

Запропоновано метод, заснований на використанні штучних нейронних мереж з фрактальною структурою, який дозволяє поліпшити якість рішення задач класифікації. Показано можливість використання методу для випадку малої початкової вибірки

Ключові слова: нейронна мережа, метод синтезу, класифікація

Предложен метод, основанный на использовании искусственных нейронных сетей с фрактальной структурой, позволяющий улучшить качество решения задач классификации. Показана возможность использования метода для случая малой обучающей выборки

Ключевые слова: нейронная сеть, метод синтеза, классификация

The method based on the use of artificial neuron networks with a fractal structure is offered. It allows to improve the quality of decision of the tasks of classification. A possibility of the use of the method for the case of a small teaching selection is shown

Keywords: neuron network, method of synthesis, classification

КЛАССИФИКАЦИЯ НА ОСНОВЕ КООПЕРАТИВНЫХ НЕЙРОСЕТЕВЫХ СТРУКТУР

Д. А. Юрков

Кандидат технических наук, доцент

Кафедра автоматизации и компьютерно-интегрированных технологий

Восточноукраинский национальный университет имени

Владимира Даля

ул. Тухачевского, 11, г. Луганск, Украина, 91050

Контактный тел.: 8-050-475-97-59

E-mail: rusdma@rambler.ru

1. Актуальность проблемы

Использование искусственных нейронных сетей (ИНС) в самых разнообразных системах управления находит всё более широкое применение по ряду причин, одной из которых является трудность формализации многих процессов, протекающих в моделируемой системе.

Эффективность управления любым объектом непосредственно связана с адекватностью используемых для его описания моделей, а в случае, если в качестве модели используется ИНС, эффективность управления напрямую зависит от качества обучения сети. С математической точки зрения под обучением в общем случае понимается поиск такого состояния сети W (все весовые коэффициенты всех нейронов, входящих в сеть), при котором достигается минимум некоторой целевой функции ϵ [1,2], зависящей от текущего состояния сети W^t :

$$\epsilon = \sum_{j=1}^k (\Omega_j(W^t, z^j) - y^j)^2, \quad (1)$$

где $\Omega: z \Rightarrow y$ – отображение, реализуемое нейронной сетью; k – количество примеров в обучающей выборке; y^j – требуемое значение выхода для j -го примера; z^j – входной вектор для j -го примера. Таким образом, ошибка обучения сети ϵ , появляющаяся в некотором состоянии W^t , представлена как сумма

квадратов ошибок для всей обучающей выборки. Если сеть работает безошибочно, то $\epsilon = 0$, а для обученной сети $\epsilon \rightarrow \min$. Таким образом, задача обучения нейронной сети сводится к задаче поиска экстремума-минимума функции ошибки (1) в пространстве состояний W .

Можно выделить ряд факторов, влияющих на качество получаемой в результате оптимизации функции (1) нейросетевой модели, из которых обратим внимание на следующие:

1. Во-первых, качество обучения ИНС непосредственно зависит от информативности обучающей выборки данных, что достаточно очевидно и интуитивно понятно.

2. Во-вторых, используемые в настоящее время методы, обобщённые и подробно описанные в монографиях [1,2], позволяют обнаружить локальный, а не глобальный экстремум-минимум целевой функции ошибки (1).

Такая ситуация обуславливает необходимость разработки новых методов, которые могут обеспечить требуемое качество обучения и должны иметь преимущества над методами существующими, а также удовлетворять требованиям практического использования – времени обучения, простоте реализации, ограничениям по вычислительным ресурсам и т.п. Это – актуальная проблема, не имеющая на данный момент удовлетворительного для ряда задач решения.

2. Цели и задачи

Ранее автором данной работы предложен [3,4] метод синтеза нейросетевых моделей, позволяющий формировать структуру нейронной сети в процессе итерационного вычисления самоподобной логической функции, определяющей принадлежность элемента обучающей выборки к заданному классу – метод формирования фрактальной структуры (ФФС). Основным достоинством предложенного метода является практическая возможность обнаружения глобального экстремума-минимума функции ошибки (1) для любой обучающей выборки. Кроме того, описанный в работах [3,4] метод объединяет в рамках одного итерационного процесса синтез как структуры сети, так и настройку параметров входящих в неё нейронов, что значительно упрощает его использование.

Несмотря на ряд преимуществ, присущих данному методу, остаётся вопрос о качестве получаемой модели. Например, синтезированная для решения задачи классификации ИНС может безошибочно разделять обучающую выборку, т.е. при некотором состоянии сети W^* значение функции (1) $\varepsilon = 0$. Однако, при использовании синтезированной сети для других данных, не входящих в обучающую выборку, можно получить неприемлемый с практической точки зрения результат. Например, классификация может выполняться с большой погрешностью. Описанный эффект можно показать на простейших примерах синтеза сетей, решающих задачу классификации для случаев,

показанных на рис. 1. Примеры иллюстрируют использование ИНС при классификации образов, принадлежащих одному из двух классов.

На рисунке окружностями и прямоугольниками изображены элементы обучающей выборки, относящиеся к различным классам. Входной сигнал для нейронной сети рассматривается как точка на плоскости с координатами $z = (x, y)$, а центр каждой фигуры соответствует этой точке. Закрашенный элемент означает, что нейронная сеть после обучения отнесла его к искомому классу. Затемнённая область на рисунке соответствует области, занимаемой элементами этого класса, и найдена путём полного перебора всех возможных точек в границах изображения и их классификации синтезированной нейронной сетью, структура которой также показана на соответствующем рисунке.

Анализ данных примеров позволяет выделить одну общую для них особенность – несмотря на правильную классификацию элементов обучающей выборки, области, занимаемые искомым классом и полученные путём полного перебора всех точек в границах видимого изображения, достаточно отдалённо напоминают фигуру, ограниченную элементами соответствующего класса. Даже для таких сравнительно простых случаев, которые показаны на рис. 1 а-в, очевидно очень грубое приближение реальной границы фигуры несколькими прямыми. Очевидно, что с практической точки зрения, полученные нейросетевые структуры проблематично использовать в целях управления, т.к. недостаточно точная аппроксимация может привести

к недопустимо большому количеству ошибок.

Основная причина грубой аппроксимации в нашем случае – недостаточно представительная обучающая выборка. Действительно, если гипотетически представить ситуацию, при которой обучающая выборка содержит все элементы, принадлежащие реальной границе между разделяемыми классами, то метод ФФС дал бы замечательный результат. Однако, сложность заключается в том, что реально иметь выборку необходимого объёма возможно только в случае неограниченных возможностей в получении статистического материала. Но в этом случае можно использовать широко известные методы оценки параметров распределений и получать незначительные ошибки при проверке гипотез. К сожалению, практика показывает, что обучающая выборка представляет собой ничтожную часть от общего количества элементов, которые могут принадлежать искомому классу, а увеличение размеров обучающей выборки чаще всего




Рис. 1. Примеры обучающих выборок и синтезированные ИНС

сопряжено с дополнительными затратами, которые не всегда оправданы или же недопустимы вовсе. Можно привести неисчислимое количество примеров, когда получение достаточного объёма статистического материала вызывает объективные трудности. Например, такая ситуация наблюдается при мелкосерийном производстве, при эксплуатации высоко надёжных и дорогостоящих технических систем, при проведении дорогостоящих и опасных экспериментов и т.д. В подобных случаях при анализе статистического материала задача оценки функции распределения становится проблемой, не имеющей простого, очевидного и надёжного решения.

Другой, второстепенной причиной получения достаточно грубой оценки границы между классами является сама целевая функция, смысл которой есть минимизация количества ошибок классификации. Конечно, возможно усложнение целевой функции, включив в неё понятие «гладкости» границы, её равно удалённости от элементов, принадлежащих разным классам или же какие-то иные критерии. Однако, всё это эмпирические методы, чувствительные к конкретной задаче и не решающие проблему в большинстве случаев.

Ещё один недостаток предложенного в работах [3,4] метода ФФС заключается в невозможности оценить вероятность принадлежности предъявляемого ИНС образа к одному из классов, что также снижает его практическую ценность.

Учитывая перечисленные недостатки, становится очевидной необходимость дальнейшего совершенствования ранее описанного метода ФФС, что определим как цель настоящей работы.

3. Развитие метода

В связи с вышеизложенным, автором данной работы предлагается другой подход, частично позволяющий сгладить ранее перечисленные недостатки, суть которого заключается в следующем. Учитывая, что в методе ФФС разделяющие классы плоскости могут формироваться случайным образом, то для какой-то обучающей выборки существует возможность построить K различных нейронных сетей, с помощью которых можно определить области пространства, занимаемые тем или иным классом. Очевидно, что полученные области будут иметь разные границы и пересекаться. Обозначим G_i множество точек, которые могут быть отнесены к искомому классу при использовании i -ой полученной нейронной сети. Также очевидно, что существует множество точек H , каждый элемент которого принадлежит всем областям, полученным по результатам применения всех K полученных нейронных сетей:

$$H = \bigcap_{i=1}^K G_i. \quad (2)$$

Элементы, представленные вектором входных параметров z , не принадлежащие H , ($z \notin H$), могут относиться к заданному классу ω_j с некоторой вероятностью $P(\omega_j|z)$, которую можно рассматривать как апостериорную вероятность. На понятии апостериорной вероятности базируется байесовская класси-

фикация, подробно о которой замечательно написано в монографии [5]. Согласно байесовскому правилу, апостериорная вероятность принадлежности элемента выборки заданному классу (для случая m классов) вычисляется по априорной вероятности $P(\omega_j)$ и условным по классу плотностям $p(z|\omega_j)$ как

$$P(\omega_j|z) = \frac{p(z|\omega_j)P(\omega_j)}{\sum_{i=1}^m p(z|\omega_i)P(\omega_i)}. \quad (3)$$

Однако, для всех ранее рассмотренных примеров определить условные по классу плотности с требуемой точностью не представляется возможным, т.е. данная величина нам неизвестна. Поэтому лучшее, что можно сделать, это вычислить апостериорную вероятность принадлежности к классу предъявляемого ИНС образа на основе той информации, которая у нас имеется – каким образом его классифицировала каждая из K полученных нейронных сетей. В таком случае, соотношение количества классификаций S в пользу искомого класса (который обозначим как C) к общему количеству попыток классификации K можно считать апостериорной вероятностью принадлежности образа z к этому классу, что можно записать в следующем виде:

$$P(C|z) = \frac{S}{K}. \quad (4)$$

Для случая двух классов можно ограничиться только формулой (4), так как значение апостериорной вероятности другого класса вычисляется элементарно. Из (4) следует метод улучшения качества классификации:

- получить заданное число нейронных сетей на основании имеющейся обучающей выборки методом ФФС;
- вычислив $P(C|z)$, сравнить полученное значение с заданным пороговым значением апостериорной вероятности P_0 и в случае, если выполняется условие $P(C|z) \geq P_0$ принять решение о принадлежности элемента z классу C .

Таким образом, система, реализующая вычисление (4), должна быть представлена как объединение K нейронных сетей, синтезированных методом ФФС на основе одной и той же обучающей выборки. Общая структура такой системы показана на рис. 2 и не требует подробных комментариев.




Рис. 2. Структура нейронной сети, получаемая в результате объединения ИНС, полученных методом ФФС

Очевидно, что подобная структура может легко быть реализована в виде обобщающей единой нейронной сети, где вычисление $P(C|z)$ легко представить в

нейросетевом базисе – формальным нейроном, математическая модель которого представляется в виде:

$$\psi = f(w_0 + \sum w_i \phi_i), \quad (5)$$

где ψ - выходной сигнал нейрона, ϕ_i - i -й входной сигнал, w_i - вес i -го входа (в случае двух классов $w_i = 1/K$, $w_0 = -P_0$), f - пороговая функция активации. В дальнейшем назовём полученную структуру нейронной сетью с кооперативной структурой.

4. Теория и практика

Использование теоретических результатов требует как минимум качественных оценок, в связи с чем рассмотрим возможности и преимущества предлагаемого метода синтеза нейронных сетей. Для этого оценим результаты, полученные для различных обучающих выборок, отличающихся степенью сложности с точки зрения задачи классификации, а также сделаем некоторые выводы об эффективности его использования.




Рис. 3. Результаты синтеза и использования сети для $K=100$ при различных значениях P_0 : а) $P_0=0.05$; б) $P_0=0.1$; в) $P_0=0.2$; г) $P_0=0.5$; д) $P_0=0.9$; е) $P_0=1$

В дополнение к сказанному, конкретные примеры позволяют лучше понять и оценить предлагаемый метод синтеза.

Очевидно, что качество классификации для любого образа непосредственно зависит от количества K используемых в общей структуре (рис. 2) ИНС, а также от величины порога апостериорной вероятности, согласно которому принимается решение о принадлежности образа искомому классу.

В первом случае рассмотрим, как влияют указанные параметры на качество определения границы области решений для достаточно сложного случая, когда элементы искомого класса занимают невыпуклую область.

Результаты синтеза и классификации показаны на рис. 3 (а-е).

Из рис. 3а и 3б видно, что недостатком малого порогового значения P_0 является неоправданное расширение области решений до максимально возможной, что не соответствует действительно занимаемой искомым классом области пространства. Это приводит к увеличению количества ошибок при использовании полученной нейронной сети на практике.

Другая крайность – принять $P_0 \approx 1$ (рис. 3д и 3е), что приводит к неоправданному уменьшению области решений. В последнем случае вообще к области, занимаемой элементами искомого класса, относятся только эпизодические участки и элементы, включённые в обучающую выборку.

Данный пример, а также многочисленные другие примеры, не приведенные в данной работе, позволяют утверждать, что при больших значениях K приемлемым можно считать значение P_0 в диапазоне от 0.5 до 0.8, что зависит от конкретной задачи и определяется практическими соображениями. Для данного диапазона значений P_0 достаточно точно находится внешняя граница области, занимаемой элементами искомого класса.

На качество аппроксимации границы области решений значительное влияние оказывает количество нейронных сетей K , объединяемых в единую структуру.

Очевидно, что значение K влияет на точность классификации, что хорошо видно на рис. 4, (а-г) для примера обучающей выборки, показанной на рис. 1, г.




Рис. 4. Результаты синтеза и использования сети при $P_0 = 0.5$ для различных значениях K : а) $K = 5$; б) $K = 20$; в) $K = 50$; г) $K = 100$

Необходимо отметить, что предложенный метод синтеза ИНС позволяет получать нейросетевые структуры, успешно работающие с выборками малого объёма, что для статистического анализа является существенной проблемой [6].

Пример такой малой обучающей выборки и результат использования предлагаемого метода показан на рис. 5.




Рис. 5.

Результаты синтеза нейронной сети и её использования для случая малой обучающей выборки: а) $P_0 = 0.5$; б) $P_0 = 0.6$; в) $P_0 = 0.8$; г) $P_0 = 0.9$

Обратим внимание, что вся обучающая выборка состоит только из девятнадцати элементов, из которых только девять относятся к искомому классу. Тем не менее, полученные результаты позволяют утверждать, что синтезированная ИНС для данного случая достаточно успешно определила область пространства, занимаемую искомым классом. По крайней мере, тенденция к размещению элементов искомого класса определена верно.

5. Выводы

На основании изложенного в работе материала можно утверждать, что для описанного класса задач:

1. Рассмотрены особенности применения ИНС, синтезированные методом формирования фрактальной структуры [3,4] для примеров различной сложности. Анализ рассмотренных примеров показал что, несмотря на ряд преимуществ дан-

ного метода, его существенным недостатком остаётся грубая аппроксимация границы области пространства, занимаемой элементами искомого класса, что может приводить к недопустимо большому количеству ошибок при использовании полученных моделей на практике.

2. Предложен метод, основанный на объединении отдельных нейронных сетей в единую структуру, позволяющий значительно улучшить достоверность классификации.

3. Исследования нейронных сетей, синтезированных предложенным методом, показали возможность его успешного использования для обучающей выборки малого размера.

4. Определен диапазон значений P_0 , при котором достигается приемлемое качество классификации для самых разнообразных случаев.

5. Рассмотренный подход к синтезу ИНС отличается простотой реализации и высокой скоростью работы.

Литература

1. Методы классической и современной теории автоматического управления: Учебник в 5-ти тт.; 2-е изд., перераб. и доп. Т.5: Методы современной теории автоматического управления / Под ред. К.А. Пупкова, Н.Д. Егупова. – М.:Издательство МГТУ им. Н.Э. Баумана, 2004. – 784 с.

2. Методы робастного, нейро-нечеткого и адаптивного управления: Учебник / Под ред. Н.Д. Егупова; издание 2-ое, стереотипное. - М.:Издательство МГТУ им. Н.Э. Баумана, 2002. - 744 с.
3. Д. А. Юрков. Синтез нейронных сетей с фрактальной структурой. // Восточно-Европейский журнал передовых технологий. №4-3 (40) - Харьков: Технологический центр, 2009 г. С 39-44.
4. Д.А. Юрков. Метод синтеза нейросетевых модельных структур. // Вісн. Східноукр. нац. ун-ту. - 2009. - № 5 (135). - С.115-122.
5. Р. Дуда, П. Харт. Распознавание образов и анализ сцен. - М.:Мир, 1976. - 512 с.
6. Гаскаров Д.В., Шаповалов В.И. Малая выборка. - М.: Статистика, 1978. - 248 с.

У статті розглядається метод синтезу багатозв'язних регуляторів, заснованих на VARMAX-моделі, для керування технологічним процесом вирощування органічних монокристалів. Приведено використаний алгоритм структурної і параметричної ідентифікації VARMAX-моделі, що відповідає даному процесу

Ключові слова: органічний монокристал, метод Бриджмена-Стокбаргера, кристалізація, віджиг, оптимальне керування, синтез регулятора, VARMAX-модель

В статье рассматривается метод синтеза многосвязных регуляторов, основанных на VARMAX-модели, для управления технологическим процессом выращивания органических монокристаллов. Приведен использованный алгоритм структурной и параметрической идентификации VARMAX-модели, соответствующей данному процессу

Ключевые слова: органический монокристалл, метод Бриджмена-Стокбаргера, кристаллизация, отжиг, оптимальное управление, синтез регулятора, VARMAX-модель

In this article the multivariate controllers synthesis method founded on VARMAX-models for governing of organic monocrystals growing technological process is considered. The structural and parametrical used algorithm of VARMAX-models identification is represented

Key words: organic monocrystal, Bridgman-Stockbarger method, crystallization, anneal, optimal control, controller synthesis, VARMAX-model

УДК 658.012

ОБ ОДНОМ МЕТОДЕ СИНТЕЗА МНОГОСВЯЗНЫХ РЕГУЛЯТОРОВ

А.Д. Тевяшев

Доктор технических наук, профессор, заведующий кафедрой*

В.Н. Щелкалин

Аспирант*

*Кафедра прикладной математики

Харьковский национальный университет

радиоэлектроники

пр. Ленина, 14, г. Харьков, Украина, 61200

Ю.М. Епифанов

Кандидат технических наук**

Ю.С. Козьмин

Инженер**

**Институт сцинтилляционных материалов НАН

Украины

пр. Ленина, 60, г. Харьков, Украина, 61001

1. Введение

Органические монокристаллы (ОМК) — это системы, обладающие наилучшими характеристиками для задач спектроскопии короткопробежных заряженных частиц и быстрых нейтронов. Наиболее широкое рас-

пространение получили кристаллы стильбена и партерфенила. Последний является наиболее эффективным органическим сцинтиллятором с наилучшими механическими характеристиками [8].

Технология получения органических монокристаллов состоит из следующих основных стадий: