



ISSN 1815-4840

Himičeskaâ tehnologiâ. Kontrol' i upravlenie
**CHEMICAL TECHNOLOGY.
CONTROL AND MANAGEMENT**

2020, №1 (91) pp.66-72

International scientific and technical journal
journal homepage: <https://uzjournals.edu.uz/ijctcm/>



Since 2005

UDC 519.71(575.1)

TECHNIQUES TO SOLVE DECISION-MAKING PROBLEMS**Tulkun Fayzievich Bekmuratov¹, Dilnoz Tulkunovna Muhamediyeva²**

^{1,2}*Scientific and Innovation Center of Information and Communication Technologies at Tashkent University of Information Technologies named after Muhammad al-Khwarizmi,
Address: Amir Temurstreet, 108, 100200, Tashkent city, Republic of Uzbekistan
E-mail: dilnoz134@rambler.ru, Phone: +998-95-195-47-52*

Abstract: Solving decision-making problems in poorly formalized systems only with the help of deterministic and probabilistic methods is insufficient. To do this, it is necessary to widely apply the methods of hybrid intelligent systems and, especially, the methods of “soft” calculations (SoftCalculation, SoftComputing) and the directions of ComputationalIntelligence — intelligent computing technologies that are emerging on this theoretical and methodological base. An immune - fuzzy algorithm for the synthesis of fuzzy inference systems (FIS) is proposed. A two-stage adaptive FIS synthesis algorithm is described. At the first stage, the initial fuzzy parameters are clustered in order to reduce the number of input parameters of the fuzzy rules, and at the second stage, fuzzy models (inference rules) of the Sugeno type are synthesized.

Keywords: immune algorithm, fuzzy set, monitoring, poorly formalized system, decision making.

Аннотация: Сист шакланган тизимларда қарор қабул қилиш масаласини фақат детерминанлашган ва эҳтимоллик усуллари билан ечиш етарли ҳисобланмайди. Бунинг учун гибрид интеллектуал тизим усуллари, айниқса “юмшоқ” ҳисоблаш усуллари (Soft Calculation, Soft Computing) ва ушбу назарий-услубий асосда вужудга келган йўналиш Computational Intelligence – интеллектуал ҳисоблаш технологияларини кенг қўллаш зарур. Норавиан хулосалар тизимини синтезлашнинг иммун-норавиан алгоритми таклиф қилинган. Норавиан хулосалар тизимини синтезлашнинг икки босқичли мослашувчан алгоритми тавсифланган. Биринчи босқичда норавиан қоидаларнинг қирувчи параметрлари сонини қисқартириш мақсадида берилган норавиан параметрлар кластеризацияси, иккинчи босқичда эса Сугэно типдаги норавиан моделлар (хулосалаш қоидалари) синтези амалга оширилган.

Таянч сўзлар: иммун алгоритмлар, норавиан тўпламлар, мониторинг, сунт шакланган тизимлар, қарор қабул қилиш.

Аннотация: Выявлена недостаточность решения задач принятия решений в слабоформализуемых системах с помощью детерминированных и вероятностных методов. Рекомендовано широко применять методы гибридных интеллектуальных систем и, особенно, методы «мягких» вычислений (SoftCalculation, SoftComputing) и зарождающиеся на этой теоретико-методологической базе направления ComputationalIntelligence – интеллектуальные вычислительные технологии. Предложен иммунно - нечеткий алгоритм синтеза систем нечеткого вывода (СНВ). Приведен двухэтапный адаптивный алгоритм синтеза СНВ. На первом этапе производилась кластеризация исходных нечетких параметров с целью сокращения числа входных параметров нечетких правил, а на втором - осуществлялся синтез нечетких моделей (правил вывода) типа Сугэно.

Ключевые слова: иммунный алгоритм, нечеткое множество, мониторинг, слабоформализуемая система, принятие решения.

1. Введение. В прикладных интеллектуальных системах мониторинга и поддержки принятия слабоформализуемых решений основными функциональными задачами являются: классификация, кластеризация, распознавание образов, прогнозирование, оценка состояний, выявление закономерностей между параметрами различных типов, оптимизация и принятие решений. Отличительными особенностями решаемых задач указанных типов являются: большая размерность, многокритериальность, наличие неопределенностей в исходной

информации и ситуации, динамичность изменения параметров внешней среды, предсказуемость которых, зачастую, является затруднительной или невозможной.

Эти особенности обуславливают использование для решения указанных задач, наряду с традиционными методами и средствами исследования операций и интеллектуального анализа данных (ИАД), интеллектуальных технологий, основанных на неформальных эмпирических знаниях экспертов и логических рассуждениях, а также на природно-биологических механизмах обучения, эволюции, адаптации и оптимизации [1-4]. Примерами таких интеллектуальных технологий, получивших наибольшее развитие и использование, являются экспертные системы (ЭС), технологии SoftComputing (SC), включающие нечеткие множества [1,2], нейронные сети (НС) [2,5-7] и генетические алгоритмы (ГА) [8,9]; эволюционные алгоритмы (Swarmintelligence – роевого интеллекта: муравьиные, пчелиные, стаи птиц и рыб) [10-11]. В последнее время получают развитие новые интеллектуальные технологии, основанные на природно-биологических механизмах – такие, как искусственные иммунные системы (ИИС) [12-13], называемые также иммунными вычислениями или иммунокомпьютингом (ИК). Из них наибольшее практическое применение получают ИИС. Поэтому представляет интерес исследование возможностей и определение основных направлений по совместному использованию интеллектуальных технологий для создания гибридных интеллектуальных, в том числе эволюционных, алгоритмов и программных средств, которые обеспечат более высокую эффективность решения исследуемых задач. Модели и алгоритмы нечеткого вывода занимают центральное место в задачах принятия решений, управления, прогнозирования, классификации, распознавания и машинного обучения в условиях неопределенности нечеткой природы. Алгоритмы нечеткого вывода реализуются системами нечеткого вывода (СНВ), ядром которых являются продукционные правила типа «Если *A*, То *B*» [2,4]. Эти правила формируются на основе лингвистических высказываний экспертов. В совокупности система таких правил отображает эвристическую модель исследуемых задач.

При решении прикладных задач в условиях неопределенности нечеткой, размытой (т.е. нестохастической) природы информацию, необходимую для построения и реализации системы принятия решений, можно разделить на две части: численную (количественную), и лингвистическую (качественную), поступающую от эксперта. Значительная часть нечетких систем использует второй вид знаний, чаще всего представляемых в форме базы нечетких правил, объединяемых в СНВ. Особенностью моделей таких задач является наличие в них нечеткой базы правил, описывающей структуру нечеткой модели задачи в целом и содержащих основные знания (экспертную информацию) о моделируемой системе, т.е. главную составляющую «интеллекта» рассматриваемой задачи. Поэтому корректное формирование нечеткой базы правил является очень важным условием эффективного решения поставленной задачи. Для решения задач такого класса широкое применение получают подходы, основанные на интеллектуальных технологиях «SoftComputing» [1-14].

Для того, чтобы такая модель была адекватна реальной ситуации, количество формируемых правил в СНВ обычно должно быть равно числу элементов входного вектора – условия *A* правила. Чрезмерно большое их число приводит к увеличению размерности и, соответственно, сложности решаемой задачи. Кроме того, объем имеющейся доступной информации, в том числе экспертной, о моделируемой системе часто оказывается недостаточным для построения более сложной и адекватной модели. Следует также учитывать наличие объективных ограничений на точность получения исходных данных. Поэтому при их формировании и оценке в процессе построения исследуемых моделей следует использовать принцип разумной полноты и точности. Это обуславливает важность анализа исходной информации, и использования процедур разумного сокращения количества правил.

С целью устранения этого недостатка предлагается комбинированный метод построения базы нечетких правил с использованием кластеризации на основе нечетких отношений и

иммунных алгоритмов. При построении процедур классификации и кластеризации были проанализированы и систематизированы различные критерии [2]. Достоинство этого метода заключается в его простоте и высокой эффективности. Кроме того, он позволяет объединять численную информацию, представленную в форме обучающих данных, с лингвистической информацией, имеющей вид базы правил, за счет дополнения имеющейся базы правилами, созданными на основе численных данных.

Предлагаемый алгоритм синтеза правил СНВ и настройки их параметров реализуется в два этапа.

На первом этапе осуществляется кластеризация (clustering) входных переменных правил. Каждый из сформированных кластеров будет объединять группу исходных входных переменных, сходных по определенным признакам. В этом случае каждый кластер может рассматриваться как обобщенное условие для соответствующего формируемого правила СНВ. Результатом этого этапа являются лингвистические правила СНВ с предварительными, грубыми значениями их параметров, описывающих математические модели функций принадлежности.

На втором этапе производится уточнение и настройка этих параметров с использованием иммунных алгоритмов обучения.

2. Методы исследования и полученные результаты

Рассматривается задача нечеткого логического вывода (НЛВ), описываемая нечеткой моделью Сугэно [2]:

$$\bigcup_{p=1}^{k_j} \left(\bigcap_{i=1}^n x_i = a_{i,jp} - \text{с весом } w_{jp} \right) \rightarrow y_j = f_j(x_1, x_2, \dots, x_n). \quad (1)$$

Здесь: $j = \overline{1, m}$ - номер правила; $a_{i,jp}$ - лингвистический терм, которым оценивается входная переменная x_i , $i = \overline{1, n}$ в строке-конъюнкции с номером jp ($jp = \overline{1, k_j}$) j -го правила; $w_{jp} = [0, 1]$ - весовой коэффициент правила с номером jp ; $y_j = f(x_1, x_2, \dots, x_n)$ - выход (заключение) нечеткого правила, который может быть описан, например, полиномом вида:

$$y_j = b_{j,0} + b_{j,1} \cdot x_1 + b_{j,2} \cdot x_2 + \dots + b_{j,n} \cdot x_n, \quad j = \overline{1, m}.$$

В модели (1) каждая входная переменная, оцениваемая соответствующим нечетким термом $a_{i,jp}$, описывается собственными функциями принадлежности (ФП) нечетким термам (например, квантификаторам типа ОН – очень низкий, Н - низкий, НС – ниже среднего, С - средний, ВС – выше среднего, В - высокий, ОВ – очень высокий). В общем виде ФП описываются выражением:

$$\tilde{\mu}^k(x_i^j) = \exp\left(-\frac{1}{2} \left(\frac{x_i^j - c_k^j}{s_k^j}\right)^2\right). \quad (2)$$

Известные алгоритмы кластеризации K-Means и Expectation Maximization [2,3] налагают ограничения на геометрию получаемых кластеров, требуя, в частности, возможности охвата каждого кластера отдельным выпуклым множеством. Такое ограничение налагается используемыми этими алгоритмами предположениями о существовании центров кластеров (K-Means) или функции плотности вероятности для каждого кластера с соответствующим значениями математического ожидания и дисперсии (Expectation Maximization). Поэтому эти алгоритмы не в состоянии адекватно разбить на кластеры невыпуклые множества, тем более вложенные структуры.

Эту проблему решает описываемый ниже алгоритм кластеризации конечного набора элементов произвольного метрического пространства на основании разбиения исходного множества на классы эквивалентности по нечеткому отношению. Он позволяет группировать в

кластеры элементы, между которыми есть последовательность «близких» друг к другу элементов, что также соответствует интуитивному представлению о группировке.

Алгоритм кластеризации реализуется в следующей последовательности.

Шаг 1. Разделение множества $\{X_1, X_2, \dots, X_N\}$ на непересекающиеся классы эквивалентности. Представим, что нам известно минимальное и максимальное значение каждой входной и выходной информации. По ним можно определить интервалы, в которых находятся допустимые значения. Для входного сигнала x_i такой интервал обозначим $[x_{iq}^-, x_{iq}^+]$. Если значения x_{iq}^- и x_{iq}^+ неизвестны, то можно воспользоваться обучающими данными и выбрать из них соответственно минимальное и максимальное значения.

Каждый определенный таким образом интервал разделим на K областей (отрезков), причем значение K для каждого сигнала подбирается индивидуально, а отрезки могут иметь одинаковую или различную длину.

Для оценки значений лингвистических переменных будем использовать указанную выше семиуровневую шкалу квантификаторов термов. Каждый из этих термов представляет нечеткое множество, заданное с помощью соответствующей функции принадлежности.

Используя операции \wedge (И - min) и \vee (ИЛИ - max), можно легко записать систему нечетких логических уравнений, связывающих функции принадлежности заключений НЛВ и входных переменных.

В общем случае каждая переменная входного вектора $X_q^* = (x_{1q}^*, \dots, x_{nq}^*)$ $q = \overline{1, N}$ имеет свои собственные функции принадлежности нечетким термам (ОН, Н, НС, С, ВС, В, ОВ), которые используются в правилах СНВ. Для упрощения моделирования будем использовать для всех переменных входного вектора только одну – гауссовую форму функций принадлежности.

Шаг 2. Построение нечетких правил на основе обучающих данных.

Вначале определим степени принадлежности обучающих данных к каждой области, выделенной на шаге 1. Эти степени будут выражаться значениями ФП нечетких множеств соответствующей группы данных.

Алгоритм идентификации и настройки параметров нечетких правил СНВ реализует второй этап общего алгоритма синтеза СНВ. Для идентификации параметров заключений в правилах (1) предлагается использовать следующий иммунно - нечеткий алгоритм:

1. Фиксируются значения входных и выходных параметров состояния объекта:

$$X_q^* = (x_{1q}^*, \dots, x_{nq}^*), \quad Y^* = \{y_q^*\} \quad q = \overline{1, N}.$$

2. Определяются значения функций принадлежности входных параметров $\mu^q(x_i^*)$ при фиксированных значениях вектора $X_q^* = (x_{1q}^*, \dots, x_{nq}^*)$.

3. Вычисляются значения функций принадлежности выходных параметров $\mu^{y_q}(x_{1q}^*, x_{2q}^*, \dots, x_{nq}^*)$ при фиксированных значениях вектора $X_q^* = (x_{1q}^*, \dots, x_{nq}^*)$.

4. Путем обучения с помощью иммунных алгоритмов подбираются такие значения параметров c_k^q, s_k^q функций принадлежности (2), которые минимизируют величину невязки $E_i = y_q^* - y_q$, т.е. различие между зафиксированными реальными значениями выходных параметров объекта (y_q^*) и значениями выходных параметров (y_q), которые формируются на выходе нечеткого вывода, аппроксимирующей правила (1). В результате определяется значение y_q^* , для которого:

$$\mu^{y_q^*}(x_1^*, x_2^*, \dots, x_n^*) = \max_{q=1, n} [\mu^{y_q}(x_1^*, x_2^*, \dots, x_n^*)].$$

Для обучения использован иммунный алгоритм.

Алгоритм обучения состоит из двух фаз. На первой фазе вычисляется модельное значение выхода объекта (y), соответствующее заданной архитектуре сети. На второй фазе

вычисляется значение невязки (E_i) и пересчитываются параметры функций принадлежности по следующему алгоритму.

1) генерация выборки экспериментальных данных (X_q, y_q) , $q=1, 2, \dots, N$, где $X_q = (x_{1q}, x_{2q}, \dots, x_{nq})$ – входной вектор в q -й паре и y_q – соответствующий выход.

2) нормирование значений параметров вектора $X_q = (x_{1q}, x_{2q}, \dots, x_{nq})$ на $[0, 1]$, где l – значение масштаба:

$$u_i^q = l \frac{x_{iq} - x^{\min}}{x^{\max} - x^{\min}}.$$

3) фаззификация нормированных значений $X_q = (x_{1q}, x_{2q}, \dots, x_{nq})$:

$$\mu^k(u_i^q) = \exp\left(-\frac{1}{2}\left(\frac{u_i^q - c_q}{s_q}\right)^2\right) \quad c_q = 0, 1, 2, \dots, l.$$

4) максимизация : $\mu^*(u_i^q) = \max_j \mu^k(u_i^q)$.

5) вычисление степени истинности выполнения заключения k -го правила:

$$SP^q = \mu^*(u_1^q) \cdot \mu^*(u_2^q) \dots \mu^*(u_n^q).$$

6) нормирование значений SP^q на $[0, 1]$:

$$\eta^q = l \frac{SP^q - SP^{\min}}{SP^{\max} - SP^{\min}}.$$

7) фаззификация значений η^q :

$$\mu^k(\eta^q) = \frac{1}{1 + \frac{(\eta^q - c_q)}{s_q}}.$$

8) нахождение максимума функции принадлежности: $\mu^*(\eta^q) = \max_j \mu^k(\eta^q)$.

9) формирование совокупности нечетких правил вида (1) для базы знаний:

$$\text{Если } x_1^1 = u_{11}^1 \cap x_2^1 = u_{21}^1 \dots \cap x_n^1 = u_{n1}^1 \text{ или}$$

$$x_1^2 = u_{11}^2 \cap x_2^2 = u_{21}^2 \dots \cap x_n^2 = u_{n1}^2 \text{ или}$$

$$-----$$

$$x_1^{k_q} = u_{11}^{k_q} \cap x_2^{k_q} = u_{21}^{k_q} \dots \cap x_n^{k_q} = u_{n1}^{k_q}$$

$$\text{То } y_q = b_{q0} + b_{q1} x_1^q + \dots + b_{qn} x_n^q, \quad q = \overline{1, N}.$$

Необходимо найти такие значения элементов матрицы коэффициентов заключений правил

$$B = \begin{pmatrix} b_{10} & b_{11} & \dots & b_{1n} \\ b_{20} & b_{21} & \dots & b_{2n} \\ - & - & - & - \\ b_{N0} & b_{N1} & \dots & b_{Nn} \end{pmatrix},$$

которые обеспечивают минимум квадратичной невязки:

$$E = \sum_{q=1}^N (y_q - y_q^f)^2 \rightarrow \min,$$

где y_q^f - результат вывода по нечеткой модели, y_q - эталонное значение выхода объекта.

Пусть задана выборка нечетких экспериментальных данных (X_r, y_r) , $r = \overline{1, M}$; здесь $X_r = (x_{r1}, x_{r2}, \dots, x_{rn})$ - входной n -мерный вектор и $y_r = (y_1, y_2, \dots, y_M)$ - соответствующий ему выходной вектор.

В общем виде требуется построить модель, основанную на нечетких правилах вывода (1)

$$\bigcup_{p=1}^{k_j} \left(\bigcap_{i=1}^n x_i = a_{i,jp} - \text{с весом } w_{jp} \right) \rightarrow y_j = b_{m0} + b_{m1}x_1^j + \dots + b_{mn}x_n^j.$$

В процессе построения модели нужно найти такие значения коэффициентов правил

$$B = (b_{ij}), i = \overline{1, m}, j = \overline{0, n},$$

при которых достигается минимум следующего выражения:

$$\sum_{r=1}^M (y_r - y_r^f) \rightarrow \min ,$$

где y_r^f - результат нечетких правил вывода с параметром B в r -й строке выборки (X_r) .

Входной матрице X_r соответствует следующий результат нечеткого вывода:

$$y_r^f = \frac{\sum_{i=1}^m \mu_{d_i}(X_r) \cdot d_i}{\sum_{i=1}^m \mu_{d_i}(X_r)} . \tag{3}$$

Здесь: $d_i = b_{i0} + b_{i1}x_{r1} + b_{i2}x_{r2} + \dots + b_{in}x_{rn}$ - выход i -правила; $\mu_{d_i}(X_r)$ - функция принадлежности, соответствующая каждой экспериментальной информации:

$$\begin{aligned} \mu_{d_j}(X_r) &= \mu_{i1}(x_{r1}) \cdot \mu_{i1}(x_{r2}) \cdot \mu_{i1}(x_{r3}) \cdot \dots \cdot \mu_{i1}(x_{rn}) \vee \\ &\vee \mu_{i2}(x_{r1}) \cdot \mu_{i2}(x_{r2}) \cdot \mu_{i2}(x_{r3}) \cdot \dots \cdot \mu_{i2}(x_{rn}) \vee \\ &\dots \dots \dots \vee \\ &\vee \mu_{im}(x_{r1}) \cdot \mu_{im}(x_{r2}) \cdot \mu_{im}(x_{r3}) \cdot \dots \cdot \mu_{im}(x_{rn}) . \end{aligned}$$

Функции принадлежности элемента x_i терму a_i^{jp} имеет следующий вид:

$$\mu^{jp}(x_i) = \exp \left(- \frac{1}{2} \left(\frac{a_i^{jp} - b_i^{jp}}{c_i^{jp}} \right)^2 \right) .$$

где b_i^{jp}, c_i^{jp} - параметры функции принадлежности.

Для решения задачи (2) используем иммунный алгоритм.

Иммунные алгоритмы (ИА) оптимизации содержат следующие операторы: клонирование, мутация, старение и селекция.

Настройка параметров функций принадлежности $B = (b_1, b_2, \dots, b_q)$ и $C = (c_1, c_2, \dots, c_q)$ - и веса правил $W = (w_1, w_2, \dots, w_N)$ состоит из следующих этапов.

Сведем неизвестные параметры W, B, C в один вектор [12,13]:

$$\begin{aligned} S &= (W, B, C) = (w_1, w_2, \dots, w_N, \\ &b_{11}, c_{11}, \dots, b_{l_1}, c_{l_1}, b_{n1}, c_{n1}, \dots, b_{n l_1}, c_{n l_1}) \end{aligned}$$

где N - общее число строк в нечеткой базе знаний; l_i - количество термов-оценок входной переменной λ_i , $l_1 + l_2 + \dots + l_n = q$, $i = \overline{1, n}$; q - общее число термов;

3. Заключение

Таким образом, показана целесообразность объединения метода нечеткого вывода и иммунных алгоритмов в задачах с параметрами, содержащими неопределенности различного типа, а также в задачах, для которых характерны интуитивные решения [15,16]. Предложенный метод позволяет существенно улучшить качество решения задач мониторинга с нечетко заданными параметрами и критериями. В дальнейшем планируется изучение различных

гибридных методов применительно к задачам мониторинга, а также методов автоматического формирования базы нечетких правил. Это позволит существенно повысить эффективность решений задач рассматриваемого класса.

References:

1. Zade L.A. Ponyatie lingvisticheskoy peremennoy i ego primeneniye k prinyatiyu priblijennoy resheniy. - M.: Mir, 1976. -165 s.
2. Aliev R.A., Aliev R.R. Teoriya intellektual'ny'h sistem i ee primeneniye. - Baku, Izd-vo CHashy'ogly', 2001. - 720 s.
3. SHtovba S.D. "Vvedeniye v teoriyu nechetkiy mnojstv i nechetkuyu logiku". <http://www.matlab.exponenta.ru>.
4. Bekmuratov T.F., Muhamedieva D.T., Bobomuratov O.J. Model prediction of yield initial conditions. Ninth International Conference on Application of Fuzzy Systems and Soft Computing. ICAFS – 2010. . Edited by R.A. Aliev, K.W. Bonfig, M. Jamshidi, W. Pedrycz, I.B. Turksen. b – QuadratVerlag, Prague, Czech Republic. August 26-27, 2010. – pp. 321-328.
5. Hopfield J.J., Tank D.W. "Neural" computation of decisions in optimization problems // Biological Cybernetics, 1985, vol. 52, no. 3, pp. 141-152.
6. Hung D.L. Wang J. Digital hardware realization of a recurrent neural network for solving the assignment problem // Neurocomputing, 51, 2003, pp. 447-461.
7. Holland J. H. Adaptation in natural and artificial systems. An introductory analysis with application to biology, control, and artificial intelligence.— London: Bradford book edition, 1994 —211 p.
8. Bryant K., Benjamin A., Genetic Algorithms and the Traveling Salesman Problem, Department of Mathematics, HarveyMudd College, 2000.
9. G.K., Mahotilo K.V., Petrashev S.N., Sergeev S.A., Geneticheskie algoritmy', iskusstvenny'e neyronny'e seti i problemy' virtual'noy real'nosti, Har'kov, OSNOVA, 1997. - 112s.
10. Cantu-Paz E., Efficient and Accurate Parallel Genetic Algorithms, Lawrence Livermore National Lab, 2000.
11. Dorigo Marco, Stutzle T. Ant colony optimization. – Cambridge: The MIT Press, 2004. – 305 p.
12. Dasgupta D. Iskusstvenny'e immunny'e sistemy' i ih primeneniye.- Fizmatlit.- 2006.-344 s.
13. Dasgupta D., Artificial Immune Systems and Their Applications, Springer-Verlag, 1998.
14. Muhamedieva D.T. Immunny'y algoritm resheniya zadach klassifikatsii i prognozirovaniya v nechetkoy srede // Vestnik TUIT. Vy'p.1. -Tashkent. 2012. -S.38-41.
15. Muxamediyeva D.T. Problems of constructing models of intellectual analysis of states of weakly formalizable processes // IOP Conf. Series: Journal of Physics: Conf. Series 1210 (2019) 012101 doi:10.1088/1742-6596/1210/1/012102
16. Muxamediyeva D.T. Structure of fuzzy control module with neural network //International Journal of Mechanical and Production Engineering Research and Development (IJMPERD) ISSN (P): 2249-6890; ISSN (E): 2249-8001 Vol. 9, Issue 2, Apr 2019, pp.649-658 DOI : 10.24247/ijmperdapr201965.