услугах, возникающих и преобразующихся в логистических процессах предприятия. Колоссальный объем средств, вкладываемых в товарные запасы, придает проблеме управления ими первостепенную важность, исходя из чего, данный элемент управления цепями поставок и был выбран

для детального анализа и оптимизации посредством прогнозирования. Целью данного исследования является повышение эффективности управления цепями поставок благодаря анализу и прогнозируемости состояния товарных запасов с использованием алгоритмов обучения нейронных сетей.

### Устройство нейронных сетей

Для понимания возможностей нейронных сетей и формирования исходных данных для анализа необходимо иметь представление об их начальном устройстве. Искусственные нейронные сети представляют собой математическую модель, построенную на основе принципов работы бионических нейросетей. Самыми распространёнными применениями нейронных сетей являются классификация, распознавание и прогнозирование, нас будет интересовать именно последний вариант. На рисунке 1 изображён нейрон, из которых и состоит ИНС. Рассмотрим его структуру и окружение.




Рис. 1. Модель искусственного нейрона

Нейронной сети предоставляется входящая информация для анализа и эталонные данные для самопроверки. На изображении мы видим нейроны входного слоя (X) – каналы, через которые наш основной нейрон получает изначальную информацию для анализа. Связи между нейронами (синапсы) обладают определённым весом для следующего нейрона (обозначены  $w$ ), в соответствии с ним нейрон придаёт ту или иную важность поступившему по синапсу сигналу. Изначально они задаются случайным образом. При поступлении входящей информации нейрон суммирует все сигналы в долях, соответствующих их весам (функция  $S$ ), а затем обрабатывает полученную информацию в соответствии с выбранной функцией активации (функция  $Y$ ) и передаёт дальше, затем полученные ответы сеть сравнивает с эталонными данными и в зависимости от размера и качества ошибки корректирует веса синапсов, таким образом сеть обучается на своих ошибках. Обучение длится до тех пор, пока не будет достигнут обозначенный минимум ошибки или не пройдёт заданное количество итераций (сессий обучения). По итогу обучения нейрон передаёт окончательные результаты на выходной слой (Y) через аксон. Выбор активационной функции определяется спецификой поставленной задачи либо ограничениями, накладываемыми некоторыми алгоритмами обучения: самыми распространёнными являются жесткая пороговая функция, линейный

порог, сигмоидальная функция. Для решения нашей задачи подходит именно сигмоида, так как она предоставляет более детальную картину прогноза на выходе. Для того, чтоб сеть адекватно воспринимала обучающую выборку (не было таких сильных числовых разрывов как от 1 до 10000), перед обучением выборку нормализуют: классический способ нормализации – деление единицы на каждое значение выборки.

#### Параметры для построения сети

Исходя из поставленной в исследовании задачи, видов и классификаций нейронных сетей, для построения собственной ИНС были выбраны следующие параметры конфигурации. Важно отметить, что данные рекомендации и особенности обучающей выборки требуют написания собственного программного кода нейронной сети, так как рассматриваемые примеры ориентированы на крупные торговые компании с широким номенклатурным рядом и требуют разработки сложной системы идентификаторов входящей информации и дальнейшей адекватной обработки данных:

Многослойная сеть прямого распространения (Перцептрон Румельхарта)

2 скрытых слоя нейронов

Связи между нейронами внутренних слоёв полноценны

Алгоритм обучения – Backpropagation (Метод обратного распространения ошибки)

Функция активации внутренних слоёв – сигмоидальная

Интервал установки весов – (-0,5;+0,5)  
 Размер валидации – 95/5 (деление выборки на обучающую и тестовую)  
 Размер допустимой ошибки – 0,05%  
 Шаг обучения – 0,01

Данные параметры выявлены для сети посредством изучения опытов и работ множества учёных, но полноценное обоснование их возможно лишь в процессе реализации, так как нейронные сети по сей день являются экспериментальным способом анализа данных. Такой параметр как количество итераций будет зависеть от момента достижения сети требуемого минимума ошибки и может быть выявлен лишь экспериментальным методом. Количество нейронов в каждом слое варьируется в зависимости от объёма обучающей выборки и поведения сети в ходе обучения и также может быть определено лишь в ходе эксперимента.

### Алгоритм обратного распространения ошибки (Backpropagation)

Для более детального понимания работы сети, рассмотрим действие выбранного алгоритма. В конфигурации сети мы приняли решение использовать 2 скрытых слоя, на примере рассмотрим лишь один для облегчения визуализации, ведь метод функционирования скрытых слоёв будет абсолютно идентичен. Функция активации в алгоритме обратного распространения ошибки должна обладать несколькими важными характеристиками: непрерывностью, дифференцируемостью и являться монотонно неубывающей. Таким образом, нам полностью подходит сигмоидальная функция с областью значений в интервале (0;1). Сначала происходит инициализация весов случайным образом в указанном ранее интервале. До тех пор пока сеть не достигнет требуемого минимума ошибки, выполняются шаги с 1 по 5 (рис.2).




Рис. 2. Алгоритм Backpropagation

Шаг 1. Каждый входной нейрон ( $X_i$ ) отправляет полученный сигнал  $X_i$  всем нейронам в следующем скрытом слое.

Шаг 2. Каждый скрытый нейрон ( $Z_j$ ) суммирует взвешенные входящие сигналы и применяет активационную функцию, после чего посылает результат всем элементам следующего слоя (выходного).

Шаг 3. Каждый выходной нейрон ( $Y_k$ ) также суммирует и применяет активационную функцию.

Далее идёт обратное распространение ошибки:

Шаг 4. Каждый выходной нейрон ( $Y_k$ ) сравнивает полученное после активации значение с эталонным ( $T_k$ ) и вычисляет ошибку (формула на слайде), а также вычисляет величину, на которую изменится вес связи  $W$ , и посылает ошибку нейронам в предыдущем слое. Изменение веса равно полученной ошибке умноженной на шаг обучения и на размер входящего ранее сигнала от  $Z$ .

Шаг 5. Каждый скрытый нейрон ( $Z_j$ ) суммирует входящие ошибки (от нейронов в последующем слое) и вычисляет свою величину ошибки и также вычисляет величину,

на которую изменится вес связи  $V$  аналогичным с  $W$  образом.

Далее происходит изменение весов в соответствии с вычисленными коэффициентами. Каждый выходной нейрон ( $Y..$ ) и скрытый нейрон ( $Z..$ ) изменяют веса своих связей с предыдущими нейронами: (старый вес  $W +$  вычисленное изменение). Условием прекращения работы алгоритма в нашем случае является достижение суммарной ошибки, значение которой равно  $5/10000$ , соответственно, сеть обучится тогда, когда будет достигнута данная цифра. Далее сеть проходит проверку на тестовой выборке, если размер ошибки подтверждается, сеть готова к прогнозу, если нет, процесс повторяется.

#### Подбор входящей выборки

Выведенный способ использования нейронной сети будет реализован на множествах данных следующего типа:

множество данных по затратам от доходов запаса;

множество данных по затратам от расходов запаса;

множество данных по затратам на хранение запасов;

множество данных по затратам от прослеживания (устаревания) запасов;

множество данных по затратам на вынужденное (внеплановое) пополнение запасов.

#### Пример.

Данные отгрузок товарных запасов определяются множеством:

$$O = \{R, S, V, t_1, t_2, type, C, Z\}, (1)$$

где  $R$  – отгружаемый товар;

$S$  – с какого склада;

$V$  – в каком количестве;

$t_1$  – время начала отгрузки;

$t_2$  – время окончания отгрузки;

$type$  – тип плана отгрузки;

$C$  – стоимость отгружаемого товара;

$Z$  – затраты, связанные с отгрузкой.

Логика выбора множества, оказывающего влияние на затраты проста, ведь оптимизация запасов прежде всего осуществляется минимизацией затрат на них. Данные множества содержат как информацию о факти-

ческом уровне затрат, так и структуру этих самых затрат, что в итоге анализа сети даст возможность понять не только какие именно виды затрат являются наиболее убыточными, но и какие именно структурные элементы имеют на это влияние, например, не оптимальное время отгрузки или объём отгружаемого товара могут приводить к существенному увеличению затрат, что не всегда возможно выявить, используя классические статистические методы анализа.

#### Обучение и прогноз сети

Таким образом, мы выбрали способ обучения сети и входящую выборку. Опишем в общих чертах, как именно будет происходить процесс запуска обучения и получения прогнозных данных. Для наглядности используем интерфейс одного пакетного решения для построения нейросетей, хотя, напомним, что данные методики разработаны для сети самописного вида.

На рис. 3 в левом нижнем углу указаны фактические данные за прошлый период, в правом нижнем углу – нынешние фактические данные. Анализируя и сопоставляя представленные данные, сеть и будет обучаться. Данные процессы будут проходить для каждого вида товара за определённый промежуток времени по каждому виду затрат.

Какой именно период брать для обучения сети и прогноза сугубо индивидуально для каждого предприятия, но рекомендуется либо использовать краткосрочное прогнозирование (неделя с неделей), так как это позволяет минимизировать влияние внешних факторов на прогноз, либо сравнивать год с годом, как это произведено на примере для минимизации, например, сезонных колебаний.

После обучения сеть готова к прогнозированию. На рис. 4 видно, как в левое верхнее поле вносятся данные на текущий период, а в правом верхнем поле формируется прогноз на будущий период. После прогноза по всем 5 пунктам

множество результаты интегрируются для формирования картины, идентичной планируемым затратам на запасы. В правом нижнем поле внесены данные по планируемым затратам на запасы. Исхо-

дя из сравнения их с прогнозными данными, формируются графики в левом нижнем поле, по которым можно выявить несоответствия планируемых затрат прогнозным.

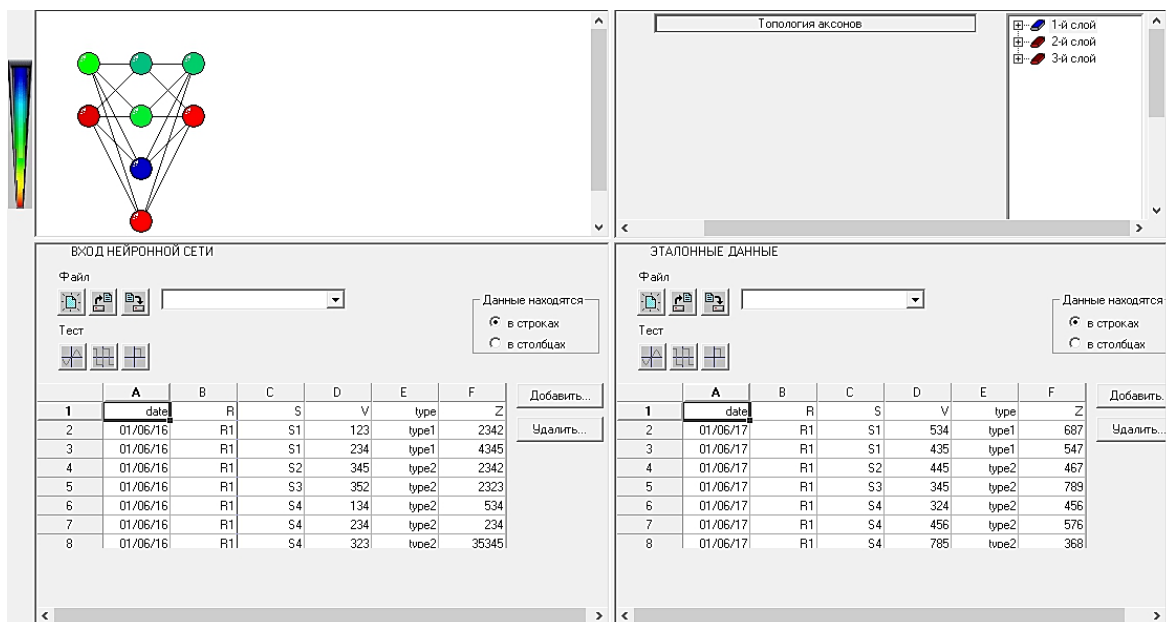


Рис. 3. Обучение нейронной сети

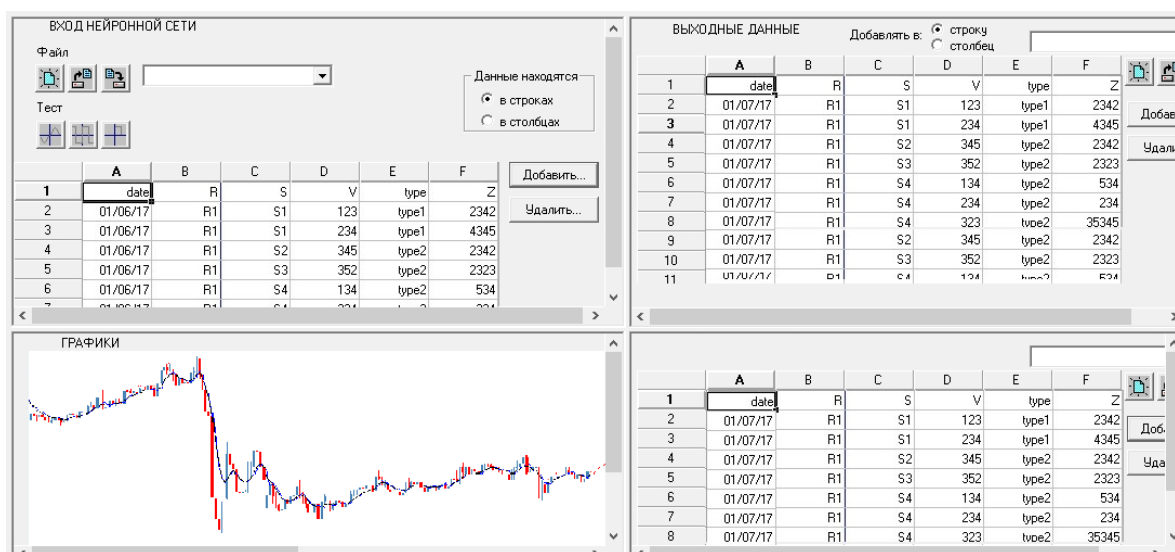


Рис. 4. Прогноз нейронной сети

По данным графикам можно выявить, в какой именно точке произошло критичное отклонение как это показано на рис. 5. При детализации точки отклонения будут отображаться множества по затратам с пометкой самого критичного значения (рис. 6). Далее мы имеем возможность просмотреть структуру и составляющие затрат на запасы (рис.

7). В примере на критичным является отклонение затрат на отгрузку типа type2 по товару R<sub>1</sub> на складе S<sub>2</sub>, а за счёт наглядной структуры точки отклонения его можно проанализировать и оптимизировать. Предположим, некоторые из данных отгрузок можно было совместить, учитывая, что тип параметра отгрузки идентичен.




Рис. 5. График прогнозных и планируемых затрат на запасы

Затраты на отгрузку Июль/2017				
R	S	type	V	Z
R1	S1	type1	12	233
R1	S2	type2	40	456
R1	S3	type1	15	301

Рис. 6. Пример затрат на отгрузку в точке отклонения

R1 S2 type2	Затраты на отгрузку Июль/2017				
	V	Z	t1	t2	C
01.07.2017	10	120	15:20	16:01	360
15.07.2017	17	235	13:30	14:05	612
17.07.2017	3	101	11:42	12:05	108
20.07.2017	10	96	10:15	11:10	360

Рис. 7. Пример детализации структуры затрат на отгрузку

### Алгоритм управления запасом и пути решения итоговых задач регулирования

Из предложенного метода оптимизации затрат на запасы складывается алгоритм управления запасами (рис. 8), по которому в начале сеть прогнозирует и сравнивает полученные значения с плановыми, а затем ЛПР по детальным данным принимает решение о способе оптимизации запасов. После некоторого количества итераций и адаптации сети под особенности конкретного предприятия, она сможет сама прогнозировать будущий запас без вмешательства ЛПР. Можно будет лишь при необходимости задавать ей дополнительные вводные, которые могут влиять на уровень запаса (внешняя эконом. ситуация, сезонность, «мода» на те или иные товары, покупательская способность конечного потребителя и т.д.).

В таблице 1 представлены причины и пути решения задач, которые стоят перед ЛПР по итогам произведённых работ. Товарные запасы позволяют сгладить колебания спроса, снизить риски при работе с контрагентами. Низкий товарный запас порождает дефицит товара и негативно сказывается на сервисе и лояльности покупателей. Большой товарный запас влечет за собой залежалый товар, срок годности которого постепенно истекает, или спрос на который падает из-за изменения модных тенденций, что увеличивает издержки на его хранение. Используя средства прогнозирования, можно решить данную задачу и найти оптимальный запас на конкретный период.



**Рис. 8. Алгоритм управления запасом на основе анализа прогноза затрат**

**Таблица 1. Пути решения итоговых задач регулирования**

Показатель	Причины	Пути решения
Изменение затрат на поставку	Изменился план поставок или нормы расчета поставок	Проведение оптимизации поставок
Изменение затрат на отгрузку	Изменился план отгрузки или нормы расчета отгрузок	Проведение оптимизации отгрузки
Изменение затрат на хранение	Изменился либо план поставок, либо план отгрузок, либо изменились нормы расчета затрат на хранение	Провести оптимизацию поступлений, затем провести оптимизацию хранения
Возросли затраты в результате пролеживания запасов	Изменилось время пролеживания запасов или объем вложенных в запасы средств в результате изменения планов закупки или планов отгрузок (может измениться ставка расчета затрат)	Оптимизировать поступление товаров, затем оптимизировать хранение запасов
Увеличение объема морально и физически устаревших запасов	Слишком большой объем закупок или уменьшившийся объем запланированных отгрузок	Проведение оптимизации закупок, проведение оптимизации хранения
Увеличение уровня внепланового пополнения товаров	Уменьшение плана поставок или увеличение объема планируемого отпуска товаров	Оптимизация поступлений, оптимизация отпуска
Изменение структуры затрат	Один элементов затрат претерпел изменения	Необходимо более детально проанализировать изменения в структуре затрат
Изменение уровня затрат	Общая тенденция затрат изменилась	Необходимо более детально проанализировать изменения в структуре затрат
Степень показателя критичности повысилась	Прогнозируется сильные нехватка или переизбыток запаса в один из критических периодов	Необходимо проанализировать планы поставок и провести оптимизацию поставок, затем провести оптимизацию отгрузок

### **Заключение**

Таким образом статье представлена композиционная модель расчета затрат, как целевая функция оптимизации системы управления товарными запасами, а также разработана модель объекта управления и выявлены наиболее значимые, с точки зрения повышения эффективности, процессы принятия решений в системе управления товарными запасами. Предложены наиболее

оптимальные параметры обработки данных нейронной сетью для прогнозирования затрат на товарные запасы посредством обучения на имеющихся учётных данных предприятия. Предложен алгоритм принятия решений в процессах управления поступлением, хранением и выбытием товарных запасов, основанный на итоговых прогнозах затрат.

### **Литература:**

1. Хайкин, С. Нейронные сети. Полный курс – 2-е изд., М.:Вильямс, 2006. – 114 с.
2. Armstrong, J. S. Long-range Forecasting: From Crystal Ball to Computer. – Wiley, 1978. – p. 2
3. Cybenko, G. Approximation by superpositions of a sigmoid function. – Mathematics of Control, Signals and Systems, vol. 2, 1989. – p. 303-314
4. Hyndman, Rob J. Another look at measures of forecast accuracy/ Hyndman Rob J., Koehler Anne B. International Journal of Forecasting, 2006. – p. 679–688

**Ступак Анастасия Александровна** – студент кафедры «Экономика и управление на предприятиях строительства и землеустройства», Южно-Уральский государственный университет (НИУ), г. Челябинск Россия.

Дата поступления 1 июня 2017 г.

DOI: 10.14529/iimj170216

## **INVENTORY MANAGEMENT USING NEURAL NETWORKS**

**STUPAK A.A.**

“South Ural State University (National Research University)”, Chelyabinsk, Russia

**Abstract** The article explores the issue of optimization of inventory management by minimizing the costs for them at large trading companies with a wide range of nomenclature due to the neural network data prondonization. The main task of this article is to identify the problems of the inventory management system during the analysis of the structure and component costs for inventories, and also to compare the forecast and planned indicators with the given parameters and propose recommendations for optimizing the inventory management system. The novelty consists in analyzing and finalizing new methods of the inventory management system using innovative technologies for forecasting data. The article presents recommendations on the use of the developed forecasting system, as well as the decision-making algorithm based on the final forecast indicators, argument the expediency of using the recommended innovations.

**Keywords:** inventory management, optimization, minimization of costs, neural networks, forecasting of data, logistics.

### **References**

1. Armstrong J. S. Long-range Forecasting: From Crystal Ball to Computer. – Wiley, 1978. – p. 2



- 
2. Cybenko G. Approximation by superpositions of a sigmoid function. – Mathematics of Control, Signals and Systems, vol. 2, 1989. – p. 303-314
  3. Hyndman Rob J., Koehler Anne B. Another look at measures of forecast accuracy. – International Journal of Forecasting, 2006. – p. 679–688
  4. Khaikin S. Neural networks. Full course - 2 ed., M.: Williams, 2006. - 114 p.

**Stupak Anastasia** – graduate student of the Department “Economics and management in construction and land development”, “South Ural State University (National Research University)”, Chelyabinsk, Russia.

**Received 1 June 2017**

---

**ОБРАЗЕЦ ЦИТИРОВАНИЯ**

Ступак А.А. Управление запасами с использованием нейронных сетей / А.А. Ступак // . – 2017. – №2. Стр. 92 – 100.  
DOI: 10.14529/iimj170216.

**FOR CITATION**

Stupak A.A. Inventory management using neural networks. *Investment and innovation management journal*. – 2017. – No. 2. Pp. 92 – 100.  
DOI: 10.14529/iimj170216.

---