

### 10.9. О ПРИМЕНЕНИИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ФИНАНСОВЫХ ПОКАЗАТЕЛЕЙ ПРЕДПРИЯТИЯ

Романовский А.В., ведущий специалист по методологии планирования планово-экономического отдела департамента финансов

ЗАО «Русагротранс»

В статье предлагается методика расчета прогноза финансовых показателей деятельности предприятия на основе математического аппарата искусственных нейронных сетей и обосновывается целесообразность ее применения. Также приводятся основные результаты пробных исследований в указанном направлении.

Предприятие является не просто системной единицей экономики, но и самостоятельной управляемой системой. Планирование на предприятии является основным инструментом адаптации управленческих воздействий под изменяющиеся условия окружающей среды, в которых происходит деятельность организации. Управленческие воздействия направлены, в конечном счете, на максимально эффективное использование ресурсов предприятия. При этом критерии эффективности деятельности определяет менеджмент, но наиболее часто в качестве критерия обосновано выступают показатели финансового результата [1, с. 19]. Поэтому качество планирования, в том числе финансового, оказывает серьезное влияние на конкурентоспособность организации, что обуславливает большой интерес менеджмента к качественным финансовым моделям как для целей управления компанией, так и при оценке ее стоимости в случае использования доходного подхода.

В финансовом планировании наибольший интерес для менеджмента представляют следующие формы:

- бюджет доходов и расходов (БДР);
- бюджет движения денежных средств (БДДС);
- прогнозный баланс (ПБ);
- инвестиционный бюджет (ИБ).

В процессе разработки финансовой модели для компании, как правило, определяются жестко детерминированные зависимости большинства показателей этих форм от небольшого количества экзогенно определяемых показателей (драйверов). Другими словами, множество плановых финансовых показателей (F) может быть разделено на два подмножества: драйверы (D) и те показатели, которые могут быть математически выражены, через другие показатели системы (N). Запишем это в следующем виде:

$$D \subset F, N \subset F;$$

$$D = \{d_1, d_2 \dots d_k\};$$

$$N = \{n_1, n_2 \dots n_m\}.$$

При этом зависимость:

$$n_i = f(d, n)$$

может быть однозначно детерминирована. Однако такое утверждение не верно для элементов множества D, которые зависят от внешних по отношению к системе факторов, вектор которых обозначим как **INPUT**:

$$d_i = f(INPUT).$$

Определение формы и силы такой зависимости является основным предметом изучения в настоящей статье, поскольку представляет наибольшую сложность и интерес в процессе прогнозирования на долгосрочном горизонте.

Проиллюстрируем зависимость финансовых показателей предприятия на примере рис. 1.

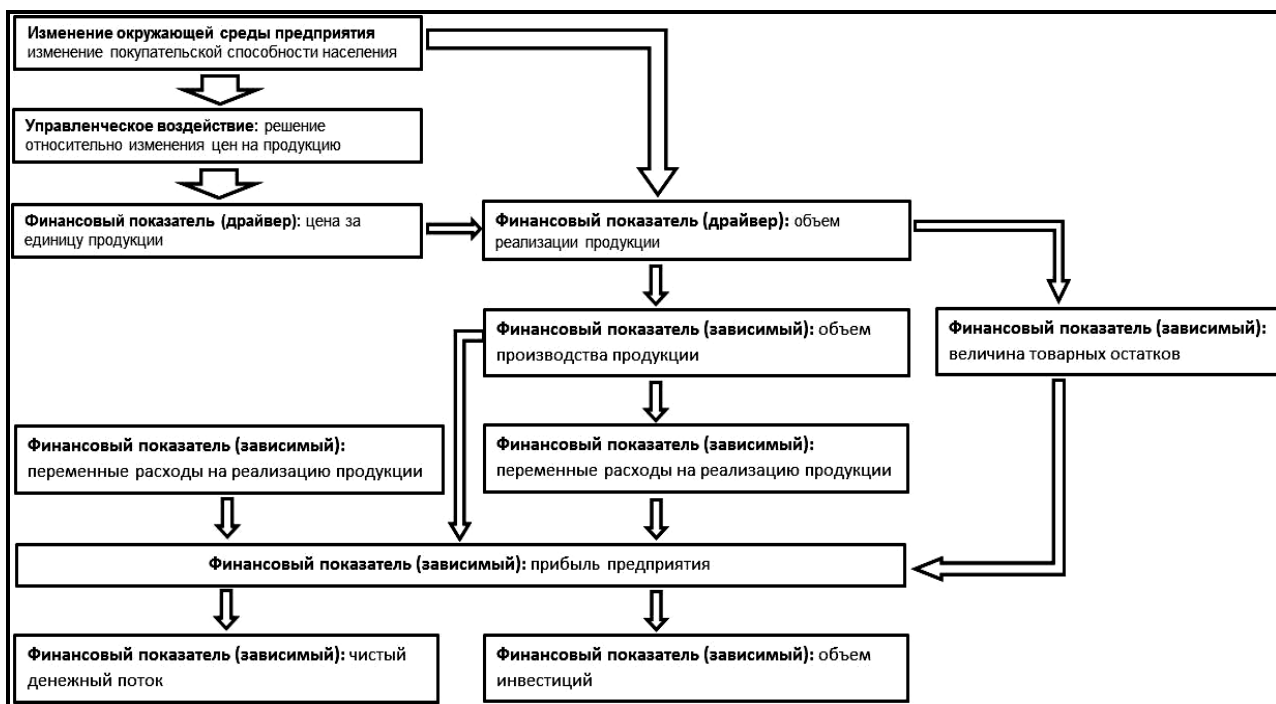


Рис. 1. Зависимости финансовых показателей предприятия

В процессе анализа системы финансовых показателей, можно говорить о том, что целевая функция компании является приближенным аналогом функции Лагранжа [6, с. 31]:

$$\begin{cases} \text{Фин.результат} = F(K1, K2, K3...H1, H2, H3) \rightarrow \max \\ \text{ФС}(Л, ЧОК, СС...) \geq \text{ФС}(normЛ, normЧОК, normСС...) \end{cases}$$

где

Фин.результат – конечный финансовый результат деятельности предприятия;

**K1, K2, K3...** – контролируемые эндогенные воздействия;

**H1, H2, H3...** – неконтролируемые экзогенные воздействия (прогнозируемые тенденции внешней конъюнктуры);

**ФС** – уровень финансовой устойчивости (финансовой стабильности);

**Л, ЧОК, СС...** – факторы финансовой устойчивости, такие как:

- ликвидность (**Л**), финансовая маневренность и величина чистого оборотного капитала (**ЧОК**),
- общая платежеспособность и доля собственных средств в источниках финансирования (**СС**) и др.;

**norm** – нормативные значения показателей финансовой устойчивости.

Значение каждого драйвера в определенный период является результатом влияния большого числа эндогенных и экзогенных факторов, а форма и сила этого влияния зачастую неизвестна. При отсутствии достаточной базы для статистического анализа, прогнозирование драйверов с достаточной степенью надежности, представляется трудноразрешимой задачей. Решение такой задачи с использованием традиционных статистических методов, таких как регрессия, требует высоких затрат и наличие специальных математических знаний. В свете этого, налицо необходимость разработки методики планирования финансовых показателей предприятия, которая будет лишена указанных недостатков и иметь достаточно сложную структуру, поскольку следует вспомнить принцип Эшби, который говорит о том, что управляющая система, должна быть не менее сложной, чем управляемая. В качестве основного метода для этого предлагается использовать инструментальный нейросетевой моделирования по ряду причин:

1. Искусственная нейронная сеть (ИНС), которая является совокупностью множества достаточно простых процессоров (нейронов), способна быстро выполнять сложные слабоформализованные задачи.
2. Другое важное свойство ИНС – способность к обучению и обобщению полученных знаний. Это позволит модели на ограниченном тренировочном множестве данных выявлять большое количество различных по формам и степени выраженности зависимости между данными и применять их на данных, не использовавшихся в процессе обучения [4, с. 14].
3. Поскольку конкретное значение драйвера является своеобразным отражением рыночной ситуации, то само значение драйвера, можно определить как образ, т.е. результат отражения прообразов, которое в разных случаях может не совпадать, но должно быть сходно структурно, ИНС наилучшим образом подойдет для его моделирования как наиболее мощная технология распознавания образов. Такая способность достигается благодаря памяти ассоциативного типа. Даже, если на вход сети подается вектор входных данных сильно искаженный шумом, ИНС способна сгенерировать соответственный истинный выходной вектор [5, с. 34].
4. Привлекательной особенностью ИНС является то, что случайная величина, моделируемая сетью, не должна

быть распределена по какому-то определенному закону, как этого требуют статистические регрессионные методы.

5. Немаловажным является наличие готовых программных продуктов со встроенными алгоритмами ИНС, позволяющих сотрудникам предприятия без специальных математических знаний применять ИНС для прогнозирования.

В соответствии с предлагаемым подходом задача прогнозирования драйверов сводится к разовой разработке нейросетевой математической модели и дальнейшему ее использованию. При этом вектор входных данных должны формировать показатели, которые прогнозируются на регулярном уровне экономическими агентствами, чтобы обеспечить наличие информации для планирования. В данном случае предполагается, что менеджмент компании принимает оптимальные решения по использованию имеющихся в распоряжении предприятия ресурсов, равно как и в предшествующие прогнозные периоды. В случае нарушения последнего предположения при наличии управленческих ошибок, которые повлияли на величину прогнозируемого драйвера в прошлом, достаточно будет скорректировать фактические значения этого драйвера, используемые для разработки модели, на величину потерь от этих ошибок.

В свете описанного выше, приведем основные этапы, которые следует преодолеть в процессе разработки нейросетевой модели прогнозирования, а также ее дальнейшего использования. При этом не будем акцентировать внимание на хорошо известных специалистам по бюджетированию аспектов формирования бюджетных систем, а остановимся подробно на методических вопросах прогнозирования с использованием нейросетевых моделей. Иначе говоря, предлагаемый алгоритм является инструментом определения конкретных прогнозных показателей при существующей и функционирующей бюджетной системе (рис. 2).

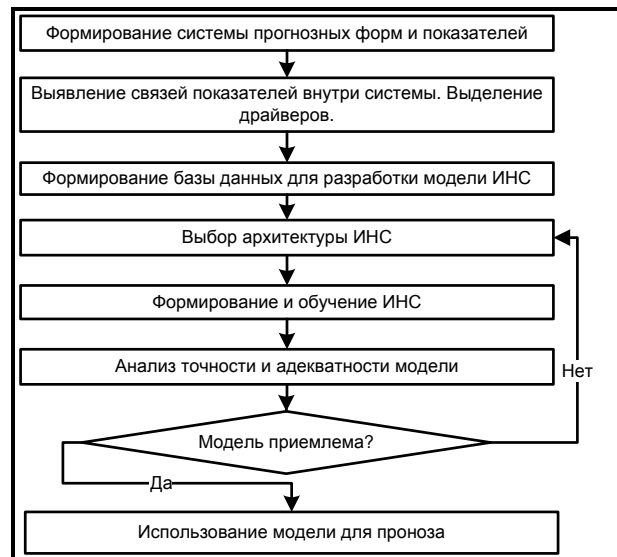


Рис. 2. Схема разработки модели прогнозирования финансовых показателей компании.

Для построения модели, во-первых, необходимо выявить все детерминированные связи показателей бюджетной системы. Как правило, в корректно построенной прогнозной финансовой системе таких показателей абсолютное большинство. Действительно, если говорить о форме БДР, то расходная часть достаточно просто

может быть выражена как функция от объема производства для переменных расходов, и некоторая константа для условно-постоянных расходов. Аналогично оттоки денежных средств по операционной деятельности с учетом условий договоров с поставщиками и известными объемами расходов также однозначно могут быть спрогнозированы. БДДС в части финансовой и инвестиционной деятельности определяются исходя из планов менеджмента и текущих обязательств при этом практически не зависят от внешних факторов. Поэтому наиболее сложной задачей выступает прогнозирование объема реализации продукции, который определяет в конечном итоге весь финансовый прогноз. Поэтому, на втором этапе необходимо разработать алгоритм прогноза именно таких показателей, которые определяют другие плановые показатели, но не могут быть выражены через третьи плановые показатели.

На втором этапе разрабатывается модель, которая будет служить инструментом прогноза. В рамках этого этапа следует решить следующие задачи:

- разработать порядок определения целевых значений драйверов. Определение будет происходить в рамках допустимого интервала посредством эндогенных управленческих воздействий, ограничивая которые будет рыночная ситуация, как определяющая сила. Обычно для этого используется функция прибыли от управляемого параметра, которая исследуется на максимум. Такие модели достаточно широко представлены как в отечественной, так и зарубежной литературе, поэтому не будем уделять им большого внимания;
- сформировать модель, позволяющую посредством идентификации рыночной ситуации определить допустимый интервал целевых значений драйверов. Порядок и особенности формирования такой модели рассмотрим ниже, как основную проблему настоящей статьи.

На третьем этапе, который, по сути, является итерационным на всем периоде использования модели, определяется ошибка прогнозирования, адекватность и достоверность полученных прогнозных результатов и, при необходимости, корректируются параметры модели.

Теперь рассмотрим процесс формирования модели прогнозирования на основе ИНС в отдельности. Традиционно наиболее трудоемким является процесс формирования массива данных для разработки модели, который состоит из двух подмножеств – подмножество целевых данных, на котором будет обучаться и тестироваться сеть, и подмножество эндогенных факторов, которые предположительно определяют значение искомого драйвера. При этом данные должны быть по возможности предварительно обработаны для увеличения качества модели. С этой целью во многих статистических пакетах реализованы процедуры предобработки, которые служат инструментами очистки и восстановления исходных данных. Общий принцип предобработки данных для обучения состоит в максимизации энтропии входов и выходов [2, с. 127].

Основные процедуры предварительной обработки данных заключаются в следующем:

- Кодирование данных – перевод всех факторов в числовое выражение, поскольку для работы сети все входы сети должны быть числовыми;
- Нормализация – для быстрого обучения сети, а также в целях избежать застревания в локальных минимумах, необходимо, чтобы все входные данные были нормализованы. Наиболее распространена нормализация по формуле:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}};$$

- Парциальная обработка – спектральная обработка, восстановление пропущенных значений, вейвлет преобразования, робастная фильтрация (редактирование аномальных значений).

Отбор эндогенных управляющих факторов должен быть произведен как с использованием корреляционного анализа, т.е. отбираются те факторы, связь искомого драйвера с которыми статистически значима, так и с использованием экспертных заключений, поскольку не любая связь может быть математически идентифицируема на этапе предварительного отбора факторов. Однако эксперты, работающие в данной конкретной области достаточно хорошо «чувствуют рынок» и могут определить факторы, не учтенные в результате корреляционного анализа. Следует отметить необходимость провести предварительную статистическую работу с факторами, как например факторный анализ с выделением факторов методом главных компонент. Такая обработка необходима для редукции числа факторов. Поскольку следует учитывать, что общее число факторов должно соответствовать количеству данных, используемых в процессе обучения ИНС.

Заметим, что в качестве факторов могут выступать также циклическая и сезонная составляющая динамики драйвера, а также ошибка прогноза предыдущего периода. В этом случае сеть будет отличаться от традиционной сети прямого распространения и становится рекуррентной.

При этом, как упоминалось выше, факторы модели должны на регулярной основе прогнозироваться специализированными агентствами. Кроме того, фактические данные также должны быть доступны аналитику с не слишком большим запаздыванием, для отслеживания и корректировки прогноза. Наиболее приемлемыми для этого являются показатели государственной статистики, факт по которым регулярно публикуется в отчетах Росстата, а для планирования могут быть использованы консенсус-прогнозы ряда наиболее авторитетных источников, в числе которых также могут выступать отраслевые министерства и ведомства.

После формирования базы данных для построения ИНС, переходим непосредственно к ее разработке. Поскольку формирование сети, а тем более ее обучение, достаточно сложный процесс, для этого лучше всего использовать готовые программные решения по искусственным нейронным сетям.

Следует учитывать, что методы ИНС насчитывают огромное количество модификаций: сети могут обладать как прямой связью (сигналы проходят в одном направлении – от входных данных к выходу), так и обратной (выходной сигнал некоторого элемента оказывает влияние на его входной сигнал). Кроме этого, имеется множество вариантов архитектур нейронной сети, как самой их топологии, так и функций активации нейронов (табл. 1).

Построение **ИНС** производим с учетом ряда специфических особенностей нейросетевых моделей. Для этого следует указать наиболее общие рекомендации при формировании **ИНС**. Так для целей прогнозирования наиболее часто используются **ИНС** в виде многослойного персептрона (**МЛП**) и сети радиально-базисных функций (**РБФ**). При этом замечено, что в долгосрочных (стратегических) прогнозах лучше себя

зареккомендовали сети **МЛП**, в то время как на кратко- и средне-срочной перспективе лучше использовать сети **РБФ**.

Таблица 1

**ФУНКЦИИ АКТИВАЦИИ НЕЙРОНОВ**

Название	Формула
Линейная	$f(x) = k * x$
Полулинейная	$f(x) = \begin{cases} k * x, x > 0; \\ 0, x \leq 0 \end{cases}$
Логистическая (сигмоидальная)	$f(x) = \frac{1}{1 + \exp(-k * x)}$
Гиперболический тангенс (сигмоидальная)	$f(x) = \frac{\exp(k * x) - \exp(-k * x)}{\exp(k * x) + \exp(-k * x)}$
Экспоненциальная	$f(x) = \exp(-k * x)$
Синусоидальная	$f(x) = \sin(x)$
Сигмоидальная (рациональная)	$f(x) = \frac{x}{k +  x }$
Сигнатурная	$f(x) = \begin{cases} -1, x \leq 0; \\ 1, x > 0 \end{cases}$
Пороговая (функция Хэвисайда)	$f(x) = \begin{cases} 0, x < 0; \\ 1, x \geq 0 \end{cases}$
Шаговая	$f(x) = \begin{cases} -1, x \leq -1; \\ x, -1 < x < 1; \\ 1, x \geq 0 \end{cases}$
Модульная	$f(x) =  x $
Степенная	$f(x) = x^k$
Функция Гаусса	$f(x) = \exp\left(\frac{(x - k)^2}{2\sigma^2}\right)$

Рассмотрим, что из себя представляют МЛП и РБФ сети. В сети МЛП каждый элемент сети рассчитывает взвешенную сумму собственных входных сигналов с поправкой в виде обособленного от входных данных слагаемого (биаса). Полученный таким образом сигнал подается на функцию активации. Таким образом получается выходное значение этого элемента. Элементы организованы в послойную топологию с прямой передачей сигнала. Такую сеть легко можно интерпретировать как модель вход-выход, в которой веса и пороговые значения (смещения) являются свободными параметрами модели. Такая сеть может моделировать функцию практически любой степени сложности, причем число слоев и число элементов в каждом слое определяют сложность функции.

В основу сетей РБФ положен принцип разбиения пространства на гиперплоскости. Сеть состоит из слоя радиально-базисных элементов, которые определяются координатами центра и радиусом. Функция каждого такого элемента реагирует на расстояния входного сигнала до своего центра.

Что касается количества слоев нейронов, то сети РБФ в абсолютном большинстве трехслойные. В них первый слой – сенсорный, т.е. поставляет сигналы, формирующие информацию для дальнейшей обработки. Единственный скрытый слой в ИНС РБФ – второй, образованный R-нейронами. Он обеспечивает нелинейное преобразование пространство входных векторов (**Rn**) в скрытое (**Rh**), зачастую более высокой размерности (**h > n**), что обеспечивает лучшую аппроксимацию. Выходной слой формирует отклик ИНС. В скрытом слое, активация нейрона задается функцией

Гаусса. Выходной сигнал ИНС определяется взвешенной суммой сигналов элементов скрытого слоя.

В сетях МЛП количество различных вариантов, как по числу слоев, так и по виду функции активации, значительно больше, чем в сетях РБФ. Тем не менее, применение сетей с более чем одним, в редких случаях двумя, скрытыми слоями редко бывает оправданным [3, с. 36]. Количество нейронов в скрытых слоях также должно быть меньше чем в предыдущем слое.

Отметим, что недостаток нейронов и их избыток могут навредить качеству сети. При малом числе нейронов сеть не сможет обучиться, поскольку функция ошибок будет далека от нуля. Так же при слишком большом числе нейронов сеть не будет выполнять в достаточной мере функцию обобщения, а при обучении велика вероятность попадания в локальные минимумы.

Таким образом, не составив труда с использованием программных средств нейросетевого моделирования сформировать семейство сетей, из которых предстоит выбрать оптимальную. Выбор оптимальной модели может быть произведен по критерию минимума ошибок на обучающем и тестовом множестве. При этом следует учитывать, что более достоверной оценкой ошибки служит точность на тестовом множестве, т.к. оно не использовалось в процессе обучения. Однако доля значений, которая попадает в тестовое множество, значительно меньше, чем обучающее множество, поэтому оно является менее репрезентативным. В связи с этим предлагается делать выбор на основании совокупности этих оценок.

После выбора конкретной топологии, необходимо выбрать параметры обучения нейронной сети. Эта фаза имеет большое значение для сетей, обучающихся с учителем. От выбора параметров зависит не только то, насколько быстро ответы сети будут сходиться к правильным ответам. Например, выбор низкой скорости обучения увеличит время схождения, однако иногда позволяет избежать паралича сети. Увеличение момента обучения может привести как к увеличению, так и к уменьшению времени сходимости, в зависимости от формы поверхности ошибки. Исходя из такого противоречивого влияния параметров, можно сделать вывод, что их значения нужно выбирать экспериментально, руководствуясь при этом критерием завершения обучения (например, минимизация ошибки или ограничение по времени обучения).

Что касается самих алгоритмов обучения ИНС, то, несмотря на их кажущееся разнообразие, смысл каждого в исследовании полученной многомерной функции ошибок на минимум. Аналитического решения этой задачи не существует, поэтому определяется произвольная точка на поверхности функции ошибок и далее перемещается в сторону глобального минимума. В каждом конкретном случае могут быть использованы различные варианты обучения или их совокупность. Детальное их рассмотрение не имеет смысла, поскольку каждый алгоритм обучения обладает своими сильными и слабыми сторонами, как то скорость, застревание в локальных минимумах и проч. Математические алгоритмы защиты в программные продукты и не требуют от аналитика их досконального знания. Укажем лишь некоторые особенности обучения ИНС. Просмотр обучающей выборки при обучении с учителем может проводиться последовательно или хаотично, один или множество раз. В случае обучения с учителем, обучающую

выборку данных делят на две части – собственно обучающую выборку и тестовые данные; принцип разделения может быть произвольным. Обучающие данные подаются сети для обучения, а проверочные используются для расчета ошибки сети (проверочные данные никогда для обучения сети не применяются). Таким образом, если на проверочных данных ошибка уменьшается, то сеть действительно выполняет обобщение. Если ошибка на обучающих данных продолжает уменьшаться, а ошибка на тестовых данных увеличивается, значит, сеть перестала выполнять обобщение и просто «запоминает» обучающие данные. Это явление называется переобучением сети или оверфиттингом. В таких случаях обучение обычно прекращают. В процессе обучения могут проявиться другие проблемы, такие как параллелизм или попадание сети в локальный минимум поверхности ошибок. Невозможно заранее предсказать проявление той или иной проблемы, равно как и дать однозначные рекомендации к их разрешению.

Таблица 2

### ИСХОДНЫЕ ДАННЫЕ ДЛЯ МОДЕЛИРОВАНИЯ ТЕМПА РОСТА ВЫРУЧКИ КОМПАНИИ

Год	Индексы физического объема ВВП	ИПЦ	Динамика импорта, всего	% к предыдущему году	
				Динамика среднедушевых денежных доходов населения	Темп роста выручки компании
2000	110,05	120,20	113,67	137,51	140,27
2001	105,09	118,60	119,82	134,23	125,98
2002	104,74	115,10	113,38	128,91	129,53
2003	107,30	112,00	124,75	130,91	131,15
2004	107,18	111,70	127,99	123,83	122,74
2005	106,38	110,90	128,75	126,40	125,29
2006	108,15	109,00	131,02	125,55	127,57
2007	108,54	111,90	136,03	123,49	148,92
2008	105,25	113,30	130,60	118,53	128,89
2009	92,18	108,80	65,71	113,67	50,46
2010	104,50	108,80	129,61	112,17	104,84
2011	104,29	106,10	130,25	109,52	133,17
2012	103,44	106,00	103,58	109,95	113,78

Следует помнить, что даже при соблюдении всех правил построения и обучения ИНС, результат может оказаться неадекватным. Поэтому по завершению обучения, ИНС должна быть проверена на контрольных примерах, отличных от обучающих. Анализ чувствительности полученной модели, который также позволяет делать большинство статистических пакетов поможет аналитику оценить модель, а также правильность включения факторов в модель. Так при невысокой чувствительности прогнозируемой величины к одному или нескольким факторам, должна вызывать сомнение обоснованность их включения в модель. Также не лишним будет проверка модели на устойчивость, посредством внесения сильно завышенных и заниженных значений факторов, и дальнейшего анализа поведения прогнозируемой величины. При условии, что проверка даст положительный результат, можно приступать к формированию непосредственно прогноза.

В качестве иллюстрации приведем пример расчета прогнозного темпа роста выручки некой компании. На выручку этой компании оказывает влияние макроэкономическая ситуация в стране, которая характеризуется величиной **ВВП**, индексом потребительских цен (**ИПЦ**), величиной импорта в страну и среднедушевыми доходами населения. Исходные данные для модели содержатся в табл. 2. Данные макроэкономической статистики получены из отчетов Росстата ([www.gks.ru](http://www.gks.ru)). Рассмотрим четыре варианта ИНС для прогноза темпа роста выручки (табл. 3).

Оптимальной представляется сеть, обозначенная как RBF 4-7-1. Это радиально-базисная ИНС с количеством элементов в слоях 4, 7 и 1 соответственно. В процессе обучения сети определяются параметры радиально-базисных элементов – координаты центра элемента ( $c_j$ ) и значение  $\sigma$ , которые являются параметрами функции Гаусса. Кроме этого, определяются веса для выходных сигналов скрытого слоя при формировании выхода сети. Вид сети приведен на рис. 3.

Таблица 3

### ВАРИАНТЫ АРХИТЕКТУРЫ ИНС ДЛЯ МОДЕЛИРОВАНИЯ ДОХОДА ТЕМПА РОСТА ВЫРУЧКИ КОМПАНИИ

Index	Net. name	Training perf.	Test perf.	Training error	Test error	Training algorithm	Hidden activation	Output activation
1	MLP 4-8-1	0,7974	1	0,021052	0,000029	BFGS 2	Логистическая	Гиперболический тангенс
2	RBF 4-7-1	0,9658	-1	0,000214	0,004441	RBFT	Гауса	Линейная
3	MLP 4-3-1	0,8921	-1	0,027594	0,000101	BFGS 2	Линейная	Логистическая
4	RBF 4-4-1	0,5326	-1	0,022923	0,000289	RBFT	Гауса	Линейная

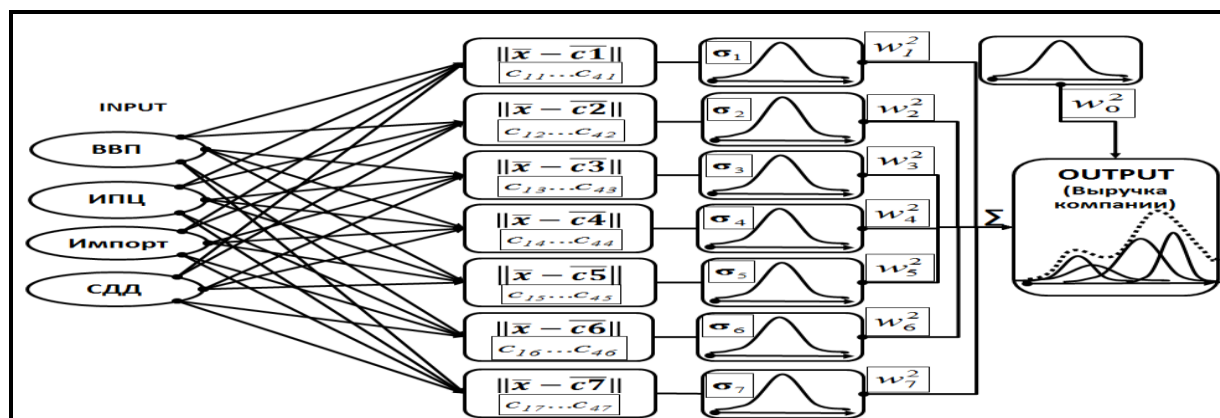


Рис. 3. Вид сети RBF 4-7-1.

Таблица 4

РЕГРЕССИОННАЯ МОДЕЛЬ ПРОГНОЗА ТЕМПА РОСТА ВЫРУЧКИ (ВЫГРУЗКА ИЗ ПАКЕТА STATISTICA 8.0)

Показатель	$\beta$ – коэффициент (нормированный)	Стандартная ошибка $\beta$	Коэффициент $B$	Стандартная ошибка $B$	t-статистика $t(8)$	Уровень значимости $p$ -level
<i>Intercept</i>	-	-	-423,918	151,0798	-2,80592	0,022987
<b>ВВП</b>	0,778887	0,319459	4,295	1,7614	2,43815	0,040682
<b>ИПЦ</b>	0,179208	0,25268	0,998	1,4073	0,70923	0,498329
<b>Импорт</b>	0,192381	0,273233	0,248	0,3525	0,70409	0,501353
<b>СДД</b>	-0,148336	0,292902	-0,385	0,7593	-0,50644	0,62621

Регрессионная модель для зависимой переменной: Выручка.

Коэффициент детерминации ( $R^2$ ) = 0,88.

Скорректированный коэффициент детерминации (*Adjusted*  $R^2$ ) = 0,82.

Значение критерия Фишера для коэффициента детерминации  $F(4,8) = 14,531$




Рис. 4. Динамика факта и вариантов прогноза по модели ИНС и модели регрессии

Для сравнения качества прогноза построим соответствующую регрессионную зависимость (табл. 4). Сравнение динамики факта и различных вариантов прогноза (модель ИНС и регрессионная модель) приведено на рис. 4.

Несмотря на визуальную согласованность всех трех графиков, сравнение суммы квадратов ошибок в регрессионной модели (696,29) значительно выше, чем в модели ИНС (456,50).

Лучшее качество нейросетевой модели объясняется неочевидными и нелинейными зависимостями между факторами и искомой переменной, которые нейронная сеть выявляет эффективнее. С увеличением количества факторов эффективность нейронной сети по сравнению с регрессионными моделями увеличивает-

ся. При этом нейронной сети требуется меньше статистической информации о предметной области для настройки модели.

В частном случае модели нейронных сетей по виду могут быть сведены например к регрессионным моделям, однако не стоит забывать, что процесс получения этих уравнений принципиально отличается.

Среди прочих распространённых статистических методов, подобные поставленной в статье задачи, могут быть решены с использованием модифицированных моделей временных рядов с учетом эндогенных параметров. Однако такие модели будут достаточно субъективны и ограничены в своем применении в силу отсутствия способности к обучению. Нейронная сеть может учитывать те же параметры, что и модели временных рядов, но в силу свойства адаптивности выбирает оптимальные варианты связей в процессе обучения без субъективного фактора аналитика.

Обращаясь к парадигмам прогнозирования, отметим, что в экономике выделяют технический подход (будущее поведение показателя однозначно определяется на основе исторической динамики и текущих тенденций) и фундаментальный (прогноз должен быть основан только на базовых закономерностях системы). Нет никакой причины ограничить нейронную сеть любой из этих теорий. У аналитика могут быть собственные наборы объясняющих факторов, которые включают цену на продукцию в текущем месяце, цену в прошлом месяце, и 3 месяца назад, сезонный фактор, индекс потребительских цен в текущем месяце и прошлом месяце, уровень безработицы, политический климат, и т.д. Аналитики редко используют все эти показатели, потому что это слишком перегружает модель, но нейронные сети хорошо справляются с большим объемом данных.

Аналитик можете добавить традиционные математические методы к нейросетевым моделям. Например, к анализирующей тенденции сети аналитик может добавить информацию, основанную на скользящих средних значениях. Создание скользящих средних значений помогает построить сети, которые зависят от текущих значений и предшествующих им. В более сложном случае синтеза нейронных сетей и традиционных статистических методов могут быть выделены отдельные нейроны, отвечающие за определенные математические преобразования: удаление сезонности, авторегрессию, долгосрочные тенденции и т.п.

Особенно ценным нейросетевые алгоритмы делает способность предсказывать социальную динамику. Поведение потребителей является результатом воздействия на личность множества окружающих раздражителей. Под влиянием этих раздражителей сознание формирует определенный образ – некоторое ментальное отражение окружающей действительности. Совокупность этих образов формирует в социальной системе некий аффективный аналог физического понятия «энергия». Как и любая другая, эта «энергия» находит свой выход, в данном случае в потребительском поведении. Формирование прогноза при такой постановке задачи представляется невозможным для традиционных методов математической статистики. Нейронная сеть, в основе которой лежит принцип работы человеческого мозга, способен симитировать такой процесс.

Стоит отметить, что нейросетевые технологии обладают некоторыми недостатками. Наиболее существенный из них связан с непрозрачностью алгоритма расчета выходных данных. Весь процесс работы сети скрыт от пользователя. Перекладка нейросетевой модели в систему алгоритмических правил является достаточно сложным процессом. Варианты «извлечения знаний» из нейронной сети представлены в книге [2, глава 9]. Наиболее простой способ связан с удалением неэффективных связей в модели, что позволит свести количество логических правил к минимуму. Кроме того, облегчает понимание модели ее графическое представление и математическая запись, что и представлено в статье.

Ряд ученых говорит о малой вероятности вытеснения нейронными сетями остальных статистических моделей, поскольку только традиционные методы помогут досконально разобраться в изучаемом процессе. Однако этот недостаток для практических целей финансового планирования представляется несущественным.

Для более полного понимания специфики нейросетевых моделей приведем сравнительный анализ терминологии традиционных статистических моделей и моделей нейронных сетей (табл. 5.)

Таблица 5

#### ТЕРМИНОЛОГИЯ СТАТИСТИЧЕСКИХ МОДЕЛЕЙ И МОДЕЛЕЙ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Статистическая терминология	Нейросетевая терминология
Переменная	Признак
Независимая переменная	Вход сети
Предсказанная величина	Выход сети
Зависимая переменная	Целевая величина обучения
Остатки	Ошибки
Оценивание	Обучение
Критерий оценивания	Функция ошибок
Наблюдение	Обучающий паттерн

Статистическая терминология	Нейросетевая терминология
Коэффициент модели	Вес элемента
Регрессионный и дискриминантный анализ	Обучение с учителем
Кластерный анализ и понижение размерности	Обучение без учителя
Интерполяция и экстраполяция	Обобщение
Свободный член	Биас
Остаточный член	Шум
Прогноз	Предсказание

На практике трудности могут быть связаны и с человеческим фактором – нежеланием аналитика делиться эксклюзивной информацией. Это связано, прежде всего, с ростом стоимости работника, обладающего такими знаниями. Однако этот конфликт должен быть разрешен менеджментом, поскольку такие важные процессы, как стратегическое планирование и бюджетирование должны быть четко описаны во внутренних методических и регламентных документах компании. Применение незадокументированных алгоритмов в процессе финансового планирования может привести к серьезным ошибкам при принятии управленческих решений на основе субъективных результатов.

Таким образом, показана возможность и целесообразность ИНС в процессе финансового планирования на предприятии. Предложенная методика не только позволяет использовать преимущества ИНС для целей финансового планирования, но и позволяет гибко реагировать на изменение эндогенных факторов деятельности предприятия. Возможность использования в модели необходимого числа факторов, в т.ч. цикличность, сезонность, авторегрессию, позволяет получить максимально обоснованный прогноз для принятия управленческих решений. При этом сравнительный анализ результатов моделирования темпа роста выручки предприятия показал преимущество нейросетевого подхода.

Предлагаемая методика обладает важной особенностью, связанную с многовариантностью прогнозов. На их основе определяется возможная реакция результатов финансово-хозяйственной деятельности предприятия на изменение как внутренних, так и внешних факторов производства и реализации продукции.

#### Литература

1. Добровольский Е. Бюджетирование: шаг за шагом [Текст] / Добровольский Е., Карабанов Б., Боровков П., Глухов Е., Бреслав Е. – СПб: Питер, 2005.
2. Ежов А.А. Нейрокомпьютеринг и его применение в экономике и бизнесе / Ежов А.А., Шумский С.А. – М: электронная книга, 1998.
3. Заенцев И. В. Нейронные сети: основные модели [Текст] / Заенцев И. В. – Воронеж, 1999.
4. Калан Р. Основные концепции нейронных сетей [Текст] / Калан Р.; пер. с англ. – М: Вильямс, 2001.
5. Хайкин С. Нейронные сети: полный курс [Текст] / Хайкин С.; пер. с англ. – М: Вильямс, 2006.
6. Щиборщ К.В. Бюджетирование деятельности промышленных предприятий России [Текст] / Щиборщ К.В. – М.: Издательство «Дело и Сервис», 2001.

#### Ключевые слова

Искусственная нейронная сеть; предприятие; финансовое прогнозирование; драйверы; финансовая модель; перцептрон; радиально-базисная функция; финансовые показатели; бюджет.

*Романовский Александр Валерьевич*

## РЕЦЕНЗИЯ

Статья Романовского А.В. «О применении искусственных нейронных сетей для прогнозирования финансовых показателей предприятия» посвящена проблеме прогнозирования финансовых показателей предприятия средствами искусственных нейронных сетей. Данный вопрос недостаточно полно рассмотрен в литературе. Между тем особая значимость для отечественных предприятий проблемы формирования качественных прогнозов является основой их конкурентоспособности. Инструменты нейросетевого моделирования заслуживают подробного рассмотрения в качестве метода прогнозирования финансовых показателей, которое представлено в статье.

Автором изложена общая концепция финансового планирования на предприятии, классифицированы финансовые показатели и предложена методика использования нейронных сетей для прогнозирования величины драйверов. Рассмотрены особенности построения нейросетевых моделей и сформированы рекомендации по их оптимальному применению.

Заключение. Представленная статья обладает научной новизной, практической значимостью и может быть рекомендована к публикации.

*Лившиц В.Н., д.э.н., зав. лабораторией «Системный анализ эффективности отраслей естественной монополии» ИСА РАН*