

ОЦЕНКА РИСКА С ИСПОЛЬЗОВАНИЕМ АДАПТИВНОЙ НЕЙРО-НЕЧЕТКОЙ СИСТЕМЫ ВЫВОДА

А.А. Болгов

В работе предлагается использование адаптивной нейро-нечеткой системы вывода для оценки риска. Проводится подробный обзор адаптивной нейро-нечеткой системы вывода, выделяя основные свойства этой системы в области методов оценки рисков. Приведены основные преимущества использования адаптивной нейро-нечеткой системы вывода. Рассматривается архитектура адаптивной нейро-нечеткой системы вывода. Выделены и рассмотрены основные методы обучения системы. Предложены методы оценки эффективности модели на основе адаптивной нейро-нечеткой системы вывода для оценки риска. Представлен алгоритм внедрения адаптивной нейро-нечеткой системы вывода. Проводятся эксперименты, которые показывают влияние процесса обучения на форму функций принадлежности системы нечеткой логики. Выполнено сравнение результатов оценки риска, полученных с помощью нечеткой логики и при использовании адаптивной нейро-нечеткой системы вывода.

Ключевые слова: нейро-нечеткая система, нейронная сеть, метод обучения, функция принадлежности, риск, нечеткая логика, обучение.

Введение

Адаптивная нейро-нечеткая система вывода (АННСВ) – это искусственная нейронная сеть, основанная на нечеткой системе вывода Такаги-Сугено. Данная система интегрирует принципы нейронных сетей с принципами нечеткой логики [1]. АННСВ считается первой интегрированной гибридной нейро-нечеткой системой, которая использует подход декомпозиции для извлечения правил на отдельных узлах искусственной нейронной сети (ИНС) [2]. Затем извлеченные правила объединяются для построения глобальных описаний поведения. В источнике [3] говорится, что АННСВ – это тип адаптивных сетей, который функционально эквивалентен нечеткому интерфейсу системы (НИС). Она использует обучающие данные для автоматического создания нечетких правил и функций принадлежности. Как правило, сеть АННСВ состоит из соединённых между собой узлов, зависящих от параметров, которые постоянно изменяются после применения методов обучения для минимизации возможных ошибок. Наиболее распространенными методами обучения в АННСВ являются обратное распространение и гибридный метод обучения [3].

Основным свойством адаптивной нейро-нечеткой системы вывода является

оптимизация параметров системы нечеткой логики путем применения алгоритма обучения с использованием наборов данных ввода-вывода. Оптимизация параметров выполняется таким образом, чтобы ошибка, измеренная между целевым значением и фактическим результатом, была сведена к минимуму [4]. АННСВ обладает высокой способностью адаптироваться к окружающей среде в процессе обучения. Таким образом, его можно использовать для автоматической настройки функций принадлежности и уменьшения количества ошибок для определения нечетких правил системы нечеткой логики.

АННСВ объединяет в себе преимущества системы нечеткой логики и нейронной сети [3]. Это позволяет получить более лучшие результаты для приложений, где производительность важнее, чем интерпретация, поскольку результаты обучения могут быть трудными для интерпретации [5]. У адаптивной нейро-нечеткой системы вывода есть множество преимуществ [6]:

- оптимизирует нечеткие правила для описания поведения сложной системы;
- не требует наличия предварительного опыта у человека;
- обладает простотой в реализации;

- обеспечивает быстрое и точное выражения для решения задач обучение;
- создает более широкий выбор функций принадлежности для использования;
- обладает сильными способностями к обобщению;
- является отличным инструментом объяснения с помощью нечетких правил;
- позволяет легко использовать как лингвистические, так и численные

Архитектура АННСВ

Адаптивная нейро-нечеткая система вывода состоит из пяти уровней: нечеткий уровень, уровень продукта, нормализованный уровень, уровень дефаззификации и уровень суммирования [5], как показано на рис. 1.

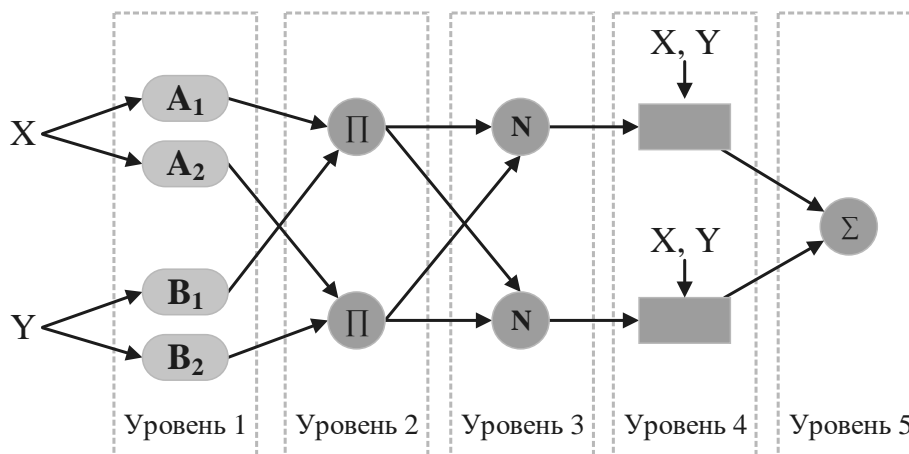


Рис. 1. Архитектура адаптивной нейро-нечеткой системы вывода

Уровень 1 – это входной уровень. В этом уровне четкие входные значения преобразуются в нечеткие с помощью функций принадлежности. Выходные данные каждого узла представляют собой значение степени принадлежности, которое задается на входе функции принадлежности [7].

Уровень 2 – это уровень продукта. Нейроны в этом уровне представляют собой нечеткие множества, используемые в предшествующих элементах нечетких правил. Нейрон фаззификации получает четкие входные данные и определяет степень, в которой эти входные данные принадлежат нечеткому набору нейрона. Каждый узел в этом уровне фиксирован, и помечен как Π . Выходной узел – это результат умножения значения, поступающего в узел и доставляемого следующему узлу. Каждый узел на этом уровне определяет весовой коэффициент каждого правила [8].

Уровень 3 – это уровень нечетких правил. Каждое нечеткое правило представлено нейроном в этом уровне. Этот нейрон получает входные данные от нейронов фаззификации, которые

представляют нечеткие множества в предшествующих элементах правила. Каждый узел в этом уровне фиксирован и помечен как N .

Уровень 4 – это выходной уровень принадлежности. Нейроны в этом уровне представляют нечеткие множества, используемые в последовательности нечетких правил. Выходной нейрон принадлежности объединяет все свои входные данные с помощью нечеткой операции объединения [9].

Уровень 5 – это уровень дефаззификации. Каждый нейрон в этом уровне представляет собой один выходной сигнал АННСВ. Он принимает выходные нечеткие множества с различными весами нечетких правил и объединяет их в единый нечеткий набор. Единственный узел в этом слое обеспечивает общий вывод в виде суммирования всех входящих значений из предыдущего узла. На этом уровне узел помечен как Σ [5].

Методы обучения АННСВ

Обучение является одной из важных функций, предоставляемых АННСВ для изменения параметров и снижения количества ошибок для адаптации к новым условиям. В АННСВ есть два распространенных метода обучения: гибридный и обратное распространение.

Гибридный метод обучения

Основной целью процесса обучения является обновление параметров системы для адаптации к окружающей среде. В архитектуре АННСВ первый и четвертый уровни содержат параметры, которые обновляются по мере обучения. Гибридный метод обучения является одним из распространенных методов обучения адаптивной нейро-нечеткой системы вывода [3]. Данный метод обучения состоит из двух основных частей, а именно прямого и обратного прохода. При прямом проходе параметры на первом уровне должны находиться в устойчивом состоянии. Метод рекурсивной оценки наименьших квадратов (RLSE) применяется для коррекции

параметров на четвертом уровне. Затем, после получения соответствующих параметров, входные данные подаются снова на вход адаптивной сети, и полученный результат сравнивается с фактическим результатом [7].

Во время прохода обратным распространением последующие параметры должны находиться в устойчивом состоянии. Ошибка, возникшая во время сравнения между полученным и ожидаемым результатом, передается обратно на первый уровень. В то же время исходные данные параметров на первом уровне обновляются с использованием методов обучения градиентного спуска или обратного распространения. При использовании гибридного метода обучения, который сочетает в себе методы RLSE и обратного распространения, можно обеспечить более высокую скорость сходимости, поскольку данный метод уменьшает размерное пространство поиска относительно оригинального метода обратного распространения [10].

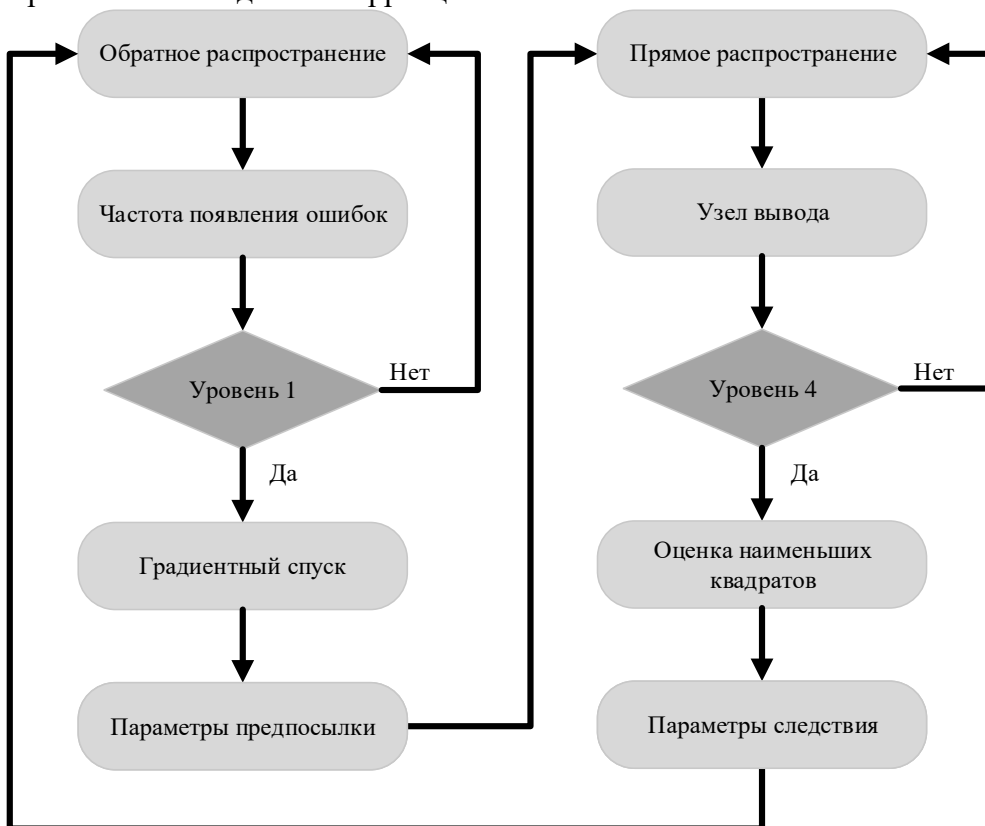


Рис. 2. Блок-схема гибридного алгоритма обучения

Метод RLSE используется для прямом распространении, в то время как оптимизации последующих параметров в метод обратного распространения

используется для оптимизации параметров предпосылки при обратном распространении, как показано на рис. 2. Выходные данные АННСВ вычисляются с использованием последующих параметров, найденных в прямом распространении. Ошибка на выходе

Метод обучения обратного распространения

Обратное распространение является распространенным методом обучения в нейронных сетях. Этот метод обучения многоуровневых нейронных сетей использует процесс контролируемого обучения. Контролируемые алгоритмы основаны на ошибках, в которых внешний опорный сигнал используется для получения сигнала ошибки путем сравнения полученного выходного сигнала с опорным сигналом. Используя сгенерированный сигнал ошибки, адаптивная нейро-нечеткая система вывода обновляет свои параметры для повышения производительности системы [12]. Метод обратного распространения обучается путем оценки в выходном уровне для извлечения ошибок в скрытых уровнях. Благодаря своей гибкости и возможностям обучения, он был успешно реализован в нескольких приложениях [13].

Процесс обучения обратным распространением можно описать следующим образом:

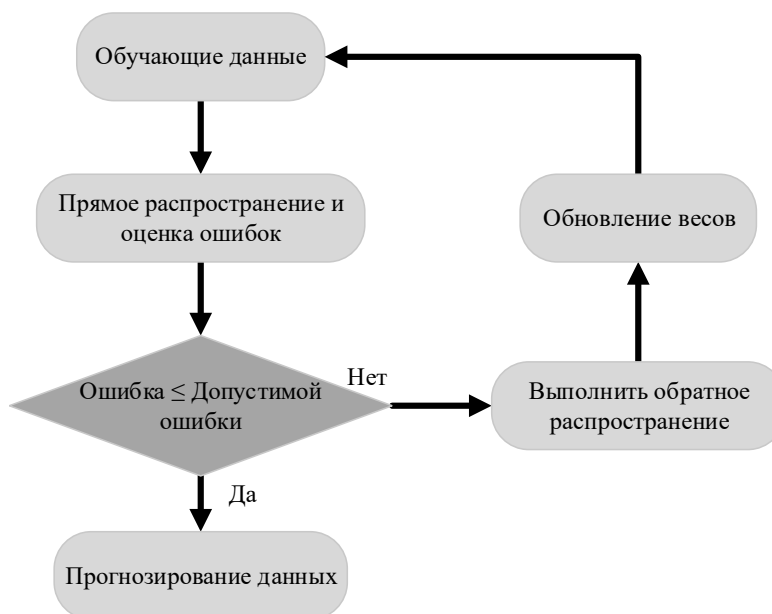


Рис. 3. Блок-схема алгоритма обратного распространения

используется для адаптации параметров предпосылки с помощью стандартного метода обратного распространения. Несколько исследований показали, что гибридный метод очень эффективен при обучении систем АННСВ [11].

- Прямое распространение рабочего сигнала: входной сигнал распространяется от входного уровня к выходному уровню через скрытый уровень. Во время прямого распространения рабочего сигнала значения веса и смещения сети поддерживаются неизменными, и состояние каждого нейрона уровня будет оказывать влияние только на нейрон следующего уровня. В случае, если на выходном уровне ожидаемый результат не может быть достигнут, то он может быть переключен на обратное распространение ошибки сигнала [14].

- Обратное распространение ошибки сигнала: разница между желаемым выходом и полученным выходом сети определяется как ошибка сигнала. В способе обучения с обратным распространением ошибка сигнала распространяется от выходного уровня к входному уровню. Во время обратного распространения ошибки сигнала значение веса сети регулируется обратной связью по ошибке. Непрерывная модификация значений веса и смещения используются для того, чтобы сделать полученный выходной сигнал сети более близким к желаемому [14].

Основная цель метода обучения с обратным распространением ошибки состоит в том, чтобы скорректировать значения веса в обучающем наборе данных, чтобы получить то же значение, что и ожидается увидеть на выходе сети, используя набор данных проверки. Технологическая схема метода обратного распространения показана на рис 3. При прямом распространении входные веса вводятся в последующий слой. Функция активации реализована с целью генерации весов для следующего слоя [15]. Наконец, выходной слой готов к генерации выходного значения. Сгенерированные и исходные значения выходных данных используются для расчета ошибки, которая распространяется обратно на входной уровень. Этот процесс будет продолжаться до тех пор, пока ошибка не станет меньше заданного допуска к ошибкам и сеть не будет готова к использованию. Помимо этого, обучение может быть прекращено при достижении максимального количества эпох [15, 16].

Внедрение АННСВ

АННСВ – это нечеткий интерфейс системы типа Сугено, в котором параметры,

связанные с функциями принадлежности, вычисляются с использованием метода обучения обратным распространением, либо в сочетании с методом наименьших квадратов (гибридный метод). Нечеткий интерфейс системы широко применяется к случайным последовательностям данных с крайне нерегулярной динамикой [8]. Реализация адаптивной нейро-нечеткой системы вывода требует:

- построения системы нечеткой логики с определением лингвистических выражений как для ввода, так и для вывода;
- определения нечетких множеств для ввода и вывода;
- задания функций принадлежности;
- построения нечетких правил;
- обучения нейронной сети.

Поскольку предложенный метод оценки риска был реализован с использованием системы нечеткой логики ранее, как обсуждалось в работе [17], поэтому в данной статье основное внимание уделяется только обучению адаптивной нейро-нечеткой системы вывода для достижения наилучшей точности для предлагаемого процесса оценки риск.

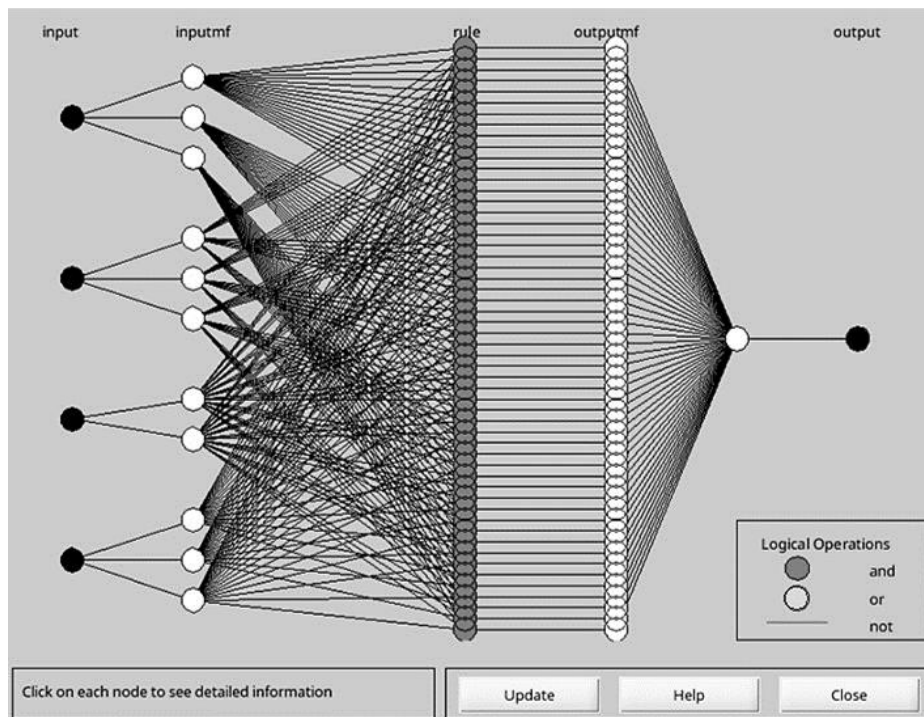


Рис. 4. Модель АННСВ предлагаемого метода оценки риска

Модель на основе АННСВ обучена для определения соответствующего количества эпох, функции принадлежности и предлагаемого метода оценки риска была

метода обучения, которые дают наименьшую ошибку и наилучшим образом соответствуют процессу обучения. На рис. 4 показана структура модели на основе АННСВ предлагаемого метода оценки риска.

Как обсуждалось ранее, модель на основе адаптивной нейро-нечеткой системы вывода состоит из пяти уровней. Входной уровень содержит четыре входных параметра контроля доступа предлагаемой модели на основе рисков:

- контекст пользователя;
- оценка критичности ресурса;
- оценка критичности операции;
- история рисков.

Второй уровень содержит нечеткие наборы каждого входного сигнала, в которых каждый параметр представлен тремя нечеткими наборами.

Третий уровень представляет собой нечеткие правила метода оценки риска, которые представлены заданным набором правил.

Четвертый уровень представляет собой выходную функцию принадлежности, которая была представлена пятью нечеткими наборами.

Пятый уровень представляет собой выходной уровень, который возвращает итоговое значение оценки риска.

Основная цель обучения модели на основе АННСВ в предложенной методике оценки риска состоит в настройке различных функций принадлежности и определении подходящей из них, которая в конечном итоге даст наименьшую ошибку и наилучшим образом будет соответствовать процессу обучения. Помимо этого, использование адаптивной нейро-нечеткой системы вывода добавит возможность обучения в процесс оценки рисков для адаптации к новым изменениям различных приложений Интернета вещей и позволит повысить точность полученных значений риска для будущих запросов на доступ.

Сбор данных

Для реализации модели на основе адаптивной нейро-нечеткой системы вывода требуется наличие набора данных или примеров для обучения. После реализации предложенной методики оценки рисков с

использованием системы нечеткой логики на основе экспертных оценок, как обсуждалось в работе [17], был создан набор данных для обучения АННСВ. Чтобы избежать возможного смещения выборки данных в сторону модели на основе АННСВ, набор данных был рандомизирован и разделен на два набора с использованием метода перекрестной проверки.

- Обучающий набор – этот набор содержит 70% от общего набора данных для обучения модели.

- Контрольный набор – этот набор содержит 30% от общего набора данных для тестирования модели.

Экспериментальные результаты

Было проведено несколько экспериментов для обучения модели предложенного метода оценки риска, чтобы повысить точность значений выходного риска, а также определить и настроить различные функции принадлежности, использование которых должно привести к наименьшей ошибке и наилучшим образом соответствовать процессу обучения при различном количестве периодов обучения. Все обучающие функции и эксперименты были выполнены с использованием программного обеспечения MATLAB.

Оценка эффективности

Модель на основе АННСВ была обучена и ее производительность оценивалась с использованием среднеквадратичной ошибки (RMSE), средней абсолютной ошибки (MAE), коэффициента корреляции (R) и коэффициента детерминации (R^2), как рекомендовано в соответствующих моделях АННСВ [18, 19].

Среднеквадратичная ошибка

Среднеквадратичная ошибка (RMSE) – это часто используемая мера различий между прогнозируемыми и наблюдаемыми значениями, которая измеряет среднюю величину ошибки. Величина этой ошибки рассчитывается, как квадратный корень из среднего значения квадратов различий между прогнозируемым и фактическим объемом производства [19]. Математическое

представление RMSE выглядит следующим образом:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2},$$

где n – общее количество данных, O_i – наблюдаемое (целевое) значение, а P_i – прогнозируемое значение.

Средняя абсолютная погрешность

Средняя абсолютная погрешность (MAE) упоминалась в нескольких моделях на основе АННСВ в качестве основного показателя эффективности [21, 22, 23]. MAE напрямую вычисляет среднее арифметическое абсолютных ошибок. Следовательно, его очень легко вычислить. Однако это может привести к необъективным результатам, когда в наборах данных существуют чрезвычайно большие выбросы [20]. Математическое представление MAE выглядит следующим образом:

$$MAE = \sum_{i=1}^n (O_i - P_i),$$

где n – общее количество данных, O_i – наблюдаемое (целевое) значение, а P_i – прогнозируемое значение.

Коэффициент корреляции

Коэффициент корреляции (R) используется для измерения корреляции между наблюдаемым значением и прогнозируемым значением. Он измеряет силу линейной зависимости между наблюдаемым и прогнозируемыми значениями [15]. Другими словами, это индикатор рассеяния вокруг линии соответствия. Если R близко к 1, это означает, что взаимосвязь между наблюдаемыми и прогнозируемыми переменными положительна и, таким образом, указывает на то, что точки данных лежат почти вдоль линии подгонки с положительным наклоном. Принимая во внимание, что, когда R близко к -1, взаимосвязь между наблюдаемыми и прогнозируемыми переменными отрицательна, и точки данных лежат почти вдоль линии подгонки с отрицательным наклоном. Когда R близко к нулю, это подразумевает слабую взаимосвязь между наблюдаемыми и прогнозируемыми переменными, а точки данных разбросаны

вокруг линии подгонки, и большинство точек данных не очень хорошо согласуются с линией подгонки [20]. Математическое представление R выглядит следующим образом:

$$R = \frac{n \sum_{i=1}^n O_i P_i - \sum_{i=1}^n O_i \sum_{i=1}^n P_i}{\sqrt{\left(n \sum_{i=1}^n O_i^2 - \left(\sum_{i=1}^n O_i \right)^2 \right) \left(n \sum_{i=1}^n P_i^2 - \left(\sum_{i=1}^n P_i \right)^2 \right)}},$$

где n – общее количество данных, O_i – наблюдаемое (целевое) значение, а P_i – прогнозируемое значение.

Коэффициент детерминации

Коэффициент детерминации (R^2) – это показатель того, насколько хорошо линия регрессии представляет данные. Если бы линия регрессии проходила точно через каждую точку на точечном графике, она смогла бы объяснить все вариации [19]. Этот коэффициент является статистическим показателем, который выражает качество соответствия уравнения регрессии и интенсивность линейной зависимости. Это помогает получить общее представление о том, подходит ли выбранная модель или нет. Значение коэффициента детерминации находится в диапазоне от 0 до 1 и, если оно близко к 1, то можно сказать о том, что выбранная модель подходит достаточно хорошо [20]. Математическое представление R^2 выглядит следующим образом:

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=0}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=0}^n (P_i - \bar{P})^2}} \right)^2,$$

где n – общее количество данных, O_i – наблюдаемое (целевое) значение, а P_i – прогнозируемое значение, \bar{O} – среднее наблюдаемое значение, а \bar{P} – среднее прогнозируемое значение.

Нечеткая система и АННСВ

Ранее было предложено оценивать риск с использованием системы нечеткой логики с помощью НИС Мамдани. Одной из основных проблем, применения НИС Мамдани при оценке рисков, является выбор подходящей

функции принадлежности, которая в свою очередь обеспечивала бы наилучшую точность для полученного риска. Поэтому было предложено использовать адаптивную нейро-нечеткую систему вывода для того, чтобы получить оптимальный способ настройки различных функций принадлежности, что в свою очередь приведет к повышению точности выходных данных, а также добавит возможность обучения предлагаемому методу оценки риска.

После нескольких экспериментов в качестве оптимальной функции принадлежности была выбрана TrapMF с гибридным методом обучения. Для реализации предложенной методики оценки риска модель на основе АННСВ проходила обучение при разном количестве эпох. На рис. 5 показано влияние обучения на форму

функций принадлежности. На нем наглядно видно, как изменилась форма нечетких множеств функции принадлежности TrapMF для оценки критичности ресурса и оценки критичности ресурса до и после обучения. Очевидно, что в процессе обучения были внесены значительные изменения в формы функций принадлежности. Аналогичные изменения можно увидеть и на других нечетких множествах компонентов предлагаемой модели, а именно: контекста пользователя и истории рисков до и после процесса обучения. Помимо этого, стоит обратить внимание, какое влияние оказало обучение на нечеткие правила и значение выходного риска. После обучения модели риск стал равен 56.3, тогда как до обучения он был равен 61.7 для тех же комбинаций входных данных.

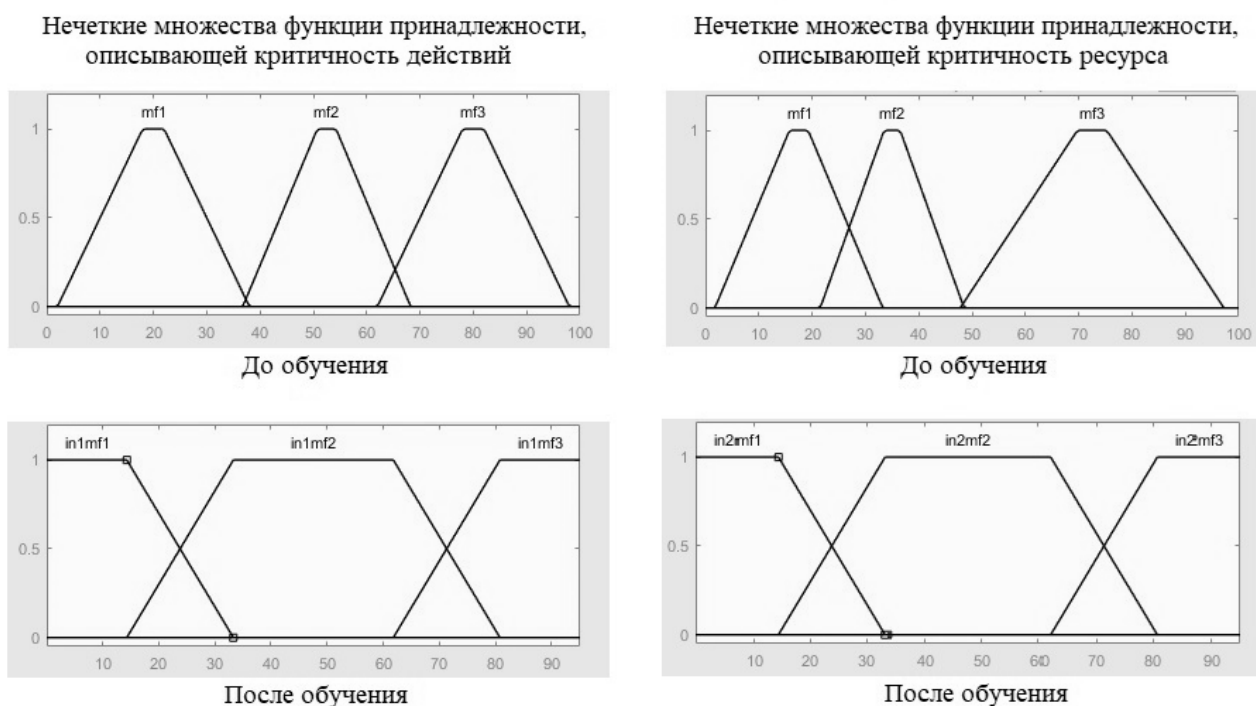


Рис. 5. Форма нечетких множеств функции принадлежности TrapMF критичности операций и критичности ресурса до и после обучения

Заключение

Результатом данной работы является реализация процесса оценки рисков с использованием адаптивной нейро-нечеткой системы вывода. АННСВ считается первой интегрированной гибридной нейро-нечеткой моделью, которая объединяет преимущества искусственных нейронных сетей и системы нечеткой логики. Ключевой целью АННСВ

является оптимизация параметров системы нечеткой логики путем применения алгоритма обучения с использованием наборов данных ввода-вывода. Эта оптимизация выполняется таким образом, что погрешность измерения между целевым и фактическим результатом сводится к минимуму. Чтобы настроить различные функции принадлежности и добавить

возможности обучения в метод оценки рисков предлагаемой риск-ориентированной модели была предложена адаптивная нейронечеткая система вывода. Были проведены эксперименты с использованием двух отдельных наборов данных: обучающего и контрольного, для обучения и проверки точности обученной модели. После нескольких экспериментов, было зафиксировано влияние обучения на форму функций принадлежности. Результатом работы модели на основе адаптивной нейронечеткой системы выводы по оценке риска стало то, что значение риска уменьшилось до более реального.

Таким образом, можно сделать вывод о том, что использование адаптивной нейронечеткой системы вывода для предлагаемой риск-ориентированной модели контроля доступа является более подходящим и гибким инструментом для оценки риска в сетях Интернета вещей. Это связано с тем, что благодаря АННСВ, модель может обучаться и подстраиваться под динамически изменяющиеся входные данные и параметры системы.

Список литературы

1. ANFIS [Электронный ресурс]. – 2022. – URL: <https://ru.wikipedia.org/wiki/ANFIS>
2. Zanchettin C., Mimku L., Ludermir T. Design of Experiments in Neuro-Fuzzy Systems. International Journal of Computational Intelligence and Applications, 2010. no. 09(02), pp. 137–152.
3. Jang, J. S. R. ANFIS: Adaptive-Network-Based Fuzzy Inference System. IEEE Transactions on Systems, Man and Cybernetics, 1993, no. 23(3), pp. 665–685.
4. Guney K. Concurrent neuro-fuzzy systems for resonant frequency computation of rectangular, circular, and triangular microstrip antennas. Progress In Electromagnetics Research, 2008, no. 84, pp. 253–277.
5. Wu Y., Zhang B., Lu J., Du K. L. Fuzzy Logic and Neuro-fuzzy Systems: A Systematic Introduction. International Journal of Artificial Intelligence and Expert Systems, 2011), no. 2(2), pp. 47–80.
6. Al-Hmouz A., Jun Shen, Al-Hmouz R., Jun Yan. Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning. IEEE Transactions on Learning Technologies, 2012, no. 5(3), pp. 226–237.
7. Suparta W., Alhasa K. M. Adaptive Neuro-Fuzzy Interference System. In Modeling of Tropospheric Delays Using ANFIS, Springer International Publishing Inc, 2016, pp. 5–19.
8. Gao P., Xue L., Lu Q., Dong C. Effects of alkali and alkaline earth metals on N-containing species release during rice straw pyrolysis. Energies, 2015, no. 8(11), pp. 13021–13032.
9. Vieira J., Dias F. M., Mota A. Neuro-Fuzzy Systems: A Survey. In: 5th WSEAS NNA International Conference on Neural Networks and Applications, 2004, pp. 1–6.
10. Pramanik N., Panda R. K. Application of neural network and adaptive neuro-fuzzy inference systems for river flow prediction. Hydrological Sciences Journal, 2009, no. 54(2), pp. 247–260.
11. Jang J. R., Sun C., Mizutani E. Neuro-Fuzzy and Soft-Computing. Prentice Hall, Upper Saddle River, NJ, 1997.
12. Saduf M., Wani A. Comparative Study of Back Propagation Learning Algorithms for Neural Networks. International Journal of Advanced Research in Computer Science and Software Engineering, 2013, no. 3(12), pp. 1151–1156.
13. Haykin S. Neural Networks – A Comprehensive foundation. 2nd Ed., Pearson Education, 2004.
14. Li Jing, Cheng J., Shi J., Huang F. Brief Introduction of Back Propagation (BP) Neural Description of BP Algorithm in Mathematics. Advances in Computer Science and Information Engineering, 2012, no. 2, pp. 553–558.
15. Shaf J., Angelov P., Umair M. Prediction of the Attention Area in Ambient Intelligence Tasks. In: Sgurev V., Yager R., Kacprzyk J., Jotsov V. (eds) Innovative Issues in Intelligent Systems. Studies in Computational Intelligence, Springer, Cham, 2016, vol 623.
16. Okut H. Bayesian Regularized Neural Networks for Small Big Data. Artificial Neural Networks - Models and Applications, 2016, pp. 28–48.
17. Болгов А.А., Ермаков С.А., Паринаова Л.В., Баранников Н.И. Оценка риска безопасности в сетях интернета вещей. // Информация и безопасность: Регион. науч. -

техн. журнал. – Воронеж, 2020. – Т. 23. – №4. – С. 561-566.

18. Ghorbanzadeh O., Rostamzadeh H., Blaschke T., Gholaminia K., Aryal J. A new GIS-based data mining technique using an adaptive neuro-fuzzy inference system (ANFIS) and k-fold cross-validation approach for land subsidence susceptibility mapping. *Natural Hazards*, 2018, no. 94(2), pp. 497–517.

19. Tiwari S., Babbar R., Kaur G. Performance Evaluation of Two ANFIS Models for Predicting Water Quality Index of River Satluj (India). *Advances in Civil Engineering*, 2018, pp. 1–10.

20. Konaté A. A., Pan H., Khan N., Yang J. H. Generalized regression and feed-forward back propagation neural networks in modelling porosity from geophysical well logs. *Journal of*

Petroleum Exploration and Production Technology, 2015, no. 5(2), pp. 157–166.

21. Ahmed A. M., Shah S. A. Application of adaptive neuro-fuzzy inference system (ANFIS) to estimate the biochemical oxygen demand (BOD) of Surma River. *Journal of King Saud University - Engineering Sciences*, 2017, no. 29(3), pp. 237–243.

22. De Myttenaere A., Golden B., Le Grand B., Rossi F. Mean Absolute Percentage Error for regression models. *Neurocomputing*, 2015, no. 192, pp. 38–48.

23. Rahbari O., Mayet C., Omar N., Mierlo J. Battery Aging Prediction Using Input-Time-Delayed Based on an Adaptive Neuro-Fuzzy Inference System and a Group Method of Data Handling Techniques. *Applied Sciences*, 2018, no. 8(8), p. 1301.

Воронежский государственный технический университет
Voronezh State Technical University

Поступила в редакцию 11.11.2022

Информация об авторе

Болгов Андрей Александрович – аспирант, Воронежский государственный технический университет, e-mail: mnac@comch.ru

RISK ASSESSMENT USING ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM

A.A. Bolgov

The work proposes the use of an adaptive neuro-fuzzy inference system for risk assessment. A detailed review of the adaptive neuro-fuzzy inference system is carried out, highlighting the main properties of this system in the field of risk assessment methods. The main advantages of using an adaptive neuro-fuzzy inference system are given. The architecture of an adaptive neuro-fuzzy inference system is considered. The main methods of teaching the system are highlighted and considered. Methods for evaluating the effectiveness of the model based on an adaptive neuro-fuzzy inference system for risk assessment are proposed. An algorithm for implementing an adaptive neuro-fuzzy inference system is presented. Experiments are being conducted that show the influence of the learning process on the form of the membership functions of the fuzzy logic system. The results of risk assessment obtained using fuzzy logic and using adaptive neuro-fuzzy inference system are compared.

Keywords: neuro-fuzzy system, neural network, training method, membership function, risk, fuzzy logic, training.

Submitted 11.11.2022

Information about the author

Andrey A. Bolgov – graduate student, Voronezh State Technical University, e-mail: mnac@comch.ru