

УДК 004.93-52:378.14

С.С. МИХНЕВ, Р.О. ПЕШКУРОВ

*Севастопольский национальный университет ядерной энергии и промышленности*

## ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ С ОБУЧЕНИЕМ ХЕББА ДЛЯ КЛАССИФИКАЦИИ ОБРАЗОВ ЗНАНИЙ ОБУЧАЮЩИХСЯ

*Приведен аналитический обзор методов, позволяющих уменьшить размерность данных при классификации образов знаний обучающихся. Приведены описания терминов «траектория обучения» и «образ знаний обучающегося». Отмечено, что не все методы предварительной классификации образа знаний обучающегося позволяют обеспечить адаптивность системы обучения. Предлагается для решения задачи предварительной классификации образов знаний обучающихся при условии обеспечения адаптивной работы системы использовать инструментарий нейронных сетей. В частности, использовать нейронные сети с обучением по методу Хебба.*

**Ключевые слова:** траектория обучения, адаптивное обучение, образ обучающегося, нейронные сети, нейронные сети с обучением Хебба, факторный анализ, метод главных компонентов.

### Введение

На сегодняшний день информационные технологии достаточно узко применяются в системах адаптивного обучения. В основном применение информационных технологий ограничивается системами адаптивного тестового контроля, где они позволяют в удобной форме производить тестирование и вести учет показателей успеваемости. На одном из этапов обучения в адаптивных системах возникает задача предварительной классификации образов знаний обучающихся.

В статье представлен анализ методов уменьшения размерности данных, подлежащих классификации, приведены основные преимущества использования нейронной сети с обучением по методу Хебба, для предварительной классификации образов знаний обучающихся для адаптивной системы обучения.

### 1. Основные определения и постановка задачи

Траектория обучения – совокупность мероприятий, которая позволяет добиться необходимого уровня знаний и навыков за отведенное на обучение время.

Образ знаний обучающегося – совокупность характеристик, значения которых различны для каждого индивидуума, проходящего обучение с учетом причинно-следственных связей между значениями этих характеристик на разных этапах обучения. Данные характеристики формируются на макро-

мезо- и микро-уровнях обучения (учебный курс, дисциплина, занятие).

Сформировав образ каждого обучающегося, преподаватель может сделать выводы о наиболее эффективной методике преподавания и выдачи учебного материала на каждом этапе обучения. Этапы обучения можно представить в виде многомерной «спиральной» диаграммы образа обучающегося. Термин «спиральная» для данной диаграммы связан с тем, что успеваемость по дисциплинам и другие характеристики образа обучающегося, подчиняются детерминированным причинно-следственным связям. Графическое представление «среза» диаграммы приведено на рис. 1. Возможный цикл обучения в системе адаптивного обучения представлен на рис. 2.

Рассмотрим более детально этап № 2 на диаграмме цикла обучения. На данном этапе производится предварительная классификация результатов анализа наиболее значимых характеристик обучающегося, которая подразумевает, что из множества измеренных характеристик конкретного обучающегося требуется выделить те значения, которые сильнее всего будут влиять на последующую классификацию объектов, при этом выполнив уменьшение размерности данных.

Уменьшение размерности данных – уменьшение количества характеристик, описывающих состояние объекта таким образом, чтобы потеря значимых характеристик, при дальнейшем использовании информации, сводилась к минимуму.

Выполнение данной операции позволяет уменьшить количество вычислений при последующей классификации, а также минимизировать коли-

чество передаваемой информации и свести влияние «шумов» к допустимым значениям.

## 2. Анализ методов предварительной классификации образов знаний обучающегося

На сегодняшний день основным методом для уменьшения размерности данных является факторный анализ [1, 2].

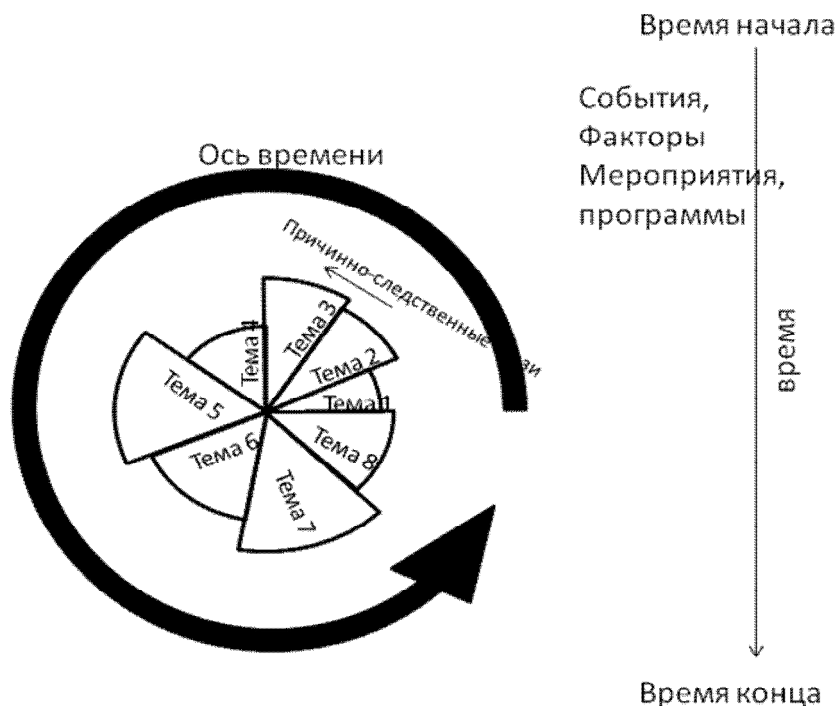


Рис. 1. Срез образа знаний обучающегося

Основные задачи ФА – установить зависимости между переменными и сокращение числа переменных.

Методы факторного анализа можно разделить, исходя из критериев «отброса факторов»:

**Критерий Кайзера.** Отброс факторов с собственными значениями меньше 1.

**Критерий «каменистой осыпи».** Определение точки на графике собственных значений, где их убывание слева направо минимально. Оба описанных фактора дают хорошие результаты при малом кол-ве факторов и большом кол-ве переменных.

**Критерий значимости.** Оценка вероятности определения «неподходящих» данных для их последующего отброса.

**Критерий доли воспроизводимой дисперсии.** Факторы ранжируются по доле детерминируемой дисперсии, когда процент дисперсии оказывается несущественным, выделение следует остановить.

Факторный анализ (ФА) – это подход, который широко используется в психологии, политологии, социологии, экономике и др.

Основная идея метода состоит в установлении скрытых факторов, влияющих на переменные, с помощью анализа матрицы корреляций исходных данных. После этого представляется возможным отбросить данные, изменения которых минимальным образом влияют на изменения свойств объектов.

**Критерий интерпретируемости и инвариантности.** Данный критерий сочетает статистическую точность с субъективными интересами. Согласно ему, главные факторы можно выделять до тех пор, пока будет возможна их ясная интерпретация.

### 2.1. Основные методы факторного анализа

Рассмотрим основные методы факторного анализа с целью определения их применимости для решения поставленной задачи:

Корреляционный анализ – метод обработки статистических данных, заключающийся в изучении коэффициентов корреляции между переменными [3, 4]. При этом сравниваются коэффициенты корреляции между одной парой или множеством пар признаков для установления между ними статистических взаимосвязей. Явным минусом данного подхода является тот факт, что его можно использовать только для определения линейных зависимостей

рассматриваемых данных, также сам по себе факт корреляционной зависимости не даёт основания утверждать, какая из переменных предшествует или является причиной изменений, или что переменные

вообще причинно связаны между собой, например, ввиду действия третьего фактора. Исходя из вышесказанного, данный подход в принципе не применим для сокращения числа переменных.



Рис. 2. Цикл обучения в адаптивной системе:

Метод максимального правдоподобия – метод оценивания неизвестного параметра путём максимизации функции правдоподобия. Основан на предположении о том, что вся информация о статистической выборке содержится в функции правдоподобия. Оценка максимального правдоподобия является популярным статистическим методом, который используется для создания статистической модели на основе данных, и выполнения оценки параметров модели. Данный метод не применим при предварительной классификации образа обучающегося, так как выполняет иную задачу: находит усредненные значения данных о совокупности, исходя из информации по случайной выборке, с помощью функции правдоподобия. Также на данный момент трудно подобрать функцию правдоподобия для статистической выборки данных об обучающемся.

Метод главных компонент (МГК) – подход к задаче уменьшения размерности данных, заключающийся в том, что оцениваются наиболее важные данные (изменения которых максимальны), после вычисления собственных чисел и собственных векторов ковариационной матрицы исходных данных. Включает большое количество методов, реализованных для разных случаев представления данных и через разные способы их обработки. МГК – есть

метод ФА использующий процедуру ортогонального вращения факторов. Данный подход может быть использован при генерации образа обучающегося, так как основная идея данного метода совпадает с идеей выделения образа, как совокупности главных характеристик объекта, с учетом возможных нелинейных зависимостей в значениях переменных. Кроме этого, существуют достаточно простые в реализации МГК.

## 2.2. Характеристика основных аналитических подходов для метода главных компонент

Аппроксимация данных линейными многообразиями – задача наилучшей аппроксимации конечного множества точек прямыми и плоскостями. Применима для решения однотипных задач оптимизации.

Поиск ортогональных проекций с наибольшим рассеянием. Основная цель метода – найти такое ортогональное преобразование в новую систему координат, для которого выполняется следующее условие: выборочная дисперсия данных вдоль значений  $k$ -ой координаты максимальна при условии ортогональности первым  $k-1$  координатам.

Аннулирование корреляций между координатами. Для заданной  $n$ -мерной случайной величины  $X$  найти такой ортонормированный базис,  $\{a_1, \dots, a_n\}$ ,

в котором коэффициент ковариации между различными координатами равен нулю. После преобразования к этому базису  $\text{cov}(X_i, X_j) = 0$  для  $i \neq j$ .

Вышеуказанные методы неприменимы для решения поставленной задачи ввиду необходимости наличия ограниченного малого количества элементов выборки на начальном этапе работы системы, их сложной реализации и отсутствии адаптивности в этих подходах к изменениям количества и составу входных данных.

### 2.3. Характеристика нейросетевых технологий, применимых для решения задачи предварительной классификации образов

В последнее время все чаще для решения задач классификации в условиях наличия неопределенности используют инструментальный нейронных сетей [5 – 8]. Рассмотрим виды нейронных сетей (НС) наиболее применимых для решения поставленной задачи.

Самоорганизующаяся карта Кохонена – современная нейронная сеть (НС) с обучением без учителя, выполняющая задачу визуализации и кластеризации. Является методом проецирования многомерного пространства в пространство с более низкой размерностью. Изначально известна размерность входных данных, по ней некоторым образом строится первоначальный вариант карты. В процессе обучения векторы веса узлов приближаются к входным данным. Для каждого наблюдения выбирается наиболее похожий по вектору веса узел, и значение его вектора веса приближается к наблюдению.

Нейронная сеть с «узким горлом» - нейронная сеть, которая используется при решении задачи сжатия. Топология сети и алгоритм ее обучения таковы, что данные большой размерности требуется передать с входа нейронной сети на ее выходы через канал сравнительно небольшого размера. В процессе работы такой НС алгоритм обратного распространения ошибки минимизирует ошибку. Веса связей от входного слоя нейронов и, до серединного слоя будут работать на компрессию сигнала, а остальные – на его декомпрессию. Сети, реализующие метод «узкого горла», более пригодны скорее для эффективного сжатия данных для последующей передачи, так как в основе архитектуры данной сети лежит многослойный персептрон, обучающийся по методу обратного распространения ошибки. Кроме этого сеть может некорректно работать в случае образования случайных зависимостей в исходных данных. Возможность уменьшения размерности данных является слабовыраженным побочным эффектом

Нейронная сеть Хопфилда – обладает свойством восстанавливать сигнал по его поврежденному образу. Также позволяет реализовать задачу автоассоциативной памяти, что делает возможным сжатие данных. Данный тип НС сильно зависит от обучающего периода чтобы в дальнейшем обладать способностью возвращать значения из автоассоциативной памяти, которая сформировалась при обучении, т.о. решение задачи обеспечения адаптивности затруднительно

Сети с методом обучения по Хеббу – нейронные сети с принципом обучения, выдвинутым нейрофизиологом Хеббом – «усиление наиболее часто взаимодействующих связей и ослабление менее взаимодействующих». В природе сети заложена реализация метода МГК в его классическом варианте: определение собственных значений матрицы ковариации. Это позволяет уменьшать количество выходных параметров сети без боязни потери большого числа информации при генерации образа.

Следует отметить, что карта Кохонена и сеть с обучением по методу Хебба обладают похожими свойствами: обучаются без учителя, достаточно близки по устройству обучения. Однако сети Кохонена более близки к реализации многомерного шкалирования – альтернативного по отношению к МГК метода, в среднем требующего заметно большего кол-ва вычислительных операций, что скажется и на времени работы сетей. Также стоит отметить, что сети Кохонена зависят от оценки аналитика (погрешность работы сети) и длительность процесса их обучения зависит от этого параметра.

Сети с обучением по Хеббу обучаются все время жизни, что делает их более адаптивными к изменениям в данных и являются достаточно простыми в реализации, по сравнению с перечисленными выше моделями, что также является их достоинством.

## Заключение

Сети с обучением по Хеббу обучаются все время жизни, что делает их более адаптивными к изменениям в данных и являются достаточно простыми в реализации, по сравнению с перечисленными выше моделями, что также является их плюсом.

## Литература

1. Енюков И.С. Факторный дискриминатный и кластерный анализ: сборник работ / И.С. Енюков. – М.: Финансы и статистика 1989. – 215 с.
2. Айвазян С.А. Прикладная статистика: Классификации и снижение размерности: справ. изд. /

С.А. Айвазян, В.М. Бухштабер, И.С. Енюков. – М.: Финансы и статистика, 1989. – 607 с.

3. Крамер Г. Математические методы статистики / Г. Крамер. – М.: Мир, 1975. – 648 с.

4. Huber P.J. *The Annals of Statistics* / P.J. Huber // *Harvard University*. – 1985. – 13, No. 2. – P. 435-475.

5. Хайкин С. *Нейронные сети. Полный курс* / С. Хайкин. – М.: Издательский дом «Вильямс», 2008. – 1104 с.

6. Kohonen T. *Self-Organizing Maps (Third extended edition)* / T. Kohonen. – New York, 2001. – 501 p.

7. Уоссермен Ф. *Нейрокомпьютерная техника: Теория и практика* / Ф. Уоссермен. – М.: Мир, 1992. – 240 с.

8. Hopfield J.J. *Neural networks and physical systems collective computational abilities* / J.J. Hopfield // *Proceedings of National Academy of Science*. – Vol. 79, no 8. – P. 2554-2558.

Поступила в редакцию 12.05.2010

**Рецензент:** д-р техн. наук, проф., зав. каф. информационных технологий В.П. Квасников, Национальный авиационный университет, Киев.

### ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ З НАВЧАННЯ ХЕББА ДЛЯ КЛАСИФІКАЦІЇ ОБРАЗІВ ЗНАЬ УЧНІВ

*С.С. Міхнев, Р.О. Пешкуров*

Наведено аналітичний огляд методів, що дозволяють зменшити розмірність даних при класифікації образів знань учнів. Наведено описи термінів «траєкторія навчання» і «образ знань учня». Відзначено, що не всі методи попередньої класифікації образу знань учня дозволяють забезпечити адаптивність системи навчання. Пропонується для вирішення задачі попередньої класифікації образів знань учнів за умови забезпечення адаптивної роботи системи використовувати інструментарій нейронних мереж. Зокрема, використовувати нейронні мережі з навчанням за методом Хебба.

**Ключові слова:** траєкторія навчання, адаптивне навчання, образ учня, нейронні мережі, нейронні мережі з навчанням Хебба, факторний аналіз, метод головних компонентів.

### APPLICATION OF NEURAL NETWORKS WITH HEBB'S LEARNING FOR CLASSIFICATION OF THE KNOWLEDGE OF STUDENTS

*S.S. Mikhnev, R.O. Peshkurov*

In this article analytical review of methods which allow reducing the data dimensionality in the classification of students' knowledge patterns is shown. The descriptions of the terms "teaching trajectory" and "pattern of student's knowledge" are given. It is noted that not all methods of pre-classification of students' knowledge pattern make the teaching adaptive. The use of neural networks tools is proposed to solve the problem of students' knowledge pre-classification if the adaptive system operation is possible. In particular it is possible to use the neural networks according to Hebb's teaching method.

**Key words:** trajectory learning, adaptive learning, properly trained, neural networks, neural networks with Hebbian learning, factor analysis, principal components method.

**Міхнев Сергей Сергеевич** – старший преподаватель кафедры компьютерного эколого-экономического мониторинга Национального университета ядерной энергии и промышленности, Севастополь, Украина, e-mail: mss-keem@yandex.ru.

**Пешкуров Роман Олегович** – студент 3 курса факультета информационных технологий Национального университета ядерной энергии и промышленности, Севастополь, Украина, e-mail: blazerer@mail.ru.