



[16x16] LeNet-1	1,7
LeNet-4	1,1
LeNet-4/Local	1,1
LeNet-4/K-NN	1,1
LeNet-5	0,95
[dist] LeNet-5	0,8
[dist] Boosted LeNet-4	0,7

Таким образом, реализованная в рамках данной работы нейронная сеть, при более простой по сравнению со свёрточной сетью структуре, показывает результаты распознавания, сопоставимые с сетями LeNet.

Литература

1. LeCun, Y. The MNIST database of handwritten digits – <http://yann.lecun.com/exdb/mnist>.
2. Солдатова О.П., Гаршин А.А. Применение сверточной нейронной сети для распознавания рукописных цифр. Компьютерная оптика. – 2010. – Том 34, №2. – с. 252-260 – ISSN 0134-2452.
3. LeCun, Y. Gradient Based Learning Applied to Document Recognition / Y. LeCun, L. Bottou, P. Haffner – IEEE Press, 1998. – 46 pages.

О.П. Солдатова, Д.А. Панкратова

АНАЛИЗ РЕЗУЛЬТАТОВ ПРОГНОЗИРОВАНИЯ УЧЕТНЫХ ЦЕН НА ДРАГОЦЕННЫЕ МЕТАЛЛЫ С ПОМОЩЬЮ НЕЧЕТКОЙ НЕЙРОННОЙ ПРОДУКЦИОННОЙ СЕТИ ВАНГА-МЕНДЕЛЯ

(Самарский государственный аэрокосмический университет)

Способности нейронной сети к прогнозированию напрямую следуют из её способности к обобщению и выделению скрытых зависимостей между входными и выходными данными. После обучения сеть способна предсказать будущее значение некой последовательности на основе нескольких предыдущих значений и (или) каких-то существующих в настоящий момент факторов. Следует отметить, что прогнозирование возможно только тогда, когда предыдущие изменения действительно в какой-то степени определяют будущее. Например, прогнозирование котировок акций на основе котировок за прошлую неделю может оказаться успешным (а может и не оказаться), тогда как прогнозирование результатов завтрашней лотереи на основе данных за последние 50 лет почти наверняка не даст никаких результатов [1].

Для прогнозирования учетных цен на драгоценные металлы была выбрана сеть Ванга-Менделя, поскольку только для этой сети существует эффективный и достаточно простой адаптивный алгоритм обучения, который позволяет автоматически организовать сеть. Данный алгоритм подбирает число нейронов



в скрытом слое для решения конкретной задачи, что является основной проблемой при проектировании многослойных сетей.

Сеть Ванга-Менделя относится к классу нечётких продукционных нейронных сетей, который объединяет возможности нечёткого логического вывода, присущих базам продукционных правил, и способности нейронных сетей обучаться на ограниченном множестве примеров.

Сеть представляет собой четырехслойную структуру, в которой первый слой выполняет фуззификацию входных данных, второй – агрегирование значений активации условия нечёткого правила вывода, третий (линейный) – агрегирование M правил вывода (первый нейрон) и генерацию нормализующего сигнала (второй нейрон), тогда как состоящий из одного нейрона выходной слой осуществляет нормализацию, формируя выходной сигнал $y(x)$. Только первый и третий слои являются параметрическими. В первом слое это параметры функции фуззификации $(c_j^{(k)}, \sigma_j^{(k)}, b_j^{(k)})$, а в третьем слое – веса v_1, v_2, \dots, v_M , интерпретируемые как центр c_k функции принадлежности следствия i -го нечеткого правила вывода [2]. Структура сети представлена на рисунке 1.




Рис. 4. Структура нечеткой нейронной сети Ванга-Менделя

Выходной сигнал данной нечеткой сети определяется по формуле:



$$y = f(x) = \frac{\sum_{i=1}^M v_i \prod_{j=1}^N \exp \left[- \left(\frac{x_j - c_j^{(i)}}{\sigma_j^{(i)}} \right)^{2b_j^{(i)}} \right]}{\sum_{i=1}^M \prod_{j=1}^N \exp \left[- \left(\frac{x_j - c_j^{(i)}}{\sigma_j^{(i)}} \right)^{2b_j^{(i)}} \right]}.$$

Для обучения сети Ванга-Менделя использовались два алгоритма: адаптивный и обратного распространения ошибки [2]. Поскольку второй алгоритм имеет линейную сходимость и проводит «грубую» аппроксимацию, он применялся не в чистом виде, а в совокупности с адаптивным алгоритмом (последовательный метод обучения) и с предварительной инициализацией нелинейных параметров сети с помощью алгоритма K -усреднений.

Адаптивный алгоритм позволяет определить количество и расположение центров, иначе говоря, число нейронов в скрытом слое (нечетких продукционных правил).

Общий вид формулы адаптации для алгоритма обратного распространения ошибки имеет вид:

$$p_{il}(l+1) = p_{il}(l) - \eta_p \frac{\partial E(l)}{\partial p_{il}},$$

где η_p – коэффициент обучения,

$E(l)$ – мера абсолютной погрешности обучения,

p_{il} – нелинейные параметры сети.

С помощью данного алгоритма выполняется подбор нелинейных параметров сети – $c_j^{(k)}, \sigma_j^{(k)}$, которые соответствуют центру и ширине компоненты входного вектора.

Алгоритм K -усреднений проводит инициализацию нелинейных параметров сети [2]. Он так же, как и адаптивный алгоритм заключается в разделении пространства входных данных на кластеры.

В научно-исследовательской работе обучение проводилось на выборках, включающих учетные цены на золото, платину, серебро и палладий в период с 01.01.2013 по 10.04.2014, т.е. мощность выборки составляет около 300 значений.

Примем обозначения:

r – максимальный радиус кластера для адаптивного алгоритма;

w – размер скользящего окна;

$test$ – мощность тестовой выборки;

e – количество эпох;

$rools$ – количество правил (нейронов в скрытом слое);

tol – точность для алгоритма обратного распространения ошибки.

Результаты исследований были собраны в таблицы, в которых отражены значения параметров, использованных при обучении разными алгоритмами, и значения погрешностей обучения и тестирования (см. таблицу 1 и таблицу 2).



Таблица 1 – Параметры алгоритмов обучения

Название металла	Название алгоритма обучения	Максимальный радиус, r	Размер скользящего окна, w	Количество правил, rools	Количество эпох, e
Серебро	Адаптивный	0.06	3	-	10
	ОРО	-	2	2	65
	Последовательный	0.5	2	47	24
Платина	Адаптивный	3	2	-	10
	ОРО	-	2	33	300
	Последовательный	15	2	63	30
Золото	Адаптивный	4	2	-	11
	ОРО	-	2	25	45
	Последовательный	4	2	222	27
Палладий	Адаптивный	1	2	-	30
	ОРО	-	2	50	34
	Последовательный	10	2	48	45

Таблица 2 – Погрешности обучения и тестирования

Название металла	Максимальная цена, руб.	Название алгоритма обучения	Погрешность обучения	% соотношение	Погрешность тестирования	% соотношение
Серебро	31.26	Адаптивный	0.2591	0,83	0.2671	0,85
		ОРО	0.5074	1,62	0.1252	0,40
		Последовательный	0.9112	2,91	0.2061	0,66
Платина	1738.05	Адаптивный	7.4096	0,43	18.6029	1,07
		ОРО	17.2892	0,99	20.029	1,15
		Последовательный	240.8300	13,86	26.4316	1,52
Золото	1644.68	Адаптивный	8.6406	0,53	21.9411	1,33
		ОРО	37.2129	2,26	15.9596	0,97
		Последовательный	229.2618	13,94	27.7305	1,69
Палладий	925.57	Адаптивный	2.8794	0,31	16.4163	1,77
		ОРО	12.1499	1,31	11.8707	1,28
		Последовательный	16.5982	1,79	15.3426	1,66

В качестве меры погрешности использовалось значение СКО, полученное на последнем этапе обучения:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (y_i^{val} - y_i)^2}{N-1}},$$

где y_i^{val} – вычисленное значение выходного сигнала сети;

y_i – эталонное значение выходного сигнала сети,

N – размерность выборки.



Кроме того, для наглядности была найдено процентное соотношение данной погрешности относительно максимального значения цены драгоценного металла.

Из таблиц 1 и 2 следует, что:

- задаваемый радиус кластера растет пропорционально порядку значений выборки;
- адаптивный алгоритм обучения работает эффективнее при обучении, чем при тестировании;
- адаптивный алгоритм требует наименьшее количество эпох обучения;
- адаптивный алгоритм обучения инициализирует алгоритм обратного распространения ошибки гораздо хуже, чем алгоритм K-усреднений;
- для драгоценных металлов, имеющих большее количество скачков цен, приходится выбирать минимально возможный размер прогнозного окна;
- при последовательном применении двух алгоритмов обучения используется больше нейронов скрытого слоя, что увеличивает вычислительную мощность, но ухудшает показатели прогнозирования в целом;
- задаваемая для алгоритма обратного распространения точность не оказывает существенного влияния на результат;
- при прогнозировании использовалось прогнозное окно преимущественно размера 2, с увеличением размера существенно увеличивалась погрешность.

Следует отметить, что сеть Ванга-Менделя показывает хорошие результаты при прогнозировании цен на драгоценные металлы, а если инициализировать параметры сети методом K-усреднений, то точность прогноза значительно возрастает, особенно для серебра (погрешность около 0,004). Данный факт связан с тем, что цены на серебро наиболее стабильны, график динамики цен имеет наименьшее среди представленных металлов количество пиков, резких скачков практически не наблюдается, а это значит, что потребуется меньше нейронов в скрытом слое. Отсюда следует сокращение времени обучения сети, упрощение расчетов, а также сеть наиболее точно «предугадает» будущие значения цен.

Планируется дальнейшее изучение прогнозирующих способностей сети Ванга-Менделя, направленных на уменьшение погрешности прогнозирования цен других металлов, с использованием других алгоритмов обучения и попыткой гибридизации данной сети путем добавления дополнительных слоев, например, содержащих нейроны типа WTA.

Литература

1. Искусственная нейронная сеть [Электронный ресурс]. – http://ru.wikipedia.org/wiki/Искусственная_нейронная_сеть (дата обращения 07.05.2014 г.).
2. Осовский, С. Нейронные сети для обработки информации [Текст]/ С. Осовский.: Пер. с пол. Рудинского И.Д. – М.: Финансы и статистика, 2002. – 344 с.: ил.