

УДК 004.93

С.А. Зайцев¹, С.А. Субботин²¹ Запорожский национальный технический университет,
г. Запорожье, zaitsev.serge@gmail.com² Запорожский национальный технический университет,
г. Запорожье, subbotin@zntu.edu.ua

СИНТЕЗ НЕЙРО-НЕЧЕТКОГО АППРОКСИМАТОРА МАМДАНИ НА ОСНОВЕ ПРИНЦИПОВ ОТРИЦАТЕЛЬНОГО ОТБОРА ДЛЯ РЕШЕНИЯ ЗАДАЧ ДИАГНОСТИРОВАНИЯ С ВЕЩЕСТВЕННЫМ ПРЕДСТАВЛЕНИЕМ ПРИЗНАКОВ

Решена актуальная задача автоматизации диагностирования объектов и систем, описанных вещественными признаками. Исследовалось использование результатов работы модели отрицательного отбора с маскированием в процессе обучения сети Мамдани. Предложен метод синтеза нейро-нечеткого аппроксиматора Мамдани с помощью модели отрицательного отбора с маскированием детекторов. Экспериментально подтверждена целесообразность применения нейро-нечеткого аппроксиматора Мамдани, обученного с помощью предложенного метода, как средства нечеткого вывода в задачах диагностирования.

НЕЙРО-НЕЧЕТКИЙ АППРОКСИМАТОР МАМДАНИ, ОТРИЦАТЕЛЬНЫЙ ОТБОР, НЕЧЕТКИЕ ПРАВИЛА, ДЕТЕКТОР, МАСКИРОВАНИЕ

Введение

Задача автоматизации процессов диагностирования и распознавания образов решается посредством синтеза диагностических моделей. В [1] построение диагностических моделей проводилось с помощью принципов отрицательного отбора в искусственных иммунных системах. При этом в основе работы модели лежит идея маскирования детекторов, что позволяет повысить скорость обучения модели за счет дообучения детекторов в ее составе. Благодаря тому, что непригодные детекторы проходят этап дополнительного обучения, значительно реже происходит генерация новых кандидатов в детекторы, что дает возможность сократить использование ресурсов памяти. Данная модель предназначена для работы с вещественным представлением диагностических признаков.

Следует отметить, что в результате работы модели, предложенной в [1], может быть получен набор продукционных правил вида «если-то», с помощью которого проводится дальнейшая классификация диагностируемого объекта. Согласно таким правилам решение о принадлежности экземпляра к классу «своих» может быть определено однозначно. Однако существуют случаи, когда экземпляр нельзя однозначно отнести к классу «своих» или «чужих». В частности, это касается экземпляров, находящихся на границах классов. В таких случаях целесообразно определять принадлежность экземпляра к тому или иному классу с некоторой вероятностью. Иными словами, принимать решение о принадлежности экземпляра к классу «своих» следует на основе нечетких правил.

Применение нейро-нечеткого аппроксиматора Мамдани [2] позволит использовать механизм нечеткого вывода при решении задачи классификации объектов.

Цель данной работы заключается в разработке метода синтеза нейро-нечеткого аппроксиматора Мамдани на основе обученной модели отрицательного отбора с маскированием детекторов.

1. Постановка задачи

Пусть в пространстве признаков U размерностью n задана обучающая выборка S' . Известно, что каждый экземпляр $x \in U$ можно отнести к классу «своих» (годных) или «чужих» (дефектных). Множества S и N , содержащие «свои» и «чужие» экземпляры соответственно, комплементарны: $S \cap N = \emptyset$, $U = S \cup N$.

Построение модели отрицательного отбора заключается в формировании на основе обучающей выборки $S' \subset S$ набора детекторов D таким образом, чтобы с помощью этого набора любой экземпляр $x \in U$ можно было однозначно отнести к классу «своих» или «чужих».

Задача синтеза нейро-нечеткого аппроксиматора Мамдани заключается в определении термов, задании функций принадлежности j и расчете весовых коэффициентов для связей между узлами сети на основе полученного набора детекторов D .

2. Метод обучения модели отрицательного отбора с маскированием детекторов

Предлагаемый в [1] метод отрицательного отбора с маскированием детекторов является развитием парадигмы отрицательного отбора [3]. Основная идея метода заключается в том, что детектору соответствует не точка в пространстве признаков, а гиперкуб максимально возможного объема. Это позволяет использовать меньшее число детекторов для обеспечения покрытия больших областей в пространстве признаков.

Также метод использует процедуру дообучения детекторов, которая служит заменой этапу

цензурирования в базовом методе отрицательного отбора [4]. В процессе дообучения гиперкуб, которым описан кандидат в детекторы, изменяет свои размеры таким образом, чтобы не соответствовать ни одному из «своих» экземпляров.

В качестве первоначального объема гиперкуба принимается все пространство признаков задачи и в процессе обучения метод старается сохранить его максимальным.

Пусть дана обучающая выборка S' . Перед обучением модели необходимо установить значения коэффициента α , который определяет значение допуска при классификации детектора, и минимально допустимое значение порога g_{min} , который определяет способность модели к обобщению. Оба коэффициента должны принимать значения в диапазоне $(0,1]$.

Для данной модели рекомендуется использовать следующую метрику:

$$match(d, s) = \begin{cases} 1, & \sum_{i=1}^n \{1 | d_{min}^i < s_i \wedge d_{max}^i > s_i\} = n; \\ 0, & \text{в противном случае.} \end{cases}$$

Метод обучения модели отрицательного отбора с маскированием в случае использования вещественных признаков включает в себя следующие этапы:

1. Установить: $D = \emptyset$.
2. Сформировать кандидата в детекторы

$$d = \langle d_{min}, d_{max} \rangle, \quad d_{min} = \{s_{min}^1, s_{min}^2, \dots, s_{min}^n\}, \\ d_{max} = \{s_{max}^1, s_{max}^2, \dots, s_{max}^n\},$$

где s_{min}^i и s_{max}^i – минимальное и максимальное значения i -го признака среди экземпляров выборки соответственно, $i = 1, \dots, n$.

3. Для каждого экземпляра $s \in S'$ выполнять п.п. 3.1–3.4.

3.1 Если $match(d, s) = 1$, тогда перейти к п. 3.2, в противном случае – взять следующий экземпляр и перейти к п. 3.4.

3.2 Найти такой i -й признак, чтобы $d_{min}^i < s_i$ и $d_{max}^i > s_i$.

3.3 Если $rand > 0,5$, где $rand$ – функция, возвращающая случайное число в диапазоне $(0,1]$, тогда принять: $d_{min}^i = s_i + \alpha(s_{max}^i - s_{min}^i)$, в противном случае – принять: $d_{max}^i = s_i - \alpha(s_{max}^i - s_{min}^i)$.

3.4 Если $match(d, s) = 0$, тогда перейти к п. 3.5, в противном случае – перейти к п. 3.2.

3.5 Выбрать следующий экземпляр $s \in S'$ и перейти к п. 3.1.

4. Оценить способность детектора к обобщению:

$$g(d) = \frac{\sum_{i=1}^n \frac{d_{max}^i - d_{min}^i}{s_{max}^i - s_{min}^i}}{n}.$$

5. Если $g(d) > g_{min}$, тогда добавить детектор в набор: $D = D \cup \{d\}$.

В результате обучения будет сформирован набор детекторов, описывающих пространство, комплементарное к пространству «своих» экземпляров, при этом все детекторы обладают требуемой способностью к обобщению, что позволяет избежать проблемы переобученности модели.

Также, изменяя значение коэффициента α , можно установить порог толерантности модели к своим экземплярам – чем больше значение α , тем больше расстояние между детекторами модели и «своими» экземплярами.

В результате обучения распознающей модели с помощью метода отрицательного отбора с маскированием детекторов будет получен набор детекторов, на основе которого можно производить классификацию экземпляров.

Данный метод не проверяет наличие одинаковых детекторов в наборе в процессе обучения, что часто приводит к избыточному количеству детекторов. Также могут быть сформированы два детектора, покрывающие одну и ту же область, однако различные по объему. В таком случае в состав модели должен войти детектор с большей степенью покрытия.

С целью устранения избыточности в наборе детекторов необходимо удалить такие $d \in D$, для которых:

$$\exists d' \in D, d'_{min} \leq d_{min}, d'_{max} \geq d_{max}.$$

3. Нейро-нечеткий аппроксиматор Мамдани

Нейро-нечеткий аппроксиматор Мамдани представляет собой обобщенную модель нейро-нечеткой сети, построенной на основе правил Мамдани [5].

Нейро-нечеткий аппроксиматор Мамдани можно представить в виде сети, состоящей из пяти слоев и по структуре подобной классическим искусственным нейронным сетям прямого распространения сигнала.

Первый слой представляет собой элементы входного вектора (признаки).

Второй слой содержит нечеткие термы, соответствующие входным переменным (этап фаззификации входных переменных). В этом слое вычисляется принадлежность входного вектора к каждому из нечетких термов. Целью этого этапа является получение значений истинности для всех подусловий из базы правил.

Третий слой представляет собой antecedentes нечетких правил (агрегация подусловий). Для каждого условия находят минимальное значение истинности всех его подусловий.

Четвертый слой определяет степени принадлежности входного вектора к нечетким термам выходной переменной.

Пятый слой выполняет операцию дефаззификации. Целью дефаззификации является получение

количественного значения для каждой из выходных переменных.

Как правило, нейро-нечеткий аппроксиматор Мамдани можно обучить посредством отображения всей обучающей выборки в структуру сети Мамдани с последующей коррекцией весов на основе обратного распространения ошибки [6]. Однако процесс обучения можно ускорить, а уровень обобщения сети повысить, если синтезировать сеть не по обучающей выборке непосредственно, а сформировать по выборке перед построением сети базу нечетких правил на основе знаний, полученных в результате обучения модели отрицательного отбора с маскированием. Это позволит существенно сжать выборку за счет исключения избыточных экземпляров и неясного решения задачи кластер-анализа.

4. Метод синтеза нейро-нечеткого аппроксиматора Мамдани

Число узлов в слоях сети предлагается определять следующим образом. Для первого слоя число узлов соответствует числу входных признаков, для второго слоя – числу нечетких термов в базе правил. Поскольку каждый признак в составе детектора будет преобразован в нечеткий терм, то на втором слое сети будет находиться $|D| \cdot n$ узлов.

Третий слой включает в себя $|D|$ узлов, что равно числу детекторов в наборе D , поскольку каждый детектор представляет собой одно правило.

Число детекторов в четвертом слое определяется числом классов (для задач диагностирования – два узла, поскольку рассматриваются два класса – годные и дефектные экземпляры). В пятом слое находится всего один узел.

В процессе обучения требуется скорректировать веса связей, в частности, между вторым и третьим слоями (функции принадлежности входного значения к нечетким термам), а также третьим и четвертым (веса правил).

В результате обучения модели отрицательного отбора с маскированием полученные интервалы для переменных позволяют легко настроить параметры функций принадлежности. Так, для симметричной треугольной функции:

$$j(x) = \begin{cases} 1 - \frac{|x - \frac{d_{\max} + d_{\min}}{2}|}{\frac{d_{\max} - d_{\min}}{2}}, & d_{\min} < x < d_{\max}; \\ 0, & \text{в противном случае.} \end{cases}$$

Для трапециoidalной функции:

$$j(x) = \begin{cases} 1 - \frac{a - x}{a - d_{\min}}, & d_{\min} \leq x \leq a; \\ 1, & a \leq x \leq b; \\ 1 - \frac{x - b}{d_{\max} - b}, & b \leq x \leq d_{\max}; \\ 0, & \text{в остальных случаях,} \end{cases}$$

где X – определяет угол наклона ребер трапеции, $a = d_{\min} + (d_{\max} - d_{\min}) / X$, $b = d_{\max} - (d_{\max} - d_{\min}) / X$.

Веса таких правил следует установить равными 1.

Поскольку детекторы определяют только принадлежность экземпляра к классу “чужих”, то требуется также создать нечеткие правила, относящие экземпляр к классу “своих”. Для каждого детектора создается обратное правило, определяющее принадлежность экземпляра к классу “своих”. Обратное правило получается с помощью инверсии значения функции принадлежности $1 - \mu(x)$. Поскольку такие инвертированные правила будут порождать противоречия, то рекомендуется устанавливать им меньшие веса (порядка 0,2–0,5).

5. Эксперименты и результаты

Предложенный метод синтеза нейро-нечеткого аппроксиматора Мамдани проходил тестирование как на синтетических выборках, так и на практических задачах диагностирования [7] с использованием программной реализации метода на языке Python.

В случае синтетических тестов обучающая выборка составляла 20% от числа всех экземпляров. В качестве функции принадлежности использовалась трапециoidalная функция.

После каждых 10 итераций метода обучения модели отрицательного отбора с маскированием осуществлялось тестирование данной модели, и измерялась ошибка классификации.

На рис. 1 представлены графики, отображающие динамику ошибки классификации в процессе обучения и тестирования модели отрицательного отбора с маскированием детекторов.




Рис. 1. Динамика ошибки классификации в процессе обучения и тестирования модели отрицательного отбора с маскированием детекторов

Как видно из рис. 1, после определенного момента ошибка классификации обучающих данных продолжает падать, в то время как ошибка классификации тестовых данных возрастает. Это

происходит вследствие переобученности модели, т.е. фактически происходит запоминание экземпляров и модель адаптируется под особенности обучающей выборки, а не задачи в целом.

На рис. 2 представлен график, отображающий динамику ошибки классификации в процессе обучения и тестирования модели с использованием нейро-нечеткого аппроксиматора Мамдани, обученного с помощью предложенного метода.




Рис. 2. Динамика ошибки классификации в процессе обучения и тестирования модели отрицательного отбора с использованием нейро-нечеткого аппроксиматора Мамдани

Как видно из рис. 2, предложенный метод позволяет снизить отрицательный эффект от переобученности модели.

Заключение

С целью решения актуальной задачи автоматизации процесса диагностирования объектов, характеризуемых набором вещественных признаков, разработано математическое обеспечение, позволяющее строить диагностические модели по прецедентам на основе иммунокомпьютинга.

Научная новизна работы заключается в том, что впервые предложен метод обучения нейро-нечеткого аппроксиматора Мамдани с помощью модели отрицательного отбора с маскированием детекторов. Это позволяет ускорить процесс обучения сети Мамдани за счет того, что значения параметров функций принадлежности вычисляются на основе детекторов модели отрицательного отбора. Предложенный метод дает возможность синтезировать диагностические модели с помощью нейро-нечеткого аппроксиматора Мамдани.

Практическая ценность работы заключается в том, что разработано программное обеспечение для проведения диагностирования объектов с помощью обученного нейро-нечеткого аппроксиматора Мамдани.

Тестирование предложенной нейро-нечеткой сети Мамдани показало высокую точность классификации по сравнению с базовой моделью

отрицательного отбора с маскированием детекторов, что позволяет рекомендовать ее использование для решения практических задач.

Список литературы: 1. Зайцев, С.А. Модель отрицательного отбора с маскированием для решения задач диагностирования с вещественным представлением признаков [Текст] / С.А. Зайцев, С.А. Субботин // Вісник Національного технічного університету "Харківський політехнічний інститут": зб. наук. праць. Тематичний випуск "Інформатика і моделювання". Харків: НТУ "ХПІ", 2011. № 31. 2. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence / J.-Sh. Jang, Ch.-T. Sun, E. Mizutani. New York: Prentice-Hall, 1997. 640 p. 3. Ji Z., Dasgupta D. Revisiting negative selection algorithms // Evolutionary Computation. 2007. №15. P. 223-251. 4. Forrest S., Perelson A.S., Cherkuri R., Allen L. Self-Nonself Discrimination in a Computer // Proceedings of the 1994th IEEE Symposium on Research in Security and Privacy (1994). CA: IEEE Computer Society Press, 1994. P. 202-212. 5. Fuzzy control / K.M. Passino, S. Yurkovich. CA: Addison Wesley Longman, 1998. 522 p. 6. Neural Networks – A Systematic Introduction / R. Rojas. New York: Springer-Verlag, 1996. 502 p. 7. Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей : монография [Текст] / В. И. Дубровин, С. А. Субботин, А. В. Богуслаев, В. К. Яценко. Запорожье: ОАО "Мотор-Сич", 2003. 279 с.

Поступила в редколлегию 08.06.2012

УДК 004.93

Синтез нейро-нечеткого аппроксиматора Мамдани на основе принципов негативного відбору для вирішення задач діагностування з дійсним поданням ознак / С. О. Зайцев, С. О. Субботин // Біоніка інтелекту: наук.-техн. журнал. — 2012. — № 2 (79). — С. 43–46.

Вирішено актуальну задачу автоматизації діагностування об'єктів та систем, що описані дійсними ознаками. Досліджувалося використання результатів роботи моделі негативного відбору з маскуванням в процесі навчання мережі Мамдани. Запропоновано метод синтезу нейро-нечеткого аппроксиматора Мамдани за допомогою моделі негативного відбору з маскуванням детекторів. Експериментально підтверджено доцільність застосування нейро-нечеткого аппроксиматора Мамдани, який навчався за допомогою запропонованого методу, як засобу нечіткого виводу в задачах діагностування.

Л. 2. Бібліогр.: 7 найм.

UDC 004.93

Synthesis of Mamdani neuro-fuzzy approximator based on the negative selection principals in real-valued diagnostics. / S. A. Zaitsev, S. A. Subbotin // Bionics of Intelligence: Sci. Mag. — 2012. — № 2 (79). — P. 43–46.

An actual problem of the object and system automatic diagnostics has been solved. The usage of results of the negative selection model based on masked detectors in Mamdani network training process has been analyzed. A new method of Mamdani neuro-fuzzy approximator synthesis with negative selection model based on masked detectors has been proposed. The experiments have been carried to approve the appropriateness of Mamdani neuro-fuzzy approximator, that was trained with the suggested method, as a tool of a fuzzy output in diagnostics.

Fig. 2. Ref.: 7 items.