

да обучения, который базируется на минимизации суммарной квадратичной ошибки восстановления информации в скрытом и видимом слоях. Предложенный метод позволяет учитывать нелинейную природу нейронных элементов. Доказана теорема об эквивалентности максимизации функции правдоподобия распределения входных данных $P(x)$ в пространстве синаптических связей и минимизации суммарной квадратичной ошибки сети при использовании линейных нейронов, а также минимизации кросс-энтропийной функции ошибки сети в том же пространстве. Таким образом, подтверждается факт независимости природы обучения без учителя от выбора целевой функции. Рассматривается применение глубоких нейронных сетей для решения задач сжатия, визуализации и классификации образов на примере данных из базы MNIST.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Hinton, G. A fast learning algorithm for deep belief nets / G. Hinton, S. Osindero, Y. Teh // *Neural Computation*. – 2006. – Vol. 18. – P. 1527–1554.
2. Hinton, G. Reducing the dimensionality of data with neural networks / G. Hinton, R. Salakhutdinov // *Science*, 313 (5786). – 2006. – P. 504–507.
3. Hinton, G. A practical guide to training restricted Boltzmann machines // *Tech. Rep. 2010-000*. – Toronto: Machine Learning Group, University of Toronto, 2010.
4. Головкин, В.А. От многослойных перцептронов к нейронным сетям глубокого доверия: парадигмы обучения и применение / В.А. Головкин // *Лекции по Нейроинформатике*. – М.: НИЯУ МИФИ, 2015. – С. 47–84.
5. Krizhevsky, A. ImageNet classification with deep convolutional neural networks / A. Krizhevsky, L. Sutskever, G. Hinton // *In Proc. Advances in Neural Information Processing Systems*, 25. – 2012. – P. 1090–1098.
6. LeCun, Y. Deep learning / Y. LeCun, Y. Bengio, G. Hinton // *Nature*, 521 (7553). – 2015. – P. 436–444.
7. Mikolov, T. Strategies for training large scale neural network language models / T. Mikolov, A. Deoras, D. Povey, L. Burget, J. Cernocky // *In Automatic Speech Recognition and Understanding*. – 2011. – P. 195–201.
8. Hinton, G. Deep neural network for acoustic modeling in speech recognition / G. Hinton at all // *IEEE Signal Processing Magazine*, 29. – 2012. – P. 82–97.
9. Bengio, Y. Learning deep architectures for AI // *Foundations and Trends in Machine Learning*. – 2009. – Vol. 2(1). – P. 1–127.
10. Bengio, Y. Greedy layer-wise training of deep networks / Y. Bengio, P. Lamblin, D. Popovici, H. Larochelle // *In book Schölkopf, J. C. Platt, T. Hoffman (Eds.), Advances in neural information processing systems*, 11. – MA: MIT Press, Cambridge, 2007. – P. 153–160.
11. Erhan, D. Why does unsupervised pre-training help deep learning? / D. Erhan, Y. Bengio, A. Courville, P.-A. Manzagol, P. Vincent, S. Bengio // *Journal of Machine Learning Research*. – 2010. – Vol. 11. – P. 625–660.
12. Larochelle H. Exploring strategies for training deep neural networks / H. Larochelle, Y. Bengio, J. Louradour, P. Lamblin // *Journal of Machine Learning Research* 1. – 2009. – P. 1–40.
13. Glorot, X. Deep sparse rectifier networks / X. Glorot, A. Bordes, Y. Bengio // *In Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. JMLR W&CP Volume*. – 2011. – Vol. 15. – P. 315–323.
14. Golovko, V. A. Learning Technique for Deep Belief Neural Networks / V. Golovko, A. Kroshchanka, U. Rubanau, S. Jankowski // *in book Neural Networks and Artificial Intelligence*. – Springer, 2014. – Vol. 440. *Communication in Computer and Information Science*. – P. 136–146.
15. Golovko, V. A New Technique for Restricted Boltzmann Machine Learning / Aliaksandr Kroshchanka, Volodymyr Turchenko, Stanislaw Jankowski, Douglas Treadwell // *Proceedings of the 8th IEEE International Conference IDAACS-2015*. – Warsaw, 2015. – P.182–186.
16. Golovko, V. The Nature of Unsupervised Learning in Deep Neural Networks: A New Understanding and Novel Approach / Vladimir Golovko, Aliaksandr Kroshchanka, Douglas Treadwell // *Optical Memory And Neural Networks (Springer Link)*. – 2016. – Vol. 25, № 3. – P. 127–141.
17. Golovko, V. Deep Neural Networks: A theory, application and new trends / V. Golovko // *Proceedings of the 13-th International Conference on Pattern recognition and Information Processing*. – Minsk: publishing Center of BSU, 2016. – P. 33–37.
18. Jankowski, S. Deep learning classifier based on NPCA and orthogonal feature selection // Stanislaw Jankowski, Zbigniew Szymański, Uladzimir Dziomin, Vladimir Golovko, Aleksy Barcz // *Proceedings of the International Conference on Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments*. – 2016. – P. 5–9.

Материал поступил в редакцию 05.01.2017

GOLOVKO V.A., KROSHCHENKO A.A., KHATSKEVICH M.V. Theory of deep training: conventional and new approach

Over the last decade, the deep neural networks are a hot topic in machine learning. It is breakthrough technology in processing images, video, speech, text and audio. Deep neural network permits us to overcome some limitations of a shallow neural network due to its deep architecture. In this paper we investigate the nature of unsupervised learning in restricted Boltzmann machine. We have proved that maximization of the log-likelihood input data distribution of restricted Boltzmann machine is equivalent to minimizing the cross-entropy and to special case of minimizing the mean squared error. Thus the nature of unsupervised learning is invariant to different training criteria. As a result we propose a new technique called "REBA" for the unsupervised training of deep neural networks. In contrast to Hinton's conventional approach to the learning of restricted Boltzmann machine, which is based on linear nature of training rule, the proposed technique is founded on nonlinear training rule. We have shown that the classical equations for RBM learning are a special case of the proposed technique. As a result the proposed approach is more universal in contrast to the traditional energy-based model. We demonstrate the performance of the REBA technique using wellknown benchmark problem. The main contribution of this paper is a novel view and new understanding of an unsupervised learning in deep neural networks.

УДК 004.9:378

Лендюк Т.В.

ЗНАНИЕ-ОРИЕНТИРОВАННАЯ ИНФОРМАЦИОННАЯ ТЕХНОЛОГИЯ ДЛЯ ПОСТРОЕНИЯ СИСТЕМЫ АДАПТИРОВАННОГО ОБУЧЕНИЯ

Введение. В настоящее время существуют и развиваются различные методы представления и описания знаний, например: продук-

ционные модели, семантические сети, фреймы, таксономии, онтологии и так далее. В качестве наиболее перспективной модели пред-

Лендюк Тарас Васильевич, преподаватель кафедры информационно-вычислительных систем и управления Тернопольского национального экономического университета, Украина, ТНЕУ, 46020, г. Тернополь, площадь Победы, 3.

ставления знаний рассматриваются онтологии [1]. Мировой тенденцией в сфере образования является использование систем компьютеризованного обучения, в частности систем дистанционного обучения (СДО), которые используются для обучения, повышения квалификации, самоподготовки. Главными недостатками существующих систем СДО [2] является отсутствие адаптации учебного материала к потребностям студентов, а также то, что электронные учебные материалы, разработанные в различных СДО, часто несовместимы.

Перспективным направлением развития СДО является использование учебного материала, подготовленного в стандарте SCORM [3]. Такой учебный материал корректно отображается во всех СДО, и адаптивность обеспечивается благодаря использованию возможности видимости учебных фрагментов в зависимости от уровня знаний учащегося.

Поэтому, данная работа направлена на исследование возможности применения пакета SCORM для разработки моделей построения индивидуальной траектории обучения.

Обзор известных работ и постановка задачи. Целью адаптивного обучения является подготовка учебного материала с учетом индивидуальных особенностей студента. Для этого студент должен проходить краткий после изучения каждой темы для определения того, пройден ли порог оценки и достигнута ли желаемая оценка. После этого принимается решение о переходе к изучению следующей темы или о повторном изучении темы.

Главным недостатком классического тестирования [4] является фиксированное и большое количество тестовых вопросов. Этого недостатка лишена система компьютерного адаптивного тестирования [5, 6], в которой обеспечена возможность адаптации к особенностям студента. В таком тесте сначала, обычно, задается вопрос средней сложности. Если ответ правильный, то следующий вопрос задается большей сложности, а если нет, то меньшей сложности. При адаптивном тестировании, оценка уровня знаний проходит быстрее, и с допустимой точностью. Тестирование продолжается до тех пор, пока количество переходов уровня сложности не достигнет определенного числа, или завершится время тестирования, или если будет задано определенное количество вопросов.

Адаптивное тестирование – это совокупность процессов генерации, выдачи и оценки результатов выполнения адаптивных тестов, обеспечивающая высокую эффективность определения уровня знаний по сравнению с традиционным тестированием благодаря оптимизации подбора характеристик задач, их количества, последовательности и скорости выдачи в зависимости от особенностей подготовки тестируемых [7].

Поэтому необходимо создание учебного материала и тестовых вопросов для создания системы компьютеризованного обучения и самоподготовки. Но при этом возникают определенные трудности. В настоящее время существует много СДО [2], которые не могут обмениваться подготовленным учебным материалом, что связано с использованием различных стандартов. Однако рынок отреагировал на это формированием инициатив по стандартизации – консорциумов разработчиков систем и учебного материала. В результате были созданы отраслевые спецификации и стандарты, важнейшими из которых являются стандарты AICC и ADL SCORM [8], а также спецификации консорциума IMS [9]. Важнейшим результатом работы ADL стало создание концепции, спецификаций и руководства, объединенных названием SCORM (Shareable Content Object Reference Model) – промышленный стандарт для обмена учебными материалами на базе концептуальной модели стандарта IEEE 1484.12.1 [2].

Основной модели SCORM является построение учебников и учебных пособий. Модули учебного материала в SCORM называются разделяемыми объектами контента Shareable Content Objects (SCO). SCO – это автономная единица учебного материала, в которую входят метаданные и содержательная часть. SCO могут объединяться друг с другом в различных сочетаниях и формировать учебники и учебные пособия.

При формировании набора учебного материала целесообразно использовать нечеткий подход для оценивания знаний студентов и характеристик учебного материала. Удобно оперировать нечеткими

характеристиками, но конечным итогом является превращение нечеткой оценки в четкую [10, 11].

Адаптивное обучение на основе знание-ориентированных моделей в компьютерном обучении. Подготовка тестов для адаптивного тестирования и, собственно, самого учебного материала является достаточно трудоемким процессом. Для надежной работы системы автоматизированной подготовки учебного материала необходимо:

- сформировать полный набор учебного материала;
- определить уровень сложности всех учебных фрагментов;
- их последовательность и связи между ними, распределить материал на базовый и дополнительный;
- задать норматив изучения каждого учебного фрагмента; определять уровень знаний студентов, обучающихся дистанционно;
- выдавать им учебный материал, адаптированный в соответствии с их уровнем знаний.

В процессе изучения учебного материала студент получает оценки за промежуточные и финальные тесты по каждой теме, которые вносятся в модель студента или, иными словами, в его профиль в СДО. Таким образом, во время адаптивного обучения формируется и постоянно заполняется модель студента, то есть данные о нем, где указываются изученные темы, сданные тесты, сложность вопросов, фиксируются ответы и затраченное время на них, полученные оценки.

В начале обучения, когда модель студента еще не заполнена, нужно его зарегистрировать и внести первичные данные. Таким образом, сложность тестов в начале изучения темы зависит от предыдущих оценок студента, а в случае отсутствия записей – от оценки предварительного тестирования.

По данным модели студента формируется индивидуальная траектория обучения, содержащая учебные фрагменты заданного уровня сложности. Затем студент изучает подготовленный учебный материал, решает задачи, отвечает на контрольные вопросы, проходит учебные тесты. После завершения обучения ему выдаются тестовые вопросы.

СДО проверяет уровень знаний студента, и, в случае, когда он имеет низкую оценку и претендует на получение базового уровня знаний, направляет его на повторное изучение, добавляя к индивидуальной траектории обучения разъясняющий материал и новые задания.

Когда же студент после тестирования проходит минимальный порог, ему предлагается изучение материала на повышенном уровне сложности. Если он соглашается, то обучение продолжается, а к учебному материалу добавляются учебные фрагменты высшего уровня сложности. Если же студент не соглашается – он завершает изучение учебного материала [12] (рис. 1).

То есть обучающая система контролирует, чтобы студент получил соответствующий учебный материал и сдал тесты с гарантированной минимальной оценкой, а дальнейшее обучение для получения высшей оценки зависит уже от его желания.

Целью адаптивной системы является выявление пробелов в знаниях и формирование набора учебного материала для их заполнения. Уровень знаний студента необходимо определить хотя бы приблизительно и сформировать набор учебного материала соответственно уровню знаний студента. Когда (во время тестирования) выявляется недостаточный уровень знаний студента, он должен изучить дополнительный материал, повторить уже изученный, выполнить задачи и повторно пройти тестирование.

При адаптивном тестировании студенту выдается блок тестовых вопросов, состоящий из трех вопросов. При большинстве правильных ответов следующий блок содержит вопросы более высокого уровня сложности, при большинстве неправильных ответов – более низкого уровня сложности.

Еще одной важной особенностью для обеспечения возможности адаптивного обучения является наличие признака видимости учебного фрагмента в пакете SCORM. Видимость сложных учебных фрагментов зависит от их уровня знаний. Студенты, получившие низкие оценки, видят только часть учебного материала, и, чем выше уровень знаний студента, тем больше учебных фрагментов ему доступно для изучения. Весь объем учебных фрагментов доступен для студентов с высоким уровнем знаний.



Рисунок 1 – Схема адаптивного обучения

После проведения промежуточного тестирования адаптивная система определяет пробелы в знаниях студента. Когда полученная оценка ниже, чем было запланировано, студенту выдается учебный материал для разъяснения, который тоже расположен в данном пакете, но в начале изучения был невидимым.

Реализованная возможность построения индивидуальной траектории обучения обеспечивает улучшение уровня знаний, уменьшение времени тестирования и учит студента работать самостоятельно. Данный подход реализован в виде плагина для СДО Moodle, который обеспечивает невидимость отдельных учебных фрагментов в соответствии с уровнем знаний студента. В результате, для каждого студента формируется перечень учебных фрагментов, выводимых на монитор для изучения, которые, фактически, являются составными элементами индивидуальной траектории обучения студента.

Для того, чтобы адаптивное тестирование не было бесконечным, его продолжительность необходимо ограничивать. Сначала студенту выдается блок вопросов средней сложности, например, 80 баллов. Если студент отвечает правильно на три вопроса – сложность следующего блока повышается на 20 баллов, если на 2 – сложность следующего блока повышается на 10 баллов. Если сложность следующего блока 100 баллов, и студент правильно отвечает на два или три вопроса – тестирование прекращается. При двух неправильных ответах сложность следующего блока уменьшается на 10 баллов, а при трех – уменьшается на 20 баллов. Если сложность следующего блока составляет 40 баллов, и студент неправильно отвечает на два или три вопроса – то тестирование прекращается. Если у студента набирается три цикла «повышение-снижение» или «снижение-повышение» сложности, когда происходит изменение направления сложности, то тестирование прекращается [13].

Нечеткая модель изменения сложности тестовых вопросов.

Введение нечетких характеристик в оценке учебного материала может помочь в разработке задач и создании тестов. Например, преподаватель может достаточно быстро определить, является вопрос сложным или нет. Но сказать точно, насколько он сложен по 100-балльной шкале или оценить разницу сложности двух вопросов, будет затруднительно [14–16]. Можно допустить, что, с точки зрения студента, нечеткая оценка знаний является более понятной, чем оценка, полученная в результате тестирования.

В нечетких множествах для построения математических моделей формализуют лингвистическую информацию с помощью понятия лингвистической переменной, значениями которой являются слова

или выражения. Лингвистические значения называются термами, а набор всех возможных термов формирует терм-множество [16].

Функцией принадлежности в нашем случае будет функция $\mu^A(u) : U \rightarrow [0; 1]$, что разрешает для каждого элемента u универсального множества U рассчитать степень его принадлежности к нечеткому множеству \tilde{A} . Универсальное множество U содержит полное множество значений, охватывающее всю проблемную область.

Также нечеткими лингвистическими переменными описываются уровень знаний студента и время ответа на тестовый вопрос. Термами лингвистической переменной «Уровень знаний студента» могут быть: {Низкий, Средний, Высокий, Очень высокий}. Термами лингвистической переменной «Время ответа на тестовый вопрос» могут быть {Малое, Среднее, Длительное, Очень длительное}.

Тестирование начинается с блока вопросов среднего уровня сложности. После ответа система определяет уровень сложности следующего блока вопросов, учитывая процент правильных ответов, уровень сложности текущего блока и времени, затраченного на ответ на все вопросы блока. Сложность следующего блока вопросов зависит от большинства правильных ответов на блок вопросов, а также затраченного времени.

Контроль времени при ответах на вопросы вводится во избежание списывания. Когда студент длительное время не выбирает правильный ответ – это значит, что у него, вероятно, недостаточный уровень знаний или вопрос слишком сложный. Когда студент ответил правильно, но затратил много времени на ответ, то он, возможно, списывал.

Из вышесказанного можно сделать вывод, что для определения уровня сложности следующего блока вопросов нужно учитывать одновременно три показателя (долю правильных ответов, сложность текущего блока вопросов и время ответа на текущий блок вопросов), например:

- если процент правильных ответов $p_i = 0$, сложность поточного блока вопросов C_i – низкая, время ответа t_i – малое, то сложность следующего блока вопросов необходимо уменьшить;
- если процент правильных ответов $p_i = 0$, сложность поточного блока вопросов C_i – низкая, время ответа t_i – очень длительное, то сложность следующего блока вопросов необходимо значительно уменьшить;
- если процент правильных ответов $50 < p_i < 100$, сложность поточного блока вопросов C_i – низкая, время ответа t_i – малое, то сложность следующего блока вопросов необходимо увеличить;

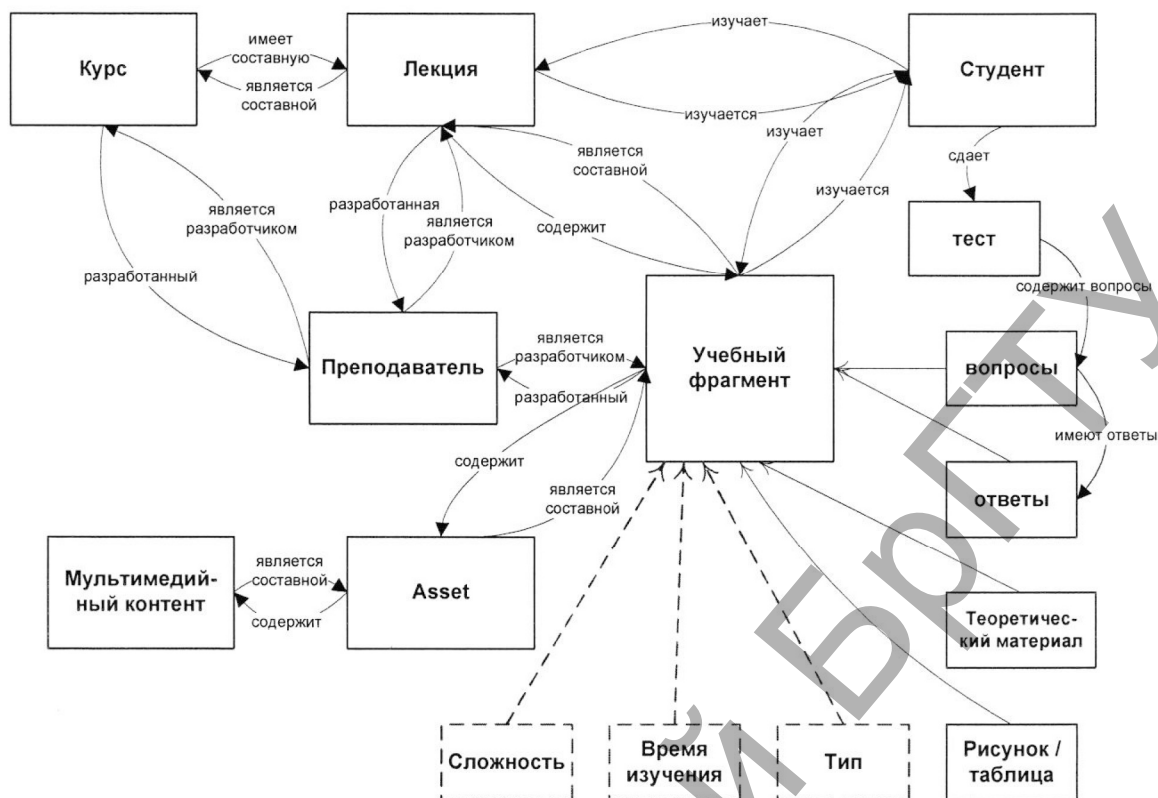


Рисунок 2 – Онтология учебного фрагмента

- если процент правильных ответов $p_i = 0 < p < 50$, сложность поточного блока вопросов C_i – средняя, время ответа t_i – среднее, то сложность следующего блока вопросов необходимо уменьшить;
- если процент правильных ответов $p_i = 100$, сложность поточного блока вопросов C_i – средняя, время ответа t_i – малое, то сложность следующего блока вопросов необходимо значительно увеличить.

Онтологическая структура учебного фрагмента. В основе Web-онтологии лежат свойства, классы, объекты и ограничения, которые реализуют представление об объектах в виде множества сущностей, характеризующихся определенным набором свойств. Эти сущности находятся в определенных отношениях и объединяются по определенным признакам в группы [17].

В рамках учебного процесса применение Web-онтологий позволяет специфицировать основные компоненты учебных дисциплин – лекции, практические, лабораторные работы, учебный материал. Онтология также обеспечивает возможность организации эффективного распределенного доступа к учебным ресурсам путем создания единой базы знаний, которая сочетает в себе разные учебные ресурсы и может быть распределенной в сети Интернет, что делает ее независимой от интерпретации конкретного учебного процесса.

В результате, роль учебной системы может быть сведена к роли интеллектуального агента, который проводит выборку учебного материала из базы знаний или отслеживает изменение базы знаний в зависимости от контекста обучения. Также есть возможность, проводить тестирование, генерируя контрольные задания в соответствии с семантикой описанных онтологий конкретных учебных курсов.

Онтология учебного фрагмента включает следующие классы: автор; тема; описание; издатель; дата; формат; идентификатор; источник; язык. Дополнительно предложено ввести два класса: тип и сложность. Тип учебного материала содержит данные о его типе (базовый теоретический материал, дополнительный материал, разъясняющий материал, задачи на решение). Очень важным классом для построения индивидуальной траектории обучения является

класс сложности, с помощью которого и производится формирование набора учебного материала.

Также важным критерием является время изучения учебного фрагмента. Когда сложность учебного фрагмента превышает уровень знаний, время изучения увеличивается, в обратном случае – уменьшается.

Разработанная онтология учебного фрагмента (рис. 2) включает следующие классы: сложность, тип и время изучения учебного фрагмента (блоки и стрелки изображены пунктиром).

Экспериментальные исследования. Для реализации нечеткой базы знаний был использован Fuzzy Logic Toolbox – пакет прикладных программ, входящий в состав среды MatLab. На основе данного пакета создана система нечеткого логического вывода и нечеткой классификации.

База нечетких знаний системы содержит три входа: «Правильные ответы», «Сложность блока» и «Время на ответ» и один выход – «Сложность следующего блока» (рис. 3).

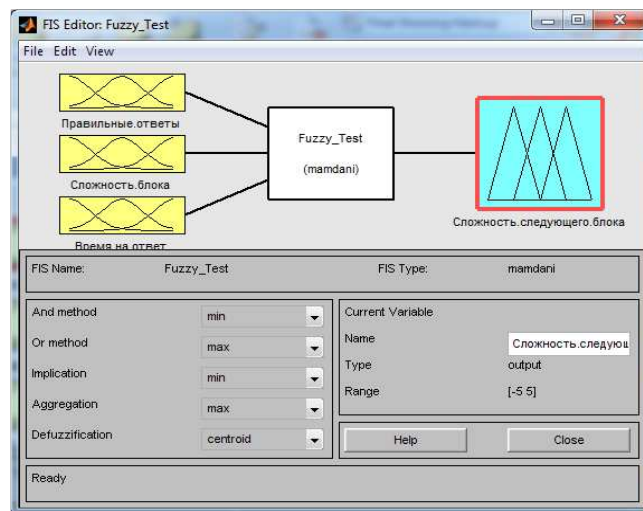


Рисунок 3 – Входы и выходы нечеткой системы тестирования

В процессе работы системы сформирован набор правил изменения сложности следующего блока (рис. 4). По окончании формирования правил зависимость выходной величины от значений входных параметров системы можно просмотреть с помощью инструмента «Rule Viewer» (рис. 5).




Рисунок 4 – Набор нечетких правил изменений сложности

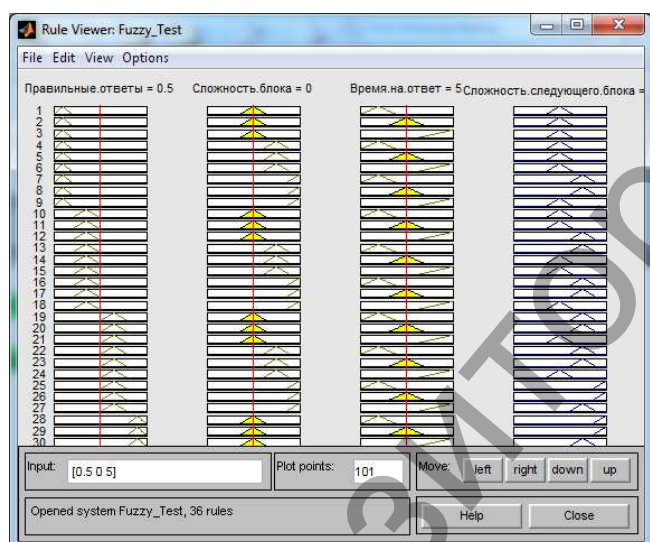


Рисунок 5 – «Rule Viewer»

Как видно из рисунков 4 и 5, сложность следующего блока тестовых вопросов больше всего зависит от сложности текущего блока и времени, затраченного на ответ.

Отметим, что в знание-ориентированных СДО предусмотрена обратная связь для адаптивной выдачи учебного материала. Кроме того, интеллектуальность работы системы обеспечивается нечетким подходом с использованием онтологий и семантических характеристик учебного материала.

Заключение. Решена актуальная научная задача создания индивидуальной траектории обучения студента в СДО Moodle с использованием пакета SCORM. Показано, что учебные фрагменты необходимо дополнять метаданными и оформлять с использованием стандарта SCORM для достижения независимости контента от программ управления с последующим использованием в СДО.

Рекомендовано использование технологий семантического Веба для хранения и выдачи учебного материала студенту на базе онтологии. Показано, что современное дистанционное обучение должно адаптироваться к индивидуальным особенностям студента при ор-

ганизации контроля знаний и построении индивидуальной траектории обучения.

Предложен механизм построения индивидуальной учебной траектории с использованием навигации в учебном материале с выбором учебных фрагментов. Разработана база нечетких знаний для согласования уровня сложности вопросов при адаптивном тестировании в системах дистанционного обучения.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Тузовский, А. Ф. Системы управления знаниями (методы и технологии) / А. Ф. Тузовский, С. В. Чириков, В. З. Ямпольский; под общ. ред. В. З. Ямпольского. – Томск: Изд-во НТЛ, 2005. – 260 с.
2. Глибовец, М. М. Роль стандартов в системах электронного обучения / М. М. Глибовец // Научные труды государственного гуманитарного университета им. П. Могилы. – Серия: Компьютерные технологии. – 2011. – Выпуск 148. – Том 160. – С. 122–129.
3. Соловов, А. В. Электронное обучение: проблематика, дидактика, технология / А. В. Соловов. – Самара: Новая техника, 2006. – 462 с.: ил. ISBN 978-5-88940-086-8.
4. Батешов, Е. А. Основы технологизации компьютерного тестирования: учебное пособие / Е. А. Батешов – Астана: ТОО «Полиграф-мир», 2011. – 241 с.
5. Гданский, Н. И. Адаптивные методы тестирования знания при компьютерных формах обучения: монография / Н. И. Гданский, Д. Ю. Альтиментова. – М.: Издательство РГСУ, 2015. – 220 с.
6. Сметанюк, Л. В. К теории и практике использования адаптивных тестов / Л. В. Сметанюк, Г. М. Кравцов // Информационные технологии в образовании. – 2009. – № 3. – С. 148–155.
7. Челышкова, М. Б. Теория и практика конструирования педагогических тестов: учебное пособие / М. Б. Челышкова. – М: Логос, 2002. – 432 с.
8. Advanced Distributed learning <https://www.adnet.gov/>
9. IMS Global Learning Consortium www.imsglobal.org/content/packaging/
10. Voskoglou, M. Gr. Fuzzy Methods for Student Assessment / M. Gr. Voskoglou, I. Ya. Subbotin // International Journal of Education and Information Technology. – 2015. – Vol. 1. – No. 1. – P. 20–28.
11. Shilpa, N. Ingoley and J w Bakal. Article: Evaluating Students' Performance using Fuzzy Logic. IJCA Proceedings on International Conference on Recent Trends in Information Technology and Computer Science. – 2012 ICRTITCS(9):15-20 February, 2013.
12. Lendyuk, T. Individual Learning Path Building on Knowledge-based Approach / T. Lendyuk, A. Melnyk, S. Rippa, I. Golyash, S. Shandruck // Proceedings of the 8th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS'2015). – Warsaw, Poland, 24-26 September 2015. – Vol. 2. – P. 949–954.
13. Lendyuk, T. Simulation of Computer Adaptive Learning and Improved Algorithm of Pyramidal Testing / T. Lendyuk, S. Rippa, S. Sachenko // Proceedings of the 7th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, 12-14 September 2013. – Berlin, Germany. – P. 764–769.
14. Aajli, A. A new approach of learning hierarchy construction based on fuzzy logic / A. Aajli, K. Afdel // International Journal of Engineering Research and Applications. – 2014. – Vol. 4. – Issue 10. – Part 3. – P. 58–66.
15. Федорук, П. И. Модель адаптивного тестирования с нечеткой логикой / П. И. Федорук, С. М. Масловский // Математические машины и системы. – 2009. – № 1. – С. 131–137.
16. Szentes, D. Enhanced test evaluation for web based adaptive learning paths / D. Szentes, B.-A. Bargel, A. Streicher, W. Roller // in Proceedings of the 7th International Conference on Next Generation Web Services Practices, NWeSP. – Salamanca, Spain, 19-21 October 2011. – P. 352–356.
17. Михайлюк, А. Формирование лингвистической онтологии на базе структурированного электронного энциклопедического ресурса / А. Михайлюк, О. Михайлюк, О. Пилипчук, В. Тарасенко // Международный журнал «Комп'ютинг». – 2012. – Том 11. – Выпуск 3. – С. 191–202.

Материал поступил в редакцию 03.01.2017

