

УДК 681.324

Р. Н. Кветный, д. т. н., проф.; В. В. Кабачий, к. т. н., доц.; О. О. Чумаченко**ВЕРОЯТНОСТНЫЕ НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ
ИДЕНТИФИКАЦИИ ВРЕМЕННЫХ РЯДОВ**

В данной статье рассмотрена возможность идентификации временных рядов на основе вероятностных нейронных сетей и ее модифицированных версий. Исследовано влияние ширины ядерной функции на адекватное восстановление плотности и качество классификации. Рассмотрены модифицированные версии вероятностных нейронных сетей и, особенности их применения. Выделены преимущества и недостатки вероятностных нейронных сетей.

Ключевые слова: вероятностные нейронные сети (PNN), идентификация, классификация образов, анализ временных рядов.

Введение

Задача идентификации (процессов, систем) или построение математической модели по результатам наблюдений занимает одно из главных мест в современной теории управления и принятия решений в разных областях: технике, экономике, биологии и др. Наиболее эффективными математическими моделями, с помощью которых можно прогнозировать развитие процессов являются те, при построении которых используются временные ряды [1].

Традиционные подходы к идентификации становятся все менее пригодными для моделирования сложных нелинейных систем. Большинство процессов не могут быть описаны с помощью традиционных статистических моделей, поскольку они являются существенно нелинейными и имеют или хаотичную, или квазипериодическую, или смешанную (стохастическую, хаос-динамическую, детерминированную) основу. Адекватным аппаратом для построения моделей практически любых нелинейных структур могут служить методы, построенные на основе искусственного интеллекта, а именно искусственные нейронные сети, которые имеют способность к моделированию нелинейных процессов, адаптации и позволяют работать с зашумленными данными. Перспективными отмечаются радиально-базисные структуры, отличающиеся высокой скоростью обучения и универсальными аппроксимирующими возможностями [2, 3].

Именно таким инструментом являются вероятностные нейронные сети (PNN – Probabilistic Neural Network), которые на фоне других интеллектуальных средств, что могут быть использованы для идентификации систем, имеют ряд существенных преимуществ, которые будут приведены в данной статье. Вероятностные нейронные сети относятся к нейронным сетям радиально-базисного типа, которые благодаря их надёжности, сегодня используются в различных задачах классификации образов [5 – 16]. Не случайно в [17] автор отмечает, что PNN являются наиболее эффективной нейронной сетью. Вероятностные нейронные сети предложены Д. Ф. Шпехтом [18 – 20] как совершенствование статистических методов распознавания образов.

Целью статьи является повышение эффективности использования вероятностных нейронных сетей и её модификаций в задачах идентификации временных рядов в режиме реального времени.

Постановка задачи

Для прогнозирования развития процессов перспективным является применение методов распознавания образов, целью которых является классификация объектов по нескольким классам. Такой подход помогает решить комплекс задач, которые занимают важное место в прогнозировании [2, 21].

Аппарат вероятностных нейронных сетей, который рассматривается, может быть

использован для исследования следующих процессов, которые представлены временными рядами:

- прогнозирование электрических нагрузок;
- прогнозирование изменения котировок;
- прогнозирование состояния и качеств поверхностных вод;
- распределение нагрузки сети между информационными потоками.

Для этого является возможным применение метода скользящего окна. Пусть идентифицируемая нелинейная зависимость представлена как выборка «входы-выход»:

$$(X_i, y_i), i = \overline{1, M}, \quad (1)$$

где $X_i = (x_{i,1}, x_{i,2}, \dots, x_{i,p})$ – вектор входов, y_i – выход в i -ой паре, M – объем выборки.

Задача идентификации – нахождение модели F , которая обеспечивает минимальное значение отклонения значения выхода модели при значениях входов, заданных вектором X , от выхода y .

В вероятностных нейронных сетях образцы классифицируются на основе оценок их сходства с соседними образцами. Формальным правилом при классификации является то, что класс с большей плотностью распределения вероятностей в области неизвестного образца будет иметь преимущество по сравнению с другими классами. Для оценки функции плотности распределения вероятностей используются непараметрические методы оценки. Исследование работ по данному вопросу показало, что, как правило, применяют метод Парцена, в соответствии с которым для каждого учебного образца рассматривается некоторая весовая функция, которая еще имеет название функции потенциала или ядра.

Чаще всего в качестве ядерных функций берут упрощенные функции Гаусса:

$$K(X) = e^{\left(-\frac{\|X - X_i\|^2}{2\sigma^2}\right)}, \quad (2)$$

где X_i – i -ый образец вектора X , $i = \overline{1, L}$, X – неизвестный образец, σ – параметр, который задаёт ширину ядерной функции Гаусса и определяет её влияние. Но вид функции ядра K практически не влияет на точность восстановления плотности и на качество классификации.

Структура вероятностной нейронной сети

Пример структуры вероятностной нейронной сети для решения задачи классификации p -х компонентных входных векторов x на M классов изображен на рис. 1. Входной слой сети расчетов не выполняет и служит для приема и деления признаков входного вектора. Количество нейронов входного слоя определяется количеством признаков вектора x . Слой образцов содержит по одному нейрону для каждого образца входного вектора из обучающей выборки. То есть при общем объеме обучающей выборки, которая содержит L образцов, слой образцов должен иметь L нейронов. Входной слой и слой образцов образуют полносвязную структуру.

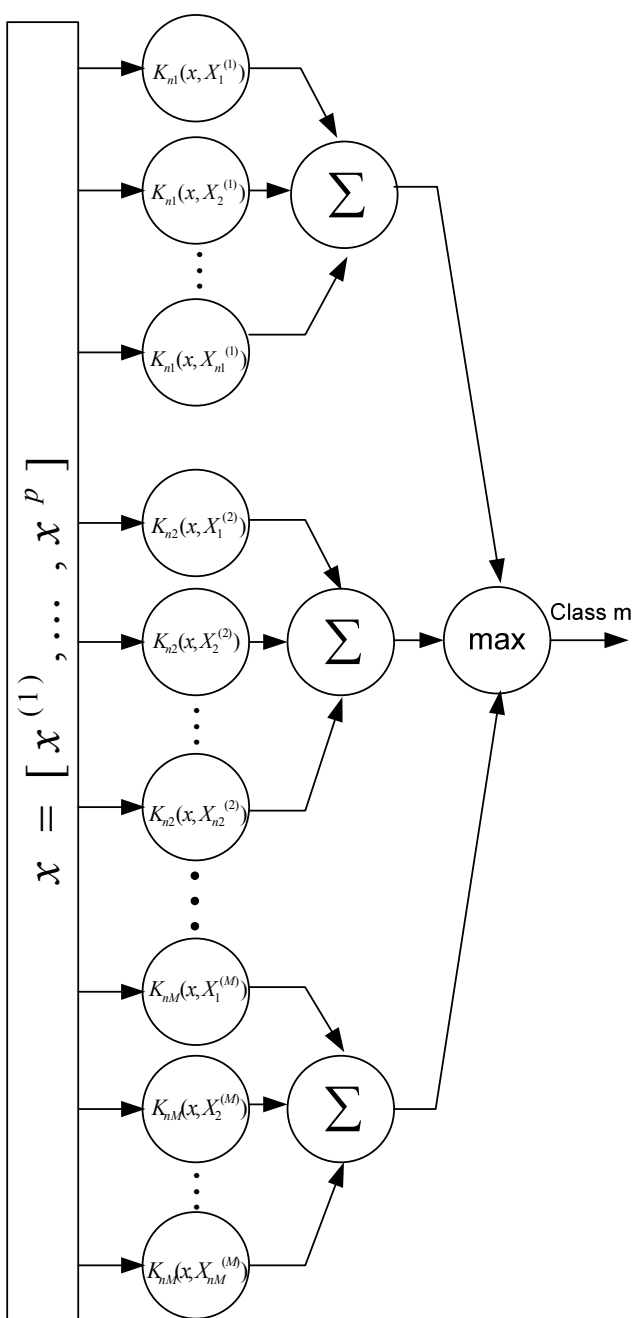


Рис. 1. Архитектура вероятностной нейронной сети

Слой суммирования содержит количество нейронов, равное количеству классов, на которые разбиваются входные образы. Каждый нейрон слоя суммирования имеет связи только с нейронами слоя образцов, которые относятся к соответствующему классу. Все веса связей слоя суммирования в традиционной вероятностной нейронной сети приравниваются единицам.

Исходный нейрон выполняет функции дискриминатора пороговой величины. Он указывает, какой нейрон слоя суммирования имеет максимальный выходной сигнал. Тем самым определяется класс, к которому принадлежит представленный входной образ. Веса связей нейрона исходящего слоя устанавливаются так, чтобы на его выходе идентифицировался нейрон слоя суммирования с наибольшим значением активности.

В ходе обучения формируется структура вероятностной нейронной сети. Размерность N векторов обучающей выборки $X_i, i = \overline{1, L}$ определяет количество нейронов и структуру входящего слоя вероятностной нейронной сети. Общий размер L обучающей выборки $X_i, i = \overline{1, L}$ соответствует общему количеству нейронов слоя образцов.

Предъявление сети каждого из L образцов сопровождается указанием от учителя номера k -го класса, которому принадлежит входящий образец. Последовательность

предъявления обучающих образцов может быть любой. После предъявления всех L векторов обучающей выборки, формируется структура сети, и становятся определены параметры сети в виде матрицы. На этом процесс обучения вероятностной нейронной сети завершается и сеть готова к классификации неизвестных образцов.

В рабочем режиме сети подается входной образ X неизвестного класса, который сначала нормализуется, а потом умножается на матрицу весов и соответствующим образом активизирует нейроны слоя образцов. Каждый нейрон слоя образцов показывает на своём выходе некоторый уровень активности $y_i(X)$. Каждый k -ый нейрон слоя суммирования складывает равные активности $y_i(X)$ всех нейронов слоя образцов своего k -го класса и показывает на своём выходе общий уровень активности данного k -го класса

$y^k(X), k = \overline{1, M}$, определяет, какой нейрон слоя суммирования имеет максимальный выходной сигнал $y^k(X)$. Таким образом, по номеру k -го нейрона определяется номер класса k , которому с большей вероятностью принадлежит образ X .

Таким образом, вероятностные нейронные сети принадлежат к классу нейронных сетей с учителем, который автоматически ставит ещё одну очень важную задачу формирования эффективной обучающей выборки. Используя описанный выше инструмент, мы можем: спрогнозировать относительное изменение будущих значений временного ряда; идентифицировать тренд (восходящий, нисходящий, боковой); построить индикатор для идентификации точек разворота тренда.

Надлежащий выбор значения параметра сглаживания σ является критичным для эффективности вероятностной нейронной сети. Отметим, что величина σ влияет на качество восстановления плотности. Результаты моделирования влияния значения ширины ядерной функции на восстановление плотности показаны на рис. 2.

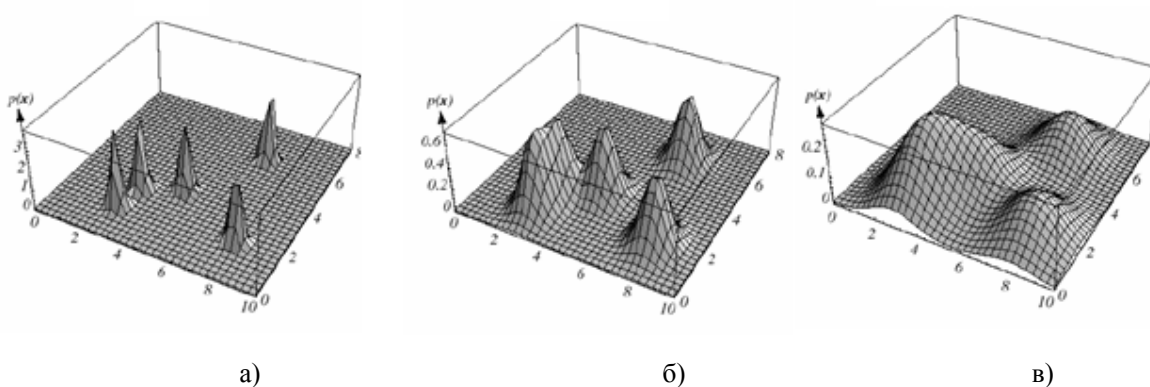


Рис. 2. Влияние управляющего параметра σ на вид оценки Парцена:
а) небольшое σ ; б) среднее σ ; в) большое σ

Из рис. 2 следует: если значение σ небольшое, то плотность концентрируется вблизи обучающих образцов и функция плотности вероятностей будет испытывать резкие скачки. Однако, если значение σ большое, то детали плотности будут размыты. Таким образом, должно существовать оптимальное значение ширины окна σ , при котором возобновляемая плотность будет наиболее адекватна. Оптимальная ширина окна σ является компромиссом между точностью описания конкретных данных и гладкостью эмпирической функции.

Функция активности k -го нейрона суммирования определяет значение плотности распределения вероятностей для всего k -го класса. В общем виде она рассчитывается по формуле:

$$Y^k(X) = \frac{1}{N(2\pi)^{\frac{p}{2}} \sigma^p} \sum_{j=1}^{L_k} e^{\left(-\frac{(x-x_{kj})^T(x-x_{kj})}{2\sigma^2} \right)}, k = \overline{1, M}, \quad (3)$$

Взвешенная вероятностная нейронная сеть (WPNN) является усовершенствованной версией традиционной вероятностной нейронной сети PNN. Такая сеть обеспечивает более высокий коэффициент распознавания и сохраняет преимущества PNN. Отделимость классов используется как один из базовых критериев выбора в классификации образцов. В отличие от WPNN, традиционная вероятностная нейронная сеть устанавливает равные веса для всех образцов без расчета делимости классов. То есть WPNN включает весовые коэффициенты между слоем образцов и слоем суммирования. Структура WPNN подобна PNN, единственное отличие – наличие весовых коэффициентов. Функция активности k -го нейрона суммирования рассчитывается по формуле:

$$Y^k(X) = \frac{1}{N(2\pi)^{\frac{p}{2}} \sigma^p} \sum_{j=1}^{L_k} V_{kj} e^{-\frac{(x-x_{kj})^T(x-x_{kj})}{2\sigma^2}}, k = \overline{1, M}, \quad (4)$$

где V_{kj} – весовой коэффициент, который высок для образца с высокой степенью отделимости классов и небольшой для образца с небольшой степенью отделимости классов.

Традиционная вероятностная нейронная сеть, предложенная Д. Ф. Шпехтом, реализуется с помощью алгоритма, который обеспечивает обучение сети всего за один проход. Использование другой модификации вероятностной нейронной сети (MPNN) особенно целесообразно для анализа нелинейных временных рядов. Это достигается за счет введения связи между структурой PNN и радиальными базисными функциями Гаусса. Подобно PNN, обучение MPNN ориентировано на память и требует только одного прохода. Во время обучения, нейронная сеть сохраняет обучающие входные векторы как центры нейронной сети. Эти центры связываются со значениями желаемых выходов. Во время классификации наиболее близкий по отношению к каждому из центров, классифицируемый входной вектор определяется с помощью ядерной функции. Выход ассоциируется с центром наиболее близким к входящему вектору как наиболее подходящий выход. Модель такой сети:

$$\hat{y}(x) = \frac{\sum_{i=1}^N Z_i y_i e^{-\frac{(x-c_i)^T(x-c_i)}{2\sigma^2}}}{\sum_{i=1}^N Z_i e^{-\frac{(x-c_i)^T(x-c_i)}{2\sigma^2}}}, \quad (5)$$

где c_i – центр вектора для класса во входном пространстве, Z_i – количество входных векторов, которые ассоциируются с центром c_i [5].

Выводы

В данной работе проанализированы возможности применения вероятностных нейронных сетей для анализа и прогнозирования временных рядов. Эти сети отличаются особенно высокой скоростью обучения, что позволяет использовать их для идентификации временных рядов в режиме реального времени, и возможностью получения полезных результатов на маленьких обучающих выборках даже при условии наличия ошибочных данных.

Обзор состояния проблемы показал, что сегодня вероятностные нейронные сети эффективно используются для решения задач классификации при исследовании разных объектов. Доказано, что эффективность данного метода идентификации определяется качеством подготовки входных данных: обеспечением их статистической независимости и нормализацией, что максимально повышает их энтропию. Исследованы пути повышения эффективности на основе регулирования основных параметров нейронных сетей.

СПИСОК ЛИТЕРАТУРЫ

1. Мокін Б. І. Математичні методи ідентифікації електромеханічних процесів / Б. І. Мокін, В. Б. Мокін. – Вінниця: УНІВЕРСУМ-Вінниця, 1999. – 99 с.
2. Тихонов Е. В. Методы и алгоритмы прогнозирования экономических показателей на базе нейронных сетей и модулярной арифметики / Е. В. Тихонов, В. А. Кузьмищев. – Невинномысск: НИЭУП, 2004. – 166 с.
3. Сигеру О. Нейроуправление и его приложения / О. Сигеру. – М.: ИПРЖР, 2001. – 321 с.
4. Streit R. L. Maximum likelihood training of probabilistic neural networks / R. L. Streit, T. E. Luginbuhl // IEEE Trans. Neural Networks, V. 5, 1994. – №5. – P. 764 – 783.
5. Zaknich A. Introduction to the modified probabilistic neural network for general signal processing applications / A. Zaknich // IEEE Transactions on Signal Processing, V. 46, 1998. – №7. – P. 1980 – 1990.
6. Saad E. W. Comparative study of stock trend prediction using time delay, recurrent and probabilistic neural networks / E. W. Saad, D. V. Prokhorov, D. C. Wunsch, // IEEE Transactions on Neural Networks, V. 9, 1998. – №6.

– P. 1456 – 1470.

7. Tsuji T. A loglinearized Gaussian mixture network and its application to EEG pattern classification // IEEE Transactions on Systems, Man, and Cybernetics / T. Tsuji, O. Fukuda, H. Ichinobe, V. 29, 1999. – №1. – P. 60–72.

8. Tian B. Temporal updating scheme for probabilistic neural network with application to satellite cloud classification / B. Tian, M. R. Azimi-Sadjadi, T. H. Vonder Haar // IEEE Transactions on Neural Networks, V.11, 2000. – №4. – P. 903 – 920.

9. Lin W. M. Adaptive multiple fault detection and alarm processing for loop system with probabilistic network / W. M. Lin, C. H. Lin, Z. C. Sun // IEEE Transactions on Power Delivery, V. 19., 2004. – №1. – P. 64 – 69.

10. Anagnostopoulos I. Classifying Web pages employing a probabilistic neural network / I. Anagnostopoulos, C. Anagnostopoulos, V. Loumos // IEEE Proceedings – Software, V. 151, 2004. – №3. – P. 139– 150.

11. Gerbec D. Allocation of the load profiles to consumers using probabilistic neural networks / D. Gerbec, S. Gasperic, I. Smon // IEEE Transactions on Power Systems, V.20, 2005. – №2 – P. 548 – 555.

12. Masters T. Advanced Algorithms For Neural Networks. A C++ Source-book New York / T. Masters – New York: Wiley, 1995. – 431 p.

13. Specht D. F. Probabilistic neural networks and the polynomial adaline as complementary techniques for classification / D. F. Specht // IEEE Trans. Neural Networks, Jan, 1990. – P. 111 – 121.

14. Specht D. F. Probabilistic neural networks / D. F. Specht // Neural Networks, V. 3, 1990. – P.109 – 118.

15. Specht D. F. Enhancements to the probabilistic neural networks / D. F. Specht // Proc IEEE Int Joint Conf. Neural Networks, 1992. – P.761 – 768.

16. Минаев Ю. Н. Методы и алгоритмы решения задач идентификации и прогнозирования в условиях неопределенности в нейросетевом логическом базисе / Ю. Н. Минаев, О. Ю. Филимонова, Бенамеур Лиес. – М.: Горячая линия – Телеком, 2003. – 205 с.

Кветный Роман Наумович – д. т. н., профессор заведующий кафедрой автоматике и информационно-вычислительной техники.

Кабачий Владислав Владимирович – к. т. н., доцент кафедры автоматике и информационно-вычислительной техники.

Чумаченко Ольга Олеговна – студентка института магистратуры, аспирантуры и докторантуры. Винницкий национальный технический университет.