

УДК 621.391: 681.883.77

А.Н. Продеус, д-р техн. наук

Применение генетических алгоритмов для выбора классификационных признаков в системах классификации с нечеткой логикой

Приведен краткий обзор работ, посвященных получению интерпретируемых (понятных конечному пользователю) классификационных признаков в системах классификации, основанных на применении нейросетевых технологий. Показано, что решение данной задачи может быть получено путем обращения к таким направлениям как генетические алгоритмы и нечеткая логика.

The brief review of papers dedicated obtaining interpreted (understandable to the end user) classification signs in classification systems, based on application of neural network technologies is made. It is shown, that the solution of the problem can be obtained by an address to such directions as genetic algorithms and fuzzy logic.

Ключевые слова: генетический алгоритм, классификационный признак, интерпретируемость, нейронная сеть, нечеткая логика.

Введение

У современных специалистов в области обработки акустических сигналов отношение к технологии нейронных сетей весьма смешанное. Например, известны попытки использовать нейронные сети в задаче гидроакустической классификации [1], в области автоматического распознавания речи [2]. Вместе с тем, достаточно очевидным и общепризнанным фактом является известное неудобство нейронных сетей, используемых в системах классификации сигналов, состоящее в трудности интерпретации классификационных признаков, используемых в нейронных сетях. Как справедливо замечено в работе [3], нейронная сеть – это «черный ящик», принцип действия которого известен, однако описанию эти действия практически не поддаются.

Цель данной работы состоит в кратком обзоре работ последних лет, направленных на восполнение указанного пробела путем обращения к таким направлениям как генетические алгоритмы и нечеткая логика [4-16].

1. Применение нейронных сетей для классификации сигналов

Термин «нейронные сети» сформировался в 40-х годах прошлого века. Основные результаты, полученные в этой области, связаны с именами американских исследователей У. Маккалоха, Д. Хебба, Ф. Розенблатта, М. Минского, Дж. Хопфилда и ряда других исследователей [10–14].

Составной частью нейронной сети является нейрон, структура которого показана на рис. 1.

Математическая модель нейрона описывается соотношением

$$s = \sum_{i=1}^n w_i x_i + b; \quad y = f(s), \quad (1)$$

где x_i – компонент входного вектора (входной сигнал); w_i – весовые коэффициенты; b – значение смещения; y – выходной сигнал нейрона; n – число входов нейрона; $f(s)$ – функция активации.

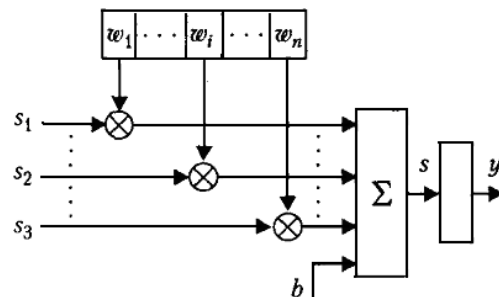


Рис. 1. Структура нейрона

Существуют различные структуры нейронных сетей. На практике выбирают структуру с известными свойствами (сети Хопфилда, Гроссберга, Кохонена), исходя из класса решаемых задач.

Нейронные сети обычно применяют в таких задачах распознавания, где иными методами трудно было строить нелинейную разделяющую гиперповерхность в многомерном пространстве признаков (для отличающихся негауссовых распределений классов). По-

сколькx соотношение (1) представляет собой уравнение гиперплоскости в n -мерном пространстве признаков, объединяя несколько нейронов (рис. 2), можно сформировать набор гиперплоскостей, обеспечивающих кусочно-линейную аппроксимацию требуемой гиперповерхности.



Рис. 2. Объединение нескольких нейронов

Гиперплоскости реализуются нейронами первого слоя. Блок отнесения признаков к тому или иному классу также реализуют нейронной сетью из соображений функциональной однородности системы – в результате сеть становится многослойной.

Двухслойная нейронная сеть обладает ограниченными возможностями в смысле реализации различных конфигураций разделяющей поверхности, тогда как трехслойная сеть обеспечивает требуемое качество аппроксимации. Исследования показывают, что качество работы многослойных нейронных сетей с последовательными связями монотонно возрастает при увеличении количества слоев и количества нейронов в каждом слое.

Известны многочисленные попытки использовать нейронные сети в задаче гидроакустической классификации [1], в области автоматического распознавания речи [2], а также в ряде иных направлений. В силу многочисленности примеров такого рода, ограничимся лишь двумя примерами решения задач гидроакустической классификации.

В работе [1] рассмотрена возможность применения нейронных сетей для решения задачи гидроакустической классификации шумов движущихся кораблей в диапазоне частот 5 Гц – 2 кГц.

В силу квазистационарности шумов надводных кораблей, для их анализа применялся кратковременный спектральный анализ. В качестве классификационных признаков использовались коэффициенты кепстра, вычисленные по результатам представления оценок спектра мощности шума на мал-частотной шкале. Система классификации строилась на основе самообучающейся, 2-мерной, 30x30 элементов, нейронной сети Кохонена. Результаты классификации проецировались на

плоскость, в результате чего получалась карта классов.

Экспериментальные исследования проводились по кораблям пяти классов (три проекта минных тральщиков, спасательный буксир и ракетный крейсер). Отношение сигнал-шум для спектральных данных составляло около 28 дБ.

Для обучения сети использовалось 35 000 опытов. При тестировании по обучающим выборкам вероятность правильной классификации составила около 95%, а при тестировании по новым выборкам – около 80%, что на 10% превысило результаты, достигнутые для случая, когда признаками служили оценки спектра мощности.

Метод идентификации надводных объектов с применением нейросетевых технологий для классификации радиолокационных эхосигналов от морских надводных объектов исследовался в работе [11]. Разработанный метод, алгоритм и программное обеспечение предназначались для разработки систем идентификации морских надводных объектов, используемых в навигационных автоматизированных комплексах для решения задач судовождения.

2. Формирование пространства признаков путем эволюционного моделирования (генетические алгоритмы)

Поскольку обучение нейронных сетей состоит в подборе таких коэффициентов w_j , которые минимизируют ошибку классификации на обучающей выборке, очевидно, что высокое качество классификации достигается ценой существенного усложнения нейронной сети, т.е. путем увеличения количества коэффициентов w_j .

Другим существенным недостатком нейронных сетей является их плохая интерпретируемость: пользователю трудно понять, почему нейронная сеть принимает то или иное решение.

Поэтому в последнее время исследователи пытаются создавать гибридные системы классификации, в которых, помимо нейронной сети, содержится блок нечеткой логики [3, 4]. Применение таких гибридных систем позволяет представлять решение задачи классификации, осуществляемое нейронной сетью, в виде набора интерпретируемых (понятных для пользователя) логических правил. Кроме того, что немаловажно, благодаря использованию генетических алгоритмов, за

дачу получения интерпретируемых признаков удается совместить с задачей минимизации пространства признаков.

Генетические алгоритмы представляют собой адаптивные методы решения задач оптимизации [6]. Сущность генетических алгоритмов состоит в том, что вначале формируется некоторое множество (популяция) значений аргумента функции, служащей критерием качества решения оптимизационной задачи, а затем осуществляется поиск экстремума этой функции путем выполнения ряда малых (кроссинговер) и больших (мутация) случайных скачков по оси абсцисс, выполняемых популяцией значений аргумента. Скачки прекращаются, когда все члены популяции становятся практически одинаковыми – это и является признаком «схождения» алгоритма, то есть признаком нахождения глобального экстремума.

Поскольку в генетических алгоритмах используются аналоги механизмов генетического наследования и естественного отбора, такие алгоритмы оказываются весьма эффективными в тех случаях, когда пространство «первичных» признаков представляет собой некий «первобытный бульон», в котором чрезвычайно трудно разобраться, поскольку признаков много, их информативность неизвестна, а физический смысл, как правило, отсутствует.

Примером задач такого рода является, например, построение человеко-машинного интерфейса (BCI – Brain-Computer Interface), когда в качестве управляющих сигналов для компьютера служат так называемые «мозговые волны», обычно регистрируемые в виде электроэнцефалограммы.

В работе [7] для формирования признакового пространства, при решении таких задач, использованы два типа операторов.

Операторы первого типа B_j , $j = 1, 2, \dots, n$, позволяют осуществлять преобразования числовой последовательности (фильтрация сигнала, сглаживание сигнала, удаление тренда, вычисление производной, нахождение абсолютного значения, вычисление логарифма, сортировка и т.п.):

$$B_j : \vec{x} = \{x_1, x_2, \dots, x_s\} \rightarrow \vec{y} = \{y_1, y_2, \dots, y_p\}.$$

Операторы второго типа C_j , $j = 1, 2, \dots, m$, – это операторы «сжатия» числовой последо-

вательности в скаляр (среднее значение сигнала, максимальное значение сигнала, стандартное отклонение, «центр тяжести» сигнала и т.п.):

$$C_j : \vec{y} = \{y_1, y_2, \dots, y_p\} \rightarrow z.$$

Признаки $z_{i_1 i_2 \dots i_k j}$, описывающие сигнал, представляются кодом $[i_1][i_2] \dots [i_k][j]$ и формируются путем последовательного применения к исходной последовательности \vec{x} нескольких операторов первого типа и одного оператора второго типа:

$$z_{i_1 i_2 \dots i_k j} = C_j(B_{i_k}(\dots(B_{i_1}(\vec{x}))))).$$

Поскольку количество таких признаков может быть чрезвычайно велико, ставится задача сократить это количество, руководствуясь определенным критерием качества конечного множества (популяции) признаков. При этом используют различного рода ограничения, требуя, например, чтобы при формировании признаков использовалось не более четырех операторов первого типа.

Другим важным, для понимания возможностей генетических алгоритмов, примером применения генетических алгоритмов является формирование пространства признаков для систем классификации, существенно использующих нечеткую логику. В работах [4, 8] показано, как двухкритериальные (максимум количества правильных решений при использовании минимума решающих правил) генетические алгоритмы могут применяться для отбора лингвистических классификационных правил. Под лингвистическими правилами в данном случае подразумеваются правила продукции «если–то», широко используемые в технологии экспертных систем и позволяющие использовать знания людей-экспертов как на стадии формирования пространства классификационных признаков, так и на стадии непосредственного принятия решений. Используемые в этих правилах лингвистические признаки принимают значения «small» (S), «medium small» (MS), «medium» (M), «medium large» (ML), «large» (L), а также значение «don't care» (DC). Функции принадлежности, с помощью которых осуществляется переход от числовой шкалы значений признаков к лингвистической шкале, имеют вид треугольников (рис. 3). Принцип формирования лингвистических решающих правил поясняется с помощью рис. 4.




Рис. 3. Значения лингвистической переменной

Каждое j -е ($j=1,2,\dots,r$; $r=6^n$; n — количество признаков) лингвистическое решающее правило R_j имеет вид: (если $x_1 \in A_{j1}$) и ... и (если $x_n \in A_{jn}$) \rightarrow класс C_j с достоверностью CF_j , где A_{ji} — нечеткое множество, определяемое j -й функцией принадлежности i -го признака.




Рис. 4. Решающие правила, использующие нечеткие множества

Смысл достоверности CF_j поясняется с помощью рис. 4: в случае (а) достоверность максимальна; в случае (г) достоверность минимальна; в случае (б) достоверность выше, чем в случае (в).

Нетрудно убедиться, что даже в случае двух признаков количество лингвистических решающих правил значительно и достигает $6^2 = 36$. Ясно, что при решении реальных задач количество лингвистических правил становится неприемлемо большим. Решить про-

блему уменьшения количества решающих правил при сохранении высокого качества распознавания удастся с помощью генетических алгоритмов. Помимо двухкритериальных генетических алгоритмов, практический интерес представляют также трехкритериальные генетические алгоритмы, позволяющие не только минимизировать количество решающих правил, но и минимизировать их суммарную протяженность [10, 15].

Как отмечено в работе [16], помимо возможности существенно сокращать мерность пространства классификационных признаков, другим, не менее важным преимуществом использования генетических алгоритмов, является последующая (после выбора признаков) возможность привлечения знаний и опыта экспертов с целью выбора окончательного подмножества предсказывающих признаков. Нетрудно видеть, что такая возможность обеспечена интерпретируемостью полученного множества признаков. Следует лишь добавить, что использование интерпретируемых признаков чрезвычайно важно и на этапе собственно классификации, когда решения о классе объекта принимаются с участием человека-оператора.

Выводы

При создании человеко-машинных систем классификации сигналов классификационные параметры должны быть интерпретируемы, то есть понятны конечному пользователю. Тем самым обеспечивается возможность обоснованного вмешательства человека-оператора в процедуру классификации в полуавтоматическом режиме функционирования системы классификации, а также существенно облегчается процедура обучения и тренировки операторов системы классификации.

В этой связи значительный интерес представляют гибридные системы классификации, содержащие блок нечеткой логики и позволяющие представлять решение задачи классификации, осуществляемое нейронной сетью, в виде набора интерпретируемых (понятных для пользователя) логических правил.

Литература

1. Zak A. Kohonen Networks as Hydroacoustic Signatures Classifier / Zak A. // 9th WSEAS International Conference on Neural Net-

- works (NN'08). – Sofia, Bulgaria: 2008. – P. 209–232.
2. *Ле Н.В.* Распознавание речи на основе искусственных нейронных сетей / Н.В. Ле, Д.П. Панченко // Технические науки в России и за рубежом: материалы междунар. заоч. науч. конф. (г. Москва, май 2011 г.). — М.: Ваш полиграфический партнер, 2011. — С. 8-11.
 3. *Ishibuchi H., Nii M., Tanaka K.* Linguistic rule extraction from neural networks for high-dimensional classification problems / Ishibuchi H. // Complexity International, vol. 6, 1998. [Электронный ресурс]. – Режим доступа к ресурсу: <http://life.csu.edu.au/complex/ci/vol6/ishibuchi-nii/>
 4. *Новоселова Н.А.* Построение нечеткой модели классификации с использованием многокритериального генетического алгоритма / Новоселова Н.А. // Искусственный интеллект. – 2006. – №3. – С. 613–622.
 5. *Ishibuchi H.* Interpretability Issues in Fuzzy Genetics-Based Machine Learning for Linguistic Modelling / Ishibuchi H., Yamamoto T. // Proceedings of Modelling with Words. – 2003. – P. 209-228.
 6. *Панченко Т.* Генетические алгоритмы: учебно-методическое пособие / Панченко Т. – Астрахань: Издательский дом «Астраханский университет», 2007. – 87 с.
 7. *Власова Ю.В.* Применение генетических алгоритмов в задаче классификации сигналов (приложение в ВСИ) / Власова Ю.В. // Сборник тезисов XVI Международной научной конференции студентов, аспирантов и молодых учёных «ЛОМОНОСОВ-2009», секция «Вычислительная математика и кибернетика». – М.: МГУ им. М.В. Ломоносова, 2009. – С. 17.
 8. *Ishibuchi H.* Selecting Linguistic Classification Rules by Two-Objective Genetic Algorithms / Ishibuchi H., Murata T., Turksen I.B. // Proc. of 1995 IEEE International Conference on Systems, Man and Cybernetics. – Vancouver, Canada, October 1995. – P. 1410–1415.
 9. *Ishibuchi H.* Performance Evaluation of Fuzzy Rule-Based Classification Systems Obtained by Multi-Objective Genetic Algorithms / Ishibuchi H., Murata T., Gen M. // Computers ind. Engng. – 1998. – Vol. 35. – № 3–4. – P. 575–578.
 10. Нейрокомпьютерная технология в задачах классификации морских объектов / [Бобровский А.И. [и др.] // Петербургский журнал электроники, – 1997. – №2 (15). – С. 48–52.
 11. *Жеретинцева Н.Н.* Нейросетевой метод идентификации надводных объектов в решении задач автоматизации судовождения: дисс. канд. техн. наук: 05.22.19. / Жеретинцева Н.Н. // Владивосток, 2008. – 162 с.
 12. *Нечаев Ю.И.* Нейросетевые технологии в бортовых интеллектуальных системах реального времени / Нечаев Ю.И. [Электронный ресурс]. – Режим доступа к ресурсу: http://library.mephi.ru/data/scientific-sessions/2002/Lec_Neuro_1/114.html
 13. *Рассел С.* Искусственный интеллект: современный подход, 2-е изд.: Пер. с англ. / Рассел С., Норвиг П. – М.: Издательский дом "Вильямс", 2006. – 1408 с.
 14. *Галушкин А.И.* Нейронные сети: основы теории. / Галушкин А.И. – М.: Горячая линия-Телеком, 2010. – 496 с.
 15. *Новоселова Н.А.* Построение нечеткой нейросетевой модели для решения задач классификации / Новоселова Н.А. // Информатика. – 2006. – № 3. – С. 5–14.
 16. *Новоселова Н.А.* Эволюционный подход к выделению информативных признаков в задачах анализа медицинских данных / Новоселова Н.А., Мاستыкин А.С. // Искусственный интеллект. – 2008. – №3. – С.105–112.