



2. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика. – М.: Горячая линия-Телеком, 2002. – 382 с.
3. Jose Orozco, Carlos A. Reyes Garcia Detecting Pathologies from Infant Cry Applying Scaled Conjugate Gradient Neural Networks // European Symposium on Artificial Neural Networks, Bruges (Belgium), 23-25 April 2003, d-side publ. – Pp. 349-354.
4. Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth Neural Network Toolbox. User's Guide. – 2017.
5. Клячкин В.Н., Кувайскова Ю.Е., Алексеева В.А. Статистические методы анализа данных. – М. : Финансы и статистика, 2016. – 240 с.
6. Клячкин В. Н., Кувайскова Ю. Е., Жуков Д. А. Использование агрегированных классификаторов при технической диагностике на базе машинного обучения // Сборник трудов III международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ-2017). – Самара: Новая техника, 2017. – С. 1763-1766.
7. Жуков Д.А., Клячкин В.Н., Кувайскова Ю.Е. Сравнительный анализ методов машинного обучения при прогнозировании состояния технического объекта // Радиоэлектронная техника. – 2017. – №1(10). – С. 189-192.
8. Жуков Д. А. Повышение эффективности машинного обучения при решении задач технической диагностики // IN MEMORIAM: Султан Галимзянович Валеев : сборник памяти С.Г. Валеева. – Ульяновск : УлГТУ, 2016. – С. 139-143.

А.А. Тарасов, И.В. Лёзина

АППРОКСИМАЦИЯ ПЛОТНОСТЕЙ ВЕРОЯТНОСТИ НЕЧЁТКИМ ПЕРСЕПТРОНОМ

(Самарский университет)

При обработке статистического материала часто приходится решать вопрос о том, как подобрать для данного статистического ряда теоретическую кривую распределения, выражающую лишь существенные черты статистического материала [1]. Эта задача относится к классу задач аппроксимации.

Существует множество способов аппроксимации, одним из которых является использование нейронных сетей в качестве универсального аппроксиматора. Это следует из теоремы Хета-Нильсена о представимости любой многомерной функции нескольких переменных с помощью нейронной сети фиксированной размерности [3]. Таким образом, любую сложную функцию можно заменить более простой нейросетевой аппроксимацией, причём требуется только нелинейность функции активации нейрона.

В качестве обучающей последовательности может использоваться файл со сгенерированной случайной последовательностью. На основании этого файла будет построена гистограмма. Выделив на этой гистограмме M крайних ле-



вых точек $\{x_i, y_i\}$, где M -число дифференциальных коридоров, мы получим выборки, которые будут входить в обучающую последовательность. При этом в нечётком слое будет происходить кластеризация координат x . На рисунке 1 представлена гистограмма и показаны пары $\{x_i, y_i\}$, которые будут использованы при аппроксимации [1].

Важную роль при аппроксимации нейронными сетями играет выбор архитектуры сети. В данной работе будет использована структура «нечёткого» персептрона, структура которой показана на рисунке 2. «Нечёткая» сеть объединяет в себе сеть с нечёткой организацией (препроцессора) и многослойный персептрон в качестве постпроцессора[2].

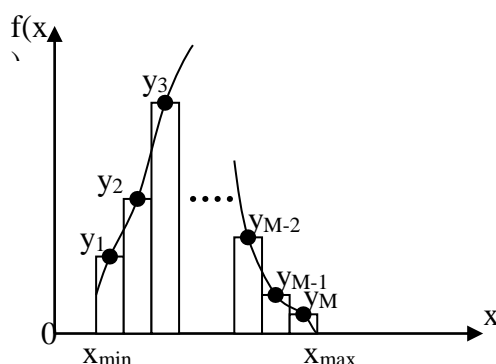


Рисунок 1 – Модель плотности вероятности

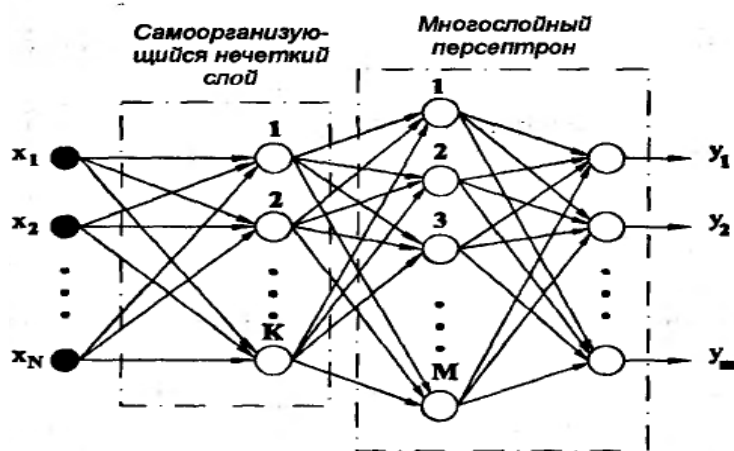


Рисунок 2 – Структура нечёткого персептрона

Использование препроцессора, размерность которого больше размерности входного вектора, обосновывается теоремой Ковера о разделимости образов [3]. В ней утверждается, что преобразование задачи классификации в пространство более высокой размерности повышает вероятность линейной разделимости образов[3]. Это позволяет подавать на вход многослойного персептрона уже откластеризованные данные.

Для настройки центров кластеризации нечёткого слоя будем применять алгоритм нечёткой нечёткой кластеризации C-means. Он позволяет после предъявления очередного вектора x уточнять центры кластеров, на которые



разделяется многомерное пространство. Использование данных центров гарантирует сходимость алгоритмов к глобальному минимуму [2].

Таким образом, если на вход сети подаётся вектор $x = [x_1, x_2, \dots, x_n]$, на выходе нечёткого слоя будет получен вектор u , который состоит из коэффициентов принадлежности x к конкретным центрам: $u = [u_1(x), u_2(x), \dots, u_k(x)]$. Конкретные компоненты рассчитываются в соответствии с формулой [2]:

$$u_{ij} = \frac{1}{\sum_{k=1}^K \left(\frac{d^2(x_j, c_i)}{d^2(x_j, c_k)} \right)^{\frac{1}{m-1}}} \quad (1)$$

где $d^2(x_j, c_i)$ расстояние между x_j и c_i , m -коэффициент нечёткости множества.

После стабилизации положений центров кластеризации начинается процесс обучения многослойного персептрона. В данной работе будет использован метод обратного распространения ошибки для коррекции весов персептронного слоя, в котором будет минимизироваться следующая функция ошибки:

$$E = \frac{1}{2} \sum_{j=1}^p (y_j - d_j)^2 \quad (2)$$

где p – количество обучающих выборок, y_k – фактический отклик сети, d_j - желаемый отклик сети [2].

Для модификации весов персептронного слоя воспользуемся следующей формулой:

$$w(k+1) = w(k) + \Delta w \quad (3)$$

где

$$\Delta w = -\eta \nabla E(w) \quad (4)$$

η – коэффициент обучения, $\nabla E(w)$ – градиент функции ошибки [2].

В качестве входного слоя будет использоваться нечёткий слой, формирующий коэффициенты принадлежности вектора x , а желаемым откликом будет необходимое значение аппроксимируемой функции. После завершения процесса обучения все веса запоминаются, и сеть становится готовой к аппроксимации.

Исследования проводились на случайной последовательности, распределённой по нормальному закону. Объём выборки 10000 отсчетов, количество дифференциальных коридоров 20, количество нейронов в нечётком слое 10, количество нейронов в скрытом персептронном слое 20. СКО аппроксимации составило 0,04.

На практике гибридная сеть, как правило, более эффективна, чем одиночная сеть с нечёткой самоорганизацией и чем самостоятельный многослойный персептрон. Этот вывод следует из факта, что при использовании гибридной сети задача разделяется на два независимых этапа, реализуемых отдельно друг от друга [2].

Литература

1. Прохоров, С.А. Аппроксимативный анализ случайных процессов. [Текст]/А.С.Прохоров. –2-е изд., перераб. и доп./СНЦ РАН, 2001. – 125с.



2. Осовский, С. Нейронные сети для обработки информации [Текст]/ Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344с.: ил.
3. Хайкин, С. Нейронные сети: полный курс, 2-е издание [Текст]/ Пер. с англ. – М.: Издательский дом «Вильямс», 2006. – 1104 с.: ил.

Я.Ф. Узянбаева

РАЗРАБОТКА СИСТЕМЫ АВТОМАТИЗАЦИИ ИМИТАЦИОННЫХ ИССЛЕДОВАНИЙ «АВТОБУСНЫЙ МАРШРУТ» В СРЕДЕ ANYLOGIC

(Башкирский государственный педагогический университет им. М.Акумуллы)

Увеличение автомобилей и общественного транспорта привело к появлению пробок на дорогах. Наиболее тяжелая ситуация на дорогах складывается в час пик. Оптимизация работы городского транспорта необходима, так как она многие годы не подвергалась научному исследованию и перегружена дублирующими маршрутами и их неэффективной работой. Создание имитационной модели «Автобусный маршрут» должно помочь выявить оптимальные пути решения транспортных проблем [1-5].

Для разработки научно-исследовательских имитационных моделей используются системы имитационного моделирования Anylogic и GPSS World [6-8]. В версии AnyLogic 7.3.3 и выше новая библиотека дорожного движения позволяет детально имитировать физическое перемещение машин по дорожной сети. Кроме того, она дает возможность моделировать: движение с учётом ПДД, светофоры и приоритеты проезда на перекрестках, парковки, движение и остановки общественного транспорта. Также в библиотеке есть инструмент, позволяющий визуализировать плотность трафика в сети.

Для разработки имитационной модели автобусного маршрута был выбран отрезок пути от остановки Музей им. Нестерева до остановки Монумент Дружбы маршрутного автобуса 234к.

Построенная имитационная модель улично-дорожной сети, максимально приближена к реальной системе. На данной модели проведены предварительные исследования по оптимизации автобусного маршрута. Модель позволяет изучить ситуацию на дороге и выбирать эффективные пути решения проблем.

На рис. 2 представлена модель участка улично-дорожной сети г.Уфы, построенная с помощью среды моделирования AnyLogic.

Дорога построена на основе библиотеки дорожного движения. Поточковая диаграмма, которая показана на рисунке 3, отвечает за движение машин и автобусов.