

www.europarl.europa.eu/RegData/etudes/BRIE/2015/564393/EPRS_BRI(2015)564393_EN.pdf. – Date of access: 12.10.2022.

6. Governance of science and technology policies [Electronic resource] / OECD science, technology and industry policy papers 2019. – № 84. – Mode of access: <https://doi.org/10.1787/2b3bc558-en>. – Date of access: 12.10.2022.

Статья поступила в редакцию 29.11.2022 г.

УДК 004.94

M. Ulasenka
BSEU (Minsk)

CLASSIFICATION ARTIFICIAL NEURAL NETWORK AS AN ALTERNATIVE TO BANKING SCORING

The article demonstrates the possibilities of using machine learning methods to build models of creditworthiness of retail bank customers. The development of an artificial neural network, which refers to non-interpretable algorithms, is considered in detail. The proposed approach is more reliable than traditional scoring and can be used in banking practice.

Keywords: credit scoring; classification; machine learning; interpretable and non-interpretable methods; neural network; Gini index; type I and type II errors.

М. Н. Власенко
кандидат экономических наук
БГЭУ (Минск)

КЛАССИФИКАЦИОННАЯ ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ КАК АЛЬТЕРНАТИВА БАНКОВСКОМУ СКОРИНГУ

В статье продемонстрированы возможности использования методов машинного обучения для построения моделей оценки кредитоспособности розничных клиентов банков. Детально рассмотрена разработка искусственной нейронной сети, которая относится к неинтерпретируемым алгоритмам. Предложенный подход обладает большей предсказательной способностью по сравнению с традиционным скорингом и может быть использован в практике банковского бизнеса.

Ключевые слова: кредитный скоринг; классификация; машинное обучение; интерпретируемые и неинтерпретируемые методы; нейронная сеть; индекс Джини; ошибки первого и второго рода.

Одной из важнейших задач в сфере банковского розничного бизнеса является наиболее точное определение кредитоспособности будущих заемщиков, т. е. выявление потенциальных неплательщиков на стадии принятия решения о выдаче кредита. Чем точнее оценка кредитоспособности, тем ниже уровень будущих потерь по кредитному портфелю, а следовательно, выше уровень рентабельности. Исторически сложившимся способом оценки кредитоспособности физических лиц является так называемый кредитный скоринг – система присвоения баллов кредитополучателю на основании его способности и потенциала погасить долг.

В рамках кредитного скоринга потенциальному заемщику начисляются баллы по определенным признакам в зависимости от их конкретных значений с использованием простой статистической модели (например, есть иждивенцы – баллов меньше, есть в собственности жилье – баллов больше и т. д.) 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. Вместе с тем одной из его главных проблем всегда было и остается неоднозначное разделение клиентов на «хороших» и «плохих» (присутствие достаточно большой «серой зоны» – клиентов с трудно идентифицируемой кредитоспособностью, что обусловлено сложностями с увязкой конкретного количества баллов по каждому признаку и реальных исторических случаев дефолтов клиентов в рамках скорингового метода), т. е. часть платежеспособных потенциальных клиентов банками теряется и возникает недополученная прибыль.

В то же время в распоряжении банков находится такой мощный ресурс, как накопленная детальная статистика по всем историческим заемщикам и степени их успешности в обслуживании кредитных обязательств. На фоне трансформации финансового рынка и развития вычислительных технологий данную информацию можно использовать для разработки моделей оценки кредитоспособности, альтернативных кредитному скорингу и основанных на современных методах машинного обучения. Поэтому целью данной статьи является демонстрация потенциала одного из таких методов на реальных данных и его преимуществ по сравнению с традиционным кредитным скорингом.

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 данном случае объектами являются заемщики, признаками – их характеристики (данные анкеты, кредитная история и т. д.), классами – возможные результаты оценки (хороший клиент / будущий дефолтник). В этом смысле задача классификации заемщиков может быть решена стандартными методами машинного обучения, которое приобрело популярность в последние десятилетия. Следует отметить, что классификация объектов относится к типу «обучение с учителем», т. е. известны правильные классы, к которым относится каждый объект в обучающей выборке, в отличие от кластеризации, когда эти классы заранее неизвестны и алгоритм распределяет объекты самостоятельно по признаку схожести («обучение без учителя»). План действий, которые необходимо реализовать при построении модели машинного обучения «с учителем», представлен в следующих семи пунктах:

1. Сбор данных, их очистка, удаление пропусков и аномальных значений, перевод категориальных переменных в количественный формат и нормировка всех потенциальных объясняющих переменных.

2. Анализ репрезентативности выборки (нужно убедиться, что данные стабильны в пространстве и времени; для этого рассчитывается так называемый PSI индекс – индекс стабильности популяции), а также разбиение всех данных случайным образом на обучающую, валидационную и тестовую выборки в пропорции 70 % – 15 % – 15 % соответственно. Обучающая выборка – это данные, с помощью которых настраиваются параметры модели

(т. е. происходит ее обучение). Валидационная выборка, предназначенная для оценки возможной переобученности модели, определения ошибки прогнозирования и настройки гиперпараметров, показывает, как может повести себя модель с новыми данными. Тестовая выборка предназначена для оценки качества работы готовой модели машинного обучения.

3. Проведение однофакторного и многофакторного анализа по потенциальным объясняющим переменным: нужно проверить, насколько хорошо они связаны с целевой переменной и друг с другом (для этого, как правило, рассчитывается коэффициент ранговой корреляции Спирмена); удаление признаков, недостаточно связанных с целевой переменной или чрезмерно связанных между собой.

4. Выбор метода машинного обучения, настройка соответствующих гиперпараметров. Под гиперпараметрами понимаются параметры алгоритмов, значения которых устанавливаются перед запуском процесса обучения для управления его ходом, и настройки самих обучающих алгоритмов, которые помогают улучшить модель. Например, в случае искусственной нейронной сети гиперпараметрами являются форма функции активации, число скрытых слоев и количество нейронов в них.

5. Непосредственно обучение модели с заданными гиперпараметрами, получение значений необходимых параметров.

6. Анализ стабильности и точности модели, оценка возможных ошибок прогнозирования (как на валидационной, так и на тестовой выборках). К основным метрикам качества классификационных моделей относятся индекс Джини, ошибки первого и второго рода, коэффициент точности. Индекс Джини – это мера дискриминационной способности модели, принимающая значения в диапазоне от 0 до 1, где 1 – идеальный классификационный алгоритм, работающий без ошибок; 0 – угадывание случайным образом по аналогии с подбрасыванием монеты без какого-либо объяснения результата.

Допустим, задача состоит в разделении всех объектов из некоторого множества на два класса (как в случае с кредитоспособностью). Тогда одному классу можно присвоить метку «0» (заемщик кредитоспособный), а другому – метку «1» (заемщик некредитоспособный)¹⁵. И формулу для вычисления индекса Джини можно записать следующим образом:

$$Gini = 2 \frac{\sum_{i=1}^{n_1} \sum_{j=1}^{n_0} S(x_i, x_j)}{n_1 n_0} - 1, \quad (1)$$

где n_1 – количество объектов класса «1», n_0 – количество объектов класса «0», x_i – ответ модели машинного обучения на i -ом объекте из класса «1», x_j – ответ модели на j -ом объекте из класса «0», $S(x_i, x_j)$ вычисляется следующим образом:

$$S(x_i, x_j) = \begin{cases} 1, & x_i > x_j \\ \frac{1}{2}, & x_i = x_j \\ 0, & x_i < x_j \end{cases}$$

В случае бинарной классификации результатом работы (ответом) модели по каждому объекту является некоторое число в диапазоне от 0 до 1. Оно отражает вероятность принадлежности объекта к классу «1» (при моделировании кредитоспособности это вероятность дефолта заемщика). Поэтому крайне важно выбрать границу отсечения – количественный порог, при превышении модельной вероятностью которого объект будет отправляться в один

¹⁵Класс с меткой «1» обычно называют положительным классом, а класс с меткой «0» – отрицательным классом.

класс, а при непревышении – в другой. Стандартным подходом, который будет использоваться и в настоящей статье, является установка границы отсечения на уровне 0,5. То есть, если согласно модели вероятность дефолта данного заемщика выше 0,5, относим его классу неплатежеспособных, в противном случае – к классу платежеспособных.

Принцип действия формулы (1) интуитивно понятен. Если случайным образом извлечь пару объектов, где первый объект будет из класса «1», а второй – из класса «0» (количество таких пар объектов равно n_1, n_0), то при идеальной работе классификационного алгоритма всегда $x_i > x_j$, т. е. $Gini = 1$. Но если по «мнению» алгоритма вероятности обоих классов всегда равны, т. е. $x_i = x_j$, значит $Gini = 0$.

Значение индекса Джини зависит не от выбранной границы отсечения, а лишь от эффективности самого алгоритма в том смысле, что ответ модели на любой объект из класса «1» всегда должен быть больше ответа модели на любой объект из класса «0». Но если граница отсечения задана, то по итогам работы модели возможны следующие четыре исхода классификации:

1) положительный класс распознан как положительный (некредитоспособный заемщик классифицирован как некредитоспособный); такие наблюдения называют истинно положительными (True Positive – TP);

2) отрицательный класс распознан как отрицательный (кредитоспособный заемщик классифицирован как кредитоспособный); наблюдения, у которых это имеет место, называют истинно отрицательными (True Negative – TN);

3) отрицательный класс распознан как положительный (кредитоспособный заемщик классифицирован как некредитоспособный); наблюдения, для которых получен такой исход классификации, называются ложно положительными (False Positive – FP);

4) положительный класс распознан как отрицательный (некредитоспособный заемщик распознан как кредитоспособный); соответствующие наблюдения называют ложно отрицательными (False Negative – FN).

Исходы FP и FN являются ошибками, снижающими качество модели. Величина $FP / (FP + TN)$ называется ошибкой первого рода и отражает вероятность признания кредитоспособного заемщика будущим дефолтником. Величина $FN / (FN + TP)$ является ошибкой второго рода и характеризует вероятность признания дефолтного клиента платежеспособным. Соответственно, мера $(TN + TP) / (FN + FP + TN + TP)$ называется коэффициентом точности и отражает долю верно классифицированных заемщиков.

7. Определение сильных и слабых сторон построенной модели, выдача рекомендаций по практическому использованию.

Для разработки модели машинного обучения была использована выборка потребительских кредитов, выданных некоторыми белорусскими банками в 2019–2020 гг. по дистанционным каналам банковского обслуживания. К ним относятся, во-первых, кредитование, осуществляемое банками в рамках партнерских программ в розничных торговых сетях (целевые кредиты, выданные на приобретение бытовых товаров); во-вторых, нецелевое онлайн-кредитование через официальные интернет-ресурсы банков. В выборку вошли 6526 кредитных договоров, из которых 4568 были успешно обслужены клиентами и погашены, а 1958 оказались в дефолте (здесь и далее под дефолтом заемщика понимается возникновение просрочки по уплате основного долга более 90 дней). Таким образом, частота дефолтов в рассматриваемой выборке составляет 30 %, что делает ее достаточно сбалансированной и хорошо подходящей для целей моделирования. Промежуток времени между датами открытия и закрытия всех

недефолтных кредитных договоров превышает 1 год, что позволяет рассматривать факторы кредитоспособности, устойчиво действующие на более продолжительных интервалах. Так как промежуток выдачи всех кредитов в выборке достаточно короткий и охватывает всего 2 года, можно обойтись без предварительного расчета PSI-индекса (индекса стабильности популяции).

Моделируемая бинарная переменная *default_flag* принимает значение «1» в случае дефолтного кредита и «0» – в случае успешно обслуженного кредита. Каждое наблюдение имеет 14 признаков (объясняющих переменных), которые условно можно сгруппировать в 3 блока:

- 1) личные данные клиента: пол (*sex*), возраст (*age*), среднемесячный доход (*income*), образование (*education*), категория занимаемой должности (*position*), сфера деятельности (*field*);
- 2) параметры кредитного соглашения с банком: сумма кредита (*sum*), срок кредита (*term*), годовая процентная ставка по договору (*rate*);
- 3) данные, полученные 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 Республики Беларусь (*rating*); коэффициент долговой нагрузки DTI (*dti*).

Перечень используемых признаков, их краткая характеристика и способ нормировки¹⁶ представлены в таблице 1.

Для нормировки непрерывных переменных (в данном случае это *age*, *income*, *sum*, *term*, *rate*, *dti*) был использован метод минимакс. Категориальные бинарные переменные (*sex*, *history*) нормируются естественным образом через присвоение соответствующих значений {0, 1}. Для нормировки остальных категориальных переменных, которые могут принимать *n* различных значений (где *n* > 2), применялась следующая схема. Сперва уникальные значения каждой такой переменной ранжировались по априорной степени возрастания либо убывания кредитного риска (например, переменная *education* упорядочивалась по убыванию риска следующим образом: «неполное среднее образование», «среднее образование», «среднее специальное образование», «высшее образование», «два или более высших образования / ученая степень»; переменная *position* – по возрастанию риска следующим образом: «директор / владелец бизнеса», «прочие руководящие должности», «менеджер», «специалист», «рабочий» и т. д.; в частности, для переменных *crime*, *admin*, *rating* такое упорядочивание достаточно очевидно). После этого первому значению в ранжированном списке присваивалась метка 0, и далее с шагом $1/(n - 1)$ количественные метки ставились всем последующим значениям переменной до последнего с меткой 1.

Таблица 1 – Перечень и характеристика потенциальных факторных переменных

| Переменная | Тип переменной | Диапазон принимаемых значений | Способ нормировки | ρs |
|------------------------------|----------------|---|--|--------|
| Личные данные клиента | | | | |
| <i>sex</i> | Категориальная | 2 дискретных значения | Муж. = 1, жен. = 0 | 0,110 |
| <i>age</i> | Непрерывная | От 18 до 67 лет | Минимаксный метод | -0,029 |
| <i>income</i> | Непрерывная | От 300 до 8000 рублей | Минимаксный метод | -0,137 |
| <i>education</i> | Категориальная | 5 дискретных значений (уровни образования) | «Неполное среднее» = 0, далее с шагом 0,25 до «два или более высших» = 1 | -0,179 |
| <i>position</i> | Категориальная | 5 дискретных значений (категории должности) | «Директор / владелец бизнеса» = 0, далее с шагом 0,25 до «рабочий» = 1 | 0,171 |

¹⁶Под нормировкой здесь понимается перевод всех возможных значений объясняющих переменных в количественный диапазон от 0 до 1.

Окончание табл. 1

| | | | | |
|--------------------------------------|----------------|--|--|--------|
| <i>field</i> | Категориальная | 7 дискретных значений (сферы деятельности) | «IT-сфера» = 0, далее с шагом 0,1667 до «культура и развлечения» = 1 | 0,212 |
| Параметры кредитного договора | | | | |
| <i>sum</i> | Непрерывная | От 100 до 15 000 рублей | Минимаксный метод | 0,174 |
| <i>term</i> | Непрерывная | От 3 месяцев до 7 лет | Минимаксный метод | -0,111 |
| <i>rate</i> | Непрерывная | От 0 до 25 % годовых | Минимаксный метод | 0,544 |
| Данные из внешних источников | | | | |
| <i>crime</i> | Категориальная | 3 дискретных значения (0, 1 или 2 раза) | «Нет судимости» = 0, «одна судимость» = 0,5, «две судимости» = 1 | 0,269 |
| <i>admin</i> | Категориальная | 16 дискретных значений (от 0 до 15 раз) | От 0 до 1 с шагом 0,0667 | 0,079 |
| <i>history</i> | Категориальная | 2 дискретных значения | Есть = 1, нет = 0 | -0,109 |
| <i>rating</i> | Категориальная | 13 дискретных значений (12 классов рейтингов от A1 до D3 плюс отсутствие рейтинга) | A1 = 0, далее с шагом 0,0833 до D3 = 0,9167, случай «нет рейтинга» = 1 | 0,376 |
| <i>dti</i> | Непрерывная | От 0 до 40 % | Минимаксный метод | 0,112 |

Источник: собственная разработка.

Для проведения однофакторного и многофакторного анализа был использован коэффициент ранговой корреляции Спирмена (ρ_s). Данный показатель является непараметрической мерой корреляции (статистической связи между ранжированием двух признаков) и подходит для выборок, в которых присутствуют бинарные и (или) категориальные переменные. Коэффициент Спирмена оценивает, насколько хорошо связь между двумя переменными может быть описана с помощью монотонной функции. В контексте решаемой задачи это означает, что если, например, определенный признак значим для определения кредитоспособности, то дефолтным клиентам будут соответствовать наибольшие или наименьшие ранги данного признака в зависимости от того, является связь прямой или обратной. Коэффициент Спирмена принимает значения в диапазоне от -1 до 1 . Учитывая достаточно большой размер выборки, будем считать, что для идентификации присутствия связи достаточными являются значения коэффициента Спирмена, по модулю превышающие $0,1$.

Значения коэффициента ранговой корреляции Спирмена между целевой переменной *default_flag* и каждым из имеющихся в выборке признаков представлены в последней колонке таблицы 1. Как видно из полученных результатов, наибольшую связь признак дефолта имеет с переменными *rate*, *rating* и *crime*. У двух факторов (*age* и *admin*), напротив, отсутствует значимая статистическая взаимосвязь с целевой переменной. Это означает, что в рамках имеющейся выборки возраст заемщика и количество фактов его привлечения к административной ответственности никак не влияют на успешность обслуживания кредитов, поэтому данные переменные следует исключить из дальнейшего рассмотрения. Прочие признаки имеют различную степень коррелированности с целевой переменной, однако у всех у них значение $\rho_s > 0,1$, поэтому они остаются в работе.

Многофакторный анализ, в свою очередь, показал, что существует несколько групп значительно коррелированных признаков. Так, коэффициент Спирмена между переменными *history* и *rating* составляет $-0,532$. Это достаточно логично, так как в случае отсутствия у клиента кредитной истории (*history* = 0) рейтинга Национального банка у него также не будет. Далее значение между переменными *sum* и *term* равно $0,449$ (крупные кредиты, как правило, привлекаются на более длительные сроки, чем мелкие), между переменными *education* и *position* — $-0,343$ (лица с высшим образованием чаще занимают высокие должности), *income* и *position* — $-0,382$ (для более высоких должностей характерен

и более высокий уровень оплаты труда), *sex* и *income* – 0,323 (мужчины в целом имеют более высокий среднемесячный доход, чем женщины). Обычно при проведении многофакторного анализа к тесноте связи предъявляют менее строгие требования, чем в случае однофакторного анализа, поэтому граничное значение коэффициента Спирмена задается на уровне 0,5. Исходя из этих позиций, исключить из дальнейшего рассмотрения следует только признак *history*, так как в коррелированной паре $\{history, rating\}$ он в меньшей степени связан с целевой переменной.

Итак, по результатам однофакторного и многофакторного анализа 3 признака (*age*, *admin* и *history*) были исключены из первоначального списка факторов, а оставшиеся 11 переменных перешли в стадию моделирования. Но сперва предобработанный массив данных был случайным образом разделен на обучающую, тестовую и валидационную выборки в пропорции 70 % – 15 % – 15 %, детали указаны в таблице 2.

Таблица 2 – Исходные данные для моделирования

| Выборка | Количество наблюдений, | | Количество дефолтов, | |
|---------------|------------------------|------------------|----------------------|--------------|
| | единиц | % от всех данных | единиц | % от выборки |
| Обучающая | 4576 | 70,12 % | 1383 | 30,22 % |
| Тестовая | 981 | 15,03 % | 284 | 28,95 % |
| Валидационная | 969 | 14,85 % | 291 | 30,03 % |

Источник: собственная разработка.

С использованием описанных выше данных была протестирована возможность построения искусственной нейронной сети, которая считается одним из наиболее эффективных алгоритмов машинного обучения.




Рис. 1. Структура нейрона

Не останавливаясь подробно на технических деталях, ограничимся лишь общим описанием принципов работы данного алгоритма. В самом общем виде нейронная сеть как метод машинного обучения представляет собой математическую модель, обрабатывающую данные по принципу функционирования человеческого мозга. Базовым элементом такой модели является нейрон. Под нейроном понимается вычислительная единица, которая получает информацию, производит над ней простые вычисления и передает ее дальше. Нейрон, как правило, состоит из трех основных частей: 1) входа – нескольких синаптических каналов, соединенных с выходами других нейронов; каждый канал имеет определенный вес w_i ; 2) тела нейрона, представленного некоторой функцией активации (числа x_i , которые подаются на каждый канал входа, умножаются на соответствующие веса w_i и суммируются, а результат передается в функцию); 3) выхода – канала (аксона), с которого обработанный сигнал, представленный неким числом x' поступает на синапсы следующих нейронов. Структура типичного нейрона представлена на рисунке 1. В качестве функции активации могут использоваться различные пороговые функции (сигмоидная, ступенчатая, линейная, гиперболический тангенс и др.).

Нейронная сеть – это множество последовательно и параллельно соединенных нейронов, которые делятся на три основных типа: входные, скрытые и выходные. В классификационных сетях на входные нейроны подаются объясняющие переменные: одному нейрону соответствует строго одна переменная, которая умножается на соответствующий вес и передается дальше. Скрытые нейроны располагаются между входом и выходом и могут группироваться в несколько слоев. В скрытых слоях исходный вектор значений объясняющих переменных преобразуется в некоторое новое пространство, которое имеет другую размерность. Таким образом, на единственный выходной нейрон подаются не исходные характеристики объекта (объясняющие переменные), а своеобразные «характеристики характеристик», сформированные скрытыми нейронами. Результатом работы выходного нейрона, как и любой модели бинарной классификации, является некоторое число в диапазоне от 0 до 1, которое отражает определенный класс, присвоенный нейронной сетью объекту.

Наиболее распространенным способом обучения нейронной сети (настройки весов) является алгоритм обратного распространения ошибки. Его суть заключается в следующем. Сперва веса в нейронной сети выбирают случайным образом, а затем проводят через нее обучающие данные и итеративно корректируют веса так, чтобы общая ошибка уменьшалась. То есть на вход сети подается первое наблюдение, затем веса корректируются и ошибка минимизируется, после чего подается второе наблюдение и веса снова корректируются, и так до последнего наблюдения. После того, как один цикл обучения заканчивается, начинается следующий, и так до тех пор, пока общая ошибка не перестанет уменьшаться после окончания очередного цикла. Процесс достаточно трудоемкий и требует значительных ресурсов даже по меркам машинного времени.

Из изложенного выше следует, что основными гиперпараметрами, задаваемыми априори при моделировании кредитоспособности розничных клиентов на основе нейронной сети, являются количество скрытых слоев и нейронов в них, вид функции активации, а также шаг корректировки весов в процессе обучения (так называемая *learning rate* – скорость обучения). Согласно распространенному эмпирическому правилу [3], в качестве начального приближения числа скрытых нейронов в классификационных сетях берется полусумма количества нейронов во входном и выходном слоях. Так как в обучающих данных имеется 11 статистически значимых признаков, а на выходе должен располагаться один нейрон, то логично задать в архитектуре будущей сети 6 скрытых нейронов. Что касается моделирования именно кредитоспособности, то, как показал результат ряда зарубежных и отечественных исследований [1–4], очень редко качественный результат дает нейронная сеть, имеющая более двух слоев скрытых нейронов, поэтому 6 внутренних нейронов были разделены на два слоя: 4 нейрона в первом и еще 2 во втором. В качестве функции активации была выбрана сигмоидная функция, а *learning rate* задана на уровне 0,01.

Код для построения искусственной нейронной сети был написан на языке R в среде Rstudio. Веса, вычисленные в результате прогонки через нее обучающей выборки, приведены в таблице 3, а архитектура нейронной сети представлена на рисунке 2.

Общая ошибка нейронной сети на обучающих данных, не подлежащая дальнейшему уменьшению, составляет 206,9. Это очень хороший результат, учитывая, что в обучающей выборке 4576 наблюдений; выходит, что средняя ошибка в расчете на одно наблюдение составляет всего 0,045 (отклонение от 0 и 1 – недефолтного и дефолтного классов заемщиков соответственно). Для достижения такого качества потребовалось 43 138 шагов по последовательной корректировке весов сети.




Рис. 2. Архитектура обученной нейронной сети

Источник: собственная разработка.

Таблица 3 – Веса обученной нейронной сети

| Первый скрытый слой нейронов | | | | |
|------------------------------|----------|---------|----------|----------|
| номер нейрона | [1] | [2] | [3] | [4] |
| константа | -6,2746 | -4,4643 | 1,7296 | 6,3249 |
| sum | 0,0091 | -0,9434 | -4,4307 | -5,5507 |
| term | -0,5671 | 3,1624 | -3,1836 | -19,0234 |
| rate | 28,8154 | 24,0069 | -20,1722 | 46,2342 |
| sex | -0,2688 | -0,3955 | -0,1501 | 0,0894 |
| education | 0,2168 | 0,1452 | 0,5812 | -0,4153 |
| position | -0,0179 | 0,7699 | 0,2948 | 0,2551 |
| field | -3,0530 | -4,8099 | -2,3806 | -0,7727 |
| income | -39,8945 | 16,2857 | 41,5116 | 49,8571 |
| rating | 7,4297 | 3,4182 | -1,9767 | 1,1911 |
| dti | -2,2956 | 4,3811 | 2,9808 | 2,2440 |
| crime | -0,7685 | 0,2361 | -0,4767 | -0,7230 |
| Второй скрытый слой нейронов | | | | |
| номер нейрона | [5] | [6] | | |
| константа | 2,3802 | -0,7612 | | |
| выход нейрона [1] | -12,5175 | -6,6853 | | |
| выход нейрона [2] | 0,3668 | 7,2332 | | |
| выход нейрона [3] | -20,8307 | -6,8026 | | |
| выход нейрона [4] | 17,5795 | 0,4716 | | |
| Выходной нейрон | | | | |
| номер нейрона | [7] | | | |
| константа | -8,4717 | | | |
| выход нейрона [5] | 6,9839 | | | |
| выход нейрона [6] | 9,5234 | | | |

Источник: собственная разработка.

Так как в качестве функции активации выбрана сигмоидная функция, то нейронная сеть, по сути, представляет собой упорядоченный набор из нескольких логистических регрессий: каждая объясняющая переменная три раза пропускается через сигмоидную функцию с разными весами в составе линейных комбинаций признаков.

Веса, представленные в таблице 3, не несут в себе какого-либо экономического смысла – глядя на них, нельзя сказать, какова сила и направление связи с целевой переменной у каждого используемого признака; поэтому нейронные сети относятся к неинтерпретируемым методам машинного обучения. Тем не менее, как показывает таблица 4, разработанная классификационная нейронная сеть обладает достаточно высокой дискриминационной способностью.

Таблица 4 – Характеристики качества обученной нейронной сети

| Показатель | Выборка | | | | | | | | |
|-------------------------|---------------|------|-------|---------------|-----|-------|---------------|-----|-------|
| | Обучающая | | | Тестовая | | | Валидационная | | |
| | y=0 | y=1 | Итого | y=0 | y=1 | Итого | y=0 | y=1 | Итого |
| $a(x)=0$ | 2 991 | 394 | 3385 | 663 | 72 | 735 | 642 | 93 | 735 |
| $a(x)=1$ | 202 | 989 | 1191 | 34 | 212 | 246 | 36 | 198 | 234 |
| Итого наблюдений | 3193 | 1383 | 4576 | 697 | 284 | 981 | 678 | 291 | 969 |
| Индекс Джини | 0,86 | | | 0,86 | | | 0,83 | | |
| Ошибка 1-го рода | 6,3 % | | | 4,9 % | | | 5,3 % | | |
| Ошибка 2-го рода | 28,5 % | | | 25,4 % | | | 32,0 % | | |
| Коэф-т точности | 87,0 % | | | 89,2 % | | | 86,7 % | | |

Источник: собственная разработка.

Индекс Джини нейронной сети на тестовых данных достигает 0,86; ошибка первого рода составляет 4,9 %, а ошибка второго рода равна 25,4 %. Из этого следует, что модель пропускает около четверти будущих дефолтников. На первый взгляд такой результат может показаться неудовлетворительным, однако это не так. В задаче определения кредитоспособности заемщиков присутствует 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), относящаяся к наиболее сложным случаям, т. е. достижение абсолютно верной классификации невозможно. Также не следует забывать, что исходные данные, на которых обучалась модель, уже были пропущены через традиционный банковский скоринг, т. е. все наблюдения в выборке – это одобренные кредитные заявки, часть из которых впоследствии ушла в дефолт. Выходит, что применение искусственной нейронной сети поверх скоринговой модели может позволить снизить количество будущих дефолтов на три четверти и значительно повысить рентабельность кредитования. Причем, как показывает тестирование, уровень одобрения кредитных заявок при подключении нейронной сети снижается на 25 % (246/981). Среди «отсеченных» заявок окажется почти 5 % платежеспособных клиентов и 75 % будущих дефолтников ($(5 \% \cdot (1 - 0,3) + 75 \% \cdot 0,3)$, где 0,3 – частота дефолтов в тестовых данных).

Эффективность алгоритма хорошо визуализируется при помощи ROC-кривой (рис. 3). ROC-кривая (*Receiver Operating Characteristic*) отображает соотношение между долей объектов от общего количества носителей признака, верно классифицированных как несущие признак, и долей объектов от общего количества объектов, не несущих признака, ошибочно классифицированных как несущие признак при варьировании порога решающего

правила. Таким образом, ROC-кривая оценивает качество бинарной классификации: чем круче получается кривая (больше площадь, ограниченная ROC-кривой и осью доли ложных положительных классификаций), тем выше дискриминационная способность модели.

Серия альтернативных вычислительных экспериментов показала, что при увеличении количества скрытых слоев и нейронов в них разрыв между метриками качества на обучающей и валидационной выборках начинает возрастать (дальнейший рост качества на обучающей выборке, но постепенное снижение на валидационной), что свидетельствует о разумности заложенных при моделировании предпосылок (значений гиперпараметров).

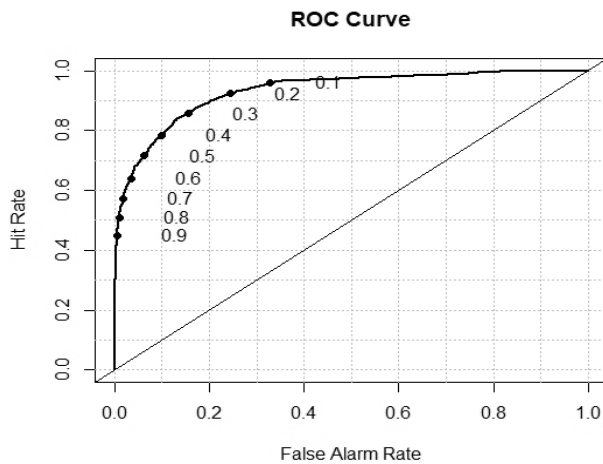


Рис. 3. ROC-кривая для разработанной нейронной сети

Источник: собственная разработка.

Конечно, неинтерпретируемость нейронных сетей накладывает некоторые ограничения на их использование в банковском бизнесе. Однако выходом могло бы стать использование данного алгоритма «поверх» традиционного скоринга, что позволило бы значительно увеличить эффективность розничного кредитования.

Источники

1. Хемахем, С. Прогнозирование кредитного риска: сравнительное исследование дискриминантного анализа и подхода на основе нейронных сетей / С. Хемахем, Ю. Бужельбен // Бухгалтерские и управленческие информационные системы. – 2015. – Т. 14, № 1. – С. 60–78.

Khemakhem, S. Credit risk prediction: A comparative study between discriminant analysis and the neural network approach / S. Khemakhem, Y. Boujelbène // Accounting and Management Information Systems. – 2015. – Vol. 14, № 1. – P. 60–78.

2. Мунхдалай, Л. Эмпирическое сравнение методов машинного обучения при оценке кредитоспособности клиентов банка [Электронный ресурс] / Л. Мунхдалай, О. Намсрай, Дж. Юн Ли // Устойчивое развитие. – 2019. – № 11. – Режим доступа: <https://www.mdpi.com/2071-1050/11/3/699>. – Дата доступа: 05.11.2022.

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. – № 11. – Mode of access: <https://www.mdpi.com/2071-1050/11/3/699>. – Date of access: 05.11.2022.

3. Гоял, С. Прогнозирование кредитного риска с использованием алгоритма искусственной нейронной сети [Электронный ресурс] / С. Гоял // Центр науки о данных, 2018. – Режим доступа: <https://www.datasciencecentral.com/profiles/blogs/credit-risk-prediction-using-artificial-neural-networkalgorithm>. – Дата доступа: 05.11.2022.

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-networkalgorithm>. – Date of access: 05.11.2022.

4. Власенко, М. Н. Оценка кредитоспособности физических лиц при помощи инструментария классификационных нейронных сетей / М. Н. Власенко // Банкаўскі веснік. – 2021. – № 3. – С. 19–30.

Ulasenka, M. N. Assessment of the creditworthiness of individuals using the tools of classification neural networks / M. N. Ulasenka // Bankovski Vesnik. – 2021. – № 3. – P. 19–30.

Статья поступила в редакцию 26.12.2022 г.

УДК 339.972

N. Voitovich

The Institute of Economics of the NASB (Minsk)

SCIENTIFIC AND TECHNOLOGICAL SECURITY: THE CONCEPT, ESSENCE AND FOREIGN EXPERIENCE OF ITS PROVISION

The article discusses the approaches to the definition of the concept of “scientific and technological safety”. The goals and objectives of ensuring scientific and technological security, as well as the interests of the state in the scientific and technological sphere are revealed. Threats to scientific and technological security are determined. The experience of ensuring scientific and technological security of foreign countries is considered. The article analyzes normative legal acts, program documents (strategies, concepts, etc.) of foreign countries in the field of scientific and technological security. The key directions, tools and mechanisms for ensuring scientific and technological security in the studied countries are revealed.

Keywords: *scientific and technological security; innovation; science; technology; scientific and technological sphere; national interests; threats; foreign experience; scientific and technological development; national security.*

Н. В. Войтович

ГНУ «Институт экономики НАН Беларуси» (Минск)

НАУЧНО-ТЕХНОЛОГИЧЕСКАЯ БЕЗОПАСНОСТЬ: ПОНЯТИЕ, СУЩНОСТЬ И ЗАРУБЕЖНЫЙ ОПЫТ ЕЕ ОБЕСПЕЧЕНИЯ

В статье рассмотрены подходы к определению понятия «научно-технологическая безопасность». Раскрыты цели и задачи обеспечения научно-технологической безопасности, а также интересы государства в научно-технологической сфере. Определены угрозы научно-технологической безопасности. Рассмотрен опыт обеспечения научно-технологической безопасности зарубежных стран. В статье проанализированы нормативные правовые акты, программные документы (стратегии, концепции и т. д.) зарубежных стран в области обеспечения научно-технологической безопасности.