

УДК 338.45 : 330.4

ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ ПРОГНОЗИРУЮЩЕЙ МОДЕЛИ СПРОСА НА ПРОДУКЦИЮ ПРОМЫШЛЕННОГО ПРЕДПРИЯТИЯ*Цона Н.В.*

Предложена схема прогнозирования спроса на продукцию промышленного предприятия с помощью нейронной сети. Рассмотрены и обоснованы этапы построения модели нейронной сети для прогноза спроса на продукцию.

Ключевые слова: нейронные сети, спрос, прогнозирование, прогнозирование спроса, промышленное предприятие.

Эффективность функционирования промышленных предприятий в условиях рыночной экономики в значительной степени зависит от того, насколько достоверно они предвидят перспективу своего развития. В зависимости от степени конкретности и характера воздействия на ход исследуемых процессов можно выделить три формы предвидения: гипотеза, прогноз, план. В отличие от гипотезы, прогноз основывается на количественных показателях, поэтому выражает предвидение на прикладном уровне. Непосредственно процесс разработки прогноза является прогнозированием. Нейросетевые модели прогнозирования дают возможность предвидеть поведение на рынке самих потребителей, систем и процессов, которые подчиняются определенным законам и могут быть заданы базой данных.

Использование нейронных сетей в прогнозировании дает два основных преимущества над остальными алгоритмами: во-первых, легко исследовать зависимость прогнозируемой величины от независимых переменных. Например, если предположить, что продажи в следующем месяце зависят от следующих параметров: продаж в предыдущий месяц, продаж в предпоследнюю неделю, количества рабочих дней, сезонных факторов, имеют тренд, зависят от активности конкурентов, то большая часть классических методов прогнозирования будет несостоятельной за счет субъективного выбора модели или негибкости. Использование же нейросетевой архитектуры и базы данных, позволяет получить работающую систему прогнозирования. Второе преимущество нейронных сетей состоит в том, что построение нейросетевой модели происходит адаптивно во время обучения, без участия эксперта.

Весомый вклад в разработку теории и практики прогнозирования внесли отечественные и зарубежные ученые, среди них Ежов А.А., Шумский С.А., С. Хайкин и другие [1-3]. Однако вопросы построения нейросетевых моделей прогнозирования спроса на продукцию промышленных предприятий не нашли отражения в существующих научных трудах. В связи с этим, целью статьи является построение нейросетевой модели прогнозирования спроса на продукцию промышленного предприятия, в рамках которой будут обоснованы этапы построения нейронной сети, разработана схема архитектуры персептрона.

Основой для прогнозирования спроса на продукцию промышленных предприятий (первый этап) является выбор показателей, характеризующих особенности функционирования отрасли и самого предприятия, в т.ч. с учетом специфических аспектов. Последние подразумевают как включение отраслевых особенностей, так и стадий развития отрасли и предприятия, а также жизненного цикла выпускаемой продукции [4]. Процедура прогнозирования рыночного спроса с помощью нейронной сети представлена на рис. 1.

Согласно рис. 1, второй этап состоит в построении и обучении нейронной сети. Как отмечено выше, прогнозирование спроса на продукцию предприятия с использованием нейронных сетей является сложной многоаспектной проблемой, включающей в себя задачи описания динамики состояний объекта в нормальных режимах функционирования, в условиях неопределенности, ограничений по ресурсам [2].

Подходы к построению нейросетевых моделей можно разделить на следующие группы:

- (1) конструирование сети Хопфилда, которая представляется как реализация некоторого алгоритма оптимизации;
- (2) использование многослойного персептрона, когда сеть обучается неявными оптимизационными методами (процесс обучения предполагает формирование правил для соответствия

выходных сигналов сети различным состояниям объекта или процесса исследования).




Рис. 1. Схема прогнозирования спроса на продукцию предприятия с помощью нейронной сети

На практике наибольшее распространение получил второй вариант, поскольку затратив время на обучение нейросетевой модели, очередной результат можно получить мгновенно [3].

Построение нейронной сети осуществляется в несколько этапов. Как видно из рис. 2, первым этапом построения нейронной сети для прогнозирования спроса на продукцию промышленного предприятия является формированием обучающей выборки (т.е. подготовка и анализ исходных данных).



Рис. 2. Этапы построения нейронной сети

Обучающая выборка представляет собой набор наблюдений, для которых указаны значения входных и выходных переменных. Определить количество переменных, характеризующих величину прогнозируемого значения спроса на продукцию промышленных предприятий, можно, используя методы экспертного оценивания. При этом возникает проблема проверки достаточности и правильности выбора переменных.

Нейронные сети работают с бинарным типом данных. Это создает проблемы в случаях, когда данные имеют нестандартный масштаб, когда в них имеются пропущенные значения или когда данные являются нечисловыми. В таком случае числовые данные масштабируются в подходящий для сети диапазон или нормируются, а пропущенные значения заменяются на среднее значение этой переменной [5].

Для временного ряда показателя $X(t_1), \dots, X(t_m)$ оценивается максимальное (X_{max}) и минимальное (X_{min}) значения. Тогда для приведения данных к бинарному виду следует воспользоваться формулой:

$$\tilde{X}(t_i) = \frac{X(t_i) - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Нечисловые данные других типов преобразовываются в числовую форму (для этого осуществляется переход от качественных значений к одной из слабых шкал).

В ходе анализа значений обучающей выборки выявляются недостоверные или «аномальные» данные. К последним относятся значения, существенно отличающиеся от среднего диапазона изменения всех данных. Аномальные данные могут быть заменены на среднее значение переменной, если же данных не так много, то можно составить выборку с пропущенными значениями.

Существенной проблемой при обучении нейронной сети является вопрос определения количества наблюдений для получения удовлетворительного результата. Существуют различные подходы к определению количества исходных наблюдений (например, возможно построение ряда эвристических правил, которые указывают на связь количества наблюдений с размерами нейронной сети). Следует учесть, что это число зависит также от (заранее неизвестной) сложности того отображения, которое нейронная сеть стремится воспроизвести. Очевидно, что с ростом количества переменных количество требуемых наблюдений растет нелинейно.

Второй этап построения нейронной сети для прогнозирования спроса на продукцию промышленных предприятий – выбор архитектуры нейронной сети. Как уже отмечалось ранее, для построения нейросетевых моделей применяются многослойные персептроны. Общая схема данного типа архитектуры нейронной сети приведена на рис. 3.




Рис. 3. Принципиальная схема архитектуры персептрона

В качестве входных показателей на рис. 3 для прогнозирования спроса продукции используются известные значения показателей X^n , влияющие на прогнозируемую величину Y .

На втором этапе построения нейронной сети определяется ее структура. В персептроне нейроны регулярным образом организованы в слои, причем элементы каждого слоя связаны только с нейронами предыдущего слоя и информация распространяется от предыдущих слоев к последующим. Выбор количества слоев сети, а также числа нейронов в каждом слое влияют на способность сети решать соответствующие задачи.

Если строимая нейронная сеть имеет L нейронов во входном слое и по n_j нейронов в каждом (j -м) скрытом слое ($j=1, 2, \dots, N-2$), можно подсчитать общее количество нейронов в N -слойной сети:

$$N_Q = L + \sum_{j=1}^{N-2} n_j + 1 \quad (2)$$

где N – общее число слоев нейронной сети.

Матрица весов настраиваемых синаптических связей, связывающих нейроны i -го слоя с нейронами $(i-1)$ -го слоя, имеет вид:

$$\bar{W}^{(i)} = \begin{pmatrix} W_{11}^i & W_{12}^i & \dots & W_{1n}^i \\ W_{21}^i & W_{22}^i & \dots & W_{2n}^i \\ \dots & \dots & \dots & \dots \\ W_{n_{i-1}1}^i & W_{n_{i-1}2}^i & \dots & W_{n_{i-1}n_i}^i \end{pmatrix}$$

где $W_{kl}^{(i)}$ – вес связи, связывающей k -й нейрон $(i-1)$ -го слоя с l -м нейроном i -го слоя нейронной

сети.

$W^{(1)}, W^{(2)}, \dots, W^{(N-1)}$

равно:

$$K = n_i L + \sum_{j=1}^{N-3} n_j n_{j+1} + n_{N-2} \quad (3)$$

После определения числа слоев и элементов в каждом из них, необходимо определить значения весовых коэффициентов связей $W_{kl}^{(i)}$ для каждого составляющего нейрона, которые минимизируют ошибку прогноза, выдаваемого сетью.

Третий этап построения нейросетевой модели прогнозирования спроса на продукцию промышленных предприятий состоит в обучении нейронной сети. Алгоритм обучения (learning algorithm) выстраивает в определенном порядке синаптические веса нейронной сети для обеспечения необходимой структуры взаимосвязей нейронов. Изменение синаптических весов представляет собой традиционный метод настройки нейронных сетей.

Выделяют три основных парадигмы обучения:

- супервизорное обучение;
- несупервизорное обучение;
- усиленное обучение.

Супервизорное обучение – наиболее часто используемый вид обучения сетей и применяется для сетей, предназначенных для классификации и предсказания. Несупервизорное обучение применяется в задачах кластеризации и сегментации для поддержки принимаемого решения. Усиленное обучение находит применение в задачах оптимизации и адаптивного управления и по сравнению с другими способами обучения используется реже.

Супервизорное обучение эквивалентно программированию на примерах. При таком подходе сети задается проблема, и она ищет решение по известному соотношению «вход-выход». Здесь исследователь указывает, каким должен быть правильный ответ. Обучающий алгоритм по разнице между требуемым выходом и действительным выходом сети регулирует ее веса таким образом, что в следующий момент времени (на следующем проходе) выход сети будет ближе к правильному ответу. На входной слой сети подается вектор входных параметров, а на выходной – соответствующий этому вектору номер класса.

Примеры «вход-выход» сети должны быть предъявлены многократно прежде, чем сеть может дать точный ответ на исследуемую проблему.

Супервизорное обучение обычно используется, когда в наличии имеется база данных примеров, содержащих вход и выход. По этой базе нейронная сеть может обучиться тому, как связаны вход и выход, и на основании этого принять соответствующее решение. Цель такой тренировки заключается в минимизации ошибки между правильным и реальным выходами сети.

Супервизорное обучение является основным подходом для обучения сети выполнять классификацию, аппроксимацию функций, прогнозирование. Это свойство используется в задачах, где данные доступны в форме пар «вход-выход», но неизвестно точное преобразование для обработки входного вектора с целью получения выхода.

Несупервизорное обучение используется в ситуациях, когда имеется множество данных об объектах и возникает задача оценки сходства объектов из рассматриваемой совокупности. Перед сетью ставится задача кластеризации входных данных таким способом, чтобы похожие образы (объекты) попали в одну группу (кластер). Нейронная сеть, использующая несупервизорное обучение, может решать такую задачу с большой точностью.

Обычно сеть с таким способом обучения состоит только из входного и выходного слоев, причем количество нейронов в первом слое определяется размерностью входного вектора, а во втором – числом предполагаемых классов, на которые желательно разбить исходную совокупность. Ячейки выходного слоя «соревнуются» между собой за право быть «победителем», которым в итоге становится нейрон выходного слоя с весами, наиболее близкими к компонентам входного вектора. В процессе обучения происходит подстройка весов, в первую очередь нейрона-победителя, с тем чтобы стать еще бли-

же к входному вектору. Здесь ячейка-победитель является, по существу, меткой класса, к которому отнесен входной вектор. Нейронные сети, которые обучаются таким методом, называются самоорганизующимися, поскольку они не получают указаний относительно требуемого выхода. При предъявлении входного образа сеть посредством конкуренции и регулирования весов относит образ к одному из существующих уже кластеров или к новому классу.

В сетях с супервизорным обучением предполагается, что имеется информация о правильных выходных значениях для каждого входного образа. Но в некоторых ситуациях доступна менее детальная информация. В предельном случае может быть только один бит информации: выход правильный или неверный. В таких условиях используется процедура усиленного обучения. Последнее является формой супервизорного обучения, так как сеть получает некоторую обратную связь из окружающей среды. Но эта обратная связь (бинарный сигнал усиления) служит лишь оценкой, но не инструкцией к поведению сети.

При использовании этой парадигмы полагают работу нейронной сети в определенной внешней среде. Среда формирует входы в сеть, получает выходы сети и затем определяет сигнал усиления r . Здесь есть несколько проблем, зависящих от характера окружающей среды.

1. В самом простейшем случае сигнал усиления r всегда одинаков для данной пары вход-выход. Таким образом, в этом случае имеется конкретное отображение вход-выход, которому сеть должна обучиться, или несколько таких отображений при наличии многих выходов для одного входа. Кроме того, входные образы выбираются в случайном порядке внешней средой без учета предыдущих выходов.
2. Расширение предыдущего случая – это стохастическое окружение. Здесь отдельная пара вход-выход определяет только вероятность положительного усиления. Эта вероятность является фиксированной для каждой пары вход-выход, а входная последовательность, как и в предыдущем случае, не зависит от прошлой истории. Подобные проблемы часто возникают в моделировании поведения, экономических системах, некоторых простых играх.
3. В самом общем случае внешняя среда может сама управляться сложным динамическим процессом. Здесь сигналы усиления и входные образы могут зависеть произвольным образом от прошлой истории сетевого выхода.

Алгоритм обучения представляет процедуру, в которой используются правила обучения для настройки весов. Известны четыре основных типа правил обучения:

- правило Хебба;
- коррекция по ошибке;
- метод конкуренции;
- машина Больцмана.

Правило Хебба является одним из первых обучающих правил и представляет собой постулат Хебба: если нейроны с обеих сторон синапса активизируются одновременно и регулярно, то сила синаптической связи возрастает. Важная особенность этого правила состоит в том, что изменение синаптического веса зависит только от активности нейронов, которые связаны данным синапсом.

Коррекция по ошибке используется в сетях супервизорного обучения. Для каждого входного примера задается требуемый выход t . Реальный выход сети y может не совпадать с требуемым, откуда следует принцип коррекции ошибки при обучении: для модификации весов, обеспечивающей постепенное уменьшение ошибки, используется сигнал $(t-y)$. Обучение проводится только в том случае, если сеть на выходе выдает сигнал, отличный от требуемого.

При обучении методом конкуренции нейроны выходного слоя соревнуются между собой за право стать активным. В результате только нейрон-победитель (тот нейрон, весовой вектор которого ближе всех к входному вектору) получает право на изменение своих весовых коэффициентов. Обучение посредством конкуренции позволяет кластеризовать входные данные: сходные образы группируются сетью в соответствии с корреляциями и представляются одним элементом (меткой кластера).

Машина Больцмана представляет собой стохастическое правило обучения, которое следует из информационных теоретических и термодинамических принципов. При адаптации производится настройка весовых коэффициентов, при которой состояния нейронов удовлетворяют желаемому рас-

пределению вероятностей (в частности, распределению Больцмана). Обучение Больцмана может рассматриваться как специальный случай коррекции по ошибке, в котором под ошибкой понимается расхождение корреляций состояния в двух режимах.

Для решения задач прогнозирования наиболее часто применяются алгоритмы контролируемого обучения: Back Propagation, Levenberg-Marquardt, Quick Propagation, Delta-Bar-Delta [3].

Построение нейросетевой прогнозирующей модели предполагает тестирование обученной сети. Для тестирования необходимо сформировать тестовую выборку, которая не использовалась в обучении сети. Необходимым условием формирования выборки является наличие в ней известных значений выходных параметров, которые будут сравниваться с результатами тестирования. Если результаты тестирования соответствуют значениям выходных параметров (для тестовых выборок) с малой величиной ошибки, то построенная сеть адекватна и может использоваться для решения задачи прогнозирования.

Согласно рис. 2 после обучения нейронной сети проводится опрос экспертов о возможных будущих значениях показателей, характеризующих состояние экономики или отрасли (четвертый этап). Полученные значения используются в качестве входных параметров для обученной нейронной сети. Результатом работы нейронной сети является прогнозное значение величины спроса на продукцию промышленного предприятия (пятый этап).

Сравнение фактического значения спроса на продукцию промышленного предприятия с прогнозным позволяет оценить точность и адекватность работы нейронной сети (шестой этап). При превышении ошибки прогноза заданного уровня осуществляется либо повторное обучение нейронной сети, либо производится процедура повторного выбора показателей, характеризующих отдельную отрасль или экономику в целом.

ВЫВОДЫ

Предложенная модель позволяет построить нейронную сеть, которая является основой для прогнозирования спроса на продукцию промышленного предприятия. Кроме имманентно присутствующих преимуществ нейронной сети, полученный этим способом инструментарий позволяет быстро учитывать изменения во внешней среде и отражать их в величине прогноза. Этому способствует привлечение к процедуре прогнозирования экспертов, указывающих на характер динамики ключевых факторов спроса исходя из собственного практического опыта и слабых сигналов внешней среды, которые не могут быть отражены количественно. При этом возникает проблема субъективности полученных оценок, а также определения согласованности мнений экспертов. Последняя задача может быть также решена методами нейросетевого моделирования.

Другим важным преимуществом является то, что данный подход опирается на причинно-следственные связи, а не на «механический» прогноз, т.е. рассматривающем в качестве причины изменения исследуемого показателя порядковый номер периода. Это особенно важно в условиях высокой турбулентности, которой характеризуется внешняя среда современного промышленного предприятия.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Медведев В.С. Нейронные сети. Matlab 6 / В.С. Медведев, В.Г. Потемкин. – М.: Диалог – МИФИ, 2002 – 489 с.
2. Ежов А.А. Нейрокомпьютинг и его применение в экономике и бизнесе / А.А.Ежов, С.А. Шумский. – М.: МИФИ, 1998. – 222 с.
3. Хайкин С. Нейронные сети. Полный курс / С. Хайкин. – М.: Вильямс, 2006. – 1104 с.
4. Цопа Н.В. Оценка развития промышленных предприятий: моногр. / Н.В. Цопа / НАН Украины. Институт экономики промышленности. – Донецк – Симферополь: ИТ «АРИАЛ», 2009. – 184 с.
5. Терехина А.Ю. Анализ данных методами многомерного шкалирования / А.Ю. Терехина. – М.: Наука, 1986. – 168 с.