

# Оценка кредитоспособности физических лиц при помощи инструментария классификационных нейронных сетей<sup>1</sup>

Максим ВЛАСЕНКО

УДК 330.43

**Ключевые слова:***кредитный скоринг; методы машинного обучения; нейронная сеть; бинарная классификация; кредитоспособность.*

БГУ, доцент кафедры корпоративных финансов экономического факультета, Республика Беларусь, г. Минск, e-mail: maximus.vlas@mail.ru

вило, осуществляется банками на индивидуальной основе с учетом не только финансово-экономических показателей, но также особенностей бизнес-модели клиента и характера будущего использования кредитных средств, то определение кредитоспособности физических лиц максимально стандартизировано и опирается на некий сугубо статистический подход. Специфика розничного кредитования такова, что суммы выдач относительно меньше, самих клиентов гораздо больше, а степень различий между заемщиками и их реакциями на внешние шоки не так велика, как в корпоративном сегменте.

Поэтому наиболее распространенным классическим способом оценки кредитоспособности физических лиц уже много десятилетий является кредитный скоринг – система присвоения баллов кредитополучателю на основании его способности и потенциала погасить долг. Баллы рассчитываются на основании имеющейся кредитной информации о прошлых периодах с использованием простой статистической модели. Как правило, основных источников информации о потенциальном клиенте всего три: анкета, заполненная клиентом при подаче заявки на кредит; сведения о по-

лучаемом доходе от работодателя (не всегда) и информация из бюро кредитных историй. Все имеющиеся данные о клиенте поступают в скоринговую систему, где каждому параметру в зависимости от его значения присваивается определенное количество баллов (например, есть иждивенцы – баллов меньше, есть в собственности жилье – баллов больше и т. д.), и чем больше их получено, тем лучше для клиента. У каждого банка своя система баллов, но набор параметров во многом является общим. Далее подсчитывается общее количество полученных баллов и присваивается клиентский рейтинг. Если он окажется выше некоей пороговой величины, то кредитная заявка клиента будет одобрена.

Кредитный скоринг за все время длительного практического использования зарекомендовал себя как достаточно надежный и относительно нетрудоемкий способ определения кредитоспособности розничных клиентов, ведь во многих банках, особенно небольших, расчет скорингового балла до сих пор осуществляется вручную специалистами операционных офисов. Хотя следует отметить, что одной из главных проблем скорингового подхода всегда было и остается неоднозначное разде-

Одним из важнейших факторов при принятии банком решения о выдаче кредита и условиях кредитного соглашения является оценка кредитоспособности потенциального заемщика, т. е. его способности полностью исполнить взятые на себя обязательства, своевременно погасив кредит и начисленные проценты. И если оценка кредитоспособности корпоративных заемщиков, как пра-

<sup>1</sup> Статья подготовлена в рамках выполнения темы НИР «Трансформация системы монетарного регулирования России и Беларуси в условиях цифровизации экономики», № Г20Р-015, грант БРФФИ.

ление клиентов на «хороших» и «плохих» (присутствие достаточно большой «серой зоны» – клиентов с трудно идентифицируемой кредитоспособностью, что обусловлено сложностью с увязкой конкретного количества баллов по каждому параметру и реальных исторических случаев дефолтов в рамках скорингового метода), т. е. часть платежеспособных потенциальных клиентов банками теряется.

Однако в последние годы происходит масштабная трансформация финансового рынка, в том числе и его кредитного сегмента. С одной стороны, максимально усилилась конкуренция между банками за привлечение клиентов. С другой стороны, в финансовую сферу активно внедряются новые информационные технологии, в частности позволяющие автоматизировать и оптимизировать стандартные бизнес-процессы. В условиях высокой межбанковской конкуренции ключевую роль играют, во-первых, сокращение финансовых затрат на рассмотрение кредитных заявок (минимизация ручного труда специалистов по работе с клиентами); во-вторых, быстрое принятие решений по кредитным заявкам; в-третьих, повышение точности в определении кредитоспособности потенциальных заемщиков и минимизация «серой зоны». В то же время благодаря современным информационным технологиям появилась возможность увеличить скорость обработки кредитных заявок, частично исключив из процесса человеческий фактор, расширить массив используемых данных о клиенте (например, за счет информации из социальных сетей и сведений об интернет-активности), а также повысить глубину анализа связей конкретных признаков заемщика с исторической вероятностью дефолта.

Указанные тенденции привели к тому, что классический скоринг стал постепенно вытесняться более продвинутыми методами машинного обучения, основанными на искусственном интеллекте. Алгоритмы искусственного интеллекта позволяют вычислительным средствам обучаться на собственном опыте, адаптироваться к задаваемым параметрам и выявлять закономерности с помощью обра-

ботки большого объема данных. Машинное обучение работает без прямого программирования того, что нужно изучать, важны лишь сами данные. Соответствующие подходы весьма многообразны: логистическая регрессия, дерево решений, метод опорных векторов, градиентный бустинг, искусственная нейронная сеть – все они относятся к методам машинного обучения. Особую популярность среди всех методов машинного обучениянискалынейронные сети. Беспрецедентный успех данного инструмента при решении ряда технических задач, таких как распознавание образов, сжатие информации, восстановление пропусков в данных, классификация объектов, привлек к тому, что появились попытки (не всегда удачные) использовать нейронные сети абсолютно во всех областях знаний, в том числе и в финансово-экономической сфере.

С точки зрения математики задача определения кредитоспособности заемщиков является типичным представителем гораздо более широкого класса задач, связанных с распределением набора имеющихся объектов, каждый из которых характеризуется вектором определенных признаков, по нескольким заранее определенным категориям (классификация объектов). В нашем случае объектами являются заемщики, признаками – их характеристики (данные анкеты, кредитная история и т. д.), классами – возможные результаты оценки (хороший клиент/будущий дефолтник). С учетом этого применение нейронных сетей при определении кредитоспособности формально оправдано. Рассмотрим далее краткие математические основания теории нейронных сетей, международный опыт их применения в оценке кредитного риска, а также результаты классификации при помощи данного инструмента реальных кредитов, выданных белорусскими банками розничным клиентам.

### Основы теории нейронных сетей

Нейронные сети можно рассматривать как современные вычислительные системы, которые преобразуют информацию по образу процессов, происходящих в

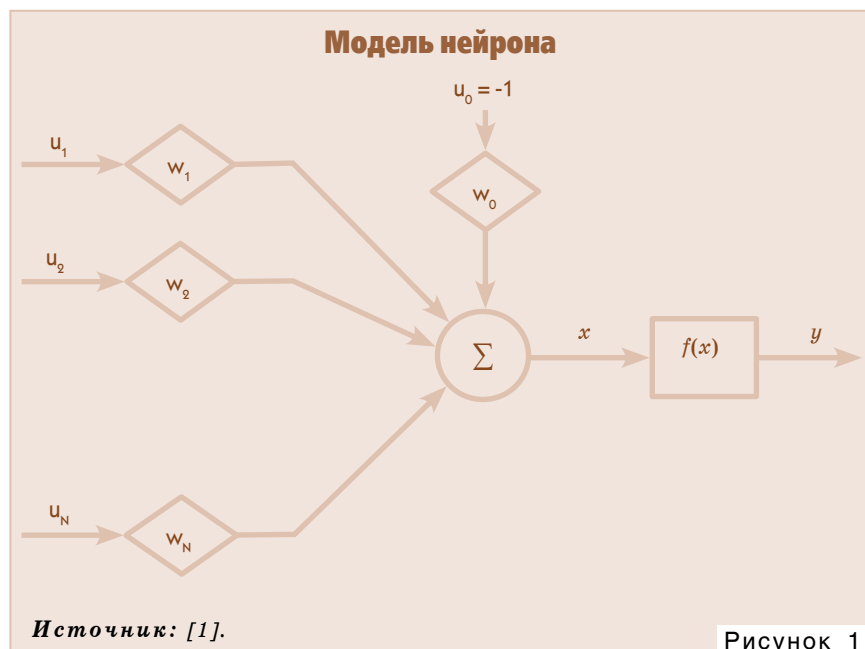
мозгу человека. Обработываемая информация имеет численный характер, что позволяет использовать нейронную сеть, например, в качестве модели объекта с совершенно неизвестными характеристиками. Базовый элемент нервной системы человека – это нервная клетка, называемая нейроном. Каждый нейрон имеет несколько отростков, по которым в него поступает информация, и только один выходной отросток, по которому он может передавать импульс (преобразованную информацию) нескольким другим нейронам. К нейрону приходит несколько импульсов, одна часть которых оказывает возбуждающее, а другая – тормозящее воздействие. Нейрон суммирует возбуждающие и тормозящие импульсы. Если их алгебраическая сумма превышает некоторое пороговое значение, то сигнал с выходного отростка нейрона пересылается к другим нейронам.

Рассмотрим одну из исторически первых формализованных моделей нейрона. Введем следующие обозначения:  $u_1, \dots, u_N$  – входные сигналы данного нейрона, приходящие от других нейронов;  $w_1, \dots, w_N$  – веса входных сигналов;  $y$  – выходной сигнал нейрона;  $v$  – некое пороговое значение. Формула, описывающая функционирование нейрона, имеет вид:

$$y = \begin{cases} 1 & \text{при } \sum_{i=1}^N w_i u_i \geq v, \\ 0 & \text{при } \sum_{i=1}^N w_i u_i < v. \end{cases} \quad (1)$$

Модель (1) может быть представлена в виде  $y = f(\sum_{i=0}^N w_i u_i)$ , где  $f(x) = 1$  при  $x \geq 0$ , и  $f(x) = 0$  при  $x < 0$ , а также  $w_0 = v$ ,  $u_0 = -1$ . Последняя формула описывает модель нейрона, представленную на рисунке 1. Эта модель была предложена в 1943 г. МакКалпоком и Питтсом [1]. Данная модель лежит в основе всех без исключения современных нейронных сетей, какой бы сложной архитектурой они ни обладали.

В качестве функции активации  $f$  может приниматься не только указанная единичная функция, но и другие пороговые функции, например:  $f(x) = 1$  при  $x > 1$  и  $f(x) = -1$  при  $x < -1$ ,  $f(x) = x$  при  $|x| \leq 1$ . В настоящее время



допускается разделение обучающей последовательности  $\{u(n)\}$  на две подпоследовательности  $\{u_1(n)\} \in L_1$  и  $\{u_2(n)\} \in L_2$ .

Обучение персептрона заключается в рекуррентной коррекции вектора весов  $w(n)$  согласно следующим формулам:

$$w(n+1) = w(n), \text{ если } w^T(n)u(n) \geq 0 \text{ и } u(n) \in L_1,$$

$$w(n+1) = w(n), \text{ если } w^T(n)u(n) < 0 \text{ и } u(n) \in L_2,$$

$$w(n+1) = w(n) - \eta u(n), \text{ если } w^T(n)u(n) \geq 0 \text{ и } u(n) \in L_2,$$

$$w(n+1) = w(n) + \eta u(n), \text{ если } w^T(n)u(n) < 0 \text{ и } u(n) \in L_1,$$

где параметр  $\eta$  при  $0 < \eta < 1$  – шаг коррекции, начальные значения компонент вектора весов устанавливаются равными нулю, т. е.  $w(0) = 0$ .

По завершении обучения решающая граница персептрона определяется выражением  $\sum_{i=0}^N w_i(n_0)u_i = 0$ , а персептрон корректно классифицирует как сигналы, которые принадлежат к обучающей выборке  $\{u(n)\}$ , так и не входящие в это множество сигналы, но выполняющие условие линейной сепарабельности. Если данное условие не соблюдается, то алгоритм не сходится. Тогда задача решается при помощи двухслойного персептрона.

Для обучения нейронных сетей, как правило, используется алгоритм обратного распространения ошибки. Его основная идея состоит в распространении сигналов ошибки от выходов сети к ее входам, т. е. в направлении, обратном прямому распространению сигналов в обычном режиме работы. При обучении персептрона требуется изменять весовые коэффициенты сети так, чтобы минимизировать среднюю ошибку на выходе нейронной сети при подаче на вход последовательности обучающих входных данных. Формально, чтобы сделать всего один шаг (сделать одно изменение параметров сети), необходимо подать на вход сети последовательно абсолютно весь набор обучающих данных, для каждого объекта обучающих данных вычислить ошибку и рассчитать необходимую

чаще всего используется логистическая (или сигмоидальная в терминологии нейронных сетей) функция, определяемая выражением:

$$f(x) = \frac{1}{1 + e^{-x}} > 0. \quad (2)$$

Модель МакКалпока – Питтса стала отправной точкой для построения простейшей однонаправленной нейронной сети, названной персептроном. Такую сеть предложил и исследовал Ф. Розенблатт в конце 50-х гг. – начале 60-х гг. XX в. Сигнал  $x$  на выходе линейной части персептрона задается выражением  $x = \sum_{i=1}^N w_i u_i - v = \sum_{i=0}^N w_i u_i$ , где  $w_0 = v$ ,  $u_0 = -1$ . Задача персептрона заключается в классификации входного вектора  $u = [u_1, \dots, u_N]^T$  в смысле отнесения его к одному из двух классов, обозначаемых символами  $L_1$  и  $L_2$ . Персептрон относит вектор  $u$  к классу  $L_1$ , если выходной сигнал  $y$  принимает значение 1, и к классу  $L_2$ , если выходной сигнал  $y$  принимает значение 0. После этого персептрон разделяет  $N$ -мерное пространство входных векторов на два полупространства, разграниченных гиперплоскостью, которая задается уравнением  $\sum_{i=1}^N w_i u_i - v = \sum_{i=0}^N w_i u_i = 0$ . Данная гиперплоскость называется решающей границей.

Если  $N = 2$ , то решающая граница – это прямая линия, задаваемая уравнением  $w_1 u_1 + w_2 u_2 -$

$-v = 0$ . Точка  $(u_1, u_2)$ , лежащая над этой прямой, относится к классу  $L_1$ , тогда как точка  $(u_1, u_2)$ , лежащая под этой прямой, относится к классу  $L_2$ . Точки, лежащие на границе решения, можно произвольно отнести и к классу  $L_1$ , и к классу  $L_2$ .

Для дальнейших рассуждений допустим, что веса  $w_i$ ,  $i = 0, 1, \dots, N$ , в уравнении гиперплоскости неизвестны, тогда как на вход персептрона последовательно подаются так называемые обучающие сигналы  $u(n)$ ,  $n = 1, 2, \dots$ , где  $u(n) = [u_1(n), u_2(n), \dots, u_N(n)]^T$ . Незвестные значения весов будут определяться в процессе обучения персептрона. Такой подход получил название «обучение с учителем». Роль «учителя» заключается в корректном отнесении сигналов  $u(n)$  к классам  $L_1$  или  $L_2$ , несмотря на неизвестность весов уравнения решающей границы. По завершении процесса обучения персептрон должен корректно классифицировать поступающие на его вход сигналы, в том числе и те, которые отсутствовали в обучающей последовательности  $u(n)$ ,  $n = 1, 2, \dots$ . Кроме того, примем, что множества векторов  $u(n)$ ,  $n = 1, 2, \dots$ , для которых выходной сигнал персептрона принимает соответственно значения 1 и 0, линейно отделены, т. е. лежат в двух различных полупространствах, разделенных гиперплоскостью. Другими словами,

коррекцию коэффициентов сети (но не делать эту коррекцию) и уже после подачи всех данных рассчитать сумму в корректировке каждого коэффициента сети (сумма градиентов) и произвести коррекцию коэффициентов «на один шаг». Очевидно, что при большом наборе обучающих данных алгоритм будет работать крайне медленно, поэтому на практике часто производят корректировку коэффициентов сети после каждого элемента обучения, где значение градиента аппроксимируется градиентом функции стоимости, вычисленным только на одном элементе обучения.

Используемые на практике нейронные сети представляют собой множества последовательно и параллельно соединенных перцептронов (перцептроны, равноудаленные от входа и выхода сети, условно объединяются в слои). В таком случае говорят о многослойном перцептроне Розенблатта. Многослойный перцептрон в общем представлении состоит из следующих элементов: 1) множества входных узлов, которые образуют входной слой нейронов; 2) одного или нескольких скрытых слоев вычислительных нейронов; 3) одного выходного слоя нейронов. Несмотря на такую сложную архитектуру многослойного перцептрона, его обучение совершенно аналогично обучению простейшего перцептрона. В классификационных перцептронах, предназначенных для разделения объектов на две категории, выходной слой всегда представлен лишь одним нейроном, который генерирует число из интервала  $[0; 1]$ . Это число можно интерпретировать как вероятность  $p$  того, что объект принадлежит к одной из категорий; соответственно, вероятность того, что он относится к другой категории, равна  $1 - p$ . Разность указанных вероятностей отражает степень уверенности нейронной сети в том, что объект классифицирован верно. Очевидно, что чем выше степень уверенности, тем лучше работает сеть. Рассмотрим работу классификационного перцептрона более подробно уже применительно к задаче определения кредитоспособности заемщиков.

### Классификационная нейросеть как альтернатива скорингу

Как уже говорилось выше, решение задачи классификации, т. е. отнесения объекта к одному из нескольких попарно не пересекающихся множеств, является одним из важнейших применений нейронных сетей. Каждый объект обучающей выборки подается на вход классификационной нейросети в виде вектора, размерность которого равна количеству анализируемых признаков объекта. Компоненты вектора представляют собой значения данных признаков, которые влияют на принятие решения о том, к какой классу можно отнести данный объект. В задаче оценки кредитного риска объектами являются заемщики, а в качестве признаков, например, могут выступать атрибуты «возраст», «доход», «стаж работы», «количество иждивенцев». В таком случае входной вектор будет четырехмерным.

Стандартным инструментом статистического решения задачи бинарной классификации долгое время считалась логистическая регрессия. Но, как правило, нейронные сети способны решать данную задачу более эффективно, так как фактически генерируют большое число логистических регрессий (в случае, если функция активации  $f(x)$  имеет вид, указанный в формуле (2)). Однако самым важным и сложным вопросом является выбор архитектуры нейронной сети, т. е. сколько использовать скрытых слоев и нейронов в них для решения конкретной задачи. Заранее ответить на данный вопрос невозможно, все зависит от специфики данных, входящих в обучающую выборку. Как уже говорилось, в простейшем случае, когда данные удовлетворяют условию линейной сепарабельности (т. е. классы объектов можно разделить прямыми линиями или гиперплоскостями, если пространство входов имеет размерность больше трех), задача может быть успешно решена при помощи одного перцептрона. Но исходные данные могут оказаться таковыми, что классы невозможно разделить линиями или плоскостями, но они разграничива-

ются с помощью более сложного деления (нелинейная разделимость); или вовсе классы пересекаются, и можно говорить только о вероятностной разделимости. В таком случае нужно использовать многослойные нейронные сети, усложняя их архитектуру по мере усложнения входных данных (роста количества признаков объектов или количества самих наблюдений в обучающей выборке).

В общем виде можно сказать, что в нейронной сети с одним скрытым слоем входной вектор преобразуется этим скрытым слоем в некоторое новое пространство, которое может иметь другую размерность, а затем гиперплоскости, соответствующие выходному нейрону, разделяют его на нужные нам классы. Таким образом, нейронная сеть распознает не только характеристики исходных данных, но и «характеристики характеристик», сформированные скрытым слоем. Какую именно вычислительную сложность имеет каждая конкретная задача, заранее неизвестно, поэтому построение нейронной сети требует проведения ряда вычислительных экспериментов. В качестве начального приближения лучше использовать сеть с одним скрытым слоем, а число нейронов в нем положить равным полусумме размерности входного вектора и количества выходов. Очевидно, что в задаче определения кредитоспособности заемщиков присутствует именно вероятностная разделимость на классы (среди кредитополучателей, обладающих совершенно идентичными значениями всех признаков, часть может оказаться платежеспособными, а часть – дефолтными, и уместно говорить лишь о соотношении указанных частот), поэтому целесообразно изначально использовать более сложные архитектуры нейронных сетей.

Указанные нюансы подчеркивают ключевую роль исходных данных в процессе построения нейросетевого классификатора, которые обязательно должны быть непротиворечивыми, максимально однородными и несмещенными. Также входные данные следует нормировать, поскольку нейронные сети работают с информацией, представленной числами в диапазоне от 0 до 1,

а исходные данные могут иметь произвольный диапазон или вообще быть нечисловыми характеристиками. Трансформация нечисловых данных в числовые будет продемонстрирована ниже.

Правильный выбор архитектуры нейронной сети имеет большое значение. Построить небольшую и качественную модель часто бывает просто невозможно, а модель со сложной структурой будет просто «запоминать» примеры из обучающей выборки и не производить аппроксимацию, что, естественно, приведет к некорректной работе классификатора. Компромисс заключается в построении изначально сети минимального размера и ее постепенном увеличении до достижения требуемой точности. При этом на каждом шаге нейронную сеть необходимо заново обучать.

Таким образом, алгоритм построения бинарного классификатора на основе нейронной сети включает в себя:

1) *подборку данных* (составление выборки из объектов, характерных для данной задачи; разбиение всей совокупности данных на два класса);

2) *предварительную обработку данных* (нормировка, стандартизация данных; удаление противоречивых наблюдений);

3) *конструирование, обучение и оценку качества нейронной сети* (выбор архитектуры: количество слоев, число нейронов в слоях и т. д.; определение функции активации нейронов и метода обучения сети; оценка качества работы классификатора на основе тестового множества данных);

4) *использование и диагностику сети* (выявление степени влияния различных факторов на принимаемое решение).

Рассмотрим работу нейросетевого бинарного классификатора, оценивающего кредитоспособность розничного заемщика, на условном примере. Допустим, по всем кредиторам известны признаки «возраст», «доход», «стаж работы», «количество иждивенцев», т. е. на вход нейронной сети подается четырехмерный вектор. В качестве первого приближения будем использовать сеть с одним скрытым слоем. Согласно изложенной выше рекомендации определяем количество

нейронов в нем как целую часть полусуммы размерности входного вектора и количества выходов:  $\lfloor (4+1)/2 \rfloor = 2$ . На входном слое нейронов должно быть больше, чем на скрытом слое, поэтому возьмем три нейрона. Итак, получаем начальную спецификацию нейросетевого классификатора, состоящего из шести нейронов: три – на входном слое, два – на скрытом и один – на выходном слое.

Положим, имеется некая обучающая выборка, в которую входят как «хорошие» клиенты (метка класса «0»), так и «плохие» (метка класса «1»). Все признаки объектов являются количественными, поэтому сразу можно приступить к нормировке данных. Наиболее часто на практике используют метод минимакс, который предполагает, что известны пределы изменения значений признаков в выборке – минимальное и максимальное значения:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}. \quad (3)$$

Пропустив нормированные данные обучающей выборки через сеть, методом обратного распространения ошибки можно найти веса всех нейронов. Допустим, что обученная сеть имеет вид, указанный на рисунке 2.

Если модель показывает корректные результаты по разделению всех заемщиков на классы «хороших» и «плохих» на обучающей и тестовой выборках, то, значит, ее можно использовать для новых клиентов. Пусть заявка подал потенциальный кредитор, которому 25 лет, ежемесячный доход которого 1 250 рублей, стаж работы 5 лет и имеется 1 ребенок. Нормируем данные с учетом всей выборки по формуле (3) и переводим их в вектор [0,1538; 0,4138; 0,3636; 0,3333]. Далее данный вектор подается на каждый из трех нейронов входного слоя, его компоненты умножаются на соответствующие веса и суммируются. Полученная таким образом взвешенная величина пропускается через сигмоидальную функцию (2) и преобразуется в сигнал нейрона. Таким образом, первоначальный 4-мерный входной вектор трансформируется на

первом слое в новый 3-мерный вектор [0,7704; 0,4588; 0,5706]. Новый вектор аналогично подается на каждый из двух нейронов скрытого слоя и преобразуется в их сигналы, составляющие уже 2-мерный вектор [0,7659; 0,5844]. Наконец, полученный 2-мерный вектор подается на единственный нейрон выходного слоя и преобразуется в его сигнал, имеющий значение 0,275.

Учитывая вероятностную интерпретацию сигналов выходного нейрона в классификационных сетях, можно сказать, что полученный результат означает, что вероятность отнесения указанного потенциального клиента к классу «плохих» заемщиков равна 27,5%. Говоря проще, вероятность дефолта этого клиента составляет 27,5% (здесь и далее под дефолтом заемщика понимается возникновение просрочки по уплате основного долга более 90 дней). Вероятность дефолта нужно сравнить с неким пороговым значением; как правило, это 50%. Если она оказывается ниже порогового значения, клиент признается кредитоспособным и его заявка одобряется.

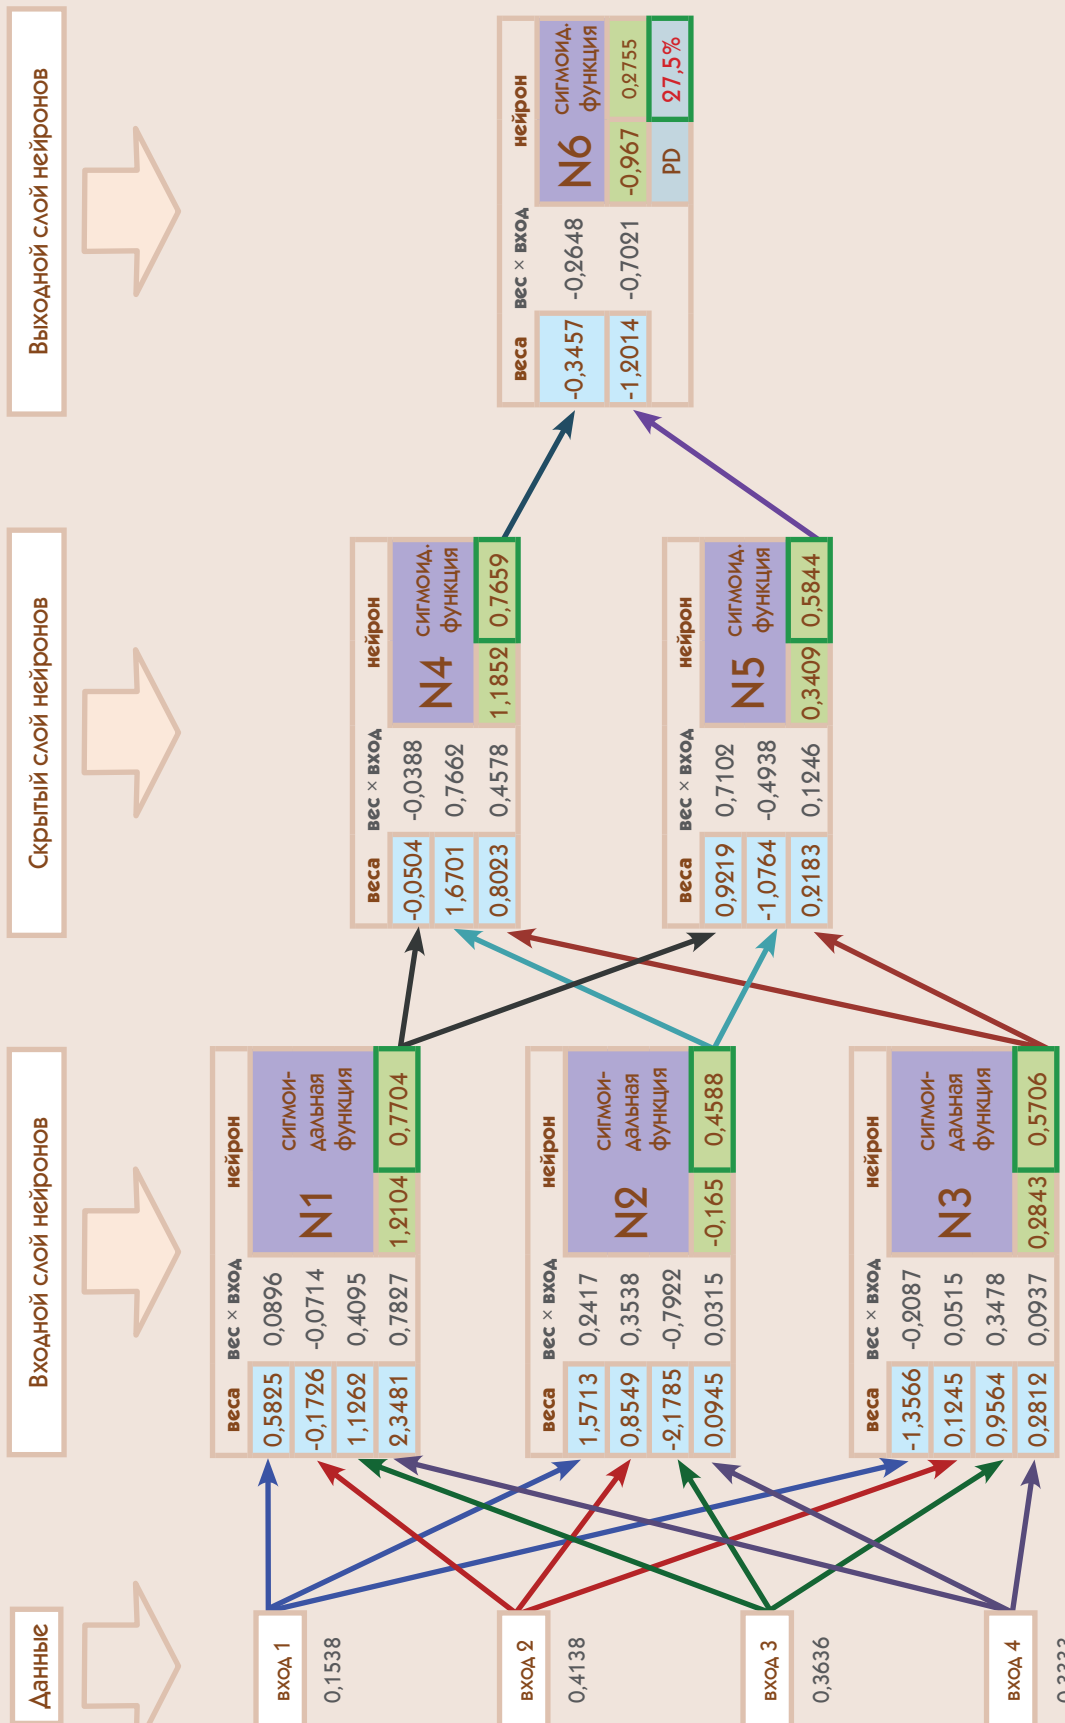
В таблице 1 приведена подборка наиболее интересных зарубежных публикаций, касающихся опыта использования классификационных нейронных сетей в оценке кредитного риска на реальных данных.

По результатам рассмотрения зарубежного опыта использования нейросетей в оценке кредитного риска можно сделать следующие выводы:

1) нейронные сети обладают большей эффективностью в разделении заемщиков на классы дефолтных и недефолтных на обучающей и, зачастую, тестовой выборке данных по сравнению с классическим скоринговым подходом, а также иными алгоритмами машинного обучения (логистическая регрессия, дискриминантный анализ, градиентный бустинг и т. д.);

2) основной проблемой при решении задачи классификации заемщиков на основании нейронной сети является выбор оптимальной архитектуры модели (количество скрытых слоев и количество нейронов в каждом

**Пример классификационной нейронной сети с шестью нейронами и одним скрытым слоем в задаче оценки кредитного риска**



Примечание. Разработка автора.

Рисунок 2

Таблица 1

### Опыт использования нейронных сетей в оценке кредитного риска

№	Автор и публикация	Суть подхода	Выборка	Результат
1	«Подход нейронных сетей для оценки кредитного риска», академическая публикация, коллектив авторов из Италии, 2006 г. [2]	Бинарная система: 1 – дефолт, 0 – нет дефолта. Классическая нейронная сеть с четырьмя слоями: входной слой, два скрытых слоя и выходной слой (один нейрон). Оценка весов методом обратного распространения ошибки	Панельные данные за 3 года по 76 малым итальянским предприятиям, 15 факторов (8 показателей по балансу, 7 кредитных показателей банковской системы)	Нулевая ошибка на обучающей выборке и ошибка 8,6% на тестовой выборке (только ошибка второго рода – признание здоровых предприятий дефолтными; все дефолтные случаи распознаны верно). Результаты очень устойчивы относительно количества нейронов в скрытых слоях
2	«Прогнозирование кредитного риска: дискриминантный анализ против нейронных сетей», Государственный университет Туниса, 2015 г. [3]	Бинарная система: 1 – дефолт, 0 – нет дефолта. Архитектура нейронной сети подбиралась эмпирически: варьировалось количество скрытых слоев (от 1 до 5) и нейронов в каждом слое до минимизации ошибки. Оценка весов методом обратного распространения ошибки	Панельные данные по 86 тунисским компаниям за 3 года, 15 факторов (все – балансовые показатели)	Лучший результат показала сеть с четырьмя слоями (2 скрытых): 0,9% ошибок на обучающей выборке и 6,1% – на тестовой. Нейронные сети продемонстрировали разделяющую способность на 11% выше по сравнению с дискриминантным анализом
3	«Эмпирическое сравнение методов машинного обучения для оценки кредитоспособности клиентов банка», интернациональный коллектив авторов (Канада, Корея, Вьетнам), 2019 г. [4]	Бинарная система: 1 – дефолт, 0 – нет дефолта. Результаты классического скорингового подхода (8 различных рейтингов) сравнивались с алгоритмами машинного обучения: логистическая регрессия, сплайны с многомерной адаптивной регрессией (MARS), опорные вектора, случайный лес, ансамблевые методы: бэггинг, бустинг и стекинг, экстремальный градиентный бустинг, искусственные нейронные сети <sup>2</sup> . Цель – определить алгоритм максимальной производительности	Данные выборочных обследований домашних хозяйств в США за 2001 г.: обучающая выборка – 4 113 наблюдений (из них 4,7% дефолтов), тестовая выборка – 4 245 наблюдений (4,6% дефолтов), 345 факторов для каждого наблюдения (те же, на основании которых строится скоринг)	Каждый алгоритм запускался 10 раз при различных параметрах, чтобы определить наилучшую архитектуру подхода. Самый высокий результат показала нейронная сеть с сигмоидальной функцией – 86,81% успешности разделения заемщиков на хороших и дефолтных <sup>3</sup> . Ансамблевые методы и экстремальный градиентный спуск показали близкие результаты, но они чаще пропускают случаи дефолта. Вместе с тем все алгоритмы машинного обучения показали лучший результат по сравнению с традиционным скорингом

<sup>2</sup> Авторы подчеркивают, что обучение нейронной сети остается сложной проблемой: большой массив входных данных вынуждает усложнять архитектуру нейронной сети (увеличивать количество скрытых слоев и количество нейронов в каждом слое), но такая сложная модель становится неустойчивой и начинает плохо работать на тестовой выборке и (или) при дальнейшем решении практических задач.

<sup>3</sup> Вместе с тем авторы подчеркивают, что нейронные сети при оценке кредитного риска имеют ограниченное применение из-за своей природы «черного ящика» – нельзя полностью понять связь между входом и выводом (как именно конкретный параметр влияет на уровень кредитного риска заемщика).

Продолжение таблицы 1

№	Автор и публикация	Суть подхода	Выборка	Результат
4	«Прогнозирование кредитного риска с использованием алгоритма искусственной нейронной сети», автор из Индии (работает в IBM Labs), 2018 г. [5]	Измерение кредитоспособности кредитной заявки при помощи нейросетевой модели. Строилась классическая нейронная сеть с прямой связью: входной слой (на который подается 10 переменных), 7 скрытых слоев и выходной слой, представленный одним нейроном (классификатор) <sup>4</sup>	Выборка из 60 000 наблюдений по ипотечным кредитам, 10 факторов (выбраны экспертно из 80 возможных)	Классическая нейронная сеть с алгоритмом прямой связи и нейронная сеть обратного распространения ошибки имеют почти одинаковую частоту ошибок. Результат: 97,68% точности при разделении заемщиков на хороших и дефолтных. Модель правильно классифицирует выходную переменную с очень низкой ошибкой, однако достигается это при помощи 7 скрытых слоев
5	«Анализ кредитных рисков с использованием моделей машинного обучения и глубокого обучения», интернациональный коллектив авторов (Франция, Италия, Великобритания), 2018 г. [6]	Сравнивались алгоритмы логистической регрессии, случайного леса, градиентного бустинга, глубокого обучения на основе нейронных сетей	Международные данные по 117 019 предприятиям, 235 факторным переменным (финансовые отчеты, балансы, отчеты о прибылях и убытках и движении денежных средств). В выборке представлено 115 288 хороших компаний и 1 731 компания-дефолтник	Логистическая регрессия показала точность 84,29%, случайный лес – 99,32%, градиентный бустинг – 99,42%, нейронные сети в зависимости от архитектуры – от 81,29% до 97,94%. Следует иметь в виду, что выборка была несбалансированной (количество дефолтов крайне мало), а архитектура моделей – очень сложной
6	«Использование нейросетевых моделей в поведенческом скоринге», Тверской государственный университет, 2015 г. [7]	Построение модели поведенческого скоринга на базе нейронной сети в среде SPSS. Цель скоринга – определить, воспользуется ли клиент предложением приобрести новую платежную карту	Объем выборки составляет 43 162 наблюдения (60% – обучающая выборка, 40% – тестовая)	Из построенных моделей лучшие результаты были получены нейронной сетью с двумя скрытыми слоями (по 8 нейронов в каждом). Доля ошибочных прогнозов в обучающей выборке составила 18,2%, в тестовой – 17,8%. В целом автор приходит к выводу, что увеличение количества нейронов не ведет к улучшению качества модели

**Примечание.** Разработка автора.

<sup>4</sup> Автор обращает внимание, что для алгоритма нейронной сети нужно тщательно выбирать функцию активации (сигмоидальная и т. д.), количество нейронов и количество скрытых слоев. Структура модели такова, что алгоритм обучения всегда сходится, однако модель представляет собой «черный ящик». И несмотря на то, что результат нейронной сети выше, чем, например, классических регрессионных моделей, его трудно объяснить по сравнению с той же моделью линейной регрессии. Следовательно, какую модель использовать, зависит от того, какая цель преследуется – снизить ошибку или выявить движущие факторы в кредитоспособности заемщиков. Также при настройке модели с использованием нейронной сети пользователю необходимо уделять особое внимание архитектуре и нормализации данных для повышения производительности.



слое): большая размерность данных вынуждает усложнять архитектуру, но по мере роста сложности модель становится неустойчивой и начинает неадекватно работать на тестовой выборке и (или) при дальнейшем решении практических задач разделения заемщиков на классы;

3) нейронные сети при оценке рискованности заемщиков имеют ограниченное применение из-за своей природы «черного ящика» – невозможно однозначно установить направленность и силу влияния конкретного параметра на уровень кредитного риска, поэтому на практике выбор конкретного метода классификации существенным образом зависит от того, какая цель преследуется: снизить ошибку в разделение классов или выявить движущие факторы в кредитоспособности заемщиков.

Ниже в статье содержится описание серии экспериментов, проведенных автором по построению классификационной нейронной сети на реальных данных белорусских банков.

### Описание используемой выборки

В первоначальную выборку данных вошли 73 463 кредита, выданных белорусскими банками. При этом 77% кредитов на момент построения модели были действующими и лишь 23% – закрытыми. В выборке присутствует 4 310 дефолтных кредитов, или 5,9% от их общего количества. Так как в обучающей выборке представлены кредиты, имеющие различную природу (выданные в разное время, на разных условиях в рамках специфических кредитных продуктов), данные для принятия решения по ним на этапе обработки банками кредитных заявок также использовались разные. В итоге все кредиты в выборке объединяют лишь 17 общих признаков, присущих заемщикам, которые условно можно сгруппировать в 4 блока:

1) *личные данные клиента*: пол (*sex*), возраст (*age*), количество иждивенцев (*depend*), регион проживания (*region*);

2) *данные, указанные клиентом в анкете*: запрашиваемая сумма кредита (*sum*), запрашиваемый срок кредита (*term*), заявленный доход (*income*), образование (*educat*), категория занимаемой должности (*position*), сфера деятельности (*field*);

3) *данные из внешних источников*: количество фактов привлечения к уголовной ответственности (*crime*), количество фактов привлечения к административной ответственности (*admin*), наличие кредитной истории (*history*), класс рейтинга Национального банка (*rating*);

4) *прочие сведения*: коэффициент долговой нагрузки DTI (*dti*), время подачи заявки на кредит (*time*), наличие зарплатного счета в банке (*salary*).

Были проанализированы данные о частоте дефолтов клиентов в разрезе отдельных значений признаков. Результаты показали, что частота дефолтов в значительной мере дифференцирована в зависимости от значений каждого отдельного признака (например, частота дефолтов среди мужчин составляет 7,2%, среди женщин – 4,9%; среди клиентов с высшим образованием – 3,7%, со средним специальным – 7,1%, со средним – 9,6%; среди работников сельского хозяйства – 14,5%, IT-специалистов – 3,1% и т. д.). Данный факт повышает вероятность того, что указанные признаки действительно существенны при определении кредитоспособности заемщиков и их разделении на соответствующие классы.

Большинство признаков заемщиков являются количественными переменными, их нормировка проводилась по формуле (3); такие признаки, как *sex*, *history*, *salary*, относятся к бинарным переменным (принимают только значения «0» и «1») и уже, по сути, являются нормированными. Вместе с тем признаки *region*, *educat*, *position*, *field* и *rating* представлены качественными параметрами, и их преобразование в числовые данные осуществлялось по следующей схеме: значения каждого качественного параметра ранжировались по возрастанию частоты дефолтов; значению с минимальной частотой дефолтов

присваивалась метка «1», следующему значению – «2» и т. д. Таким образом, максимальное число получало значение параметра, которому соответствует наибольшая частота дефолтов. Уже после этого к трансформированным в числа качественным параметрам применялось правило нормировки (3).

### Эксперименты по построению модели

На первом этапе была принята попытка построения обыкновенной логистической регрессии (простейший метод машинного обучения) на указанных данных. Во-первых, целесообразно иметь отправную точку, с которой можно в дальнейшем сравнивать классификационную нейронную сеть. Во-вторых, логистическая регрессия позволяет проанализировать, насколько значимы отдельные признаки заемщиков (в рамках нейронной сети, которая относится к неинтерпретируемым методам моделирования, этого сделать невозможно). В регрессии бинарная зависимая переменная *y* принимала значение «1» на дефолтных кредитах и «0» – на всех остальных. Результаты построения логит-модели, выполненные в среде программы Eviews 10, представлены в таблице 2.

В целом все признаки, за исключением пола клиента, оказались статистически значимыми и, кроме DTI, имеют экономически ожидаемое направление связи с вероятностью дефолта. Коэффициент Макфаддена равен 0,14, что также достаточно неплохо для такой крупной выборки. На первый взгляд модель адекватна, но если посмотреть на качество разделения клиентов (таблица 3), то результат нельзя назвать удовлетворительным.

То есть логистическая регрессия хорошо определяет заемщиков, обслуживающих кредитные обязательства, но пропускает значительное количество будущих дефолтников, верно идентифицируя лишь 3,5% из них. Иначе говоря, модель имеет очень высокую ошибку второго рода. Вместе с тем следует отметить, что все кредиты, вошедшие в обучающую выборку,

Таблица 2

## Результаты оценки коэффициентов логистической регрессии

Переменная	Коэффициент	Стандартная ошибка	z-статистика	Вероятность стат. незначимости
Sex	-0,021218	0,036775	-0,576967	0,5640
Age	-1,041584	0,076642	-13,59033	0,0000
Depend	-0,516418	0,153932	-3,354850	0,0008
Region	0,411484	0,054991	7,482753	0,0000
Sum	2,126488	0,121174	17,54908	0,0000
Term	2,111389	0,075889	27,82212	0,0000
Income	-5,171880	1,100520	-4,699486	0,0000
Educat	0,670185	0,060373	11,10070	0,0000
Position	1,153296	0,102284	11,27541	0,0000
Field	1,114349	0,068688	16,22333	0,0000
Crime	1,574055	0,058699	26,81567	0,0000
Admin	2,270440	0,246866	9,197056	0,0000
History	-0,692419	0,059742	-11,59020	0,0000
Rating	0,902077	0,074543	12,10137	0,0000
DTI	-1,070160	0,127384	-8,401075	0,0000
Time	-0,977999	0,119822	-8,162127	0,0000
Salary	-1,101929	0,134272	-8,206713	0,0000
C	-4,854864	0,135176	-35,91516	0,0000
Наблюдений с $y = 0$		69 153	Всего наблюдений	73 463
Наблюдений с $y = 1$		4 310		

*Примечание.* Разработка автора.

Таблица 3

## Качество разделения заемщиков на классы по логит-модели

	Обслуживаемый кредит	Дефолтный кредит
Доля верной классификации, %	99,78	3,48
Доля ошибочной классификации, %	0,22	96,52

*Примечание.* Разработка автора.

были в свое время одобрены банками к выдаче на основании их внутренних скоринговых моделей, то есть напрямую сравнивать методы машинного обучения с классическим скоринговым подходом не совсем корректно. Можно лишь оценить, насколько улучшает итоговый результат использование того или иного метода машинного обучения поверх скоринговой модели. При этом важно не только «отсечь» как можно больше будущих дефолтников,

но и по-максимуму сохранить платежеспособных заемщиков, которые приносят банкам прибыль. В то же время вопрос, каким образом повели бы себя кредиты, одобренные только на основании метода машинного обучения без предварительного расчета скорингового балла, за неимением соответствующей выборки остается открытым.

Обучение нейронной сети в рамках настоящего исследования проводилось в пакете MATLAB. В среде программи-

рования MATLAB присутствует надстройка Neural Networks Toolbox, в состав которой входит более 150 различных функций, образующих своеобразный макроязык программирования и позволяющих пользователю создавать, обучать и использовать самые различные нейронные сети [8].

В рамках построения классификационной нейронной сети исходная выборка данных (73 463 наблюдения) была случайным образом разделена на три подвыборки – обучающую (70% исходной выборки), валидационную (15%) и тестовую (15%). Был написан скрипт в MATLAB и осуществлен перебор различных вариантов архитектуры нейронной сети с количеством скрытых слоев нейронов от 1 до 10. Результаты в разрезе различных конфигураций менялись незначительно, но наилучшую разделяющую способность про-

демонстрировала модель с пятью скрытыми слоями (таблица 4), при этом степень распознавания оказалась очень близкой на всех трех подвыборках.

Из таблицы 4 видно, что кардинального улучшения по сравнению с логистической регрессией не произошло. Искусственная нейронная сеть идентифицировала лишь 8,3% дефолтных клиентов (логит-модель – 3,5%). Если считать в абсолютных цифрах, то из 4 310 случаев дефолта нейронная сеть правильно распознала лишь 357, притом что ошибочно отнесла к дефолтникам 240 платежеспособных заемщиков.

Частично полученный выше результат обусловлен тем, что первоначальную выборку нельзя назвать в достаточной мере однородной и несмещенной<sup>5</sup>, поэтому желательно перестроить выборку таким образом, чтобы в ней было по 50% дефолтных и недефолтных кредитов. Кроме того, как указывалось выше, кредиты в исходной выборке имеют слишком разную природу. С учетом этого было принято решение уменьшить первоначальную выборку и оставить в ней только онлайн-кредиты (кредиты, которые выдаются банками в автоматизированном режиме на основе дистанционно оформленных через сеть Интернет заявок). Выборка из онлайн-кредитов является максимально однородной, так как они не подвержены влиянию человеческого фактора со стороны работников операционных офисов банков, – все анкеты клиентов обрабатываются по унифицированному алгоритму. Всего в первоначальной выборке имелось 1 790 дефолтных онлайн-кредитов. К ним были добавлены еще 1 790 успешно погашенных онлайн-кредитов (признак закрытого кредитного договора гарантирует, что кредит не перейдет в категорию дефолтных в будущем). Таким образом была сформирована новая выборка, гораздо меньшая,

чем первоначальная (всего 3 580 кредитов), но зато в полной мере однородная и несмещенная (дефолтные и недефолтные кредиты в ней соотносятся 1:1).

После этого классификационная нейронная сеть была переобучена на новой выборке. Наилучший результат продемонстрировала спецификация модели уже с тремя скрытыми слоями нейронов (таблица 5).

Как следует из таблицы 5, нейронная сеть правильно идентифицировала 60% дефолтных онлайн-кредитов, но неверно отнесла к классу дефолтных 26% успешно погашенных онлайн-кредитов. Интегральной мерой качества моделей бинарной классификации наиболее часто служит коэффициент Джини, который варьируется в диапазоне от 0 до 1, где 1 – идеальный классификационный алгоритм, 0 – угадывание случайным образом. В рассмотренном примере коэффициент Джини<sup>6</sup> равен 0,47 (притом что соотношение корректных предсказаний модели к общему числу

наблюдений в выборке гораздо выше – 0,67). Тем не менее это достаточно неплохой результат, позволяющий утверждать, что нейронная сеть действительно обладает некоторой обобщающей способностью.

Исходя из значений метрик качества очевидно, что использование данной нейронной сети на практике привело бы к снижению уровня одобрения кредитных заявок, но общий финансовый эффект для кредитора был бы положительным. Также следует отметить, что, возможно, в дефолтной части выборки присутствовала некоторая доля сделок мошеннического характера (когда клиент предоставляет в банк заведомо недостоверные сведения с целью получить кредит, не обслуживая его в будущем), и их исключение повысило бы разделяющую способность модели.

Учитывая сложности с выбором оптимальной архитектуры модели и неинтерпретируемый характер алгоритма, нейронные сети вряд ли способны полностью

Таблица 4

**Качество разделения заемщиков на классы по нейронной сети**

	Обслуживаемый кредит	Дефолтный кредит
Доля верной классификации, %	99,65	8,28
Доля ошибочной классификации, %	0,35	91,72

*Примечание.* Разработка автора.

Таблица 5

**Качество разделения заемщиков на классы по нейронной сети № 2**

	Обслуживаемый кредит	Дефолтный кредит
Верная классификация, шт.	1 327	1 065
Ошибочная классификация, шт.	463	725
Доля верной классификации, %	74,13	59,50
Доля ошибочной классификации, %	25,87	40,50

*Примечание.* Разработка автора.

<sup>5</sup> Смысл принципа несмещенности выборки заключается в том, что если дефолтных наблюдений в обучающей выборке слишком мало, например порядка 5% (т. е. она смещена), то обучение нейронной сети может закончиться тем, что она станет идентифицировать всех заемщиков как платежеспособных, и при этом точность классификации формально будет на уровне 95%.

<sup>6</sup> Преимуществом коэффициента Джини как метрики качества ранжирующей способности модели является его независимость от вариации порога отсеивания. Так, в данном исследовании всюду порог отсеивания равен 50%; уменьшив его, можно искусственно увеличить способность модели распознавать дефолтников, но при этом, вероятнее всего, будет расти и количество случаев неверной идентификации платежеспособных клиентов. Коэффициент Джини определяется лишь качеством самого алгоритма.

заменить традиционный кредитный скоринг. Однако они могут стать его весьма эффективным дополнением. В частности, перспективной видится следующая комбинация подходов: первичное «отсечение» неблагонадежных клиентов проводится на базе автоматизированного скорингового

подхода, в котором приоритет отдается поиску неких критичных комбинаций значений определенных признаков; далее весь массив данных о клиентах, прошедших первый этап, пропускается через классификационную нейронную сеть, которая и формирует базу для принятия

решения по каждой кредитной заявке. При этом будет достигаться как экономия времени и финансовых ресурсов банка, так и приемлемый уровень одобряемости заявок клиентов.

\* \* \*

*Материал поступил 22.02.2021.*

#### **Библіографічны спісак:**

1. Рутковская, Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский; пер. с польск. – Изд.: «Горячая линия – Телеком», 2013. – 384 с.
2. Angelini, E. A Neural Network Approach for Credit Risk Evaluation [Electronic resource] / E. Angelini, G. di Tollo, A. Roli // Kluwer Academic Publishers, 2006. – Mode of access: <https://economia.unich.it/documenti/DEC/arc/wpapers/2006/2006-002.pdf>. – Date of access: 18.12.2020.
3. Khemakhem, S. Credit risk prediction: A comparative study between discriminant analysis and the neural network approach / S. Khemakhem, Y. Boujelbune // Accounting and Management Information Systems. – 2015. – Vol. 14, № 1. – P. 60–78.
4. Munkhdalai, L. An Empirical Comparison of Machine-Learning Methods on Bank Client Credit Assessments [Electronic resource] / L. Munkhdalai, O. Namsrai, J. Yun Lee // Sustainability, 2019. – Mode of access: <https://www.mdpi.com/2071-1050/11/3/699>. – Date of access: 23.12.2020.
5. Goyal, S. Credit Risk Prediction Using Artificial Neural Network Algorithm [Electronic resource] / S. Goyal // Data Science Central, 2018. – Mode of access: <https://www.datasciencecentral.com/profiles/blogs/credit-risk-prediction-using-artificial-neural-network-algorithm>. – Date of access: 27.12.2020.
6. Guegan, D. Credit Risk Analysis Using Machine and Deep Learning Models [Electronic resource] / D. Guegan, P. Addo, B. Hassani // Risks, 2018. – Mode of access: <https://halshs.archives-ouvertes.fr/halshs-01835164/document>. – Date of access: 18.12.2020.
7. Сорокин, А.С. Использование нейросетевых моделей в поведенческом скоринге / А.С. Сорокин // Прикладная информатика. – 2015. – № 2 (56). – С. 92–109.
8. Дьяконов, В.П. Математические пакеты расширения Matlab / В.П. Дьяконов, В.В. Круглов // Специальный справочник. – Изд.: Питер, 2001. – 488 с.

## **Assessment of creditworthiness of natural persons using toolkit of classification neural networks**

**Maksim ULASENKA**, *Belarusian State University, Associate Professor, Department of Corporate Finance, Faculty of Economics, Republic of Belarus, Minsk, e-mail: maximus.vlas@mail.ru.*

**Abstract.** *The article demonstrates prospects of using artificial neural networks – the most popular methods of machine learning – in defining the creditworthiness of retail borrowers. Specifications of classification models on the basis of neural networks confirm that mentioned algorithms in general have a more distinguishing power compared to traditional methods of banks. Besides, neural networks have the nature of «black box» and may be unstable in case of difficult architecture, which limits their exclusive use in the practice of banking business.*

**Keywords:** *credit score; methods of machine learning; neural network; binary classification; creditworthiness.*