



А. С. Пуряев

ПРОГНОЗИРОВАНИЕ В МЕТОДЕ ПОТОКА ПЛАТЕЖЕЙ («CASH FLOW») НА ОСНОВЕ ТЕОРИИ НЕЙРОННЫХ СЕТЕЙ

Одной из сложных проблем, раскрытых нами в процессе исследования [4] слабых мест официально принятой концепции оценки эффективности инвестиций [3], является проблема необходимости применения в методе потока платежей (МПП) процедуры прогнозирования цены продукции по периодам жизненного цикла (Π_t), ставки дисконтирования (R) и величины самого периода жизненного цикла инвестиционного проекта (ИП) – T . Эта обязательная процедура в данном методе является вероятностной и зачастую субъективной.

Задача прогнозирования являлась и является всегда самой сложной задачей в деятельности человечества. Вышеотмеченная задача не является исключением. Ученый мир разработал немало теорий прогнозирования в тех или иных областях исследования. Сегодня становится очевидным, что наука единая и существующие границы, отрасли, приложения науки лишь условны и предназначены для лучшего понимания науки и ее места в деятельности людей. На самом деле наука как таковая не имеет жестких границ для своих предметных областей. Она словно единая жидкость, состоящая из множественных кластеров (предметных областей), постоянно меняющих свою форму и содержание, течет в своем русле развития. С этой позиции очевидным также становится и тот факт, что и методология исследования для тех или иных предметных областей (природа, человек, техника, общество, экономика) имеют и должны иметь общие принципы, методы, приемы и подходы. В данной работе предлагаются направления по использованию некоторых положений науки как таковой в области прогнозирования применительно к социально-экономическим системам (СЭС), а именно к прогнозированию некоторых показателей предстоящей инвестиционной деятельности этих СЭС.

Современный рыночный мир деятельности СЭС стремительно сжимается в точку, т.е. в единицу времени происходит намного больше изменений в СЭС, чем во второй половине XX века. Особенно это характерно для новоиндустриальных стран. Фактор сжатия времени, ускоренного темпа развития СЭС в российских условиях усугубляется и действием затянувшегося переходного периода к новой системе хозяйствования. Наличие форс-ма-

жорных обстоятельств, флуктуаций (отклонений) и нелинейных условий деятельности (политическая и экономическая нестабильность, несовершенство правового поля, развитость теневого сектора экономики и т.п.) становятся нежелательной нормой повседневной деятельности хозяйствующих субъектов. Нелинейное, неадекватное, трудно прогнозируемое поведение субъектов деятельности, к сожалению, усугубляет проблему прогнозирования и оценки деятельности, и особенно деятельности на перспективу, связанную с долгосрочными капиталовложениями и инновациями. В таких условиях деятельности большинство ранее наработанных формализованных методов прогнозирования не имеют шансов выступать в качестве достоверных и надежных. Основная причина этого – использование абстрактных линейных моделей и ограничений по ним, применение цензурированных выборок, исключение всяких единичных отклонений (флуктуаций) из возможности рассмотрения, использование принципа «при прочих равных условиях», фетишизирование метода «абстрагирования» и т.п. Становится очевидным, что в таких условиях необходимо базироваться на принцип «перманентности» или «непрерывного подхода» в любой деятельности, т.е. механизм действий по цепочке «контроль деятельности – анализ отклонений – корректирующее действие деятельности» должен стать основным и постоянным.

В первую очередь для поставленной задачи прогнозирования вышеотмеченных показателей необходимо использовать накопленный опыт в области прогнозирования из других предметных областей науки (с учетом выше перечисленных современных реалий деятельности), во-вторых, совершенствовать существующие или разрабатывать новые, исчерпав все возможности имеющихся.

Одной из нелинейных концепций прогнозирования в современных условиях деятельности, нашедшая широкое применение во многих предметных областях науки, но не имеющих никакого отношения к области экономики и управления деятельностью СЭС (в первую очередь производственного назначения), является концепция, основанная на применении теории нейронных сетей или теории нейросетевого моделирования [1, 2]. Ниже в работе представляются:

– некоторые доводы в пользу возможности применения основных положений теории нейронных сетей (ТНС) к решению задач прогнозирования в деятельности СЭС и сущность нейронных сетей;

– основные положения данной теории и рекомендации, рассмотренные и предложенные в аспекте прогнозирования цены, ставки дисконта и жизненного цикла инвестиционного проекта (ИП) при применении метода «потока платежей» («Cash flow») в обосновании ИП.

Разработка искусственных нейронных сетей началась в начале XX столетия, а широкое применение нейронные сети получили в 90-х годах. База приложений нейронных сетей не мала: автоматическое управление движением автомобиля, идентификация подводных объектов по сигналам гидролокатора, решение задачи понимания обычного разговорного языка (моделирования дислексии), принятие решений при посадке поврежденного летательного аппарата, профилактика и диагностика заболеваний человека, оптическое распознавание символов, выявление фальшивых кредитных карточек, составление планов по выдаче кредитов финансово-кредитными учреждениями и даже прогнозирование изменений на фондовой бирже [1]. Проводя параллель между возможностью прогнозирования изменений на фондовой бирже и возможностью прогнозировать *цену предполагаемой производимой продукции* этим же методом в результате реализации ИП, непроизвольно задумываешься о расширении базы приложения данной теории. Аналогично и вопрос установления прогнозного значения *ставки сравнения* (ставки дисконтирования, нормы дисконта – R) и *периода жизненного цикла ИП* при оценке проектов методом «потока платежей» позволяет задуматься об использовании ТНС и для решения данных задач.

Сущность нейронных сетей [1, 2]. Искусственные нейронные сети (их называют также *коннекциями*) представляют собой устройства параллельных вычислений, состоящие из множества взаимодействующих простых процессоров. Такие процессоры имеют дело только с сигналами, которые он периодически получает, и сигналами, которые он периодически посылает другим процессорам. Локально простые процессоры, соединенные в достаточно большую сеть с управляемым взаимодействием, способны выполнять довольно сложные задачи.

Нейронная сеть является совокупностью элементов, соединенных так, чтобы между

ними обеспечивалось взаимодействие. Элемент (*нейрон, узел, нейроузел*) – простой процессор, вычислительные способности которого ограничиваются некоторым правилом комбинирования входных сигналов и правилом активизации, позволяющим вычислить выходной сигнал по совокупности входных сигналов. Выходной сигнал элемента может посылаться другим элементам по *взвешенным связям*. Взвешенная связь – связь между двумя элементами, характеризующаяся некоторым действительным числовым весовым значением или весом (весовым коэффициентом), используемым для усиления или подавления сигналов, идущих по данной связи. Связь определяется начальным элементом (из которого исходит данная связь), конечным элементом (к которому связь направлена) и значением, задающим вес.

Большинство сетей представляются в виде программных моделей (встречаются также и аппаратные устройства). Выглядят сети как обычное программное обеспечение, но принцип работы заложен иной в отличие от обычной компьютерной программы. Нейронные сети «обучаются», а не программируются, т.е. сеть учится выполнять конкретную задачу, а не программируется разработчиком. «Решение, принятое на основе нейронной сети, является более гибким, поскольку соответствующая система может в дальнейшем совершенствовать точность предсказаний по мере накопления ею опыта и адаптироваться к происходящим на рынке изменениям» [1, С. 14]. И в большинстве случаев «нейронные сети используются тогда, когда невозможно написать подходящую программу, или по причине того, что найденное нейронной сетью решение оказывается более совершенным» [там же, С. 14].

Большое количество типов сетей имеют ряд общих характеристик, а именно [1, 2]:

– *Множество простых процессоров*. Узлы, нейроны, нейроузлы (все это название простого процессора) являются обрабатывающими элементами сети, с которыми связывается набор входящих связей, по которым к данному элементу поступают сигналы от других элементов сети, и набор исходящих связей, по которым сигналы данного элемента (процессора) передаются другим элементам.

– *Структура связей (топология сети)*. Это то, как элементы сети связаны между собой. Здесь много альтернативных возможностей. Структуры связей обычно представляют в виде весовых матриц W_k , в которых каждый элемент w_{ij} представляет значение весового коэффициента (веса) для связи, идущей от

щей от
го слоя
мать с
как дол
ке 1 пр
с стремя

– Пр
сети. I
которо
ментов
дящих
сигнал
выбира
данной
– Пр
налов.
щие си
путем
е В:
деляет

net_j

Сущ
вания
квадра
ем пере
зей дав

– Пр
ти. Да
сигнал
тивно
актив
обозна
 $f(net_j)$
эlemen
С. 21 –
ый m
ность
 $f(net_j)$

2) не
ограни
симост
да в ср

чиной

3) не
нием и
значен
ния ко

0: $f(net$

ность э

муле: и



шей от элемента i к элементу j определенного слоя (уровня) k . Матрица весов – это память сети, содержащая информацию о том, как должна выполняться задача. На рисунке 1 представлен пример матрицы весов сети с тремя слоями.

– *Правило распространения сигналов в сети.* В сетях предполагается наличие некоторого правила обновления состояния элементов сети (правила комбинирования входящих сигналов и вычисления исходящего сигнала). Моменты обновления элементов выбираются случайным образом или по заданной программе.

– *Правило комбинирования входящих сигналов.* В нейронных сетях очень часто входящие сигналы предполагается комбинировать путем суммирования их взвешенных значений. Входной сигнал элемента j (net_j) определяется по следующей формуле:

$$net_j = \sum_{i=1}^n x_i w_{ij} \quad (1)$$

Существуют и другие способы комбинирования входящих сигналов, например, сумма квадратов разницы между весом и значением передаваемого сигнала всех входящих связей данного элемента.

– *Правило вычисления сигнала активности.* Данное правило вычисления выходного сигнала элемента называется *функцией активности*, а выходное значение сигнала – *активностью* соответствующего элемента и обозначается, например, для элемента j как $f(net_j)$. Функции активности для входных элементов могут быть представлены в виде [1, С. 21 – 23]:

1) *тождественной функции* когда активность равна комбинированному вводу: $f(net_j) = net_j$;


2) *пороговой функции*, когда активность ограничивается значениями 1 или 0 в зависимости от значения комбинированного ввода в сравнении с некоторой пороговой величиной θ : $f(net) = \begin{cases} 1, & \text{если } net_j \geq \theta \\ 0, & \text{если } net_j < \theta \end{cases}$;

3) *пороговой функции с учтенным смещением* w_0 , когда активность ограничивается значениями 1 или 0 в зависимости от значения комбинированного ввода в сравнении

$$f(net) = \begin{cases} 1, & \text{если } net_j \geq 0 \\ 0, & \text{если } net_j < 0 \end{cases}, \text{ при этом актив-}$$

ность элемента j должна вычисляется по фор-

$$муле: net_j = w_0 + \sum_{i=1}^n x_i w_{ij} \quad (2)$$



$$W_1 = \begin{bmatrix} -0,7 & 1,1 & -1,8 \\ . & . & . \\ . & . & 0,2 \\ . & . & . \end{bmatrix} \quad W_2 = \begin{bmatrix} 1,4 & -0,7 \\ . & . \\ . & . \end{bmatrix}$$

Рис. 1. Сеть с тремя слоями и матрица весов

4) *сигмоидальной функции*, когда активность непрерывно заполняет диапазон от 0 до 1. Примером может служить обратная экспоненциальная функция вида:

$$f(net) = \frac{1}{1 + \exp(-net)} \quad (3)$$

– *Правило обучения, корректирующее связи.* Обучение сети – это возможность сети программироваться автоматически с помощью некоторых заложенных в алгоритм правил. Цель обучения – нахождение такого набора весовых коэффициентов сети, который обеспечивает решение данной конкретной проблемы. Обучение заключается в изменении значений весовых коэффициентов. Типичная форма обучения – *управляемое обучение*, когда для каждого набора данных, подающегося в процессе обучения на вход сети, известен выходной набор. В начале обучения весовые коэффициенты устанавливаются равным случайным малым значениям. Расхождение между тем, что есть, и тем, что должно быть получено, составляет ошибку работы сети, которая может быть использована для корректировки весов. Одним из используемых правил коррекции ошибок является *дельта-правило* (правило Видроу – Хоффа) [1, С. 26 – 27]. Данное правило основывается на принципе минимизации суммы квадратов ошибок. Часто используемое в обучении правило корректировки весов для устра-



нения этих ошибок – алгоритм обратного распространения ошибок [там же, С. 51]. В процессе обучения на вход сети подаются образцы за образцом (обычно набор двоичных данных, подаваемый на вход сети, описывающих, например, реальные сделки купли-продажи объектов недвижимости в аспекте зависимости цены от строго определенных факторов). В результате их обработки весовые коэффициенты корректируются до тех пор, пока для всех вводимых образцов ошибки не станут меньше некоторого приемлемого достаточно малого значения. Образцов должно быть достаточно для решения определенной задачи (в принципе, чем больше образцов, тем лучше). Рекомендуются следующий размер

$$\text{набора учебных данных (образцов): } N > \frac{W}{\varepsilon},$$

где N – число учебных образцов; W – число весовых коэффициентов в сети; ε – доля ошибок, допустимая в ходе тестирования. Например, при допустимости 10 % ошибок число учебных образцов должно быть в 10 раз больше числа имеющихся в сети весовых коэффициентов. Полный цикл рассмотрения всех имеющихся образцов называется эпохой. Имеющиеся образцы подаются на рассмотрение снова и снова, эпоха за эпохой, пока на протяжении одной эпохи (одной итерации всех образцов!) все значения реального вывода для каждого образца не попадут в допустимые рамки. Рамки обучения определяются установленной нормой обучения η (параметр, равный некоторому постоянному значению, установленный перед началом обучения и ограничивающий величину, на которую может измениться весовой коэффициент за одно обновление; например 0,1 или 0,25). Далее при завершении процесса обучения сеть тестируется на данных (реально осуществленные данные с установленной зависимостью), не представленных в фазе обучения. Если сеть порождает правильный вывод для большинства вводимых образцов из набора тестовых данных, то это означает, что сеть обладает хорошими свойствами обобщения.¹ Набор учебных данных должен быть характерным для решаемой проблемы.

Рекомендации. Итак, метод потока платежей («Cash flow») применяется при обосновании эффективности вложения средств в инвестиционный проект, оперируя входя-

щими и выходящими денежными потоками (потоками платежей). При этом ИП должен рассматриваться за некоторый определенный прогнозируемый **жизненный цикл** (T), разбитый на заранее установленные инвестиционные периоды (шаги). Для моделирования предстоящей инвестиционной, операционной и финансовой деятельности, связанной с проектом, необходимо прогнозировать цену реализации (Π) предполагаемой продукции (услуг) по проекту и ставку сравнения (норму дисконта – R) для реализации процедуры дисконтирования прогнозируемых потоков платежей. Для того чтобы реализовать описанную ТНС в решении задачи прогнозирования цены предполагаемой продукции ИП, ставки сравнения (нормы дисконта) и периода жизненного цикла продукции необходимо иметь некоторые исходные данные:

– Цены продукции (Π) аналогичных ИП. Учебные данные должны быть типичными для задачи, решению которой обучается сеть. Под *аналогичными ИП* следует подразумевать проекты, реализующие типичную продукцию, относящуюся к одной специализированной отрасли с возможной градацией внутри этой отрасли. Например, проекты отрасли автомобильной промышленности (с возможным делением на грузовое автомобилестроение и легковое автомобилестроение), приборостроения, тяжелого машиностроения, авиастроения, черной металлургии, цветной металлургии, нефтеперерабатывающей промышленности, горнодобывающей промышленности и т.п.

– Ставки сравнения (нормы дисконта, R), принятые при обосновании реализованных ИП.

– Фактические периоды жизни реализованных ИП (T).

– Систему расчетных параметров (входных элементов) аналогичных ИП для каждого набора прогнозируемых вышеотмеченных параметров (Π, R, T), т. е. необходимо иметь значения, например, объемов производства по ИП, издержек производства в этом проекте и т.п.

В настоящее время (в условиях рыночной экономики) собрать фактическую информацию для обучения построенной сети и ее тестирования довольно трудно, но, тем не менее, существуют определенные возрастающие возможности. В условиях «сжимающего времени» и быстрого изменения в технологиях производства и проектирования, ведущих к увеличению числа реализованных ИП, создаются для этого объективные предпосылки. К

¹ Обобщение – способность сети правильно выполнять задачу с данными, которые оказываются аналогичными данным, предъявлявшимся сети в процессе обучения, но все же отличными от них [1, 2].

таким
пользо
сийски
ми и би

Для
зирова
ставки
да жизни
сетевог

1. М
обучен
зью и с
бок. На
аналог
ным кл
зависи
раметр
и выхо
з' зне
И...). Т

сится к
ный И
обучен
связью
бок) хо
сов мн
мого об
пользу
соответ
следук
тировка
транен
ния си
связь (с
ко в на
ному, :
всеми :
Р' о в
сети –

2. П
ти. Си
ной за
польз

$f(\text{net})$

данной
рывно
вых, на
прогно
ИП, с
продол
относя
Потом
ную) с
же па
непре
алгори

Серия



таким возможностям следует отнести использование накопленной базы данных российских экспертов по управлению проектами и бизнес-планированию.

Для решения поставленной задачи прогнозирования цены предполагаемой продукции ставки сравнения (нормы дисконта) и периода жизненного цикла ИП посредством нейросетевого моделирования рекомендуется:

1. Модель нейронной сети с управляемым обучением: *полносвязная сеть с прямой связью и с обратным распространением ошибок*. Нам необходимо по исходным данным аналогичных реализованных ИП (по известным классам учебных примеров) установить зависимость между параметрами сети (параметрами этих инвестиционных проектов) и выходным сигналом сети (определенным заранее результирующим показателем этих ИП). Т.е. известен класс, к которому относится каждый учебный образец (реализованный ИП). Поэтому необходимо *управляемое обучение* [1, С. 280]. Тип модели (с прямой связью и с обратным распространением ошибок) хорошо подходит для корректировки весов многослойной сети в процессе управляемого обучения и является наиболее часто используемым типом нейронных сетей [1, 2]. В соответствии с этим необходимо использовать следующие инструменты: а) правило корректировки весов – алгоритм обратного распространения ошибок; б) правило распространения сигналов в сети – полносвязная прямая связь (сигналы активности передаются только в направлении от входного слоя к выходному, а элементы одного слоя соединены со всеми элементами следующего слоя); в) правило комбинирования входных сигналов сети – суммирование взвешенных частей.

2. Правило вычисления сигнала активности. Сигнал активности в сети для поставленной задачи предполагается определять, используя сигмоидальную функцию типа:

$$f(net) = \frac{1}{1 + \exp(-net)}$$

Выходные значения данной экспоненциальной функции непрерывно заполняют диапазон от 0 до 1. Во-первых, нам необходимо научить сеть определять прогнозируемые значения цены продукции ИП, ставки сравнения (нормы дисконта) и продолжительности жизненного цикла ИП, относящиеся к *непрерывному множеству*. Потом применять обученную (тренированную) сеть для прогнозирования значений тех же параметров аналогичных ИП из того же непрерывного множества. Во-вторых, для алгоритма обратного распространения оши-

бок функция активности должна быть непрерывной, дифференцируемой и монотонно возрастающей [1, С. 51], каковой и является сигмоидальная функция активности вышеотмеченного типа. В-третьих, нелинейная функция активности экспоненциального типа ориентирована на многослойные сети (смотри п.5) и поиск сложных нелинейных зависимостей, решение сложных задач, чем и является поставленная задача прогнозирования трех важных и необходимых параметров ИП.

3. Правило обучения, корректирующее связи [1, 2]. Тип обучения – управляемое (см. п. 1). Правило коррекции ошибок – дельта-правило (правило Видроу – Хоффа). Норма обучения (η) устанавливается в зависимости от необходимой точности обучения (доли ошибок в ходе тестирования) и продолжительности обучения [1, С. 26 – 27].

4. Параметры сети. Входные элементы:

– Объем производства предполагаемой продукции за первый или другой определенный прогнозный год (период) инвестиционного проекта (фактическая для учебных и тестируемых образцов или принятая на момент обоснования и начала реализации разрабатываемого ИП) – V_{IP} . В качестве периода ИП может быть период выхода ИП на полную (или максимальную) производственную мощность.

– Текущие издержки производства при реализации ИП за первый или другой определенный прогнозный год (период) инвестиционного проекта (фактическая для учебных и тестируемых образцов или принятая на момент обоснования и начала реализации разрабатываемого ИП) – $ИзП$.

– Суммарные капитальные вложения (инвестиции) без приведения к моменту времени $t=0$ (фактические для учебных и тестируемых образцов или принятые на момент обоснования и начала реализации разрабатываемого ИП) – KV .

– Чистая текущая стоимость ИП (фактическая для учебных и тестируемых образцов или установленная в виде критериального ограничения на момент обоснования и начала реализации разрабатываемого ИП) – NPV . В качестве альтернативного критериального ограничения может быть использована внутренняя норма доходности проекта (внутренний коэффициент окупаемости) – IRR .

Выходной слой (элементы):

– Средняя цена продукции ИП за первый или другой определенный прогнозный год (период) инвестиционного проекта (реальная оценка сети для учебных и тестируемых об-

разцов или принимаемая цена на момент обоснования и начала реализации разрабатываемого ИП) – Ц.

– Ставка сравнения (норма дисконта) инвестиционного проекта (реальная оценка сети для учебных и тестируемых образцов или принимаемая ставка на момент обоснования и начала реализации разрабатываемого ИП) – R.

– Продолжительность жизненного цикла ИП инвестиционного проекта (реальный вывод сети для учебных и тестируемых образцов или принимаемая продолжительность на момент обоснования и начала реализации разрабатываемого ИП) – Т.

5. Топология сети. Рекомендуемое число выходных элементов – 3. Данное количество принято, основываясь на содержании поставленной задачи. Необходимо определить прогнозные значения трех параметров, что и обуславливает соответствующее решение. Рекомендуемое число входных элементов – 4. В качестве входных элементов были приняты необходимые и достаточные параметры, участвующие наряду с выходными параметрами сети в обосновании ИП, значения которых можно рассчитать, а не принимать. Первые три параметра ИП непосредственно необходимы для расчета чистого потока платежей, а четвертый – NPV (или IRR) – является критерием оценки эффективности ИП по действующим официально принятым положениям оценки [3], что обусловило его включение в нейронную сеть. Количество скрытых слоев – 1. Рекомендуется принять то количество слоев, которое позволило бы обучить сеть способности обобщать полученные знания (правильно выполнять задачу с данными). Теория нейронных сетей говорит о том, что сеть с одним скрытым слоем может представить любое непрерывное отображение вида $y=f(x)$. Нами рекомендуется использовать один слой с четырьмя элементами с целью сократить количество весов (весовых связей). В таком случае получится 35 весовых связей. Если допустить долю ошибок в ходе тестирования $\varepsilon = 0.1$, то размер учебных данных, вычисленный по рекомендуемой формуле Баума и Хаслера [Baum, Haussler, 1989] $N > \frac{W}{\varepsilon}$, составит 350. Такое количество реализованных ИП (учебных образцов) со своими реальными данными найти на сегодняшний день довольно сложно, но все более становится возможным в перспективе, в условиях роста активности инвесторов и развития промышленной политики региона и страны. Главное, чтобы набор учебных данных был характерным для решаемой пробле-

мы. На данный момент можно рекомендовать минимальное количество образцов – 5, но ужесточив при этом норму обучения, например, принять $\eta = 0.1$, что будет соответствовать завершению обучения сети после рассмотрения каждого учебного образца 10 000 раз. Правда, иногда оказывается, что сеть с двумя скрытыми слоями обучить проще и быстрее. Рекомендуемый алгоритм обратного распространения ошибок применяет пошаговое обновление набора весовых значений (после рассмотрения каждого образца). Иногда более выгодно использовать пакетное обновление (после рассмотрения целой эпохи – одной итерации всех образцов). Рекомендуемый подход – это осуществление экспериментирования сетью и определение количества скрытых слоев и метода обновления весов.

6. Масштабирование данных (признаков). В случае программного моделирования реальных процессов на входные элементы обычно подаются уже предварительно подготовленные данные из некоторого файла данных, а не непосредственно из внешней среды. Данная процедура необходима для того, что бы попасть в *область действия сети*. Целевые выходные данные для сети с обратным распространением ошибок и сигмоидальной функцией активности должны лежать в диапазоне от 0 до 1. Признак сети в этом случае может быть масштабирован (и рекомендуется) к диапазону 0.1–0.9 с помощью формулы (4), для того что бы избежать состояния «холостого хода» сети при достижении крайних пределов области ее работоспособности [1]:

$$y = \frac{0.9 - 0.1}{x_{\max} - x_{\min}} \cdot x + \left(0.9 - \frac{0.9 - 0.1}{x_{\max} - x_{\min}} \cdot x_{\max} \right) \quad (4)$$

где y – новое значение признака; x – первоначальное значение признака; $x_{\min}$, $x_{\max}$ – соответственно минимальное и максимальное значение признака из совокупности учебных образцов. Для входных данных также можно использовать простейший способ масштабирования: деление значения признака на максимальное значение признака.

7. Весовые коэффициенты. На первой стадии необходимо случайным образом установить весовые коэффициенты. Рекомендуется [1, С. 55] в их качестве взять значения из диапазона между -0,3 и +0,3. Обучение сети необходимо проводить до тех пор, когда выход для каждого учебного образца (эпохи) оказывается в рамках допустимого отклонения. Для поставленной задачи и при применении сигмоидальной функции активности в сети целевым выходным значением явля-

Vпр

ИзП

KV

NPV

 W_{XS}
 P_L

ется
тиме
выс
меж,
мых
ком
пря
нием
дачи
а и
прое
фици
фици
обуч
до +
Ра
нию
став.
дим
тока
ляют




Рис. 2. Полносвязная сеть с прямой связью для решения поставленной задачи

ется значение – 1.0, а рекомендуемая допустимая погрешность равна 0.1. Если любое выводимое значение сети лежит в интервале между 0.9 и 1.0, то оно находится в допустимых рамках. На рисунке 2 представлена рекомендуемая полносвязная модель сети с прямой связью и с обратным распространением ошибок для решения поставленной задачи прогнозирования цены, нормы дисконта и продолжительности жизненного цикла проекта вместе с матрицами весовых коэффициентов связей (значения весовых коэффициентов установлены на момент начала обучения произвольно из диапазона от –0.3 до +0.3).

Разработанные рекомендации по применению теории нейронных сетей в решении поставленной задачи прогнозирования необходимых и ключевых параметров метода «потока платежей» (метода «Cash flow») позволяют решить определенным способом слож-

ную проблему, а также являются предпосылками для раскрытия дальнейших путей совершенствования необходимой процедуры прогнозирования в нелинейных условиях деятельности.

Литература

1. Каллан Р. Основные концепции нейронных сетей.: Пер. с англ. М.: Издательский дом «Вильямс», 2003. 288 с.: ил. Парал. тит. англ.
2. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика, 2002. 382 с.: ил.
3. Методические рекомендации по оценке эффективности инвестиционных проектов: (Вторая редакция) / М-во экон. РФ, М-во фин. РФ, ГК по стр-ву, архит. и жил. политике; рук.авт.кол.: Косов В. В., Лившиц В. Н., Шахназарова А. Г. М.: ОАО «НПО «Изд-во «Экономика», 2000. 421 с.
4. Пуряев А. С. Система оценки выбора технологических процессов плавки и литья чугуна. Наб. Челны: Изд-во Камского госуд.политехн. ин-та, 2004. 191 с.

а) X1, X2, X3, X4 – значения нормированных (масштабированных) входных элементов сети соответственно V_{пр}, ИзП, КВ, NPV;

б) S1, S2, S3, S4 – расчетные значения скрытого слоя сети;

в) Y1, Y2, Y3 – расчетные масштабированные значения выходных элементов сети соответственно Ц, R, Т;

г) Cm – смещение сети с активностью, равной 1;

д) W_{XS}, W_{SY} – матрицы весовых коэффициентов первого и второго слоев связи соответственно со значениями на момент начала обучения