



О.П. Солдатова, Ю.М. Шепелев

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ЗАГРУЖЕННОСТИ СУПЕРКОМПЬЮТЕРА «СЕРГЕЙ КОРОЛЕВ»

(Самарский университет)

Цель данной научной работы состоит в построении прогнозирующей модели для оценки возможной загруженности суперкомпьютера «Сергей Королев» с помощью нейронной сети Такаги-Сугено-Канга. Подобная модель позволит предсказать объем доступных при выполнении задачи вычислительных ресурсов для их более эффективного использования [1].

Решение задач подобного рода осложнено отсутствием очевидных зависимостей в массиве входных данных. Возможный вариант решения подобной задачи – использование нечеткой нейронной сети Такаги-Сугено-Канга [2]. Она реализует модель нечеткого вывода, способную относить входные данные к нескольким классам с учетом их степени принадлежности этим классам. Это качество потенциально позволяет получить относительно корректные результаты. Схематическое изображение нейронной сети показано на рисунке 1 [2].

Первый слой выполняет отдельную фузификацию каждой переменной x_i , определяя для каждого k -го правила вывода значение коэффициента принадлежности $\mu_A^{(k)}(x_i)$ в соответствии с применяемой функцией фузификации. В данной работе используется обобщенная функция Гаусса вида

$$\mu_A^{(k)}(x_i) = \frac{1}{1 + \left(\frac{x_i - c_i^{(k)}}{\sigma_i^{(k)}} \right)^{2b_i^{(k)}}}$$

В процессе обучения адаптации подлежат параметры $c_i^{(k)}$, $\sigma_i^{(k)}$, $b_i^{(k)}$.

Второй слой агрегирует отдельные переменные x_i , определяя результирующий коэффициент принадлежности $w_k = \mu_A^{(k)}(\mathbf{x})$ для каждого входного вектора \mathbf{x} .

Третий слой задает генератор функции TSK, рассчитывающий значения полинома TSK вида

$$y_k(\mathbf{x}) = p_{k0} + \sum_{j=1}^N p_{kj} x_j.$$

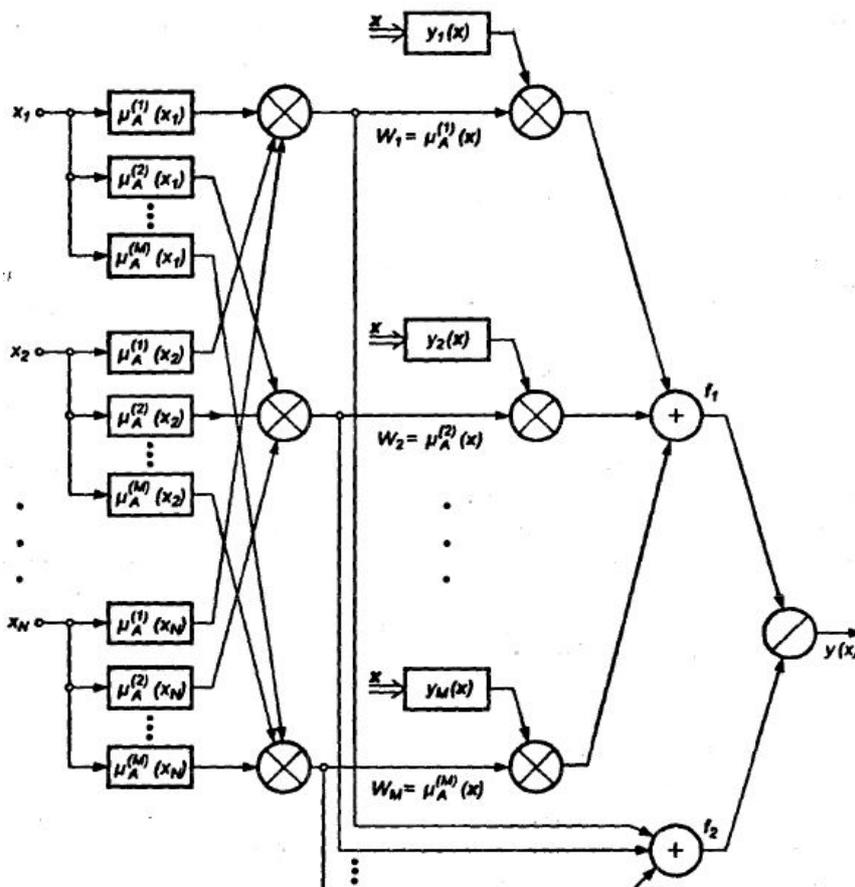


Рисунок 1 – Нейронная сеть Такаги-Сугено-Канга

Также этот слой умножает $y_k(x)$ на значения w_k , которые получены предыдущим слоем. Адаптации подлежат коэффициенты полинома p_{kj} .

В четвертом слое находятся два нейрона-сумматора, один из которых рассчитывает сумму сигналов $y_k(x)$:

$$f_1 = \sum_{k=1}^M y_k(x),$$

а другой определяет сумму весов w_k :

$$f_2 = \sum_{k=1}^M w_k.$$

В последнем слое, состоящем из одного нейрона, выходной сигнал определяется отношением выходов последнего слоя:

$$y(x) = \frac{f_1}{f_2}.$$

Заметим, что эта структура не является жесткой. Заранее неизвестно, сколько нечетких множеств (и их функций принадлежности) достаточно для успешной аппроксимации требуемой функции. Поэтому выбор количества нейронов может сильно влиять на результат.

В качестве входных данных были использованы открытые данные о выполнении задач на кластере «Сергей Королев» с 1 января по 7 апреля 2016 года. Данные представляют собой сведения о числе занятых узлов в группе кластера



и имеют большой диапазон изменения, так как в группе может быть задействовано до 70 узлов [1]. Поэтому используется преобразование входных данных к диапазону $[-1; 1]$, с которым нейронная сеть работает эффективнее [3].

Изначально модель обучалась с использованием алгоритма наискорейшего спуска, традиционно применяемым для обучения нейронных сетей. На рисунке 2 представлены результаты, полученные с помощью алгоритма наискорейшего спуска. Графики отражают зависимость числа занятых узлов в группе кластера от времени. Красный график показывает ожидаемые значения, желтый – прогнозные.

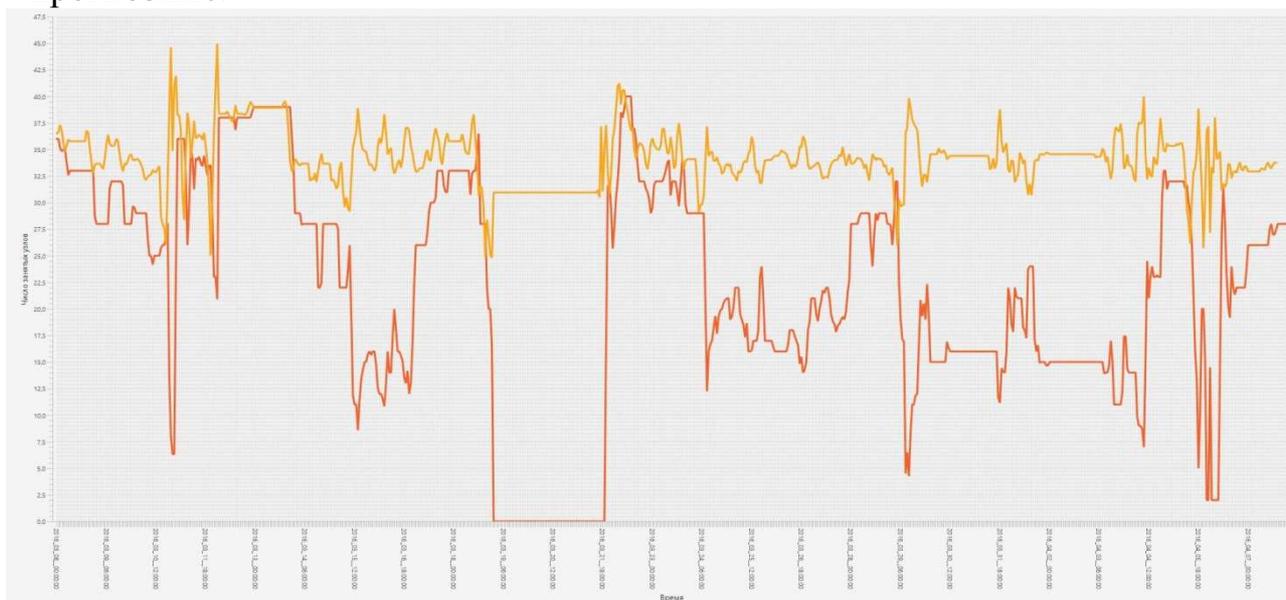


Рисунок 2 – Результаты прогнозирования с использованием алгоритма наискорейшего спуска (6 входов, 20 нечетких множеств)

Результат далек от удовлетворительного. В большинстве случаев сеть повторяет динамику изменения эталонных данных, однако полученные количественные показатели значительно отличаются от требуемых. Максимальная абсолютная ошибка составляет 50 узлов, что свидетельствует о некачественно обученной модели. Поэтому было принято решение об использовании метода роя частиц – стохастическом алгоритме, хорошо зарекомендовавшем себя при решении задач оптимизации большой размерности [4]. Как показано на рисунке 3, этот алгоритм позволяет достичь существенно лучших результатов.

Погрешность прогнозирования числа занятых узлов не превышает двух узлов, что является значительным улучшением.

Также в ходе работы было замечено, что качество прогноза зависит от числа нейронов в сети. Изменение числа параметров приводит к сильным изменениям на выходе сети, как показано в таблице 1.

Из представленных результатов не вполне очевидно, как именно влияют параметры на ошибку прогнозирования. Однако наименьшие значения погрешностей получены при значении числа входов, равному 6, и при значении числа нечётких множеств, равном 10 или 30. Ввиду того, что с увеличением числа нечётких множеств растёт вычислительная сложность алгоритмов обучения, следует признать наилучшим значение 10. Для того, чтобы установить характер



зависимости результатов прогнозирования от параметров сети, необходимо разработать методику подбора архитектуры сети, в частности, методику генерации базы нечётких правил вывода.



Рисунок 3 – Результаты прогнозирования с применением метода роя частиц (6 входов, 20 нечетких множеств)

Таблица 1. Зависимость погрешностей прогнозирования от параметров сети TSK

Число нечетких множеств	Число входов	СКО	Средняя абсолютная ошибка	Макс. ошибка
10	6	0.049	0.140	1.663
10	12	0.045	0.148	1.801
10	18	0.125	0.246	1.775
20	6	0.053	0.139	1.759
20	12	0.073	0.194	1.461
20	18	0.139	0.363	2.132
30	6	0.047	0.144	1.603
30	12	0.068	0.189	1.662
30	18	0.142	0.290	1.782

Литература

- 1 Артамонов, Ю.С. Применение модели EMMSP для прогнозирования доступных вычислительных ресурсов в кластерных системах // Известия Самарского научного центра РАН. – 2016. – том 18, № 4 (4). – С. 681-687.
- 2 Осовский, С. Нейронные сети для обработки информации [Текст] / С. Осовский. – М.: Финансы и статистика, 2002. – 344 с.: ил.
- 3 Ежов, А. Нейрокомпьютинг и его применения в экономике и бизнесе [Текст] / А.А. Ежов, С.А. Шумский. – М.: НОУ «ИНТУИТ», 2016. – 307 с.: ил.



4 Pedersen, M. Tuning & Simplifying Heuristical Optimisation [Текст] /М.Е.Н. Pedersen. – University of Southampton, 2010. – 204 с.

П.К. Шиверов, В.П. Цветов, С.С. Яковлев

ПОНЯТИЯ РЕПУТАЦИИ И ОПЫТА В КОНТЕКСТЕ ОЦЕНКИ РИСКОВ, СВЯЗАННЫХ С ДОВЕРИЕМ В ИНФОРМАЦИОННЫХ СИСТЕМАХ

(Самарский университет)

Введение

В процессе разработки модели количественной оценки доверия некоторые понятия выделяются в отдельные темы для изучения.

К таким понятиям относятся репутация, опыт, характеристика среды, стоимость информации и оценка рисков. В данной работе рассмотрены понятия репутации и опыта и их места в сложной структуре модели доверия.

Формальная оценка репутации объекта доверия

Одним из основных факторов, влияющих на уровень доверия, является репутация, роль которой сводится к накоплению знаний об оцениваемом объекте [1].

Репутация - это знание об агенте, сложившееся на основе его прошлых действий, о его намерениях и нормах, накопленное в некотором сообществе абонентов [2].

Особенную роль репутация играет в оценке доверия в электронной коммерции и социальных сетях, где позволяет пользователю выбирать более надёжных собеседников, поставщиков товаров или покупателей на основе отзывов других пользователей [3].

Иными словами, репутация - это коллективный опыт, связанный с поведением оцениваемого объекта.

Значение репутации каждого объекта глобально (оно одинаково для всех абонентов), в то время, как значение доверия персонально (каждый субъект формирует своё значение доверия по отношению к каждому объекту, исходя из репутации и личного опыта). Однако, именно репутация позволяет абоненту сделать выбор в пользу того или иного объекта, фактически, выполняя рекомендательную роль.

Также, к различиям в расчётах доверия и репутации следует отнести следующее.

Во-первых, доверие, как правило, является более "общим" понятием, которое выводится на основании многих субъективных и объективных знаний, в то время, как репутация рассчитывается исходя исключительно из объективных знаний об объекте (поведение при конкретных событиях, транзакциях).