

Раздел 5. МАТЕМАТИЧЕСКИЕ МЕТОДЫ И МОДЕЛИ В ЭКОНОМИКЕ

УДК 658.5:004.8.032.26

ПРОГНОЗИРОВАНИЕ СОСТОЯНИЯ СИСТЕМЫ МЕНЕДЖМЕНТА КАЧЕСТВА ПРОМЫШЛЕННОГО ПРЕДПРИЯТИЯ С ИСПОЛЬЗОВАНИЕМ АППАРАТА ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Абалдова Светлана Юрьевна (ab0103@rambler.ru)

ФГБОУ ВПО «Ивановский государственный химико-технологический университет»

Елина Татьяна Николаевна

ФГБОУ ВПО «Норильский индустриальный институт»

Важным моментом при оценке деятельности СМК предприятия является прогнозирование развития системы менеджмента качества. Однако на сегодняшний день не существует универсальной методики прогнозирования экономических показателей, но очевидной является эффективность использования для этих целей нейронных сетей. В представленной статье разработана математическая модель искусственной нейронной сети обратного распространения ошибки для прогнозирования значения интегрального показателя системы менеджмента качества промышленного предприятия. Предложенные математические модели сетей и компьютерный программный комплекс для их оптимального подбора под конкретные показатели позволяет дать объективную оценку прогноза показателей деятельности СМК предприятия.

Ключевые слова: система менеджмента качества, результативность, нейронные сети, прогнозирование, управленческие решения.

Введение

Наиболее распространенным на сегодняшний день в мире методом оценки деятельности организации является система менеджмента качества (СМК). Повышение эффективности СМК требует непрерывного мониторинга оцениваемых показателей качества, а также их прогнозирования, которое позволит получать необходимую информацию о возможных состояниях системы на ближайший период для принятия управленческих решений.

Оценка СМК проводится по основополагающим процессам деятельности предприятия с их возможной детализацией. Для решения этой задачи разработана нечеткая модель оценки результативности СМК [3], результатом которой является интегральный показатель эффективности рассматриваемой системы. На основании рассчитанного показателя результативности СМК за текущий и предыдущие периоды можно сделать выводы о динамике анализируемой системы, а также провести прогнозирование ее состояния.

В настоящее время для решения задач прогнозирования временных показателей широкое применение получили методы, основанные на использовании искусственных нейронных сетей. Однако на текущий момент сложной остается проблема определения правильной архитектуры нейронной сети и ее параметров при реализации конкретной задачи.

Целью настоящего исследования является разработка математической модели искусственной нейронной сети обратного распространения ошибки для прогнозирования значения интегрального показателя системы менеджмента качества промышленного предприятия, а также реализация данной модели в виде компьютерного программного комплекса, не тре-

бующего от пользователя (специалиста на предприятии) познаний в области искусственных нейронных сетей.

1. Построение нейронной сети для прогнозирования интегрального показателя оценки результативности СМК

В процессе определения архитектуры сети использовалось общее обучающее множество значений оцениваемого показателя результативности СМК. При этом необходимым было условие валидации работы сети, то есть сеть не обучалась на множестве тестирования. Проводилось исследование сетей с разными параметрами, и по оценкам среднеквадратической ошибки и Евклидова расстояния был определен наиболее удачный вариант конфигурации. Рассматривались следующие параметры сетей:

- архитектура нейронной сети (количество слоев и количество нейронов);
- активационные функции (логистическая и гиперболический тангенс);
- «кривизна» активационных функций;
- качество обучающей выборки;
- инерционный момент;
- скорость обучения;
- смешанное применение активационных функций.

Проводилось исследование следующих алгоритмов снижения скорости обучения с течением времени (эпох):

- линейное снижение;
- экспоненциально сглаженное снижение;
- по закону Больцмана (из алгоритма отжига);
- по закону Коши (из алгоритма отжига).

Количество входов и выходов нейронной сети задаётся «окном» – количеством предыдущих значений ряда, на основании которых

сеть делает прогноз и длиной периода прогноза – количеством периодов, на которые нужно получить прогноз.

В результате экспериментов с различными моделями нейронных сетей были сделаны следующие выводы о влиянии указанных выше параметров:

1. Количество слоёв: дополнительный скрытый слой может дать прирост вычислительной мощности сети, однако способен затруднить настройку «кривизны» активационных функций всех слоёв. В большинстве случаев прогнозирования, с различной величиной «окна» и прогноза, достаточно двух слоёв – одного скрытого и одного выходного.

2. Количество нейронов: при недостаточном или избыточном количестве нейронов сеть не способна обучиться. Небольшое количество может позволить делать прогноз, но может не учесть всех скрытых тенденций, однако небольшие отклонения от оптимального в их числе влияют на ошибку прогноза, но достаточно слабо, чтобы им можно было пренебречь.

3. Активационная функция и её кривизна: в большинстве случаев функция гиперболического тангенса давала увеличение скорости обучения и уменьшала ошибку прогноза, однако она более «капризна» в значениях кривизны, чем логистическая, которой не требуется очень точная настройка.

Чем менее крута активационная функция, тем больше признаков она способна транслировать. Архитектура сети может не справиться с обработкой чрезмерно большого количества признаков при малых значениях кривизны активационной функции всех слоёв и недостаточном количестве нейронов (транслируется больше признаков, чем сеть способна учесть).

4. Обучающая выборка: с размером выборки, главным образом, связана архитектура. Чем больше выборка, тем больше признаков возможно извлечь (если позволяет архитектура).

Малый размер «окна» может оказаться недостаточным для создания адекватного прогноза, так как предоставляет меньше данных о внутренних тенденциях временного ряда.

Вычисляя эффективность сети как значение её ошибки на тестирующем множестве, можно «не угадать» с остановкой обучения из-за малого тестирующего множества, так как в нём могут оказаться «удачные» значения, на которых сеть покажет малую ошибку, притом, что на прочих значениях ошибка будет критически большая. Однако малое же обучающее множество увеличивает время обучения.

5. Инерционный момент позволяет уменьшить время обучения сети, за счёт учёта предыдущих изменений веса каждого нейрона. В некоторых ситуациях (когда сеть изначально взяла ориентировку на неверное направление спуска) учёт этих изменений не позволит мак-

симально возможно снизить значение ошибки, тем самым увеличивая время обучения, или, в худшем случае, даже увеличит значение ошибки, переучивая веса.

6. Скорость обучения: фиксированная скорость не способна «тонко» настроить веса, если её значение велико, либо значительно увеличивает время обучения, если она мала. Из рассмотренных способов снижения скорости наилучшим образом показывают себя способы Больцмана и, в некоторых случаях, Коши.

Это можно объяснить более пологим убыванием – сеть уменьшает начальные большие ошибки на первых шагах, после чего корректирует веса в более спокойном темпе. Однако представляется возможным улучшить эти методы, растянув график по оси ОУ.

7. Смешанная архитектура в данном случае сильно осложняется настройкой кривизны функций активации для слоёв разного типа, в ходе компьютерных экспериментов авторам так и не удалось создать сеть с разными активационными функциями на разных слоях, которая давала бы более-менее приемлемый и адекватный прогноз.

На данный момент не существует однозначных алгоритмов подбора оптимальной архитектуры нейронной сети обратного распространения. Для её определения предлагается использовать перебор в рамках задаваемых пользователем значений шага каждого параметра, их максимальных и минимальных границ и, в качестве критерия оценки, максимальное значение ошибки за несколько эпох.

2. Модель прогнозирования интегрального показателя результативности СМК промышленного предприятия

Изначально при разработке модели прогноза рассматривалась возможность прогнозирования каждого из 35 показателей выделенных по всем бизнес-процессам СМК [3] с дальнейшим расчетом интегрального показателя, но полученные значения ошибки прогноза по каждому показателю увеличивают общую ошибку прогноза, тем самым, делая прогноз не приемлемым. Поэтому было принято решение прогнозировать само значение интегрального показателя.

Деятельность предприятия в области качества рассматривалась в период с 2003 по 2012 годы, что позволило включить в модель влияние различных внешних факторов. В качестве обучающей и тестирующей выборки использовались рассчитанные значения интегрального показателя результативности СМК предприятия (ОАО «Автокран», г. Иваново) за 120 месяцев (рис. 1). Четные значения интегрального показателя результативности выступали в качестве данных для обучения, а для тестирования модели брались нечетные значения данного показателя.

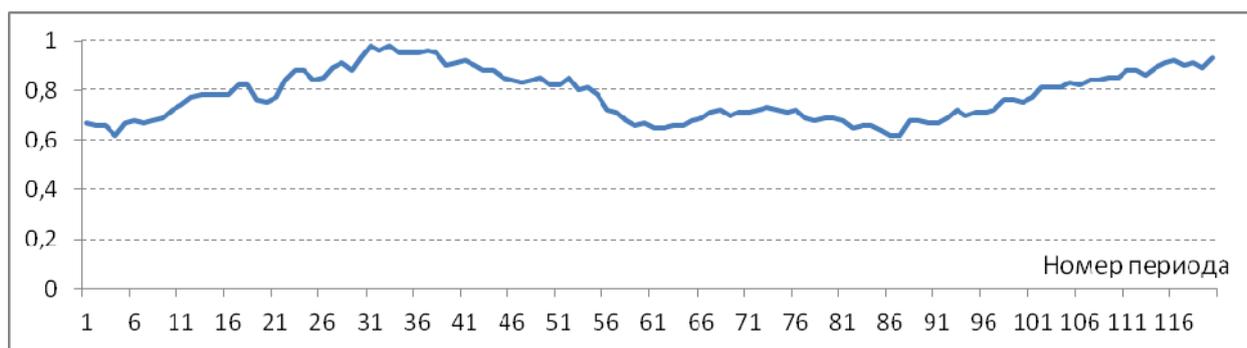


Рисунок 1. Динамика интегрального показателя результативности СМК предприятия ежемесячно за 2003-2012 гг.

Количество входов нейронной сети задавалось количеством предыдущих значений ряда, на основании которых сеть делает прогноз и длиной периода прогноза – количеством периодов, на которые нужно получить прогноз. Данные показатели должны подаваться на вход нейронной сети, в нашем случае число входных нейронов – 3.

По четным значениям интегрального показателя $Y_2, Y_4, Y_6, Y_8, \dots, Y_{120}$ за 120 периодов проводилось обучение для периода t . По последним трем значениям временного ряда $Y_{t-3}, Y_{t-2}, Y_{t-1}$ получили прогнозное значение интегрального показателя Y_t на следующий период.

Число выходных нейронов X равно 1, так как исследуемое предприятие может принимать только одно из трех взаимоисключающих состояний: X_1 – не устойчивое, X_2 – устойчивое, X_3 – сверх устойчивое.

Для оценки числа нейронов в скрытых слоях можно воспользоваться следующей методикой

$$\frac{mN}{1 + \log_2 N} \leq L_\omega \leq m\left(\frac{N}{m} + 1\right)(n + m + 1) + m \quad (1)$$

где L_ω - число нейронов в скрытом слое,

n – размерность входного сигнала (3 переменных),

m – размерность выходного сигнала (1 переменная),

N – число элементов обучающей выборки (120 периодов).

$$15,17 \leq L_\omega \leq 606 \quad (2)$$

Исходя из данного правила, в скрытом слое нейронной сети для нашего конкретного случая может быть от 16 до 606 нейронов.

В ходе проектирования была получена сеть с наиболее рациональной структурой обеспечивающая относительно высокую скорость обучения и точностью прогнозирования. На рисунке 2 показана модель нейронной сети, а в таблице 1 основные определяющие ее параметры.

Чтобы различать весовые матрицы, векторы выхода и т.д. для каждого из слоев, введем номер слоя как верхний индекс для представляющей интерес переменной. Так, например, в первом слое весовую матрицу, связанную с входами обозначим, через IW^{11} , верхние индексы которой указывают, что адресатом является первый слой (первый индекс) и источником входов является также первый слой (второй индекс). Элементы этого слоя, такие, как смещение b^1 , вход функции активации n^1 и выход слоя a^1 , имеют верхний индекс 1, чтобы обозначить, что они связаны с первым слоем. В дальнейшем для матриц весов входа и выхода будут использованы обозначения IW (Input Weight) и LW (Layer Weight) соответственно. Под каждым слоем показаны векторы-столбцы выходных слоев a^1, a^2 .

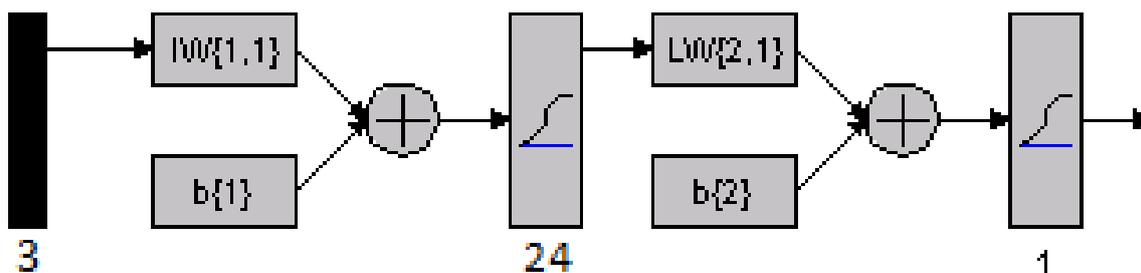


Рисунок 2. Модель нейронной сети

Таблица 1

Параметры нейронной сети

Параметр	Значение параметра
Тип сети	Feed-forward backprop (Сеть с прямым распространением сигнала и обратным распространением ошибки)
Функция обучения	Больцман
Функция представления	MSE (средняя сумма квадратов ошибки обучения)
Количество слоев	2
<i>Первый слой</i>	
Число нейронов	24
Функция активации	LOGSIG (логистическая)
<i>Второй слой</i>	
Число нейронов	1
Функция активации	LOGSIG (логистическая)

Эффективность использования нейронных сетей в качестве инструмента управления можно оценить по числу среднеквадратической ошибки при прогнозировании. К концу процесса обучения описываемой модели удалось достичь значения ошибки 4,4% за 9500 эпох.

Работа полученной сети описывается целевой функцией:

$$\sum_{z=1}^{10000} \frac{(y_z - \bar{y}_z)^2}{z} \rightarrow \min \quad (3)$$

$$\bar{y} = \text{LOGSIG}\left(\sum_{q=1}^3 LW_q^2 \times \text{LOGSIG}\left(\sum_{i=1}^{24} IW_i^1 \times p_i + b^1\right) + b^2\right), \quad (4)$$

где IW_i^1 , LW_j^2 - весовые матрицы входов первого и второго слоев сети,

p_i - входные данные (результаты измерений), LOGSIG - функция активации,

z - количество периодов обучения сети,

y и \bar{y} - соответственно фактические и прогнозные значения.

Оценка адекватности нейросетевой модели проводилась по данным вошедшим в обучающую и тестовую выборки. Результаты модельных расчетов и их сравнение с экспериментом представлено на рисунке 3.



Рисунок 3. Фактические данные и прогнозные значения интегрального показателя результативности СМК

Из рис. 3 видно некоторое несовпадение расчетных значений с фактическими данными. Однако, при сравнении тенденций изменения данных без привязки к значениям показателя,

четко прослеживаются участки с одинаковым характером поведения обоих графиков (рис. 4).

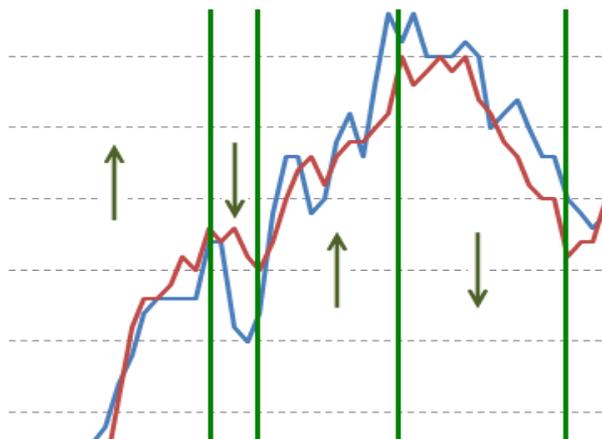


Рисунок 4. Совпадение тенденций колебания значения интегрального показателя результативности СМК

Из этого обстоятельства можно сделать вывод, что архитектура нейронной сети подобрана верно, но для отображения более точного прогноза необходимо дополнительное ее обучение. Значение ошибки прогноза 4,5% при прогнозировании показателя на один месяц вперед достаточно велико, однако уменьшить ошибку можно только увеличив объем обучающей выборки, что будет возможно в будущем при накоплении данных в СМК предприятия. Добиться хорошей гарантии прогноза возможно, когда все тенденции, влияющие на прогнозируемый показатель, имели место в прошлом, что отразилось на обучающей выборке, то есть чем больше сеть будет знать о влияниях скрытых тенденций на показатель в прошлом, тем точнее будет её прогноз в будущем. При этом будет не важен порядок следований тенденций друг за другом в обучающем множестве и в реальном времени.

3. Программная реализация разработки нейросетевых моделей для прогноза значений интегрального показателя оценки результативности СМК промышленного предприятия

В рамках решения задачи подбора оптимальной архитектуры нейронной сети обратного распространения ошибки для прогнозирования значений показателя результативности СМК была разработана компьютерная программа, позволяющая пользователю самому подбирать архитектуру сети и оценивать результаты прогноза. Само приложение условно можно разделить на две части – ядро и оболочку. Ядром является подключаемая библиотека KernelNeuroNet.dll, написанная на языке объектно-ориентированного программирования C# и реализующая работу с нейронными сетями (создание, обучение, сохранение, загрузка, прогнозирование) и обучающим множеством (загрузка, нормализация, и др.). Приложение с формами реализует больше интерфейсную часть и может быть модифицировано без вреда для основного кода. Для хранения обученных нейронных сетей используется механизм се-

риализации, позволяющий отойти от разработки громоздких форматов и сохранять нейронную сеть в виде бинарного содержимого области памяти, выделенной под объект (нейронную сеть).

В приложении реализуется подбор оптимальной, с точки зрения величины ошибки прогноза, архитектуры нейронной сети в виде конструктора, включающего три основных этапа:

1. Загрузка обучающей выборки и определение параметров и способа изменения скорости обучения.

2. Создание нейронной сети (пользователем самостоятельно или с использованием помощника), при этом задаются начальные значения параметров активационной функции сети. При использовании конструктора сети пользователь самостоятельно задает количество слоев сети, вид и кривизну активационных функций и число нейронов на каждом слое. При работе с помощником создания сетей необходимо задать интервал изменения данных параметров и количество отбираемых вариантов, при этом приложение определяет максимальное количество вариантов архитектур сетей и минимально возможную ошибку обучения.

3. Определение критериев обучения (максимальное количество эпох и допустимое значение выбранного вида ошибки обучения) и непосредственное обучение сети. Длительность обучения зависит в основном от количества эпох. Отчет о результатах прогноза и графики обучения сети выгружаются в файлы форматов html и xls.

Заключение

Прогнозирование является одной из самых важных и сложных задач управления предприятием. Система менеджмента качества позволяет проводить мониторинг основных показателей производственной деятельности и выражать их в виде индексов. Прогнозирование значений этих индексов позволит повысить эффективность производственного менеджмента.

На сегодняшний день не существует универсальной методики прогнозирования экономических показателей, но очевидной является эффективность использования для этих целей нейронных сетей.

Однако, из-за сложности математических моделей сетей и множества различных архитектур, применение их в управлении реальными предприятиями практически не встречается. Предложенные математические модели сетей и компьютерный программный комплекс для их оптимального подбора под конкретные показатели значительно упрощает работу менеджера в части реализации функции прогнозирования.

Литература

1. Аристов, О. В. Управление качеством: учеб. / О. В. Аристов. – М.: ИНФРА-М, 2009. – 240 с.: ил.

2. Волынский, В. Ю. Анализ практики реализации методических подходов к оценке результативности систем менеджмента качества / В. Ю. Волынский, С. Ю. Абалдова // *Фундаментальные исследования*. – 2009. – №3. – С. 112 – 115.
3. Герасимова, Е. Б. Управление качеством / Е. Б. Герасимова, Б. И. Герасимов, А. Ю. Сизикин; под ред. Б. И. Герасимова. – М.: ФОРУМ: ИНФРА-М, 2007. – 256с.
4. Четыркин С.М. Статистические методы прогнозирования. - М.: Статистика, 1975.
5. Статистическое моделирование и прогнозирование: Учебное пособие / Под ред. А.Г. Гранберга. - М.: Финансы и статистика, 1990.

УДК 338.45: 303.09

МЕТОДИКА ПРИМЕНЕНИЯ ТЕОРИИ НЕЧЕТКИХ МНОЖЕСТВ ПРИ ПРИНЯТИИ РЕШЕНИЙ В РАМКАХ КАЛЕНДАРНОГО ПЛАНИРОВАНИЯ

Карякин Александр Михайлович (karyakin@economic.ispu.ru)

Березка Виталий Викторович

ФГБОУ ВПО «Ивановский государственный энергетический университет им.В.И.Ленина»

Для решения задачи многокритериальной оптимизации при формировании календарных планов предлагается интерактивная процедура сужения допустимой области в пространстве переменных. На различных этапах реализации данной интерактивной процедуры лицо принимающее решение осуществляет выбор тех или иных решений, при этом нечеткость, размытость области принятия решений очевидна. В статье предложена методика обработки мнений экспертов при принятии решений в рамках формирования календарных планов инвестиционно-строительных процессов. В основе предложенной методики использован аппарат нечеткой логики.

Ключевые слова: экспертная оценка, нечеткая логика, календарный план, многокритериальная оптимизация.

Календарное планирование занимает особое место в комплексе задач планирования и управления инвестиционно-строительной деятельностью. Это связано, прежде всего, с той ролью, которую в силу специфики строительного производства играет координация по времени деятельности многочисленных участников производственного процесса.

Основная задача календарного планирования состоит в составлении такого графика выполнения работ, который удовлетворяет всем ограничениям, отражающим в технологических моделях строительства объектов взаимосвязь, сроки и интенсивность ведения работ, а также рациональный порядок использования ресурсов.

Если заранее сформулирован критерий качества календарного плана (скажем, минимальная продолжительность возведения объекта или максимальная равномерность использования бригад рабочих и строительных машин), то наилучшим считается календарный план, оптимальный по этому критерию, напри-

мер, предусматривающий наименьшую возможную длительность строительства или наиболее равномерную загрузку рабочих.

Однако следует отметить, что на практике однокритериальная постановка проблемы встречается не часто. Как правило, имеется несколько критериев, которые зачастую конфликтуют друг с другом. При этом сведение множества критериев к единственному критерию, например, аддитивному, не всегда позволяет решить поставленную задачу. Так как в этом случае, положительный вектор изменения одного из критериев ведет к отрицательному вектору изменения другого (сроки и качество, стоимость и сроки и т.п.).

Для решения задачи многокритериальной оптимизации при формировании календарных планов предлагается интерактивная процедура сужения допустимой области в пространстве переменных, основанная на элементах метода последовательных уступок и процедуры поиска удовлетворительных значений критериев STEM при заданных весах. На различных этапах ре-