

УДК 355.01:004.056

А.А. Перцев, А.Н. Подобрый, Ю.А. Радионова

ПОДХОД К ПЛАНИРОВАНИЮ РЕСУРСОВ ПРОИЗВОДСТВА МАШИНОСТРОИТЕЛЬНОГО ПРЕДПРИЯТИЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Перцев Андрей Алексеевич, кандидат технических наук, окончил механико-математический факультет Ульяновского государственного университета. Начальник отдела ФНПЦ АО «НПО «Марс». Имеет статьи в области внедрения автоматизированной системы управления предприятием. [e-mail: mars@mv.ru].

Подобрый Александр Николаевич, кандидат технических наук, окончил механико-математический факультет УлГУ. Заместитель начальника отдела ФНПЦ АО «НПО «Марс». Имеет статьи в области внедрения автоматизированной системы управления предприятием. [e-mail: mars@mv.ru].

Радионова Юлия Александровна, кандидат технических наук, окончила механико-математический факультет УлГУ. Ведущий инженер-программист ФНПЦ АО «НПО «Марс». Имеет публикации в сфере автоматизированных систем документооборота, интеллектуальной организации хранилищ технической документации, статистической оценки поставщиков. Сфера научных интересов: электронный документооборот, архивохранилища, статистический анализ данных, системы поддержки принятия решений. [e-mail: julia-owl@mail.ru].

Аннотация

При проведении предварительных оценок возможности изготовления технических средств (ТС), как правило, используется опыт работников предприятия: производственников, экономистов, конструкторов и т. д. Для предварительной оценки достаточно понимать сложность изготовления изделия и наличие аналогов. В то же время точный расчет длительности изготовления изделия не всегда возможен из-за отсутствия полного набора конструкторской и технологической документации.

В статье представлен подход к расчету длительности изготовления (ТС) с использованием нейронных сетей (НС) на основании существующих данных за предыдущие периоды и о видах ТС. Данный подход позволяет проводить оценки длительности изготовления без использования точных данных о конструктиве и технологии изготовления ТС.

Описана структура НС, определена обучающая выборка, и на основании данных из выборки были проведены эксперименты для определения начальных весовых коэффициентов НС. Программная реализация выполнена в виде дополнительного модуля для интерактивного веб-ресурса и использует T-SQL.

Ключевые слова: формирование плана производства, нейронная сеть, мелкосерийное производство, проектное производство, машиностроение, мощность производства, статистика выполнения операций.

doi: 10.35752/1991-2927-2021-2-64-46-55

AN APPROACH TO PLAN THE PRODUCTION RESOURCES OF A MACHINE-BUILDING ENTERPRISE USING NEURAL NETWORKS

Andrei Alekseevich Pertsev, Candidate of Sciences in Engineering; graduated from the Faculty of Mechanics and Mathematics of Ulyanovsk State University; Head of a department of FRPC JSC 'RPA 'Mars'; an author of articles in the field of the automated enterprise management system implementation. e-mail: mars@mv.ru.

Aleksandr Nikolaevich Podobrii, Candidate of Sciences in Engineering; graduated from the Faculty of Mechanics and Mathematics of Ulyanovsk State University; Deputy Chief of a department of FRPC JSC 'RPA 'Mars'; an author of articles in the field of the automated enterprise management system implementation. e-mail: mars@mv.ru.

Iuliia Aleksandrovna Radionova, Candidate of Sciences in Engineering; graduated from the Faculty of Mechanics and Mathematics of Ulyanovsk State University; Leading Software Engineer at FRPC JSC 'RPA 'Mars'; an author of articles in the field of automated workflow systems, intelligent technical documentation storage bases and systems for statistical analysis of supplier appraisal; research interests are in the field

of electronic document management, archival depositories, statistical data analysis, decision support systems.
e-mail: julia-owl@mail.ru.

Abstract

Generally, this is the experience of production workers, economists, designers, etc. that used to get a preliminary assessment of feasibility of hardware manufacturing at an enterprise. For a preliminary assessment, it is enough to understand the complexity of the product and available analogues. At the same time, it is not always possible to calculate an accurate production time for the product due to the lack of a complete set of design and technological documentation.

The article presents an approach to calculating the production time of hardware using neural networks based on existing data for previous periods and types of hardware using. This approach allows estimating the production time without using accurate data on the design and manufacturing technology.

The article also describes the structure of neural networks and defines the training sample. Some experiments were conducted based on the sample data, which allowed determining the initial weight coefficients of the neural network. The software implementation is made in the form of an additional module for an interactive web resource and uses T-SQL.

Keywords: production plan formation, neural network, small-scale manufacturing, project manufacturing, mechanical engineering, production capacity, operation performance statistics.

ВВЕДЕНИЕ

Основной задачей предварительной оценки исполнения заказа с существующими производственными мощностями является определение длительности выполнения работ, т. е. составление прогноза выполнения всего набора производственных заданий в конкретный временной промежуток. Предварительная оценка может использоваться на разных этапах: на этапе договорной работы, на этапе модернизации производственных мощностей и т. д.

Целью планирования является максимальное сокращение сроков подготовки и освоения производства новых изделий при наименьших затратах трудовых, материальных и финансовых ресурсов. Данный вид планирования называется оперативно-производственным и должен выполнять следующие функции [1]:

- объёмные расчёты по предприятию и производственным подразделениям;
- расчёты календарно-плановых нормативов организации производственного процесса;
- разработка календарных графиков запуска-выпуска изделий;
- формирование оперативных производственных заданий подразделениям предприятия;
- оперативное регулирование, учёт и контроль выполнения плановых заданий.

Оперативно-производственное планирование можно разделить на три этапа [2]:

1. Планирование на уровне предприятия, заключается в распределении выпуска продукции по календарным срокам (месяцам планируемого года, а при позаказной системе – по номерам недель). На этом этапе достигается такое распределение продукции, при котором могут быть получены, с одной стороны, наилучшие финансовые результаты, а с другой — равномерная продолжительность циклов сборки. Для достижения этих целей используются: номенклатура изделий, их цена и рента-

бельность, трудоёмкость и станкоёмкость. Полученный таким образом объёмный план производства служит основой для разработки новых планов. На основе календарно-плановых нормативов (партий запуска, циклов и опережений) составляются производственные планы каждому цеху. В планах указываются не только модели и количество изделий, но и номера изделий, планируемых к выпуску. На основе разработанного объёмного плана производства определяются необходимые ресурсы для его выполнения (потребности в материалах, комплектующих, трудовых ресурсах и денежных средствах).

2. Планирование на межцеховом уровне заключается в том, чтобы объёмные цеховые планы превратить в поддетальные. На основе календарно-плановых нормативов, спецификаций и расцеховочных ведомостей изделия расписываются по деталям. Составляется поддетальный план запуска-выпуска деталей с указанием их номеров, количества в партиях, сроков их запуска и номеров выпускаемых изделий, которые ими будут укомплектованы.

3. Внутрецеховое планирование. На этом этапе поддетальный план запуска-выпуска превращается в плановые задания на смену на каждое рабочее место (сменные задания). Этот этап условно называют ещё и оперативным планированием, поскольку именно на этом этапе вскрываются и оперативно устраняются все недостатки предыдущего планирования. Работу по планированию выполняют цеховые специалисты. Они составляют ежедневно на следующую смену для каждого рабочего сменные задания на основе следующих данных: сведений о наличии заготовок на складе, плана запуска-выпуска деталей, маршрутных карт и норм времени, партий запуска. При этом проверяется готовность производства к выполнению задания: наличие заготовок, состояние оборудования, наличие документации, оснастки, инструмента. При необходимости принимаются меры. Если устранить недостатки за период подготовки не удаётся, к производству планируются другие

детали. После выполнения рабочим сменного задания детали или изделия предъявляются контролёру. В сменном задании делается отметка о количестве фактически изготовленных изделий или деталей.

При планировании на уровне предприятия оценка длительности изготовления выпуска дополнительных заказов при существующем уровне производственных мощностей без срывов позволяет расширять выпускаемую продукцию – как следствие, улучшение всех экономических показателей.

Невыполнение плана по объему и номенклатуре приводит к срыву поставок. За этим следует не только снижение текущих показателей выручки, прибыли, рентабельности, но и ухудшение конкурентного статуса предприятия, в результате чего уменьшается выручка и прибыль будущих периодов [3].

На предприятиях единичного и мелкосерийного типов производства, выпускающих сложную продукцию с длительным производственным циклом, существует тесная зависимость между его величиной и сроками кредиторской задолженности (авансовые платежи, как правило, «привязаны» к срокам окончания определенных этапов работы). Таким образом, сокращается не только цикл выполнения работ, но и продолжительность использования краткосрочных пассивов [3].

Существующие методики оценки производственных возможностей предприятия и оперативно-производственного планирования оперируют следующими критериями [4]:

- количество и виды оборудования;
- численность и квалификация персонала;
- бюджет рабочего времени.

В статье [5] для решения задач оперативно-производственного планирования рассматриваются два варианта информационных технологий планирования:

1) внедрение MRP II (Material Requirement Planning – Планирование материальных ресурсов) и CRM (Customer Relationship Management – Управление взаимоотношениями с клиентами) совместно;

2) внедрение ERP (Enterprise Resource Planning System – Система планирования ресурсов предприятия).

В работах [6–8] даны различные подходы к моделированию структуры и событий изготовления изделия в связи с системой планирования и типами производства.

Общемировой тенденцией является использованием методов машинного обучения для решения прикладных задач концептуального планирования во всевозможных проектах: строительства зданий, реконструкции автомобильных дорог, судостроении, разработки программного обеспечения и других областях. В работе [9] представлено использование нейронной сети (НС) для планирования работ в судостроении на основании движения данных, кластеризации данных и выявления аномалий в работе критического оборудования. В работе [10] НС используется при симуляции данных для оборудования и позволяет существенно сократить время нахождения отношений во входящих и исходящих данных. Отдельно следует отметить исполь-

зование НС для решения задач планирования потоков работ на уровне цеха. В работах [11–14] представлены различные подходы построения и использования НС для решения задач планирования потоков работ. В целом, представленные исследования позволяют сделать вывод, что внедрение методов машинного обучения в существующие системы планирования и прогнозирования несет выгоды и является перспективным направлением для исследования.

Сбор информации и проведение расчетов – трудоемкий процесс, который требует хорошей квалификации специалистов по производственному планированию, т. к. большинство методик сводится к решению сложной системы линейных уравнений с многими неизвестными. В то же время всегда существует набор данных о том, как выполнялись производственные задачи в предыдущие периоды, что позволяет использовать для проведения оценки и расчетов производственных мощностей НС.

1 ОСНОВНЫЕ ПОНЯТИЯ И СТРУКТУРА НС

В настоящее время выделяют два основных типа НС: обучение которых ведется с использованием обучающей выборки и без использования таковой. Второй тип НС применяется, в основном, в задачах кластеризации на некотором неупорядоченном множестве значений. Первый тип НС широко применяется в задачах распознавания, классификации и прогнозирования с использованием массива статистических данных [15].

Наиболее широко применяемым алгоритмом для обучения НС с обучающей выборкой является алгоритм обратного распространения ошибки, представляющий собой обобщение метода наименьших квадратов, для которого, в свою очередь, наиболее часто используется метод градиентного спуска [16]. Данный тип НС является наиболее подходящим и для задачи, поставленной в рамках данного исследования, так как позволит прогнозировать значения некоторых параметров анализируемого процесса в будущем, основываясь на значениях предыдущих периодов.

Общая структура и параметры НС включают в себя следующие понятия, которые необходимо определить до начала обучения сети:

- количество слоев (входной и выходной слою обязательны, скрытые возможны);
- количество нейронов на каждом слое;
- функция активации, определяющая выходное значение нейрона на основании входящих сигналов;
- первоначальные веса связей между нейронами.

Процесс обучения состоит из следующих этапов:

- подача значений вектора параметров из обучающей выборки на нейроны входного слоя;
- получение результирующего сигнала на нейроне выходного слоя;
- сравнение результирующего сигнала с корректным значением обучающей выборки, вычисление ошибки;
- корректировка весов связей методом градиентного спуска в соответствии с полученной ошибкой.

Таким образом, для каждого вектора обучающей выборки производятся вычисления:

1) для каждого нейрона j слоя i (кроме входного), вычисляется входное значение:

$$S_{ij} = \sum_{k=1}^n x_{i-1}^k \cdot w_{jk}^k,$$

где $(x_{i-1}^1, \dots, x_{i-1}^n)$ – выходные значения нейронов предыдущего слоя (или значения параметров вектора обучающей выборки для входного слоя), w_{jk}^k – вес связи между j -м нейроном i -го слоя и k -м нейроном $(i-1)$ -го слоя;

2) вычисляется значение функции активации, которое уходит на вход нейронов следующего слоя:

$$f(S_{ij}) = y_{ij};$$

3) для нейрона выходного слоя вычисляется значение ошибки выхода:

$$E = \frac{1}{2} \sum_{i=1}^k (d_i - y_i)^2,$$

где k – количество нейронов выходного слоя, $\{d_i\}$ – требуемое значение выхода, $\{y_i\}$ – полученное значение выхода.

Метод обратного распространения ошибки производит корректировку весов от текущего слоя к предыдущему на основании значения ошибки выхода текущего слоя:

1) корректировка весов слоя, предыдущего выходному (k – выходной нейрон):

$$w_{ik}(t+1) = w_{ik}(t) + \Delta w_{ik},$$

$$\Delta w_{ik} = \eta \cdot \varepsilon_k \cdot y_i,$$

где $\eta \in (0,1)$ – параметр скорости обучения сети, y_i – выход i -го нейрона;

2) вычисление ошибки для каждого k -го нейрона предыдущего слоя m на основании ошибок всех j -х нейронов слоя $m+1$:

$$\varepsilon_{k_m} = \left(\sum \varepsilon_{j_{m+1}} \cdot w_{k_m j_{m+1}} \right) \cdot f'(S_{k_m}),$$

где S_{k_m} – взвешенная сумма входов k -го нейрона слоя m .

Также может быть использован градиентный метод с учетом момента (разброса), корректировка весов в котором производится следующим образом:

$$w_{ij}(t+1) = \eta \cdot \varepsilon_i \cdot y_j + \alpha \cdot \Delta w_{ij}(t),$$

где $\Delta w_{ij}(t)$ – «момент», отражающий последнее изменение весов, $\alpha \in (0,1)$.

Для исключения излишнего доминирования момента проводится оценка значения ошибки. Если $\varepsilon_k(t+1) < 1,05 \cdot \varepsilon_k(t)$, то момент используется. Если $\varepsilon_k(t+1) \geq 1,05 \cdot \varepsilon_k(t)$, то значение $\Delta w_{ij}(t)$ принимается равным нулю.

3) Если ошибка выходного слоя не превышает некоторого порогового значения, то процесс обучения останавливается.

2 ФУНКЦИИ АКТИВАЦИИ

Пороговая функция используется для однослойного персептрона [15] для решения линейных задач:

$$f(x) = \begin{cases} C_1, & \text{если } \langle \text{Условие 1} \rangle, \\ C_2, & \text{если } \langle \text{Условие 2} \rangle. \end{cases}$$

Сигмоидальная униполярная $f(x) = \frac{1}{1 + e^{-\beta x}}$

и сигмоидальная биполярная $f(x) = \tanh(\beta x) = \frac{e^{\beta x} - e^{-\beta x}}{e^{\beta x} + e^{-\beta x}}$ функции являются непрерывно диффе-

ренцируемыми, что удовлетворяет требованиям алгоритма градиентного спуска [16].

3 ПОСТРОЕНИЕ СТРУКТУРЫ НС

В качестве параметров, необходимых для анализа производственного процесса, были выбраны следующие:

- 1) количество номенклатуры, изготавливаемой в составе технического средства (ТС);
- 2) трудоемкость изготовления ТС в нормочасах;
- 3) количество уникальной номенклатуры, изготавливаемой в составе ТС;
- 4) фактическая длительность изготовления ТС в днях;
- 5) общее количество номенклатуры, произведенной в период изготовления данного ТС;
- 6) общее количество оборудования, используемого на предприятии в период изготовления данного ТС;
- 7) общее количество операций, выполненных производством в период изготовления данного ТС;
- 8) количество работников производства с различными разрядами.

В соответствии с выбранными параметрами в состав входного слоя НС были включены 13 нейронов. В процессе проведения экспериментов некоторые параметры исключались, что позволило проанализировать их влияние на процесс производства. При этом сокращалось количество нейронов входного слоя.

Наличие скрытого слоя НС позволяет проводить расчеты с более сложными обобщениями и использовать сеть для решения нелинейных задач. Однако создание и увеличение количества скрытых слоев может приводить к неконтролируемому росту времени обучения НС и к возникновению проблемы переобучения. Расчет количества скрытых слоев может представлять собой тему для отдельного исследования, но по данным изученной литературы большинство проблем решаются сетями с одним скрытым слоем. Поэтому в экспериментах была заложена возможность использования НС без скрытого слоя и с одним скрытым слоем.

В качестве результата работы НС должна получиться длительность изготовления ТС, поэтому в структуре выходного слоя предусмотрен один нейрон.

Таким образом, для проведения экспериментов были взяты несколько структур НС, отличающихся друг

от друга количеством скрытых слоев, количеством нейронов на разных слоях и выбором функции активации.

Визуализация НС в виде структуры базы данных (БД) представлена на рисунке 1.

4 ФОРМИРОВАНИЕ ОБУЧАЮЩЕЙ ВЫБОРКИ

Для процесса обучения НС сформирована выборка данных по изготовлению ТС за 2017 – 2019 годы. В качестве тестовой выборки используются данные 2020 года. Состав входных параметров для НС формируется следующим образом:

1) значения количества номенклатуры и количества уникальной номенклатуры, изготавливаемой в составе ТС, получаем из состава сборок ТС;

2) трудоемкость изготовления ТС в нормочасах получаем из утвержденных технологических процессов;

3) фактическая длительность изготовления ТС в днях формируется на основании даты выполнения первой технологической операции и даты окончания сборки ТС.

4) для расчета общего количества номенклатуры, произведенной в период изготовления данного ТС; общего количество оборудования, используемого на предприятии в период изготовления данного ТС; общего количества операций, выполненных производством в период изготовления данного ТС, используется статистика выполнения технологических операций;

5) количество работников производства с различными разрядами рассчитывается, исходя из существующих на предприятии разрядов (0;6). Данное деление необ-

ходимо в связи с привязкой разрядов к сложности выполнения технологических операций.

Далее приведен пример формирования выборки по количеству сотрудников с разделением по разрядам.

```
DECLARE @TBL_R TABLE (RAZR INT)
DECLARE @I INT=0
SELECT RO.IPP,S.SP1812 AS RAZR,COUNT(RO.SOTR_ID)
AS K_S
INTO #STAT_RAZR
FROM
(
SELECT TS.IPP,RO.SP3350 AS SOTR_ID
FROM #TBL_TS AS TS
LEFT JOIN db1.dbo.SC3344 AS RO ON RO.SP3348
BETWEEN TS.DATE_START AND TS.DATE_FINISH AND
RO.SP3350<>' 0'
GROUP BY TS.IPP,RO.SP3350
) AS RO
LEFT JOIN db1.dbo.SC83 AS S ON S.ID=RO.SOTR_ID
GROUP BY RO.IPP,S.SP1812
SET @I=0
WHILE @I<7
BEGIN
INSERT INTO @TBL_R (RAZR)
SELECT @I
SET @I=@I+1
END
SELECT IPP,[0],[1],[2],[3],[4],[5],[6]
```

<p>NS_V_START (стартовая структура НС)</p> <p>UI (уникальный идентификатор нейрона) I (индекс нейрона в слое) S (номер слоя) V (выходное значение нейрона)</p>	<p>NS_V_MAX (значения нейронов по окончании эксперимента)</p> <p>I (индекс нейрона в слое) S (номер слоя) V (выходное значение нейрона)</p>	<p>NS_IN (коэффициенты нормирования)</p> <p>I_NOM (количество номенклатуры в приборе) I_TRUD (трудоемкость в нормочасах) I_NOM_Y (количество уникальной номенклатуры) I_TS_DLIT (длительность изготовления прибора) I_0 (количество рабочих без разряда) I_1 (количество рабочих с 1 разрядом) I_2 (количество рабочих с 2 разрядом) I_3 (количество рабочих с 3 разрядом) I_4 (количество рабочих с 4 разрядом) I_5 (количество рабочих с 5 разрядом) I_6 (количество рабочих с 6 разрядом) I_NOM_OBOR (количество номенклатуры, изготовленной в период изготовления прибора) I_KOL_OBOR (количество используемого оборудования в период изготовления прибора) I_KOL_OPER (количество выполненных операций в период изготовления прибора)</p>
<p>NS_W_START (стартовые веса НС)</p> <p>UI (уникальный идентификатор нейрона) I (индекс нейрона в слое) S (номер слоя) W (вес связи от нейрона S-I к нейрону UI)</p>	<p>NS_W_MAX (веса НС по окончании эксперимента)</p> <p>UI (уникальный идентификатор нейрона) I (индекс нейрона в слое) S (номер слоя) W (вес связи от нейрона S-I к нейрону UI)</p>	<p>NS_HIST_EПОНА (история экспериментов)</p> <p>N_EПОНА (номер эксперимента) RESULT (количество выборок тестового набора, значение ошибок которых не превышает 20%)</p>
<p>NS_V (память значений НС)</p> <p>UI (уникальный идентификатор нейрона) I (индекс нейрона в слое) S (номер слоя) V (выходное значение нейрона)</p>	<p>NS_TV (тестовые данные для экспериментов)</p> <p>IPP (идентификатор плановой позиции прибора) DATE_START (дата начала изготовления) DATE_FINISH (дата окончания изготовления) KOL_NOM (количество номенклатуры в приборе) TRUD (трудоемкость изготовления в нормочасах) KOL_NOM_Y (количество уникальной номенклатуры в составе прибора) TS_DLIT (длительность изготовления прибора в днях) Y (год изготовления прибора) O,...,6 (количество работников с соответствующим разрядом, работающих на производстве в период изготовления) KOL_NOM_OBOR (количество номенклатуры, изготовленной в производстве в период изготовления прибора) KOL_OBOR (количество оборудования, используемого в производстве в период изготовления прибора) KOL_OPER (количество операций, выполненных производством в период изготовления прибора)</p>	<p>NS_T (результаты тестирования НС)</p> <p>IPP (идентификатор плановой позиции) V (значение, полученное нейронной сетью) FV (правильное значение) E (процент отклонения)</p>
<p>NS_W (память весов НС)</p> <p>UI (уникальный идентификатор нейрона) I (индекс нейрона в слое) S (номер слоя) W (вес связи от нейрона S-I к нейрону UI)</p>		

Рис. 1. Структура БД для НС

```

INTO #TBL_SOTR
FROM
(
    SELECT TS.IPP,R.RAZR,ISNULL(S_R.K_S,0) AS K_S
    FROM @TBL_R AS R
    LEFT JOIN #TBL_TS AS TS ON TS.IPP=TS.IPP
    LEFT JOIN #STAT_RAZR AS S_R ON S_R.IPP=TS.IPP
AND S_R.RAZR=R.RAZR
) AS SourceTable
PIVOT
(
    SUM(K_S)
    FOR RAZR IN ([0],[1],[2],[3],[4],[5],[6])
) AS PivotTable
DROP TABLE #STAT_RAZR

```

5 НОРМИРОВАНИЕ ВХОДНЫХ ПАРАМЕТРОВ

В качестве входных параметров взяты различные параметры производства, интервальные значения которых могут сильно отличаться [5, 17, 18]. При этом влияние малых значений параметров буквально потеряется на фоне значений больших, что будет не совсем корректно влиять на выходное значение функции активации. Для исключения подобной ситуации применяем нормирование входных параметров, которое может осуществляться следующими способами:

1) простейший:
$$x_i = \frac{x_i}{\max(x_i)}$$

2) учитывающий полный интервал значений параметра X^j [19]:

$$x_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)},$$

где $X^j = (x_1, \dots, x_n)$ – значения j -го параметра из всех обучающих выборок. Подобное нормирование позволит масштабировать значения всех параметров в пределы интервала $[0,1]$. Нормирование для значений параметров тестовых выборок применяется с коэффициентами, вычисленными по данным обучающих выборок.

Для формирования коэффициентов производственных мощностей необходимо преобразовать входные

данные к средним значениям в один день [20]. Параметры количества оборудования и рабочих по разрядам формируется на основании уникальных записей в справочниках. Количество изготовленной номенклатуры и выполненных операций формируется в рамках периода изготовления ТС. Для получения средних значений необходимо разделить данные параметры на длительность изготовления ТС.

6 АНАЛИЗ НАЛИЧИЯ ПИКОВЫХ ЗНАЧЕНИЙ

При формировании значений выборок был проанализирован такой показатель, как отношение значения трудоемкости изготовления изделия к длительности его изготовления (назовем его коэффициентом напряженности производства). Если данное значение относительно велико или слишком мало, можно сделать предположение, что исходные данные недостаточно корректны. Среди проанализированных возможностей возникновения некорректных данных выделены следующие:

- 1) несвоевременное оформление или внесение в БД документов запуска в производство;
- 2) наличие задела;
- 3) незапланированные проблемы с поставкой материалов;
- 4) неравномерное распределение рабочих дней (длительные календарные праздники);
- 5) неравномерное распределение трудовых ресурсов.

Подобную некорректность данных нельзя с полным правом назвать ошибкой, скорее это допустимая погрешность производственного процесса. Однако наличие подобной погрешности не должно быть заложено в план производства, поэтому ее необходимо исключить из процесса обучения ИС.

На рисунке 2 представлен пример распределения коэффициента напряженности производства по изготовлению изделий в 2019 году.

Анализ распределения данного коэффициента показал, что основной массив данных имеет значение коэффициента $K \leq 10$. Аномально большие значения коэффициента могут сильно исказить общую картину выборок, поэтому было принято решение удалить 10% выборок с пиковыми значениями данного показателя.



Рис. 2. Распределение коэффициента напряженности по изготовлению изделий в 2019 году



Рис. 3. Распределение коэффициента напряженности по изготовлению изделий в 2019 году с удаленными пиковыми значениями

На рисунке 3 представлен пример графика с удаленными пиковыми значениями коэффициента.

7 ПОДБОР ЗНАЧЕНИЙ НАЧАЛЬНЫХ ВЕСОВЫХ КОЭФФИЦИЕНТОВ

Выбор значений начальных весов для обучения НС обусловлен выбором типа функции активации – для больших значений значение суммарного входа на нейрон может быть достаточно большим, и существует возможность попасть на пологий участок функции активации, что приведет к малым значениям градиента, незначительному изменению весов и сильно замедлит процесс обучения.

При использовании в обучении НС метода градиентного спуска может возникнуть ошибка – попадание в локальный минимум, что зависит исключительно от выбора начальных значений весов.

Для исключения данной возможности производится подбор различных значений начальных весов. Определить точное попадание в глобальный минимум не представляется возможным, поэтому достаточно провести эксперименты по обучению с различными начальными значениями весов и выбрать оптимальный результат. Начальные значения весов могут выбираться случайным образом из исходного интервала, но для гарантии охвата всего интервала целесообразно выбирать случайные значения из некоторых мини-интервалов, на которые разбит исходный, и проводить отдельные эксперименты с полученными значениями.

Для проведения экспериментов была выбрана генерация случайных значений начальных весов в интервале (0,1).

8 План и результаты экспериментов

С учетом вышеописанных методов выбора и формирования параметров был определен план экспериментов, общее описание которого может быть представлено в виде многомерной матрицы, каждый слой которой представляет собой набор значений следующих параметров:

- 1) количество входных нейронов;
- 2) количество нейронов на скрытом слое (если 0, то скрытый слой отсутствует);
- 3) функция активации;
- 4) функция нормирования значений входных параметров;
- 5) объем обучающей выборки;
- 6) начальные значения весов.

В ходе исследования было проведено более 15000 экспериментов с различными комбинациями входных параметров и настроек структуры НС. Оптимальный набор параметров, показавший наилучшие результаты по тестовой выборке, приведен в таблице 1.

Пример комбинации настроек НС для одной обучающей выборки объемом 548 элементов с динамикой количества тестовых выборок, значение ошибки которых не превышает 20%, приведен в таблице 2.

ЗАКЛЮЧЕНИЕ

Использование ранее накопленного опыта позволяло существенно расширить горизонты прогнозирования, планирования, организации и управления производством. Особенную ценность представляет формализованный опыт – формализованные показатели производ-

Таблица 1

Оптимальный набор параметров

Кол-во входных нейронов	Кол-во нейронов на скрытом слое	Функция активации	Функция нормирования	Объем обучающей выборки	Результат
13	13	Сигмоидальная униполярная	Простейшая	600	108

Таблица 2

Зависимость динамики ошибки от значений параметров НС

Кол-во входных нейронов	Кол-во нейронов на скрытом слое	Функция активации	Функция нормирования	Сортировка	Кол-во тестовых выборок с допустимым значением ошибки, %
13	13	Сигмоидальная униполярная	Простейшая	Случайным образом	86
13	13	Сигмоидальная униполярная	Простейшая	По возрастанию длительности	69
13	13	Сигмоидальная униполярная	Простейшая	По убыванию длительности	28
13	13	Сигмоидальная биполярная	Простейшая	Случайным образом	5
6	13	Сигмоидальная униполярная	Простейшая	Случайным образом	10
6	6	Сигмоидальная униполярная	Простейшая	Случайным образом	5
13	20	Сигмоидальная униполярная	Простейшая	Случайным образом	3
13	6	Сигмоидальная униполярная	Простейшая	Случайным образом	61

ственного процесса, которые позволяют непрерывно сравнивать производственный процесс предприятия в прошлом, настоящем и давать оценки на будущее.

В статье представлен подход к применению НС для получения параметров длительности изготовления изделий с использованием данных о производстве прошлых периодов и выпускаемых аналогах. Основным недостатком предложенного подхода являются ограничения НС. В то же время переход от неформализованного метода оценки сроков изготовления изделий, например, метода «пол-палец-потолок», к механизмам оценки сроков с помощью НС является существенным улучшением, т. к. позволяет проводить оценку сроков изготовления в кратчайшие сроки с учетом формальных показателей, присущих конкретным изделиям.

Таким образом, следует сказать, что предложенный механизм позволяет повысить точность предварительных прогнозных планов без существенных доработок используемой системы автоматизации планирования производственной деятельности.

СПИСОК ЛИТЕРАТУРЫ

1. Рыжов Е.В., Бахотский В.В. Организация и планирование производства : учеб. пособие. Псков : Псковский государственный университет, 2013. 148 с.
2. Черкасова О.В. Управление предприятием (организацией) : учеб. пособие. Саранск : МГУ, 2010. 212 с.
3. Ершова И.В., Минеева Т.А., Черепанова Е.В. Оперативно-производственное планирование : учеб. пособие. Екатеринбург : Изд-во Урал. ун-та, 2016. 96 с.

4. Рейнгольд Е. Методика оценки производственных возможностей предприятия. URL: https://www.cfin.ru/management/manufact/capability_appraisal.shtml (дата обращения: 08.06.2021).

5. Перцев А.А., Подобрий А.Н., Радионова Ю.А. Планирование расхода материалов для обеспечения производства машиностроительного предприятия // Автоматизация процессов управления. 2021. № 1 (63). С. 34–45.

6. Manfred Schulte-Zurhausen. Organisation. München : Verlag Franz Vahlen, 2014. 637 p.

7. Непомнящий Е.Г. Планирование на предприятии : Конспект лекций. Таганрог : ТИУиЭ, 2011.

8. Родов А.С. Крутянский Д.И. План, поток, ритм : Новочеркас. электровозостроит. завод. – Ростов н/Д : Кн. изд-во, 1964. – 72 с.

9. Data-driven process planning for shipbuilding / Jinsong Bao, Xiaohu Zheng, Jianguo Zhang, Xia Ji, Jie Zhang // AI EDAM. 2018. Vol. 32. Iss. 1. pp. 122–130. DOI: 10.1017/S089006041600055X. URL: <https://www.cambridge.org/core/journals/ai-edam/article/abs/datadriven-process-planning-for-shipbuilding/DDCB89835D01D056AA195099E7773290#article>. (дата обращения: 15.05.2021).

10. Simulation of Scheduling Production System by Using Integrating Simulation Models with Artificial Neural Network Model. / Z.I. Al-Daoud, Ouf A. Shams // Journal of Engineering. 2008. Vol. 14. Iss. 4. pp. 3121–3133. URL: https://www.researchgate.net/publication/284605091_Simulation_of_Scheduling_Production_System_by_Using_Integrating_Simulation_Models_with_Artificial_Neural_Network_Model (дата обращения: 18.04.2021).

11. A dynamic scheduling mechanism of part feeding for mixed-model assembly lines based on the modified neural network and knowledge base. / Binghai Zhou, Zhixin Zhu // *Soft Computing*. 2021. Vol. 25 (8). URL: https://www.researchgate.net/publication/342922634_A_dynamic_scheduling_mechanism_of_part_feeding_for_mixed-model_assembly_lines_based_on_the_modified_neural_network_and_knowledge_base (дата обращения: 07.05.2021).

12. Consideration of processing time dissimilarity in batch-cyclic scheduling of flowshop cells. / Najat Almasarwah, Gursel A. Suer // *Int. J. of Production Research*. 2020. Vol. 58. URL: https://www.researchgate.net/publication/344529678_Consideration_of_processing_time_dissimilarity_in_batch-cyclic_scheduling_of_flowshop_cells (дата обращения: 01.06.2021).

13. Solving flow-shop scheduling problem with a reinforcement learning algorithm that generalizes the value function with neural network. / Jianfeng Ren, Chumming Ye, Feng Yang // *Alexandria Engineering Journal*. 2021. Vol. 60 (3). pp. 2788–2800. URL: https://www.researchgate.net/publication/349103269_Solving_flow-shop_scheduling_problem_with_a_reinforcement_learning_algorithm_that_generalizes_the_value_function_with_neural_network (дата обращения: 08.06.2021).

14. Actor-Critic Deep Reinforcement Learning for Solving Job Shop Scheduling Problems. / Chien-Liang Liu, Chuan-Chin Chang, Chun-Jan Tseng // *IEEE Access*. 2016. Vol. 4. pp. 1–11. URL: https://www.researchgate.net/publication/340639690_Actor-Critic_Deep_Reinforcement_Learning_for_Solving_Job_Shop_Scheduling_Problems (дата обращения: 05.06.2021).

15. Каллан Р. Основные концепции нейронных сетей: пер. с англ. М. : Издательский дом «Вильямс», 2001. 287 с.

16. Хайкин С. Нейронные сети: полный курс. 1-е изд. : пер. с англ. М. : Издательский дом «Вильямс», 2006. 1104 с.

17. Перцев А.А., Подобрий А.Н. Формирование и анализ плана производства машиностроительного предприятия // *Автоматизация процессов управления*. 2019. № 1 (55). С. 74–83.

18. Перцев А.А., Подобрий А.Н. Подход к автоматизированному формированию плана изготовления производственного подразделения проектной организации // *Сб. науч. тр. 7-й Всерос. науч.-техн. конф. аспирантов, студентов и молодых ученых «Информатика и вычислительная техника» (ИВТ-2015)*, г. Ульяновск, 25–27 мая 2015. Ульяновск : УлГТУ, 2015. С. 398–405.

19. Структура и принцип работы полносвязных нейронных сетей. URL: http://proporprogs.ru/neural_network/ (дата обращения: 08.06.2021).

20. Перцев А.А., Подобрий А.Н., Радионова Ю.А. Реализация равномерной загрузки производства машиностроительного предприятия // *Автоматизация процессов управления*. 2020. № 4 (62). С. 49–60.

REFERENCES

1. Ryzhov E.V., Bakhotskii V.V. *Organizatsiia i planirovanie proizvodstva. Ucheb. posobie* [Organization and Production Scheduling. Tutorial]. Pskov, Pskovskii gosudarstvennyi universitet Publ., 2013. 148 p.

2. Cherkasova O.V. *Upravlenie predpriatiem (organizatsiei)*. Ucheb. posobie [Factory Management (Management of an Organization). Tutorial]. Saransk, MSU Publ., 2010. 212 p.

3. Ershova I.V., Mineeva T.A., Cherepanova E.V. *Operativno-proizvodstvennoe planirovanie*. Ucheb. posobie [Production Scheduling. Tutorial]. Ekaterinburg, Ural University Publ., 2016. 96 p.

4. Reingold E. *Metodika otsenki proizvodstvennykh vozmozhnostei predpriatiia* [Techniques for Factory Capacity Evaluation]. Available at: https://www.cfin.ru/management/manufact/capability_appraisal.shtml (accessed 08.06.2021).

5. Pertsev A.A., Podobrii A.N., Radionova Iu.A. *Planirovanie raskhoda materialov dlia obespecheniia proizvodstva mashinostroitel'nogo predpriatiia* [Material Scheduling to Provide Manufacturing in Machine Industry]. *Avtomatizatsiia protsessov upravleniia* [Automation of Control Processes], 2021, no. 1 (63), pp. 34–45.

6. Manfred Schulte-Zurhausen. *Organisation*. München, Verlag Franz Vahlen, 2014, 637 p.

7. Nepomniashchii E.G. *Planirovanie na predpriatii*. Konspekt lektsii [Scheduling of Enterprise. Course of Lectures]. Taganrog, TIUIE Publ., 2011.

8. Rodov A.S., Krutianskii D.I. *Plan, potok, ritm. Novoчеркасск. elektrovozostroit. zavod* [Plan, Flow, Rhythm. Novoчеркасск Electric Locomotive Building Plant]. Rostov-on-Don, Knizhnoe Publ., 1964. 72 p.

9. Jinsong Bao, Xiaohu Zheng, Jianguo Zhang, Xia Ji, Jie Zhang. Data-Driven Process Planning for Shipbuilding. *AI EDAM*, 2018, vol. 32, iss. 9, pp. 122–130. DOI: 10.1017/S089006041600055X. Available at: <https://www.cambridge.org/core/journals/ai-edam/article/abs/datadriven-process-planning-for-shipbuilding/DDC889835D01D056AA195099E7773290#article>. (accessed 15.05.2021).

10. Z.I. Al-Daoud, Ouf A. Shams. Simulation of Scheduling Production System by Using Integrating Simulation Models with Artificial Neural Network Model. *Journal of Engineering*, 2008, vol. 14, iss. 4, pp. 3121–3133. Available at: https://www.researchgate.net/publication/284605091_Simulation_of_Scheduling_Production_System_by_Using_Integrating_Simulation_Models_with_Artificial_Neural_Network_Model (accessed 18.04.2021).

11. Binghai Zhou, Zhixin Zhu. A Dynamic Scheduling Mechanism of Part Feeding for Mixed-Model Assembly Lines Based on the Modified Neural Network and Knowledge Base. *Soft Computing*, 2021, vol. 25 (8). Available at: https://www.researchgate.net/publication/342922634_A_dynamic_scheduling_mechanism_of_part_feeding_for_mixed-model_assembly_lines_based_on_the_modified_neural_network_and_knowledge_base (accessed 07.05.2021).

12. Najat Almasarwah, Gursel A. Suer. Consideration of Processing Time Dissimilarity in Batch-cyclic Scheduling of Flowshop Cells. *Int. J. of Production Research*, 2020, vol. 58. Available at: https://www.researchgate.net/publication/344529678_Consideration_of_processing_time_dissimilarity_in_batch-cyclic_scheduling_of_flowshop_cells (accessed 01.06.2021).
13. Jianfeng Ren, Chumming Ye, Feng Yang. Solving Flow-Shop Scheduling Problem with a Reinforcement Learning Algorithm that Generalizes the Value Function with Neural Network. *Alexandria Engineering Journal*, 2021, vol. 60 (3), pp. 2788–2800. Available at: https://www.researchgate.net/publication/349103269_Solving_flow-shop_scheduling_problem_with_a_reinforcement_learning_algorithm_that_generalizes_the_value_function_with_neural_network (accessed 08.06.2021).
14. Chien-Liang Liu, Chuan-Chin Chang, Chun-Jan Tseng. Actor-Critic Deep Reinforcement Learning for Solving Job Shop Scheduling Problems. *IEEE Access*, 2016, vol. 4, pp. 1–11. Available at: https://www.researchgate.net/publication/340639690_Actor-Critic_Deep_Reinforcement_Learning_for_Solving_Job_Shop_Scheduling_Problems (accessed 05.06.2021).
15. Callan R. *Osnovnye kontseptsii neironnykh setei*. Per. s angl. [The Essence of Neural Networks. Transl. from Engl.]. Moscow, ID Williams Publ., 2001. 287 p.
16. Haykin S. *Neironnye seti. Polnyi kurs*. 1-e izd., per. s angl. [Neural Networks: A Comprehensive Foundation. First Ed. Transl. from Engl.], Moscow, ID Williams Publ., 2006. 1104 p.
17. Pertsev A.A., Podobrii A.N. Formirovanie i analiz plana proizvodstva mashinostroitel'nogo predpriiatiia [Production Planning of the Machine-Building Enterprise]. *Avtomatizatsiia protsessov upravleniia* [Automation of Control Processes], 2019, no. 1 (55), pp. 74–83.
18. Pertsev A.A., Podobrii A.N. Podkhod k avtomatizirovannomu formirovaniuu plana izgotovleniia proizvodstvennogo podrazdeleniia proektnoi organizatsii [An Approach to Automated Plan Formation of a Production Unit in Project Organization]. *Sb. nauch. tr. 7-i Vseros. nauch.-tekhn. konf. aspirantov, studentov i molodykh uchenykh "Informatika i vychislitelnaia tekhnika" (IVT-2015)* [Proc. of 7th Russian Sci.-Tech. Conf. on Informatics and Computer Facilities for Postgraduate, Students, and Young Scientists (IVT-2015)]. Ulyanovsk, UISTU Publ., 2015, pp. 398–405.
19. Struktura i printsip raboty polnosviaznykh neironnykh setei [Structure and Principles of Functioning of Fully Connected Neural Networks]. Available at: http://proprogrs.ru/neural_network/ (accessed 08.06.2021).
20. Pertsev A.A., Podobrii A.N., Radionova Iu.A. Realizatsiia ravnomernoi zagruzki proizvodstva mashinostroitel'nogo predpriiatiia [The Balanced Production Load of a Machine-Engineering Enterprise]. *Avtomatizatsiia protsessov upravleniia* [Automation of Control Processes], 2020, no. 4 (62), pp. 49–60.