

ИСПОЛЬЗОВАНИЕ ГИПОТЕЗЫ λ -КОМПАКТНОСТИ ПРИ ПОСТРОЕНИИ ОБУЧАЮЩЕЙ ВЫБОРКИ ДЛЯ ПРОГНОЗИРУЮЩИХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

В.А. КРИСИЛОВ, С.А. ЮДИН, Д.Н. ОЛЕШКО

Решается задача построения качественной обучающей выборки для нейронных сетей в прогнозировании. Описана возможность использования гипотезы λ -компактности на этапе построения множества распознаваемых классов. На основе рассмотренных механизмов предложен усовершенствованный алгоритм построения качественной обучающей выборки.

ВВЕДЕНИЕ

Проблема качества данных, используемых для обучения — одна из важнейших проблем, решаемых при построении интеллектуальных обучающихся систем. От качества обучающего материала зависит не только достоверность функционирования системы в будущем, но и возможность обучиться в принципе.

Сегодня в различных предметных областях широко применяются обучающиеся системы, построенные на основе аппарата искусственных нейронных сетей (ИНС). Чаще всего, это прогнозирующие модели, используемые в системах поддержки принятия решений (СППР) в задачах управления технологическими процессами, электронного бизнеса и экономического мониторинга. Как и в любой другой обучающейся системе, при построении ИНС предполагается обеспеченность некоторыми исходными данными для обучения, формирующими ее обучающую выборку (ОВ).

Особенность большинства экономических и технологических процессов, требующих применения СППР — их высокая динамичность и связанная с ней необходимость достаточно частого обновления прогнозирующих нейросетевых моделей. Однако отсутствие формальных методик, которые позволили бы оценить качество сформированной ОВ приводит к увеличению затрат на синтез прогнозирующей модели в целом. Причинами этого является и увеличение времени сходимости процесса обучения на некачественной ОВ, и затраты на поиск альтернативных методов построения ОВ в случае неуспешного обучения. Увеличение же времени, затрачиваемого на построение или на актуализацию прогнозирующей модели, делает данный метод прогнозирования неэффективным [1, 2].

В разрабатываемом методе формирования ОВ предложено рассматривать проблему «времени и качества» с точки зрения достаточности. Под достаточностью в каждом конкретном случае будем подразумевать некоторое огрубление условий и, возможно, некоторое ослабление ограничений задачи. Такая операция позволяет, теряя в качестве, выигрывать во времени. В каждый конкретный момент определение значений параметров преобразования данных, структурного или параметрического синтеза происходит именно исходя из принципа достаточности (ПД) [8].

Идея отказа от 100%-ного качества не нова. Первым с аналогичной идеей выступил профессор Lotfi A. Zadeh: «Терпимость к неточности, нечеткости и частичной правде может эксплуатироваться для достижения удобства манипулирования, устойчивости, низкой стоимости решения и лучшего соответствия действительности» [9].

В другой, более конструктивной, трактовке ПД состоит в том, что существует достаточный (не избыточный) уровень детализации исходных данных, внутренних состояний СППР и результатов процесса принятия решения, который может быть задан на основании формализованного анализа условий и цели конкретной задачи. Применение ПД подразумевает формирование входного, внутреннего и выходного пространств СППР так, чтобы уровень их нечеткости оставался достаточным для получения конструктивного результата, т.е. результата приемлемого качества (достоверности, точности и т.п.) при допустимых затратах. При такой постановке задачи становится очевидно, что соблюдение ПД непосредственно связано с формализацией цели конкретной задачи [8].

Таким образом, задача построения качественной ОВ в контексте развития интеллектуальных систем, основанных на нейронных сетях, является актуальной. Ее решение позволит существенно ускорить процесс обучения нейронных сетей, а, следовательно, и сам процесс интеллектуального анализа данных.

Цель данной работы — повышение скорости и качества интеллектуального анализа данных за счет формализации процесса построения ОВ при обучении нейронных сетей.

В ходе исследования разрабатывались:

- комплексный критерий оптимальности качественной ОВ;
- алгоритм построения множества распознаваемых классов в рамках формирования ОВ, основанного на гипотезе λ -компактности [6, 7].

АЛГОРИТМ ПОСТРОЕНИЯ КАЧЕСТВЕННОЙ ОВ

Входными данными для алгоритма служит ОВ, построенная методом «скользящих окон» для некоторого заданного размера окна W_k и содержащая n обучающих наборов (ОН).

Задача алгоритма — построить оптимальное разбиение на классы множества эталонных значений ОВ.

При построении обучающей выборки классическим методом «скользящих окон» обучающая выборка представляет собой набор объектов, заданных в виде таблицы объект – свойство [7], дополненной эталоном — иден-

тификатором класса. В этом случае задача заключается в том, чтобы научить нейронную сеть распознавать один из n эталонов по k -входным значениям предыдущих элементов ряда. С целью снижения числа распознаваемых классов, а следовательно, уменьшения времени обучения сети логично преобразовать выборку таким образом, чтобы похожие значения эталонов объединить в один таксон и обучать сеть распознавать уже $(n - m)$ классов, где m — количество образованных таксонов. Для решения объединения в классы эталонных значений обучающей выборки, построенной с использованием метода «скользящих окон», целесообразно использовать методы кластерного анализа.

Одним из используемых методов построения качественной ОВ является алгоритм, базирующийся на комплексном критерии [3].

Предлагаемый в этом алгоритме преобразования ОВ критерий оптимальности основан на таких характеристиках ОВ.

Непротиворечивость. Пусть множество пар вида $((x_{1i}, x_{2i}, \dots, x_{ki}))$, Y_l — множество ОН преобразованной ОВ, причем: $\forall Y_l \in Y\{Y_1, Y_2, \dots, Y_s\} | Y_l = \frac{1}{n} \sum_i y_z$; n — количество начальных классов y_z , составивших класс

Y_l ; s — мощность нового множества распознаваемых классов; i — номер ОН. Тогда для двух обучающих наборов i и j : $\Delta Y_{mn} = \sqrt{(Y_m - Y_n)^2}$ — расстояние между центроидами, соответственно, m -го и n -го классов, а расстояние между объектами этих классов будет вычисляться по формуле

$$\Delta x_{ij} = \sqrt{(1/Dx_1)(\Delta x_1)^2 + \dots + (1/Dx_k)(\Delta x_k)^2},$$

где $\Delta x_k = x_{ki} - x_{kj}$; Dx_k — дисперсия свойства k -го измерения по всей ОВ.

Теперь, введя два расстояния: между объектами и между центроидами классов, к которым они принадлежат, можно определить понятие противоречивости.

Пусть C_{ij} — парная противоречивость — противоречивость двух обучающих наборов (i -го и j -го), принадлежащих, соответственно, классам Y_m и Y_n . Тогда, очевидно, что C_{ij} возрастает, если возрастает ΔY_{mn} или убывает Δx_{ij} .

На основании данных рассуждений предложена следующая формула для вычисления C_{ij} :

$$C_{ij} = \frac{\Delta Y_{mn}}{\Delta x_{ij} + \Delta Y_{mn}}.$$

Согласно этой формуле, противоречивость двух объектов лежит в диапазоне $[0; 1]$, достигает максимума при совпадении характеристик объектов, принадлежащих разным классам, и становится равной 0 в случае, если рассматриваются объекты одного класса. Противоречивостью всей ОВ будет среднее всех C_{ij} .

$$C_{\text{OB}} = \left(\sum_1^n C_{ij} \right) / n, \quad (1)$$

где n — количество всех парных противоречивостей в ОБ.

Равномерность. Для оценки неравномерности была рассмотрена случайная величина $N_{\text{ОН}}$ — количество ОН в классе. В качестве величины, характеризующей неравномерность построенной ОБ, предлагается среднеквадратичное отклонение $N_{\text{ОН}}$.

$$R_{\text{OB}} = \sigma(N_{\text{ОН}}). \quad (2)$$

Среднеквадратичная ошибка преобразования исходных данных. Как и для любого преобразования данных, здесь важно уметь оценить его погрешность и стремиться выбирать решение с минимальной величиной этой погрешности.

В данном случае после преобразования множества распознаваемых классов $Y\{y_1, y_2, \dots, y_m\} \Rightarrow Y\{Y_1, Y_2, \dots, Y_s\}$ ошибкой преобразования на одном наборе является величина

$$D_i = Y_i - y_i,$$

а среднеквадратичная ошибка может быть вычислена следующим образом:

$$D_{\text{OB}} = \sqrt{\sum_1^n D_i^2 / n}, \quad (3)$$

где n — количество ОН.

Количество классов. Ограничивающим фактором для понижения R_{OB} служит величина N_{CLASS} . Таким образом, она также должна быть включена в искомый критерий.

Оптимальной считается ОБ, удовлетворяющая критерию

$$Q_{\text{OB}}^* = \min(Q_{\text{OB}}), \quad (4)$$

где Q_{OB} — функционал, позволяющий оценить качество ОБ на каждой отдельной итерации, и вычисляется по формуле

$$Q_{\text{OB}} = C_{\text{OB}}^{w_C} * R_{\text{OB}}^{w_R} * D_{\text{OB}}^{w_D} * N_{\text{CLASS}}^{w_N}, \quad (5)$$

где w_C, w_R, w_D, w_N — показатели, характеризующие важность той или иной характеристики для разработчика в рамках текущей задачи.

Максимальное количество объектов в классах ограничивается некоторым значением N_{max} , которое достаточно мало на начальной итерации и увеличивается до некоторого предела на последующих итерациях алгоритма. Кроме того, пользователем задается ограничение на точность представления данных L_{max} , которое является максимально допустимым расстоянием между объектами класса для заданной шкалы.

Такой алгоритм построения качественной ОБ, как правило, обеспечивает удовлетворительные результаты таксономии, а, следовательно, быстрое

и качественное обучение нейронной сети. Однако вследствие того, что в нем на первом месте стоят ограничения на количество объектов в классе и на размеры класса, при объединении объектов в таксоны могут быть нарушены реальные закономерности, отражающие специфику распределения объектов.

Другими словами, объекты в этом алгоритме продолжают образовывать один и тот же таксон до тех пор, пока не выполнится одно из условий:

1. Количество объектов в таксоне превысит максимально допустимое.
2. Диаметр таксона превысит максимально допустимый.

И только после этого исследуем величину, характеризующую плотность распределения объектов, играющую в процессе формирования таксонов решающую роль [6, 7]. Таким образом, алгоритм не чувствителен к распределению объектов внутри и на границах интервала L_{\max} . Такая последовательность действий иногда может привести к неправильным результатам таксономии и некорректному отнесению объектов к классам, а, следовательно, к ошибкам при обучении НС.

Для того чтобы продемонстрировать некорректную работу алгоритма, достаточно рассмотреть процесс анализа ОВ, изображенный на рис. 1.




Рис. 1. Пример таксономии исходным алгоритмом при условии $L_{\max} = 6$

Как видно из рис. 1, предложенный алгоритм не всегда способен адекватно распределить объекты по классам. Это приводит к дополнительным искажениям исходных данных и, как следствие, снижению достоверности самой прогнозирующей модели, несмотря на достаточно разносторонний критерий качества ОВ, позволяющий количественно учитывать важные его показатели.

Таким образом, для повышения эффективности построения качественной ОВ необходимо предложить алгоритм таксономии для использования в комплексе с разработанным в [3] критерием качества ОВ, который обеспечивал бы сохранение законов распределения выборки при осуществлении таксономии и учитывал ограничения на точность, накладываемые экспертом.

АЛГОРИТМ ТАКСОНОМИИ НА БАЗЕ ГИПОТЕЗЫ λ -КОМПАКТНОСТИ

В основе подавляющего большинства методов анализа данных лежит эвристическая гипотеза компактности, которая состоит в том, что при правильном выборе системы информативных признаков реализации образов разных классов располагаются компактными группами в окрестностях центров соответствующих классов, формируя «компактные сгустки». В последнее время активно развивается гипотеза λ -компактности. В отличие от гипотезы компактности, она базируется не на понятии абсолютного расстоя-

ния, а на некотором более сложном показателе, получившем название λ -расстояния [6, 7], который позволяет дополнительно учитывать однородность распределения объектов в классах. В силу этого преимущества одними из наиболее эффективных и универсальных алгоритмов таксономии сегодня по праву считаются алгоритмы, основанные на гипотезе λ -компактности [6, 7].

Ниже предложен алгоритм, основанный на гипотезе λ -компактности, в котором отсутствуют недостатки предыдущего алгоритма.

Критерий оценки качества таксономии. Следствием гипотезы λ -компактности является утверждение о том, что чем больше величина λ -расстояния, соответствующая ребру λ -кратчайшего незамкнутого пути (λ -КНП), тем больше вероятность прохождения по этому ребру границы между таксонами [6, 7]. Таким образом, величина λ -расстояния может быть интерпретирована как вероятность разрыва ребра графа λ -КНП. Из каждой вершины λ -КНП в общем случае может исходить k ребер. Следовательно, вероятность разрыва i -го ребра p_i можно представить как

$$p_{iz} = \frac{\lambda_{iz}}{\sum_{j=1}^k \lambda_{jz}}, \quad (6)$$

где $\lambda_i - \lambda$ — расстояние, соответствующее i -му ребру, исходящему из вершины z в λ -КНП; k — количество ребер, исходящих из вершины z .

Таким образом, каждый объект может быть объединен в один класс с соседним объектом при условии, что для ребра λ -КНП, соединяющего их, вероятность разрыва минимальна. На рис. 2 показан пример объединения объектов в класс во фрагменте λ -КНП.




Рис. 2. Объединение объектов в один класс

Расчеты вероятности осуществляются для каждого объекта в исследуемом множестве. Образуется первичное множество таксонов, которые не содержат областей нарушения локальной однородности [6, 7]. Следует заметить, что все это происходит за один проход алгоритма.

Получение такого разбиения на таксоны может являться конечным результатом, так как в соответствии с гипотезой компактности полученные таксоны неделимы. Однако, как правило, такой результат первого этапа

слишком «подробен». Это объясняется тем, что каждая область, в которой нет нарушения локальной однородности, представляет собой отдельный таксон. Т.е. в результате первого этапа получается множество таксонов, характеризующееся однородностью распределения объектов внутри них, и не учитывающее расстояние между объектами или таксонами.

Другими словами, на этом этапе достигнуто *необходимое* в соответствии с гипотезой λ -компактности качество таксономии. Для достижения *достаточного* его уровня необходимо разработать показатель качества. При обсуждении недостатков критерия качества таксономии, используемого в исходном алгоритме [3], говорилось о том, что такой показатель в первую очередь должен учитывать расстояние между классами, а не показатели количества объектов в классах или их диаметры. Если исследуется большое множество объектов, один из которых находится на существенном отдалении от других, то этот один является отдельным классом, который может быть интерпретирован как помеха или случайный выброс. Вряд ли можно игнорировать единичное существенное отклонение от среднего только потому, что в исследуемой выборке оно встретилось единожды. Более того, бывают случаи, когда целью таксономии является выделение именно таких отклонений.

Теперь, если среди всех ребер построенного λ -КНП найти ребро, которому соответствует минимальное λ -расстояние, то два таксона, соединенные этим ребром графа, сольются в один таксон.

Таким образом, результаты таксономии представляют собой иерархическую структуру, количество таксонов в которой на каждом шаге уменьшается на единицу. Вершиной структуры является один таксон.

Положим в основу показателя качества таксономии величину, характеризующую изменение среднего λ -расстояния внутри таксонов f на каждом шаге. Такую характеристику можно получить, построив λ -КНП на множестве значений функции $f(x)$ — среднего λ -расстояния по всем таксонам для текущего варианта таксономии и исследовав его на наличие нарушений локальной однородности. Тогда значение показателя качества кластерного анализа на i -м шаге можно вычислить по формуле

$$K_i = \frac{f(i)}{f(i-1)}. \quad (7)$$

Критерием качества предлагается считать следующую величину как характеристику наилучшего варианта таксономии:

$$\max(K_i). \quad (8)$$

При вычислении среднего λ -расстояния по всем таксонам нужно иметь в виду, что λ -расстояние в таксоне, содержащем один объект, равно нулю [7]. Также считается, что величина показателя локальной неоднородности в таксоне, содержащем два объекта, равна единице [6]. Следовательно, величина λ -расстояния в таком таксоне вычисляется как

$$\lambda = \frac{d}{\tau_{\max} D}. \quad (9)$$

Возможны ситуации, когда необходимое число таксонов задано не конкретным числом, а интервалом. В этом случае в качестве оптимального следует выбрать максимальное значение показателя на этом интервале.

ХОД АЛГОРИТМА

1. Строится полный λ -граф, соединяющий все объекты из исследуемого множества [6, 7].
2. Строится λ -КНП [6, 7].
3. Рассчитываются вероятности разрыва для каждого объекта по каждому смежному ребру λ -КНП.
4. Каждый объект объединяется в один класс с соседним объектом при условии, что для ребра, соединяющего их, вероятность разрыва минимальна.
5. Вычисляется центр каждого таксона и строится λ -КНП на множестве таксонов.
6. Рассчитывается $f(x)$, где x — число таксонов на текущем шаге.
7. Среди всех ребер нового λ -КНП находится ребро, которому соответствует минимальное λ -расстояние. Два таксона, соединенные этим ребром графа, сливаются в один таксон.
8. Пп. 5...7 повторяются до тех пор, пока не останется всего один таксон. Для него рассчитывается среднее значение λ -расстояния.
9. Формируется вариант таксономии, которому соответствует максимум показателя качества.
10. Осуществляется последовательный перебор всех классов. Для каждого класса рассчитывается диаметр и количество объектов.
11. Если диаметр или количество объектов превышает заданные предельно-допустимые величины N_{\max} и L_{\max} , таксон разрывается в ребре, которому соответствует максимальное значение λ -расстояния. П. 11 повторяется для каждого из вновь образованных классов. Если рассчитанные значения находятся в допустимых пределах, работа с таксономом заканчивается.
12. Осуществляется оценка качества (5) сформированной ОВ.

РЕШЕНИЕ ПРАКТИЧЕСКИХ ЗАДАЧ

Была поставлена задача прогнозирования пунктов английского фунта на электронном рынке FOREX в частности, построить прогнозирующую модель и оценить следующие ее параметры:

- время, затрачиваемое на синтез модели;
- достоверность получаемых прогнозов и горизонт доверия прогнозу;
- время, затрачиваемое на актуализацию уже построенной модели.

Особенность исходных данных заключается в том, что существует возможность их получения с фактически любой частотой дискретизации пунктов. В данном случае интерес представляло получение прогнозов в течение одного рабочего дня для оперативной игры на курсе английской валюты. Для этого выбрана частота дискретизации 5 минут. Трудность состояла в

том, что при этом данные только за одни сутки насчитывают почти 400 позиций. Кроме того, исследуемый ВР может иметь множество видов закономерностей: часовые, дневные, недельные, месячные, годовые. Было принято решение рассмотреть ОВ, состоящую из отсчетов за один рабочий день, и на ее примере оценить заданные параметры.

При решении данной задачи без применения разработанной информационной технологии получены следующие результаты.

- Построено несколько ОВ, различающихся размером окна описания ситуации ($W_1 = 3, 5, 7$), которые содержали от 36 до 39 распознаваемых классов.

- Создано и обучено 9 сетей различной конфигурации и для различных ОВ.

- Обучение каждой сети длилось в среднем 63 часа при некоторой постоянной величине шага изменения ВК (CPU 700 MHz, 128 Mb RAM).

- В результате верификации построенных прогнозирующих моделей на тестовой выборке, состоящей из 10 значений, по минимальному значению ошибки была отобрана нейронная сеть, содержащая три слоя: 7, 40, 38 нейронов, соответственно. При построении прогноза с горизонтом прогнозирования 10 дней квадратичная ошибка построенного прогноза составила 5,12 %.

При решении поставленной задачи с помощью разработанного метода получена ОВ, содержащая 21 класс. При этом $Q_{ОВ} = 72182,77$ при следующих значениях характеристик: $R_{ОВ} = 9,517617$; $C_{ОВ} = 0,5269$; $D_{ОВ} = 9157$; $N_{CLASS} = 21$. В то время как для ОВ, построенной классическим методом, эти же параметры составляли: $Q_{ОВ} = 887524,07$ при $R_{ОВ} = 579,1501$; $C_{ОВ} = 0,3652$; $D_{ОВ} = 0,2094$; $N_{CLASS} = 38$.

С помощью предложенного механизма структурного синтеза построена нейронная сеть, содержащая три слоя с количеством нейронов: 7, 21 и 21, соответственно.

На параметрический синтез данной модели затрачено около 20 часов (CPU 700 MHz, 128 Mb RAM).

Квадратичная ошибка прогноза составила 3,84 %.

Таким образом, были исследованы зависимости точности прогноза от величины горизонта прогнозирования для обеих моделей. Полученные результаты показаны на рис. 3, где модель № 1 построена классическим методом, а модель № 2 построена с использованием разработанной технологии.

Получен выигрыш во времени, затраченном на построение прогнозирующей модели и, в частности, в три раза сокращены затраты на параметрический синтез. Ошибка прогноза уменьшена в среднем в 1,3 раза. Отметим, что и в данной задаче прогнозирующая модель показала себя более устойчивой в режиме построения прогнозов с горизонтом больше 1.

На основании предложенной технологии решена также задача прогнозирования остатков на банковском счете банка «Південний». Как и в предыдущем случае, время, затраченное на построение прогнозирующей модели, уменьшено, практически, в два раза, а ошибка прогноза — в среднем в 1,5.

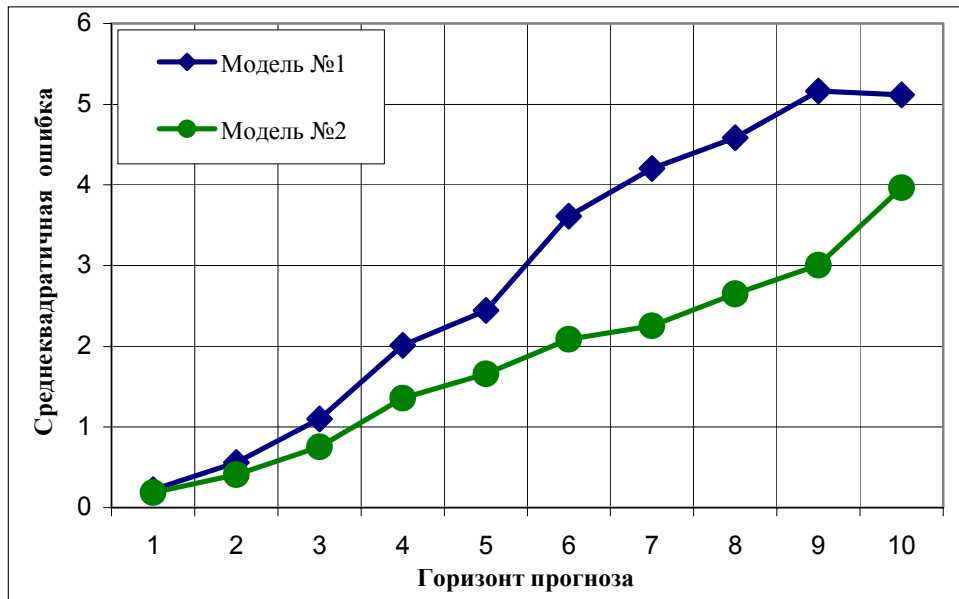


Рис. 3. Зависимость среднеквадратичной ошибки прогноза от величины горизонта прогнозирования

ЗАКЛЮЧЕНИЕ

Разработанный алгоритм построения качественной ОВ стал результатом объединения подходов [4, 5, 6, 7], подчиненных ограничениям, обусловленным требованиями к точности представления данных и качеству построенной ОВ.

Предложенный критерий оценки качества построенной ОВ позволяет осуществить объективную оценку и дает разработчику наглядную возможность оперировать степенями важности характеристик ОВ в процессе ее построения.

Разработанный алгоритм автоматического построения качественной ОВ в значительной степени облегчает труд проектировщика прогнозирующей нейросетевой модели. Ряд экспериментов по прогнозированию временного ряда валютных котировок и сравнению полученных результатов с результатами построения обучающей ОВ методом «скользящих окон» показал, что к достоинствам алгоритма можно отнести следующие факторы:

1. Существенное сокращение затрат времени на построение обучающей выборки, отвечающей всем заданным требованиям.
2. Построенная в результате выборка максимально отвечает установленным требованиям качества, что обуславливает снижение в разы затрат времени на обучение НС и снижение ошибки прогноза в среднем в полтора раза.
3. Компактное разбиение множества эталонных значений ОВ на классы позволяет выиграть в размерности сети, что также снижает затраты времени на синтез прогнозирующей НС.

Алгоритм построения качественной ОВ, основанный на гипотезе λ -компактности, базируется на понятии λ -расстояния. Это позволяет од-

новременно учитывать компактность залегания объектов в таксоне и однородность их распределения.

Недостатком алгоритма является отсутствие учета равномерного распределения количества объектов в классах на этапе кластеризации. Эту проблему можно решить, используя, наряду с показателем λ -расстояния, показатель «равномощности» распределения, лежащий в основе алгоритма таксономии λ -KRAВ

$$h = k^k \prod_{i=1}^k \frac{m_i}{m},$$

где k — количество классов; m_i — число объектов в i -м классе; m — общее число объектов.

Перспективой для дальнейших исследований является повышение качества ОБ за счет учета равномерного распределения объектов по классам в алгоритме, основанном на гипотезе λ -компактности.

ЛИТЕРАТУРА

1. Крисилов В.А., Тарасенко Р.А. Предварительная оценка качества обучающей выборки для нейронных сетей в задачах прогнозирования временных рядов // Тр. Одесского политехн. ун-та. — 2001. — Вып. 1. — С. 90–93.
2. Аксенов О.Ю. Обнаружение и распознавание объектов на изображениях с использованием искусственных нейросетей // Всероссийская научно-техн. конф. «Нейроинформатика–99». Часть 3. — М.: МИФИ, 1999. — С. 131–137.
3. Олешко Д.Н., Крисилов В.А., Блажко А.А. Построение качественной обучающей выборки для прогнозирующих нейросетевых моделей // Искусственный интеллект. — 2004. — 3. — С. 567–573.
4. Нейронные сети. Statistica Neural Networks / Пер. с англ. — М.: Горячая линия — Телеком. — 2000. — 182 с.
5. Олешко Д.Н., Крисилов В.А. Двухэтапное обучение нейронных сетей в задачах прогнозирования временных рядов // Искусственный интеллект. — 2002. — Вып. 4. — С. 742–746.
6. Загоруйко Н.Г. Гипотезы компактности и λ -компактности в методах анализа данных // Сибирский журн. индустриальной математики. — Новосибирск: Ин-т математики, 1998. — 1. — С. 114–126.
7. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. — Новосибирск: Ин-т математики, 1999. — 259 с.
8. Krisilov V.A., Krisilov A.D., Oleshko D.N. Application of the sufficiency principle in acceleration of neural networks training // Information Theories & applications. — 2003. — 10, № 2. — P. 179–183.
9. Zadeh L.A. Toward a perception-based theory of probabilistic reasoning with imprecise probabilities // Journal of Statistical Planning and Inference. — 2002. — № 105. — P. 233–264.

Поступила 23.09.2005