ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ В ЭКОНОМИЧЕСКОМ АНАЛИЗЕ

А. В. Шаталина, А. В. Рогачева

Саратовский национальный исследовательский государственный университет им. Н. Г. Чернышевского, Россия
E-mail: mexmat@sgu.ru, arinafox97@mail.ru

В данной статье рассматривается построение модели искусственной нейронной сети для решения задачи прогнозирования экономических показателей и дальнейший анализ полученных данных. Проанализированы основные методы прогнозирования, рассмотрены особенности нейронных сетей и алгоритмов обучения, определены программные средства для практической реализации поставленной задачи.

THE USAGE OF NEURAL NETWORKS IN ECONOMIC ANALYSIS

A. V. Shatalina, A. V. Rogacheva

This article shows the methods of constructing an artificial neural network to solve the problems of forecasting economic indicators and the subsequent analysis of the obtained data and the basic methods of forecasting. Considered the features of neural networks and training algorithms and also indicated software tools for the practical implementation of the task.

Одним из наиболее актуальных вопросов на сегодняшний день является исследование временных рядов. Временной ряд представляет собой собранный в разные моменты времени статистический материал о значениях каких-либо параметров. Основная работа с временными рядами подразумевает их прогнозирование. Существуют различные методы прогнозирования. Одним из наиболее простых является метод экспертной оценки. Он отражает индивидуальное мнение специалистов относительно дальнейшего развития объекта, но этот метод требует профессиональных знаний и опыта работы, а привлечение специалиста к работе может быть проблематично.

Наряду с экспертными методами существуют адаптивные, к которым относятся:

– экспоненциальное сглаживание;
– АРПСС (ARIMA, autoregressive integrated moving average);
– регрессионные модели;
– искусственные нейронные сети.

В отличие от экспертных методов прогнозирования, адаптивные методы могут непрерывно учитывать изменение динамических характеристик и процессов. При построении долгосрочного прогноза стандартные статистические методы прогнозирования практически не используют и требуется использование комплексных подходов:

– нейронных сетей;

– регрессионных моделей.

Нейронные сети – это очень мощный и гибкий механизм прогнозирования. При определении того, что нужно прогнозировать, необходимо указывать переменные, которые анализируются и предсказываются. Здесь очень важен требуемый уровень детализации. На используемый уровень детализации влияет множество факторов: доступность и точность данных, стоимость анализа и предпочтения пользователей результатов прогнозирования. В ситуациях, когда наилучший набор переменных неясен, можно попробовать разные альтернативы и выбрать один из вариантов, дающий наилучшие результаты [1,2].

При использовании нейронных сетей легко, по сравнению с другими методами, исследовать зависимость прогнозируемой величины от независимых переменных. В такой постановке задачи большая часть классических методов прогнозирования будет просто несостоятельной. Используя же даже самую простую нейросетевую архитектуру, персептрон с одним скрытым слоем и базу данных с транзакциями, легко получить работающую систему прогнозирования. При этом учет системой внешних параметров будет зависеть от соответствующего входа в нейронную сеть. Если учет внешних параметров не требуется его легко отключить, исключив необходимый вход в нейронную сеть [3].

Еще одно серьезное преимущество нейронных сетей состоит в том, что построение нейросетевой модели происходит адаптивно во время обучения, без участия эксперта. При этом нейронной сети предъявляются примеры из базы данных, и она сама подстраивается под эти данные.

Искусственный нейрон в первом приближении имитирует свойства биологического нейрона. Множество входных сигналов, обозначенных $x_1, x_2, ..., x_n$, поступает на искусственный нейрон. Эти входные сигналы, в совокупности обозначаемые вектором *X*, соответствуют сигналам приходящим в синапсы биологического нейрона. Каждый синапс характеризуется величиной синапсической связи или ее весом ω_i. Каждый сигнал умножается на соответствующий вес $\omega_1, \omega_2, ..., \omega_n$ и поступает на суммирующий блок. Каждый вес соответствует «силе» одной биологической синапсической связи. Суммирующий блок, соответствующий телу биологического элемента, складывает взвешенные входы алгебраически, создавая величину *S*. Таким образом, текущее состояние нейрона определяется как взвешенная сумма его входов

$$S = \sum_{i=1}^{n} x_i \omega_i \ .$$

Выход нейрона - это функция его состояния, она имеет вид

$$y = f(s),$$

где *f* – активационная функция, моделирующая нелинейную передаточную характеристику биологического нейрона. Такими функциями могут быть: пороговая, линейная, логистическая, гиперболический тангенс, линейная с насыщением [4].

Обучение нейронной сети – это процесс, в котором свободные параметры

нейронной сети настраиваются посредством моделирования среды, в которую эта сеть встроена.

Существует три типа обучения ИНС:

– с учителем;

– без учителя или самообучение;

– смешанное (методом критики).

Для каждого случая разработаны свои обучающие правила (коррекция ошибки, Больцман, Хебб, соревнование), архитектура (однослойный и многослойный перцептрон, рекуррентная, многослойная прямого распространения, сеть Хопфилда, сети ART, RBF), алгоритмы обучения (алгоритмы обучения перцептрона, обратное распространение Adaline и Madaline, алгоритм обучения Больцмана, линейный дискриминантный анализ, векторное квантование, ARTMap, проекция Саммона, анализ главных компонентов, обучение ассоциативной памяти, алгоритм обучения RBF) и задачи (сжатие и анализ данных, классификация образов и тд) [5].

Принципиальную возможность реализации сколь угодно сложных зависимостей с помощью относительно простых автоматов типа нейронных сетей доказывает теорема Колмогорова. Она показывает, что для реализации функций многих переменных достаточно операций суммирования и композиции функций одной переменной.

Существует множество программных средств, которые позволяют исследовать нейронные сети. Использование различных встроенных функций и инструментов позволяет провести подробный анализ выбранной нейронной сети. В данной работе будет применен MATLAB версии R2019b 9.6, для 64-bit систем. В нем существует визуальный инструмент для тестирования и оценки искусственных нейронных сетей - Neural Network Start, который предоставляет исследователю возможность выбрать из представленных областей задач нужную и воспользоваться подготовленным списком моделей, подходящих для ее решения.

В версии R2019b представлены следующие модели:

– модель многослойного персептрона, для простого анализа данных и выявления зависимостей;

– модели для классификации;

– модели для кластеризации;

– модели для анализа временных рядов.

Для обучения сети необходимо ввести выбранный набор данных. Он делится на участки, на которых сеть обучается, тестируется и проверяется. По умолчанию это соотношение 70/15/15, но его можно менять в соответствии с желанием исследователя. После обучения выводится среднеквадратичное отклонение и множественный коэффициент корреляции.

Для прогнозирования временных рядов представлены следующие алгоритмы обучения:

– Levengerg - Marquard;

– Bayesian Regulazation;

– Scaled Conjugate Gradient.

Levengerg - Marquard – алгоритм обучения сети с обратным распространением ошибки, который модифицирует веса и смещения в соответствии с оптимизацией Левенберга - Марквардта. Чаще всего является самым быстрым алгоритмом для обучения, однако может потреблять наибольшее количество ресурсов машины. Данный алгоритм обучения рекомендован создателями MATLAB, как алгоритм которым лучше воспользоваться, если дополнительных аргументов в пользу других методов нет.

Bayesian Regulazation – алгоритм обучения сети, который обновляет веса и смещения в соответствии с оптимизацией Левенберга - Марквардт. Это минимизирует сочетание квадратов ошибок и веса, а затем определяет правильную комбинацию таким образом, чтобы сеть имела наибольшую степень обобщения. Процесс называется Байесовская регуляризация. Рекомендован при использования более сложных массивах данных, на которых алгоритм Levengerg-Marquard не справляется.

Scaled Conjugate Gradient – алгоритм обучения сети, который модифицирует веса и смещения в соответствии с масштабированным методом сопряженных градиентов. Может обучать любую сеть, если ее весовые, входные и передаточные функции имеют производные функции. Рекомендован для использования при построении сети на самых сложных массива данных.

Для дальнейшей оценки нейронной сети могут быть построены различные графики, иллюстрирующие количественные оценки моделей (график регрессии, гистограмма ошибок, график автокорреляции и производительности, Time Series Response) [6].

Задача прогнозирования решалась на реальных данных, а именно, используя теорию, приведенную выше, была смоделирована ситуация планирования продаж в ООО «Мегаполис - Топливная группа».

Для задачи прогнозирования была создана выборка, содержащая количество закупленного топлива по дням за 2017 год. Объем выборки значений 365, что соответствует количеству ежедневных отчетов о поступлениях денежных средств. Вид временного ряда обусловлен особенностью работы компании. Компания работает по контрактам, и оплата по ним совершается тремя разными способами. Оплата за топливо приходит с задержкой от 3 до 180 дней. Так же на график влияют текущие клиенты: они могут быть как мелкими, так и крупными.

В ходе анализа были рассмотрены несколько моделей, различное количество нейронов, а также различная задержка прогнозирования, связанная с особенностями рассматриваемых моделей.

Тестовая выборка была поделена на три части в соотношении 70/15/15. Производился перебор от 2 до 8 нейронов.

Оценка качества модели заключалась в количественном сравнении значения среднеквадратичной ошибки и значения регрессии. Из представленных

моделей необходимо было выбрать наиболее эффективную. По итогу была выбрана модель нелинейной авторегрессии с внешними входами при задержке 10 и количестве персептронов на слое 6. Гистограмма ошибок и график автокорреляции показал, что все ошибки распределены по нормальному закону, что говорит о правильности подобранной модели.

СПИСОК ЛИТЕРАТУРЫ

Галушкин А. И. Нейронные сети: основы теории. М. : Горячая линия-Телеком, 2010. 496 с.

Аксенов С. В., Новосельцев В. Б. Организация и использование нейронных сетей (методы и технологии). М. : НТЛ, 2006. 128 с.

Каллан Р. Основные концепции нейронных сетей. М : Вильямс, 2002. 287с.

Круг П. Г. Нейронные сети и нейрокомпьютеры. М. : МЭИ, 2002. 176 с.

Хайкин С. Нейронные сети. Полный курс. М. : Вильямс, 2006. 1104 с.

Matlab Third Edition: A Practical Introduction to Programming and Problem Solving / Stormy Attaway Ph. D. Boston University. Butterworth-Heinemann, 2013.