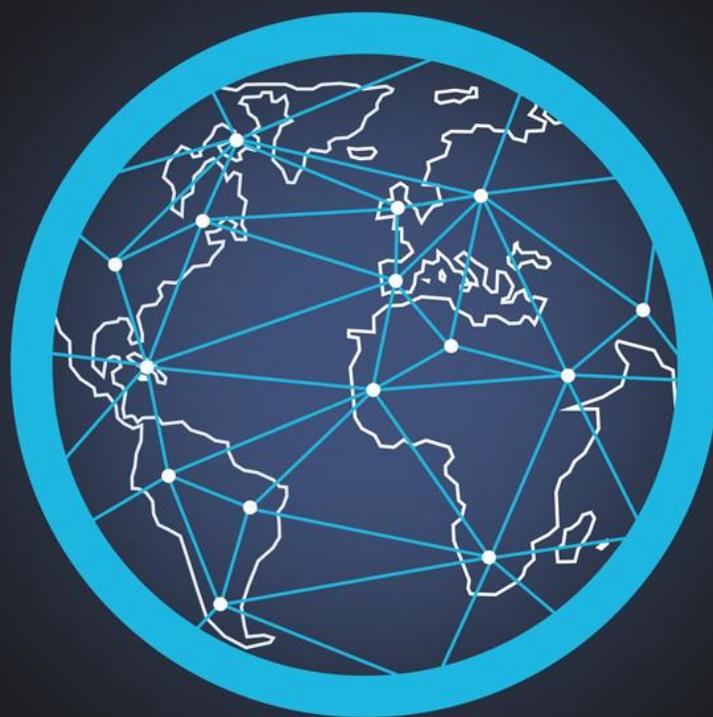


Международный журнал
информационных технологий
и энергоэффективности |



Том 6 Номер 2 (20)



2021



СОДЕРЖАНИЕ / CONTENT

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

-
1. **Быков В.Э.** Метод управления светом в умном доме на основе искусственных нейронных сетей. **3**

Bykov V.Y. Method of light control in a smart house based on artificial neural networks.

-
2. **Якушев В.А.** Сравнение подходов с использованием медианы Кемени и без неё в нечеткой байесовской сети для снижения риска. **13**

Yakushev V.A. Comparison of approaches using the median of Kemeni and without it in a fuzzy bayesian network to reduce risk.

-
3. **Жарков А.П.** Система распределения нагрузки аппаратно-вычислительных ресурсов развертываемых crm систем на базе нейронных сетей глубокого обучения. **19**

Zharckov A.P. The load distribution system of the hardware and computing resources of deployed crm systems based on neural deep learning.

-
4. **Балашов О.В., Букачев Д.С.** Методический аппарат разработки математических моделей для систем поддержки принятия решений. **25**

Balashov O.V., Bukachev D.S. Methodological apparatus for developing mathematical models for decision support systems.



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004.89

МЕТОД УПРАВЛЕНИЯ СВЕТОМ В УМНОМ ДОМЕ НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Быков В. Э.

Филиал ФГБОУ ВО «Национальный исследовательский университет «МЭИ» в г. Смоленске, Россия, (214013, г. Смоленск, Энергетический проезд, 1), e-mail: gypnopinkie@yandex.ru.

В данной работе рассмотрен метод применения искусственной нейронной сети для управления переключателями света в умном доме. Описано влияние контекста на формирование поведенческих шаблонов пользователя, разработана топология ИНС с использованием GRU, описаны этапы разработки метода: выбор набора данных для обучения, выбор признаков, способ преобразования и нормализации данных подающихся на вход ИНС на этапе обучения. Произведена оценка разработанного метода на наборе данных CASAS HH102, а также сравнение с другими похожими методами управления приборами умного дома с использованием ИНС.

Ключевые слова: умный дом (УД), искусственные нейронные сети (ИНС), управление переключателями света, рекуррентные нейронные сети, GRU.

METHOD OF LIGHT CONTROL IN A SMART HOUSE BASED ON ARTIFICIAL NEURAL NETWORKS

Bykov V. Y.

Smolensk Branch of the National Research University "Moscow Power Engineering Institute", Smolensk, Russia (214013, Smolensk, Energetichesky proezd, 1), e-mail: gypnopinkie@yandex.ru

In this paper, we consider a method for using an artificial neural network to control light switches in a smart home. The influence of the context on the formation of user behavioral patterns is described, the ANN topology with the use of GRU is developed, the stages of method development are described: the choice of a data set for training, the choice of features, the method of preprocessing and normalizing the data submitted to the ANN input at the training stage. The developed method was evaluated on the CASAS HH102 data set, as well as compared with other similar methods of controlling smart home devices using ANN.

Keywords: smart home (SH), artificial neural networks (ANN), light switch control, recurrent neural networks, GRU.

Введение

Сегодня, умный дом становится все более и более распространенным способом автоматизации рутинных задач жителя. Однако необходимость вмешательства пользователя в настройку сценариев управления теми или иными исполнительными устройствами отталкивает некоторых людей от их использования. Таким образом встает задача разработки

такого метода управления умным домом, который бы мог адаптироваться под поведение пользователя и с достаточной точностью автоматически управлять приборами домашней автоматизации.

Отличительная способность такого метода – выявлять паттерны или поведенческие шаблоны жителя умного дома. На формирование шаблонов поведения влияет контекст, а значит он играет ключевую роль при принятии решения по управлению устройствами умного дома [1]. Контекст – любая информация, используемая для характеристики (описания) некоторой ситуации, произошедшей с некоторой сущностью. Сущностью может быть объект, место или человек [2, с. 8]. В случае задачи управления УД такой сущностью является сам УД или конкретное исполнительное устройство, а его контекстом может быть время, день недели, показания датчиков, информация о нахождении человека в комнате и т. д, рисунок 1.

Исходя из этого конечная формулировка задачи умного дома стоит следующим образом: необходимо разработать метод способный на основе собранной информации о контексте (дата, время, данные с датчиков) обучаться и приспосабливаться к поведению пользователя и на основе этого принимать решения об управлении средствами домашней автоматизации в целях обеспечения комфорта пользователя [3, 4].

Благодаря способности обобщения ИНС является очевидным выбором на место такого метода способного выявлять среди некоторого набора данных закономерности и на основе этого принимать решение об управлении без вовлечения пользователя в непосредственную настройку автоматизации приборов.

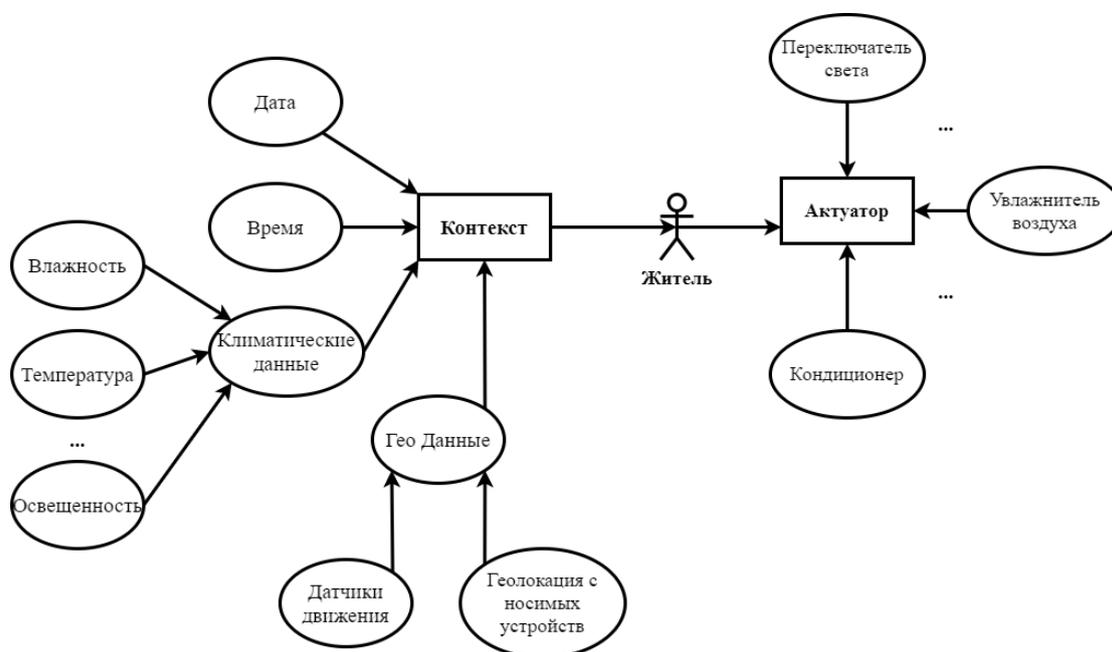


Рисунок 1 – Роль контекста в формировании шаблона поведения пользователя при использовании исполнительных устройств (актуаторов)

1. Метод использования искусственные нейронных сетей для управления элементами умного дома.

1.1. Общие сведения

Исходя из важной роли контекста в формировании решения об управлении исполняющим устройством умного дома, а также из уникальности того же контекста для каждого устройства, для каждой комнаты и специфичности поведения каждого отдельно взятого человека, было решено обучать ИНС для каждого целевого устройства. Также стоит уточнить, что в данной работе не рассматривается никакое взаимодействие между различными ИНС. Итого мы можем более конкретизировать то, что мы разрабатываем, а именно: способ управления умным домом на основе нескольких несвязных ИНС, формирующих управляющие воздействия на исполнительные устройства.

Теперь стоит уточнить топологию нашей сети. Как видно на рисунке 2, топология сети довольно простая, она состоит из нескольких последовательно соединенных между собой рекуррентных слоев, а именно GRU. Использование рекуррентной сети обусловлено необходимостью учитывать недавнюю историю контекста, что в свою очередь позволяет увеличить точность принимаемых решений. Выходной слой содержит линейную функцию активации, так как на выходе нам будет необходимо получить число из симметричного интервала $[-\tau \dots \tau]$. О данном интервале будет рассказано чуть позднее. Значение из данного интервала впоследствии мы интерпретируем в некий управляющий сигнал «ВКЛ\ВЫКЛ», так у переключателя света может находиться только именно в этих двух состояниях.

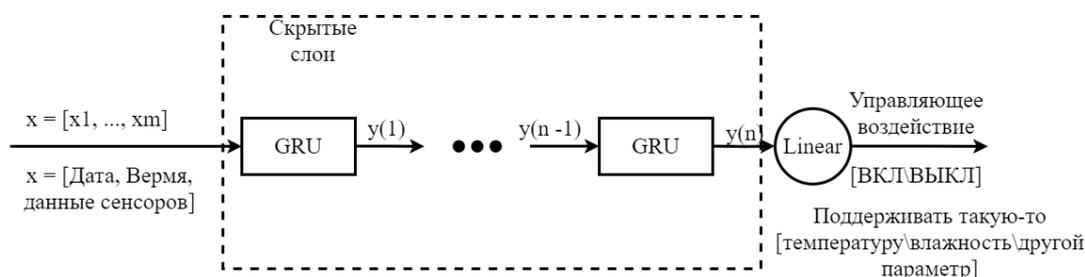


Рисунок 2 – Топология разрабатываемой ИНС, ориентированной на управление умным домом

1.2. Этапы разработки метода управления переключателями света на основе искусственной нейронной сети.

Предлагаемый в данной работе способ можно разработать, соблюдая следующие этапы:

1. Получение данных для обучения и выбор признаков.
2. Подготовка и нормализация данных.
3. Выбор параметров ИНС.
4. Обучение и оценка работы ИНС.

Этап 1. Получение данных для обучения и выбор признаков

На этапе эксплуатации разрабатываемого метода предполагается что ИНС будет использовать данные, полученные с датчиков умного дома. Но так как самому собрать необходимый объем данных весьма долго и затратно, то мы будем использовать готовый

набор данных. Так как в рамках данной статьи оценка работы нашего метода будет происходить на конкретном наборе данных, то стоит сразу о нем упомянуть.

Большинство найденных в сети наборов данных из умного дома направлены на распознавания деятельности пользователя, из-за чего лишь малое их количество содержит информацию об использовании объекта исследования (переключатели света). Однако наборы данных CASAS всё же предоставляют нам необходимую информацию. Мы будем использовать набор данных CASAS HH102, основанный на данных, полученных из умного дома с планировкой, изображенной на рисунке 3.

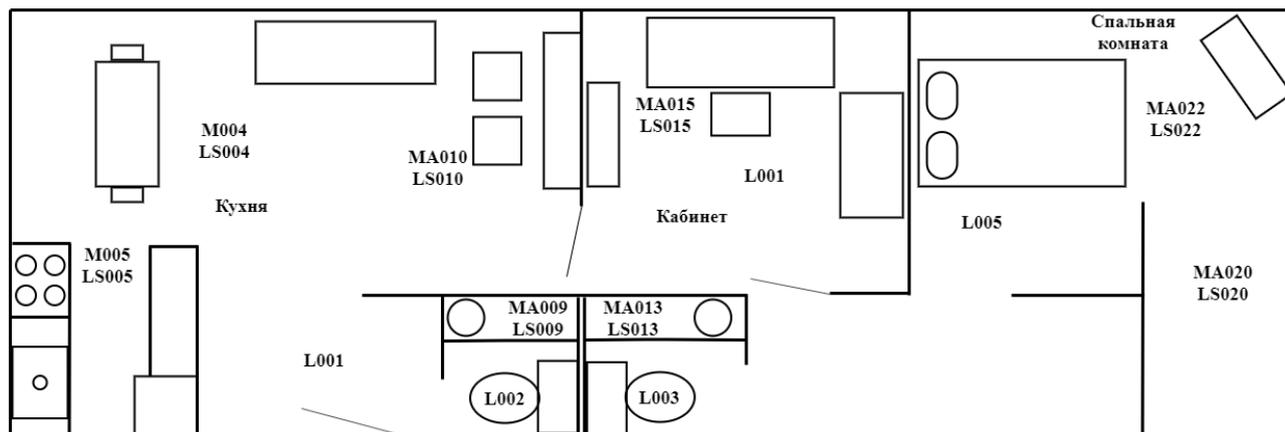


Рисунок 3 – Планировка УД представленного в наборе данных hh102

Датасет содержит информацию о данных разных типов датчиков, но в случае выбранного целевого устройства нам необходимы лишь данные из следующих сенсоров:

- датчики освещения (LS);
- датчики движения (M/MA);
- состояния переключателей света (L).

Помимо данных, полученных от сенсоров, в качестве входных признаков используются также время (в минутах) и день недели.

Объясним выбор входных признаков. День недели и текущее время в минутах напрямую влияют на принятие решения о включении или выключении света так как пользователь УД может регулярно не появляться дома, например, по причине работы в будние дни с утра до вечера, и очевидно, что в это время недопустимо использование света ради экономии средств. Данные датчика освещенности нужны, потому что пользователь может не включить свет в доме так как в комнате может быть достаточно дневного света. Данные датчика движения необходимы, потому что для экономии электроэнергии включение света производится в случае, если есть человек в комнате.

Этап 2. Подготовка и нормализация данных

Для того чтобы понять как пред обработать данные посмотрим на них в «сыром» виде, рисунок 4. Как видно из рисунка, информация о включении и выключении предоставлена по мере использования прибора. Примерно в таком виде будут храниться данные и при использовании системы автоматизации умного дома для того, чтобы не занимать дисковое пространство. Так как нам необходимо вовремя включить прибор нам нужно либо обучать сеть предсказывать время включения или использовать ИНС по таймеру с некоторой

периодичностью. Второй вариант является предпочтительным, так как ошибка при выдаче сетью и времени, и управляющего воздействия значительно выше, будет значительно выше, чем у метода, предсказывающего только лишь состояние прибора.

2011-06-15	06:57:40.025954	BATV010	9560
2011-06-15	06:57:40.05425	MA010	OFF
2011-06-15	06:57:40.143462	MA013	ON
2011-06-15	06:57:42.005975	L007	ON
2011-06-15	06:57:42.115917	LS013	28
2011-06-15	06:57:46.408918	LS013	29
2011-06-15	06:57:46.469403	MA013	OFF
2011-06-15	06:57:47.372764	LS013	30
2011-06-15	06:57:47.408146	MA013	ON
2011-06-15	06:57:51.496204	MA013	OFF
2011-06-15	06:57:52.259965	MA013	ON
2011-06-15	06:57:58.975659	LS013	29
2011-06-15	06:57:58.998033	MA013	OFF
2011-06-15	06:58:05.586509	MA013	ON
2011-06-15	06:58:08.405298	MA013	OFF
2011-06-15	06:58:41.972865	MA013	ON
2011-06-15	06:58:43.070007	MA013	OFF
2011-06-15	06:58:44.007966	MA013	ON
2011-06-15	06:58:45.150597	MA013	OFF

Рисунок 4 – Часть данных из датасета CASAS

Исходя из вышесказанного делаем вывод, что необходимо применить ресемплинг данных, то есть привести частоту данных с датчиков к некоторой постоянной частоте, например раз в минуту. Ресемплинг производится по каждому датчику с заполнением недостающих данных путём копирования значения последнего срабатывания датчика в течение последнего минутного интервала. Однако для данных из датчика движения заполнение происходит несколько иначе: берутся данные за минутный промежуток, сохраняется последнее состояние датчика, а во временную ячейку текущей минуты записывается «ON», если есть хотя бы одно срабатывание датчика, иначе «OFF»; ежели за минуту ничего не произошло то записывается последнее сохраненное значение. Отдельный подход в подготовке данных для датчика движения делается исходя из физических ограничений в виде радиуса срабатывания, так как человек может отойти на шаг от датчика и быть при этом в комнате.

Теперь преобразуем значения целевого выходного значения. Сначала преобразуем значение состояния прибора в пару значений {состояние прибора (s); время последнего изменения состояния (t)}. Значение t увеличивается на 1 временную единицу (в данной работе отсчёт между двумя наблюдениями после ресемплинга равен 1 минуте) до тех пор, пока состояние прибора не изменится, и после этого снова обращается в 0 и заново инкрементируется до следующего переключения. Затем пара значение преобразуется в одно по формуле.

$$f(s, t) = \begin{cases} (\tau - t) * (2s - 1), & \text{при } (\tau - t) \geq 0 \\ 0, & \text{при } (\tau - t) < 0 \end{cases} \quad (1),$$

где τ – целое число, означающее в каком промежутке времени мы рассматриваем изменение состояния прибора. В результате данного преобразования мы получаем целое число, варьирующееся в диапазоне $[-\tau \dots \tau]$, где отрицательное значение τ означает что прибор только выключили, а положительное что только включили. Такой способ преобразования позволяет достичь высокой точности предсказания из-за того, что оставление прибора включенным или выключенным на достаточно большом промежутке времени не будет оказывать влияния на детектирование сетью паттернов использования исполнительного прибора [5].

Затем преобразуем наши данные в виде двумерной матрицы формата (количество данных, признаки), в трёхмерную матрицу вида (количество данных, последовательность данных, признаки). Это необходимо из-за использования нами рекуррентной сети GRU, так как она оперирует последовательностями данных.

Завершим этап нормализацией данных. Мы будем использовать минмаксную нормализацию данных, формула 2 [6]. То есть значение каждого признака теперь будет варьироваться в диапазоне $[-1 \dots 1]$.

$$X_{norm} = a + \frac{X - X_{min}}{X_{max} - X_{min}} (b - a) \quad (2),$$

где $a, b \in [a, b]$, в нашем случае $a = -1, b = 1$.

Этап 3. Выбор параметров ИНС

Исходя из выбранной топологии нашей сети нам необходимо эмпирическим путём выбрать несколько параметров:

- Длина последовательности (70).
- Количество эпох обучения (100).
- Количество скрытых слоев и нейронов в них (2, формула 3).
- Выбор функции активации выходного слоя сети (линейная).

В скобках написаны оптимальные значения уже подобранных параметров. Для того чтобы не загромождать данную статью множеством сравнительных таблиц, по которым мы отобрали оптимальные параметры, мы просто объясним их смысловое значение.

Длина последовательности данных. Как было упомянуто ранее рекуррентная нейронная сеть работает с последовательностями данных, поэтому на вход подаются данные вида $x = [x(t - n), x(t - n + 1), \dots x(t)]$. Необходимо подобрать такое n , чтобы вычислительные затраты на обучение и использование сети не были высоки, но при этом сеть могла найти паттерны между входными признаками и откликом.

Количество эпох – это число показывающее количество проходов целого набора данных через сеть. Чем больше значение данного параметра, тем точнее сеть скорректирует весовые коэффициенты, а значит на выходе сети результат будет точнее. Однако слишком большое число эпох не стоит брать из-за проблемы переобучения, а также дополнительных вычислительных затрат.

Количество скрытых слоев и нейронов в них. Это очередной параметр, который мы пытаемся найти подобрать таким образом, чтобы сеть достигала достаточной точности и при этом не сталкивалась с проблемой переобучения и больших вычислительных затрат. Количество нейронов в скрытом слое, однако можно подобрать в районе некоторого числа N , полученного по формуле 3 [7].

$$N = \frac{2}{3}(N_o + N_i) \quad (3)$$

где N_o и N_i количество нейронов в выходном и входном слоях соответственно.

Линейная функция активация была выбрана из-за того [8, с. 144], что мы на выходе ожидаем увидеть число, варьирующееся в диапазоне $[-\tau \dots \tau]$.

Так как использование ИНС в задаче управления приборами УД может привести к нежелательным ложным срабатываниям нам необходимо придумать способ их уменьшения. В нашем методе на выходе ИНС мы получаем число в интервале $[-\tau \dots \tau]$, а в нормализованном виде $[-1 \dots 1]$. В некотором смысле чем ближе полученное число к какому-либо концу интервала, тем с большей уверенностью мы можем заявлять о том, что именно в данный момент времени произошло включение прибора. Поэтому можно подобрать такой интервал $[-1 \dots mt] \cup [pt \dots 1]$, значения внутри которого мы можем с большой долей уверенности интерпретировать как выключение\включение прибора. В ходе экспериментов было выявлено, что в нашем случае (ИНС обученная на наборе данных hh102) оптимальный интервал $[-1 \dots -0,5) \cup (0,8 \dots 1]$.

Этап 4. Обучение и оценка работы ИНС.

На рисунке 5 мы можем увидеть уменьшение ошибки (MAE) при увеличении количества эпох. При проходе через сеть валидационной выборки мы видим что ошибка также уменьшается так что речь о переобучении сети не стоит.

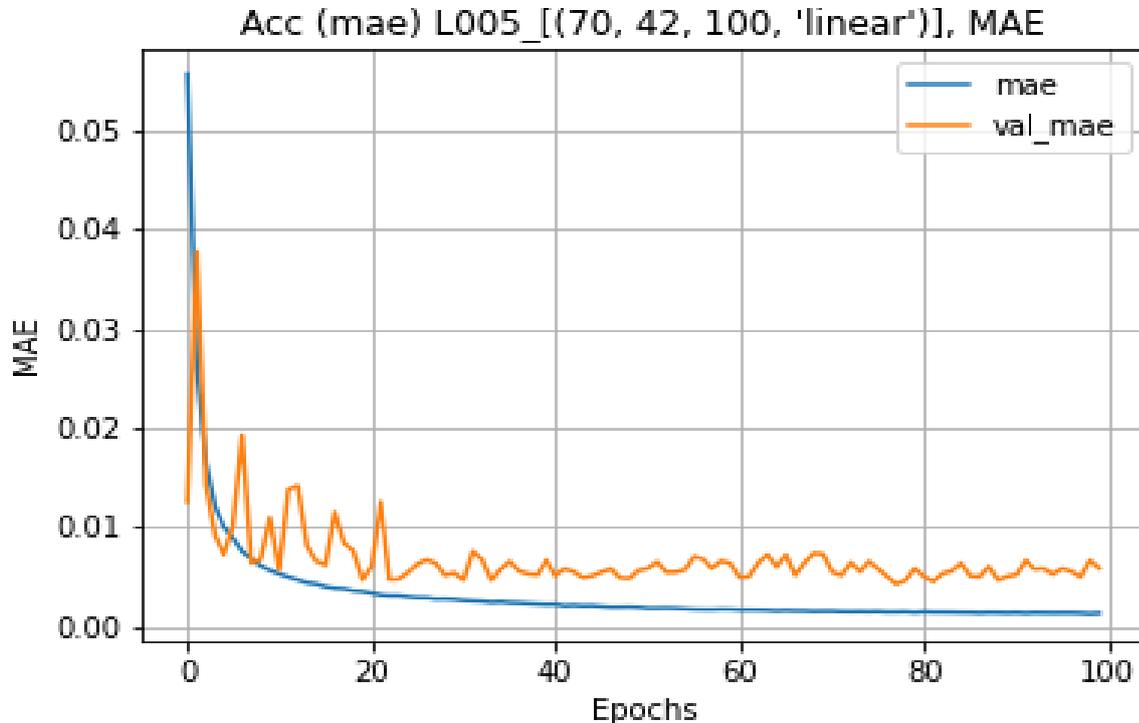


Рисунок 5 – Ошибка MAE при обучении сети

Как было упомянуто ранее оценку работы нашего метода управления переключателями света в умном доме мы будем проводить на основе набора данных CASAS HH102. Проверка будет производиться на данных одного и трёх месяцев (каждая такая выборка будет разбита на обучающую выборку (72%) и контрольную выборку (28%)). Результаты эксперимента

продемонстрированы в таблице 1. FP – ложное включение прибора, FN – ложное выключение прибора. Critical error – ложное включение прибора произошедшее в том часу в котором на самом деле включения не было (FP включает в себя ложные включения произошедшие всего лишь на 1-3 минуты раньше нужного, поэтому введена отдельная метрика чтобы отличать грубые ошибки).

Таблица 1 – Точность выдачи правильных управляющих воздействий для комнат из набора данных hh102

Имя	FP\FN	Critical error	Error	Примечание
Обучение на данных 1 месяца (72% (~23 дней.) обуч.\28% (~10 дней.) контр. выборки)				
L002	7\0	0	2,43%	
L003	27\9	0	2,27%	
L004	1\0	0	0,72%	
L005	1\0	0	1,90%	
Обучение на данных 3 месяцев (72% (~2 мес.) обуч.\28% (~1 мес.) контр. выборки)				
L002	12\1	0	3,20%	
L003	20\5	0	1,65%	
L004	7\2	0	4,01%	
L005	2\0	0	3,57%	

Исходя из первой таблицы у нас не произошло критических ошибок ни для одного переключателя света, что означает что все ложные включения лишь ранние включения приборов, произведенные на 1–3 минуты раньше положенного.

Проведем другой эксперимент. Возьмём данные от 01-07-2011 до 30-09-2011 в качестве обучающей выборки. Для тестовой выборки будет взят отрезок 01-01-2013 до 30-03-2013. Как можно заметить обучается сеть на летних данных, а проверяется на зимних. Это было сделано из-за того, что поведение человека летом и зимой может сильно отличаться, что хорошо нам подходит для проверки нашего метода управления УД.

Таблица 2 – Оценка выдачи правильных управляющих воздействий за период (01-01-2013 до 30-03-2013) ИНС, обученной на данных hh102 от (01-07-2011 до 30-09-2011)

Имя	FP\FN	Critical error	Error	Примечание
L002	90\5	2	2,96%	
L003	209\57	4	2,02%	Для данного датчика много записей в наборе данных, поэтому у него большое FP\FN
L004	85\26	3	3,18%	
L005	7\6	0	3,96%	

2. Сравнение точности нашего метода управления прибором УД с другими похожими методами

Использование ИНС для управления умным домом крайне непопулярная тема для исследований и поэтому мы будем производить сравнение всего лишь с двумя работами. Работа [5] использовала для управления УД многослойный перцептрон. Для оценки своего

метода автор использовал данные за 3 месяца одного переключателя света, поэтому оценка точности довольно слабая, но всё же она есть.

Во второй работе [9] также использовалась искусственная нейронная сеть. В данной работе использовались две нейронные сети для прогнозирования следующей активности и времени ее возникновения. Так как эта ИНС использовалась для прогнозирования, к тому же на уровне всего умного дома, а не конкретного умного устройства как в нашем случае, то точность такой сети оставляет желать лучшего. Однако в данной главе следует привести эту работу чтобы показать, насколько лучше использовать 1 нейронную сеть, обученную под управление конкретного устройства нежели пытаться предугадать следующее действие человека в пределах одного дома. Для оценки точности данная работа использовала датасеты hh102, hh104 и hh110, поэтому и оценка нашего метода будет получена на тех же данных (средняя от каждой комнат).

Таблица 3 – Сравнение точности нашего метода с другими методами управления умным домом

Метод	Точность
GRU (наш метод)	96,97%
MP [5]	96,25%
LSTM [9]	35,20%

Список литературы

1. Bourobou S.T.M., Yoo Y. User Activity Recognition in Smart Homes Using Pattern Clustering Applied to Temporal ANN Algorithm. // MDPI. Sensors. – 2015.
2. Julien Cumin. Recognizing and predicting activities in smart homes. Human-Computer Interaction // Université Grenoble Alpes, 2018. С. 158.
3. Li K.F. Smart home technology for telemedicine and emergency management. // J. Ambient Intell. Humaniz. Comput. – 2013.
4. Reaz M.B.I. Artificial Intelligence Techniques for Advanced Smart Home Implementation. Acta Tech. Corviniensis – Bulletin of Engineering. Tome 6. Eng. – 2013.
5. Carlos Machado, José A. Mendes.: Automatic Light Control in Domotics using Artificial Neural Networks. // 2008 World Academy of Science, Engineering and Technology International Journal of Electronics and Communication Engineering Vol:2, No:8, 2008.
6. Jayalakshmi T., Santhakumaran A. Statistical normalization and back propagation for classification // International Journal of Computer Theory and Engineering. – 2011. – Т. 3. – №. 1. – С. 1793-8201.
7. Swingler, K.: Applying Neural Networks: A Practical Guide. Morgan Kaufmann // San Francisco. 1996.
8. Глубокое обучение на Python. / Шолле Франсуа. — СПб.: Питер, 2018. — 400 с.
9. Niek Tax. Human Activity Prediction in Smart Home Environments with LSTM Neural Networks. // 2018 International Conference on Intelligent Environments. 2018.

References

1. Bourobou S.T.M., Yoo Y. User Activity Recognition in Smart Homes Using Pattern Clustering Applied to Temporal ANN Algorithm. // MDPI. Sensors. – 2015.

2. Julien Cumin. Recognizing and predicting activities in smart homes. *Human-Computer Interaction // Université Grenoble Alpes*, 2018. P. 158.
 3. Li K.F. Smart home technology for telemedicine and emergency management. // *J. Ambient Intell. Humaniz. Comput.* – 2013.
 4. Reaz M.B.I. Artificial Intelligence Techniques for Advanced Smart Home Implementation. *Acta Tech. Corviniensis – Bulletin of Engineering. Tome 6. Eng.* – 2013.
 5. Carlos Machado, José A. Mendes.: Automatic Light Control in Domotics using Artificial Neural Networks. // 2008 World Academy of Science, Engineering and Technology International Journal of Electronics and Communication Engineering Vol:2, No:8, 2008.
 6. Jayalakshmi T., Santhakumaran A. Statistical normalization and back propagation for classification // *International Journal of Computer Theory and Engineering.* – 2011. – Т. 3. – №. 1. – pp. 1793-8201.
 7. Swingler, K.: *Applying Neural Networks: A Practical Guide.* Morgan Kaufmann // San Francisco. 1996.
 8. *Deep Learning with Python.* / Francois Chollet. — SPb.: Piter, 2018. — p. 400.
 9. Niek Tax. Human Activity Prediction in Smart Home Environments with LSTM Neural Networks. // 2018 International Conference on Intelligent Environments. 2018.
-



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004.8

СРАВНЕНИЕ ПОДХОДОВ С ИСПОЛЬЗОВАНИЕМ МЕДИАНЫ КЕМЕНИ И БЕЗ НЕЁ В НЕЧЕТКОЙ БАЙЕСОВСКОЙ СЕТИ ДЛЯ СНИЖЕНИЯ РИСКА

Якушев В.А.

Филиал ФГБОУ ВО «Национальный исследовательский университет «МЭИ» в г. Смоленске, Россия, (214013, г. Смоленск, Энергетический проезд, 1), e-mail klan-ipgs@rambler.ru

Статья посвящена рассмотрению и сравнению получаемых вероятностей для исходных векторов мнений экспертов и медианы Кемени при применении нечёткой байесовской сети для снижения риска. Рассматривается нечёткая байесовская сеть для снижения риска. Предложен способ перевода исходных векторов мнений экспертов для нечёткой байесовской сети в общий вектор мнений без использования медианы Кемени.

Ключевые слова: медиана Кемени, вектор мнений экспертов, нечёткая байесовская сеть, сравнение, снижение риска.

COMPARISON OF APPROACHES USING THE MEDIAN OF KEMENI AND WITHOUT IT IN A FUZZY BAYESIAN NETWORK TO REDUCE RISK

Yakushev V.A.

Smolensk Branch of the National Research University "Moscow Power Engineering Institute", Smolensk, Russia (214013, Smolensk, Energeticheskyy proezd, 1), e-mail: klan-ipgs@rambler.ru

The article is devoted to consideration and comparison of the obtained probabilities for the initial vectors of expert opinions and the Kemeny median by using a fuzzy Bayesian network to reduce risk. A fuzzy Bayesian network to reduce risk is considered. A method for translating the initial vectors of expert opinions for a fuzzy Bayesian network into a general vector of opinions without using the Kemeny median is proposed.

Keywords: Kemeny median, vector of expert opinions, fuzzy Bayesian network, comparison, risk reduction.

В повседневной жизни люди очень часто сталкиваются с таким понятием, как риск. В настоящее время существуют направления абсолютно в разных индустриях, связанные с выявлением и предупреждением риска. Например, можно рассматривать IT-индустрию, в которой есть целое направление, посвящённое этому. Или же сферу бизнеса, в которой выявление и предупреждение риска является залогом успеха.

Если использовать нечёткую байесовскую сеть для снижения риска, то необходимо учитывать характеристику рисков, для получения более точного результата.

Для характеристики рисков существует несколько классификаций факторов, которые оказывают определённое влияние.

В первую группу входят данные разновидности факторов риска:

- Физические факторы;
- Инфраструктурные факторы;
- Технологические факторы;
- Финансовые факторы;
- Социально-культурные факторы;
- Политические факторы.

Но этой характеристики недостаточно для полного описания важности каждого фактора для конечной оценки риска, хоть и для почти всех мероприятий нужно учитывать разделение именно по этой классификации факторов.

В теории рисков, помимо представленной классификации, существует ещё одно разветвление факторов риска:

- Управляемые факторы;
- Факторы, поддающиеся влиянию;
- Факторы, поддающиеся только оценке.

Управляемые факторы – это факторы, которые оказывают самое наименьшее влияние на окончательную оценку риска, потому что их можно контролировать.

Факторы, поддающиеся влиянию – это факторы, которые оказывают умеренное влияние на окончательную оценку риска, вследствие своей неопределённости в контроле, то есть можно ли контролировать, нужны ли какие-то дополнительные условия для этого, сильное ли влияние этот фактор будет иметь на конечную оценку риска и тому подобное.

Факторы, поддающиеся только оценке – это факторы, которые оказывают самое наибольшее влияние на окончательную оценку риска, потому что управление ими затруднено или невозможно.

Каждая классификация факторов находит отражение в нечёткой байесовской сети, фрагмент которой представлен далее. Она составлялась с использованием [3, 4, 7].

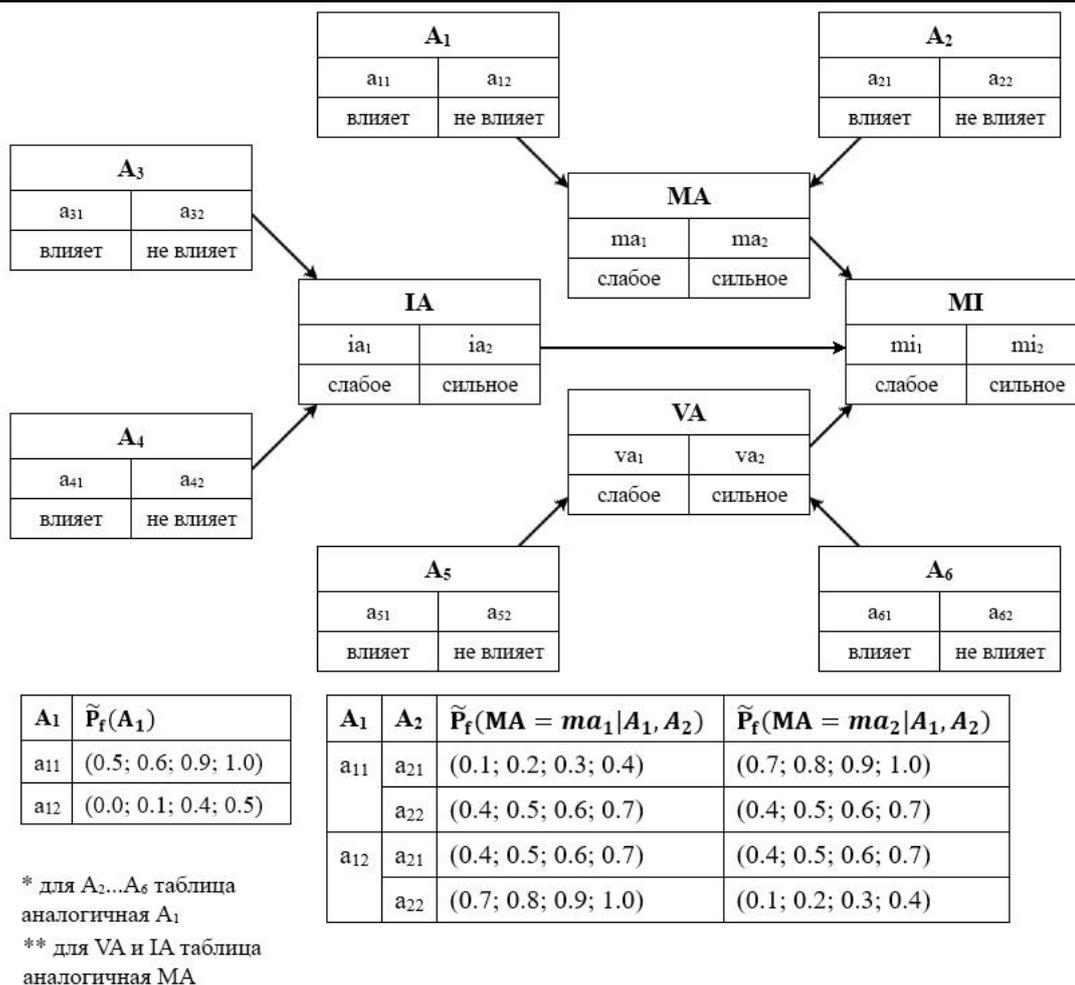


Рисунок 1 – Фрагмент нечёткой байесовской сети

На фрагменте представлено ветвление для нахождения влияния только одной первичной классификации факторов. Сама же сеть учитывает все шесть первичных групп факторов. Вторичная же классификация учтена выводом общих оценок MA, IA, VA (*Manage A, Impact A, Value A*). Здесь MA отвечает за управляемые факторы, IA – за факторы, которые поддаются влиянию, а VA – за факторы, которые поддаются только оценке.

Таким образом, чтобы получить точную оценку риска для определённой классификации факторов, необходимо проанализировать собранные мнения экспертов, используя представленную нечёткую байесовскую сеть.

Для получения оценки по вторичной классификации факторов каждая компонента из вектора мнений сопоставляется с таблицей, которая изображена ниже.

Таблица 1 – Нахождение значений MA для физических факторов

A_1	A_2	MA_1	MA_2
a_{11}	a_{21}	слабое	сильное
	a_{22}	умеренное	умеренное
a_{12}	a_{21}	умеренное	умеренное
	a_{22}	сильное	слабое

В таблице отмечены нечёткие значения для вероятностей возникновения событий MA_1 (слабое влияние) и MA_2 (сильное влияние). То есть, если управляемые факторы A_1 и A_2 оказывают влияние, то вероятность слабого влияния слабая, а сильного – сильная. Если же один из них не оказывает влияния, а другой – оказывает, то уже отнести к разряду сильное или слабое влияние становится сложнее, поэтому используется умеренная вероятность. Если ни один из факторов не оказывает влияния, то общее влияние управляемых факторов слабое с большей вероятностью, чем сильное. Для IA и VA таблицы идентичные.

Общая структура была выделена из [1, 8], но с небольшой коррекцией.

Из значений MA , IA и VA получается общая вероятностная оценка для MI (таблица 2). Эту оценку MI мы и будем рассматривать.

Пусть существует вектор факторов одного типа: $[A_1, A_2, \dots, A_6]$. Для равномерной оценки каждый из представленных факторов должен одинаковым образом относиться ко вторичной классификации. То есть, A_1 и A_2 – это управляемые факторы, A_3 и A_4 – это факторы, которые поддаются влиянию, а A_5 и A_6 – это факторы, которые поддаются только оценке. Чтобы оценить общее влияние факторов данного типа, необходимо обратиться к экспертам, которые должны расставить эти факторы в порядке важности для определённой задачи.

Пусть были опрошены три эксперта, которые выдали такие оценки:

- 1 эксперт – $[A_3, A_5, A_6, A_2, A_4, A_1]$;
- 2 эксперт – $[A_1, A_5, A_3, A_2, A_4, A_6]$;
- 3 эксперт – $[A_2, A_5, A_4, A_6, A_1, A_3]$.

Таблица 2 – Фрагмент таблицы для оценки влияния физических факторов

MA_1	IA_1	VA_1	MI_1	MI_2
1	2	3	4	5
очень сильное	очень сильное	очень сильное	<i>самая низкая</i>	<i>макс. высокая</i>
		сильное	<i>низкая</i>	<i>макс. высокая</i>
		умеренное	<i>средняя</i>	<i>высокая</i>
		слабое	<i>выше среднего</i>	<i>выше среднего</i>
	сильное	очень сильное	<i>низкая</i>	<i>макс. высокая</i>
		сильное	<i>ниже среднего</i>	<i>высокая</i>
		умеренное	<i>средняя</i>	<i>выше среднего</i>
		слабое	<i>выше среднего</i>	<i>средняя</i>
	умеренное	очень сильное	<i>ниже среднего</i>	<i>высокая</i>
		сильное	<i>средняя</i>	<i>выше среднего</i>
		умеренное	<i>выше среднего</i>	<i>средняя</i>
		слабое	<i>высокая</i>	<i>ниже среднего</i>
	слабое	очень сильное	<i>средняя</i>	<i>высокая</i>
		сильное	<i>выше среднего</i>	<i>выше среднего</i>
		умеренное	<i>высокая</i>	<i>средняя</i>
		слабое	<i>макс. высокая</i>	<i>низкая</i>
...				

Медиана Кемени для данного случая получится такой: $[A_5, A_2, A_3, A_6, A_4, A_1]$.

Если учитывать только медиану Кемени, а не исходные векторы мнений экспертов, то медиана Кемени будет учтена, как одно мнение, а не их группа. Это утверждение и будет проверено.

Рассмотрим исходный набор векторов мнений экспертов:

Каждый набор возможно представить в приоритетно-вероятностном виде. Это отмечено в таблице далее.

Таблица 3 – Представление векторов мнений в приоритетно-вероятностном виде

Оценки	1.0	0.833	0.667	0.500	0.333	0.167
1 эксперт	A ₃	A ₅	A ₆	A ₂	A ₄	A ₁
2 эксперт	A ₁	A ₅	A ₃	A ₂	A ₄	A ₆
3 эксперт	A ₂	A ₅	A ₄	A ₆	A ₁	A ₃

Рассчитав полные вероятности для каждого фактора, был получен следующий результат:

Таблица 4 – Представление векторов мнений в приоритетно-вероятностном виде

Общее	A ₁	A ₂	A ₃	A ₄	A ₅	A ₆
Оценки	0.500	0.667	0.611	0.444	0.833	0.444

То есть получены наборы: [A₅, A₂, A₃, A₁, A₆, A₄] или [A₅, A₂, A₃, A₁, A₄, A₆]. Оба эти набора абсолютно эквиваленты друг другу, но отличаются от медианы Кемени: A₁ расположился на четвёртом месте, а дальше уже A₆ и A₄, когда в медиане Кемени всё немного по-другому.

Получается, что фактор A₁ оказывает влияние на конечный результат с вероятностью 0.5. В данном случае, если фактор A₂ оказывает влияние, то фактор A₁, также, будет оказывать влияние.

Таким образом, получается оценки: VA₁ = выше умеренного, MA₁ = умеренное и IA₁ = умеренное. В цифрах же получается: VA₁ = 0.639, MA₁ = 0.584, IA₁ = 0.528.

Следовательно, оценка влияния MI равна: MI₁ = высокая вероятность, MI₂ = средняя вероятность, где MI₁ – это слабое влияние, а MI₂ – это сильное влияние.

Рассмотрим медиану Кемени:

Напомню, что медиана Кемени (МК) была получена такая: [A₅, A₂, A₃, A₆, A₄, A₁]. Представим её в приоритетно-вероятностном виде:

Таблица 5 – Представление медианы Кемени в приоритетно-вероятностном виде

Оценки	1.0	0.833	0.667	0.500	0.333	0.167
МК	A ₅	A ₂	A ₃	A ₆	A ₄	A ₁

Получается, что фактор A₆ оказывает влияние на конечный результат с вероятностью 0.5. В данном случае, если фактор A₅ оказывает влияние, то фактор A₆, также, будет оказывать влияние.

Таким образом, получается оценки: VA₁ = сильное, MA₁ = умеренное и IA₁ = умеренное. В цифрах же получается: VA₁ = 0.750, MA₁ = 0.500, IA₁ = 0.500. Оценки влияния MI равны: MI₁ = вероятность выше среднего, MI₂ = средняя вероятность.

Полученный в итоге результат для медианы Кемени довольно неоднозначен, то есть очень сложно в итоге понять, имеет ли данная первичная категория факторов сильное влияние, в то время, как из исходного вектора мнений был получен более однозначный результат, что влияние слабое, а значит не имеет смысла искать пути снижения риска для этого фактора, потому что оно окажет очень малое влияние на общую картину, или не окажет влияния совсем. В итоге следует рассматривать другие первичные классификации факторов риска, чтобы определить их оценку относительно данной, и проводить анализ для мероприятий по снижению вероятности риска.

Список литературы

1. Zaharov A.S., Borisov V.V., Senkov A.V. Accident risks assessment by temporal fuzzy bayesian network // International journal of applied engineering research. // 2016. Т. 11, No 22. С. 10731-10736.
2. Белозерский А.Ю., Какатунова Т.В., Иванова И.В. Использование аппарата нечетких байесовых сетей для оценки инновационных рисков // Транспортное дело России. 2011. № 2. С. 43-46.
3. Борисов В.В., Захаров А.С. Приближенные рассуждения на основе темпоральных нечетких байесовских сетей // Программные продукты и системы. 2016. № 2 (114). С. 27-33.
4. Захаров А.С. Темпоральный вывод с использованием нечётких байесовых сетей // Известия Смоленского государственного университета, №1, 2014. С. 417-430. (0,93 п.л.)
5. Захаров А.С. Разработка моделей для поддержки принятия решений на основе нечётких байесовских сетей // Сб. тр. XIII Междунар. науч.-техн. конф. «Системы компьютерной математики и их приложения» (СКМП-2012). – Смоленск: Изд-во СмолГУ, 2012. Вып. 13. С. 88-93. (0,36 п.л.)

References

1. Zaharov A.S., Borisov V.V., Senkov A.V. Accident risks assessment by temporal fuzzy bayesian network // International journal of applied engineering research. 2016. Т. 11, № 22. pp. 10731-10736.
2. Belozersky A.Yu, Kakatunova T.V., Ivanova I.V. Using fuzzy bayes networks to assess innovative risks / Russian transport business. 2011. № 2. pp. 43-46.
3. Borisov V.V., Zaharov A.S. Close reasoning based on temporal fuzzy Bayesian networks / Softwarez products and systems. 2016The temporal conclusion using fuzzy bayes networks is a temporary conclusion / Izvestia of Smolensk State University, No.1, 2014. pp. 417-430. (0.93 p.l.) . № 2 (114). pp. 27-33.
4. Zaharov A.S. The temporal conclusion using fuzzy bayes networks is a temporary conclusion / Izvestia of Smolensk State University, No.1, 2014. pp. 417-430. (0.93 p.l.)
5. Zakharov A.S. Development of models to support decision-making based on fuzzy Bayesian networks / Sat. Tr. XIII Internar. Teach--techn. conf. "Computer Mathematics Systems and Their Applications" (SMP-2012). Smolensk: SmallSU, 2012. Vol. 13. pp. 88-93. (0.36 p.l.).



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004.89

СИСТЕМА РАСПРЕДЕЛЕНИЯ НАГРУЗКИ АППАРАТНО-ВЫЧИСЛИТЕЛЬНЫХ РЕСУРСОВ РАЗВЕРТЫВАЕМЫХ CRM СИСТЕМ НА БАЗЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ОБУЧЕНИЯ

Жарков А.П.

Филиал ФГБОУ ВО «Национальный исследовательский университет «МЭИ» в г. Смоленске, Россия, (214013, г. Смоленск, Энергетический проезд, 1), e-mail: antonzharcov@yandex.ru

Существующие программные решения управления IT-проектами основаны на централизованных CRM системах. Основная проблема, выделяемая в реализации существующих CRM систем – неэффективное использование программно-аппаратных ресурсов при развёртке CRM. Для решения рассматриваемой проблемы предлагается разработать программное обеспечение на базе нейронных сетей глубокого обучения для осуществления предиктивного анализа доступных ресурсов с целью оптимизации системного программного обеспечения для повышения стабильности.

Ключевые слова: crm системы, управление проектами, нейронные сети, глубокое обучение, оптимизация процессов.

THE LOAD DISTRIBUTION SYSTEM OF THE HARDWARE AND COMPUTING RESOURCES OF DEPLOYED CRM SYSTEMS BASED ON NEURAL DEEP LEARNING

Zharckov A.P.

Smolensk Branch of the National Research University “Moscow Power Engineering Institute”, Smolensk, Russia (214013, Smolensk, Energeticheskyy proezd, 1), e-mail: antonzharcov@yandex.ru

Existing IT project management software solutions are based on centralized CRM systems. The main problem highlighted in the implementation of existing CRM systems is the inefficient use of software and hardware resources in the deployment of CRM. To address this problem, it is proposed to develop software based on neural networks of deep learning to carry out predictive analysis of available resources in order to optimize system software to improve stability.

Keywords: crm systems, project management, neural networks deep learning, optimization processes.

В основе грамотной реализации подхода управления IT-проектами заложен принцип создания иерархической системы централизованного распределения ресурсов организации, направленных на создание и продвижение различных сервисов и услуг. Для решения рассматриваемой проблемы на данный момент существуют различные прикладные программные решения, именуемые как Customer Relationship Management – CRM [1 – 2]. CRM система предлагает функциональные возможности по управлению персоналом и бизнес-логикой целевой организации. В данную систему включаются прикладные функциональные

компоненты, направленные на рост уровня продаж, организацию эффективности маркетинговых процессов с целью улучшения бизнес-процессов и предоставления аналитической информации административному сегменту. Немаловажной особенностью таких продуктов является процесс корректной конфигурации оборудования на программном и аппаратном уровнях для дальнейшего исключения возможности отказа системы. Рассматривая популярные серверные CRM-системы можно сказать, что функционал реализации почтового и файлового сервера, а также корпоративных мессенджеров требует значительных затрат аппаратных ресурсов ПК или сервера.

В результате вышеприведённых факторов представляется возможным выделить приоритетную проблему централизованного распределения аппаратных ресурсов устройства, на котором осуществляется развёртка CRM системы. В качестве побочной проблемы возможно выделить естественные процессы развития и расширения организации, и как следствие сделать вывод, что рост клиентов увеличивает затраты аппаратных ресурсов. Существующие на рынке решения в большей степени являются неэффективными ввиду работы напрямую с общими параметрами системы, реализуя процесс оптимизации потребления ресурсов. Альтернативным подходом к решению рассматриваемой проблемы является возможность развёртки CRM системы на высокопроизводительном сервере, при этом снижается коэффициент рентабельного расхода экономических ресурсов предприятия. Таким образом можно сказать, что на данный момент не существует прикладных программных решений, направленных на решение проблемы оптимизации и централизованного распределения ресурсов, что делает рассматриваемую проблему актуальной.

Для решения рассматриваемой проблемы было разработано программное обеспечение, направленное на оптимизацию расхода ресурсов. В основе предлагаемого решения используется метод предиктивного анализа доступных ресурсов и системы принятия решений на основе нечёткой логики. В качестве рассматриваемой нейронной сети использовалась двунаправленная рекуррентная нейронная сеть (BRNN), позволяющая на основе использования статических и динамических последовательностей выполнять предиктивный анализ моментов возникновения ошибок из-за превышения коэффициента использования доступных ресурсов [3 – 4].

На первоначальном этапе планирования были выделены основные модули разрабатываемого программного обеспечения. В качестве основного языка программирования используется язык C++ с совместной интеграцией модулей на базе языке программирования Python [5 – 6]. Так, реализуемый подход позволяет использовать фактор мультиплатформенности и в дальнейшем адаптировать программный продукт для работы с вариативными операционными системами. Представленный алгоритм на рисунке 1 представляет общий принцип взаимодействия модулей разрабатываемого ПО. Для удобства отладки использовался принцип модульного разделения.

- Модуль «идентификация входных параметров» идентифицируется как модуль сбора данных количества доступных и используемых аппаратно-зависимых ресурсов для выполнения последующей оптимизации работы операционной системы.
- Модуль «уточнение специфичных параметров работы системы». Используется для извлечения прикладных параметров системы, которые могут оказать значительное влияние на работоспособность CRM системы в процессе её эксплуатации.

- Модуль «предиктивная оптимизация на базе нейронной сети». Предполагает использование нейронной сети для оптимизации работы процессов системы и повышения эффективности.
- Модуль «система принятия решений на базе нечеткой логики». Для вывода и подведения обещающих результатов используется программная реализация методов нечеткой логики для аналитического сравнения и вывода исходов возможных ситуаций некорректной работы аппаратных ресурсов в режиме повышенной нагрузки. В качестве основных настраиваемых параметров пользователю предлагается возможность указания принудительной обработки в случае, если завершение системных процессов не представляется возможным.

На этапе работы модуля идентификации входных параметров выполняется анализ доступных процессов в ОС и их распределения по приоритету. При этом учитываются системные процессы CRM системы – например, если специфичная CRM система работает на базе веб-сервера с использованием как прикладных пакетов реализации веб-серверов apache, nginx, то подпроцессы работы веб-сервера также представляют исключения для дальнейшей выгрузки.

Модуль уточнения специфичных параметров работы системы осуществляет выборку процессов с наивысшим приоритетом и соответствующим процентом потребления аппаратных ресурсов единичного экземпляра. Помимо прочего, модуль выполняет снимки текущего состояния сервера в вариативные моменты времени для корректной работоспособности модуля принятия решений.

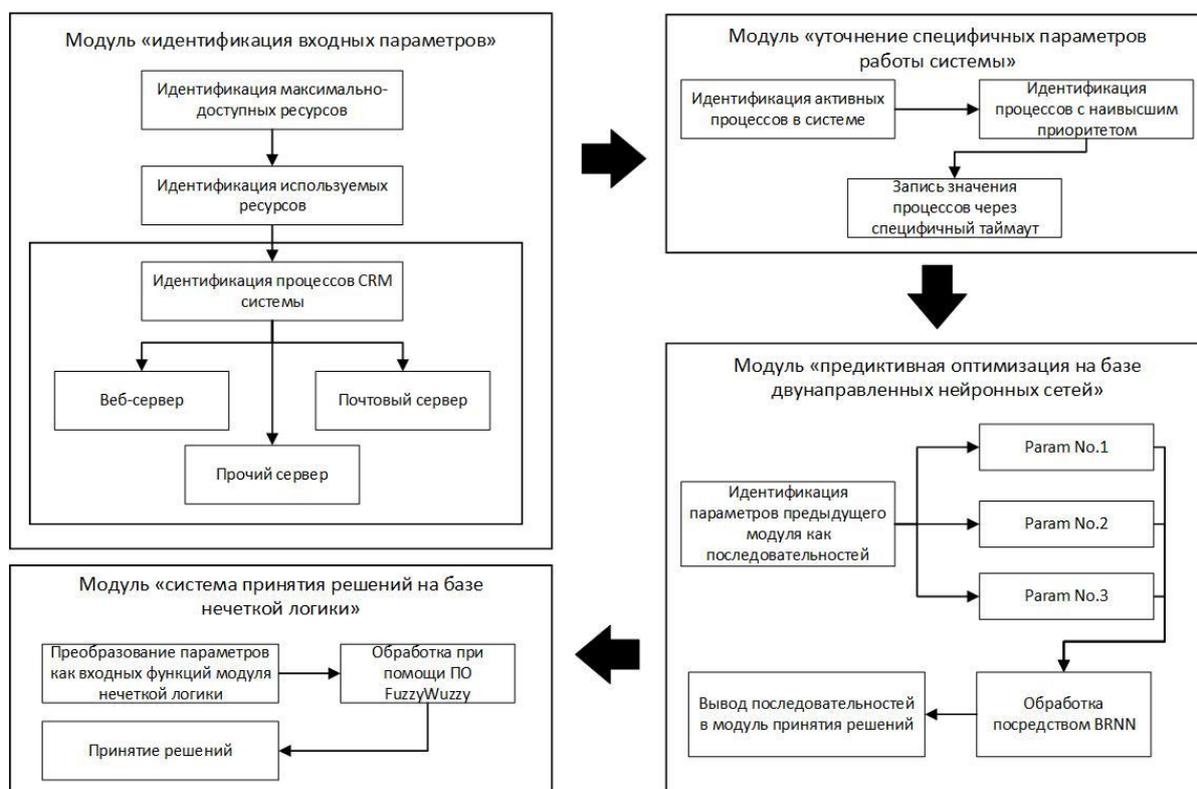


Рисунок 1 – Общий алгоритм взаимодействия разработанного программного обеспечения

Реализация программного модуля предиктивной оптимизации осуществляется на базе двунаправленных рекуррентных нейронных сетей (Bidirectional Neural Network - BRNN). Основной особенностью, выделяемой в рассматриваемой нейронной сети – возможность анализа последовательностей для идентификации дальнейшего поведения. В качестве основных параметров, выступающих входными слоями нейронной сети можно выделить статические последовательности доступной оперативной памяти, места на физическом носителе, а также последовательности, интерпретируемые в результате работы первого модуля [7]. Алгоритмический аспект реализации BRNN основан на подаче входных векторов в нескольких направлениях:

- в первом варианте на вход подаются параметры в виде стандартных слоёв рекуррентной нейронной сети;
- во втором варианте используется реверсивная подача входных последовательностей.

На следующем этапе выполняется слияние векторов в единичный экземпляр с учётом временного шага, и за счёт этого пользователю предоставляется возможность получения значений в различные промежутки времени. В качестве приоритетных векторов на вход представляются значения фазсификатора (x_i), выходным же вектором для каждого слоя нейронной сети является вектор (y_i). В качестве обучающих образцов на вход нейронной сети представляются вектора последовательностей с типом float. Первый слой, являющийся «стандартным» слоем в программной реализации, подается с отключенным параметром `bidirectional`, при этом второй слой является двунаправленным, то есть параметр `bidirectional` принимает значение `true`.

Программная реализация рассматриваемого модуля выполняется на основе библиотеки нейронной сети PyTorch [8]. В результате на начальном этапе подключается GRU слой, и затем, после инициализации и выполнения вычислений, выполняется процесс вычисления реверсивной последовательности (параметр `bidirectional` использует значение `false`). На предпоследнем этапе выполняется анализ сходимости весов последовательных и реверсивных слоёв нейронной сети на статичном шаге параметра t . В качестве обучающих образцов используются динамические и статические параметры системы, представляемые массивом вида «3.544, 124.32, False». Так, в результате работы нейронного модуля возможно определить предиктивное значение параметра системы, например, количество используемой оперативной памяти через интервал t .

Для аналитического сравнения выходных векторов используется уточнение за счёт программной реализации библиотеки Python – FuzzyWuzzy [9]. Рассматриваемая библиотека предоставляет возможность гибкого сравнения последовательностей с последующим выводом результатов в процентном соотношении. В результате анализа функциональных возможностей использовалась функция токена на сравнения. Как представлено на рисунке 4, на вход нечёткого модуля подаются исходные данные (`m_based`) и предиктивные (`m_out_neural`), и как вследствие на выходе нейронного модуля представляется возможным вывести отклонения от базовой последовательности.

```
Python 3.9.1 (default, Dec  8 2020, 07:51:42)
[GCC 10.2.0] on linux
Type "help", "copyright", "credits" or "license" for more information.
>>> from fuzzywuzzy import fuzz
>>> from fuzzywuzzy import process
>>> m_out_neural = ["7.98657", "6.2353426", "3.462464"]
>>> m_based = "7.99664"
>>> process.extract(m_based, m_out_neural)
[('7.98657', 57), ('3.462464', 53), ('6.2353426', 25)]
>>>
```

Рисунок 2 - Программная реализация работы модуля нечеткой логики

На завершающем этапе выполняется работа модуля принятия решений, при этом представляется возможным контролировать активность процессов от процента уменьшения или увеличения отклонений.

Таким образом, в результате разработки программного продукта можно сказать, что внедрение методов работы с последовательностями на основе нейронных сетей глубокого обучения позволяет оптимизировать работу прикладных процессов в сфере деятельности по управлению проектами.

Список литературы

1. Helgeson L. CRM For Dummies. 1st ed. United States: For Dummies, 2017. 368 p.
2. Williams D S. Connected CRM: Implementing a Data-Driven, Customer-Centric Business Strategy. 1st ed. Hoboken: Wiley, 2014. 256p.
3. Himansu D., Chittaranjan P., Nilanjan Deep Learning for Data Analytics: Foundations, Biomedical Applications, and Challenges. 1st ed. Cambridge: Academic Press, 2020. 218 p.
4. Simeon K. Recurrent Neural Networks with Python Quick Start Guide: Sequential learning and language modeling with TensorFlow. Birmingham: Packt Publishing, 2018. 122 p.
5. Andrist B., Sehr V., Garney B. C++ High Performance: Master the art of optimizing the functioning of your C++ code. 2nd ed. Birmingham: Packt Publishing, 2020. 540 p.
6. Paul D., Harvey D. Intro to Python for Computer Science and Data Science: Learning to Program with AI, Big Data and The Cloud. 1st ed. New York: Pearson, 2019. 880 p.
7. Lindigrin A.N. Iskusstvennye nejronnye seti kak osnova glubinnogo obuchenija // Izvestija TulGU. Tehnicheskie nauki. 2019. №12. PP 468-472. (In Russian)

References

1. Helgeson L. CRM For Dummies. 1st ed. United States: For Dummies, 2017. 368 p.
2. Williams D S. Connected CRM: Implementing a Data-Driven, Customer-Centric Business Strategy. 1st ed. Hoboken: Wiley, 2014. 256p.
3. Himansu D., Chittaranjan P., Nilanjan Deep Learning for Data Analytics: Foundations, Biomedical Applications, and Challenges. 1st ed. Cambridge: Academic Press, 2020. 218 p.
4. Simeon K. Recurrent Neural Networks with Python Quick Start Guide: Sequential learning and language modeling with TensorFlow. Birmingham: Packt Publishing, 2018. 122 p.
5. Andrist B., Sehr V., Garney B. C++ High Performance: Master the art of optimizing the functioning of your C++ code. 2nd ed. Birmingham: Packt Publishing, 2020. 540 p.

6. Paul D., Harvey D. Intro to Python for Computer Science and Data Science: Learning to Program with AI, Big Data and The Cloud. 1st ed. New York: Pearson, 2019. 880 p.
 7. Lindigrin A.N. Iskusstvennye nejronnye seti kak osnova glubinnogo obucheniija // Izvestija TulGU. Tehnicheskie nauki. 2019. №12. PP 468-472. (In Russian)
-



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 681.3.06

МЕТОДИЧЕСКИЙ АППАРАТ РАЗРАБОТКИ МАТЕМАТИЧЕСКИХ МОДЕЛЕЙ ДЛЯ СИСТЕМ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ

Балашов О.В.¹, Букачев Д.С.².

¹Смоленский филиал АО «Радиозавод», Россия, (214027, г. Смоленск, улица Котовского, 2), e-mail: smradio@mail.ru

²ФГБОУ ВО Смоленский государственный университет, Смоленск, Россия (21400, г. Смоленск, ул. Пржевальского, 4), e-mail: dsbuka@yandex.ru

Предложен методический аппарат, который позволяет разработать комплекс методик оценки возможностей выполнения действий объектами организационно-технических систем. Данный методический аппарат основан на методах теории возможностей, состоит из нескольких этапов решения частных задач и предназначен для разработки математических моделей функционирования объектов в системах поддержки принятия решений.

Ключевые слова: теория вероятностей, математическая статистика, теория возможностей, математическое моделирование.

METHODOLOGICAL APPARATUS FOR DEVELOPING MATHEMATICAL MODELS FOR DECISION SUPPORT SYSTEMS

¹Balashov O.V., ²Bukachev D.S.

¹ Smolensk branch of joint-stock company "Radio factory", Russia, (214027, Smolensk, street Kotovskogo, 2), e-mail: smradio@mail.ru

² Federal State Educational Institution of Higher Education Smolensk State University, Smolensk, Russia (21400, Smolensk, street Przewalski, 4), e-mail: dsbuka@yandex.ru

A methodological apparatus is proposed that allows developing a complex of methods for assessing the possibilities of performing actions by objects of organizational and technical systems. This methodological apparatus is based on the methods of the theory of possibilities, consists of several stages of solving particular problems and is intended for the development of mathematical models of the functioning of objects in decision support systems.

Keywords: probability theory, mathematical statistics, theory of possibilities, mathematical modeling.

Введение. Функционирование организационно-технических систем (ОТС) характеризуется большой сложностью. Результаты проведенных исследований показали, что в составе системы поддержки принятия решений (СППР) должна быть предусмотрена модель принятия решений общего характера [1, 2], которая должна позволять осуществлять выбор альтернатив на основе любого из разработанных в теории принятия решений методов:

- по векторному критерию качества;

- на основе предпочтений лица, принимающего решение (ЛПР);
- на основе правил принятия решений.

В зависимости от характера задачи управления в СППР возможно формирование множества альтернатив одного из трех типов [6]:

- нечёткое множество нечётких альтернатив;
- нечёткое множество чётких альтернатив;
- чёткое множество нечётких альтернатив.

В свою очередь, указанные типы множеств альтернатив образуют аналогичные множества исходов [6]. Исходом может оказаться: нечёткое множество нечётких состояний объекта управления; нечёткое множество чётких состояний; нечёткое состояние.

Если к тому же наступление исхода – недетерминированное событие, то исходом будет случайная величина, значениями которой будут являться множество состояний первого, второго, третьего типа.

Следовательно, для обеспечения функционирования СППР требуется несколько типов математических моделей, образующих состав их программного обеспечения [2]:

- 1) математические модели прогнозирования;
- 2) математические модели, соответствующие задачам управляемых объектов;
- 3) математические модели, обеспечивающие обобщение информации по определенным правилам.

К первому типу относятся модели не только математического, но и эвристического прогнозирования. Информация об этих моделях достаточно подробно изложена в литературе, поэтому в этой статье они рассматриваться не будут.

Ко второму типу моделей относятся:

- модели оценки возможностей управляемых объектов по выполнению ими типовых действий (по своему функциональному предназначению)
- модели оценки степени выполнения управляемыми объектами их действий;
- модели имитации и отображения процессов выполнения управляемыми объектами их типовых действий;
- модели оценки согласованности действий управляемых объектов по значениям параметров этих действий.

К третьему типу относятся:

- модели обработки информации о ресурсах системы (расчёты ресурсов, времени, издержек и др.);
- модели расчёта значений различных показателей;
- модели, обеспечивающие формирование нормативно-справочной информации.

Необходимо отметить, что модели третьего типа используются при определении значений входных параметров для моделей второго типа. На различных этапах процесса управления в органах управления ОТС каждой типовой задаче любого типового объекта рассматриваемой системы ставятся в соответствие следующие модели:

- модель генерации вариантов выполнения действия;
- модель оценки возможностей объекта по выполнению функционального действия;
- модель выбора рационального варианта выполнения действия из множества возможных вариантов;
- модель отображения процесса выполнения объектом действия.

Следует отметить, что необходимость создания предлагаемого методического аппарата определяется тем, что на сегодняшний день отсутствует единый подход к созданию унифицированного математического обеспечения при проектировании СППР различного назначения. В настоящей статье предлагается подход к разработке подобного аппарата, включающего в себя теоретические и практические положения, обеспечивающие разработку по единым правилам математических моделей второго и третьего типов. Содержание математических моделей определяется предметной областью ОТС, а результатом их разработки является математическое обеспечение, на основе которого создается прикладное программное обеспечение СППР.

1. Постановка задачи.

В настоящее время в качестве наиболее широко распространённого подхода к учёту неопределённости информации, используемого, в математическом обеспечении существующих и разрабатываемых информационных систем, является теория вероятностей [2, 3].

Результаты исследований функционирования сложных объектов [2, 3], показывают, что использование вероятностной меры для оценки возможностей выполнения действий, является некорректным, так как обычными для функционирования таких объектов являются условия нестатистической неопределённости. Это приводит к тому, что используемые математические модели неадекватно отображают не только условия обстановки, но и процессы функционирования рассматриваемых в данных моделях объектов ОТС.

Как недостаток применяемой вероятностной модели неопределённости, необходимо также отметить нецелесообразность использования вероятностных показателей для оценки возможностей выполнения нечётких событий, поскольку структура нечётких событий может меняться в зависимости от сложившихся условий обстановки, и накопление статистической информации по данным событиям с целью их формализованного описания и оценки затруднительно. Использование вероятностных мер при оценке возможностей выполнения нечётких событий в конечном итоге приводит к неадекватности описания процессов функционирования рассматриваемой ОТС в сложившихся или прогнозируемых условиях обстановки.

Анализ математических аппаратов показал, что в теории принятия решений для оценки качества принимаемых решений в условиях нестатистической неопределённости наиболее применим аппарат теории возможностей [5]. Этот аппарат позволяет оценить возможности выполнения объектом задачи как степени реализации его потенциальных возможностей в рассматриваемых условиях обстановки. Одно из преимуществ теории возможностей заключается в том, что она позволяет одновременно моделировать неточность (на основе теории нечётких множеств) и количественно характеризовать неопределённость (парой чисел «возможность – определённость») [5].

Оценка возможностей выполнения задачи состоит в сравнении значения показателя, характеризующего процесс её выполнения в реальных условиях с его значением в эталонных («идеальных») условиях. Использование аппарата теории возможностей требует меньшего объёма статистической информации для получения оценки, однако существующая теория возможностей не располагает методическим аппаратом, обеспечивающим практическую

разработку моделей оценки возможностей по выполнению задач организационно-техническими системами в различных предметных областях.

С учетом изложенного, сформулируем постановку задачи следующим образом: на основе теории возможностей требуется разработка методического аппарата, с помощью которого можно создавать модели оценки возможностей отдельных объектов ОТС по выполнению действий по своему функциональному предназначению.

2. Предлагаемый подход.

В рамках предлагаемого подхода под способом достижения результата понимается совокупность действий, выполняемая объектом ОТС и приводящих к намеченной цели. Иными словами, способ достижения результата – это технология выполнения действия объектом ОТС. В зависимости от условий неопределённости, в которых осуществляется выполнение действия, рассматриваются два способа оценки достижения требуемого результата: вероятностный и возможностный.

Рассматриваемый подход предполагает использование аппарата теории возможностей и имеет место в условиях нестатистической неопределенности, когда условия и способы выполнения действий объектами ОТС ситуативные. Возможность характеризует степень реализации объектом ОТС своих потенциальных возможностей по выполнению конкретного действия в рассматриваемой ситуации (условиях сложившейся обстановки), т.е. она характеризует, насколько выполнимо действие в рассматриваемых условиях обстановки. Как и объективная вероятность, возможность определяется с помощью соответствующей математической модели. В основе всех математических моделей оценки возможностей объектов по выполнению задач лежит расчёт текущих возможностей ($\tau_{\text{тек}}$) объекта по выполнению действия и их сравнение с его потенциальными возможностями ($\tau_{\text{ид}}$). В зависимости от физического смысла задачи могут иметь место следующие случаи расчёта возможностей

$$P(Z) = \tau_{\text{тек}} / \tau_{\text{ид}}, \text{ при } \tau_{\text{тек}} \leq \tau_{\text{ид}}, \quad (1)$$

$$P(Z) = \tau_{\text{ид}} / \tau_{\text{тек}}, \text{ при } \tau_{\text{тек}} \geq \tau_{\text{ид}}. \quad (2)$$

Предлагаемый подход к оценке возможностей отличается тем, что в нем рассматриваются не возможности достижения каких-то абстрактных событий, а возможности объектов ОТС по выполнению типовых действий, и является развитием подхода, предложенного в работе [4]. В рамках рассматриваемого подхода так же, как и в существующем, не сохраняется условие аддитивности

$$P(Z) + P(\bar{Z}) = 1. \quad (3)$$

Однако причиной этого является не предположение о слабой связи возможного и невозможного событий, а то, что в данном подходе рассматривается необходимость выполнения действия, а не необходимость события. Иными словами, для действия не может существовать противоположного действия и именно этим объясняется некорректность выражения (3) при применении к ОТС.

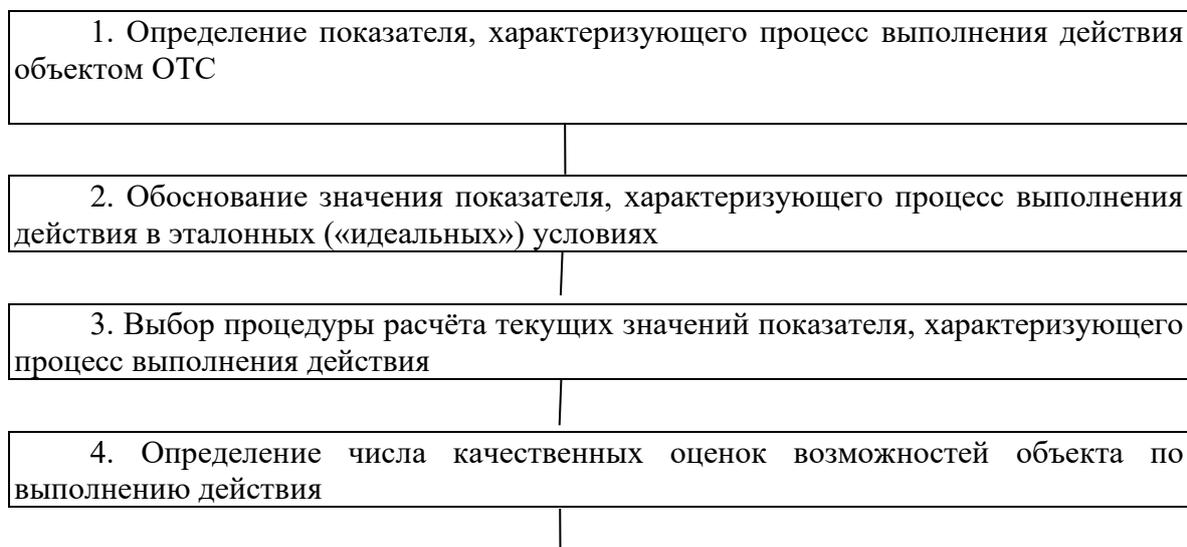
Для решения общей поставленной задачи последовательно рассмотрим следующие задачи частного характера:

- 1) выбор показателя оценки потенциальных и текущих возможностей объекта;
- 2) методику разработки правил определения идеальных условий выполнения действия объектом;
- 3) формулировка правил расчёта текущих возможностей объекта по выполнению типового действия;
- 4) построение логико-лингвистических шкал оценки возможностей объекта по выполнению типового действия.

Заметим, что выполнением последней из задач собственно построение соответствующей математической модели и завершается.

Остановимся на правилах выбора показателя оценки потенциальных и текущих возможностей объекта. В основе оценки возможностей объекта по выполнению типового действия лежит анализ соотношения значений показателя, характеризующего текущие и потенциальные возможности объекта по выполнению рассматриваемого действия. Выбор показателя определяется физическим смыслом действия, в частности, в качестве показателя могут рассматриваться время, расстояние, производственная мощность и т.п., используемых при обосновании решения на выполнение типового действия. Выбранному показателю должна соответствовать математическая модель расчёта его значений, которая должна отражать технологию выполнения соответствующего ей типового действия объекта. В состав математической модели расчета показателя оценки возможностей объекта по выполнению действия должны входить математические зависимости, обеспечивающие выполнение ряда расчётов на каждом технологическом этапе выполнения действия, например, расчёт времени выполнения технологического этапа, расчёт расхода ресурсов за технологический этап, расчёт издержек за технологический этап и т.д.

Рассмотрим теперь разработку математической модели расчёта значений показателя оценки возможностей объекта по выполнению действия. Методика построения математической модели оценки возможностей объекта по выполнению действия показана на рисунке 1.



5. Получение и обработка статистической информации о результатах выполнения действия (объективной или субъективной)

Рисунок 1 – Последовательность построения модели оценки возможностей выполнения объектом типового действия

Выбор процедуры расчёта текущих значений показателя заключается в выборе и обосновании математических зависимостей, которые позволяют получить значения показателя, характеризующего процесс выполнения действия, адекватные рассматриваемым условиям функционирования объекта. При выборе математических зависимостей принимается во внимание тот факт, что процесс выполнения действия состоит из технологических этапов (операций). Каждый такой этап подлежит оценке, и ему ставится в соответствие временной показатель. Значение показателя может быть нормативным, расчётным или комбинированным, сочетающим как нормативные, так и расчётные значения. Кроме количественной оценки возможностей объекта по выполнению действия может определяться также качественная оценка. Качественная оценка позволяет выделить диапазоны значений количественной составляющей и определить их физический смысл. Число качественных оценок (термов) определяется, как правило, экспертным путем.

Количественные и качественные возможностные оценки получаются после обработки статистической информации (объективной или субъективной) о результатах выполнения задачи, отображенной на шкалу значений объективного показателя [2, 3, 6]. ЛПР представляется количественная и качественная составляющие оценки возможности по выполнению задачи рассматриваемым объектом.

Таким образом, количественная составляющая определяется числовым значением показателя, характеризующего процесс выполнения действия. Качественная составляющая формируется в результате выделения экспертами интервалов значений данного показателя, соответствующих значениям лингвистической переменной, определяющей возможность выполнения рассматриваемого действия [2, 3].

Определим теперь правила определения эталонных («идеальных») условий выполнения действия объектом. В качестве эталонных рассматриваются условия, при которых отсутствуют какие-либо ограничения на выполнение объектом одной из множества его типовых действий. Выбор эталонных условий необходим для определения потенциальных возможностей объекта по выполнению его типового действия. Потенциальным возможностям соответствует максимальное или минимальное значение оценки показателя возможностей объекта по выполнению типового действия (определяется физическим смыслом действия). Эталонным условиям выполнения действия соответствуют конкретные значения переменных математической модели расчёта значений показателя. Эталонным условиям соответствуют также состояние объекта, при котором он полностью обеспечен ресурсами, необходимыми для выполнения задачи. Таким образом, для расчёта значений показателя, характеризующего потенциальные возможности объекта по выполнению типового действия, используется математическая модель расчёта значений этого показателя, причем значения переменных, рассматриваемых в этой модели, соответствует эталонным («идеальным») условиям.

Следующим этапом построения модели оценки возможностей средств отдельных объектов ОТС по выполнению действий по своему функциональному предназначению является формулировка правил расчёта текущих возможностей объекта по выполнению

типового действия. Расчёт таких возможностей проводится в условиях, определяемых текущей ситуацией (заметим, что текущие условия не могут быть лучше идеальных). Определение текущих условий может проводиться в процессе оценки текущей ситуации или моделирования этой ситуации в процессе планирования и оперативного управления. Результатом определения текущих условий является определение значений всех переменных, используемых при расчете текущего значения показателя оценки возможностей объекта по выполнению действия.

При определении текущих возможностей объекта по выполнению типового действия проводится расчёт следующих величин: время выполнения действия; ресурсов, необходимых для его выполнения; издержек, которые может понести объект при выполнении действия; количество объектов воздействия и степень оказанного воздействия за время выполнения действия; количество произведенной продукции за время выполнения действия. Расчёт перечисленных величин проводится по всем этапам действия с учётом параметров текущей ситуации.

Таким образом, математическая модель расчёта показателя оценки возможностей объекта по выполнению действия обеспечивает расчёт потенциальных и текущих возможностей объекта по выполнению рассматриваемого действия.

Рассмотрим теперь последнюю из поставленных частных задач – построение логико-лингвистических шкал оценки возможностей объекта по выполнению типового действия.

Результаты исследований содержания действий, выполняемых объектами ОТС в зависимости от способа оценки возможностей их выполнения, можно условно разделить на группы по характеру построения логико-лингвистической шкалы (ЛЛШ) [2, 3].

К *первой* группе можно отнести модели, в которых левая граница ЛЛШ равна 0, а правая максимальному значению показателя, характеризующего процесс выполнения действия. Правая граница характеризует потенциальные возможности объекта по выполнению действия в эталонных («идеальных») условиях обстановки. Например, возможность монтажа электрооборудования, кладка кирпича, штукатурка стен и т. д.

Вторую группу составляют модели, в которых правая граница определяется минимальным значением показателя, характеризующего процесс выполнения задачи, и соответствует определённому нормативному значению, полученному в наперёд заданных условиях. В качестве примера – это возможность развёртывания или свёртывания оборудования на строительной площадке и т. д.

К *третьей* группе предлагается отнести модели, в которых правая граница шкалы равняется минимальному значению показателя, характеризующего процесс выполнения задачи, и зависит от конкретных условий обстановки, то есть определяется в ходе принятия решения на выполнение задачи. Например, оценка возможностей по доставке строительных материалов на площадку.

В зависимости от физического смысла действия оценка возможностей объекта по его выполнению проводится посредством выражений (1) или (2). Отношение текущих возможностей к потенциальным возможностям (или наоборот) позволяет определить количественную оценку возможностей объекта по выполнению действия. Для большинства действий, выполняемых объектами ОТС, возможно использование качественных оценок, позволяющих учесть большое количество трудно формализуемых факторов, которые

невозможно учесть при разработке математической модели расчёта показателя оценки возможностей объекта по выполнению действия.

С целью реализации качественных оценок, предлагается включать в состав моделей оценки возможностей объектов по выполнению действий, процедуры, реализующие логико-лингвистические шкалы. Основными этапами разработки ЛЛШ являются:

а) определение множества качественных оценок возможностей объектов по выполнению действия;

б) сбор статистической информации о результатах выполнения действия объектом (сбор объективной информации или проведение экспертного опроса);

в) построение распределений функций принадлежности качественных оценок по интервалам шкалы измерения количественной оценки (обработка результатов сбора объективной информации или проведения экспертного опроса).

Заключение. Предложенный методический аппарат позволяет разработать комплекс методик оценки возможностей объектов ОТС по выполнению действий. Данный методический аппарат основан на методах теории возможностей, состоит из нескольких этапов решения частных задач и предназначен для разработки математических моделей функционирования объектов в СППР.

Список литературы

1. Балашов О.В., Букачев Д.С. Подход к разработке технологии автоматизированного планирования и оперативного управления организационно-техническими системами // Международный журнал информационных технологий и энергоэффективности. – 2020. – Т.5, №4 (18). – с. 21-31.
2. Балашов О. В. Теоретическое обобщение и развитие методов построения систем поддержки принятия решений для управления организационно-техническими системами военного назначения. – Смоленск: Изд-во. ВА ВПВО ВС РФ, 2006. – 118 с.
3. Балашов О. В., Борисов В. В., Круглов В. В. Вопросы управления организационно-техническими системами военного назначения. – Смоленск: Изд-во. ВА ВПВО ВС РФ, 2005. – 62 с.
4. Борисов А. Н., Крумберг О. А. Федоров И. П. Принятие решений на основе нечетких моделей: Примеры использования. – Рига: Зинатне, 1990. – 184 с.
5. Дюбуа Д., Прад А. Теория возможностей. Приложения к представлению знаний в информатике. М., Радио и связь, 1990. – 288 с.
6. Круглов В. В., Дли М. И. Интеллектуальные информационные системы: Компьютерная поддержка систем нечеткой логики и нечеткого вывода. – М.: Физматлит, 2002. – 256 с.

References

1. Balashov O.V., Bukachev D.S. Podhod k razrabotke tekhnologii avtomatizirovannogo planirovaniya i operativnogo upravleniya organizacionno-tekhnicheskimi sistemami // Mezhdunarodnyj zhurnal informacionnyh tekhnologij i energoeffektivnosti. – 2020. – Т.5, №4 (18). – pp. 21-31.

2. Balashov O. V. Teoreticheskoe obobshchenie i razvitie metodov postroeniya sistem podderzhki prinyatiya reshenij dlya upravleniya organizacionno-tekhnicheskimi sistemami voennogo naznacheniya. – Smolensk: Izd-vo. VA VPVO VS RF, 2006. – 118 p.
 3. Balashov O. V., Borisov V. V., Kruglov V. V. Voprosy upravleniya organizacionno-tekhnicheskimi sistemami voennogo naznacheniya. – Smolensk: Izd-vo. VA VPVO VS RF, 2005. – 62 p.
 4. Borisov A. N., Krumberg O. A., Fedorov I. P. Prinyatie reshenij na osnove nechetkih mo-delej: Primery ispol'zovaniya. – Riga: Zinatne, 1990. – 184 p.
 5. Dyubua D., Prad A. Teoriya vozmozhnostej. Prilozheniya k predstavleniyu znaniy v informatike. M., Radio i svyaz', 1990. – 288 p.
 6. Kruglov V. V., Dli M. I. Intellektual'nye informacionnye sistemy: Komp'yuternaya podderzhka sistem nechetkoj logiki i nechetkogo vyvoda. – M.: Fizmatlit, 2002. – 256 p.
-