

Из результатов кластерного анализа данных следует, что «Интегральный показатель проекта» [4] (рис. 2) следует рассматривать как главный показатель для выбора оптимального проекта (рис. 3).

Из профилей кластеров (рис. 4) видно, что помимо «Интегрального показателя проекта» важными показателями для управления портфелем инновационных проектов модернизации оборудования электроэнергетического предприятия являются также «Инвестиции» и «Энергоэффективность».

Из кросс-диаграммы и изображения куба OLAP (рис. 5) следует еще одно подтверждение о том, что показатель «Интегральный показатель проекта» выбран в качестве главного показателя.

В целом рис. 1–5 наглядно иллюстрируют технические возможности аналитической платформы Deductor, создавая базу для гибкого и достаточно простого мониторинга и управления инновационными проектами модернизации на энергопредприятии.

Заключение. Разработана концепция и описаны применяемые инструментальные средства для управления инновационными проектами модернизации на энергопредприятии. Предложенный подход позволяет максимально упростить принятие решений по выбору оптимального проекта, освобождает руководителей энергопредприятий от необходимости анализа данных и создания сложных моделей управления, даёт возможность сравнительно легко принимать решения на основе дружественного интерфейса.

Разработанная концепция системы поддержки принятия решений прошла апробацию на Хмельницком Облэнерго, Украина. Ожидается, что внедрение системы позволяет сократить время и повысить точность и эффективность принятия решений в ходе формирования портфеля проектов в соответствии со стратегией развития электроэнергетического предприятия.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Потенциал инновационного развития предприятия: монография / Под ред. д.э.н., проф. С.Н. Козьменко – Сумы: деловые перспективы, 2005. – 256 с.
2. Кендалл, Д.И. Современные методы: управления портфелями проектов и офис управления проектами [Текст] / Д.И. Кендалл, С.К. Роллинз. – Питер, 2004. – 570 с.

3. Sachenko, O. Criteria for Selecting the Investment Projects on DEMATEL and ANP Combination / Oleg Sachenko, Grygoriy Hladiy, Sergey Bushuyev, Zbyshek Dombrowsky // Proceedings of the 8th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS'2015). September 24–26. – 2015. – Warsaw: Poland. – P. 555–558.
4. Саченко, О.А. Управление портфелем инновационных проектов по модернизации оборудования: сборник научных трудов / О.А. Саченко // Управление проектами и развитие производства – 2013. – № 4(48). – С. 129–135.
5. Программная среда для разработки экспертных систем. – Режим доступа: CLIPS: <http://clipsrules.sourceforge.net>.
6. Семейство систем управления реляционными базами данных. – Режим доступа: DB2: <http://www-01.ibm.com/software/data/db2>.
7. Режим доступа: The AnyLogic Company: <http://www.anylogic.ru/>
8. Режим доступа: Oracle Corporation: <http://www.oracle.com/>
9. Аналитическая платформа. – Режим доступа: Deductor: <https://basegroup.ru/>
10. Fontela E. The DEMATEL Observer. DEMATEL 1976 Report / E. Fontela, A. Gabus. – Geneva: Battelle Institute, Geneva Research Center, Женева, Швейцария. – 1976.
11. Tamura, M. Extraction and systems analysis of factors that prevent safety and security by structural models / M. Tamura, H. Nagata, K. Akazawa // Proceedings of the IEEE 41st SICE Annual Conference, SICE. – 2002. – 5–7 Aug. – 2002. – Vol. 3. – P. 1752–1759.
12. Jerry, Ho W.-R. Combined DEMATEL technique with a novel MCDM model for exploring portfolio selection based on CAPM / Ho W.-R. Jerry, C.-L. Tsai, G.-H. Tzeng, S.-K. Fang // Expert Systems with Application – 2011. – № 38. – P. 16–25.
13. Saaty, T.L. Decision making with dependence and feedback: The analytic network process. – Pittsburgh, PA: RWS Publications, 1996.
14. Tzeng, G.H. Multiple Attribute Decision Making: methods and Applications / G.H. Tzeng, J.-J. Huang. – Boca Raton, FL: CRC Press, 2011. – 335 p.
15. Тянь, Р.Б. Проблемы управления энергопотреблением и энергосбережением на предприятиях: монография / Р.Б. Тянь, М.К. Сухонос // ХНАМГ. – Х.: Изд-во «Форт», 2010. – 296 с.

Материал поступил в редакцию 08.01.16

SACHENKO O.A. Tools for Managing a portfolio of Innovative Projects on Modernization in the Electric Utilities Company

There was developed a concept and describes the tools used for the management of innovative projects on the modernization of the electric utilities. The model selection criteria for evaluating the innovative projects for electric power enterprise through sound separation criteria for assessing energy efficiency into five major groups, and use a combination of two methods: DEMATEL - DEcision MAKING Trial and Evaluation Laboratory for mapping mutually influence and ANP -- Analytic Network Process to calculate the weight the criteria on the basis of mutual cards. This made it possible to construct a map of group interferences criteria and get top criteria for evaluating projects in the formation of the portfolio. A method of forming an effective portfolio of innovative modernization projects equipment of the electricity companies on the basis of a comparative evaluation of alternative projects portfolio by identifying standardized indicators in the reference design and integral criterion that allows you to build a base matrix for selecting the most effective projects. The proposed approach makes possible to simplify the decision-making on forest-you optimal design frees managers from power companies request data analysis and create complex management models, allowing comparative, but easy to make decisions based on user-friendly interface.

УДК 004.032.26

Марушко Е.Е.

ПРИМЕНЕНИЕ АНСАМБЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ТЕЛЕМЕТРИЧЕСКИХ ПАРАМЕТРОВ КОРРЕКТИРУЮЩЕЙ ДВИГАТЕЛЬНОЙ УСТАНОВКИ КОСМИЧЕСКОГО АППАРАТА

Введение. Благодаря возможности обучения, нейронные сети (НС) позволяют при анализе данных учесть не только случайный характер сигналов, но и особенности поведения конкретных подсистем космического аппарата (КА) в заданных условиях [1, 2]. Хотя при этом процедура обучения НС связана с проведением больших объемов вычислений. Также существуют проблемы переобучения, недообучения и локальных минимумов, что приводит к необходимо-

сти многократного проведения экспериментов. Для решения данных проблем могут использоваться ансамбли нейронных сетей (АНС) [3].

АНС – это набор НС, принимающий решение путем усреднения результатов работы отдельных моделей. Частные решения индивидуальных сетей попадают на обобщающий модуль, который и делает окончательное решение.

В прогнозном анализе и машинном обучении существует термин «дрейф целевой переменной», означающий, что статистические

свойства целевой переменной, которую модель пытается предсказать, меняются с течением времени непредсказуемым образом [4]. Это вызывает проблемы, так как далее предсказания становятся менее точными. Отсюда эффективность нейросетевой модели для детектирования нештатных ситуаций и прогнозирования параметров может быть повышена при помощи АНС, обучаемых с использованием алгоритмов итерационного обучения [5, 6].

Для преодоления проблемы дрейфа целевой переменной был разработан ряд методов, называемых Leap++ и основанных на итерационном обучении АНС [4, 6]. Методы подразумевают оценку точности всех моделей и ранжирование по качеству на каждой итерации анализа. При значительном понижении суммарной точности данная модель детектирует «дрейф целевой переменной» и производится добавление нового элемента, обученного на релевантных данных, в ансамбль. При таком подходе сохраняются старые данные, заложенные при начальном обучении, и вносятся новые без проблемы «забывания».

1. Подготовка данных. Выборка – конечный набор прецедентов, некоторым способом выбранных из множества всех возможных прецедентов, называемый генеральной совокупностью. При подготовке генеральной совокупности телеметрической информации датчиков КА выполняется ресемплирование, масштабирование и удаление константных временных рядов.

Ресемплирование выполняется для преобразования исходных данных, представляющих собой последовательность временных отметок важных событий, в форму с фиксированным временем дискретизации. Масштабирование необходимо, чтобы привести данные в допустимый диапазон [-1, 1]. Выходы сети также масштабируются. Производится удаление переменных, имеющих константные значения во всем наборе данных.

В таблице 1 представлены параметры наборов данных, на которых проводился анализ. Каждый из них представляет собой перечень телеметрической информации, формируемой датчиками корректирующей двигательной установки (КДУ) белорусского КА и характеризующей функционирование данной подсистемы: температурные параметры и уровни давления блока подачи ксенона, электрические параметры регулятора расхода, анода и катода двигателей.

Главной задачей при тестировании было прогнозирование многомерных временных рядов входных наборов. Для этого выполнялось преобразование входного набора в набор. Основным параметром при прогнозировании является временное окно W , т.е. то количество отсчетов в истории, по которому делается прогноз. Таким образом, если размер образца набора данных N , то НС должна принимать на вход образец размером $N \times W$. Так, для окна прогнозирования $W = 20$ набор Dt_set_s1 без констант преобразуется во входной набор размером 280×6594 и целевой набор размером 14×6594 .

Таблица 1. Данные ТМИ для тестирования алгоритмов

Название набора	Время дискретизации, с	Размер образца	Размер образца без констант	Количество образцов
Dt_set_s01	1	24	14	57501
Dt_set_s05	0.5	24	14	12245
Dt_set_s1	0.1	24	14	6613

В данном тестировании входной набор после удаления константных значений, ресемплирования, масштабирования и преобразования к окну прогнозирования нужного размера разделялся в соотношении 9:1 на общую обучающую выборку и итоговую тестовую выборку. Общая обучающая разделялась на валидационную (15%), тестовую (15%) и обучающую (70%) выборки случайным образом, которые использовались для обучения, оценки и поиска лучшей архитектуры НС. Итоговая тестовая выборка необходима для вычисления конечных параметров полученных НС.

2. Тестирование. Ошибка обучения для конкретной конфигурации сети определяется после прогона через сеть всех имеющихся наблюдений и сравнения выходных значений с целевыми значениями в случае обучения с учителем. Ошибка сети, выходной слой которой имеет n нейронов, $e_i = y_i - \hat{t}_i$ есть разность между реальным и желаемым сигналами на выходе i -го нейрона. Для оценки качества обученных НС и АНС, а также для сравнения различных архитектур АНС, используются следующие величины [1]:

- средний квадрат ошибки (mean square error (MSE)) (квадратный корень из MSE есть среднеквадратическое отклонение определяемой величины от ее математического ожидания), вычисляется по формуле:

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2, \quad (1)$$

средняя абсолютная ошибка (mean absolute error (MAE)), вычисляется по формуле:

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i|, \quad (2)$$

максимальная ошибка, вычисляется по формуле:

$$MAX = \max_i |e_i|. \quad (3)$$

2.1. Анализ алгоритмов формирования АНС. Был проведен сравнительный анализ различных способов формирования АНС.

- 1) выходное значение АНС формируется как сумма выходов отдельных НС:

$$y = \frac{1}{n} \sum_{i=1}^n y_i, \quad (4)$$

где n – число моделей, y_i – выход одиночной НС;

- 2) выходное значение АНС формируется как взвешенная на основе индивидуальной точности сумма выходов отдельных НС:

$$y = \sum_{i=1}^n y_i \cdot w_i, \quad (5)$$

где n – число моделей, y_i – выход одиночной НС, w_i – вес одиночной НС, который формируется по формуле:

$$w_i = \frac{mse_i}{\sum_{i=1}^n mse_i}, \quad (6)$$

mse_i – MSE-ошибка отдельной сети на валидационном наборе;


- 3) выходное значение АНС формируется как взвешенная на основе индивидуальной точности сумма выходов отдельных НС (формулы (5-6)), при этом взвешивание повторяется через определенный интервал обработанных наборов с оценкой по этому набору (динамически взвешиваемый АНС).

В таблице 2 приведены оценки различных архитектур на тестовом наборе Dt_set_s1.

Таблица 2. Оценка различных архитектур на тестовом наборе Dt_set_s1

Архитектура	MSE, 10^{-4}	MAX, 10^{-1}	MAE, 10^{-3}
Одиночная НС	3.51	4.12	0.115
АНС	3.66	3.83	0.114
Взвешенный АНС	2.76	4.11	9.65
Динамически взвешиваемый АНС с шагом 10	2.75	4.11	9.59

Из данных таблицы 2 видно, что лучшей точностью обладает динамически взвешиваемый АНС, при этом разница в оцениваемых параметрах между динамически и однократно взвешенными АНС очень мала.



1) возрастающий тренд; 2) сезонное отклонение; 3) модифицированный многомерный сигнал

Рис. 1. Модификация набора данных для оценки дообучения АНС

2.2. Оценка архитектур НС при наличии дрейфа целевой переменной. Понятие дрейф значений относится к изменению значения определения с течением времени и, следовательно, изменению в распределении данного значения. Среда, из которой эти значения получены, не является стационарной. Сдвиг в вероятности может указывать на то, что определения событий также могут изменяться.

Общим знаменателем в алгоритмах детектирования дрейфа выступает ансамбль экспертов, которые постепенно обучаются (без доступа к предыдущим данным) на входных данных, в сочетании с некоторой формой взвешенного голосования для получения финального решения [4, 6].

Для данного эксперимента в исследуемые данные искусственно вносились модификации. Был добавлен линейно возрастающий тренд, а в качестве сезонной составляющей моделировался синусоидальный сигнал.

На рис. 1 показана модификация набора данных Dt_set_s1 для оценки дообучения АНС. Первые 1319 отсчетов используются без модификации. Процедура оценки состоит из следующих шагов:

- 1) обучить АНС;
- 2) модифицировать набор данных для обработки добавлением тренда и (или) сезонной составляющей;
- 3) задать порог для алгоритма дообучения;
- 4) задать минимальный объем дообучающей выборки;
- 5) оценить точность лучшей НС из ансамбля, АНС, взвешенного АНС, динамически взвешенного АНС с фиксированным шагом, динамически взвешенного АНС с дообучением (дообучение производится только при накоплении указанного объема данных).

В таблице 3 приведены оценки различных архитектур на тестовом наборе Dt_set_s1 с трендом и сезонным отклонением. Все модели показали значительное падение точности на модифицированном наборе, включая и АНС с дообучением, что связано с интервалом накопления минимального объема дообучающей выборки.

Заключение. Использование АНС значительно повышает результирующую точность при одновременном уменьшении разброса ошибки, характерного для лучшей одиночной НС.

Лучшей точностью обладает динамически взвешиваемый АНС, при этом разница в оцениваемых параметрах между динамически взвешиваемым и однократно взвешенным АНС незначительна, и

появляются вычислительные затраты на реализацию повторного взвешивания.

Таблица 3. Оценка различных архитектур на тестовом наборе с трендом и сезонным отклонением

Архитектура	MSE	MAX	MAE
Одиночная НС	0.6035	7.5637	0.48428
АНС	0.030388	2.2604	0.12742
Взвешенный АНС	0.028874	2.7914	0.12115
Динамически взвешиваемый АНС с шагом 10	0.02661	2.3195	0.11703
Динамически взвешиваемый АНС с шагом 10 с дообучением	0.015286	2.0645	0.08767

Наименьшая среднеквадратическая ошибка при анализе телеметрической информации, формируемой датчиками корректирующей двигательной установки, достигается при использовании динамически взвешиваемого АНС с шагом взвешивания 10 и равна $2,75 \times 10^{-4}$.

Для модифицированных наборов данных с трендом и сезонным отклонением все модели показали значительное падение точности, АНС с дообучением также показал падение точности, что связано с интервалом накопления минимального объема дообучающей выборки, при этом результирующая ошибка меньше чем в других моделях НС.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Оссовский, С. Нейронные сети для обработки информации / С. Оссовский. – М.: Финансы и статистика, 2002. – 344 с.
2. Нейросетевая система мониторинга состояния и поведения подсистем космических аппаратов по телеметрическим данным для наземного командно-измерительного комплекса / А.А. Дудкин [и др.] // Актуальные проблемы создания космических систем дистанционного зондирования Земли: материалы II Международ. науч.-техн. конф. (Москва, 15 мая 2014 г.). – М.: ВНИИЭМ, 2014. – С. 194–204.
3. Jordan, M.I. Hierarchical Mixtures of Experts and the EM Algorithm / M.I. Jordan, R.A. Jacobs // Neural Computation. – 1993. – Vol. 6. – P. 181–214.
4. Elwell, R. Incremental Learning of Variable Rate Concept Drift / R. Elwell, R. Polikar // MCS. – Vol. 5519 of Lecture Notes in Computer Science. – 2009. – P. 142–151.

5. Marushko, Y. Using Ensembles of Neural Networks with Different Scales of Input Data for the Analysis of Telemetry Data / Y. Marushko // Proc. of the XV Intern. PhD Workshop OWD 2013 (Wisla, 19–22 Oct. 2013). – Gliwice: Silesian University of Technology, 2013. – P. 386–391.
6. Parikh, D. An ensemble-based incremental learning approach to data fusion / D. Parikh, R. Polikar // IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics. – 2007. – Vol. 37. – № 2. – P. 437–450.

Материал поступил в редакцию 25.11.15

MARUSHKO E.E. Using ensembles of neural networks for prediction of spacecraft corrective propulsion system telemetry parameters

Issues related to intellectual processing of complex poorly formalized tasks in the field of the analysis of telemetry data are considered. Methods of combining of neural networks into ensembles based on weighing for forecasting tasks are described in detail. Possibility of additional training of the neural network ensemble is analyzed.