

ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ ПЛАТЕЖЕСПОСОБНОСТИ КОНТРАГЕНТОВ ОРГАНИЗАЦИИ

На современном этапе многие коммерческие организации и предприятия получают множество проблем от просроченных сумм дебиторской задолженности своих клиентов и контрагентов. Чтобы избежать дальнейшего наращивания задолженности текущих клиентов нужно правильно оценить их платежеспособность, до момента возникновения потребности клиента в услугах организации или в реализуемых ею товарах. Таким образом, ставится задача получения комплексного анализа платежеспособности клиента на основании имеющихся у организации данных о клиенте. Проект предлагает создание программного решения, базирующегося на нейросетевых технологиях, реализуемого в виде приложения к стандартной конфигурации 1С: Предприятие.

Ключевые слова: Нейросетевые технологии, анализ контрагентов, финансовые риски, прогнозирование, дебиторская задолженность, нейронные сети, многослойный перцептрон, программное решение.

E. G. Zaguzina

BUILDING A NEURAL NETWORK MODEL PREDICTION SOLVENCY COUNTERPARTIES

At the present stage, many commercial organizations and enterprises get a lot of problems on the outstanding amounts of receivables of its customers and counterparties. To avoid further compounding the debt current clients need to properly assess their ability to pay, until the appearance of the client's needs in the services organization or products sold by it. Thus, the task of producing a comprehensive analysis of the client's solvency on the basis of available data on the client organization. The project proposes the creation of software solutions, based on neural network technologies implemented in an annex to the standard configuration 1С: Enterprise.

Keywords: Neural network technology analysis of the counterparties, financial risks, forecasting, accounts receivable, neural network, multilayer perceptron, a software solution.

Выбор надежных деловых партнеров является одним из главных факторов результативной хозяйственной деятельности коммерческих организаций, функционирующих в условиях рыночной экономики. Выбор партнеров при организации цепочек поставок и реализации товара, анализ объектов инвестиций или выбор соисполнителей для действующих контрактов — это типичные задачи, в которых лицам, принимающим решения, требуется оценить финансовое состояние большого числа текущих контрагентов [1, с. 1–3]. Не менее важным является мониторинг финансового состояния текущих клиентов организации, позволяющий принимать правильное решение при повторном обращении клиента в организацию. Так, в случае накопления больших сумм дебиторской задолженности или большого количества дней просрочки в прошлых периодах, у организации возникает финансовый риск неполучения денежных средств за оказанные услуги или реализацию товара. Посколь-

ку многие организации работают в режиме пост оплаты, вопрос о покрытии дебиторской задолженности ставится на первый план. Однако, чтобы дебиторская задолженность не являлась проблемой для организации и источником дополнительных расходов (обращения в арбитражный суд и пр.), необходимо качественно подходить к оценке того или иного контрагента на способность оплатить долг вовремя. Таким образом, ставится задача получения комплексного анализа платежеспособности клиента или контрагента на основании имеющихся у организации данных о клиенте или контрагенте соответственно.

На современном этапе статистические методы анализа постепенно уходят на второй план, и все больший интерес проявляется к нейросетевым технологиям [2, С.5-6]. Применение нейросетевой технологии уместно в случаях, когда формализация процесса решения трудна или вообще невозможна. Они являются очень мощным инструментом моделирования, поскольку нелинейны по своей природе. Кроме того, для нейронных сетей не существует проблемы «проклятия размерности», не позволяющей моделировать линейные зависимости при большом количестве переменных.

Общая постановка задачи оценки платежеспособности контрагентов представляет собой нахождение способа достоверно предсказать надежность контрагента до наступления неблагоприятных финансовых событий для организации. В качестве неблагоприятного события рассматривается положительная дебиторская задолженность в пользу организации, ее накопления по мере сотрудничества с сомнительным контрагентом [3, с. 122].

Задача оценки платежеспособности контрагентов рассматривается как задача бинарной классификации (платежеспособен или неплатежеспособен). Объектами классификации являются контрагенты, а их классы определяются по отношению к свойству платежеспособности. Признаки, на основе которых производится классификация, представляют собой достаточно специфические финансовые показатели, редко используемые при финансовом анализе, такие как [4, С. 6-8]:

- наращённая сумма дебиторской задолженности;
- первоначальная величина дебиторской задолженности;
- стоимость финансирования дебиторской задолженности;
- средний период просрочки дебиторской задолженности в днях;
- оборачиваемость дебиторской задолженности конкретного контрагента.

Основное достоинство данных параметров в том, что ими обладает каждый контрагент, ведущий деятельность с другими организациями, и в этом состоит легкость получения анализа платежеспособности той или иной организации.

Таким образом, исходя из постановки задачи построим структурную схему системы прогнозирования платежеспособности на основе метода бинарной классификации (рис. 1). Данная система построена с использованием искусственной сети прямого распространения сигнала (feed-forward network)

класса «многослойный персептрон», состоящая из трех слоев: входного, внутреннего (скрытого) и выходного [5, с. 43–45].

На вход нейронной сети поступает вектор нейронов, представляющий собой набор из представленных вышепоказателей X_n исследуемого контрагента. Внутренний слой формирует вектор признаков Y_1 , размер которого меньше размера вектора входных параметров ($n > 1$). Выходной слой преобразует вектора Y_1 из пространства признаков в вектор Z_k — вектор оценок функции принадлежности объекта к одному из K классов. В итоге, бинарный классификатор выбирает по правилу максимуманомер компоненты выходного вектора, ассоциированный с одним из predetermined классов.




Рис. 1. Структура нейронной сети бинарной классификации контрагентов

Блок обучения сети представляет собой механизм адаптации нейронной сети, производимой за счет изменения параметров нейронов скрытых и выходных слоев сети [6, с. 843].

На рис. 2 изображен нейрон внутреннего слоя, который представляет собой элемент-сумматор со смещением, имеющего нелинейную функцию активации:




Рис. 2. Структурная схема нейрона скрытого слоя

Правило вычисления вектора признаков Y_l состоит из суммирующей функции и функции активации:

$$v_l = f(b_l + w_l^T X) \tag{1}$$

где l — номер нейрона внутреннего слоя ($l=1, \dots, L$), b_l — смещение для l -го нейрона внутреннего слоя и w_l — вектор весов для l -го нейрона внутреннего слоя, а $f(v)$ — нелинейная функция активации, которая обычно задается в виде сигмоидальной, или логистической, функции:

$$Y_l = f(v) = \frac{1}{1 + e^{-v}} \tag{2}$$

Структура выходного слоя сети бинарной классификации, предназначенной для отнесения предприятий к двум классам, предполагает закрепление за каждым из выделенных классов одного из выходов [7, с. 96]. В нашем случае, контрагентов можно отнести к одному из 2 классов K (Z_1 и Z_2). Тогда компонент Z_k выходного вектора Z представляет собой оценку функции принадлежности к k -му классу для контрагента, заданного совокупностью показателей. Величина Z_k принимает значения от нуля до единицы ($0 < Z_k < 1$), при этом значения близкие к единице трактуются как высокая степень принадлежности к соответствующему классу, а близкие к нулю указывают на то, что контрагент к указанному классу не принадлежит.

Конечное решение состоит в отнесении контрагента к тому классу, для которого соответствующий компонент Z_k принимает максимальное значение среди всех компонент выходного вектора.

Построенная нейронная сеть может находиться в одном из двух режимов: в режиме использования и в режиме обучения. В режиме использования сеть работает как закрытая система («черный ящик»), на вход которой подается вектор финансовых показателей, а с выхода снимается номер класса. Однако для эффективной работы нейронной сети должны быть настроены ее параметры, а именно смещения и весовые коэффициенты внутреннего и выходного слоев. Данные параметры должны принять значения, обеспечивающие наибольшее количество правильных решений, вырабатываемых сетью. Для их нахождения используется режим обучения, в котором сеть адаптируется, т. е. ее параметры (смещения и весовые коэффициенты скрытого и выходного слоев) изменяются по результатам анализа предъявляемых сети примеров.

Традиционно обучение данной нейронной сети будет производиться по схеме обучения с учителем (supervised learning). Это значит, что в процессе обучения используются примеры, в которых соотнесены финансовые показатели и номер класса, к которому данный контрагент относится согласно мнению эксперта, обучающего сеть.

В итоге, для сети вводится целевая функция, представляющая собой сумму квадратов ошибок e_k , вычисленных как разность оценок функции принадлежности и целевых значений этой функции:

$$E = \frac{1}{2} \sum_{k=1}^K e_k^2 = \frac{1}{2} \sum_{k=1}^K (z_k - t_k)^2 \rightarrow \min \tag{3}$$

В задачах статической классификации, к которым в полной мере относится рассматриваемая задача классификации контрагентов по их платежеспособности, обычно используется пакетный режим обучения (batchmode), при котором подстройка параметров осуществляется после представления сети всей совокупности примеров обучающей выборки.

Пакетный режим обучения в отличие от последовательного (interactivemode) режима, в котором подстройка осуществляется после представления каждого примера, позволяет получить более устойчивые в статистическом смысле решения задачи минимизации целевой функции в пространстве параметров.

В общем случае подстройка некоторого параметра θ осуществляется по следующей формуле:

$$\theta_{m+1} = \theta_m + a \cdot \Delta \theta_m \quad (4)$$

где a — скорость обучения сети, θ_m — это величина желательного изменения параметра, способ вычисления которой зависит от метода обучения, а индекс m указывает на номер эпохи. С увеличением номера эпохи данный алгоритм описывает итеративный процесс изменения величины до достижения ей некоторого оптимального значения. Типичный процесс адаптации сети сопровождается плавным уменьшением величины ошибки E до достижения ей некоторой минимальной величины E_{\min} как на обучающей, так и на контрольной выборке, если последняя используется. Необходимым признаком успешного процесса адаптации, является монотонное уменьшение абсолютной величины для всех настраиваемых параметров сети, начиная с некоторого номера эпохи.

Таким образом, построенная модель нейронной сети для конечного пользователя будет являться «советующей» системой при нахождении ответа на следующие вопросы: Стоит ли оказывать услугу/продавать товар этому клиенту? Или стоит ли сотрудничать далее в этом контрагентом?

На данный момент не существует реальных моделей оценки платежеспособности организаций, основанных на достаточно специфических входных параметрах нейросети. Достоинство данных параметров в том, что ими обладает каждый контрагент, ведущий деятельность с другими организациями, и в этом состоит легкость получения анализа платежеспособности той или иной организации.

Литература

1. Санжеева Д. Д., Мункуев Б. В. Направления развития поддержки малого бизнеса в муниципальном образовании // Вестник Бурятского государственного университета. Экономика и менеджмент. 2014. № 1. С. 25–36.
2. Бартунаев Л. Р., Сергеева Т. В. Современные информационные технологии и новая экономика // Вестник Бурятского государственного университета. Экономика и менеджмент. 2012. № 1. С. 34–43.
3. Гордеев М. А. Модель управления дебиторской задолженностью // Вестник Саратовского государственного социально-экономического университета. 2010. № 5. С. 120–123.

4. Цыренов Д. Д., Стробел Д. Клиентоориентированный подход к управлению предприятием // Вестник Бурятского государственного университета. Экономика и менеджмент. 2014. № 1. С. 34–43.

5. Богданова Т. К., Шевгунов Т. Я., Уварова О. М. Применение нейронных сетей для прогнозирования платежеспособности российских предприятий обрабатывающих отраслей // Бизнес-информатика. 2013. № 2(24). С. 40–48.

6. Хайкин С. Нейронные сети: полный курс. 2-е изд., испр. / пер. с англ. М.: Вильямс, 2006. 1104 с.

7. Корнеев Д. С. Использование аппарата нейронных сетей для создания модели оценки и управления рисками предприятия // Управление большими системами: сборник трудов. 2007. № 17. С. 81–102.

Загузина Екатерина Геннадьевна, магистрант, Бурятский государственный университет, Россия, 670000, г. Улан-Удэ, ул. Смолина, 24а, E-mail: ezaguzina@yandex.ru.

Zaguzina Ekaterina Gennadevna, undergraduate, Buryat State University, 24a Smolina St., Ulan-Ude, 670000 Russia, E-mail: ezaguzina@yandex.ru.