

ОПТИМАЛЬНЫЕ АЛГОРИТМЫ ПРОГНОЗИРОВАНИЯ БИЗНЕС-ПРОЦЕССОВ

Бык О. В.

Кафедра систем управления, Белорусский государственный университет информатики и радиоэлектроники
Минск, Республика Беларусь
E-mail: bykalgerd@gmail.com

В данной статье автором рассматриваются основные классические и современные алгоритмы прогнозирования бизнес-процессов.

ВВЕДЕНИЕ

В настоящее время все более широкое применение находят алгоритмы для прогнозирования бизнес-процессов. С каждым годом конкуренция на рынках продуктов становится все более серьезной и все большее значение имеет правильное прогнозирование наперед различных тенденций и итогового результата. Как правило, алгоритмы прогнозирования достаточно тривиальны – осуществляется сбор исторических данных за прошлые периоды и на их основе составляются прогнозы на будущие периоды. Подобные методы являются действенными и успешными, однако ввиду постоянно усиливающейся конкуренции на рынке, в связи с чем такие алгоритмы прогнозирования становятся все более актуальными.

I. КЛАССИЧЕСКИЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ

Большинство методов, которые используются при решении задач искусственного интеллекта, базируются на регрессионных моделях и методах или используют их в качестве составных элементов. Важной их особенностью является развитый математический аппарат, с помощью которого можно оценивать качество построенных моделей, в частности, их точность и адекватность. Построение и исследование трех видов моделей: парной линейной регрессии (см. рис. 1), множественной линейной регрессии и некоторых типов нелинейной парной и множественной регрессии базируется на использовании метода наименьших квадратов. Вместе с тем, адекватное его применение требует выполнения определенного ряда предпосылок.

Метод наименьших квадратов (МНК), вне всяких сомнений, является тем классическим методом, с которого рационально начинать представление и обоснование методов прогнозирования. Он предназначен для оценки неизвестных величин по результатам измерения или экспериментов, содержащих случайные ошибки, и применяется для приближенного представления заданной функции другими (более простыми) функциями при обработке данных наблюдений. МНК предложен К. Гауссом и А. Лежандром.




Рис. 1 – Парная регрессия

Для данного метода используются критерии оценки по минимуму суммы квадратов отклонений значений y , а также поиска минимума и максимума значений y . Применение первого из них направлено на уменьшение влияния отдельных «выбросов», а второго – приводит к более равномерному приближению во всех точках. Иное объяснение состоит в том, что они отвечают наблюдениям в условиях помех с разными статистическими свойствами. Если значения исходной характеристики определяются с точностью до нормально распределенного случайного слагаемого, то для оценивания коэффициентов используется первый функционал. Его применение оправдано также в условиях, если ошибка измерений распределена по закону Лапласа. Если слагаемое распределено нормально в некотором интервале, то для оценки параметров регрессии необходимо использовать второй функционал [1].

II. НЕЙРОСЕТЕВЫЕ МЕТОДЫ И ИСПОЛЬЗОВАНИЕ ИХ ДЛЯ ПРОГНОЗИРОВАНИЯ

В последние несколько лет мы наблюдаем взрыв интереса к нейронным сетям которые успешно применяются в самых различных областях – бизнесе, медицине, технике, геологии, физике. Нейронные сети вошли в практику везде, где нужно решать задачи прогнозирования, классификации или управления. Такой впечатляющий успех определяется несколькими причинами. Во-первых, нейронные сети – исключи-

тельно мощный метод моделирования, позволяющий воспроизводить чрезвычайно сложные зависимости. В частности, нейронные сети нелинейны по своей природе. На протяжении многих лет линейное моделирование было основным методом моделирования в большинстве областей, поскольку для него хорошо разработаны процедуры оптимизации. В задачах, где линейная аппроксимация неудовлетворительна (а таких достаточно много), линейные модели работают плохо. Кроме того, нейронные сети справляются с проблемой размерности, которая не позволяет моделировать линейные зависимости в случае большого числа переменных. Во-вторых, нейронные сети учатся на примерах. Пользователь нейронной сети подбирает представительные данные, а затем запускает алгоритм обучения, который автоматически воспринимает структуру данных [2].

Для прогнозирования бизнес-процессов популярно использование сетей встречного распространения (СВР). Данные сети предназначены для начального быстрого моделирования (см. рис. 2). Автор СВР Роберт Хехтнильсен.




Рис. 2 – Сети встречного распространения

СВР работает с векторами, значениями которых являются непрерывные величины или двоичные, то есть такие, которые состоят из нулей и единиц. В результате обучения входные векторы ассоциируются с векторами на выходе сети и, если сеть обучена, подача входных образов приводит к получению результирующих образов.

СВР работает в двух режимах: обучения и использования. В первом случае на входы подаем и вектор X , и вектор Y , корректируем весовые коэффициенты; во втором режиме на вход уже обученной сети подаем X или Y , а на выходе получаем значения и X , и Y . Рассмотрим аспекты алгоритма функционирования СВР. Пер-

вое: нормируем каждый элемент таблицы. Далее генерируем случайным образом весовые коэффициенты и обязательно их нормируем, тем самым, сокращая процесс обучения. Здесь существует несколько нюансов, о них можно прочитать, например, в известной книге Ф. Уоссермана, а также частично ниже. После подаем на вход сети строку матрицы Z и рассчитываем скалярные произведения с векторами весовых коэффициентов, которые связаны со всеми нейронами слоя Кохонена. Среди всех скалярных произведений выбираем произведение с максимальным значением и настраиваем вес соответствующего нейрона. Выход нейрона, который выиграл, равен единице, все остальные – нулю. Значения выходного вектора слоя Кохонена подаются на слой нейронов Гроссберга. В каждом нейроне слоя Гроссберга обычным способом рассчитывается активация, корректируем все веса слоя Гроссберга и выводим результаты.

Применение такого алгоритма обучения является проблематичным, если значительное количество обучающих шаблонов образует совокупность незначительных размеров в области обучения. В таком случае результат работы классического алгоритма будет правильным и необходимо применять предварительную обработку данных [3].

Применение нейронных сетей для прогнозирования является перспективным в случае существования сложных нелинейных зависимостей со значениями факторов, на которые не наложено ни одного ограничения. Вместе с тем, необходимо заметить, что получение высокоточных результатов возможно только при наличии квалифицированных специалистов, поскольку необходимым условием эффективного функционирования нейросети является формализация задачи, предварительная подготовка данных и обеспечение избежания исключительных ситуаций [4].

III. ЗАКЛЮЧЕНИЕ

Были рассмотрены и проанализированы основные алгоритмы прогнозирования бизнес-процессов, начиная от алгоритмов, созданных на первых этапах, и заканчивая наиболее актуальными и перспективными алгоритмами нейронных сетей для построения прогнозов. Оценена актуальность использования нейронных сетей для прогнозирования бизнес-процессов.

1. Снытюк В. В. Прогнозирование. Модели, методы, алгоритмы / В. В. Снытюк – Киев: Национальный Университет имени Тараса Шевченко, 2008.
2. Назаров А. В., Лоскутов А. И. Нейросетевые алгоритмы прогнозирования и оптимизации систем / Назаров А. В., Лоскутов А. – Москва, 2017.
3. Хайкин С. Нейронные сети / Хайкин С. – Издательский дом "Вильямс 2006.
4. Бугорский В. Н. Использование нейронных сетей в работе трейдера / Бугорский В. Н. – Москва, 2011.