

О. В. Р о г о з и н

ОЦЕНКА ИННОВАЦИОННОЙ ПРИВЛЕКАТЕЛЬНОСТИ ПРОЕКТА С ИСПОЛЬЗОВАНИЕМ НЕЙРО-НЕЧЕТКОГО АДАПТИВНОГО ПРОГРАММНОГО КОМПЛЕКСА

Рассмотрен программный комплекс анализа качественных характеристик инновационного проекта, разработанный с помощью созданной нейро-нечеткой модели, благодаря которой можно получать эффективное решение для слабо-структурируемых задач. Предложен подход к реализации структуры системы на основе процессной организации, приведена реализация модуля для наиболее известного алгоритма нечеткого вывода Мамдани. Разработана система критериев для оценки эффективности инновационного проекта. Проведен анализ скорости и качества обучения системы.

E-mail: logic00@mail.ru

Ключевые слова: нечеткая логика, нейронная сеть, поддержка принятия решений, инновационный проект, качество.

Задача разработки и внедрения новых технологий состоит в инновационном выборе эффективного варианта решения. В качестве такого решения будем понимать объединение инновационных проектов на основе цели или набора целей и критериев выбора. Инновационные проекты могут включать как завершенные, так и не завершенные процессы. Каждый инновационный процесс представляет собой совокупность технологий, материальных и временных ресурсов, затрачиваемых на их выполнение.

Сформируем набор показателей эффективности инновационного проекта и представим обобщенную модель такого проекта процессного типа в виде $I < I_n, G, T, R >$, где I – инновационный проект; I_n – начальное состояние инновационного проекта; G – цель; T – технологии или правила перехода от одного состояния проекта к другому; R – ресурсы, используемые при этом. В показатели оценки проекта включим:

- финансовые результаты реализации проекта;
- воздействие данного проекта на другие в рамках портфеля НИОКР корпорации;
- влияние проекта в случае его успеха на экономику корпорации в целом.

Все эти факторы зависят от состояния рынка и, соответственно, в значительной степени непредсказуемы. Таким образом, при оценке проекта мы имеем дело с типичной задачей принятия решений в условиях неопределенности.

Предложенный метод оценки эффективности инновационного проекта основан на использовании нейро-нечеткого вывода, объединяющего в себе естественность нечеткой логики и обучаемость нейронных сетей, с использованием так называемых уточняемых нечетких множеств, т. е. нечетких множеств, для которых функции принадлежности могут быть скорректированы с помощью нейронной сети особой структуры.

Критерии оценки эффективности инновационного проекта.

До начала оценки проекта необходимо любым способом выделить критерии, по которым будет производиться оценка. Большая часть критериев оценки не относится к научно-технической области. Инновации (успешные и неуспешные) распространяются на деятельность всей компании и становятся частью ее экономической деятельности. Все критерии можно подразделить на пять групп.

1. Критерии, связанные с целями корпорации, ее стратегиями, политикой и ценностями: совместимость проекта с текущей стратегией компании и ее долгосрочными планами; допустимость изменений в стратегии фирмы с учетом потенциала проекта; согласованность проекта с представлениями о компании; соответствие проекта отношению корпорации к риску; соответствие проекта отношению корпорации к нововведениям; соответствие временного аспекта проекта требованиям корпорации.

2. Рыночные критерии: соответствие проекта четко определенным потребностям рынка; общая емкость рынка; доля рынка, которую сможет контролировать корпорация; жизненный цикл продукта в виде товара; вероятность коммерческого успеха; вероятный объем продаж; временной аспект рыночного плана; воздействие на существующие продукты; ценообразование и восприятие продукта потребителями; позиция в конкуренции; соответствие продукта существующим каналам распределения; оценка стартовых затрат.

3. Научно-технические критерии: соответствие проекта стратегии НИОКР; допустимость изменений в стратегии НИОКР с учетом потенциала проекта; вероятность технического успеха проекта; стоимость и время разработки проекта; патентная чистота проекта; наличие научно-технических ресурсов для выполнения проекта; возможность выполнения будущих НИОКР на базе данного проекта и новой технологии; воздействие на другие проекты.

4. Финансовые критерии: стоимость НИОКР; вложения в производство; вложения в маркетинг; наличие финансов в соответствующие моменты времени; влияние на другие проекты, для которых требуются финансовые средства; время достижения точки безубыточности и максимальное отрицательное значение расходов; потенциальный годовой размер прибыли, ожидаемая норма прибыли; соответствие проекта критериям эффективности инвестиций, принятым в компании;

производственные критерии; новые технологические процессы; достаточная численность и квалификация производственного персонала; соответствие проекта имеющимся производственным мощностям; цена и наличие материалов; производственные издержки, потребности в дополнительных мощностях.

5. Внешние и экономические критерии: возможные вредные воздействия продуктов и технологии, влияние общественного мнения, текущее и перспективное законодательство, воздействие на уровень занятости.

В этот перечень входят все возможные критерии оценки. Для конкретных проектов, как правило, используются только наиболее значимые критерии: соответствие проекта отношению корпорации к риску; вероятность коммерческого успеха; стоимость и время разработки проекта; возможность выполнения будущих НИОКР на базе данного проекта и новой технологии; стоимость НИОКР; вложения в производство, в маркетинг; время достижения точки безубыточности и максимальное отрицательное значение расходов; потенциальный годовой размер прибыли, цена и наличие материалов.

Каждый из приведенных выше критериев обладает определенной степенью нечеткости, его можно описать такими лингвистическими понятиями, как “высокий”, “низкий”, “минимальный” и пр. Многие критерии с трудом поддаются числовому выражению. Поэтому в данном случае очень удобно использовать нечеткую логику для описания зависимости эффективности проекта от выбранных качественных критериев. Количество знаний о конкретном проекте и об инновациях в целом накапливается с течением времени, уменьшая степень неопределенности при оценке проекта. Эти знания должны быть использованы для обучения системы оценки и увеличения точности ее предсказаний.

Созданная система, основанная на объединении нечеткой логики и нейронных сетей, предоставляет возможность удобного для человека представления знаний и самообучения на основе статистических данных (рис. 1.)

Нейро-нечеткая гибридная система. *Уточняемое нечеткое множество* определим как нечеткое множество, функция принадлежности которого может быть скорректирована в процессе обучения гибридной сети, построенной на основе механизма нечеткого вывода. Для объединения достоинств продукционной модели и нейронных сетей появилась гибридная система, основанная на нейро-нечеткой модели. Данная система сочетает в себе возможности обучения и задания знаний на языке, близком к естественному. Под гибридной системой будем понимать такую систему, в которой комбинируются подходы и методы нейронных сетей, экспертных и нечетких систем (рис. 2).

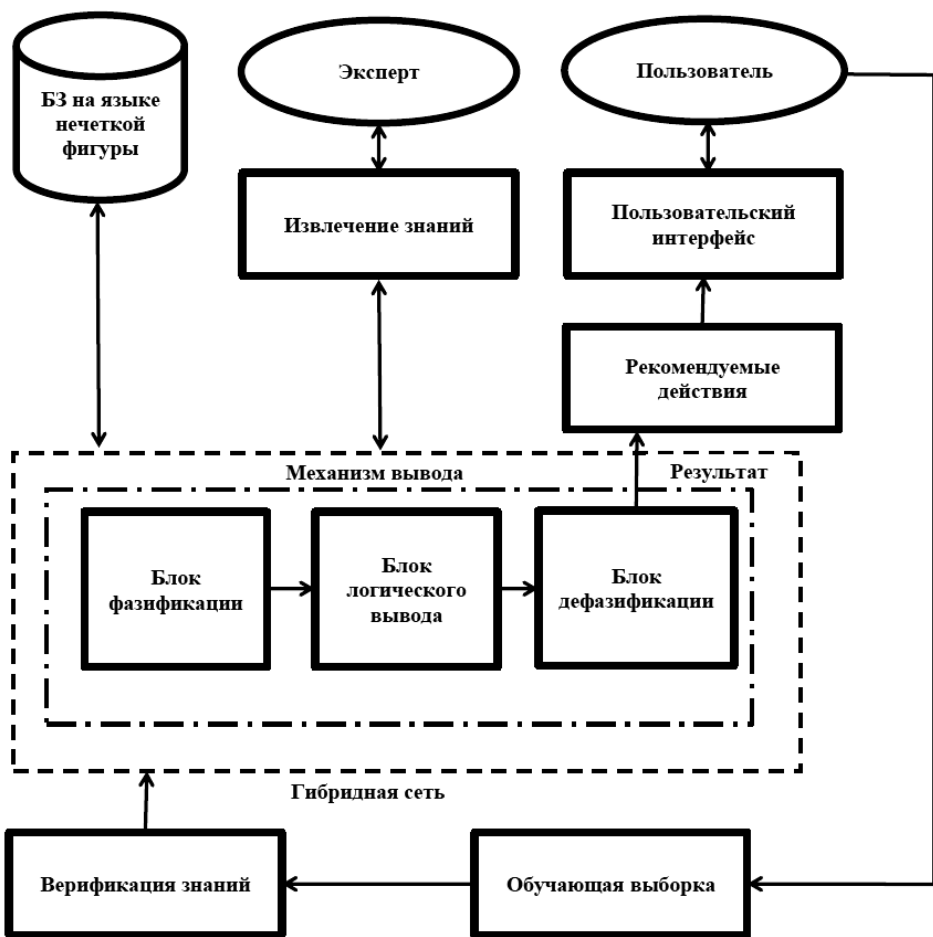


Рис. 1. Структура нейро-нечеткой системы

Адаптивная нейро-нечеткая система вывода на основе алгоритма Суджено. Рассмотрим способ конструирования гибридных систем, основанных на методе Суджено. Пусть система имеет следующие правила:

“ R_1 : если x_1 есть A_{11} и x_2 есть A_{12} , то $z = c_{11}x_1 + c_{12}x_2$ ”;

“ R_2 : если x_1 есть A_{21} и x_2 есть A_{22} , то $z = c_{21}x_1 + c_{22}x_2$ ”.

Выход системы представлен формулой

$$z_0 = \frac{\sum_{i=1}^n \alpha_i z_i}{\sum_{i=1}^n \alpha_i},$$

где z_i — выход i -го правила.

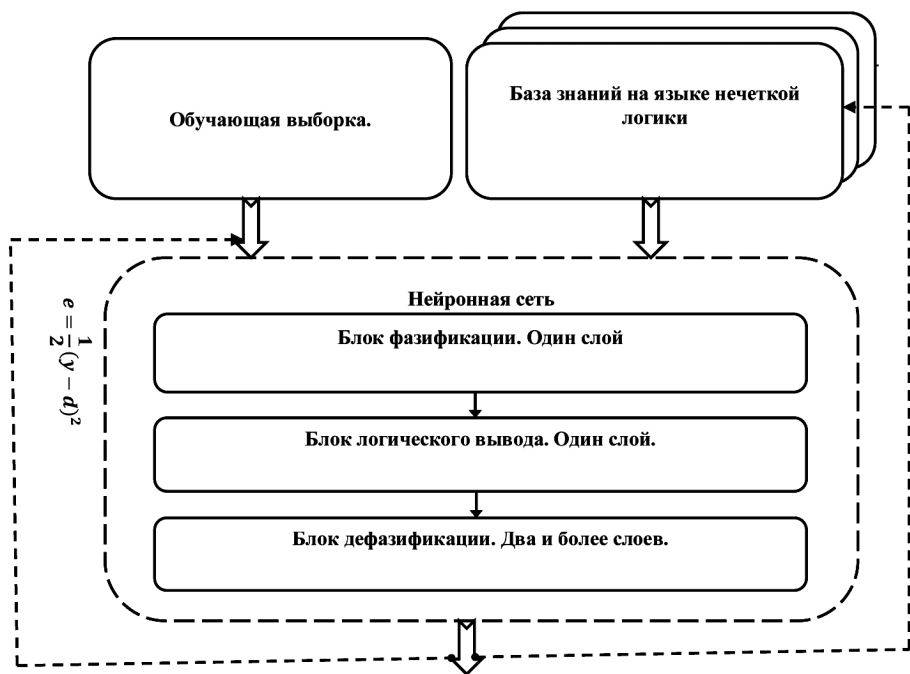


Рис. 2. Общая структура нейро-нечеткой гибридной сети

Данная система может быть реализована в виде нейронной сети, состоящей из пяти слоев; ее называют адаптивной нейро-нечеткой системой вывода (Adaptive Neuro-Fuzzy Inference System, ANFIS), каждый слой которой имеет следующие функции.

Слой 1. Выходы нейронов этого слоя представляют собой степени принадлежности входных значений нечетким множествам, ассоциированным с нейронами. Обычно применяются гауссовы функции принадлежности:

$$A_{ij} = \exp \left[\frac{1}{2} \left(\frac{x - a_{ij}}{b_{ij}} \right)^2 \right],$$

где a_{ij} — множество параметров, которые необходимо настраивать в процессе обучения. Также может быть использована произвольная непрерывная функция, например, трапецевидной или треугольной формы.

Слой 2. Каждый нейрон этого слоя вычисляет уровень истинности правила по формуле:

$$\alpha_{ij} = A_{i1}(x_1) \wedge A_{i2}(y_0), \quad i = 1, 2,$$

где для моделирования связки “и” может использоваться дифференцируемая Т-норма.




Рис. 3. Общая структура нейро-нечеткой гибридной сети, основанная на методе Суджено

Слой 3. На данном слое производится нормализация уровней истинности каждого правила по формуле

$$\beta_i = \alpha_i / (\alpha_1 + \alpha_2).$$

Слой 4. Выходы нейронов представляют произведение нормализованных значений уровней истинности на соответствующие выходы правил:

$$y_i = \beta_i (c_{i1}x_1 + c_{i2}x_2).$$

Слой 5. Нейрон последнего (выходного) слоя производит адаптивное суммирование выходов нейронов предыдущего слоя. Адаптивная нейро-нечеткая система вывода (ANFIS) представлена на рис. 3.

Гибридная сеть на основе алгоритма вывода Мамдани. Разработанная гибридная сеть основана на алгоритме нечеткого вывода Мамдани, она содержит пять слоев, подобно сети на основе метода Суджено. Первый (входной) слой реализует функции принадлежности для каждого термина каждой входной переменной. На вход слоя поступают входные сигналы x , а на выходе слоя получаем значение функции принадлежности для этих сигналов $\mu_{A_k}(x)$. Параметры функций принадлежности становятся весами связей для нейронов первого слоя сети, и они будут модифицироваться в процессе обучения. То, что веса теперь имеют конкретную физическую интерпретацию, позволяет задать хорошие начальные значения, а также анализировать и контролировать процесс корректировки этих параметров.

Конфигурация связей второго слоя соответствует структуре правил, а сам слой реализует блок логического вывода. Число нейронов в слое равно числу правил. Каждый узел слоя связан с предыдущим слоем таким образом, что узел слоя $L2$, соответствующий k -му правилу, соединен со всеми нейронами слоя $L1$, соответствующими нечетким множествам условий этого правила. Нейроны слоя $L2$ могут быть либо мультипликаторами, либо реализовывать функцию “минимум” в зависимости от выбранной модели логического вывода. На выходе слоя формируются значения функций принадлежности $\mu_{B_k}(y)$.

Третий, четвертый и пятый слои представляют собой реализацию блока дефазификации. Веса связей, входящих в верхний сумматор слоя $L3$ (обозначены \bar{y}_k), интерпретируются как центры функций принадлежности выходной переменной и также будут скорректированы в процессе обучения. На выходе слоя $L5$ формируется четкое значение переменной вывода Z_0 .

При такой структуре нейронной сети можно говорить об уточняемых нечетких множествах как входных переменных, так и переменной вывода. Поскольку описанная структура является многослойной нейронной сетью с прямым распространением сигнала, то для ее обучения может быть применен, например, алгоритм обратного распространения ошибки. Алгоритм нечеткого вывода Мамдани для получения результирующего нечеткого множества использует операцию отсечения:

$$C(y) = V_{k=1}^{N_R} \alpha \wedge C_k(y). \quad (1)$$

Для того чтобы получить четкое значение, необходимо вычислить границы отсечения:

$$y_1, y_2 : C_k(y_1) = \alpha_k(y_2) = \alpha_k y_1 < y_2,$$

Тогда четкое значение будет:

$$Center(\alpha_k \wedge C_k) = (y_1 + y_2)/2. \quad (2)$$

Для реализации этих вычислений следует ввести еще один слой нейронов между слоями $L2$ и $L3$. Получаемая при этом структура показана на рис. 4.

Обучение сети для нечеткого вывода по алгоритму Мамдани.

В сети (см. рис. 4) значения \bar{y}^m определяются динамически с помощью специально введенного слоя. Поэтому они уже не могут быть модифицированы как веса. Следовательно, изменению подлежат только веса \bar{h}_i^m и \bar{w}_i^m :

$$\begin{aligned} \frac{\partial \varepsilon}{\partial \bar{w}_i^m} &= \frac{\bar{y} - d}{b^2} \left(\frac{\partial a}{\partial \bar{w}_i^m} b - \frac{\partial b}{\partial \bar{w}_i^m} a \right); \\ \frac{\partial \varepsilon}{\partial \bar{h}_i^m} &= \frac{\bar{y} - d}{b^2} \left(\frac{\partial a}{\partial \bar{h}_i^m} b - \frac{\partial b}{\partial \bar{h}_i^m} a \right); \end{aligned}$$

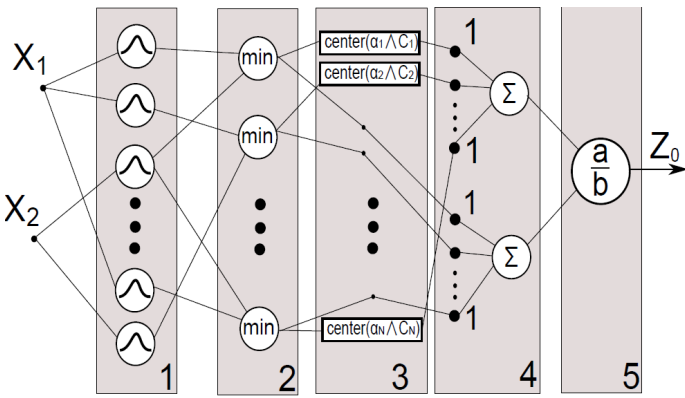


Рис. 4. Гибридная сеть, реализующая алгоритм Мамдани с композицией “минимум”

$$\frac{\partial b}{\partial \bar{w}_i^m} = \frac{\partial}{\partial \bar{w}_i^m} \left(\sum_{k=1}^N \bar{z}^k \right) = \sum_{k=1}^N \frac{\partial \bar{z}^k}{\partial \bar{w}_i^m};$$

$$\frac{\partial a}{\partial \bar{w}_i^m} = \frac{\partial}{\partial \bar{z}^m} \left(\sum_{k=1}^N Center(C^k(\bar{z}^k)) \right).$$

где $Center(C^k(\bar{z}^k)) = \bar{z}^m \frac{y_1 + y_2}{2}$, $y_1, y_2 : C_k(y_1) = C_k(y_2) = \bar{z}^k$, $y_1 < y_2$, т.е. для “сложной” функции

$$Center(C_k(\bar{z}^k)) = \bar{z}^m \frac{C_L^{-1}(\bar{z}^k) + C_R^{-1}(\bar{z}^k)}{2}.$$

Поскольку функции принадлежности независимы друг от друга, то справедливо равенство:

$$\begin{aligned} \frac{\partial}{\partial \bar{z}^m} \left(\sum_{k=1}^N Center(C^k(\bar{z}^k)) \right) &= \\ &= \frac{1}{2} \bar{z}^m \left[\frac{\partial C_L^{-1}(\bar{z}^m)}{\partial \bar{z}^m} + \frac{\partial C_R^{-1}(\bar{z}^m)}{\partial \bar{z}^m} \right] + \frac{C_L^{-1}(\bar{z}^k) + C_R^{-1}(\bar{z}^k)}{2}. \end{aligned} \quad (3)$$

Окончательно получаем:

для композиции “произведение”

$$\begin{aligned} \frac{\partial e}{\partial \bar{w}_i^m} &= \frac{(\bar{y} - d)}{b^2} \sum_{k=1}^N (b\bar{y}^k - a) \left(\frac{1}{2} \bar{z}^m \left[\frac{\partial C_L^{-1}(\bar{z}^m)}{\partial \bar{z}^m} + \frac{\partial C_R^{-1}(\bar{z}^m)}{\partial \bar{z}^m} \right] + \right. \\ &\quad \left. + \frac{C_L^{-1}(\bar{z}^m) + C_R^{-1}(\bar{z}^m)}{2} \right) \frac{\partial f_i^m}{\partial \bar{w}_i^m} \prod_{j=1, j \neq i}^n f_j^m(x_j^m), \end{aligned} \quad (4)$$

$$\frac{\partial e}{\partial \bar{h}_i^m} = \frac{(\bar{y} - d)}{b^2} \sum_{k=1}^N (b\bar{y}^k - a) \left(\frac{1}{2} \bar{z}^m \left[\frac{\partial C_L^{-1}(\bar{z}^m)}{\partial \bar{z}^m} + \frac{\partial C_R^{-1}(\bar{z}^m)}{\partial \bar{z}^m} \right] + \frac{C_L^{-1}(\bar{z}^m) + C_R^{-1}(\bar{z}^m)}{2} \right) \frac{\partial f_i^m}{\partial \bar{h}_i^m} \prod_{j=1, j \neq i}^n f_j^m(x_j^m), \quad (5)$$

для композиции “минимум”

$$\frac{\partial e}{\partial \bar{w}_i^m} = \begin{cases} \frac{(\bar{y} - d)}{b^2} \sum_{k=1}^N (b\bar{y}^k - a) \left(\frac{1}{2} \bar{z}^m \left[\frac{\partial C_L^{-1}(\bar{z}^m)}{\partial \bar{z}^m} + \frac{\partial C_R^{-1}(\bar{z}^m)}{\partial \bar{z}^m} \right] + \frac{C_L^{-1}(\bar{z}^m) + C_R^{-1}(\bar{z}^m)}{2} \right) \frac{\partial f_i^m}{\partial \bar{w}_i^m}, & \text{если } f_{\min}^m = f_i^m; \\ 0, & \text{если } f_{\min}^m \neq f_i^m. \end{cases} \quad (6)$$

$$\frac{\partial e}{\partial \bar{h}_i^m} = \begin{cases} \frac{(\bar{y} - d)}{b^2} \sum_{k=1}^N (b\bar{y}^k - a) \left(\frac{1}{2} \bar{z}^m \left[\frac{\partial C_L^{-1}(\bar{z}^m)}{\partial \bar{z}^m} + \frac{\partial C_R^{-1}(\bar{z}^m)}{\partial \bar{z}^m} \right] + \frac{C_L^{-1}(\bar{z}^m) + C_R^{-1}(\bar{z}^m)}{2} \right) \frac{\partial f_i^m}{\partial \bar{h}_i^m}, & \text{если } f_{\min}^m = f_i^m; \\ 0, & \text{если } f_{\min}^m \neq f_i^m. \end{cases} \quad (7)$$

Практическое приложение нейро-нечеткой сети. Задачу оценки эффективности инновационных проектов с учетом выбранных критериев можно формализовать с помощью следующего набора лингвистических переменных (ЛП): допустимый риск; риск проекта; вероятность коммерческого успеха; время разработки; вероятность использования в будущих НИОКР; совокупные затраты; время достижения точки безубыточности; потенциальный годовой размер прибыли; доступность материалов; эффективность проекта. Для каждого показателя целесообразно ввести по три термина: “низкий”, “средний”, “высокий” для ЛП “допустимый риск”, “риск проекта”, “вероятность коммерческого успеха”, “вероятность использования в будущих НИОКР”, “совокупные затраты”, “доступность материалов”; “маленький”, “средний”, “большой” для ЛП “время разработки”, “время достижения точки безубыточности”, “потенциальный годовой размер прибыли”. Для ЛП “эффективность проекта” введем более детальную градацию: “очень низкая”, “низкая”, “средняя”, “высокая” и “очень высокая”. База знаний должна содержать нечеткие правила двух типов:

1) отражающие зависимость риска банкротства от каждого из показателей, например,

ЕСЛИ Совокупные затраты Высокие, ТО Эффективность проекта Низкая;

2) выражающие взаимосвязь некоторых показателей, например, ЕСЛИ Совокупные затраты Высокие И Вероятность коммерческого успеха Высокая, ТО Эффективность проекта Средняя.

В качестве обучающей выборки использованы данные, приведенные в таблице.

Эффективность алгоритмов обучения можно оценить с помощью уравнения:

$$q = \frac{\sum_{i=0}^N \sum_{j=0}^K e_{ij}}{N},$$

где N — число итераций обучения; K — число векторов обучающей выборки; — ошибка на каждом шаге.

При вычислении значения q учитывается как форма графика функции ошибки, так и значение ошибки на конец обучения. Чем меньше величина q , тем эффективнее обучение. Поэтому в качестве критерия эффективности удобно использовать обратную величину:

$$Q = \frac{1}{q} \frac{N}{\sum_{i=0}^N \sum_{j=0}^K e_{ij}},$$

На графиках изменения суммарной погрешности для различных сетей (рис. 5, 6) по оси e отложена суммарная погрешность по всем элементам обучающей выборки, по оси N — номер итерации.

На графиках видно, что уменьшение шага коррекции ведет к сглаживанию локальных максимумов. В начале обучения, когда шаг коррекции еще велик, наблюдается кратковременный рост ошибки, но затем она уменьшается. При этом скорость обучения снижается незначительно в отличие от варианта, когда шаг коррекции мал изначально.

Заключение. Проведенные исследования показывают резкие скачки функции погрешности, что обусловлено функцией вычисления центра, значение которой может существенно изменяться даже при незначительном изменении входа, если функция несимметрична. Таким образом можно “перескочить” минимум функции погрешности. Данную проблему решают путем уменьшения шага коррекции, но при этом существенно увеличивается время обучения. Поэтому часто в начале обучения берут достаточно большой шаг коррекции, и по мере приближения ошибки к нулю шаг уменьшают. При использовании операции “минимум” корректируют только веса тех нейронов, которые дают минимальные значения на входе нейронов-правил. С одной

Таблица

Допустимый риск, %	Риск проекта, %	Вероятность коммерческого успеха, %	Время разработки, мес.	Вероятность выполнения будущих НИОКР, %	Совокупные затраты, млн р.	Время достижения точки безубыточности, мес.	Потенциальный годовой размер прибыли, млн р.	Доступность материалов, %	Эффективность проекта, %
40	50	75	12	10	2,3	16	5	60	55,7
10	50	30	20	50	4	30	4	30	21
10	90	10	24	14	5,7	30	5	20	5,6
80	10	99	6	60	1,5	12	10,6	100	89,1

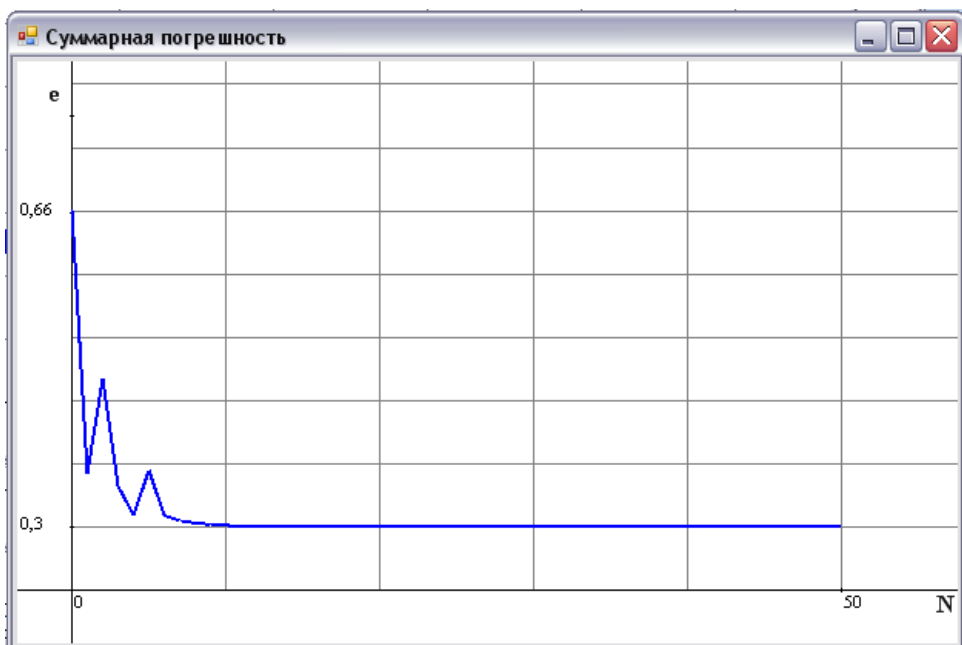


Рис. 5. Изменение суммарной погрешности для сети, реализующей алгоритм Мамдани с композицией "произведение". $Q = 15,85$




Рис. 6. Изменение суммарной погрешности для сети, реализующей алгоритм Мамдани с композицией "минимум". $Q = 15,85$

стороны, это приводит к более резкому уменьшению погрешности за счет обратного прохождение ошибки через нейрон-минимизатор без изменения. С другой стороны, возможно и резкое возрастание погрешности, что и наблюдается на 2-й итерации ввиду изменения нейрона, дающего минимальное значение. В целом обучение для такой композиции эффективно, если соответствующие изменения весов отрицательны, и неэффективно, если они положительны, так как высок риск “перехода” минимума на другой нейрон. Уменьшение шага коррекции по ходу обучения существенно увеличивает эффективность алгоритма, практически устраняя проблему локального роста функции ошибки. При этом скорость обучения практически не снижается.

СПИСОК ЛИТЕРАТУРЫ

1. З а д е Л. Понятие лингвистической переменной и его применение к принятию приближенных решений. – М.: Мир, 1976. – 165 с.
2. К о л м о г о р о в А. Н., Д р а г а л и н А. Г. Математическая логика. – М.: КомКнига, 2006. – 240 с.
3. К р у г л о в В. В., Д л и М. И. Нечеткая логика и искусственные нейронные сети. – М.: ФИЗМАТЛИТ, 2001. – 224 с.
4. О с у г а С. Обработка знаний: Пер. с япон. – М.: Мир, 1989. – 293 с.
5. Р о г о з и н О. В. Адаптивный программный комплекс анализа качественных показателей инновационного решения // Открытое образование. – 2011. – № 5. – С. 54–59.
6. Р о г о з и н О. В. Метод нечеткого вывода решения в задаче подбора программного обеспечения на основе качественных характеристик этого обеспечения как объекта инвестиций // Качество: Инновации: Образование. – 2009. – е 3. – С. 43–49.
7. С м и р н о в В. А. Теория логического вывода: Сб. тр. по теории логического вывода. – М.: РОССПЭН, 1999. – 318 с.
8. У э н о Х., И с и д з у к а М. Представление и использование знаний: Пер. с япон. – М.: Мир, 1989. – 220 с.
9. М а м д а н и Е. Н., А s s i l i a n S. An experiment in linguistic synthesis with a fuzzy logic controller // Int. J. Man Mach. Studies. – 1975. – Vol. 7, No. 1. – P. 1–13.
10. Q u i n l a n J. R. Introduction of decision tree // Machine Learning. – 1986. – 1:81–106.
11. Q u i n l a n J. R. C4.5: Programs for Machine Learning. – Morgan Kauffman, 1993.
12. S u g e n o M., K a n g G. T. Structure identification of fuzzy model // Fuzzy Sets Syst. – 1988. – Vol. 28, No. 1. – P. 15–33.
13. Z a d e h L. Fuzzy Sets // Information and Control. – June 1965. – No. 8(3). – P. 338–353.

Статья поступила в редакцию 07.06.2012